

PROGNOZOWANIE ZAWARTOŚCI CUKRU W KORZENIACH BURAKA CUKROWEGO Z WYKORZYSTANIEM TECHNIK REGRESYJNYCH I NEURONOWYCH

Gniewko Niedbała, Jacek Przybył, Tadeusz Sęk
Institut Inżynierii Rolniczej, Akademia Rolnicza w Poznaniu

Streszczenie. Celem pracy było zbudowanie modelu prognozującego zawartość cukru w korzeniach buraka cukrowego. Prognozę można przeprowadzić przy pomocy klasycznych metod regresyjnych oraz z wykorzystaniem nowoczesnej techniki modelowania neuronowego. W pracy dokonano porównania obu tych metod dla budowy krótkoterminowych modeli prognoz zawartości cukru w korzeniach buraka cukrowego, opartych na danych empirycznych z trzyletnich badań.

Słowa kluczowe: burak cukrowy, prognozowanie plonu cukru, sztuczne sieci neuronowe, model regresyjny

Wprowadzenie

Prognozowanie plonu roślin uprawnych można wykorzystać do planowania struktury ich zasiewów, zarówno w skali mikro, czyli gospodarstwa rolnego, jak i makro, czyli np. kraju. Na tej podstawie można także szacować opłacalność uprawy danej rośliny. W przypadku uprawy buraka cukrowego prognozowanie plonu cukru ma jeszcze większe znaczenie, ponieważ kwota produkcji cukru jest określona ustawowo. Jej przekroczenie zmniejsza zysk plantatora i cukrowni [Ustawa z dnia 16 kwietnia 2004 r.; Rozporządzenie Komisji (WE) NR 952/2006]. Dlatego stosowanie nowoczesnych technik prognozowania może przynieść wymierne korzyści finansowe.

Zawartość cukru w korzeniach buraka cukrowego jest uzależniona od wielu wzajemnie oddziaływujących na siebie czynników, wśród których można wskazać grupę mającą największy bezpośredni wpływ na akumulację cukru. Należą do niej przede wszystkim czynniki klimatyczne, czyli temperatura powietrza, opady atmosferyczne i usłonecznienie, a także czynniki agrotechniczne np. poziom nawożenia organicznego i mineralnego, długość okresu wegetacji i końcowa obsada roślin [Borówczak 1999; Dobrowolski i Iciek 2000; Ostrowska 2001].

W opisanych w literaturze modelach prognostycznych plonu korzeni buraka cukrowego i zawartości cukru były wykorzystywane zbiory czynników opisujących siedlisko, jak i mechanizmy kształtowania się plonu, np. proces fotosyntezy. Możliwość wykonania prognozy w większości z tych modeli wymaga wprowadzenia wartości wielu czynników, określanych często na podstawie analiz laboratoryjnych [Vandendriessche 2000a, 2000b].

Stanowi to poważne utrudnienie dla szerokiego wykorzystania tych modeli. Dlatego w niniejszej podjęto próbę zbudowania modelu prognozującego zawartość cukru w korzeniach na podstawie czynników opisujących warunki uprawy buraka cukrowego z łatwo dostępnych z kart plantacji i danych meteorologicznych. Celem pracy było zbudowanie modelu prognozującego zawartość cukru w korzeniach buraka cukrowego w oparciu o nowoczesne techniki modelowania neuronowego. Dla porównania dokładności prognozy opracowano dla tych samych danych model przy zastosowaniu klasycznych metod statystycznych.

Material i metody

Do budowy modeli wykorzystano dane z kart plantacji buraka cukrowego i dane ze stacji meteorologicznej z obszaru działania cukrowni „Środa” w Środzie Wielkopolskiej. Łącznie wykorzystano dane z 1774 plantacji z lat 2001-2003. Na podstawie badań innych autorów [Vandendriessche 2000a, 2000b; Smit i in. 1996] oraz po przeprowadzeniu obliczeń statystycznych niektóre czynniki zawarte w kartach plantacji uznano za nieistotne przy budowie modeli. Są to czynniki kanoniczne, typowe dla procesu produkcji buraka cukrowego i stałe w danym regionie uprawy. Zaliczono do nich klasę bonitacyjną gleby, odmianę i dawkę nasion, termin siewu, system ochrony roślin i metodę zbioru.

W modelach uwzględniono te czynniki, których wpływ na zawartość cukru wykazały testy statystyczne. Jest to poziom nawożenia mineralnego i organicznego, uzależniony od zasobności gleby w składniki pokarmowe, długość okresu wegetacji, obsada roślin, opady atmosferyczne, temperatura i usłonecznienie. Większość z tych czynników, jako mających wpływ zarówno na plon korzeni, jak i na zawartość cukru, uwzględniają w swoich badaniach także inni autorzy [Borówczak 1999; Dobrowolski i Iciek 2000; Ostrowska 2001]. Do budowy modeli prognostycznych przyjęto więc następujące czynniki:

- dawkę azotu w nawozach organicznych i mineralnych [$\text{kg}\cdot\text{ha}^{-1}\text{N}$],
- dawkę fosforu w nawozach organicznych i mineralnych [$\text{kg}\cdot\text{ha}^{-1}\text{P}_2\text{O}_5$],
- dawkę potasu w nawozach organicznych i mineralnych [$\text{kg}\cdot\text{ha}^{-1}\text{K}_2\text{O}$],
- obsadę końcową roślin [$\text{szt}\cdot\text{ha}^{-1}$],
- liczbę dni wegetacji [dni],
- sumę usłonecznienia w okresie wegetacji [h],
- sumę temperatur w okresie wegetacji [$^{\circ}\text{C}$],
- sumę opadów w okresie wegetacji [mm].

Dane dotyczące usłonecznienia, temperatur średniodobowych i opadów atmosferycznych uzyskano ze stacji meteorologicznej, a końcową obsadę roślin odczytano z kart plantacji. Wartości pozostałych czynników uzyskano na podstawie dodatkowych obliczeń. Liczbę dni wegetacji roślin określono jako różnicę pomiędzy datą zbioru i datą siewu.

Dawki nawozów N, P, K wyrażone w czystym składniku, pochodzące z nawożenia organicznego i mineralnego, obliczono na podstawie odpowiednich przeliczników. Dla nawozów organicznych przyjęto wskaźniki podane przez Maćkowiaka i Żebrowskiego [2000], odnoszące się do 1t masy nawozu. Dla obornika bydłęcego przeliczniki wynoszą: $4,7\text{ kg}\cdot\text{ha}^{-1}\text{N}$, $2,8\text{ kg}\cdot\text{ha}^{-1}\text{P}_2\text{O}_5$ i $6,5\text{ kg}\cdot\text{ha}^{-1}\text{K}_2\text{O}$. W przypadku obornika świńskiego:

5,1 kg·ha⁻¹ N, 4,4 kg·ha⁻¹ P₂O₅ i 6,8 kg·ha⁻¹ K₂O. Dla obornika mieszanego wartości przeliczników były następujące: 4,6 kg·ha⁻¹ N, 3,0 kg·ha⁻¹ P₂O₅ i 6,3 kg·ha⁻¹ K₂O. Powyższe przeliczniki skorygowano równoważnikiem nawozowym dla pierwszego roku stosowania obornika. Dla azotu przyjęto 0,3, dla fosforu 0,4 i dla potasu 0,7 [Eghball i in. 2001; Ostrowska 2005]. Po tak wykonanych obliczeniach, zsumowano składniki uzyskane z nawozów organicznych i mineralnych.

Metoda budowy modelu regresyjnego

Według Krzysztofiaka i Urbanka [1979] poziom ściśle określonego zjawiska kształtuje się pod wpływem nie jednej, lecz wielu jednocześnie działających przyczyn. Dlatego zebrany materiał badawczy został poddany analizie za pomocą metody regresji wielorakiej (wielokrotnej), która pozwala określić wpływ wielu cech niezależnych na jedną wybraną cechą zależną [Kala 2002; Wysocki i Lira 2003] i zbudować model regresyjny w postaci:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_pX_p \quad (1)$$

gdzie:

- Y – zmienna zależna,
- a – wyraz wolny,
- X_p – wartość zmiennej niezależnej,
- b_p – współczynnik regresji.

W przeprowadzonej analizie za cechy niezależne przyjęto całkowitą dawkę azotu, fosforu i potasu, końcową obsadę roślin, liczbę dni wegetacji oraz sumę usłonecznienia, temperatur i opadów w okresie wegetacji. Cechą zależną była zawartość cukru w korzeniach buraka. Regresję wieloraką poprzedzono analizą współczynnika determinacji R^2 dla badanych cech oraz określeniem współczynnika prawdopodobieństwa dla statystyki bezwzględnej t , weryfikowanego na dwóch poziomach istotności $\alpha = 0,05$ (różnica statystycznie istotna) i $\alpha = 0,01$ (różnica statystycznie wysoce istotna).

Metoda budowy neuronowego modelu prognostycznego

Dobór zmiennych niezależnych do budowy modelu sieciowego wykonano w taki sposób, aby sieć neuronowa funkcjonowała na bazie tych samych informacji, co model regresyjny. Zmienne niezależne oznaczono następująco:

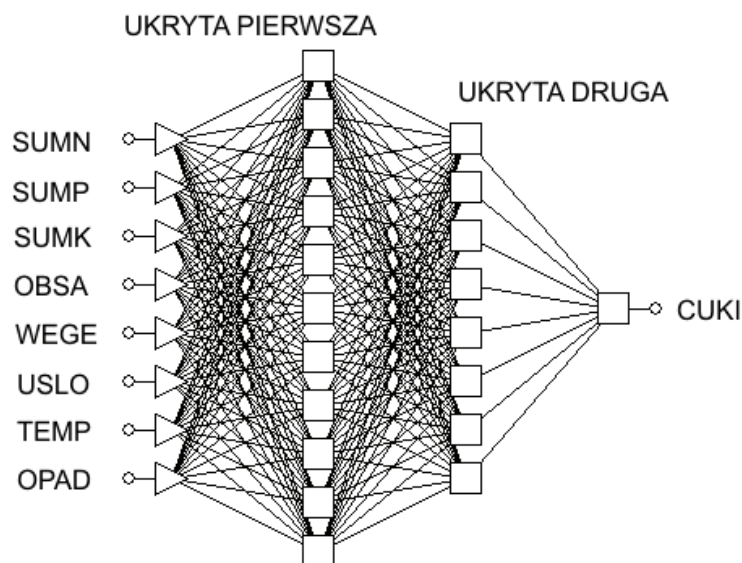
- SUMN – dawka azotu w nawozach organicznych i mineralnych [kg·ha⁻¹ N],
- SUMP – dawka fosforu w nawozach organicznych i mineralnych [kg·ha⁻¹ P₂O₅],
- SUMK – dawka potasu w nawozach organicznych i mineralnych [kg·ha⁻¹ K₂O],
- OBSA – obsada końcowa roślin [szt.·ha⁻¹],
- WEGE – liczba dni wegetacji [dni],
- USLO – suma usłonecznienia w okresie wegetacji [h],
- TEMP – suma temperatur w okresie wegetacji [°C],
- OPAD – suma opadów w okresie wegetacji [mm].

Zmienną zależną (wyjście sieci) była zawartość cukru w korzeniach buraka (CUKI).

Przy wyborze topologii sieci i metody uczenia uwzględniono jej zdolność do aproksymacji i uogólniania, opierając się na miarach ich jakości przy założeniu, że dla najlepszej sieci błąd sumy kwadratów różnic będzie najmniejszy. Zastosowanie programu Statistica v.6.0 pozwoliło na przetestowanie sieci o różnych architekturach. Dla poszczególnych modeli neuronowych liczba testowanych sieci wyniosła 5000 (automatyczny projektant sieci). Wybór topologii sieciowej nastąpił w oparciu o najlepsze parametry określające jakość sieci.

Dla modelu zawartości cukru NE_C , najlepszym typem sieci okazała się sieć typu perceptron wielowarstwowy (MLP) z dwiema warstwami ukrytymi. Pierwsza warstwa posiadała 11 neuronów, a druga 8 neuronów (rys. 1).

Zbiór danych empirycznych został podzielony losowo na zbiór uczący (U), walidacyjny (W) i testowy (T). Liczebność zbiorów ukształtowała się następująco: uczący – 888 przypadków, walidacyjny – 443, testujący – 443 przypadki (podział zbioru w proporcji 1:0,5:0,5). Do modyfikacji wag wykorzystano zbiór uczący, natomiast zbioru walidacyjnego użyto do kontrolowania wielkości błędu sieci w trakcie uczenia (RMS), a także do kontroli zdolności aproksymacyjnych. Na wejściu i wyjściu sieci dane zostały poddane konwersji metodą liniowego skalowania wartości mini-max. Związane to było z koniecznością dostosowania danych wejściowych do przedziałów, dla których zmienność wartości w funkcji aktywacji jest wysoka. Wartość najmniejsza określana jako min przyjmowała 0, a wartość największa max przyjmowała wartość 1. Także w warstwie wyjściowej sieci wartości zostały przeskalowane powyższą metodą.



Rys. 1. Schemat sieci MLP dla prognozy zawartości cukru z dwoma ukrytymi warstwami
 Fig. 1. Scheme of net MLP for prognosis of sugar content with two hidden layers

Wyniki badań

Ocena analizy wrażliwości sieci neuronowej

Analiza wrażliwości (tab. 1) sieci neuronowej, zbudowanej na podstawie danych empirycznych wykazała, że najistotniejszą zmienną wpływającą na prognozę zawartości cukru (CUKI) była suma usłonecznienia w okresie wegetacji (USLO). Usunięcie z modelu tej zmiennej skutkowałooby wzrostem błędu sumarycznego sieci o 1,391 raza. Pozycję drugą z wartością 1,043 przyjęły opady atmosferyczne. Trzecią rangą w skali wpływu na wzrost błędu sumarycznego sieci była zmienna określająca sumę temperatur średniodobowych w okresie wegetacji. Wartość jej ilorazu wyniosła 1,027. Kolejne czynniki uwzględnione w modelu, czyli SUMN, SUMP, SUMK, OBSA, WEGE przyjęły wartości bliskie jedności. Oznacza to, że nie miały one istotnego wpływu na wzrost błędu prognozy wykonanej dla zawartości cukru w burakach cukrowych.

Tabela 1. Ocena analizy wrażliwości sieci neuronowej
Table. 1. The rating of the analysis of the sensibility of the neural network

	SUMN	SUMP	SUMK	OBSA	WEGE	USLO	TEMP	OPAD
Iloraz	1,005	1,002	1,004	1,003	1,004	1,391	1,027	1,043
Ranga	4	8	6	7	5	1	3	2

Źródło: badania własne autorów

Charakterystyka jakościowa modelu regresyjnego i neuronowego

Wybrany model neuronowy dla zawartości cukru charakteryzował się najmniejszymi wartościami ilorazu odchyień standardowych I_{SB} (iloraz odchylenia standardowego błędów predykcji i odchylenia standardowego zmiennej wyjściowej). Przyjmuje się, że mniejsza wartość współczynnika I_{SB} wskazuje na lepszą jakość predykcji. W modelu neuronowym określono wartości współczynników I_{SB} i r , które wyniosły odpowiednio 0,59 i 0,8. Zakres uzyskanych współczynników I_{SB} we wszystkich sieciach wahał się w zakresie 0,59–0,63 (tab. 2).

Tabela 2. Parametry jakościowe modelu neuronowego NE_C
Table. 2. The qualitative parameters of the neural model NE_C

Parametr	Zbiór uczący	Zbiór walidacyjny	Zbiór testujący
Średnia	17,40404	17,50488	17,58928
Odchylenie standardowe	1,13739	1,15194	1,20547
Średni błąd	-0,00949	-0,00884	-0,04839
Odchylenie błędu	0,67278	0,68819	0,70808
Średni błąd bezwzględny	0,53111	0,54878	0,56437
I_{SB}	0,59151	0,59742	0,58739
r	0,80632	0,80241	0,80936
R^2	0,65015	0,64386	0,65506

Źródło: badania własne autorów

Iloraz odchylenia standardowego błędów predykcji i odchylenia standardowego zmiennej wyjściowej (I_{SB}) dla zawartości cukru osiąga wartość dla wszystkich zbiorów około 0,59, co jest wartością mniejszą od granicznej wartości 0,7. Współczynnik korelacji dla zawartości cukru we wszystkich zbiorach osiągnął poziom 0,8 co jest wartością dopuszczalną.

W tabeli 3 zostały przedstawione estymatory współczynników regresji oraz błędy standardowe obliczone na podstawie danych empirycznych. Z przedstawionych danych zawartych w tabeli 3 wynika, że dla modelu RE_C wysoce istotne statystycznie są: zawartość fosforu w nawozach mineralnych i organicznych, usłonecznienie i opady. Duże dawki fosforu korzystnie wpływają na akumulację cukru oraz na podwyższenie wartości technologicznej korzeni buraka cukrowego [Borówczak 1991; Jaszczółt 1991; Gutmański 1994]. W związku z tym, że roślina pobiera najwięcej fosforu w pierwszych trzech miesiącach wegetacji, odpowiedni poziom nawożenia tym składnikiem jest szczególnie istotny. Czynniki SUMP, USLO i OPAD mają znaczący wpływ na zawartość cukru w korzeniach buraka cukrowego, co potwierdzone zostało wynikami obliczeń statystycznych metodą regresji wielorakiej. Wynika z nich, że fosfor jest ważnym czynnikiem, wpływającym na gromadzenie się cukru w korzeniu buraka. Istotnymi czynnikiem plonotwórczym jest również usłonecznienie, przy optymalnej ilości opadów.

Tabela 3. Współczynniki regresji, błędy standardowe oraz poziomy prawdopodobieństwa dla analizowanego modelu regresyjnego RE_C

Table 3. The coefficients of the regress, standard mistakes and the horizontal probability for the analysed regression model RE_C

Czynnik	Model RE_C Zawartość cukru $r = 0,7933$ $R^2 = 0,6294$ Wyraz wolny 11,027			
	B_i	Istotność	$Pr > t $	Błąd stand. B
SUMN	-0,00065	-	0,152273	0,000453
SUMP	-0,00107	**	0,005653	0,000386
SUMK	0,00035	-	0,136454	0,000234
OBSA	-0,00000	-	0,652317	0,000002
WEGE	-0,00253	-	0,705972	0,006709
USLO	0,00890	**	0,000000	0,000358
TEMP	-0,00065	-	0,160637	0,000463
OPAD	-0,00718	**	0,000037	0,001737

Źródło: badania własne autorów

Oznaczenie poziomu istotności statystycznej:

- nieistotne,

** wysoce istotne dla $\alpha = 0,01$

Uwzględniając tylko czynniki wpływające wysoce istotnie statystycznie na zawartość cukru w korzeniach buraka cukrowego model regresyjny RE_C przyjmuje następującą postać:

$$CUKI = 11,027 - 10,7 \times 10^{-4} SUMP + 8,9 \times 10^{-3} USLO - 71,8 \times 10^{-4} OPAD \quad (2)$$


Dla zbudowanego modelu neuronowego zostały określone także współczynniki determinacji. Losowy dobór zawartości zbiorów U, W i T dla zawartości cukru wykazał wyższą wartość R^2 , wynoszącą 0,65 (tab. 4) Całkowity względny błąd aproksymacji (RAE) dla modelu NE_C wyniósł 0,031333. Dla modelu regresyjnego RE_C wartość błędu była większa i wyniosła 0,149318. Uzyskane wartości błędów aproksymacji dla modelu regresyjnego i neuronowego wskazują, że opracowany model neuronowy dla plonu cukru charakteryzuje się mniejszym błędem prognozy, co pozwala wstępnie wnioskować, że model ten został poprawnie zbudowany i w sposób prawidłowy pozwala na prognozę badanej cechy. Błąd RMS był zdecydowanie mniejszy dla modelu neuronowego NE_C i wyniósł 0,686048. Błąd modelu RE_C wyniósł 2,670994.

Tabela 4. Parametry jakościowe modeli RE_C i NE_C
 Table 4. The qualitative parameters of models RE_C and NE_C

Model	RAE	RMS	R^2
RE_C	0,149318	2,670994	0,6294
NE_C	0,031333	0,686048	0,65015

Źródło: badania własne autorów

Dla modelu neuronowego NE_C w celu określenia jego charakterystyki prognostycznej utworzono tzw. powierzchnię odpowiedzi, czyli wykres trójwymiarowy, prezentujący dwie cechy niezależne i jedną zależną. Na rysunku 2 przedstawiono powierzchnię odpowiedzi sieci NE_C dla dwóch zmiennych niezależnych w postaci sumy usłonecznienia (USLO) i sumy opadów (OPAD). Powierzchnia odpowiedzi sieci obejmuje zawartość cukru w granicach od 15,8 do 18,2%. Wykres powierzchni odpowiedzi wskazuje na najistotniejszy wpływ jednego czynnika na zawartość cukru w korzeniach, jakim jest usłonecznienie (USLO). Można zauważyć, że przy wzroście opadów, ale przy stałej sumie usłonecznienia, zawartość cukru w korzeniach buraka cukrowego może ulec nawet zmniejszeniu.



Rys. 2. Powierzchnia odpowiedzi sieci NE_C dla dwóch zmiennych niezależnych w postaci sumy usłonecznienia (USLO) i sumy opadów (OPAD) w okresie wegetacji

Fig. 2. The surface the answer the network NE_C for two changing independent in the figure of sum insolation (USLO) and the sum of falls (OPAD) in the period of vegetation

Charakterystyka własności prognostycznych modelu regresyjnego i neuronowego

W tabeli 5 przedstawiono mierniki prognostyczne analizowanych modeli regresyjnych i neuronowych na podstawie danych ze zbioru testowego, który nie brał udziału w estymacji parametrów zbudowanych modeli. Mniejszą wartość błędu średniego bezwzględnego (MAE) stwierdzono dla modelu neuronowego NE_C (0,82). Wartość błędu MAE modelu RE_C była o 2,4 raza większa. Również maksymalne wartości błędów modeli (MAX) wskazują na korzystniejsze wartości prognoz w modelu neuronowym. Wartość błędu MAX dla modelu NE_C była o 1,7 raza mniejsza, niż w przypadku modelu RE_C .

Tabela 5. Mierniki prognostyczne analizowanych modeli
Table 5. The prognostic measures of analysed models

Model	Błąd średni MAE [%cukru]	Błąd średni procentowy MAPE [%]	Błąd maksymalny MAX [% cukru]	Błąd maksymalny procentowy MAXP [%]
Regresyjny dla zawartości cukru RE_C	1,95331	10,94748	3,56189	21,36710
Neuronowy dla zawartości cukru NE_C	0,827858	4,557223	2,107947	10,80998

Źródło: badania własne autorów

Wnioski

1. Opracowany i zweryfikowany model neuronowy dla zawartości cukru w burakach cukrowych, potwierdził możliwości zastosowania sztucznych sieci neuronowych do prognozowania plonów buraka cukrowego.
2. Uzyskane wyniki za pomocą neuronowego modelu prognostycznego wskazują na znaczący wpływ sumy opadów atmosferycznych i usłonecznienia w okresie wegetacji na gromadzenie się cukru.
3. Wyniki badań modeli prognostycznych z wykorzystaniem sieci neuronowych o dwóch warstwach ukrytych wskazują na nieliniowość przyrostu zawartości cukru podczas wegetacji buraków cukrowych.
4. Przedstawiona metoda modelowania neuronowego, po wykonaniu modyfikacji, może służyć do prognozowania plonów innych roślin uprawnych, co w konsekwencji może przynieść wymierne skutki makro i mikroekonomiczne.

Bibliografia

- Borówczak F.** 1991. Wpływ deszczowania, zagęszczenia roślin i nawożenia azotowego na plon buraków cukrowych. Biuletyn IHAR nr 178. Radzików. ISSN 0373-7837.
- Borówczak F.** 1999. Problemy uprawy buraków cukrowych w Polsce. Gazeta Cukrownicza Nr 12.
- Dobrowolski M., Iciek J.** 2000. Możliwości zastosowań sztucznych sieci neuronowych w cukrownictwie – przewidywanie plonu buraków przed kampanią. Gazeta Cukrownicza 11-12.
- Eghball B., Wienhold B.J., Gilley J.E.** 2001. Mineralization of Manure Nutrients. American Society of Agronomy 142049.
- Gutmański I.** 1994. Wpływ dawki i formy azotu na wschody, plony i jakość przetwórczą buraka cukrowego w dwóch terminach zbioru. Biuletyn IHAR nr 189. Radzików. ISSN 0373-7837.
- Jaszczołt E.** 1991. Nawożenie buraka cukrowego makroskładnikami. Biuletyn IHAR nr 178. Radzików. ISSN 0373-7837.
- Kala R.** 2002. Statystyka dla przyrodników. Wydawnictwo AR Poznań. ISBN 837160291X.
- Krzysztofiak M., Urbanek D.** 1979. Metody statystyczne. PWN Warszawa.
- Maćkowiak Cz., Żebrowski J.** 2000. Skład chemiczny obornika w Polsce. Nawozy i nawożenie R2, 4/2000. ISSN 1509-8095.
- Ostrowska D.** 2001. Czynniki wpływające na jakość buraka cukrowego. Wieś Jutra nr 1.
- Ostrowska D.** 2005. Nawożenie buraka cukrowego nawozami organicznymi. W: Technologia produkcji buraka cukrowego. Wydawnictwo Wieś Jutra.
- ROZPORZĄDZENIE KOMISJI (WE) NR 952/2006 z dnia 29 czerwca 2006 r. ustanawiające szczególne zasady stosowania Rozporządzenia Rady (WE) nr 328/2006 w odniesieniu do zarządzania rynkiem wewnętrznym cukru oraz systemu kwot (Dz. U. UE L 178/39 z 1.07.2006 r.)
- 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. s. 69-85
- Ustawa z dnia 16 kwietnia 2004 roku o nadmiernych zapasach produktów rolnych i produktów cukrowych (Dz.U. Nr 97, poz. 964 ze zm.)
- 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. Volume 64, Issue 1. s. 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. Volume 64, Issue 1. s. 21-35.
- Wysocki F., Lira J.** 2003. Statystyka opisowa. Wydawnictwo AR Poznań. ISBN 8371603045.

PROGNOSIS OF THE CONTENT OF SUGAR IN THE ROOTS OF SUGAR-BEET WITH UTILIZATION OF THE REGRESSION AND NEURAL TECHNIQUES

Summary. Prognosis of the content of sugar in the roots of sugar-beet is an important element of the organization of the production in the farm. The high content of the sugar gives measurable financial advantages for the grower and delivers to the sugar factories the material from which one gets white sugar of high quality. The aim of the research was to build a prognosis model of the content of sugar in the sugar-beet roots. One can conduct the realization of the prognosis by means the classic regression method, and the modern techniques of neural modeling as well. During research comparisons of both methods were performed when it comes to the building of short-term models of prognoses the content of sugar in the roots of sugar-beet based on empirical data's of three-years investigations.

Key words: artificial neural networks, prediction, sugar beet

Adres do korespondencji:

Gniewko Niedbała; e-mail: gniewko@au.poznan.pl
Instytut Inżynierii Rolniczej
Akademia Rolnicza w Poznaniu
ul. Wojska Polskiego 50
60-627 Poznań