

METODA OCENY NOWOCZESNOŚCI TECHNICZNO-KONSTRUKCYJNEJ CIĄGNIKÓW ROLNICZYCH WYKORZYSTUJĄCA SZTUCZNE SIECI NEURONOWE. CZ. II: MODELE NEURONOWE DO OCENY NOWOCZESNOŚCI CIĄGNIKÓW ROLNICZYCH

Sławomir Francik

Katedra Inżynierii Mechanicznej i Agrofizyki, Uniwersytet Rolniczy w Krakowie

Streszczenie. Celem pracy było zbudowanie sztucznych sieci neuronowych przeznaczonych do oceny nowoczesności techniczno–konstrukcyjnej różnych modeli ciągników rolniczych. Te modele neuronowe (wielowarstwowe Perceptrony) pozwalają na ocenę grup cech charakteryzujących: silnik, WOM, uciąg, napęd, wielkość ciągnika, trójpunktowy układ zawieszania, inne cechy, a następnie ocenę całego ciągnika. Sieci te wykazują małe wartości błędów średniokwadratowych (od 1,05 do 2,50 roku dla oceny grup cech, oraz 0,38 i 0,96 roku dla oceny całego ciągnika).

Słowa kluczowe: nowoczesność, ciągnik rolniczy, sztuczne sieci neuronowe

Wstęp

Niniejsza publikacja dotyczy kontynuacji badań zmierzających do opracowania metody oceny nowoczesności techniczno-konstrukcyjnej (NTK), która wykorzystywałaby sztuczne sieci neuronowe (SSN). Przy tworzeniu metody przyjęte zostały trzy założenia [Francik 2009]:

1. Poziom nowoczesności techniczno-konstrukcyjnej ciągnika rolniczego będzie opisany przez wektor cech (parametrów) charakteryzujących dany ciągnik.
2. Do oceny poziomu NTK będzie wykorzystywany zmienny w czasie wzorzec nowoczesnego ciągnika. Miarą poziomu NTK jest różnica między rzeczywistym a wyznaczonym przez SSN rokiem wprowadzenia do produkcji danego modelu.
3. Metoda oceny będzie oparta na technologii sztucznych sieci neuronowych.

Ze względu na dużą liczbę parametrów opisujących ciągnik rolniczy, które są zmiennymi wejściowymi dla sieci neuronowych, opracowane będą niezależne SSN służące do oceny poszczególnych grup cech, oraz dodatkowa sieć neuronowa do końcowej oceny ciągnika.

Cel pracy

Celem pracy było zbudowanie sztucznych sieci neuronowych przeznaczonych do oceny nowoczesności techniczno-konstrukcyjnej różnych modeli ciągników rolniczych, przy uwzględnieniu przyjętych uprzednio założeń.

Metodyka przeprowadzonych badań

Opracowanie modeli neuronowych wymagało zgromadzenia danych, które były następnie wykorzystywane w procesie uczenia. Badania przeprowadzono dla różnych modeli kołowych ciągników rolniczych wprowadzonych do produkcji w latach od 1985 do 2007, przez firmy: Case, Massey Ferguson, John Deere i New Holland. Analizą objęte zostały modele ciągników o mocy silnika od 33kW do 200kW, z napędem na jedną oś (2WD), możliwością włączenia napędu na przednią oś (FWA) i stałym napędem na obie osie (4WD).

Aby maksymalnie zobiektywizować ocenę, dane dotyczące poszczególnych modeli ciągników zaczerpnięto z testów Nebraska i OECD, dla których pomiary wartości poszczególnych parametrów są ujednolicone.

Opracowano wstępną listę zmiennych do oceny poszczególnych grup: klasy projektowej ciągnika (3 wielkości), silnika (14 cech), wałka odbioru mocy (5 cech), uciagu (15 cech), przeniesienia napędu (6 cech), wielkości ciągnika (9 cech), trójpunktowego układu zawieszenia (4 cechy), innych cech (4 cechy). Zmienne, będące wejściami dla poszczególnych sieci neuronowych, miały charakter zarówno ilościowy jak i jakościowy (zmienne skategoryzowane).

Do tworzenia modeli neuronowych wykorzystany został program STATISTICA Sieci Neuronowe v.6.1. Utworzono bazę danych zawierającą wartości zmiennych dla poszczególnych modeli ciągników (przypadków). Przypadki podzielono losowo na trzy zbiory uczący, walidacyjny i testowy, liczące odpowiednio 287 (73,8%), 66 (17,0%) i 36 (9,2%) wzorców.

Przeprowadzone zostały wstępne badania z wykorzystaniem Automatycznego Projektanta (AP) mające na celu sprawdzenie, jaki rodzaj sieci neuronowej najlepiej nadaje się do oceny NTK. Analizowane różne architektury dla sieci Liniowych, RGB oraz MLP. Stwierdzono, że najmniejsze błędy występują dla sieci MLP (3 i 4 warstwowych Perceptronów). Dlatego w dalszych badaniach uwzględniono tylko ten rodzaj SSN.

Budowanie modeli neuronowych do oceny nowoczesności techniczno-konstrukcyjnej przebiegało w dwóch etapach:

Etap I: opracowanie SSN dla poszczególnych grup cech charakteryzujących ciągnik rolniczy (7 modeli);

Etap II: opracowanie jednej SSN dla końcowej oceny ciągnika na podstawie ocen częściowych, uzyskanych dla poszczególnych grup cech.

W etapie I dla każdego z modeli przebadano po 100 sieci neuronowych o różnych architekturach, z których wybrano po 10 charakteryzujących się najmniejszymi wartościami błędów. Jako miarę jakości działania modeli neuronowych przyjęto błąd średniokwadratowy (E_{RMS}) [Maters 1996]. Następnie przeprowadzono normalizację (skalowanie) wartości zmiennych wejściowych, aby sprawdzić czy zabieg ten zmniejszy błędy uzyskiwanych modeli neuronowych [Górski i in. 2008]. Przeliczenie wartości zmiennych wykonano według wzoru [Łapczyńska-Kordon i in. 2006]:

$$normX_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

gdzie:

- $normX_i$ – i -ta wartość po normalizacji,
- X_i – i -ta wartość rzeczywista (przed normalizacją),
- X_{min} – graniczna wartość rzeczywista minimalna,
- X_{max} – graniczna wartość rzeczywista maksymalna.


Wartości graniczne minimalne i maksymalne przyjmowano w taki sposób, aby uzyskane wartości po normalizacji mieściły się w przedziale (0,15; 0,80).

Wykonano analizę wrażliwości w celu ewentualnego odrzucenia dla poszczególnych modeli zmiennych wejściowych, które nie wpływają na polepszenia jakości działania modelu neuronowego (nie zmniejszają wartości błędu). Następnie dla najlepszych modeli przeprowadzono dodatkowy proces douczania, aby dodatkowo osiągnąć zmniejszenie błędów. Zarówno podczas wstępnego określenia złożoności sieci z wykorzystaniem Automatycznego Projektanta, jak i podczas procesu douczania najlepszych sieci neuronowych zastosowano metodę wstecznej propagacji błędu, a następnie metodę gradientów sprzężonych. Przy czym, podczas douczania ustalono liczbę epok na 1000 dla każdej z metod.

Proces opracowania modelu neuronowego w etapie II przeprowadzono w analogiczny sposób jak w etapie I (budowa SSN z wykorzystaniem AP a następnie douczanie najlepszych sieci). Wielkościami wejściowymi dla sieci neuronowych były zmienne charakteryzujące klasę projektową ciągnika (XX_1, XX_2, XX_3) oraz wyniki ocen danego modelu ($YS, YW, YU, YN, YM, YT, YR$) dla grup cech ocenianych w etapie I (zgodnie z przyjętymi wcześniej założeniami [Francik 2009]). Wartości zmiennych wejściowych XX_1 i XX_2 były normalizowane (podobnie, jak w etapie I), natomiast wartości pozostałych zmiennych wejściowych (Yi – ocen poszczególnych grup cech) nie poddano normalizacji.

Wyniki badań

Porównanie dokładności działania sieci neuronowych wykorzystujących dane pierwotne i normalizowane (skalowane) wykazało, że średnie wartości błędu E_{RMS} dla zbiorów uczącego i walidacyjnego nie różnią się zasadniczo (rys. 1). Nieznacznie mniejsze błędy uzyskały SSN wykorzystujące na wejściu zmienne normalizowane, dlatego też tak przeliczone dane były stosowane do budowy sieci neuronowych.



Rys. 1. Wartości błędu średniokwadratowego dla danych pierwotnych i normalizowanych (U-zbiór uczący; W-zbiór walidacyjny)

Fig. 1. Mean square error values for primary and standardised data (U-teaching set; W-validation set)

Analiza wrażliwości, przeprowadzona dla uzyskanych modeli neuronowych, umożliwiła redukcję liczby zmiennych wejściowych dla sieci neuronowych służących do oceny poszczególnych grup cech (etap I). Ostatecznie modele (zależności pomiędzy wyjściem a zmiennymi wejściowymi) przyjęły postać:

$$\begin{cases} YS = f(XK_{01}, XK_{02}, XS_{01}, \dots, XS_{14}) \\ YW = f(XK_{01}, XK_{02}, XK_{03}, XW_{01}, XW_{02}, XW_{03}) \\ YU = f(XK_{01}, XK_{02}, XK_{03}, XU_{01}, \dots, XU_{14}) \\ \left. \begin{aligned} YN &= f(XK_{01}, XK_{02}, XN_{01}, \dots, XN_{06}) \\ YM &= f(XK_{01}, XK_{02}, XM_{01}, \dots, XM_{09}) \\ YT &= f(XK_{01}, XK_{02}, XK_{03}, XT_{01}, \dots, XT_{04}) \\ YR &= f(XK_{01}, XK_{02}, XR_{01}, XR_{02}, XR_{03}) \end{aligned} \right\} \end{cases}$$

gdzie:

Yi – ocena (S – silnika, W – wałka odbioru mocy, U – uciągu, N – napędu, M – wielkości ciągnika, T – trójpunktowego układu zawieszenia, R – innych cech) [rok],

XK_1 – moc przy nominalnych obrotach silnika [kW],

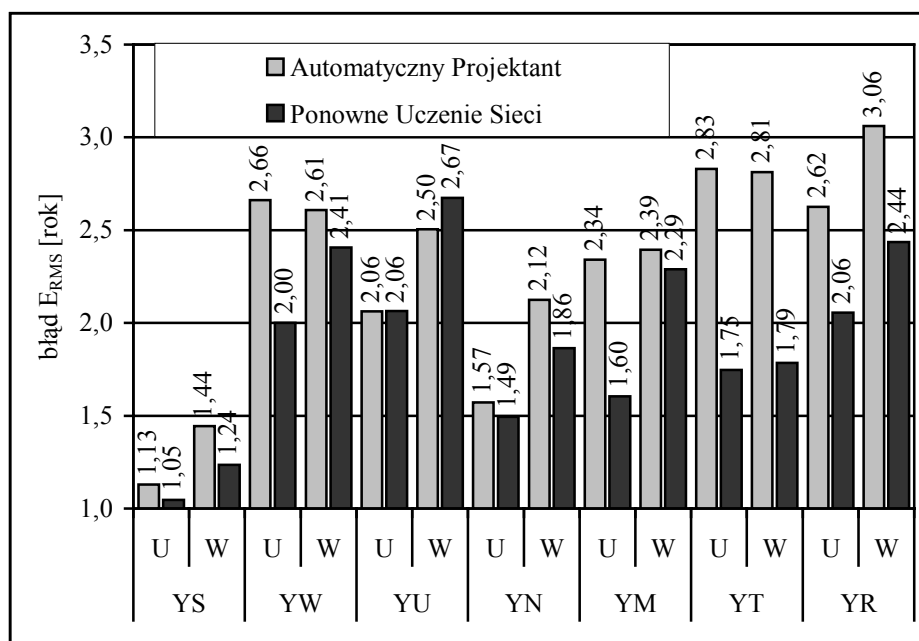
XK_2 – masa całkowita ciągnika bez operatora [kg],

XK_3 – typ podwozia (napęd na jedną lub dwie osie),

- XS₀₁* – nominalne obroty silnika [obr·min⁻¹],
- XS₀₂* – jednostkowe zużycie paliwa przy nominalnych obrotach silnika [g·kWh⁻¹],
- XS₀₃* – moc maksymalna [kW],
- XS₀₄* – obroty silnika przy mocy maksymalnej [obr·min⁻¹],
- XS₀₅* – jednostkowe zużycie paliwa przy mocy maksymalnej [g·kWh⁻¹],
- XS₀₆* – moment maksymalny [Nm],
- XS₀₇* – obroty silnika dla momentu maksymalnego [obr·min⁻¹],
- XS₀₈* – zapas momentu [%],
- XS₀₉* – typ silnika (turbodoładowanie),
- XS₁₀* – liczba cylindrów,
- XS₁₁* – pojemność skokowa [cm³],
- XS₁₂* – stopień sprężania,
- XS₁₃* – średnica tłoka [mm],
- XS₁₄* – skok tłoka [mm],
- XW₀₁* – moc przy nominalnych obrotach WOM [kW],
- XW₀₂* – nominalne obroty WOM [obr·min⁻¹],
- XW₀₃* – moment przy nominalnych obrotach WOM [Nm],
- XU₀₁* – maksymalna moc uciągu [kW],
- XU₀₂* – siła uciągu dla maksymalnej mocy uciągu [kN],
- XU₀₄* – obroty silnika dla maksymalnej mocy uciągu [obr·min⁻¹],
- XU₀₅* – jednostkowe zużycie paliwa dla maksymalnej mocy uciągu [g·kWh⁻¹],
- XU₀₆* – poślizg dla maksymalnej mocy uciągu [%],
- XU₀₇* – maksymalna siła uciągu [kN],
- XU₀₈* – moc uciągu dla maksymalnej siły uciągu [kW],
- XU₀₉* – prędkość jazdy dla maksymalnej siły uciągu [km·h⁻¹],
- XU₁₁* – jednostkowe zużycie paliwa dla maksymalnej siły uciągu [g·kWh⁻¹],
- XU₁₂* – poślizg dla maksymalnej siły uciągu [%],
- XU₁₃* – ciągnik testowany z (lub bez) balastem,
- XU₁₄* – liczba kół na osi tylnej podczas testu,
- XN₀₁* – rodzaj skrzyni biegów,
- XN₀₂* – liczba biegów do przodu,
- XN₀₃* – liczba biegów do tyłu,
- XN₀₄* – prędkość nominalna na najniższym biegu [km·h⁻¹],
- XN₀₅* – prędkość nominalna na najwyższym biegu [km·h⁻¹],
- XN₀₆* – rodzaj sprzęgła,
- XM₀₁* – masa całkowita ciągnika z operatorem bez balastu [kg],
- XM₀₂* – masa całkowita ciągnika z operatorem z balastem [kg],
- XM₀₃* – masa przypadająca na oś tylną testowanego ciągnika z operatorem [kg],
- XM₀₄* – rozstaw osi [mm],
- XM₀₅* – minimalny rozstaw kół osi przedniej [mm],
- XM₀₆* – maksymalny rozstaw kół osi przedniej [mm],
- XM₀₇* – minimalny rozstaw kół osi tylnej [mm],
- XM₀₈* – maksymalny rozstaw kół osi tylnej [mm],
- XT₀₁* – udźwig podnośnika (maksymalny) [kg],
- XT₀₂* – wydatek pompy podnośnika przy minimalnym ciśnieniu [dm³·min⁻¹],

- XT_{03} – wydatek pompy przy maksymalnej mocy hydraulicznej [$\text{dm}^3 \cdot \text{min}^{-1}$],
 XT_{04} – moc układu hydraulicznego [kW],
 XR_{01} – obecność kabiny lub jej brak,
 XR_{02} – maksymalny poziom hałasu na stanowisku operatora [dB(A)],
 XR_{03} – typ układu hamulcowego.

Dodatkowe uczenie najlepszych modeli neuronowych uzyskanych z Automatycznego Projektanta spowodowało w większości przypadków zamierzone zmniejszenie wartości błędów średniokwadratowych (rys. 2). Wyjątkiem była sieć neuronowa przeznaczona do oceny uciagu (YU), w związku z tym do dalszych badań pozostawiona została SSN uzyskana przy użyciu Automatycznego Projektanta. Błąd E_{RMS} uzyskany przez tą SSN nie zmienił się dla zbioru uczącego, a dla zbioru walidacyjnego zwiększył o 6,8%. Dla pozostałych modeli neuronowych wartość błędu zmniejszyła się od 4,4% (YM zbiór walidacyjny) do 38,3% (YT zbiór uczący). Średnie zmniejszenie błędu E_{RMS} dla wszystkich modeli neuronowych wyniosło 15,5%.



Rys. 2. Zmiany wartości błędu E_{RMS} podczas opracowywania SSN dla etapu I (U-zbiór uczący; W-zbiór walidacyjny)

Fig. 2. Changes in the E_{RMS} error values while developing the ANN for a stage (U-teaching set; W-validation set)

Model dla sieci neuronowych służących do oceny końcowej nowoczesności techniczno-konstrukcyjnej ciągników rolniczych (etap II badań) miał postać:

$$YC = f(XK_{01}, XK_{02}, XK_{03}, YS, YW, YU, YN, YM, YT, YR)$$

gdzie:

- YC** – ocena końcowa ciągnika, [rok],
- XK₁** – moc przy nominalnych obrotach silnika, [kW],
- XK₂** – masa całkowita ciągnika bez operatora, [kg],
- XK₃** – typ podwozia (napęd na jedną lub dwie osie),
- Yi** – ocena (**S**– silnika, **W**– wałka odbioru mocy, **U**– uciągu, **N**– napędu, **M**– wielkości ciągnika, **T**– trójpunktowego układu zawieszenia, **R**– innych cech), [rok],

Analiza wrażliwości wykazała, że wszystkie przyjęte zmienne wejściowe wpływają na poprawę dokładności działania opracowanego modelu. Dodatkowe uczenie najlepszego modelu uzyskanego przy użyciu Automatycznego Projektanta pozwoliło zmniejszyć błąd średniokwadratowy E_{RMS} dla zbioru uczącego o 51,3%. Natomiast dla zbioru walidacyjnego błąd ten nieznacznie wzrósł (o 2,5%).

Podsumowanie i wnioski

Przeprowadzone badania pozwalają na sformułowanie wniosków:

1. Spośród przebadanych typów sieci neuronowych (sieci liniowe, sieci o radialnych funkcjach bazowych, sieci typu Perceptron) najlepszą dokładność, przy ocenie nowoczesności techniczno-konstrukcyjnej, uzyskały wielowarstwowe Perceptrony.
2. Opracowane modele neuronowe mają różne topologie:
 - YS**: MLP 16:20-6-1:1 (ocena silnika)
 - YW**: MLP 6:10-9-5-1:1 (ocena wałka odbioru mocy)
 - YU**: MLP 16:19-6-5-1:1 (ocena uciągu)
 - YN**: MLP 8:23-5-2-1:1 (ocena napędu)
 - YM**: MLP 11:11-8-4-1:1 (ocena wielkości ciągnika)
 - YT**: MLP 7:10-9-5-1:1 (ocena trójpunktowego układu zawieszenia)
 - YR**: MLP 5:8-9-4-1:1 (ocena innych cech)
 - YC**: MLP 10:13-6-4-1:1 (ocena końcowa ciągnika)
3. Modele neuronowe służące do oceny poszczególnych grup cech charakteryzują się dużą dokładnością - wartości błędu średniokwadratowego E_{RMS} wynoszą od 1,05 do 2,50 roku. Najdokładniejsze były tu oceny silnika (E_{RMS} od 1,05 do 1,24 roku) i układu przeniesienia napędu (E_{RMS} od 1,49 do 1,86 roku), a najmniej dokładne oceny uciągu (E_{RMS} od 2,06 do 2,50 roku) i oceny innych cech (E_{RMS} od 2,06 do 2,44 roku).
4. Model SSN do oceny końcowej ciągnika uzyskał bardzo małe wartości błędu średniokwadratowego (E_{RMS} 0,38 roku dla zbioru uczącego i 0,96 roku dla zbioru walidacyjnego).

Bibliografia

- Francik S.** 2009. Metoda oceny nowoczesności techniczno-konstrukcyjnej ciągników rolniczych wykorzystująca Sztuczne Sieci Neuronowe. Cz. I: Założenia metody. Inżynieria Rolnicza. Nr 9(118). Kraków. s. 41-47.
- Górski M., Kaleta J., Langman J.** 2008. Zastosowanie sztucznych sieci neuronowych do oceny stopnia dojrzałości jabłek. Inżynieria Rolnicza. Nr 7(105). Kraków. s. 53-56.
- Łapczyńska-Kordon B., Francik S., Frączek J., Ślipek Z.** 2006. Modelowanie skurczu suszarniczego wybranych warzyw korzeniowych za pomocą sztucznych sieci neuronowych. Inżynieria Rolnicza. Nr 13(88). Kraków. s. 303-311.
- Masters T.** 1996. Sieci neuronowe w praktyce. WNT. Warszawa. ISBN 83-204-2061-X.

METHOD ALLOWING TO ASSESS TECHNICAL AND CONSTRUCTIONAL MODERNITY OF FARM TRACTORS WITH THE USE OF ARTIFICIAL NEURAL NETWORKS PART II: NEURAL MODELS FOR FARM TRACTOR MODERNITY ASSESSMENT

Abstract. The purpose of the work was to build artificial neural networks designed to assess technical and constructional modernity of various farm tractor models. These neural models (multilayer Perceptrons) allow to evaluate groups of properties that characterise: a motor, power take-off shaft, draw-bar pull, drive, tractor size, three-point suspension system, other properties, and finally - the whole tractor. These networks show low mean square error values (from 1.05 to 2.50 years when assessing groups of properties, and 0.38 and 0.96 years in case of the whole tractor).

Key words: modernity, farm tractor, artificial 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