

Jerzy Napiórkowski, Paweł Mikołajczak
Katedra Budowy, Eksploatacji Maszyn i Pojazdów
Uniwersytet Warmińsko-Mazurski w Olsztynie

MODELE NEURONOWE ZUŻYWANIA ELEMENTÓW ROBOCZYCH W GLEBIE

Streszczenie

Przedstawiono próbę wykorzystania modeli neuronowych do prognozowania zużycia elementów roboczych narzędzi rolniczych użytkowanych w glebie. Podstawą opracowania modeli neuronowych były wyniki uzyskane z badań eksploatacyjnych zużycia lemieszki płuźnych w dziesięciu gatunkach gleb. Wygenerowano 12 modeli neuronowych, oddzielnie dla przyjętych miar zużycia, gatunków gleb oraz postaci konstrukcyjnych elementu roboczego. Nie udało się wygenerować, z odpowiednią dokładnością dopasowania, jednego modelu neuronowego uwzględniającego warunki glebowe oraz postaci konstrukcyjne lemieszki płuźnych.

Słowa kluczowe: zużycie, lemieszki płuźne, gleba, skład granulometryczny, wilgotność, modele neuronowe.

Wprowadzenie

Racjonalna eksploatacja maszyn rolniczych wymaga znajomości przebiegu procesu zużywania elementów roboczych w funkcji czasu użytkowania lub w funkcji obrobionej powierzchni. Dotychczasowy stan wiedzy nie daje odpowiedzi według jakiego modelu można dokładnie prognozować wielkości zużycia elementów roboczych użytkowanych w glebie. Jest to związane między innymi z dużą liczbą czynników wpływających na wielkość zużycia oraz złożonymi zależnościami pomiędzy nimi [Kufel i inni 1998]. Dotychczas opracowane modele zużywania elementów roboczych w glebie można podzielić na dwa rodzaje. Pierwsze z nich wyjaśniają zjawiska obserwowane podczas obróbki gleby [Tenenbaum 1990], drugie umożliwiają prognozowanie trwałości elementów roboczych w glebie, w zależności od wymuszeń systemu bioagrotechnicznego [Napiórkowski 2005, Owsiak 1998]. Użytkownik maszyny roboczej chcąc praktycznie skorzystać z tych modeli (np. chcąc prognozować wartości zużycia) musi określić bardzo wiele wartości parametrów, współczynników, i wielkości fizycznych, które nie są łatwo

wyznaczalne. Brak jest również powszechnie dostępnego zapisu tych modeli w postaci programów komputerowych, które można praktycznie wykorzystywać. Opracowanie modeli matematycznych, pomimo możliwości zastosowań nowoczesnych metod informatycznych, ma swoje ograniczenia. Modele te często przyjmują postać złożoną, np. dla modelu wielomianowego stopnia drugiego, przy czterech zmiennych niezależnych wyznaczanych jest dziesięć parametrów modelu, a upraszczanie do postaci liniowej niesie za sobą niejednokrotnie zbyt duże błędy.

Sz szczególnie dynamicznie rozwijającymi się w ostatnim okresie metodami budowy modeli są sztuczne sieci neuronowe (SSN). Swoją popularność zawdzięczają przede wszystkim możliwościom modelowania dowolnie złożonych i nieliniowych odwzorowań. Są one przy tym narzędziem bardzo wygodnym, niewymagającym od użytkownika bogatej wiedzy odnośnie szczegółowych warunków i założeń. Posiadają ponadto zdolność do samoprogramowania się w procesie uczenia, a znaczna liczba udanych zastosowań w najróżniejszych dziedzinach świadczy o permanentnym i ciągle wzrastającym zainteresowaniu [Cholewa, Moczulski 2004]. Dlatego w pracy podjęto próbę zbudowania modeli neuronowych na przykładzie zużycia lemiszy płużnych w glebie.

Celem pracy jest budowa modeli zużycia się elementów roboczych w glebie, na przykładzie lemiszy płużnych z wykorzystaniem Sztucznych Sieci Neuronowych.

Metodyka badań

Podstawą opracowania modeli z wykorzystaniem SSN były wyniki zużycia lemiszy płużnych uzyskane z badań w naturalnych warunkach glebowych. Badania przeprowadzono w 10 gatunkach gleb (tab. 1).

Tabela 1. Charakterystyka składu granulometrycznego gleb
Table 1. Soil grain composition characteristics

Gatunek gleby	Wilgotność [%]	Zawartość frakcji [%]		
		II <0,02	Pył 0,02-0,1	Piasek 0,1-1,0
II	11,0-12,5	63,8	28,0	8,2
Gлина ciężka	11,0-14,7	52,2	25,4	22,4
Gлина ciężka pylasta	18,0-19,2	52,8	34,9	12,3
Gлина średnia	9,0-12,0	39,2	29,2	31,6
Gлина lekka pylasta	10,9-12,4	32,4	29,2	38,4
Gлина lekka	14,0-17,4	27,8	27,4	44,8
Gлина piaszczysta pylasta	14,8-16,3	22,8	26,2	51,0
Piasek gliniasty mocny	7,9-9,9	20,2	20,6	59,2
Piasek gliniasty lekki	9,4-11,4	14,8	21,0	64,2
Piasek luźny	10,0-12,3	2,6	10,2	87,2

Zawartość frakcji glebowych oceniono zgodnie z BN-78/9180-11. Podstawową charakterystyką stanu gleby była jej wilgotność [Dobrzański, Zawadzki 1995].

Badania wykonano w glebach o jednakowym odczynie, podczas wykonywania orek głębokich na ściernisku przy zachowaniu prędkości około 2 m/s.

Badaniom poddano lemieszki typu Pr59 wykonane ze stali 38GSA w dwóch postaciach konstrukcyjnych: standardowe i z napawanymi krawędziami tnącymi. Lemieszki napawano proszkiem metalicznym PMFe61P z wykorzystaniem napawarki plazmowej NP1 250. W każdych warunkach glebowych przebadano minimum po 5 lemieszki standardowych i napawanych.

Podczas badań zużycie lemieszki scharakteryzowano ubytkiem masy, zmianami długości dzioba oraz maksymalnej szerokości lemieszki. Pomiarów wartości zużycia dokonywano po zaoraniu ustalonej wcześniej powierzchni. Dane do uczenia sieci neuronowej przygotowano w trzech wariantach.

W **pierwszym wariantcie** wykorzystane zostały wszystkie dane zebrane podczas badań eksploatacyjnych (1164 serie danych). Wprowadzono następujące dane wejściowe:

- zaorana powierzchnia [ha],
- rodzaj lemieszki,
- zawartość iłu [%],
- zawartość pyłu [%],
- zawartość piasku [%],
- wilgotność gleby [%].

Dane wyjściowe stanowiły ubytek:

- masy lemieszki [g],
- długości lemieszki [mm],
- maksymalnej szerokości lemieszki [mm].

W **drugim wariantcie** podzielono dane na dwie grupy, podział ten został dokonany pod kątem rodzaju gleby (osobne bazy dla glin i piasków). W bazach uwzględniono po 582 serie danych.

W **trzecim wariantcie** uczenia sieci neuronowej zdecydowano się na rozdzielanie wyników badań, tworząc osobne bazy danych dla rodzaju lemieszki, gatunku gleby i miary zużycia. Utworzono w ten sposób 12 baz z danymi do uczenia SN, w których wyróżniono po 5 wielkości wejściowych (powierzchnia, wilgotność gleby i procentowa zawartość iłu, pyłu i piasku) oraz po jednej wielkości wyjściowej

(zmiana masy lemiesza, zmiana długości lemiesza lub zmiana szerokości lemiesza). Każda baza zawierała po 97 serii danych.

We wszystkich wariantach losowo wybierano 20% serii danych, które zostały wykorzystane do testowania wytrenowanych modeli neuronowych.

Opis zastosowanego symulatora SSN

Do budowy modelu neuronowego zużywania się lemieszy płuźnych wykorzystano program Neuronix [Neuronix 2003], z zastosowaniem metody wstecznej propagacji błędu. Algorytm propagacji wstecznej jest jednym z najskuteczniejszych algorytmów uczenia sieci wielowarstwowej. Jego nazwa pochodzi od sposobu obliczania błędu w poszczególnych warstwach sieci. Najpierw obliczane są błędy w warstwie ostatniej na podstawie porównania aktualnych i wzorcowych sygnałów wyjściowych i na tej podstawie dokonywane są zmiany wag połączeń, następnie w warstwie ją poprzedzającej i tak dalej aż do warstwy wejściowej. W algorytmie propagacji wstecznej można wyróżnić trzy fazy:

- podanie na wejście sygnału uczącego \mathbf{x} i wyliczenie aktualnych wyjść \mathbf{y} .
- porównanie sygnału wyjściowy \mathbf{y} z sygnałem wzorcowym \mathbf{d} , a następnie obliczenie lokalnych błędów dla wszystkich warstw sieci,
- adaptacja wag.

Opisany proces kontynuuje się aż do momentu kiedy sygnały wyjściowe sieci będą dostatecznie bliskie oczekiwany. Celem algorytmu propagacji wstecznej jest optymalizacja funkcji energetycznej [Tadeusiewicz 1993].

Do nauki sieci neuronowej wykorzystano różne architektury sieci tzn. testowano sieci składające się z jednej lub dwóch warstw ukrytych, od trzech do pięciu neuronów w tych warstwach. Ostateczną topologię przyjętych modeli przedstawiono na rys. 1. Każda zmiana parametrów sieci powoduje losowy dobór wag połączeń międzyneuronowych. Dane do uczenia zostały wprowadzone bez przeskalowania, natomiast symulator SSN automatycznie przeskalowuje (w sposób niewidoczny dla użytkownika) daną serię danych do przedziału 0–1, a po wyuczeniu sieci następuje ponowne przeskalowanie na wartości z przyjętymi jednostkami. Jako miarę dopasowania modeli neuronowych do wartości rzeczywistych zastosowano błąd RMS (dla wartości przeskalowanych), taka miara w dużym stopniu upraszcza optymalizację. Ze względu na to, że błąd RMS nie pozwala na oszacowanie błędu pojedynczego wyjścia sieci, dodatkowo wyznaczono błędy bezwzględne, procentowe dla danych testowych.

Wyniki trenowania SN


Wyniki uczenia się SN dla pierwszego i drugiego wariantu danych okazały się niezadowolające. Pomimo prób doboru różnych topologii SN, błąd generowanych wartości neuronów wyjściowych był rzędu kilkudziesięciu procent, niezależnie od tego czy była to zmiana masy, długości czy też szerokości lemiesza, a czas nauki SN sięgał kilkunastu godzin. Wygenerowane modele neuronowe według trzeciego wariantu danych cechowały się błędem rzędu kilku procent dopasowania wartości neuronów wyjściowych do wartości testowych. Maksymalny błąd bezwzględny, we wszystkich 12 wygenerowanych modelach wyniósł 24% i był to przypadek dla piasku luźnego z zawartością żwiru 1,3%, przy zastosowaniu lemiesza nienapawanego. Zestawienie błędów RMS dla 12 ostatecznych modeli przedstawiono w tabeli 2.

Tabela 2. Zestawienie błędów RMS

Table 2. List of RMS errors

Wariant modelu	Błąd RMS uczenia	Błąd RMS testowania
Lemiesz nienapawany, ił lub glina, zmiana masy.	0,023	0,026
Lemiesz nienapawany, ił lub glina, zmiana długości.	0,019	0,022
Lemiesz nienapawany, ił lub glina, zmiana szerokości.	0,021	0,028
Lemiesz napawany, ił lub glina, zmiana masy.	0,009	0,008
Lemiesz napawany, ił lub glina, zmiana długości.	0,012	0,018
Lemiesz napawany, ił lub glina, zmiana szerokości.	0,015	0,019
Lemiesz nienapawany, piasek, zmiana masy.	0,278	0,290
Lemiesz nienapawany, piasek, zmiana długości.	0,105	0,112
Lemiesz nienapawany, piasek, zmiana szerokości.	0,163	0,201
Lemiesz napawany, piasek, zmiana masy.	0,065	0,078
Lemiesz napawany, piasek, zmiana długości.	0,057	0,086
Lemiesz napawany, piasek, zmiana szerokości.	0,109	0,069

Strukturę trenowanych SN dla trzeciego wariantu danych pokazano na rys. 1, natomiast na rys.2 i 3 przedstawiono przykładowe, wygenerowane wartości zużycia odpowiednio lemieszy nienapawanych i napawanych, dla gleby gliniastej.



Rys. 1. Struktura sieci neuronowej dla modelu zużycia w trzecim wariantcie danych, dla gleb gliniastych

Fig. 1. Neural network structure for wear model in the third data variant, for clayey soils

[D:\...\PROJEKTY\NIEPAWGL\NYOSTMASA.LRN]								
A3		1						
Typ	A	B	C	D	E	F	G	
Nazwa	we POW	we IL	we PYL	we PIA	we WIL	wy Ubytek masowy	wy Ubytek wg SN	
3	1	64	28	8	11,8	309	307	
4	2	64	28	8	11,8	598	589	
5	3	64	28	8	11,8	987	981	
6	4	64	28	8	11,8	1376	1370	
7	5	64	28	8	11,8	1645	1641	
8	6	64	28	8	11,8	2092	2111	
9	1	62	28	10	12,5	298	293	
10	2	62	28	10	12,5	609	610	
11	3	62	28	10	12,5	977	974	
12	4	62	28	10	12,5	1403	1415	
13	5	62	28	10	12,5	1668	1670	
14	6	62	28	10	12,5	2086	2110	
15	1	65	29	6	11,4	296	283	

Wartości z badań eksploatacyjnych

Wartości wygenerowane przez SN

Rys. 2. Wygenerowane wartości zużycia masowego dla lemiesz nienapawanego, gleby gliniaste, dane uczenia SN wg wariantu 3

Fig. 2. Generated mass wear values for unpadded ploughshare, clayey soils, the AI learning data according to variant 3

Typ	A	B	C	D	E	F	G
Nazwa	we POW	we IL	we PYL	we PIA	we WIL	wy Ubytek masowy	wy Ubytek wg SN
3	1	64	28	8	11,8	52	48
4	2	64	28	8	11,8	119	102
5	6	64	28	8	11,8	461	420
6	8	64	28	8	11,8	587	581
7	10	64	28	8	11,8	736	726
8	12	64	28	8	11,8	892	815
9	14	64	28	8	11,8	1047	985
10	1	62	28	10	12,5	58	49
11	2	62	28	10	12,5	128	124
12	6	62	28	10	12,5	487	478
13	8	62	28	10	12,5	625	623
14	10	62	28	10	12,5	781	742
15	12	62	28	10	12,5	947	956

Wartości z badań eksploatacyjnych

Wartości wygenerowane przez SN

Rys. 3. Wygenerowane wartości zużycia masowego dla lemieszki napawanej, gleby gliniaste, dane uczenia SN wg wariantu 3

Fig. 3. Generated mass wear values for padded ploughshare, clayey soils, the AI learning data according to variant 3

Podsumowanie

1. Wygenerowane modele neuronowe dla wariantu 1 i 2 cechowały znacznym błędem dopasowania teoretycznych wartości zużycia się lemieszki w stosunku do wartości empirycznych (10–60% przy uczeniu sieci, 30–90% przy testowaniu).
2. Wyniki uczenia, jak i testowania sieci neuronowej dla danych przygotowanych według trzeciego wariantu były zadawalające (błąd maksymalny dla procesu uczenia wynosił 4%, zaś dla testowania do 24%).
3. Najlepsze dopasowanie wygenerowanego modelu neuronowego miało miejsce dla gleby gliniastej i lemieszki napawanej, zaś największe rozbieżności występowały dla lemieszki nienapawanej w przypadku piasków luźnych i małych powierzchni orki (do 2 ha). Należy jednak zauważyć, że dla praktycznego wykorzystania wytrenowanych sieci neuronowych do prognozowania zużycia lemieszki w glebie, nawet wartości błędów na poziomie 20–30% nie sprawiają, że wygenerowane wartości zużycia są niewiarygodne.

Same wartości obserwacji empirycznych, dla jednakowych warunków eksperymentu, przy powtórzeniach, charakteryzują się rozrzutem kilkunasto procentowym.

4. Uzyskane modele neuronowe zachęcają do dalszych prób wykorzystania metod sztucznej inteligencji do badania zużywania elementów roboczych w glebie.

Bibliografia

Cholewa W., Moczulski W. 2004. Elementy sztucznej inteligencji w diagnostyce technicznej. Inżynieria Diagnostyki Maszyn. PTDT Radom.

Dobrzański B., Zawadzki S. 1995. Gleboznawstwo, PWRiL Warszawa.

Kufel K., Wierzcholski K., Czajkowski A.A. 1998. Experimental and analytical wear study of plough sheares with the elastic and rigid connections to the frame. Tribologia, nr 5; 740 – 753.

Neronix – Instrukcja Obsługi Symulatora Sztucznych Sieci Neuronowych. 2003. Katowice.

Owsiak Z. 1998. Narzędzia skrawające glebę. Akademia Rolnicza Wrocław.

Napiórkowski J. 2005. Zużyciowe oddziaływanie gleby na elementy robocze narzędzi rolniczych. Inżynieria Rolnicza, nr 12.

Tadeusiewicz R. 1993. Sieci neuronowe. Akademicka Oficyna Wydawnicza RM, Warszawa.

Tenenbaum M. M. 1990. O vidah, processah i mehanizmah abrazivnogo iznašivaniâ. Dolgovečnost' trušihsâ detalej mašin, Sbornik naučnych statej, wyp. 5, s. 202-215. Mašinostroenie, Moskva.

NEURAL MODELS FOR WEARING OF WORKING ELEMENTS IN SOIL

Summary

The paper presents an attempt to use neural models to forecast wear of agricultural tool elements working in soil. Development of neural models was based on the results obtained after operation tests of ploughshare wear in ten soil types. 12 neural models were generated, separately for accepted wear measures, soil types and working element constructional forms. It turned out to be impossible to generate, with suitable matching accuracy, a single neural model taking into account soil conditions and ploughshare constructional forms.

Key words: wear, ploughshares, soil, grain composition, moisture content, neural models