

ZASTOSOWANIE SIECI NEURONOWEJ DO OKREŚLANIA EFEKTYWNOŚCI PRACY ROZDRABNIACZA LEŚNEGO

Michał Maksymiak, Andrzej Grieger

Zakład Użytkowania Maszyn i Urządzeń Rolniczych, Akademia Rolnicza w Szczecinie

Streszczenie. Poprawa jakości użytkowania maszyn do prac w lesie wymaga stosowania nowoczesnych narzędzi wspomagających decyzje. Celem pracy była budowa SSN do wspomaganie procesu decyzyjnego w zakresie wyznaczania efektywności wykorzystania rozdrabniacza leśnego na podstawie przewidywanych parametrów pracy. Badania przeprowadzono na dwóch różnych zestawach maszyn; ciągnika rolniczego ZTS 16245 w połączeniu z rozdrabniaczem Seppi m, i ciągnika rolniczego Crystal 160 z rozdrabniaczem Atila ST. Zebrane dane z badań stosowano do uczenia szeregu złożonych sieci neuronowych. Parametrem wyjściowym w procesie uczenia była efektywność pracy rozdrabniacza leśnego wyrażona w rbh/ha. Porównano szereg modyfikacji wag sieci. Jako właściwe rozwiązanie w postaci nauczonej sieci przyjęto najmniejszy błąd względny uzyskany po zakończeniu procesu uczenia. Powyższe badania wykazały, że różnice błędu względnego dla różnych układów SSN są nieznaczne, mianowicie występują w przedziale od 10,7% do 19,1%. Możliwe zatem jest stosowanie tego typu rozwiązania jako narzędzia ułatwiającego zarządzanie techniką do prac leśnych.

Słowa kluczowe: Sztuczne Sieci Neuronowe, rozdrabniacz leśny, efektywność

Wprowadzenie

Zasadniczym etapem prac pozyskaniowych w gospodarce leśnej jest przygotowanie powierzchni zrębu pod następny zabieg jakim jest odnowienie. Prace te polegają na uprzątnięciu i zagospodarowaniu pozostałości po zrębowych, które warunkują zwiększoną udatność upraw.

Wśród najczęściej stosowanych metod zagospodarowania pozostałości po zrębowych na powierzchni leśnej wyróżniamy: palenie gałęzi (obecnie coraz rzadziej stosowane), zrębkowanie biomasy z przeznaczeniem na materiał opałowy, względnie kompost, rozdrobnienie pozostałości po ścinie za pomocą rozdrabniacza sprzężonego z ciągnikiem i pozostawienie rozdrobnionej masy na powierzchni celem wzbogacenia gleby [Gałązka i in. 2002].

Na efektywność zestawów maszyn wpływa szereg czynników opisujących charakterystykę i warunki pracy. Maszyny użytkowane w leśnictwie cechuje duża różnorodność parametrów zmiennych występujących w pojedynczych obszarach działań co oznacza, że trudno jest określić dokładnie faktyczną efektywność ich pracy [Maksymiak 2005].

Występującą niepewność co do oceny można zminimalizować poprzez zastosowanie w procesie wspomaganie zarządzania pracą maszyny, nowego rozwiązania w postaci sieci neuronowej. W badaniach sieci neuronowej wykorzystano standardowy program Neuronix.

Program ten poprzez zdolność kojarzenia informacji oraz „uczenia się” ma szerokie spektrum zastosowania w technice rolniczej i leśnej [Korbicz 1994].

Metodyka badań eksploatacyjnych

Rozdrabnianie biomasy za pomocą rozdrabniacza i pozostawienie jej w stanie rozrzuconym na powierzchni jest jedną z najczęściej stosowanych metod utylizacji odpadów poeksploatacyjnych [Laurow 2001] (rys. 1).



Rys. 1. Powierzchnia zrębowa przed (lewa strona zdjęcia) i po wykonaniu pracy (prawa strona zdjęcia) przez rozdrabniacz Seppi m

Fig. 1. Area frame before (left side) and after execution work (right side) by forestry shredder Seppi m

Obiektem badań były zestawy maszynowe: a) ciągnik ZTS 16245 z rozdrabniaczem leśnym Seppi m, b) ciągnik Crystal 160 sprzężony z rozdrabniaczem Atilla st (tab. 1). Badania zostały przeprowadzone na terenie Regionalnej Dyrekcji Lasów Państwowych w Szczecinie i polegały na obserwacji i rejestracji warunków pracy urządzeń w trakcie całego dnia roboczego. Dane rejestrowano w okresie od 1 kwietnia 2004 do 31 marca 2005.

Celem badań było ustalenie wpływu poszczególnych czynników na efektywność pracy związanej z organizacją pracy rozdrabniacza leśnego. Parametry mierzone to: skład gatunkowy rozdrabnianego materiału; wilgotność rozdrabnianego materiału; stopień wykrzesania gałęzi; rodzaj rozmieszczenia rozdrabnianego materiału na powierzchni; występowanie podszytu; rodzaj podłoża jezdnego; ukształtowanie terenu; stopień zakamienienia powierzchni; stopień zapniaczenia powierzchni.

Tabela 1. Dane techniczne badanych zestawów maszyn
Table 1. Technical data of research machines

Zestaw „a”		Zestaw „b”	
Ciągnik	ZTS 16245	Ciągnik	Crystal 160
Liczba cylindrów silnika	6	Liczba cylindrów silnika	6
Pojemność skokowa [cm ³]	6842	Pojemność skokowa [cm ³]	7146
Moc [kW]	114	Moc [kW]	115
Rok produkcji	1996	Rok produkcji	2004
Rozdrabniacz	Seppi m	Rozdrabniacz	Atilla st
Szerokość robocza [m]	2.0	Szerokość robocza [m]	1.4
Rok produkcji	2000	Rok produkcji	2002

Źródło: Opracowanie własne autorów

Efektywność pracy określono wg wzoru (1):

$$EP = \Sigma (T_{SP} \cdot S^{-1}) [\text{Mth} \cdot \text{ha}^{-1}] \quad (1)$$

gdzie:

- T_{SP} – czas pracy ciągnika [Mth],
S – powierzchnia [ha].

Metodyka uczenia sieci

Zebrane dane w badaniach eksploatacyjnych posłużyły do zainicjowania działania symulatora Sztucznych Sieci Neuronowych „Neuronix 2.3”. W tym celu ustalono zasoby projektu poprzez stworzenie pliku uczącego, testowego, oraz pliku wag. Proces uczenia dla każdej sieci ograniczono do siedmiu tysięcy epok. Nauczanie według tego schematu było powadzone dla różnych sieci o następującym układzie warstw i liczby neuronów (tab. 2).

Tabela 2. Struktura badanych sieci neuronowych
Table 2. Structure of a neural network

Badana grupa SSN	Liczba neuronów															
	I				II				III				IV			
Warstwa ukryta pierwsza	3	5	7	9	3	5	7	9	3	5	7	9	3	5	7	9
Warstwa ukryta druga	0	0	0	0	1	1	1	1	2	2	2	2	3	3	3	3

Struktura sztucznej sieci neuronowej zmieniała się w kolejnych wariantach w sposób prezentowany powyżej, łącznie zbadano cztery grupy sieci. Pierwsza grupa w warstwie ukrytej posiadała w kolejnych wariantach odpowiednio 3,5,7 i 9 neuronów, natomiast w drugiej warstwie ukrytej nie było żadnego neuronu. Druga, trzecia i czwarta grupa SSN w pierwszej warstwie posiadała taką liczbę neuronów jak w przypadku grupy pierwszej, natomiast w warstwie drugiej wprowadzono odpowiednio jeden, dwa i trzy neurony.

Przyjęto jako miarę nauczania sieci neuronowej błąd względny, który określono według wzoru (2):

$$\varepsilon_a = \frac{|y_u - y_o|}{y_o} \cdot 100\% \quad (2)$$

gdzie:

- ε_a – błąd względny,
- y_u – wartość uzyskana,
- y_o – wartość oczekiwana.

Wyniki badań

Bazą danych zbioru uczącego sieć neuronową były wyniki uzyskane z badań eksploatacyjnych, mianowicie efektywność pracy zestawu roboczego w zależności od parametrów prezentowanych w tabeli 3.


Tabela 3. Wartości parametrów wejściowych i wyjściowych zastosowanych do uczenia SSN
Table 3. Values of entrance and exit parameters for employ of learning neuron network

Parametr	Nazwa	Jednostka miary	Wartość średnia
Wejściowy	Skład gatunkowy	-	1,7000
	Podszyt	-	2,0867
	Rodzaj powierzchni jezdnej	-	2,6467
	Ukształtowanie terenu	-	4,1933
	Stopień zakamienienia powierzchni	-	3,6867
	Stopień zapniaczenia powierzchni	-	2,5067
	Wilgotność materiału	-	3,4267
	Wykrzesanie gałęzi	-	2,7800
	Rozmieszczenie rozdrabnianego materiału	-	3,6933
Wyjściowy	Efektywność pracy zespołu	Mth · ha ⁻¹	6,3017

Źródło: Obliczenia własne autorów

Wartość każdego parametru przedstawiono w postaci wagi (w skali od 1 do 5), gdzie ocena najniższa (1) przyporządkowana została w przypadku korzystnego wpływu, natomiast wartość najwyższa (5) dla czynnika niekorzystnie wpływającego na efektywność pracy zestawu maszyn. Rozpiętość skali (od 1 do n) dostosowana została do oceny każdego czynnika oddzielnie.

Uzyskany błąd nauczanej w badanych wariantach sieci neuronowej przedstawiono w tabeli 4 oraz na rys. 2. Błąd zmienia się w trakcie uczenia, wartości minimalne i maksymalne wynikają z wyników uzyskanych w kolejnych powtórzeniach. Na potrzeby użytkownika realnym jest posługiwanie się wartościami uśrednionymi z pozycji (tab.2) wartość bezwzględna - błąd średni w %.



3N-0N, 5N-0N,9N-3N - struktura sieci neuronowej

Rys. 2. Wyniki uczenia sieci neuronowej

Fig. 2. Results of neuron network learning

Tabela 4. Wyniki uczenia sieci neuronowej

Table 4. Results of neuron network learning

Liczba neuronów		Wartość bezwzględna błąd min [%]	Wartość bezwzględna błąd max [%]	Wartość bezwzględna błąd średni [%]
warstwa ukryta pierwsza	warstwa ukryta druga			
3	0	0,16	54,35	13,73
5	0	0,03	60,38	11,96
7	0	0,03	77,76	10,97
9	0	0,19	78,38	15,94
3	1	0,14	54,88	19,10
5	1	0,05	64,86	12,90
7	1	0,03	64,48	12,77
9	1	1,02	56,67	10,87
3	2	0,22	41,47	11,02
5	2	0,06	53,74	10,70
7	2	0,16	42,32	11,47
9	2	0,09	73,82	16,63
3	3	0,03	42,06	12,35
5	3	0,20	47,69	11,45
7	3	0,31	53,44	11,99
9	3	0,18	46,65	12,60

Źródło: Obliczenia własne autorów

Najlepszy wynik (błąd średni 10,70%) uczenia uzyskano podczas symulacji sieci dwuwarstwowej z pięcioma neuronami w warstwie ukrytej pierwszej i dwoma neuronami w warstwie ukrytej drugiej. Natomiast najgorszy (błąd średni 19,10%) w sieci z trzema neuronami w warstwie pierwszej i jednym w warstwie drugiej.

Najwyższy błąd maksymalny wystąpił podczas uczenia sieci jednowarstwowej z dziewięcioma neuronami, natomiast najniższym błędem minimalnym charakteryzują się cztery sieci o następującej liczbie neuronów: 5N-0N, 7N-0N, 7N-1N, 3N-3N.

Podsumowanie i wnioski

Z przeprowadzonych badań wynika że średnia wartość błędu bezwzględnego oscyluje w przedziale (10,70; 19,10) %. Natomiast najdokładniejszy (o najmniejszej różnicy od idealnego) wynik uzyskano podczas nauczania sieci z pięcioma neuronami w warstwie ukrytej pierwszej i dwoma neuronami w warstwie ukrytej drugiej. Na podstawie przeprowadzonych prób można wyciągnąć następujące wnioski:

- Zastosowany program Neuronix 2.3 pozwala na uzyskanie dość dobrych wyników uczenia sieci.
- Analizując wartość błędu nauczania SSN, istnieją podstawy zastosowania tego typu narzędzia do wykorzystywania w warunkach praktycznych dla określenia efektywności zestawów maszyn do prac w lesie.

Bibliografia

- Galązka S., Gornowicz R., Zenon P., Wojtkowiak R.** 2002. Wstępne badania nad wpływem sposobu zagospodarowania pozostałości pozrębowych na niektóre właściwości chemiczne gleb, Poznańskie Towarzystwo Przyjaciół Nauk, Wydział Nauk Rolniczych i Leśnych. Prace Komisji Nauk Rolniczych i Komisji Nauk Leśnych. Tom 92. s. 2-5.
- Korbicz J.** i in. 1994. Sztuczne sieci neuronowe podstawy i zastosowania, Akademicka Oficyna Wydawnicza PLJ Warszawa 1994. s. 18-25.
- Laurow Z., Więsik J.** 2001. Utylizacja odpadów leśnych na Elmia Wood 2001. Przegląd Techniki Rolniczej i Leśnej nr 7. s. 17-19.
- Maksymiak M.** 2005. Wpływ czynników organizacyjnych i ekonomicznych na efektywność pracy rozdrabniacza leśnego. Praca magisterska AR Szczecin. s. 47-52.
- Grieger A., Rynkiewicz M.** 2003. Diagnostyczny układ neuronowy dla maszyny rolniczej. Inżynieria Rolnicza, Nr 12(54), Warszawa. s. 107-114.

EMPLOMENT OF NEURON NETWORK FOR DEFINITION OF EFFECTIVENESS OF WORK FORESTY SHREDDER

Summary. Improvement quality of operation machines to work on forest require to use modern implements assist decision. The aim of this study is to create a model, which would use artificial neuron networks to establish the optimal effectiveness of a forestry shredder. The research was preceded on the basis of two sets of machines: Seppi m and tractor ZTS 16245, and Atila ST and tractor Crystal 160. The initial parameter was the effectiveness of the forestry shredder indicated by working hours / area. Several modifications of network worth were compared. The process for different versions was conducted according to the methodology of comparing quality of the network learning to various number of the neurons in several layers.

Key words: artificial neuron networks, forestry, shredder, effectiveness

Adres do korespondencji:

Michał Maksymiak; e-mail: mmaksymiak@agro.ar.szczecin.pl
Zakład Użytkowania Maszyn i Urządzeń Rolniczych
Akademia Rolnicza w Szczecinie
ul. Papieża Pawła VI 3A
71-459 Szczecin