

## WYZNACZANIE WARTOŚCI PODSTAWOWYCH PARAMETRÓW TECHNICZNYCH NOWOCZESNYCH KOMBAJNÓW ZBOŻOWYCH PRZY UŻYCIU SSN

Sławomir Francik

*Katedra Inżynierii Mechanicznej i Agrofizyki, Akademia Rolnicza w Krakowie*

**Streszczenie.** W pracy zastosowano sztuczne sieci neuronowe do wyznaczania podstawowych parametrów technicznych kombajnów zbożowych. Opracowano modele neuronowe pozwalające wyznaczyć moc silnika, objętość zbiornika ziarna, masę, oraz minimalną i maksymalną szerokość roboczą kombajnu. Przebadano różne typy sieci neuronowych. Najlepszymi modelami okazały się wielowarstwowe perceptrony.

**Słowa kluczowe:** parametry techniczne nowoczesnych kombajnów zbożowych, sztuczne sieci neuronowe, nowoczesność maszyn rolniczych

### Wprowadzenie

Analiza zmian konstrukcji maszyn rolniczych wykazuje, że są one związane ze zmianami parametrów technicznych charakteryzujących te maszyny (masa maszyny, moc lub zapotrzebowanie na moc, prędkość robocza, szerokość robocza i inne) [Francik, Ślipek 1995; Francik 2005]. Znajomość wartości tych parametrów jest konieczna, między innymi, w procesie projektowania nowych maszyn, przy ustalaniu założeń projektowych [Ślipek 1993]. Aby nowo projektowana maszyna była nowoczesna, przyjęte w założeniach wartości parametrów powinny uwzględniać przyszłe zmiany konstrukcyjne wyrobów konkurencyjnych.

Jednym z najbardziej złożonych systemów technicznych eksploatowanych w rolnictwie jest kombajn zbożowy [Braun 1998; Eikel 1998a; Rademacher 1998]. Ustalanie założeń projektowych dla tak złożonej maszyny jest szczególnie trudne, gdyż produkowane są konstrukcje wykorzystujące różne rozwiązania techniczne, a ponadto kombajn charakteryzują zarówno cechy ilościowe jak i jakościowe [Eikel 1998b; Francik, Ślipek 1995; Rademacher 1998].

### Cel i zakres pracy

Celem pracy była próba zastosowania sztucznych sieci neuronowych do wyznaczenia wartości wybranych parametrów technicznych kombajnów zbożowych.

Zastosowano sieci neuronowe, gdyż są one narzędziem pozwalającym na analizę i opis nawet bardzo skomplikowanych związków pomiędzy zmiennymi wyjściowymi a przyję-

tymi wejściami [Francik, Ślipek 2000b]. Badania przeprowadzono dla kombajnów zbożowych dostępnych na polskim rynku, o poprzecznym zespole młócającym i klawiszowym zespole separującym. Przyjęto, że badania będą dotyczyły: wydajności kombajnu [ $\text{ha}\cdot\text{h}^{-1}$ ], mocy silnika [ $\text{kW}$ ], objętości zbiornika ziarna [ $\text{dm}^3$ ], masy kombajnu, oraz minimalnej i maksymalnej szerokości zespołu żniwnego.

## Metodyka badań


Przy ustalaniu mocy silnika kombajnu przyjęto, że wydajność oraz rok wprowadzenia modelu kombajnu na rynek będą wielkościami wejściowymi dla pierwszego modelu neuronowego. Następnie, wykorzystując jako zmienne wejściowe rok i moc silnika, wyznaczono objętość zbiornika ziarna (drugi model neuronowy). Kolejnym parametrem, którego wyznaczano wartość, była masa kombajnu. Jako wejścia dla trzeciego modelu wykorzystano rok wprowadzenia modelu na rynek, moc silnika i objętość zbiornika ziarna. Ostatnimi wyznaczanymi parametrami były minimalna (model neuronowy czwarty) i maksymalna (model neuronowy piąty) szerokość robocza kombajnu. Jako zmienne wejściowe wykorzystano wartości wyznaczonych wcześniej parametrów (objętość zbiornika ziarna i moc silnika) oraz przyjęty rok wprowadzenia kombajnu na rynek.

Do opracowania sieci neuronowych pozwalających wyznaczyć poszczególne parametry kombajnu, wykorzystano program Statistica Sieci Neuronowe. Użyto Automatycznego Projektanta sieci neuronowych. Przeanalizowano różne typy i architektury sieci neuronowych: sieci liniowe, sieci o radialnych funkcjach bazowych (RBF) oraz trzy i czterowarstwowe sieci typu perceptron (MLP). Dokonano analizy wrażliwości dla poszczególnych modeli neuronowych.

Jedną z najważniejszych zalet sztucznych sieci neuronowych jest ich duża dokładność, w porównaniu z klasycznymi modelami matematycznymi. Losowy charakter procesu uczenia sieci powoduje, że sieci neuronowe opracowane do modelowania tego samego procesu mogą różnić się znacznie wartościami błędów. Dlatego konieczne jest przyjęcie kryterium wyboru najlepszego z uzyskanych modeli neuronowych. W pracy przyjęto, że wartość miernika błędu względnego (MBw) dla zbioru walidacyjnego będzie kryterium wyboru najlepszego modelu neuronowego [Francik, Ślipek 2000a].

## Wyniki badań

Na rysunku 1 przedstawiono wartości miernika MBw dla sieci neuronowych opracowanych do wyznaczania mocy silnika. Jako model przyjęto sieć sn1.05 – wartość miernika MBw = 2,7% dla danych walidacyjnych. Jest to czterowarstwowy perceptron o 2 neuronach wejściowych, 9 neuronach w pierwszej i drugiej warstwie ukrytej i 1 neuronie w warstwie wyjściowej (rys. 1). Przeprowadzona analiza wrażliwości wykazała, że obie zmienne wejściowe (wydajność kombajnu i rok wprowadzenia na rynek) mają podobną wagę – wartości ilorazu wrażliwości, odpowiednio 1,7 i 1,6.




Rys. 1. Wartości miernika MBw oraz analiza wrażliwości dla SSN opracowanych do wyznaczenia mocy silnika

Fig. 1. Values of the MBw measure and sensitivity analysis for ANN developed to determine the engine power

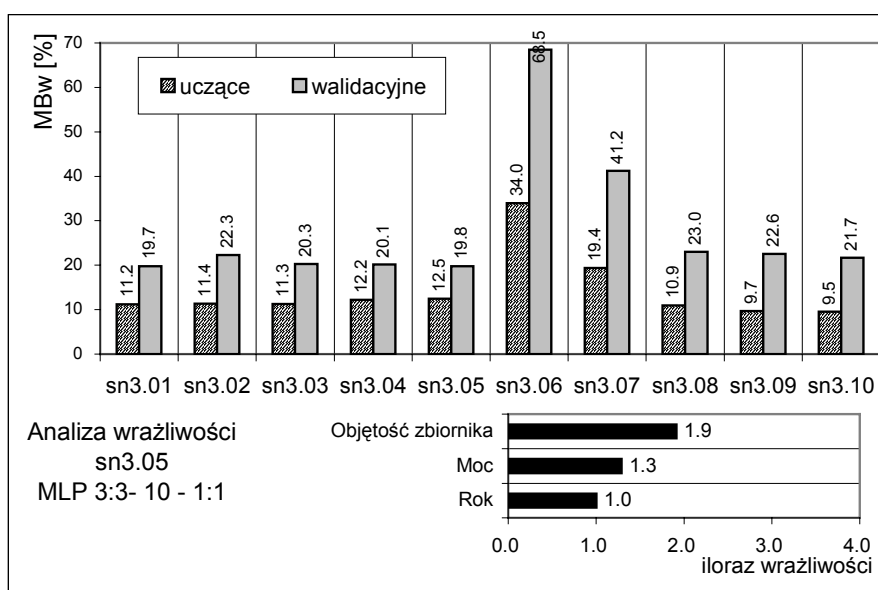
Do wyznaczenia objętości zbiornika ziarna wybrano sieć neuronową sn2.05, która uzyskała dla danych walidacyjnych MBw = 4,4% (rys. 2). Architektura wybranej sieci była identyczna jak dla modelu poprzedniego. Wartości ilorazu wrażliwości wskazują, że moc silnika jest prawie trzykrotnie istotniejsza (wartość ilorazu 3,7), niż druga ze zmiennych wejściowych – rok wprowadzenia na rynek (wartość ilorazu 1,3).

Jako trzeci model neuronowy, służący do wyznaczenia masy kombajnu, wybrano sieć sn3.05 – wartość miernika MBw = 19,8% dla danych walidacyjnych (rys. 3). Jest to trzywarstwowy perceptron o 3 neuronach wejściowych, 10 neuronach w warstwie ukrytej i 1 neuronie w warstwie wyjściowej. Minimalnie mniejszą wartość miernika błędów uzyskała sieć liniowa sn3.01. Analiza wrażliwości dla wybranego modelu wskazuje, że najmniej istotny jest rok, jako zmienna wejściowa (wartość ilorazu 1,0).



Rys. 2. Wartości miernika MBw oraz analiza wrażliwości dla SSN opracowanych do wyznaczania objętości zbiornika ziarna

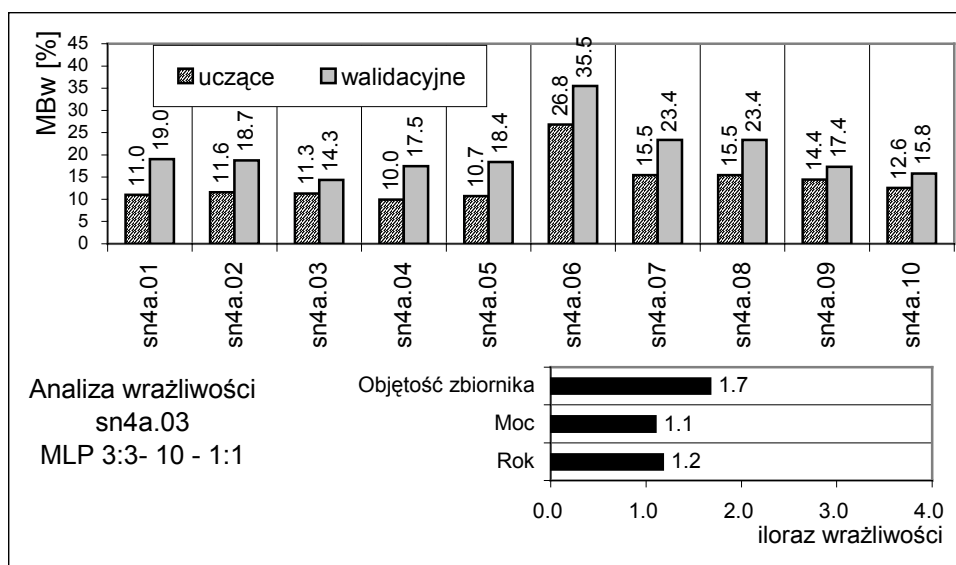
Fig. 2. Values of the MBw measure and sensitivity analysis for ANN developed to determine the corn tank volume



Rys. 3. Wartości miernika MBw oraz analiza wrażliwości dla SSN opracowanych do wyznaczania objętości masy kombajnu

Fig. 3. Values of the MBw measure and sensitivity analysis for ANN developed to determine the weight of the combine harvester


Rysunek 4 przedstawia wartości miernika MBw dla sieci neuronowych wyznaczających minimalną szerokość roboczą kombajnu. Najmniejsze wartości MBw uzyskała sieć sn4a.03 – 14,3% dla danych walidacyjnych. Wybrana sieć neuronowa to trzywarstwowy perceptron o 3 neuronach wejściowych, 10 neuronach w warstwie ukrytej i 1 neuronie w warstwie wyjściowej. Analiza wrażliwości wskazuje na istotny wpływ wszystkich zmiennych wejściowych. Uzyskane wartości ilorazu wyniosły od 1,1 dla mocy silnika kombajnu, do 1,7 dla objętości zbiornika ziarna.



Rys. 4. Wartości MBw oraz analiza wrażliwości dla SSN opracowanych do wyznaczania minimalnej szerokości roboczej kombajnu

Fig. 4. Values of the MBw measure and sensitivity analysis for ANN developed to determine the minimum operational width of the harvester

Do wyznaczania maksymalnej szerokości roboczej wybrano sieć sn4b.02, która uzyskała MBw = 7,1% dla danych walidacyjnych (rys. 5). Jest to sieć typu MLP o 3 neuronach wejściowych, 10 neuronach w pierwszej warstwie ukrytej, 6 neuronach w drugiej warstwie ukrytej, oraz 1 neuronie wyjściowym. Przeprowadzona analiza wrażliwości wykazała, że najważniejszą zmienną wejściową jest objętość zbiornika ziarna (wartość ilorazu 3,0). Pozostałe zmienne (moc silnika i rok) mają ponad dwukrotnie mniejszą wartość ilorazu wrażliwości, odpowiednio 1,3 i 1,4.



Rys. 5. Wartości MBw oraz analiza wrażliwości dla SSN opracowanych do wyznaczenia maksymalnej szerokości roboczej kombajnu

Fig. 5. Values of the MBw measure and sensitivity analysis for ANN developed to determine the maximum operational width of the combine

## Wnioski

1. Sztuczne sieci neuronowe można wykorzystać jako narzędzie do wyznaczania wartości parametrów technicznych nowoczesnych kombajnów zbożowych. Uzyskiwane wartości miernika błędów MBw dla otrzymanych modeli są zróżnicowane, od 2,7% do 19,8% dla danych walidacyjnych, oraz od 9,3% do 35,8% dla danych uczących.
2. Jako modele najlepsze okazały się wielowarstwowe perceptrony (MLP). Uzyskane modele neuronowe różnią się stopniem rozbudowania ich struktury (liczbą warstw i liczbą neuronów) – trzy modele to sieci czterowarstwowe, a dwa to sieci trójwarstwowe.
3. Dla większości opracowanych modeli wszystkie przyjęte zmienne wejściowe okazały się istotne. Świadczą o tym uzyskane wartości ilorazu wrażliwości.

## Bibliografia

- Braun O.** 1998. Trzy kombajny: Deutz – Fahr, Fiatagri i MDW (Case). Top Agrar Extra II. s. 52-59.
- Eikel G.** 1998a. Plusy i minusy kombajnów 5-klawiszowych. Top Agrar Extra. s. 72-75.
- Eikel G.** 1998b. Praktyczna ocena kombajnów 6-klawiszowych. Top Agrar Extra. s. 76-81.
- Francik S.** 2005. Tendencje zmian wybranych parametrów ciągników rolniczych. Inżynieria Rolnicza. 6(66). s. 141-147.

- Francik S., Ślipek Z.** 1995. Prognoza rozwoju konstrukcji kombajnów zbożowych na podstawie badań ankietowych. Zesz. Probl. Post. Nauk Rolniczych. Z. 423. s. 103-111.
- Francik S., Ślipek Z.** 2000a. Dokładność prognozy technicznej w zależności od architektury SSN. Prace PIMR. 2. s. 64-66. Poznań.
- Francik S., Ślipek Z.** 2000b. Metoda prognozowania techniki rolniczej przy użyciu sztucznych sieci neuronowych. Inżynieria Rolnicza. Nr 8(19). s. 79-86. Warszawa.
- Rademacher T.** 1998. New Holland TC 56: dobra wydajność. Top Agrar Extra. s. 56-60.
- Ślipek Z.** 1993. Ocena stopnia ważności wymagań konstrukcyjnych dla maszyn rolniczych. Część I. Założenia projektowe. Roczniki Nauk Rolniczych. t. 79-C-4. s. 53-58.

## **DETERMINING THE VALUE OF BASIC TECHNICAL PARAMETERS FOR MODERN HARVESTER COMBINES WITH THE USE OF ANN**

**Summary.** Artificial neural networks were used in this research to determine basic technical parameters of harvester combines. Neural models enabling to determine the engine power, the corn tank volume, the weight, and minimum and maximum operational width of the harvester were developed. Various types of neural networks were analyzed. Multilayer perceptrons proved to be the best models.

**Key words:** technical parameters of modern harvester combines, artificial neural networks, technological development of agricultural machines

**Adres do korespondencji:**

Sławomir Francik; e-mail: sfrancik@ar.krakow.pl  
Katedra Inżynierii Mechanicznej i Agrofizyki  
Akademia Rolnicza w Krakowie  
ul. Balicka 116 B  
30-149 Kraków