

## **METODA PROGNOZOWANIA SZEREGÓW CZASOWYCH PRZY UŻYCIU SZTUCZNYCH SIECI NEURONOWYCH**

Sławomir Francik

*Katedra Inżynierii Mechanicznej i Agrofizyki, Uniwersytet Rolniczy w Krakowie*

**Streszczenie.** Celem pracy było opracowanie metodyki prognozowania szeregów czasowych przy użyciu sztucznych sieci neuronowych. Prognozy wykonano zakładając klasyczny model tendencji rozwojowej. Opracowano ogólny algorytm opracowywania prognostycznego modelu neuronowego. Przedstawiono przykład zastosowania tego algorytmu do opracowania 9 modeli neuronowych dla zmiennych prognostycznych charakteryzujących wybrane maszyny rolnicze: kombajny zbożowe, pługi oraz siewniki rzędowe. Przeprowadzono analizę wrażliwości dla opracowanych modeli prognostycznych.

**Słowa kluczowe:** prognozowanie, szeregi czasowe, sztuczne sieci neuronowe

### **Wstęp**

Jednym z narzędzi wspomagających podejmowanie różnego rodzaju decyzji są prognozy [Cieślikowski 2005, Francik 2005, Trojanowska 2006, Trajer i in. 2005, Neugebauer i in. 2007]. Najistotniejszym kryterium poprawności wyznaczanych prognoz jest ich dokładność, dlatego prowadzone są ciągle prace nad nowymi metodami prognostycznymi umożliwiającymi zmniejszenie błędu prognozy. Również w inżynierii rolniczej wykonywane tego typu badania [Małopolski i in. 2008, Niedbała i in. 2007]. Jednym z najnowszych narzędzi wykorzystywanych do prognozowania są sztuczne sieci neuronowe [Francik 2001, Koszela i in. 2005, Pielecki in. 2005]. Jednak pomimo dużej liczby publikacji poświęconych tworzeniu neuronowych modeli prognostycznych nie została dotychczas sformułowana jednolita metodyka postępowania przy opracowywaniu sieci neuronowych przeznaczonych do prognozowania na podstawie szeregów czasowych.

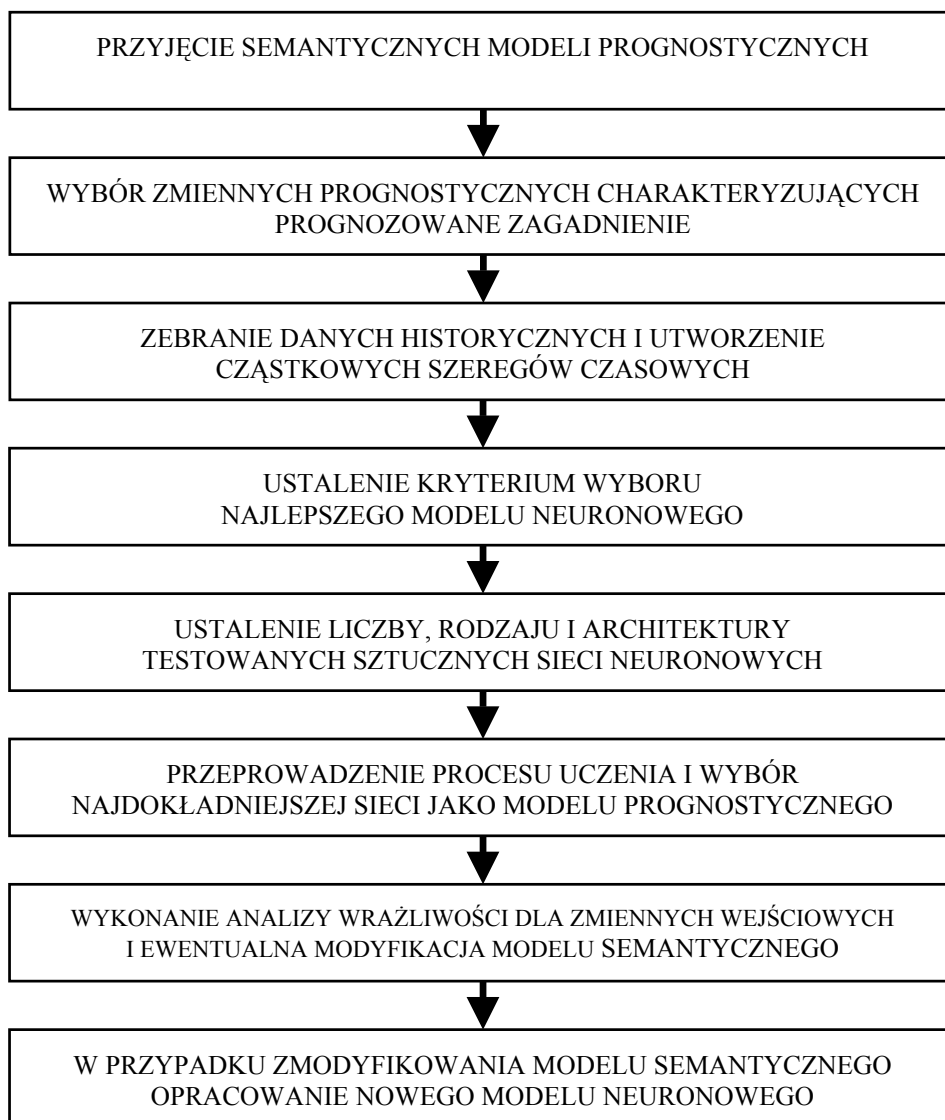
### **Cel pracy**

Celem pracy było opracowanie metodyki prognozowania szeregów czasowych przy użyciu sztucznych sieci neuronowych (SSN) zapewniającej uzyskanie maksymalnej dokładności prognoz.

Badania przeprowadzono dla zmian wartości parametrów technicznych wybranych maszyn rolniczych - kombajnów zbożowych, pługów oraz siewników rzędowych. Prognozy wykonano zakładając klasyczny model tendencji rozwojowej wykorzystując jednokierunkowe SSN. Szeregi czasowe utworzono dla modeli maszyn rolniczych dostępnych na rynku krajowym w latach 1959-2006.

## Metodyka

Na rysunku 1 przedstawiono schemat tworzenia modelu neuronowego przeznaczonego do prognozowania na podstawie szeregów czasowych.



Rys. 1. Schemat metodyki opracowywania neuronowego modelu prognostycznego wykorzystującego szeregi czasowe

Fig. 1. Diagram showing methods employed to create neural prognostic model using time series

Tworzenie modelu prognostycznego rozpoczyna się od przyjęcia modelu (lub modeli semantycznych), któremu towarzyszy wybór zmiennych prognostycznych, charakteryzujących prognozowane zjawisko, oraz zmiennych objaśniających. Dla modeli wykorzystujących klasyczny model tendencji rozwojowej zmienna prognostyczna jest równocześnie zmienną prognozowaną. Model semantyczny przyjmuje wtedy postać:

$$Y(T_{HP}) = f(T_{HP}, Y_T, Y_{T-1}, \dots, Y_{T-n})$$

gdzie:

$Y(T_{HP})$  – wartość prognozy dla horyzontu  $T_{HP}$

$T_{HP}$  – horyzont prognozy,

$Y_T$  – wartość zmiennej prognozowanej w chwili  $T$

$Y_{T-1}$  – wartość zmiennej prognozowanej w chwili  $T-1$

$Y_{T-n}$  – wartość zmiennej prognozowanej w chwili  $T-n$

Wybór szczegółowego modelu semantycznego wiąże się z ustaleniem długości horyzontu czasowego prognozy, czyli przedziału czasu na jaki wykonywana jest prognoza, oraz długości okresu analizy historycznej (wartości zmiennej  $n$ ). Długość horyzontu czasowego jest uzależniona od potrzeb (jak daleko w przyszłość ma sięgać prognoza), ale jednocześnie jest ograniczona długością szeregu czasowego zawierającego dane historyczne. Można przyjąć, że horyzont prognozy (przedział ekstrapolacji) powinien być krótszy niż długość okresu analizy danych historycznych (długość szeregu czasowego), chociaż w literaturze podawane są bardziej restrykcyjne zalecenia. Optymalne proporcje między wymienionymi przedziałami i ich długości są najczęściej uzależnione od prognozowanego zagadnienia (zmiennej prognostycznej) i powinny być ustalane na podstawie badań.

Po wybraniu modelu semantycznego należy dokonać wyboru zmiennej prognostycznej, a następnie zebrać dane historyczne (wartości zmiennej prognostycznej dla poszczególnych chwil czasu), które wykorzystywane są do tworzenia cząstkowych szeregów czasowych. Zmienne prognostyczne muszą charakteryzować prognozowane zjawisko, i jest to głównym kryterium ich wyboru. W przypadku prognozowania zmian parametrów techniczno-eksploatacyjnych maszyn rolniczych zmiennymi prognostycznymi powinny być wskaźniki czyli kombinacje poszczególnych parametrów. Wskaźnikiem takim może być na przykład wydajność jednostkowa (wydajność podzielona przez moc), czy masa jednostkowa (masa maszyny podzielona przez moc) charakteryzująca jakość konstrukcji maszyny.

Modele wykorzystujące sztuczne sieci neuronowe są tym dokładniejsze im dysponujemy większą liczbą danych uczących. Cząstkowe szeregi czasowe zawierają wartości zmiennej prognostycznej w kolejnych chwilach czasu (zgodnie z przyjętym modelem semantycznym) i stanowią wzorce uczące dla sztucznej sieci neuronowej.

Aby wybrać najlepszy model prognostyczny (najdokładniej działającą sieć neuronową) należy wybrać rodzaj błędu jaki ma być minimalizowany. Istnieje wiele mierników dokładności jednak najczęściej stosowany jest błąd średniokwadratowy *MSE*.

Następnie należy wybrać rodzaj sieci jakie będą wykorzystywane do tworzenia modelu prognostycznego oraz ich architekturę. Większa liczba warstw sieci i neuronów w poszczególnych warstwach pozwala zbudować bardziej skomplikowany model, ale wymaga większej liczby wzorców uczących.

Przeprowadzenie procesu uczenia sieci neuronowych wymaga wyodrębnienia ze zbioru danych (szeregów czasowych) podzbiorów zawierających wzorce uczące oraz wzorce służące do oceny jakości sieci neuronowej (wzorce testowe i ewentualnie walidacyjne).

Ponieważ uczenie jest procesem losowym, aby zwiększyć szansę uzyskania optymalnego modelu można wielokrotnie powtarzać proces uczenia, dla tej samej architektury sieci.

Po przeprowadzeniu uczenia dokonywany jest wybór najlepszego modelu na podstawie wartości błędu  $MSE$  dla zbioru wzorców testowych (walidacyjnych). Dla wybranego modelu neuronowego można wykonać analizę wrażliwości, która pozwala zweryfikować poprawność przyjętego modelu semantycznego. Można ewentualnie skorygować model semantyczny eliminując zmienne wejściowe które pogarszają dokładność działania sieci neuronowej.

Opisany powyżej sposób postępowania przy tworzeniu neuronowego modelu prognostycznego został następnie zastosowany do opracowania sieci neuronowych przeznaczonych do prognozowania wskaźników technicznych dla trzech rodzajów maszyn rolniczych różniących się stopniem komplikacji konstrukcji: kombajnów zbożowych, siewników oraz pługów. Dla każdej z wybranych maszyn przyjęto trzy różne modele semantyczne, różniące się długością okresu analizy danych historycznych ( $T_{AH} = 3, 4$  i  $6$  lat):

$$Y(T_{HP}) = f(T_{HP}, Y_T, Y_{T-1}, Y_{T-2},)$$

$$Y(T_{HP}) = f(T_{HP}, Y_T, Y_{T-1}, Y_{T-2}, Y_{T-3},)$$

$$Y(T_{HP}) = f(T_{HP}, Y_T, Y_{T-1}, Y_{T-2}, Y_{T-3}, Y_{T-4}, Y_{T-5},)$$

Prognozy wykonywano dla trzech horyzontów czasowych:  $T_{HP} = 1$  rok,  $T_{HP} = 2$  lata i  $T_{HP} = 3$  lata. Dla każdej z maszyn przyjęto po trzy wskaźniki (zmiennie) prognostyczne: dla kombajnów oznaczono je  $K1, K2$  i  $K3$ , dla siewników  $S1, S2$  i  $S3$ , a dla pługów  $P1, P2$  i  $P3$ . Wskaźniki te były ilorazami podstawowych parametrów technicznych i eksploatacyjnych:

- $K1, P1$  – wydajność podzielona przez zapotrzebowanie na moc [ $ha \cdot kW^{-1}$ ],
- $K2, P3, S1$  – masa podzielona przez zapotrzebowanie na moc [ $kg \cdot kW^{-1}$ ],
- $K3$  – szerokość robocza podzielona przez zapotrzebowanie na moc [ $cm \cdot kW^{-1}$ ],
- $P2$  – iloczyn szerokości i głębokości roboczej podzielony przez zapotrzebowanie na moc [ $cm^2 \cdot kW^{-1}$ ],
- $S2$  – zapotrzebowanie na moc podzielona przez wydajność [ $kW \cdot ha^{-1}$ ],
- $S3$  – szerokość robocza podzielona przez wydajność [ $cm \cdot ha^{-1}$ ].

Zebrane dla poszczególnych typów maszyn wartości zmiennych prognostycznych pozwoliły na utworzenie 1161 cząstkowych szeregów czasowych ( $43$  szeregi  $\cdot 3$  maszyny  $\cdot 3$  zmienne  $\cdot 3$  modele semantyczne). Uzyskane szeregi cząstkowe (wzorce uczące) podzielono losowo na zbiory: uczący, walidacyjny i testowy.

Do opracowania modelu neuronowego wykorzystano program Statistica Sieci Neuronowe. Do badań wybrano dwa typy sztucznych sieci neuronowych: sieci o radialnych funkcjach bazowych (RBF) oraz trójwarstwowe preceptrony (MLP). Przy użyciu Automatycznego Projektanta programu Statistica Sieci Neuronowe opracowano 2700 modeli neuronowych, z których wybrano sieci (po 1 dla każdej zmiennej prognostycznej). Kryterium wyboru była minimalna wartość błędu  $MSE$  dla danych ze zbioru walidacyjnego. Następnie przeanalizowano, jak wybrane modele neuronowe zachowują się dla danych ze zbioru testowego, który nie był wykorzystywany w procesie uczenia sieci neuronowych.

## Wyniki badań

W tabeli 1 przedstawiono wybrane modele neuronowe dla poszczególnych zmiennych prognostycznych. W większości są to trójwarstwowe perceptrony, posiadające od 4 do 10 neuronów w warstwie ukrytej. Dwa z opracowanych modeli to sieci o radialnych funkcjach bazowych. Nie można zatem stwierdzić, że któryś z typów jednokierunkowych sztucznych sieci neuronowych nadaje się lepiej do prognozowania. Różne są też długości okresu analizy historycznej w opracowanych modelach.

Tabela 1. Rodzaje SSN i architektury opracowanych modeli neuronowych  
Table 1. ANN types and architecture in developed neural models

Zmienna prognostyczna	Rodzaj sieci	Architektura sieci	Długość okresu analizy historycznej
K1	MLP	7-9-1	$T_{AH}=6$ lat
K2	MLP	5-6-1	$T_{AH}=4$ lata
K3	MLP	7-4-1	$T_{AH}=6$ lat
P1	RBF	7-18-1	$T_{AH}=6$ lat
P2	RBF	4-17-1	$T_{AH}=3$ lata
P3	MLP	5-6-1	$T_{AH}=4$ lata
S1	MLP	7-5-1	$T_{AH}=6$ lat
S2	MLP	7-10-1	$T_{AH}=6$ lat
S3	MLP	4-6-1	$T_{AH}=3$ lata

Przeprowadzona analiza wrażliwości (tab. 2) wykazała, że wszystkie przyjęte w modelach semantycznych zmienne wejściowe są istotne (wartości ilorazu błędu  $\geq 1$ ). Nie zachodziła zatem konieczność modyfikacji modeli semantycznych i ponownego opracowywania sztucznych sieci neuronowych.

Tabela 2. Analiza wrażliwości dla opracowanych modeli neuronowych  
Table 2. Sensitivity analysis for created neural models

Zmienna prognostyczna	Zmienne wejściowe sieci						
	Yt-5	Yt-4	Yt-3	Yt-2	Yt-1	Yt	Thp
K1	3,1	2,4	1,5	1,5	1,6	10,0	1,2
K2			1,1	1,1	1,0	3,7	1,0
K3	1,2	1,1	1,2	1,1	1,1	1,6	1,1
P1	1,0	1,1	1,0	1,0	1,1	1,2	1,0
P2				1,2	1,1	1,4	1,3
P3			1,0	1,0	1,1	1,2	1,0
S1	1,1	1,1	1,1	1,0	1,0	1,9	1,0
S2	1,1	1,0	1,1	1,1	1,1	1,1	1,0
S3				1,1	1,0	1,7	1,0

## Podsumowanie

Zaproponowana w pracy procedura umożliwia poprawne opracowywanie sztucznych sieci neuronowych służących do prognozowania na podstawie szeregów czasowych. Weryfikacja przyjętych modeli semantycznych pozwala na zwiększenie dokładności uzyskiwanych prognoz. Dokładność modeli neuronowych jest różna i zależy od prognozowanego zjawiska.

Zastosowanie metody dla kombajnów zbożowych, siewników i pługów pozwoliło opracować niezależne modele neuronowe do predykcji 9 zmiennych prognostycznych. Większość tych modeli to sieci typu trójwarstwowy perceptron. Liczba wejść sieci, zależna od długości okresu analizy historycznej, była różna dla różnych zmiennych prognostycznych:

- 7 wejść ( $T_{AH} = 6$  lat) dla zmiennej K1, K3, P1, S1, S2,
- 5 wejścia ( $T_{AH} = 4$  lata) dla zmiennej K2 i P3,
- 4 wejścia ( $T_{AH} = 3$  lata) dla zmiennej P2 i S3.

Potwierdzone zostało zatem, że nie można określić przed rozpoczęciem tworzenia modelu neuronowego typu sieci oraz jej architektury – liczby wejść i liczby neuronów w poszczególnych warstwach.

Prognozy wartości przyjętych wskaźników prognostycznych mogą być podstawą do analiz dotyczących przyszłych zmian w konstrukcji maszyn rolniczych (kombajnów zbożowych, siewników i pługów). Zmiany konstrukcji mogą dotyczyć zarówno materiałów stosowanych na poszczególne części maszyn, jak również wymiarów i kształtu tych części. A zatem prognozy mogą być wykorzystane na etapie opracowywania konstrukcji (układu struktur i innych stanów wytworu), jak również na etapie projektowania systemu, np. przy formułowaniu złożań projektowych.

## Bibliografia

- Cieślakowski B.** 2005. Prognozowanie stanu technicznego zespołu przekładniowego kombajnu zbożowego za pomocą modelu regresyjnego. *Inżynieria Rolnicza*. Nr 10(70). s. 49-55.
- Francik S.** 2001. Możliwości zwiększenia dokładności prognoz technicznych uzyskiwanych z użyciem sztucznych sieci neuronowych. *Inżynieria Rolnicza*. Nr 11(31). s. 69-75.
- Francik S.** 2005. Prognozowanie ceny ogórka szklarniowego za pomocą sieci neuronowych. *Inżynieria Rolnicza*. Nr 14(74). s. 91-97.
- Koszela K., Boniecki P., Weres J.** 2005. Ocena efektywności neuronowego prognozowania w oparciu o wybrane metody na przykładzie dystrybucji produktów rolniczych. *Inżynieria Rolnicza*. Nr 2(62). s. 69-76.
- Małopolski J., Trojanowska M.** 2008. Wykorzystanie modeli Mamdaniego do predykcji dobowych obciążeń wiejskich sieci elektroenergetycznych. *Inżynieria Rolnicza*. Nr 9(107). s. 205-211.
- Neugebauer M., Nalepa K., Sołowiej P.** 2007. Sieci neuronowe jako narzędzie umożliwiające prognozowanie zapotrzebowania na wodę w uprawach rolnych. *Inżynieria Rolnicza*. Nr 2(90). s. 205-210.
- Niedbala G., Przybył J., Sęk T.** 2007. Prognozowanie zawartości cukru w korzeniach buraka cukrowego z wykorzystaniem technik regresyjnych i neuronowych. *Inżynieria Rolnicza*. Nr 2(90). s. 225-234.

- Pielecki J., Skwarcz J.** 2005. Neuralna predykcja parametrów procesu biotechnologicznego. Inżynieria Rolnicza. Nr 8(68). s. 305-314.
- Trajer J., Czekalski D.** 2005. Prognozowanie sum napromienienia słonecznego dla potrzeb energetyki słonecznej. Inżynieria Rolnicza. Nr 8(68). s. 393-399.
- Trojanowska M.** 2006. Modele prognostyczne sprzedaży energii elektrycznej odbiorcom wiejskim oparte na wymiarze fraktalnym, logistyczne i krzyżowania heurystycznego. Inżynieria Rolnicza. Nr 11(86). s. 479-486.

## **THE METHOD USED TO PREDICT TIME SERIES USING ARTIFICIAL NEURAL NETWORKS**

**Abstract.** The purpose of the work was to develop methods for predicting time series using the artificial neural networks. The predictions were made assuming the classical development tendency model. The general algorithm for construction of prognostic neural model has been developed. The paper presents an example for using this algorithm to create 9 neural models for prognostic variables characterising selected farm machines: combine harvesters, ploughs and drill seeders. A sensitivity analysis was made for created prognostic models.

**Key words:** predicting, time series, artificial neural networks

**Adres do korespondencji:**

Sławomir Francik; e-mail: email: [sfrancik@ur.krakow.pl](mailto:sfrancik@ur.krakow.pl)  
Katedra Inżynierii Mechanicznej i Agrofizyki  
Uniwersytet Rolniczy w Krakowie  
ul. Balicka 120  
30-149 Kraków