

Sławomir Francik
Katedra Inżynierii Mechanicznej i Agrofizyki
Akademia Rolnicza w Krakowie

METODA PROGNOZOWANIA WARTOŚCI PARAMETRÓW TECHNICZNYCH NOWOCZESNYCH MASZYN ROLNICZYCH CZĘŚĆ II. MODELE NEURONOWE DO WYZNACZANIA PARAMETRÓW CIĄGNIKÓW ROLNICZYCH

Streszczenie

W pracy przedstawiono charakterystykę sztucznych sieci neuronowych opracowanych do prognozowania parametrów nowoczesnych ciągników rolniczych. Przedstawiono dokładność działania modeli, oraz architekturę sztucznych sieci neuronowych. Wśród opracowanych 21 modeli neuronowych znalazło się 16 trzy- i cztero-warstwowych perceptronów, 4 sieci o radialnych funkcjach bazowych i 1 sieć liniowa.

Słowa kluczowe: modele neuronowe, parametry ciągników rolniczych

Wprowadzenie

Do tworzenia modeli neuronowych wykorzystano program Statistica Sieci Neuronowe [Francik 2006]. Dla każdego z 21 wyznaczanych parametrów ciągników rolniczych opracowano 10 różnych sieci neuronowych, przy użyciu funkcji Automatycznego Projektanta Sieci. Sieci te różniły się rodzajem (Liniowa, RBF, MLP) i architekturą, czyli liczbą warstw i liczbą neuronów w poszczególnych warstwach [Niedbała i in. 2005].

Dokładność 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 2005; Ślipek i in, 2003]. MBw obliczono jako sumę średniego błędu względnego i odchylenia standardowego tego błędu, dla zbiorów uczącego (50% wzorców), walidacyjnego i testującego (po 25% wzorców).

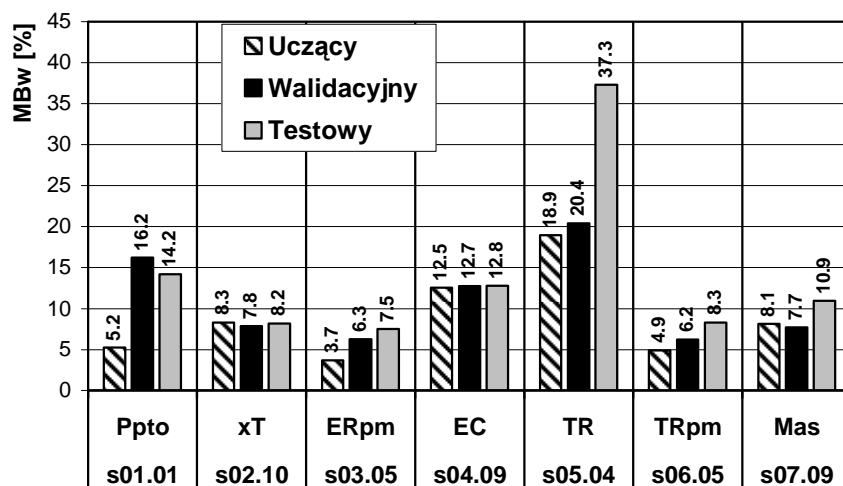
Ostatecznie, na podstawie wartości MBw dla zbioru walidacyjnego, wybrano najlepsze modele dla każdego z wyznaczanych parametrów ciągnika rolniczego. Zestawienie otrzymanych modeli neuronowych, wraz z otrzymywanymi na wyjściu parametrami, zamieszczono w tabeli 1.

Tabela 1. Oznaczenia parametrów ciągnika wyznaczanych za pomocą poszczególnych sieci neuronowych

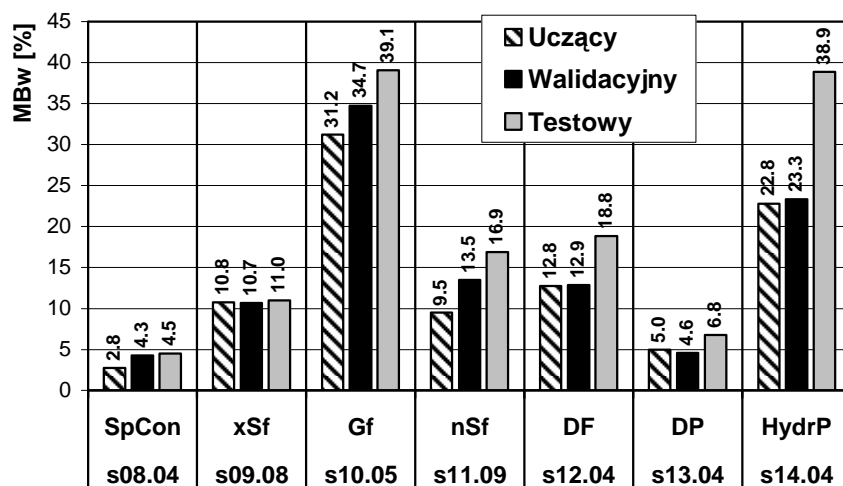
Table 1. Designations of tractor parameters set out by means of individual neural networks

Sieć neuronowa	Wyznaczany parametr ciągnika	Oznaczenie
s01.01	moc na WOM	Ppto
s02.10	maksymalny moment	xT
s03.05	nominalne obroty silnika	ERpm
s04.09	pojemność skokowa	EC
s05.04	wzrost momentu	TR
s06.05	obroty silnika dla momentu maksymalnego	TRpm
s07.09	masa całkowita	Mas
s08.04	jednostkowe zużycie paliwa	SpCon
s09.08	maksymalna prędkość jazdy do przodu	xSf
s10.05	minimalna prędkość jazdy do przodu	nSf
s11.09	liczba biegów do przodu	Gf
s12.04	maksymalna siła uciągu	DF
s13.04	maksymalna moc uciągu	DP
s14.04	moc układu hydraulicznego	HydrP
s15.10	maksymalna siła podnoszenia TUZ z tyłu	LF
s16.05	rozstaw osi	WB
s17.05	minimalny rozstaw kół tylnych	nTAr
s18.03	maksymalny rozstaw kół tylnych	xTAr
s19.05	minimalny rozstaw kół przednich	nTAf
s20.04	maksymalny rozstaw kół przednich	xTAf
s21.09	promień skrętu	TurnR

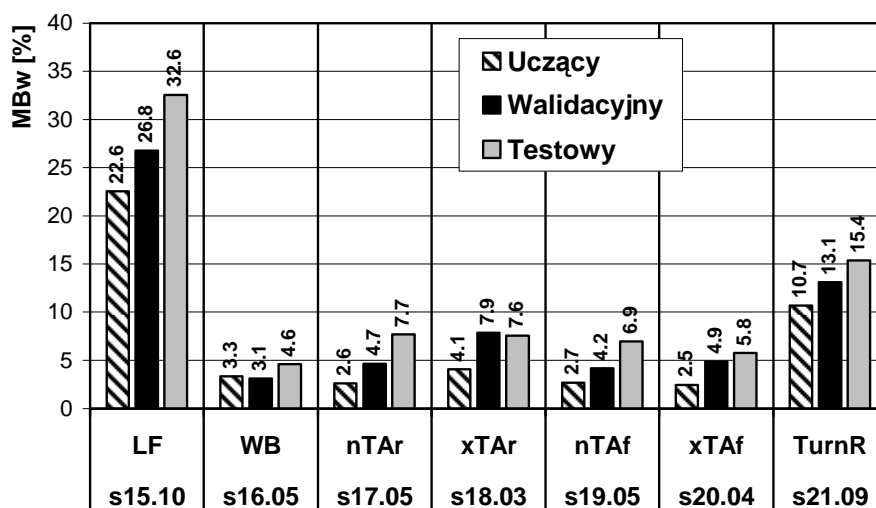
Na rysunkach 1, 2 i 3 przedstawiono wartości miernika MBw dla najlepszych modeli neuronowych (charakteryzujących się najmniejszym błędem dla zbioru danych walidacyjnych).



Rys. 1. Wartości miernika MBw dla modeli neuronowych od 1 do 7
 Fig. 1. Values of MBw measure for neural models from 1 to 7



Rys. 2. Wartości miernika MBw dla modeli neuronowych od 7 do 14
 Fig. 2. Values of MBw measure for neural models from 7 to 14



Rys. 3. Wartości miernika MBw dla modeli neuronowych od 1 do 9

Fig. 3. Values of MBw measure for neural models from 1 to 9

Uzyskane modele mają różną dokładność – 11 modeli uzyskało wartość MBw poniżej 10%, 6 modeli poniżej 20%, 3 modele poniżej 30%, a jedynie model s10.05 uzyskał MBw powyżej 30% (dla danych walidacyjnych). Większość modeli ma dobrą zdolność do uogólniania nabytej wiedzy – niewielka różnica między MBw dla danych testowych i walidacyjnych. Jedynie dla modeli s05.04 (rys. 1) i s14.04 (rys.2) wartość MBw dla danych testowych wzrosła prawie dwukrotnie.

Charakterystyka modeli neuronowych

Jako modele wybrano sieci neuronowe o radialnych funkcjach bazowych (RBF), wielowarstwowe perceptrony (MLP) oraz sieci liniowe. Wśród 21 opracowanych modeli neuronowych najwięcej, bo aż 16, było sieci typu perceptron (tab. 2). Były to sieci zarówno trójwarstwowe (10 modeli) jak i czterowarstwowe (6 modeli). Najbardziej skomplikowaną architekturę miała sieć s19.05 o 8 neuronach wejściowych, 12 neuronach w pierwszej i 10 neuronach w drugiej warstwie ukrytej, oraz 1 neuronie wyjściowym,

Wśród opracowanych modeli były także 4 sieci o radialnych funkcjach bazowych (RBF) i 1 sieć liniowa. Najbardziej rozbudowaną siecią RBF była sieć s15.10 o 6 neuronach wejściowych, 32 neuronach w warstwie ukrytej i 1 neuronie wyjściowym.


Tabela 2. Modele neuronowe (typ sieci i architektura)
 Table 2. Neural models (network type and architecture)

sieć neuronowa	model	Typ sieci i architektura
s01.01	F1	Liniowa 3:3-1:1
s02.10	F2	RBF 3:3-21-1:1
s03.05	F3	MLP 4:4-10-7-1:1
s04.09	F4	RBF 5:5-7-1:1
s05.04	F5	MLP 6:6-7-1:1
s06.05	F6	MLP 7:7-11-9-1:1
s07.09	F7	RBF 7:7-13-1:1
s08.04	F8	MLP 9:9-6-1:1
s09.08	F9	MLP 7:7-4-1:1
s10.05	F10	MLP 8:8-12-1:1
s11.09	F11	MLP 9:9-9-1:1
s12.04	F12	MLP 8:8-3-1:1
s13.04	F13	MLP 8:8-6-1:1
s14.04	F14	MLP 5:5-10-7-1:1
s15.10	F15	RBF 6:6-32-1:1
s16.05	F16	MLP 6:6-2-1:1
s17.05	F17	MLP 6:6-10-3-1:1
s18.03	F18	MLP 7:7-11-9-1:1
s19.05	F19	MLP 8:8-12-10-1:1
s20.04	F20	MLP 9:9-3-1:1
s21.09	F21	MLP 9:9-12-1:1

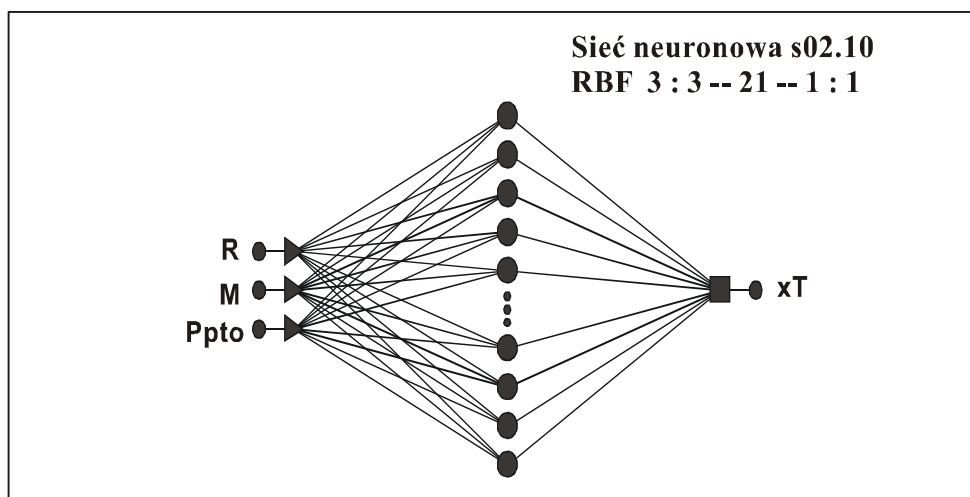
Na rysunkach 4, 5 i 6 przedstawiono schematy trzech przykładowych modeli neuronowych, różniących się typem wykorzystanej sieci.

Sieć neuronowa s01.01 jest siecią liniową (rys. 4) o trzech wejściach (R - rok, M - miesiąc, EP – moc ciągnika), 3 neuronach wejściowych, jednym neuronie wyjściowym i jednym wyjściu – Ppto (moc na WOM). Sieć była uczona metodą pseudoinwersji [Hertz i in. 1995] przy wykorzystaniu 42 przypadków uczących (walidacyjnych i testowych po 21).

Do wyznaczania momentu na WOM (xT) wybrano sieć s02.10 (rys. 5) o radialnych funkcjach bazowych (RBF). Sieć ma trzy zmienne wejściowe (R, M, Ppto), 3 neurony wejściowe, 21 neuronów w warstwie ukrytej, 1 neuron wyjściowy i jedno wyjście. Do uczenia sieci wykorzystano metody: K-średnich, K-najbliższych sąsiadów i pseudoinwersji. Wykorzystano 66 wzorców uczących, 66 walidacyjnych i 66 testowych.

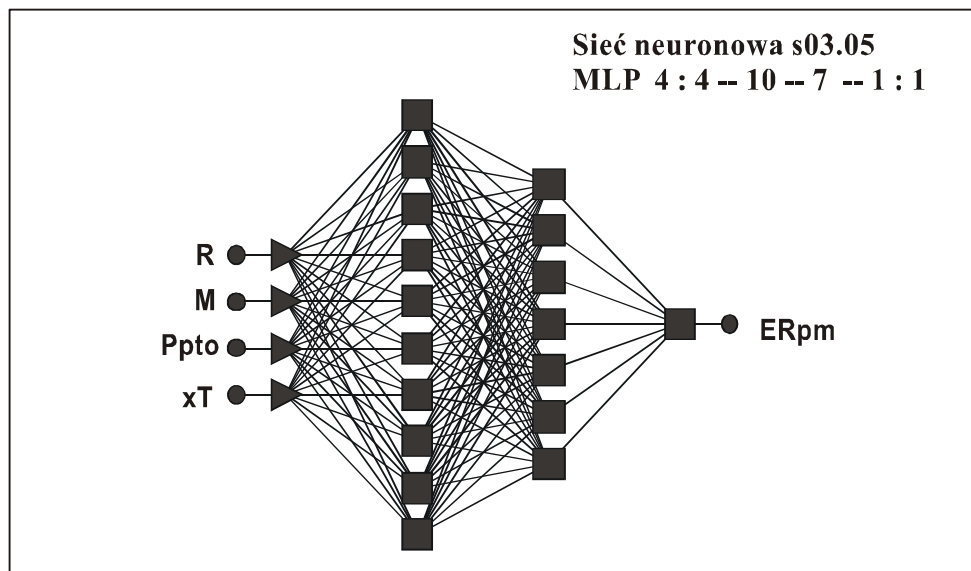


Rys. 4. Schemat sieci neuronowej s01.01
Fig. 4. Diagram of neural network s01.01



Rys. 5. Schemat sieci neuronowej s02.10
Fig. 5. Diagram of neural network s02.10

Sieć neuronowa s03.05 to czterowarstwowy perceptron (MLP) o 4 neuronach wejściowych, 10 neuronach w pierwszej warstwie ukrytej, 7 neuronach w drugiej warstwie ukrytej i 1 neuronie wyjściowym (rys. 6). Jako zmienne wejściowe występują rok (R) i miesiąc (M) wprowadzenia modelu na rynek, moc na WOM (Ppto) i moment na WOM (XT). Sieć ta ma rozbudowaną architekturę – 22 sztuczne neurony. Sieć była uczona algorytmem wstecznej propagacji błędów oraz gradientów sprzężonych – liczba przypadków w zbiorach uczącym, walidacyjnym i testowym taka sama jak dla sieci s02.10.



Rys. 6. Schemat sieci neuronowej s03.05

Fig. 6. Diagram of neural network s03.05

Wnioski

1. Sieci neuronowe można wykorzystać jako narzędzie do prognozowania wartości parametrów technicznych nowoczesnych maszyn rolniczych. Wyniki uzyskane za pomocą modeli neuronowych charakteryzują się dużą dokładnością.
2. Jako modele można zastosować zarówno sieci o radialnych funkcjach bazowych (RBF), jak i wielowarstwowe perceptrony (MLP). Uzyskane modele neuronowe różnią się stopniem rozbudowania ich struktury (liczbą warstw i liczbą neuronów).
3. Opracowane modele neuronowe pozwalają oszacować wartości 21 podstawowych parametrów kołowego ciągnika rolniczego. Zachowując przyjętą kolejność stosowania sieci neuronowych (algorytm wyznaczania parametrów ciągnika rolniczego) można, zadając początkowo jedynie moc silnika i planowany rok wprowadzenia modelu na rynek, uzyskać wartości parametrów jakie powinien mieć projektowany ciągnik.

Bibliografia

Francik S. 2005. Próba zastosowania sztucznych sieci neuronowych do oceny nowoczesności maszyn rolniczych. *Inżynieria Rolnicza* 2005, 8(68), 63-70.

Francik S. 2006. Metoda prognozowania wartości parametrów technicznych nowoczesnych maszyn rolniczych. Część I. Metodyka prognozowania parametrów ciągników rolniczych. *Inżynieria Rolnicza* 2005, (w druku).

Hertz J., Krogh A., Palmer R.G. 1995. Wstęp do teorii obliczeń neuronowych, WNT.

Niedbała G., Przybył J., Sęk T. 2005. Predykcja plonów buraka cukrowego przy wykorzystaniu sztucznych sieci neuronowych. *Inżynieria Rolnicza* 2005, 8(68), 285-292.

Ślipek Z., Francik S., Frączek J. 2003. Metodyczne aspekty tworzenia modeli SSN w zagadnieniach agrofizycznych. *Acta Agrophysica*, 95, 231-241.

METHOD OF FORECASTING TECHNICAL PARAMETER VALUES OF STATE-OF-THE-ART FARM MACHINES PART II. NEURAL MODELS FOR SETTING OUT FARM TRACTOR PARAMETERS

Summary

The paper presents a characteristic of artificial neural networks developed specifically for forecasting parameters of state-of-the-art farm tractors. Accuracy of model performance, and architecture of artificial neural networks were presented. Among 21 developed neural models there were 16 three- and four-layer perceptrons, 4 networks with radial base functions and 1 linear network.

Key words: neural models, farm tractor parameters