

## THE METHODS OF PREDICTING THE ISSUES OF AGRICULTURAL ENGINEERING WITH THE USE OF ARTIFICIAL NEURAL NETWORKS

### Summary

*The aim of the following thesis was the description of chosen methods of the prediction and the comparison of their efficiency in the field of agricultural engineering with the use of artificial neural networks. There were also pointed the typologies of networks which turned out to be the most effective in the process of solving the prediction problems.*

## METODY PROGNOZOWANIA WYBRANYCH ZAGADNIENÍ INŻYNIERII ROLNICZEJ Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH

### Streszczenie

*Celem pracy było omówienie neuronowych metod prognozowania oraz porównanie ich efektywności w wybranych zagadnieniach inżynierii rolniczej przy użyciu sztucznych sieci neuronowych. Wskazano przy tym topologie sieci, które w rozwiązaniu problemów predykcyjnych charakteryzowały się najlepszą skutecznością.*

### 1. Wstęp

Łatwy dostęp do wiarygodnych informacji jest coraz bardziej pożądanym nie tylko dla rolników, ekonomistów, przedsiębiorców oraz firm, ale również dla zwykłego człowieka. Szczególnie, gdy dotyczy to wiedzy dotyczącej problemów przyszłości. Analiza na ogół wiąże się z niepewnością, jednak określenie najbardziej prawdopodobnych zdarzeń jest często „na wagę złota”. Dzieje się tak, dlatego, że często wiedza o przyszłości jest integralną częścią teraźniejszości. Przewidywanie pewnych zjawisk z zakresu inżynierii rolniczej istotne jest zarówno dla polskiego jak i również dla europejskiego rynku. Informacje takie przydatne są w wielu sytuacjach m.in.: w codziennej konsumpcji, w szacowaniu opłacalności produkcji, w badaniach rynkowych, w zestawieniach statystycznych, w inwestycjach giełdowych w płody rolne, w handlu międzynarodowym (wielkość eksportu i importu) czy w procesie porównywania wybranych wskaźników ekonomicznych pomiędzy różnymi państwami Unii Europejskiej.

Prognozowanie ma na celu przewidywanie kształtowania się pewnych zagadnień oraz procesów zachodzących w przyszłości na podstawie informacji pochodzącej z przeszłości. Końcowym etapem takiego procesu predykcyjnego jest sformułowanie prognozy, będącej w istocie formą osądu na temat przyszłych zdarzeń). Przewidywania dotyczące przyszłości odgrywają kluczową rolę w większości procesów decyzyjnych, przebiegających w wielu obszarach działalności człowieka. Jako narzędzie wspomagające coraz częściej wykorzystuje się metody sztucznej inteligencji, a coraz częściej stosuje się w tym celu modelowanie neuronowe. Sztuczne sieci neuronowe mogą być „uczone” wykrywania złożonych relacji pomiędzy danymi wejściowymi a wyjściowymi. „W szczególności obiecujące rezultaty przynosi wykorzystanie jednego z wielu aspektów sztucznych sieci neuronowych, jakim jest zdolność do rozwiązywania zagadnień

regresyjnych oraz aproksymacyjnych, co otwiera możliwości wykorzystania symulatorów sieci neuronowych m. in. jako narzędzi predykcyjnych” [9]. Ponadto istotną zaletą sieci neuronowych jest to, że „... mogą być stosowane praktycznie w każdej sytuacji, w której celem jest oszacowanie wartości zmiennej lub dokonanie grupowania na podstawie zaobserwowanych wartości cech lub zarejestrowanych pomiarów tzn. w zagadnieniach z zakresu regresji, klasyfikacji oraz analizy szeregów czasowych. Warunkiem niezbędnym do stosowania sieci neuronowych jest dostępność odpowiedniej liczby danych i istnienie rzeczywistej odporności sieci na zakłócenia oraz szumy” [3].

### 2. Wybrane metody uczenia neuronowych modeli prognostycznych

Uczenie modeli prognostycznych można realizować w oparciu o analizę materiału badawczego, przeprowadzoną przy użyciu regresji wielorakiej. Celem tej metody jest odnalezienie związków między badanymi cechami oraz zbudowanie modelu regresyjnego, opisującego powiązania między tymi cechami a zmienną wyjściową. Analiza ta pozwala więc określić wpływ cech niezależnych na wybraną cechę zależną. Przykładowy model regresyjny, dla prognozowanych wartości przedstawia poniższe równanie:

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

gdzie:

$Y$  - zmienna zależna,

$a$  - wyraz wolny,

$X_m$  - wartość  $m$ -tej zmiennej niezależnej,

$b_m$  -  $m$ -ty współczynnik regresji.

Alternatywną techniką uczenia neuronowych modeli prognostycznych jest wykorzystanie metody szeregów czasowych. Analizowana zmienna jest w tym przypadku zmienną wejściową, zależną. Szeregi czasowe są to serie obserwacji, dokonywane w równych odstępach czasu.

Poszczególne obserwacje nazywane są wyrazami tego szeregu. Szereg czasowy zapisuje się jako zbiór:

$$\{y_t ; t(t=0,1,\dots,n-1)\} \quad (2)$$

gdzie:

$t(t=0,1,\dots,n-1)$  -momenty (przedziały) czasu,  
 $y_t$  -wyniki obserwacji.

Wyróżnia się następujące rodzaje szeregów czasowych: stały, o trendzie rosnącym oraz sezonowy. „Szeregi czasowe charakteryzują się dużym udziałem składników deterministycznych i są łatwiejsze do prognozowania. Celem analizy szeregów czasowych jest ustalenie prognozy przyszłych wartości pewnej zmiennej (o wartościach zmieniających się w czasie). Zwykle prognozowana zmienna jest ciągła, tak więc prognozowanie szeregów czasowych jest zazwyczaj specjalizowaną formą regresji” [5]. Wyróżnić można następujące składniki szeregu czasowego:

- trend - nie powtarzające się, charakterystyczne, zmiany występujące w poszczególnych przedziałach czasu,
- losowość - zmiany wywołane czynnikami losowymi lub trudne do przewidzenia czynniki.
- cykliczność - charakterystyczne zmiany występujące w kilku- lub kilkunastoletnim horyzoncie czasu,
- sezonowość - zmiany występujące w poszczególnych przedziałach czasu (wahania okresowe), charakteryzujące się specyficznymi i powtarzalnymi przebiegami.

Przewidywanie może być realizowane „o jeden krok do przodu”. Istotne jest to, że niezawodność prognozy maleje wraz ze wzrostem odległości pomiędzy wartością obecną i prognozowaną. Dobra praktyka prognozowania nakazuje przestrzegania reguły, którą sformułował, często cytowany ekonomista amerykański, Edgar Russell Fiedler. Brzmi ona: „If you have to forecast, forecast often” („Jeśli już musisz prognozować, rób to często”). Wyróżnić można następujące etapy procesu analizy szeregu czasowego:

- zbieranie i przygotowywanie danych,
- analiza,
- modelowanie (odkrywanie struktury przebiegu czasowego),
- prognozowanie (weryfikacja prognoz),
- szacowanie jakości prognoz.

### 3. Przykłady modeli prognostycznych w inżynierii rolniczej


Metody sztucznej inteligencji są rozwijane bardzo intensywnie, zarówno od strony teoretycznej, jak i aplikacyjnej. Postęp w rolnictwie jest możliwy dzięki rozwojowi naukowemu m. in. takich dziedzin jak: inżynieria rolnicza, informatyka w rolnictwie czy też prognozowanie rolnicze. Proces prognozowania jest jednym z ważnych etapów badania oraz analizy systemów empirycznych. Ma on praktyczne zastosowanie nie tylko w nowoczesnej inżynierii rolniczej, ale również w szerokim zakresie działalności ludzkiej. Poniżej przedstawiono wybrane przykłady wykorzystania neuronowych modeli prognostycznych w rolnictwie.

- W pracy pt. „Sieci neuronowe jako narzędzie predykcyjne w procesie prognozowania cen ziemniaków” [1] podjęto próbę zbudowania dwóch modeli prognostycznych, które dostarczyły informacji na temat przyszłego kształtowania się ceny ziemniaków. Modele te zbudowano z wykorzystaniem opisanych

powyżej metod: regresji wielorakiej i szeregów czasowych. Uczenie pierwszą metodą wymagało przeprowadzenia symulacji na wielu topologiach sieci o różnej liczbie neuronów. Najlepszą siecią okazał się perceptron wielowarstwowy z jedną warstwą ukrytą. Warstwa wejściowa zawierała 9 neuronów, natomiast ukryta posiadała 6 neuronów. Zbiór danych został podzielony losowo na zbiory:

- uczący (U) - zawierał 56 przypadków,
- walidacyjny (W) - zawierał 27 przypadków,
- testujący (T) - zawierał 27 przypadków.


Schemat wygenerowanej sieci neuronowej przedstawia się następująco:



Rys. 1. Schemat sieci neuronowej typu MLP dla prognozy metodą regresji wielorakiej

Fig. 1. The scheme of the neural network type MLP for the prediction carried out with the method of the manifold regression

Uczenie sieci neuronowych za pomocą szeregów czasowych polegało na przeprowadzeniu cyklu symulacji na wielu topologiach sieci o różnej liczbie neuronów. Wybór technik uczenia oraz metod poprzedzony był wieloma doświadczeniami i próbami. Wybrana została najlepsza sieć neuronowa, którą okazał się również perceptron wielowarstwowy MLP 1:10-2-1:1. Sieć posiadała jedno wejście i jedno wyjście. W pierwszej warstwie liczba neuronów wynosiła 10, w drugiej natomiast 2 neurony. Schemat wygenerowanej sieci powyższą metodą, przedstawiono na rys. 2:

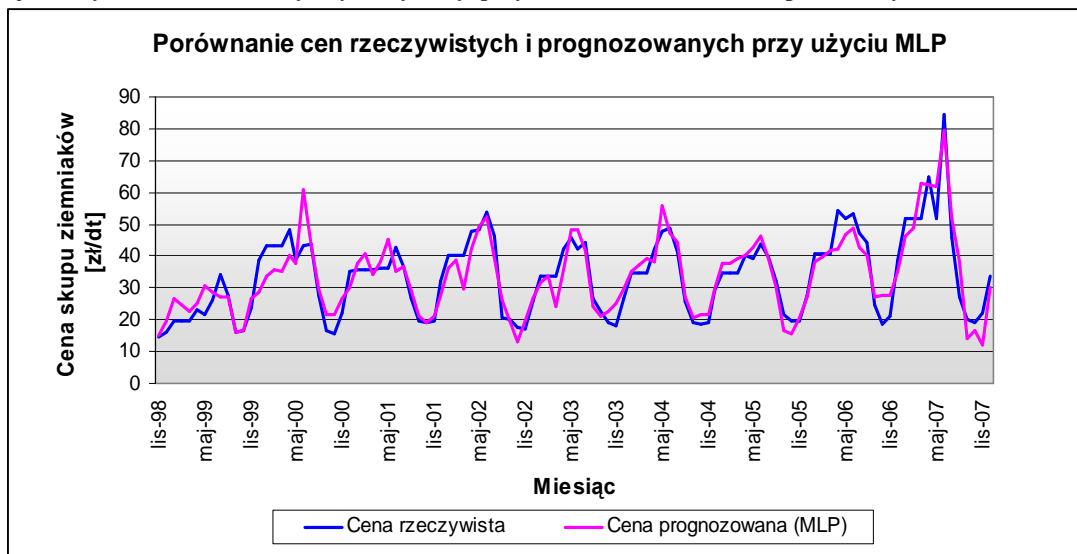


Rys. 2. Schemat sieci neuronowej typu MLP dla prognozy metodą szeregów czasowych

Fig. 2. The scheme of the neural network type MLP for the prediction carried out with the method of the time series

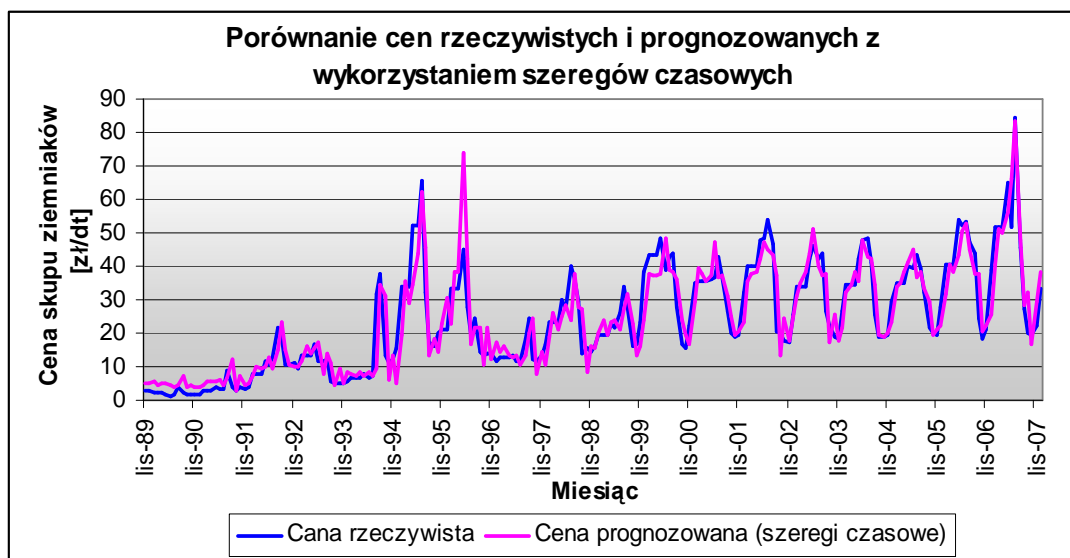
Uczenie przeprowadzono w oparciu o zbiór uczący zawierający 228 przypadków. Przy próbach uczenia sieci na mniejszym zbiorze danych (110 przypadków) osiągnięto niezadowalające wyniki. Zbiór uczący wykorzystany przy

analizie szeregów czasowych zbudowany został w oparciu o pojedynczą zmienną wejściowo- wyjściową. Była nią miesięczna cena skupu ziemniaków. Zbiór danych użyty do uczenia sieci został podzielony losowo na zbiory:



Rys. 3. Porównanie cen rzeczywistych i prognozowanych z wykorzystaniem MLP

Fig. 3. The comparison of the real and prognosed prices with the use of the MLP



Rys. 4. Porównanie cen rzeczywistych i prognozowanych metodą szeregów czasowych

Fig. 4. The comparison of the real and prognosed prices with the use of the time series

- uczący (U) - zawierał 110 przypadków,
- walidacyjny (W) - zawierał 54 przypadki,
- testujący (T) - zawierał 54 przypadki.

Wykresy, przedstawiające zależność danych rzeczywistych i prognozowanych, umożliwiają pełniejsze zobrazowanie rozrzutu tych danych. Na rys. 3 przedstawiono wartości rzeczywiste ceny skupu ziemniaków oraz ceny prognozowane skupu ziemniaków dla modelu uczonego z wykorzystaniem metody regresji wielorakiej. Na rys. 4 ukazano tą samą zależność, ale dla sieci wyuczonej metodą szeregów czasowych.

Tab. 1. Wartości błędów dla otrzymanych modeli prognostycznych

Tab. 1. Value received for error forecasting models

Metoda/ błąd	Walidacyjny	Uczący	Testowy
Regresja wieloraka	0,089368	0,050221	0,100058
Szeregi czasowe	0,080695	0,063805	0,087005

Statystyki regresyjne uzyskanych modeli wskazują na lepszą skuteczność prognozy dokonanej przez sieć wyuczoną metodą szeregów czasowych. Wskaźniki korelacji dla obu metod miały równe wartości 0,91. Iloraz odchyień natomiast w obu metodach był korzystniejszy dla sieci wyuczonej metodą szeregów czasowych.

• Kolejnym przykładem modelu prognostycznego w zakresie inżynierii rolniczej jest model neuronowy do predykcji poziomu sprzedaży wybranych produktów rolno-spożywczych. Zbiór danych uczących obejmował informacje dotyczące uprawy bazylii. „Wyższą jakość przetwarzania, czyli zgodność wyników otrzymanych z

predykcji w odniesieniu do sprzedaży rzeczywistej, otrzymano dla metody drugiej, czyli z wykorzystaniem modelowania z zastosowaniem szeregów czasowych. Średni błąd procentowy w skali roku wyniósł 5%. Pozytywny rezultat odnotowano również dla drugiej metody, jednak średni błąd procentowy w skali roku był wyższy i wyniósł 14%". [5]. Wyniki te otrzymano dla modeli prognostycznych uczonych z wykorzystaniem perceptronu wielowarstwowego.

- Model prognostyczny plonu buraka cukrowego i zawartości cukru w korzeniach oparty był na analizie informacji z 2096 plantacji. Wykorzystano tu metodę regresji wielorakiej. Model ten zbudowany został z użyciem standardowych czynników, charakteryzujących siedlisko, użyte środki produkcji i warunki pogodowe. Sieci uczono przy wykorzystaniu *MLP* (perceptron wielowarstwowy) oraz *RBF* (sieć o radialnych funkcjach bazowych). „Po wstępnych badaniach, ze względu na niższe wartości błędów, do dalszych analiz przyjęto sieci typu perceptron wielowarstwowy *MLP*” [7].

- Wytworzono również neuronowy model predykcyjny, przewidujący cenę ogórka szklarniowego. Pozwolił on na zoptymalizowanie decyzji o sprzedaży tego produktu [4]. Siecią oddającą najlepsze wyniki była liniowa sieć neuronowa. Sieci *RBF* były najmniej skuteczne, prawdopodobnie ze względu na swoją rozbudowaną architekturę.

#### 4. Podsumowanie oraz wnioski

1. Porównanie wybranych typów sztucznych sieci neuronowych pozwala wysnuć wniosek, że najdokładniejsze przewidywania (zarówno w metodzie szeregów czasowych, jak i w regresji wielorakiej) uzyskiwano przy wykorzystaniu topologii sieci typu perceptron 3-warstwowy.
2. Porównanie wyników prognozowania z wykorzystaniem modelowania neuronowego prowadzi do konkluzji, że metoda szeregów czasowych daje lepsze wyniki niż technika regresji wielorakiej.

3. Modele neuronowe umożliwiają prognozowanie zagadnień inżynierii rolniczej na zadowalającym poziomie dokładności, pod warunkiem, że prognoza ma charakter krótkoterminowy.
4. Sieć typu *RBF* (w przypadku obu badanych metod) dostarczała mniej dokładnych prognoz niż sieć typu *MLP*. Może to być wynikiem przeuczenia sieci radialnej i, co z tego wynika, gorszych zdolności do uogólniania nabytej wiedzy, jakie reprezentuje wygenerowana sieć *RBF*.

#### 5. Literatura

- [1] Błaszczak M., Dejeńska T.: Sieci neuronowe jako narzędzie predykcyjne w procesie prognozowania cen ziemniaków. Praca magisterska. Uniwersytet Przyrodniczy w Poznaniu, Poznań 2008.
- [2] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. WUP Poznań 2008.
- [3] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
- [4] Francik S.: Prognozowanie ceny ogórka szklarniowego za pomocą sieci neuronowych. *Inżynieria Rolnicza* 2005, nr 14 (74). s. 91-97.
- [5] Koszela K., Boniecki P., Weres J.: Ocena efektywności neuronowego prognozowania w oparciu o wybrane metody na przykładzie dystrybucji produktów rolniczych. Poznań 2005.
- [6] Niedbała G.: Prognozowanie plonu roślin z wykorzystaniem sztucznych sieci neuronowych na przykładzie buraka cukrowego. Akademia Rolnicza im. Augusta Cieszkowskiego w Poznaniu, Poznań 2006.
- [7] Niedbała G., Przybył J., Boniecki P., Sęk T.: Analiza założeń dla modelowania plonu buraka cukrowego z wykorzystaniem sztucznych sieci neuronowych. *Inżynieria Rolnicza* 2005, nr 2 (62). s. 123-130.
- [8] Osowski S.: Sieci neuronowe. Warszawa 1996.
- [9] Tadeusiewicz R.: Sieci Neuronowe. Akademicka Oficyna Wydawnicza RM, Warszawa 1993.