

NEURAL MODELING IN SOLVING SOME PREDICTION PROBLEMS OF AGRICULTURAL ENGINEERING

Summary

Forecasting process has practical applications in a wide range of human activity, including agriculture. The quality of such predictions is important for subsequent phases occurring in the chain of production and distribution of agricultural products. The purpose of this work, was to design, to do, and to test the informational system, which is based in technology of the artificial network of neurons, which allows to predict the size of the crops, and the contents of the starch in the potatoes bulb on the basis of the chosen agro-technical factors.

MODELOWANIE NEURONOWE W ROZWIĄZYWANIU WYBRANYCH PROBLEMÓW PREDYKCYJNYCH INŻYNIERII ROLNICZEJ

Streszczenie

Proces prognozowania ma praktyczne zastosowanie w szerokim zakresie działalności ludzkiej, w tym również w rolnictwie. Jakość takich prognoz ma istotne znaczenie dla kolejnych etapów występujących w łańcuchu produkcyjno-dystrybucyjnym płodów rolnych. Celem pracy było wytworzenie neuronowego systemu informatycznego, pozwalającego na dokonanie prognozy wielkości plonu oraz zawartość skrobi w bulwach ziemniaków, na podstawie wybranych czynników agrotechnicznych.

1. Wprowadzenie

Wiele procesów i zjawisk, zachodzących w rolnictwie, ma charakter nieliniowy, przez co relacje w nich zachodzące są skomplikowane i niełatwe do formalnego opisu. W takich sytuacjach, często trudne jest stosowanie metod tradycyjnych więc coraz częściej proponowane jest w zamian wykorzystanie nowoczesnych technik informatycznych, a w szczególności procedur bazujących na metodach sztucznej inteligencji. Dynamiczny postęp technologii komputerowych i informacyjnych stwarza nowe możliwości oraz kierunki rozwoju wielu dziedzin nauki, w tym również inżynierii rolniczej [1] Wykorzystywane w technikach komputerowych metody numeryczne, coraz efektywniej wspomagają obliczenia analityczne. Dzieje się tak przede wszystkim za sprawą nowych możliwości uwzględnienia większej złożoności oddziaływań oraz szybkości przetwarzania.

Alternatywnym podejściem do klasycznego opisu oraz analizy systemów empirycznych są nowoczesne techniki neuronowe. Sztuczne sieci neuronowe stanowią intensywnie rozwijającą się gałąź wiedzy. Główną zaletą modeli neuronowych jest ich zdolność do uogólniania nabytej podczas uczenia wiedzy. Obszary zastosowania, w których modele neuronowe dobrze się sprawdzają to m. in. prognozowanie, rozpoznawanie, klasyfikowanie oraz diagnozowanie. W odróżnieniu od tradycyjnych metod przetwarzania informacji, jakie oferują komputery szeregowo realizujące wcześniej napisany algorytm, podstawą tworzenia a następnie działania sieci neuronowych są tzw. algorytmy uczące. Zastosowanie zaawansowanych optymalizacyjnych algorytmów uczących umożliwia zaprojektowanie odpowiedniej struktury sieci neuronowej oraz dobór jej parametrów, dopasowanych do konkretnego problemu podlegającego rozwiązaniu [2]. W ostatnich latach można zaobserwować wzrost zainteresowania sztucznymi sieciami neuronowymi. Jest to wynik przydatności modeli neuronowych do realizacji wielu praktycznych zadań. Sztuczne sieci neu-

ronowe są z powodzeniem stosowane w szerokim zakresie problemów z różnych dziedzin życia i nauki, takich jak: medycyna, finanse, geologia, fizyka czy rolnictwo. Zastosowań tych może być znacznie więcej, ponieważ sieci neuronowe mogą być wykorzystane wszędzie tam, gdzie pojawia się problem związany z przetwarzaniem i analizą danych, predykcją, klasyfikacją czy sterowaniem [4].

Celem niniejszej pracy było zaprojektowanie, wykonanie i przetestowanie systemu informatycznego, opartego na technologii sztucznych sieci neuronowych, pozwalającego prognozować wielkość plonu oraz zawartość skrobi w bulwach ziemniaków na podstawie znajomości wybranych czynników agrotechnicznych, takich jak:

- średnia roczna temperatura,
- średnia roczna wartość opadów,
- odmiana ziemniaków,
- średnia wartość opadów w okresie agrotechnicznym,
- średnia wartość temperatury w okresie agrotechnicznym.

Dodatkowym celem było określenie poziomu istotności poszczególnych czynników agrotechnicznych na prognozowane wielkości. Dane empiryczne do budowy neuronowych modeli predykcyjnych pozyskane zostały z doświadczeń prowadzonych w Stacji Doświadczalnej Oceny Odmian w Kościelcu.

2. Materiał badawczy

Dane wykorzystane do uczenia sieci neuronowej pochodzą ze Stacji Doświadczalnej Oceny Odmian w Kościelcu, która reprezentuje warunki klimatyczne i glebowe byłego województwa Konińskiego (za wyjątkiem gminy Witkowo i części gminy Chodów). Stacja prowadzi 2 rodzaje działalności:

- badanie wartości gospodarczej odmian w celu ich zarejestrowania,
- porejestrowe doświadczalnictwo odmianowe (PDO).



Rys. 1. Pole doświadczalne Stacji Oceny Odmian w Kościelcu
 Fig. 1. Kościelec field experimental Station in the Variety Assessment

Badanie wartości gospodarczej odmian polegają na tym, że nowe wytworzone przez hodowców i przyjęte do księgi zgłoszeń rody biorą udział w doświadczeniach porównawczych w SDPO rozmieszczonych na terenie całego kraju. W doświadczeniach biorą udział czołowe odmiany zarejestrowane jako odmiany wzorcowe. Po trzy letnich badaniach, jeśli okaże się, że badany ród jest lepszy pod względem niektórych cech gospodarczych od przyjętego wzorca, otrzymuje nazwę odmianową. Na tym etapie badań zwykle odpada około 60-70% rodów. Badanie oceny odmian uniemożliwiają wprowadzenie do szerokiej produkcji rodów mało wartościowych. Ponadto prowadzone są badania trwałości i wyrównania odmian.

Porejestrone doświadczalnictwo odmianowe (PDO) prowadzone jest w SDPO rozmieszczonych na terenie całego kraju i zgrupowanych w wojewódzkie jednostki organizacyjne. Ich celem jest badanie wartości odmian już wcześniej zarejestrowanych. Badanie przeprowadzane są zwykle na 2 poziomach agrotechnicznych:

- zwykłym,
 - intensywnym.
- Poziom intensywny od zwykłego różni się:
- zwiększonym nawożeniem azotowym o 40 kg/ha,
 - dwukrotnym opryskiem fungicydami. Pierwszy oprysk przeprowadza się w fazie od drugiego kolanka do liścia flagowego (łamlivość podstawy źdźbła, mączniaki). Drugi oprysk odbywa się w fazie kłoszenia (rdza, septorioza),
 - opryskiem regulatorem wzrostu,
 - opryskiem pożywkami.

W Unii Europejskiej na podstawie tego typu badań opracowuje się dla poszczególnych gatunków roślin tzw. listy odmian preferowanych. Badania PDO pozwalają w bliższy sposób określić wymagania danej odmiany. Na terenie naszego kraju działa 51 oddziałów SDPO. Koordynacją pracy i oceną wyników doświadczeń zajmuje się Centralny Ośrodek Badania Odmian Roślin Uprawnych w Słupi Wielkiej koło Środy Wielkopolskiej.

3. Wpływ wybranych czynników meteorologicznych na wielkość plonu oraz zawartość skrobi w bulwach ziemniaka

Ziemniak to roślina okopowa, samopylna, jednoroczna bylina z rodziny psiankowatych (*Solanaceae*). Należy do grupy najważniejszych roślin jadalnych świata. Powszechnie uprawiany jest w klimacie umiarkowanym, rzadziej w ciepłym, dlatego nadmiernie wysoka temperatura i opady wpływają ujemnie na jego rozwój, plonowanie i cechy jakościowe bulw. Ważnymi czynnikami, wpływającymi pozytywnie na wielkość plonów, są również długość dnia i natężenie światła.

Negatywny wpływ, na wielkość zbiorów, wywiera nieodpowiednia temperatura w okresie kiełkowania i wzrostu części nadziemnej rośliny oraz bulw. W czasie sadzenia temperatura gleba powinna wynosić około 8°C, ponieważ niższa temperatura opóźnia i przedłuża okres wschodów. Część nadziemna (nać) rośnie intensywnie w temperaturze około 20°C, natomiast bulwy wymagają temperatury niższej (15-18°C). Wynika z tego, że wysokie temperatury są bardzo pożądane w okresie poprzedzającym wiązanie się bulw, natomiast w czasie ich intensywnego wzrostu gleba powinna być ocieniona, aby nie nastąpił nadmierny wzrost jej temperatury, ponieważ ma to ujemny wpływ na wysokość plonu.

Podobnie jak temperatura, również intensywność oraz obfitość opadów, istotnie oddziałują na wielkość zbiorów ziemniaków, gdyż pomiędzy opadami a temperaturą zachodzi korelacja. Największe zapotrzebowanie rośliny na wodę, w okresie wegetacji, przypada na lipiec i sierpień. Wysokie opady w znacznym stopniu łagodzą ujemny wpływ wysokiej temperatury, a układ temperatur zmienia kierunek oddziaływania opadów na kształtowaniu się plonów. Nieodór, podobnie jak nadmiar wody, ogranicza wysokość plonowania. Suma opadów, którą można uznać za zbyt niską lub zbyt wysoką, zależy od temperatury. Nawet bardzo obfite opady w latach ciepłych nie zmniejszają plonów w

sposób istotny. Natomiast w latach umiarkowanie ciepłych wyraźnie zaznacza się pewien optymalny poziom opadów, po przekroczeniu którego dochodzi do zmniejszenia plonowania.

Wpływ niedoboru wody na rozwój i wielkość zbiorów ziemniaków zależy od fazy ich wzrostu. Susza w okresie wiązania bulw wpływa na ograniczenie ich liczby oraz może powodować wtórną tuberyzację w późniejszym okresie. Niedobór opadów w okresie wegetacji ogranicza tempo przyrostu masy bulw, co może prowadzić do ich zdrobnienia. Występujące po okresie suszy opady przyczyniają się do wtórnego przyrostu bulw, które ulegają zniekształceniom (dzieciuchowatości).

Różnego rodzaju odmiany ziemniaka charakteryzują się dużą zmiennością zawartości skrobi spowodowaną zmieniającymi się warunkami atmosferycznymi w czasie ich wegetacji. Największy wpływ wywiera wielkość opadów w okresie agrotechnicznym. Duży ich poziom powoduje znaczne ograniczenie ilości skrobi, jaka jest gromadzona w bulwie ziemniaka i wynosi w granicach od 12-15%. Natomiast w latach, w których notowano niższe opady zawartość skrobi w bulwach ziemniaków wynosiła od 13-18%. [3].

4. Metodyka badawcza

Zakres pracy obejmował następujące etapy:

- pozyskanie danych empirycznych z SDOO w Kościelcu,
- wytworzenie zbioru danych do uczenia sztucznych sieci neuronowych (na podstawie pozyskanych danych),
- wygenerowanie predykcyjnych modeli neuronowych,
- przekonwertowanie kodu wytworzonych modeli neuronowych na kod języka C#,
- zaprojektowanie oraz wytworzenie aplikacji „Ziemniak” do prognozowania plonu ziemniaków oraz zawartości skrobi wraz z zaimplementowanym w niej kodem sieci neuronowych,
- weryfikacja i walidacja systemu komputerowego „Ziemniak”.

Jako cechy reprezentatywne dla procesu prognozowania plonu oraz zawartości skrobi w ziemniakach uznano pięć zmiennych wejściowych (cztery ciągle zmienne liczbowe oraz jedna wielostanowa zmienna nominalna):

- średnia roczna temperatura powietrza,
- średnie roczne opady atmosferyczne,
- średnia temperatura okresu agrotechnicznego,
- odmiana ziemniaków (wielostanowa zmienna nominalna),
- średnie opady okresu agrotechnicznego.

Wytworzenie zbioru uczącego oparto na danych empirycznych (rys. 2) pozyskanych z doświadczeń przeprowadzonych w Stacji Doświadczalnej Oceny Odmian w Kościelcu. Finalna postać zbioru danych obejmowała 291 przypadków (rys. 2). Zgodnie z przyjętą standardową procedurą zbiór ten został podzielony, odpowiednio w stosunku 2:1:1 (zbiory: uczący, walidacyjny oraz testowy).


Wykorzystując pakiet Sieci Neuronowe zaimplementowany w komercyjnym systemie informatycznym STATISTICA v. 7.1 oraz dane uczące (rys. 2), wygenerowano dwa modele neuronowe, przeznaczone (odpowiednio) do krótkoterminowego prognozowania wielkości plonu oraz zawartości skrobi. Najlepsze wyniki predykcji plonu otrzymano w oparciu o wygenerowaną topologię sieci neuronowej typu RBF (*Radial Basis Function*) o 5 zmiennych wejściowych 23 neuronach ukrytych oraz 1 neuronie wyjściowym (rys. 3).

Zmienne wyjściowe

| Nazwa odmiany | plon dt/ha | %skrobi | średnia roczna temp | średnie roczne opady | średnia temp okr. | Agro | średnie opady okr. | Agro. |
|---------------|------------|---------|---------------------|----------------------|-------------------|--------|--------------------|--------|
| ACCENT | 403 550 | 15 000 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| BAIRD | 308 120 | 12 000 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| DENAR | 415 720 | 15 800 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| FELKA | 341 370 | 15 800 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| FRESCO | 338 950 | 16 500 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| KARATOP | 326 210 | 13 800 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| LORD | 378 620 | 13 800 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| MOLLI | 365 620 | 14 800 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| RUTA | 355 050 | 15 600 | 9 383 | 46 317 | 16 960 | 50 940 | 16 960 | 50 940 |
| ANIA | 422 760 | 15 100 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| ANIELKA | 376 640 | 18 800 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| REATA | 490 700 | 13 500 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| BRYZA | 236 990 | 16 500 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| DANUSIA | 309 580 | 18 800 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| RYBITWA | 287 740 | 15 200 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| RYWAL | 384 580 | 18 800 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| SALTO | 315 950 | 14 800 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| SVRENA | 326 830 | 15 800 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| WAWRZYN | 438 660 | 13 000 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| WOLFRAM | 416 020 | 17 000 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| ZEUS | 343 750 | 15 400 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| EZURA | 506 700 | 16 500 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| GROT | 227 710 | 18 500 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| HINGA | 317 230 | 22 200 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| JASIA | 300 890 | 18 900 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| KLEPA | 249 420 | 18 800 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |
| KCYNIA | 284 680 | 20 100 | 9 383 | 46 317 | 18 020 | 62 420 | 18 020 | 62 420 |


Zmienne wejściowe

Rys. 2. Fragment zbioru uczącego
Fig. 2. Fragment of learning files



Rys. 3. Struktura sieci neuronowej typu RBF do predykcji plonu
Fig. 3. Structure of RBF neural networks for yield prediction

Najlepsze wyniki prognozowania zawartości skrobi otrzymano również w oparciu o topologię sieci typu RBF (*Radial Basis Function*). W tym przypadku jej strukturę stanowiły tylko 4 zmienne wejściowe (średnie opady okresu agrotechnicznego okazały się cechą nieistotną: analiza wrażliwości wytworzonej sieci neuronowej na tę zmienną wykazała jej pomijalnie małą range), 90 neuronów ukrytych oraz 1 neuron wyjściowy (rys. 4).



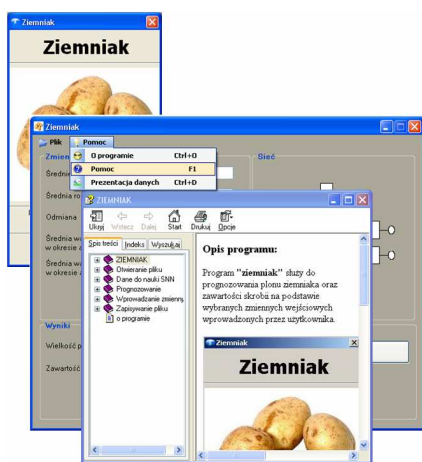
Rys. 4. Struktura sieci neuronowej typu RBF do predykcji skrobi
Fig. 4. Structure of RBF neural networks for starch prediction

5. System informatyczny „Ziemniak”

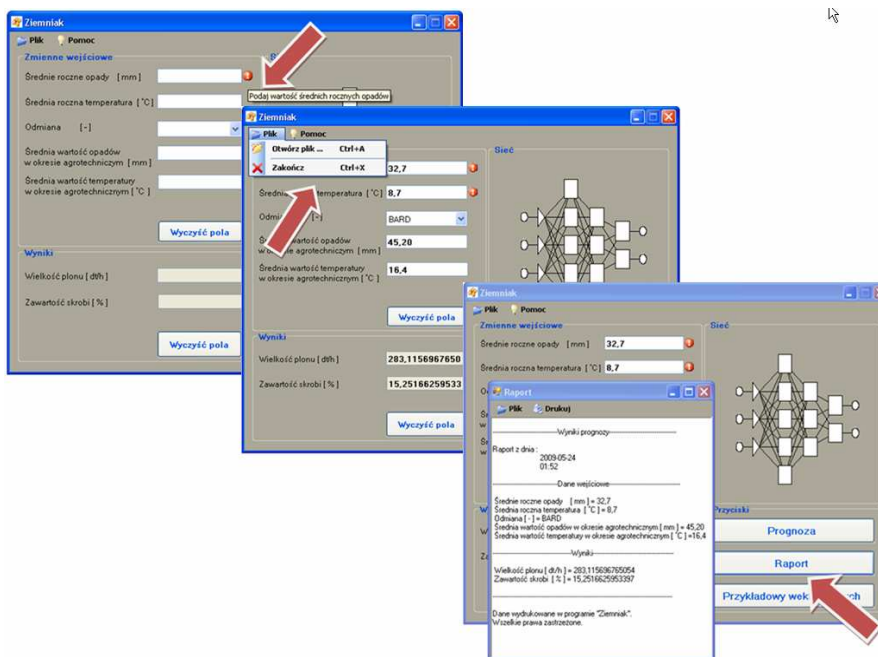
Mając na uwadze wsparcie procesów decyzyjnych zachodzących w produkcji ziemniaków zaprojektowano oraz zbudowano system informatyczny „Ziemniak”, w którym zaimplementowano wytworzone modele neuronowe. Aplikacja ta, w zamierzeniu autorów, winna stanowić funkcjonalne narzędzie predykcyjne, dedykowane dla producentów ziemniaków i przeznaczone do krótkoterminowego przewidywania wielkości plonów oraz poziomu ilości skrobi w ziemniakach.

Rdzeniem aplikacji są, wyżej wskazane, nauczone sieci neuronowe. Kod źródłowy w języku C++ uzyskany poprzez Generator Kodu zaimplementowany w pakiecie STATISTICA v. 7.1 zawiera wszystkie informacje niezbędne do prawidłowego działania wygenerowanych sieci. Do wytworzenia pozostałej części aplikacji użyte zostały standardowe składniki oraz narzędzia dostępne w MS Visual Studio 2008.

Program komputerowy „Ziemniak” oparto na sześciu formularzach. Jeden z nich, będący oknem głównym, odpowiedzialny jest za komunikację z użytkownikiem.



Rys. 5. Okno główne programu z menu
Fig. 5. The main menu window



Rys. 6. Wybrane elementy pracy aplikacji „Ziemniak”
Fig. 6. Selected elements of the application „Ziemniak” working

Oprócz sześciu formularzy w programie użyto następujące kontrolki: Button, Label, TextBox, pictureBox, menuStrip, groupBox, linkLabel, printDocument, printDialog, printPreviewDialog, pageSetupDialog, errorProvider, openFileDialog oraz openFileDialog. Wybrane okna neurologowego systemu predykcyjnego „Ziemniak” pokazano na rys. 5 oraz 6.

6. Wnioski

1. Wytworzony system komputerowy „Ziemniak” jest efektywnym i wygodnym narzędziem informatycznym, pozwalającym na dokonanie krótkoterminowej prognozy wielkości plonu oraz zawartość skrobi w bulwach ziemniaków na podstawie wybranych czynników agrotechnicznych.
2. Proponowany system informatyczny spełnia założenia funkcjonalne postawione w fazie określania wymagań oraz wszelkie wymogi inżynierii oprogramowania.
3. Na podstawie przeprowadzonych doświadczeń stwierdzono, iż techniki neuronowe są właściwym narzędziem predykcyjnym, umożliwiającym wytworzenie modelu do prognozy plonu oraz zawartość skrobi w bulwach ziemniaków.
4. Najlepsze wartości parametrów charakteryzujących jakość wytrenowanych sieci, uzyskano dla sztucznych sieci neuronowych typu RBF. Fakt ten sugeruje nieliniowy charakter badanego problemu.

7. Literatura

- [1] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. Wydawnictwo Uniwersytetu Przyrodniczego, Poznań 2008.
- [2] Ossowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006.
- [3] Niewiadomski W. (praca zbiorowa): Podstawy Agrotechniki. Państwowe Wydawnictwo Rolnicze i Leśne, Warszawa 1983.
- [4] Niedbała G., Przybył J., Boniecki P., Sęk T.: Analiza założeń dla modelowania plonu buraka cukrowego z wykorzystaniem sztucznych sieci neuronowych. Inżynieria Rolnicza 2005, Vol. 2 (62), s. 123-130.