

Gniewko Niedbała, Jacek Przybył, Piotr Boniecki, Tadeusz Sęk
Instytut Inżynierii Rolniczej
Akademia Rolnicza w Poznaniu

ANALIZA ZAŁOŻEŃ DLA MODELOWANIA PLONU BURAKA CUKROWEGO Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH

Streszczenie

Do planowania plonu roślin, w tym plonu buraka cukrowego, wykorzystuje się modele prognostyczne. Istniejące modele mają zastosowanie zarówno w skali mikro – dla gospodarstwa, jaki i makro – dla regionu, czy kraju. Te modele, najczęściej zaimplementowane w programach komputerowych, ze względu na dużą liczbę danych wejściowych, są raczej niedostępne dla plantatora buraka cukrowego i rolniczych służb doradczych. Dlatego w pracy podjęto próbę opracowania własnego modelu plonu buraka cukrowego, opartego na metodach sztucznej inteligencji, przy wykorzystaniu możliwie niewielkiej liczby danych wejściowych. Założono, że dane wejściowe do modelu powinny stanowić podstawowe czynniki charakteryzujące siedlisko, użyte środki produkcji i przebieg warunków pogodowych.

Słowa kluczowe: burak cukrowy, predykcja plonu, sztuczne sieci neuronowe

Wprowadzenie

Proces produkcji buraka cukrowego tworzą wpływające na siebie fazy rozwoju roślin, uzależnione od warunków siedliska, użytych środków produkcji i przebiegu warunków pogodowych. Układ tych czynników wpływa na plon masy korzeniowej i plon cukru. Ponieważ wielkość produkcji cukru podlega obwarowaniom ustawowym, z czym związana jest zarówno opłacalność uprawy buraka, jak i rentowność cukrowni, istotnego znaczenia nabiera prawidłowe określenie oczekiwanego plonu korzeni i ilości wyprodukowanego z nich cukru. W tym celu stosuje się różne techniki modelowania plonu buraka. Modele prognostyczne zawierają dane wejściowe, których liczba przeważnie jest znaczna. To istotnie ogranicza dostępność tych modeli dla plantatora i rolniczych służb doradczych. Dlatego w pracy podjęto próbę opracowania własnego modelu plonu buraka cukrowego, opartego na metodach

sztucznej inteligencji, przy wykorzystaniu możliwie niewielkiej liczby danych wejściowych. Wykorzystanie technik neuronowych pozwala na wskazanie najistotniejszych danych wejściowych oraz na ograniczenie ich liczby. Tym samym można wytypować czynniki niezbędne do prawidłowego prognozowania plonu.

Modele plonu buraka cukrowego

W literaturze jest opisanych wiele modeli prognozujących plon buraka cukrowego. Modele Patefielda i Austina [Patefield i in. 1971], SUBGRO [Fick i in. 1973] i SUCROS [Spitters i in. 1989] są oparte na funkcjach empirycznych i wymagają dużej liczby danych wejściowych. Jaggard [2001] modeluje wzrost korzeni buraka w sposób empiryczny, wykorzystując zależność fotosyntezy netto od intensywności dawki usłonecznienia w ciągu doby. Model Kaburlasosa [2002] przewiduje plon korzeni i cukru na podstawie trendów z danego roku w odniesieniu do lat poprzednich oraz wykorzystuje pewne techniki sztucznej inteligencji. Metoda ta ma jednak zastosowanie tylko w Grecji. W modelu uwzględniono wyniki dziesięcioletnich badań (1989-1999) następujących czynników: średnia temperatura dobową, maksymalna i minimalna temperatura dobową, wilgotność powietrza, prędkość wiatru, dzienne opady, ewaporacja, usłonecznienie, średnia masa jednego korzenia, indeks powierzchni liści, zawartość cukru, zawartość melasotworów w korzeniach, plon korzeni oraz dane dotyczące agrotechniki plantacji.

Model PIeTeR [Smit i in. 1996] prognozuje plon buraka i zawartość cukru w korzeniach na podstawie nawożenia azotem (na podstawie analizy zawartości azotu w warstwie gleby 0-60 cm) i obsady roślin oraz uwzględnia termin zbioru i dostawy korzeni do cukrowni. Zawartość cukru jest obliczana na podstawie parametrów jakościowych plonu. W modelu istotne znaczenie mają również dane o przebiegu pogody. W okresie od siewu do zamknięcia międzyrzędzi za czynnik decydujący o kiełkowaniu i wzroście roślin przyjęto średnią dobową temperaturę powietrza. Później najważniejszym czynnikiem wpływającym na wielkość plonu korzeni i zawartości cukru jest dzienna dawka usłonecznienia. Innym ważnym czynnikiem jest wilgotność gleby, której wartość w każdej fazie wzrostu jest modyfikowana współczynnikami, w odniesieniu do wilgotności równowagowej.

Model SUBEMOpo (SUGar BEet MOdel potential production) opracowany przez Vandendriesscha [2000a, 2000b] uzależnia wzrost plonu buraka cukrowego i zawartości cukru od panujących warunków pogodowych (usłonecznienie, temperatura) oraz od cech charakterystycznych plantacji (warunki glebowe, obsada). Suchą masę plonu i zawartość cukru oblicza się z przyswajanego przez rośliny dwutlenku węgla, przy uwzględnieniu strat respiracji oraz mechanizmu przydzielenia węglowodanów poszczególnym organom rośliny i zasobowi cukru. Struktura modelu

składa się z programu głównego oraz 11 podprogramów, które opisują procesy zachodzące w roślinie, jak również służą do wprowadzania wartości zmiennych. Zmienne wejściowe obejmują 24 bardzo szczegółowe parametry, dotyczące danych meteorologicznych, miejsca uprawy, przebiegu wzrostu roślin, charakterystyki roślin w okresie wegetacji i czasu przeprowadzenia symulacji.

W każdym z wyżej opisanych modeli do jego funkcjonowania potrzebna jest znajomość wartości dużej liczby zmiennych, zebranych podczas pomiarów lub uzyskanych na podstawie analiz laboratoryjnych. Wiele z tych danych wykracza poza standardowe pomiary, wykonywane podczas wegetacji buraka przez dział surowcowy cukrowni. To istotnie ogranicza możliwość szerokiego zastosowania tych modeli w praktyce rolniczej, przez plantatorów i przez doradców związanych z przemysłem cukrowniczym. Dlatego należy poszukiwać takiej metody prognozowania plonu buraka cukrowego i zawartości cukru, która przy wykorzystaniu możliwie niewielkiej liczby analizowanych czynników, pozwoli na uzyskanie wystarczająco dokładnej prognozy.

Cel i zakres pracy

Celem pracy jest wskazanie niezbędnych czynników oraz ocena ich przydatności dla budowy modelu prognostycznego plonu buraka cukrowego i zawartości cukru w korzeniach, opartego o techniki modelowania neuronowego. Założono, że utworzenie modelu za pomocą sztucznych sieci neuronowych (SSN) pozwoli na uzyskanie wystarczająco dokładnej prognozy, ponieważ SSN poprzez proces uczenia się mają większe zdolności klasyfikacyjne, niż klasyczne metody modelowania. Ponadto zastosowanie technik neuronowych pozwala na opracowanie modelu plonu, przy wykorzystaniu najistotniejszych danych wejściowych. Tym samym można wytypować czynniki niezbędne do prawidłowego prognozowania plonu buraka cukrowego.

Metoda rozwiązania problemu

Realizacja celu pracy wymagała zebrania danych empirycznych z całego procesu produkcji buraka, obejmujących podstawowe czynniki charakteryzujące siedlisko, użyte środki produkcji i przebieg warunków pogodowych. Ponieważ sieć o małym błędzie walidacyjnym wymaga dużej liczby danych, dlatego skorzystano ze szczegółowych danych zawartych w kartach plantacji, prowadzonych przez inspektorów terenowych z cukrowni „Środa” w Środzie Wielkopolskiej. Dane obejmują okres trzech sezonów agrotechnicznych od 2000/01 do 2002/03. Codziennie dane meteorologiczne pochodzą z rejonu prowadzonych badań. W każdym sezonie agrotechnicznym analizowano dane obejmujące prawie 700 plantacji. W karcie pola

znajdowało się 78 szczegółowych danych, dotyczących procesu produkcji buraka. Na podstawie informacji literaturowej, badań własnych oraz wniosków z przeprowadzonej analizy regresji, wytypowano czynniki istotne wpływające na wielkość i jakość plonu dla potrzeb prognozowania neuronowego.

Czynniki, które uznano za istotne to:

- klasa bonitacyjna gleby,
- poziom nawożenia organicznego i mineralnego, wyrażony w czystym składniku NPK,
- termin siewu i norma wysiewu nasion,
- końcowa obsada roślin
- termin zbioru buraków,
- temperatura, usłonecznienie i opady

Czynniki powodujące obniżenie jakości i ilości plonu, czyli choroby i szkodniki za Vandendriessche [2000b] zostały pominięte, ponieważ przyjęto, że ich pojawienie się jest wcześniej wykrywane i podejmowane są odpowiednie środki zapobiegawcze. Z uzyskanych informacji wynika, że wiele gospodarstw stosuje programy prewencyjne, które nie dopuszczają do powstania zagrożenia chorobami i pojawienia się szkodników.

Wybór właściwej topologii sztucznej sieci neuronowej dla zrealizowania celu pracy wymagał utworzenia, nauczania i przetestowania różnego rodzaju sieci. W czasie budowy modelu testowano sieci typu perceptron wielowarstwowy oraz sieci o radialnych funkcjach bazowych. Metody uczenia sieci ściśle zależały od wybranego typu sztucznej sieci neuronowej. Jako zmienne wejściowe dla testowanych sieci zostały przyjęte podstawowe czynniki plonotwórcze, natomiast wynikiem był prognozowany plon korzeni i zawartość cukru.

Po wstępnych badaniach, ze względu na niższe wartości błędów, do dalszych analiz przyjęto sieci typu perceptron wielowarstwowy MLP. Zaproponowane sieci neuronowe typu MLP podzielono na dwa warianty i na dwa poziomy. Wariant 1 (W1) obejmował neurony wejściowe w postaci czynników plonotwórczych i na wyjściu posiadał 1 neuron w postaci plonu korzeni [t/ha]. Przy projektowaniu przyjęto dwa poziomy ilościowe dla neuronów w warstwach ukrytych. Były to odpowiednio maksymalnie do 15 (poziom 1; P1/15) i do 30 neuronów (poziom 2; P2/30). Wariant 2 (W2) także obejmował neurony wejściowe w postaci czynników plonotwórczych, natomiast na wyjściu posiadał 1 neuron w postaci zawartości cukru [%]. Także i w tym wariantcie dokonano analizy dla maksymalnie do 15 i do 30 neuronów w warstwach ukrytych.

Wyniki

Łączna liczba analizowanych plantacji w okresie trzech lat badań wynosiła 2096, co stanowiło całkowitą liczbę przypadków dla sieci neuronowej. Wyniki działania sieci MLP przedstawiają strukturę sieci, jej charakterystyczne cechy oraz czynniki plonotwórcze, które zostały w nich uwzględnione (tabela 1).


Tabela 1. Wyniki działania sieci MLP dla 2 wariantów i 2 poziomów

Table 1. Results at working net MLP for 2 variants and 2 levels

Parametr	Plon W1P1/15	Plon W1P2/30	Cukier W2P1/15	Cukier W2P2/30
Jakość uczenia	0,189555	0,185910	0,620260	0,595152
Jakość walidacyjna	0,196188	0,181015	0,605253	0,620533
Jakość testująca	0,171177	0,192245	0,585924	0,635572
Błąd uczenia	0,021567	0,021019	0,056770	0,070705
Błąd walidacyjny	0,020157	0,021336	0,057456	0,075505
Błąd testujący	0,019644	0,021898	0,051432	0,077135
Uczenie 1	BP100	BP100	BP100	BP100
Uczenie 2	CG108b	CG141b	CG25b	CG34b
Współczynnik regresji	0,98258	0,98253	0,79399	0,79077
Wejść	7	8	9	7
Ukryta 1	12	30	15	30
Ukryta 2	5	7	5	0
Funkcja aktywacji – war 1	Liniowa	Liniowa	Liniowa	Liniowa
Funkcja aktywacji – war 2	Hiperboliczna	Hiperboliczna	Hiperboliczna	Hiperboliczna
Funkcja aktywacji – war 3	Hiperboliczna	Hiperboliczna	Hiperboliczna	Logistyczna
Funkcja aktywacji – war 4	Logistyczna	Logistyczna	Logistyczna	-
N organiczne	-	-	-	-
P organiczne	-	-	-	TAK
K organiczne	-	TAK	TAK	TAK
N mineralne	-	-	TAK	TAK
P mineralne	TAK	-	TAK	TAK
K mineralne	-	-	-	-
Norma wysiewu	-	TAK	TAK	-
Klasa bonitacyjna gleby	TAK	TAK	-	-
Obsada roślin	-	-	TAK	-
Data siewu	TAK	TAK	TAK	-
Data zbioru	TAK	TAK	-	TAK
Suma usłonecznienia	TAK	TAK	TAK	TAK
Suma temperatur	TAK	TAK	TAK	-
Suma opadów	TAK	TAK	TAK	TAK

Spośród wszystkich czynników uznanych za istotne, sieć wykorzystywała od 7 do 9. W każdym testowanym wariancie istotnym czynnikiem była suma opadów i suma usłonecznienia. Pozostałe czynniki, najczęściej uwzględniane przez sieć, to suma temperatur, termin siewu i termin zbioru oraz nawożenie potasem i fosforem.

Sieć dla wariantu W1P1 charakteryzuje się małymi błędami na poziomie 0,02 i współczynnikiem regresji 0,98. W tym wariancie istotnymi czynnikami są: dawka fosforu w nawożeniu mineralnym, klasa bonitacyjna gleby, data siewu i zbioru a także sumy; usłonecznienia, temperatur i opadów atmosferycznych. Zwiększenie liczby neuronów ukrytych do 30 (wariant W1P2, rys. 1) nie polepszyło działania sieci, chociaż liczba wejść wzrosła do ośmiu.



Rys. 1. Wygląd sieci dla przypadku W1P2
Fig. 1. The appearance of net for case W1P2

W drugim wariancie, przy 15 neuronach ukrytych (W2P1) błąd dla zawartości cukru wyniósł 0,05 i współczynnik regresji 0,79. W tym przypadku czynnikami istotnie wpływającymi na zawartość cukru były: dawka potasu z nawożenia obornikiem, dawka azotu i fosforu z nawożenia mineralnego, norma siewu, końcowa obsada roślin, data siewu, a także sumy; usłonecznienia, temperatur i opadów at-

mosferycznych. Natomiast zwiększenie liczby neuronów w warstwie ukrytej (W2P2) pogorszyło rezultaty działania sieci, szczególnie w zakresie błędu do wartości 0,07. Może być spowodowane ograniczeniem liczby czynników wejściowych z dziewięciu do siedmiu. Pomimo pogorszenia działania sieci można uznać, że rezultaty jej działania ukształtowały się na zadowalającym poziomie, co wskazuje na poprawne prognozowanie plonu korzeni buraka i zawartości cukru.

Wnioski

1. Wyniki działania zaproponowanej sieci neuronowej wskazują, że można zbudować model prognozujący plon buraka cukrowego, spełniający oczekiwania, w oparciu o niewielką liczbę standardowych czynników, charakteryzujących siedlisko, użyte środki produkcji i warunki pogodowe.
2. W oparciu o wyniki uzyskane w trakcie wstępnej obróbki danych uczących (preprocessing danych wejściowych) wskazano czynniki istotne dla prawidłowego prognozowania plonu buraka cukrowego.
3. W celu jednoczesnego prognozowania dwóch parametrów w postaci plonu korzeni i zawartości cukru należy utworzyć i przetestować sieć z dwoma neuronami wyjściowymi. Przy budowie takiej sieci, w celu minimalizacji błędów, należy uwzględnić minimum dwa lub więcej poziomów maksymalnej liczby neuronów w warstwach ukrytych.
4. Przeprowadzone postępowanie wskazuje, że sztuczne sieci neuronowe mogą stanowić wydajne narzędzie do prognozowania efektów produkcji rolniczej, nie tylko w przypadku uprawy buraka cukrowego.

Bibliografia

- Fick G. W., Williams W. A., Loomis R. S. 1973. Computer simulation of dry matter distribution during sugar beet growth. *Crop Science* 13, 413-417.
- Jaggard K. W. 2001. The growth of sugar beet in 2000. *British Sugar Beet Review*, 69 (1), 2-4.
- Jaggard K. W., Werker A. R. 1999. An evaluation of the potential benefits and costs of autumn- sown sugarbeet in NW Europe. *Journal of Agricultural Science*, 132, 91-102.
- Kaburlasos V.G., Spais V., Petridis V., Petrou L., Kazarlis S., Maslaris N., Kallinakis A. 2002. Intelligent clustering techniques for prediction of sugar production. *Mathematics and Computers in Simulation* 60 (2002) 159-168.

Patefield W. M., Austin R. B. 1971. A model for the simulation of the growth of *Beta vulgaris* L. *Annals of Botany* 35: 1227-1250.

Smit A.B., Muijs G.J.W., Struik P.C., van Niejenhuis J.H. 1996. Evaluation of a model for sugar beet production by comparing field measurements with computer predictions. *Computers and Electronics in Agriculture* 16 (1996) 69-85.

Spitters C. J. T., van Keulen H, van Kraailingen D.W.G. 1989. A simple and universal crop growth simulator: SUCROS87. In: Rabbinge R, Ward S.A., van Laar H.H., eds. *Simulation and systems management in crop protection. Simulation Monographs* 32, Pudoc, Wageningen, 147-181.

Vandendriessche H.J. 2000a. A model of growth and sugar accumulation of sugar beet for potential production conditions: SUBEMOpo. I. Theory and model structure. *Agricultural Systems* 64 (2000) 1-19.

Vandendriessche H.J. 2000b. A model of growth and sugar accumulation of sugar beet for potential production conditions: SUBEMOpo. II. Model performance. *Agricultural Systems* 64 (2000) 21-35.

THE ANALYSIS OF ASSUMPTIONS FOR MODELING SUGAR BEET CROP WITH UTILIZATION OF ARTIFICIAL NEURAL NETWORKS

Summary

In planning crops, including sugar beet crop, prognostic models are used. Existing models are utilized in micro scale – for the farm, as well as in macro scale – for region or country. These models, generally implemented in computer programmes, are rather unavailable for sugar beet planters and agricultural advisory services because of the huge amount of input data. That is why in this paper an attempt was made to create own model of sugar beet crop based on artificial intelligence methodology and the smallest possible amount of input data. It was assumed that input data for models should be the basic factors characterizing habitat, means of production used and weather conditions course.

Key words: sugar beet, crop prediction, artificial neural networks