

PREDYKCJA PLONÓW BURAKA CUKROWEGO PRZY WYKORZYSTANIU TECHNIK NEURONOWYCH

Streszczenie

Uzyskanie plonu korzeni buraka cukrowego o wysokich parametrach jakościowych i ilościowych wymaga starannego zaplanowania całego procesu produkcji. Do uzyskania możliwie najlepszych efektów produkcyjnych stosuje się modele plonu. Stosowane dotychczas modele charakteryzują się niewystarczającą dokładnością prognozy, są skomplikowane i uciążliwe w praktycznym zastosowaniu. Dlatego postanowiono utworzyć model plonu buraka cukrowego z wykorzystaniem Sztucznych Sieci Neuronowych (SSN). Symulatory tych sieci pozwalają na wytworzenie modelu prognostycznego i jego weryfikację bez dużych nakładów finansowych. Niezbędne są tu jednak badania polowe, dzięki którym zostanie utworzona baza danych empirycznych.

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

Wprowadzenie

Produkcja roślinna, ze względu na zmienne czynniki środowiskowe, zawsze obarczona jest dużym ryzykiem i niepewnością [Stańko 1994]. Szczególnie dotyczy to procesu produkcji buraka cukrowego, rośliny wrażliwej na zmienność warunków siedliska. Uzyskanie optymalnego - w danych warunkach - plonu korzeni i cukru wymaga starannego i dokładnego zaplanowania całego procesu produkcyjnego. Jedną z metod racjonalnej produkcji buraka cukrowego jest stosowanie modeli prognostycznych. Zastosowanie ich w praktyce jest często utrudnione. Wprowadzone do nich dane empiryczne muszą być dokładnie takie, jakie przewidział autor, zaś brak jednej zmiennej może doprowadzić do błędnego prognozowania. Istnieją modele [Patefield i in. 1971; Fick i in. 1973; Spitters i in. 1989; Vandendriessche 2000; Kaburlasos 2002], które wymagają wprowadzenia wszystkich danych – niewprowadzenie ich skutkuje brakiem jakiegokolwiek reakcji programu, w którym dany model został zaimplementowany. Najczęściej do budowy takich modeli potrzebne są badania nawet z kilkunastu lat.

Związek przyczynowo-skutkowy badanych zjawisk i procesów zachodzących podczas okresu wegetacji buraków cukrowych jest bardzo złożony i

do dnia dzisiejszego nie jest do końca poznany. Mając do dyspozycji jedynie dane uzyskane podczas badań, ważne wydają się poszukiwania innych metod budowy modeli systemów empirycznych, opisujących badane zależności, np. z wykorzystaniem sztucznej sieci neuronowej.

Modele plonu buraka cukrowego

Jednym z najnowszych jest model o nazwie SUBEMOpo (SUGar BEet MOdel potential production) opracowany przez H.J. Vandendriessche [2000], który jest mechanistyczną symulacją wzrostu plonu buraka cukrowego oraz procesu gromadzenia cukru dla potencjalnych warunków produkcji. Wzrost plonu buraka cukrowego i zawartości w nim cukru są uzależnione od panujących warunków pogodowych (uśłonecznienie, temperatura) oraz od cech charakterystycznych plantacji (warunki glebowe, obsada). Suchą masę 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.

Komputerowy kod modelu jest zapisany w standardzie FORTRAN 77. Struktura modelu składa się z programu głównego oraz 11 podprogramów, które opisują procesy zachodzące w roślinie, takie jak asymilacja, respiracja, parowanie, wzrost, rozwój i starzenie się, jak również służą do wprowadzania wartości tych zmiennych. Autor nie podaje stopnia dokładności opracowanego modelu, jednakże wskazuje na różnice pomiędzy danymi polowymi a danymi symulacyjnymi.

W literaturze są opisane także modele Patefielda i Austina [1971], SUBGRO [Fick i in. 1973], SUCROS [Spitters i in. 1989]. Są to modele o dużej liczbie parametrów oparte na funkcjach empirycznych. Jaggard [2001] modeluje wzrost korzenia buraka w sposób empiryczny, bazujący na zależności fotosyntezy netto od intensywności dawki uśłonecznienia w godzinach w ciągu doby.

Inny model Kaburlasosa [2002] przewiduje plon korzeni i cukru, bazując na trendach z danego roku w stosunku do lat poprzednich oraz wykorzystuje pewne techniki sztucznej inteligencji. Metoda ta ma zastosowanie jednak tylko w Grecji. W modelu uwzględniono następujące parametry (badania z lat 1989-1999): średnia dzienna temperatura, dzienna maksymalna i minimalna temperatura, wilgotność powietrza, prędkość wiatru, dzienne opady, parowanie wody, uśłonecznienie, średnia masa jednego korzenia, polaryzacja cukru, zawartość azotu, potasu, sodu, plon korzeni, indeks powierzchni liści oraz dane uprawowe plantacji.

Celem niniejszej pracy jest utworzenie modelu prognostycznego dla produkcji buraka cukrowego z wykorzystaniem technik neuronowych, który do poprawnego działania nie będzie wymagał dużej liczby parametrów wej-

ściowych, aby w sposób dokładny i prawidłowy osiągał swój cel – prognozował plon korzeni i zawartość cukru. Należy podkreślić, że brak jednego lub kilku parametrów nie będzie powodowało wadliwej prognozy, ponieważ model został utworzony za pomocą SSN, które poprzez proces uczenia się mają znacznie większe możliwości klasyfikacyjne od klasycznych metod modelowania. Zbudowany w ten sposób model wykorzystuje trzyletnie wyniki badań polowych, które uważa się za wystarczające do dokładnej symulacji neuronowej.

Koncepcja rozwiązania problemu

Wybór odpowiedniego rodzaju sztucznej sieci neuronowej do zrealizowania celu pracy wymagał utworzenia, nauczenia i przetestowania różnego rodzaju sieci. W czasie budowy modelu testowano następujące rodzaje sieci: perceptron wielowarstwowy, sieci o radialnych funkcjach bazowych, liniowe, probabilistyczne i regresyjne. Metody uczenia sieci ściśle zależały od wybranego typu SSN. Jako zmienne wejściowe dla testowanych sieci zostały przyjęte podstawowe czynniki plonotwórcze, natomiast wynikiem był prognozowany plon korzeni i zawartość cukru.

Metodyka badań

Realizacja celu pracy wymagała zebrania danych empirycznych z procesu produkcji buraka. Sieć o małym błędzie walidacyjnym wymaga dużej liczby danych, dlatego skorzystano z danych zawartych w kartach plantacji, prowadzonych przez inspektorów terenowych z cukrowni „Środa” w Środzie Wielkopolskiej oraz badań ankietowych. Dane meteorologiczne pochodzą z rejonu prowadzonych badań i pobierane były codziennie dla badanego okresu. Zakres czasowy prowadzonych badań obejmuje lata 2001-2003.

Z kart plantacji wytypowano następujące zmienne wejściowe:

- System zmianowania z czterech ostatnich lat,
- Resztki roślinne przedplonu,
- Nawożenie organiczne i mineralne (termin nawożenia obornikiem oraz rodzaj nawozu mineralnego i dawka według 6-stopniowej skali)
- Uprawa gleby (termin i rodzaj zabiegów agrotechnicznych, stosowane narzędzia i maszyny),
- Międzyplon,
- Siew (odmiana nasion, termin, norma wysiewu, rodzaj siewnika),
- Ochrona roślin (termin, stosowane środki, dawka),
- Czynniki wpływające na obniżenie plonu (wpływ czynników meteorologicznych, szkodników i chorób),
- Obserwacje rozwoju roślin (wschody i obsada roślin),
- Ilość i jakość plonu (plon korzeni, zawartość cukru, zawartość potasu, sodu, azotu alfa-aminowego i zanieczyszczeń).


Dane meteorologiczne obejmują:

- Uśłonecznienie,
- Dobową temperaturę maksymalną i minimalną,
- Minimum gruntowe,
- Temperaturę z pomiaru o godzinie 7, 13, 19 oraz temperaturę średniodobową,
- Wilgotność względną powietrza z pomiaru o godzinie 7, 13, 19,
- Opad deszczu,
- Temperaturę gleby na głębokości 5 cm, 10 cm, 20 cm, 50 cm.

Wyniki badań

Duża liczba badanych plantacji (średnio 700 w roku) i odczytane czynniki meteorologiczne pobierane codziennie skłaniają do przypuszczenia, iż utworzony model neuronowy będzie dokładny i wiarygodny. Po utworzeniu i przetestowaniu model ten będzie weryfikowany danymi połowymi z 2004 r.

Wstępne wyniki skłaniają do dalszych badań z zakresu analizy dwóch rodzajów sieci: perceptron wielowarstwowy MLP (rys. 1) oraz sieci o radialnych funkcjach bazowych RBF.



Rys.1 Schemat sieci typu MLP z 2 ukrytymi warstwami
Fig. 1. The chart of MLP net with 2 hidden layers

Zaproponowana sieć neuronowa typu MLP ma 91 neuronów na wejściu – są to zmienne niezależne, natomiast na wyjściu sieć posiada 2 neurony, które są zmiennymi zależnymi w postaci plonu korzeni i zawartości cukru.

Kolejnym ogniwem sieci są cztery warstwy ukryte, służące przetwarzaniu informacji. Dla wszystkich warstw funkcją agregującą jest funkcja liniowa. Warstwa pierwsza ma liniową funkcję aktywacji, druga – hiperboliczną, trzecia – logistyczną, natomiast dla warstwy czwartej jest to funkcja Soft-Max (zmodyfikowana funkcja wykładnicza, której suma aktywacji dla całej warstwy jest równa 1). Jednakże duża ilość zmiennych wejściowych do sieci skłania do ich ograniczenia przez wykorzystanie metod logiki matematycznej np. iloczynu kartezjańskiego [Pabis 1985], co powinno znacznie zredukować złożoność sieci (liczbę neuronów wejściowych i liczbę warstw).

W przedstawionym przypadku sieć typu perceptron wielowarstwowy (liczba zmiennych wejściowych nie zredukowana) została uczona metodą wstecznej propagacji błędu BP (maksymalnie 100 epok) oraz metodą gradientów sprzężonych (maksymalnie 500 epok). Błąd dla sieci wynosił 0,07 dla każdego zbioru – tj. walidacyjnego, testującego i uczącego.

Wnioski

1. Ze względu na różnice w uzyskiwanych plonach buraka cukrowego w Polsce w stosunku do krajów europejskich należy poszukiwać nowych dróg podniesienia efektywności produkcji tej rośliny. Dotychczasowa analiza literatury skłania do zastosowania SSN jako wydajnego narzędzia do prognozowania efektów produkcji rolniczej – nie tylko buraka cukrowego.
2. W celu eliminacji zbyt dużej liczby zmiennych niezależnych (wejść do sieci) należy zastosować metodę ich eliminacji (niektórych zmiennych) np. za pomocą iloczynu kartezjańskiego, co w znaczącym stopniu uprości strukturę sieci oraz przyspieszy jej działanie. Według analizy wstępnych wyników badań nie powinno to wpłynąć na jakość prognozy.

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., Kallinakias A. 2002. Intelligent clustering techniques for prediction of sugar production. Mathematics and Computers in Simulation, 60: 159–168*
- Pabis St. 1985. Metodologia I metody nauk empirycznych. PWN, Warszawa*

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

Spitters C. J. T., van Keulen H, van Kraalingen 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

Stańko S. 1994. Prognozowanie w rolnictwie. Wydawnictwo Szkoły Głównej Gospodarstwa Wiejskiego, Warszawa

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

PREDICTION OF SUGAR BEET YIELDS WITH THE USE OF NEURAL NETWORK TECHNIQUES

Summary

To obtain the sugar beet roots yield of both, high qualitative and quantitative parameters, the correct planning of complete production is required. During planning of this process, the models for obtaining best production effects are being used. However, the models already used are characterized by insufficient exactitude of prognosis, are complicated and inconvenient in practical implementation. This inconvenience was the reason for creation of a new sugar beet yielding model with the use of Artificial Neural Networks (ANN). Simulators of these networks enabled the prognostic model creation and its verification without large financial inputs. However, the field experiments are indispensable for creation on their ground the empirical data base.

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

Recenzent – Jerzy Langman