

ZASTOSOWANIE AUTORSKIEJ METODY WYZNACZANIA WARTOŚCI PARAMETRÓW NOWOCZESNYCH SYSTEMÓW TECHNICZNYCH DO PŁUGÓW I OPRYSKIWACZY POLOWYCH

Sławomir Francik

Katedra Inżynierii Mechanicznej i Agrofizyki, Uniwersytet Rolniczy w Krakowie

Streszczenie. Celem pracy było zastosowanie autorskiej metody, wykorzystującej sztuczne sieci neuronowe, do prognozowania wartości parametrów technicznych nowoczesnych maszyn rolniczych do pługów zawieszanych i opryskiwaczy polowych. Opracowano schematy kolejności wyznaczania poszczególnych parametrów charakteryzujących nowoczesne maszyny objęte badaniami. Jako początkowe zmienne wejściowe przyjęto rok wprowadzenia modelu maszyny rolniczej na rynek oraz jej zapotrzebowanie na moc. Następnie opracowano 10 modeli neuronowych – po 5 dla każdego typu maszyny. Modelami tymi były wielowarstwowe perceptrony oraz sieci o radialnych funkcjach bazowych.

Słowa kluczowe: nowoczesność, prognozowanie, maszyny rolnicze, sieci neuronowe

Wstęp

Obecna sytuacja na rynku maszyn rolniczych spowodowała, między innymi, pojawienie się nowego problemu. Jest to decyzja dotycząca wyboru modelu maszyny dla konkretnego gospodarstwa. Trudność polega na dokonaniu optymalnego wyboru spośród wielu modeli danej maszyny oferowanej przez różnych producentów. Wybór ten jest obciążony pewnym subiektywizmem, wynikającym chociażby z przyjęcia kryteriów decyzyjnych, które należy uwzględnić przy podejmowaniu decyzji. Jednym z kryteriów, które należy brać pod uwagę przy podejmowaniu tego rodzaju decyzji inwestycyjnych jest nowoczesność maszyny.

Nowoczesność maszyny zależy od wielu kryteriów szczegółowych. Część z nich stanowią parametry techniczne charakteryzujące dany typ maszyny. Opracowana przez autora metoda prognozowania wartości parametrów technicznych nowoczesnych maszyn rolniczych [Francik 2006a] pozwala na uzyskanie odpowiedzi, jakimi wartościami parametrów powinna się charakteryzować nowoczesna maszyna w przyszłości. Umożliwia to z kolei pośrednią ocenę, który z modeli maszyny jest najbardziej perspektywiczny. A zatem ocena ta może stanowić pomoc przy optymalizacji decyzji dotyczącej wyboru.

Wspomniana metoda własna, wykorzystująca sztuczne sieci neuronowe, została szczegółowo przedstawiona na przykładzie złożonych systemów technicznych, jakimi są ciągniki rolnicze [Francik 2006b] i kombajny zbożowe [Francik 2007].

Cel pracy

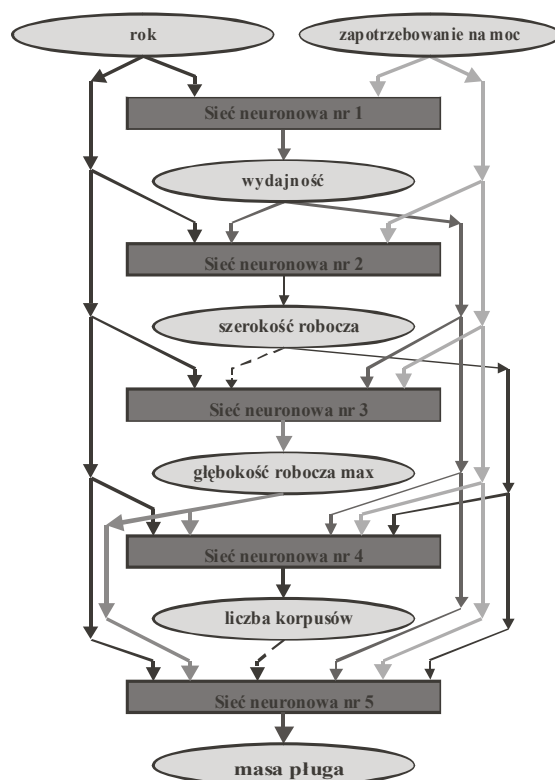
Celem pracy było zastosowanie opracowanej przez autora metody prognozowania wartości parametrów technicznych ciągników rolniczych do innych maszyn rolniczych. Badania przeprowadzono dla pługów oraz opryskiwaczy zawieszanych.

Metodyka badań

Badania przeprowadzono w kilku etapach:

Etap 1. Utworzenie baz danych zawierających wartości parametrów technicznych dla pługów zawieszanych i opryskiwaczy zawieszanych (polowych).

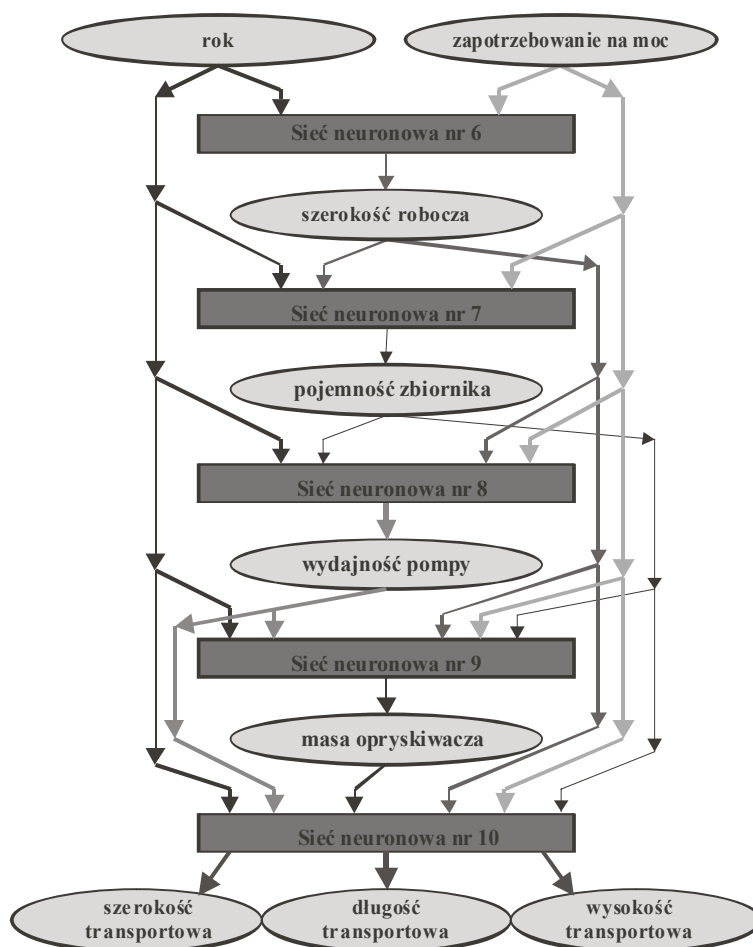
W bazie znalazły się modele maszyn, które zostały wprowadzone do sprzedaży na polskim rynku w latach od 1961 do 2005. Były to 172 modele pługów zawieszanych oraz 147 modeli opryskiwaczy polowych zawieszanych.



Rys. 1. Schemat kolejności wyznaczania parametrów dla pługów zawieszanych
 Fig. 1. Sequence scheme for determining parameters for suspended ploughs

Etap 2. Określenie zmiennych wejściowych, a następnie opracowanie kolejności wyznaczania poszczególnych parametrów charakteryzujących analizowane maszyny.

Jako zmienne wejściowe dla obu badanych typów maszyn przyjęto rok wprowadzenia modelu maszyny rolniczej na rynek oraz zapotrzebowanie na moc. Kolejność wyznaczania poszczególnych parametrów dla pługów i opryskiwaczy przedstawiono na schematach (rys. 1 i 2).



Rys. 2. Schemat kolejności wyznaczania parametrów dla opryskiwaczy polowych
Fig. 2. Sequence scheme for determining parameters for field spraying machines

Etap 3. Opracowanie modeli neuronowych do wyznaczania poszczególnych parametrów.

Do tworzenia sieci neuronowych wykorzystano program Statistica Sieci Neuronowe v.6.1. Badano przydatność różnego rodzaju sieci: liniowe (LIN), 3 i 4 warstwowe perceptrony (MLP) oraz sieci o radialnych funkcjach bazowych (RBF). W pracy ustalono, że dla każdego z wyznaczanych parametrów testowane będzie 100 sieci o różnych architekturach, z których zachowywano po 10 najlepszych sieci neuronowych. Na podstawie wartości błędu średniokwadratowego (MSE) dla zbioru walidacyjnego (i ewentualnie uczącego) wybierano jedną sieć do wyznaczania danego parametru. Stopień rozbudowania architektury sztucznej sieci neuronowej (liczba neuronów w poszczególnych warstwach) jest ograniczona liczbą wzorców uczących, jakimi dysponujemy podczas tworzenia sieci [Masters 1996, Osiński 1996, Trajer 2005]. Zgodnie z tymi zaleceniami, ograniczono liczbę neuronów w warstwach ukrytych: dla sieci RBF do 30 neuronów, dla trójwarstwowych MLP do 9 neuronów, dla czterowarstwowych MLP do 8 neuronów w pierwszej warstwie ukrytej i 5 neuronów w drugiej warstwie ukrytej.

Następnie dla wybranych modeli neuronowych dokonano analizy wrażliwości. W przypadku stwierdzenia, że występuje zmienna wejściowa, która powoduje pogorszenie działania modelu była ona eliminowana. Wtedy sztuczna sieć neuronowa (SSN) była opracowywana ponownie.

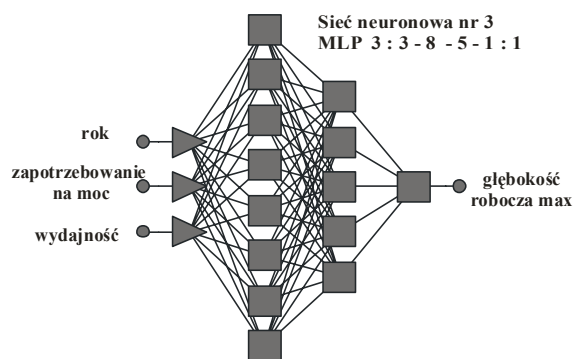
Wyniki badań

Opracowane modele neuronowe stanowiły zarówno sieci RBF, jak również trój- i czterowarstwowe perceptrony o różnym stopniu złożoności.

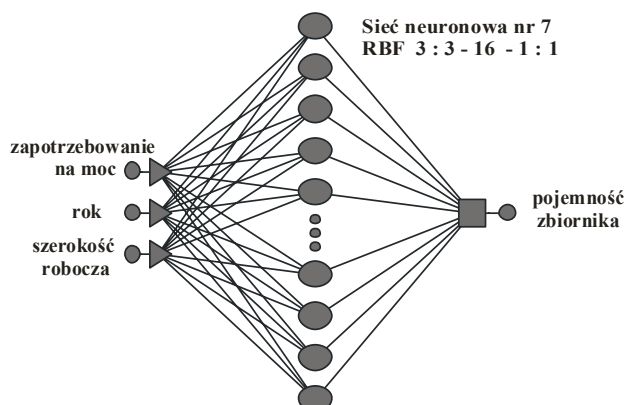
Dla pługów zawieszanych wybrano następujące modele neuronowe:

- sieć nr 1 do wyznaczania wydajności [$\text{ha}\cdot\text{h}^{-1}$] – SSN typu MLP o architekturze 2:2-8-5-1:1 (2 zmienne i neurony wejściowe, 8 neuronów w pierwszej warstwie ukrytej, 5 neuronów w drugiej warstwie ukrytej i 1 neuron wyjściowy), która uzyskała wartości błędu średniokwadratowego: dla zbioru uczącego $\text{MSE}_U = 0,215 \text{ ha}\cdot\text{h}^{-1}$, dla zbioru walidacyjnego $\text{MSE}_W = 0,145 \text{ ha}\cdot\text{h}^{-1}$, dla zbioru testowego $\text{MSE}_T = 0,125 \text{ ha}\cdot\text{h}^{-1}$,
- sieć nr 2 do wyznaczania szerokości roboczej [m] – SSN typu MLP (3:3-2-1:1), dla której $\text{MSE}_U = 0,338 \text{ m}$, $\text{MSE}_W = 0,315 \text{ m}$, $\text{MSE}_T = 0,395 \text{ m}$,
- sieć nr 3 do wyznaczania maksymalnej głębokości roboczej [cm] – SSN typu MLP (3:3-8-5-1:1), która uzyskała wartości $\text{MSE}_U = 2,5 \text{ cm}$, $\text{MSE}_W = 1,4 \text{ cm}$, $\text{MSE}_T = 3,0 \text{ cm}$,
- sieć nr 4 do wyznaczania liczby korpusów – SSN typu MLP (5:5-6-1:1), dla której $\text{MSE}_U = 0,41$, $\text{MSE}_W = 0,43$, $\text{MSE}_T = 0,55$,
- sieć nr 5 do wyznaczania masy pługa [kg] – SSN typu RBF (5:5-14-1:1), która uzyskała wartości $\text{MSE}_U = 160 \text{ kg}$, $\text{MSE}_W = 150 \text{ kg}$, $\text{MSE}_T = 185 \text{ kg}$.

Wyniki analizy wrażliwości przeprowadzone dla wybranych modeli neuronowych wykazały, że możliwe jest zwiększenie dokładności działania sieci nr 3 i sieci nr 5 poprzez redukcję liczby zmiennych wejściowych. Dla sieci nr 3 spośród zmiennych wejściowych pominięto szerokość roboczą, a dla sieci nr 5 ze zmiennych wejściowych wyeliminowano liczbę korpusów. Na schemacie (rys. 1) zmienne te zaznaczono liniami przerywanymi. Schemat przykładowego modelu neuronowego dla pługów zawieszanych przedstawiono na rys. 3.



Rys. 3. Schemat sieci neuronowej nr 3 do wyznaczenia maksymalnej głębokości roboczej
Fig. 3. Diagram of neural network no. 3 for determining maximum working depth



Rys. 4. Schemat sieci neuronowej nr 7 do wyznaczenia pojemności zbiornika
Fig. 4. Diagram of neural network no. 7 for determining tank capacity

Dla opryskiwaczy polowych najdokładniej działające modele neuronowe były w większości sieciami typu RBF:

- sieć nr 6 do wyznaczenia szerokości roboczej [m] – SSN typu MLP (2:2-2-2-1:1), która uzyskała wartości błędu średniokwadratowego: dla zbioru uczącego $MSE_U = 2,8$ m, dla zbioru walidacyjnego $MSE_W = 3,2$ m, dla zbioru testowego $MSE_T = 4,1$ m,
- sieć nr 7 do wyznaczenia pojemności zbiornika [dm^3] – SSN typu RBF (3:3-16-1:1), dla której $MSE_U = 105$ dm^3 , $MSE_W = 130$ dm^3 , $MSE_T = 152$ dm^3 ,
- sieć nr 8 do wyznaczenia wydajności pompy [$dm^3 \cdot min^{-1}$] – SSN typu RBF (4:4-10-1:1), dla której $MSE_U = 16,8$ $dm^3 \cdot min^{-1}$, $MSE_W = 16,6$ $dm^3 \cdot min^{-1}$, $MSE_T = 17,0$ $dm^3 \cdot min^{-1}$,

- sieć nr 9 do wyznaczania masy opryskiwacza [kg] – SSN typu RBF (5:5-8-1:1), która uzyskała wartości $MSE_U = 48$ kg, $MSE_W = 55$ kg, $MSE_T = 59$ kg,
- sieć nr 10 do wyznaczania wymiarów transportowych maszyny [cm] – SSN typu RBF (6:6-3-3:3), dla której $MSE_U = 33$ cm, $MSE_W = 34$ cm, $MSE_T = 56$ cm.

Analiza wrażliwości przeprowadzona dla sieci neuronowych wyznaczających wartości parametrów opryskiwaczy wykazała, że wszystkie przyjęte (zgodnie ze schematem – rys.2) zmienne wejściowe są istotne dla dokładności działania wybranych modeli. Schemat przykładowego modelu neuronowego dla opryskiwaczy polowych zawieszanych przedstawiono na rys. 4.

Podsumowanie

Zastosowana metoda prognozowania wartości parametrów nowoczesnych maszyn rolniczych może stanowić, zdaniem autora, narzędzie wspomagające podejmowanie decyzji inwestycyjnych przez rolników. O ile bowiem istnieje wiele metod doboru parku maszynowego gospodarstwa, które pozwalają określić ile i jakich maszyn rolniczych (o jakiej wydajności) należy zastosować w danym gospodarstwie, to brak jest narzędzi do wspomaganego wyboru pomiędzy modelami maszyn o podobnej wydajności oferowanymi przez różnych producentów. Proponowana metoda może zostać również wykorzystana przy opracowywaniu założeń projektowych dotyczących wartości parametrów technicznych nowych modeli maszyn, które mają dopiero zostać wprowadzone na rynek.

Wyniki przeprowadzonych badań potwierdziły, że opracowana przez autora metoda prognozowania wartości parametrów technicznych nowoczesnych ciągników rolniczych, może być z powodzeniem użyta do prognozowania parametrów pługów oraz opryskiwaczy polowych. A zatem, zdaniem autora, uzasadniona wydaje się stwierdzenie, że metoda ta może być stosowana do dowolnego systemu technicznego.

Wykorzystanie zbioru wielu niezależnych sieci neuronowych do prognozowania wartości parametrów pozwala na dodawanie do tego zbioru nowych modeli neuronowych służących do prognozowania nowych parametrów technicznych. Możliwe jest również modyfikowanie niektórych modeli (np. douczanie przy użyciu nowych uzupełnionych danych) bez wywierania negatywnego wpływu na działanie pozostałych SSN. Jest to zaletą opracowanej metody.

Opracowane modele neuronowe służące do wyznaczania wartości poszczególnych parametrów charakteryzujących badane maszyny stanowią sieci o radialnych funkcjach bazowych (RBF) oraz wielowarstwowe perceptrony (MLP), przy czym dla pługów zawieszanych były to w większości sieci typu MLP, a dla opryskiwaczy polowych (zawieszanych) sieci typu RBF. Nie można zatem stwierdzić, który typ sieci neuronowej lepiej nadaje się do prognozowania parametrów technicznych nowoczesnych maszyn rolniczych.

Bibliografia

- Francik S.** 2006a. Metoda prognozowania wartości parametrów technicznych nowoczesnych maszyn rolniczych. Część I: Metodyka prognozowania parametrów ciągników rolniczych. Inżynieria Rolnicza 11(86). s. 101-108.
- Francik S.** 2006b. Metoda prognozowania wartości parametrów technicznych nowoczesnych maszyn rolniczych. Część II: Modele neuronowe do wyznaczania parametrów ciągników rolniczych. Inżynieria Rolnicza 11(86). s. 109-116.
- Francik S.** 2007. Wyznaczanie wartości podstawowych parametrów technicznych dla nowoczesnych kombajnów zbożowych przy użyciu SSN. Inżynieria Rolnicza 2(90). s. 55-61.
- Osowski S.** 1996. Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa. ISBN 83-204-1976-X.
- Masters T.** 1996. Sieci neuronowe w praktyce. WNT, Warszawa. ISBN 83-204-2061-X
- Trajer J.** 2005. Sztuczne sieci neuronowe w modelowaniu procesów z ograniczonym zbiorem danych w inżynierii rolniczej. Inżynieria Rolnicza 2(62). s. 55-61.

EMPLOYING AN AUTHOR'S METHOD FOR DETERMINING VALUES OF PARAMETERS FOR MODERN TECHNICAL SYSTEMS IN PLOUGHS AND FIELD SPRAYING MACHINES

Abstract. The purpose of the work was to employ an author's method using artificial neural networks to predict values of technical parameters for modern farm machines used in suspended ploughs and field spraying machines. The researchers developed sequence schemes for determining individual parameters characterising modern machines subject to tests. Year of launching a farm machine model into the market and its power demand were taken as initial input variables. Then, 10 neural models were developed – 5 for each machine type. The models were multi-layer perceptrons and networks with radial basic functions.

Key words: modernity, predicting, farm machines, neural networks

Adres do korespondencji:

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