

## KLASYFIKACJA SYGNAŁÓW SIŁY SKRAWANIA ZA POMOCĄ SIECI NEURONOWEJ

### THE CLASSIFICATION OF CUTTING FORCES SIGNALS USING NEURAL NETWORK

*W artykule omówiono rezultaty wstępnych badań nad zastosowaniem sieci neuronowej do klasyfikacji stanu ostrza skrawającego mocowanego w głowicy wielonarzędziowej, stosowanego do urabiania skał. Badania te wydają się być niezbędne do identyfikowania procesu urabiania oraz skonstruowania adaptacyjnego systemu jego kontroli.*

**Słowa kluczowe:** sieci neuronowe, zużycie narzędzi, perceptron wielowarstwowy

*This paper indicates results of preliminary research on utilizing neural networks to classification excavating cutting tool's condition used in multi-tool excavating heads of mechanical coal miners. Such research is necessary to identify rock excavating process with a given head, and construct adaptation systems for control of excavating process with such a head.*

**Keywords:** neural networks, tool wear, multilayer perceptron

#### 1. Wstęp


Identyfikacja stanu ostrza skrawającego, ze szczególnym uwzględnieniem jego geometrii, jest obecnie zagadnieniem wymagającym, w kontekście sterowania procesem urabiania, wzmoczonych badań. Przemysł wydobywczy stosuje do urabiania skał noże urabiające, mocowane w głowicach wielonarzędziowych kombajnów urabiających. Noże te, z uwagi na wymaganą dużą ich odporność na zużycie przy możliwie małym obciążeniu ostrza skrawającego, charakteryzuje duża różnorodność kształtów geometrycznych. W chwili obecnej nie jesteśmy w stanie, w zmiennych warunkach urabiania, dobrać na bieżąco najbardziej efektywną, w danych warunkach geologicznych, konstrukcję noża. Budowa układów sterowania kombajnami urabiającymi musi uwzględniać zależność obciążenia, a co za tym idzie również trwałości ostrza urabiającego od jego geometrii.

W przemyśle wydobywczym, z uwagi na bardzo złożony charakter skrawania (m.in. niejednorodność urabianego materiału, różnorodność głowic wielonarzędziowych), problem właściwej identyfikacji sygnałów skrawania jest szczególnie trudny. Brak jest w zasadzie „konwencjonalnych” narzędzi i procedur pozwalających na zadowalające rozwiązanie tego problemu [4].

#### 2. Badania doświadczalne

W celu stworzenia przydatnego do procesu identyfikacji narzędzia, podjęto próbę wykorzystania sieci neuronowej. Koncepcja ta wymaga jednak

dość dużej ilości danych pomiarowych, które, znając pewne charakterystyczne parametry procesu obróbki, można wykorzystać w celu utworzenia odpowiednio efektywnego modelu sieci. Przedmiotem badań stanowiskowych był nóż typu Boart hwf-100s.



Rys. 1. Nóż typu Boart hwf-100s

Fig. 1. Cutting tool Boart hwf-100s

Zdecydowano się pozyskać przebiegi czasowe sił skrawania tym narzędziem w dwóch stanach: przydatności do procesu skrawania oraz stopnia, uzyskanego poprzez zeszlifowanie ostrza na wysokość 2 mm, prostopadle do osi chwytu noża. Ten sposób obniżenia jakości ostrza jest adekwatny do sytuacji obserwowanych w rzeczywistości. Pomiar siły dokonany był z wykorzystaniem siłomierza

tensometrycznego. Po przekształceniu do postaci cyfrowej określono średnie wartości siły: maksymalnej, średniej oraz resztkowej. Adekwatność wyników uzyskano dzięki powtarzalności pomiarów w danych warunkach.

### 3. Poszukiwanie optymalnej truktury sieci neuronowej

W celu zaprojektowania sieci neuronowej, spełniającej postawione w zagadnieniu wymagania, posłużono się pakietem STATISTICA Neural Networks [SNN]. Jako zmienne wejściowe posłużono się wspomnianymi już danymi określającymi przebieg czasowy skrawania ( $F_{c\ max}$ ,  $F_{c\ sr}$ ,  $F_{c\ min}$ ) oraz parametrami procesu obróbki („t” i „g”) – podziałką i głębokością skrawania. Wyjściową zmienną, co wynika z celu badań, był stan ostrza zaklasyfikowany jako OSTRY lub STĘPIONY.

Dane wejściowe zostały losowo podzielone na 3 podzbiory: uczący, walidacyjny oraz testujący. Wynika to z immanentnych cech sieci neuronowych, które po wykorzystaniu zbioru uczącego, sprawdzają poprawność swojego działania używając zbioru walidacyjnego, zawierającego dane nie stosowane w procesie uczenia. Ponieważ jednak przypadki zawarte w zbiorze walidacyjnym wpływają na ostateczne parametry sieci neuronowej, do zbadania jej przydatności niezbędny jest dodatkowy zbiór testujący [1].

Zdecydowano się skorzystać z opcji automatycznego projektanta SNN [1], przy narzuceniu jednak następującego podziału przypadków: zbiór uczący 34, zbiór walidacyjny 12, zbiór testujący 13. Granice ufności stosowane przez sieć do klasyfikacji przypadku określono na poziomie 0,9 dla akceptacji oraz 0,1 odrzucenie. Poszukiwanie optymalnej struktury rozpoczęto od tzw. sieci bayesowskich, tj. PNN (probabilistyczne sieci neuronowe) oraz sieci realizujących regresję uogólnioną – GRNN (Generalized Regression Neural Network). Są one stosowane wyłącznie do zagadnień klasyfikacji. Po przeprowadzeniu analizy okazało się, iż ten typ struktury sieci neuronowej generuje, w badanym zagadnieniu, wyjątkowo niezadowolające rezultaty. Efektywność najlepszej znalezionej sieci tego typu kształtowała się na poziomie 0,3 (współczynnik poprawnych klasyfikacji). Błąd zbioru uczącego wyniósł 0,3158, natomiast zbioru walidacyjnego 0,3894. Pakiet SNN przyjmuje poszukując optymalnej sieci, iż najlepsza jest ta, której walidacja posiada najmniejszy błąd. W tym wypadku był on dość wysoki.

Oprócz niezadowolających wyników otrzymanej sieci, dodatkowo na zaprzestanie dalszych prób w kierunku tej struktury wpłynęła jej, bardzo rozbudowana, struktura. Sieć posiadała kilkadziesiąt neuro-

nów w warstwie. Z pośród wszystkich analizowanych przypadków sieć poprawnie sklasyfikowała ponad 25 %, prawie 70 % nie zostało sklasyfikowanych, a liczba sytuacji rozpoznanych błędnie była niższa niż 5 %.

Kolejnym rodzajem sieci, który postanowiono przetestować dla analizowanych danych pomiarowych, była sieć o radialnych funkcjach bazowych. Posiada ona warstwę wejściową, jedną warstwę ukrytą z neuronami radialnymi oraz warstwę złożoną z neuronów o liniowych charakterystykach (wyjściową) [1]. Próby stworzenia zadowolającej sieci o tej strukturze również zostały zakończone niepowodzeniem. Sieć o radialnych funkcjach bazowych, niezależnie od generowanego współczynnika poprawnych klasyfikacji i struktury, nie czyniła znaczących postępów podczas uczenia. Błędy zbiorów uczącego, walidacyjnego oraz testującego nie były niższe niż 0,3, a często znacznie przekraczały tę wartość. Próby uczenia tego rodzaju sieci zalecanymi w literaturze [2] dla tej struktury metodami, nie przyniosły pozytywnych efektów, a samą sieć, na podstawie przeprowadzonych prób, należy uznać za niewiarygodną w badanym zagadnieniu.


Z pośród głównych (najpopularniejszych) rodzajów sieci, proponowanych przez pakiet SNN w opcji automatycznego projektanta, pozostały jedynie perceptrony wielowarstwowe oraz liniowy typ sieci neuronowej. Ten ostatni na podstawie doświadczeń autorzy postanowili pominąć w analizach, jako mało efektywnych dla rozważanych zagadnień. Pozostało więc wykorzystanie poszukiwania optymalnej struktury wśród perceptronów wielowarstwowych o trzech lub czterech warstwach.

Tym razem granice ufności stosowane przez sieć do klasyfikacji, polecono przyjąć automatycznie, umożliwiając w trakcie analizy dobór najkorzystniejszych wartości. Jako funkcję błędu przyjęto „sumę kwadratów” (błąd jest sumą kwadratów różnic pomiędzy wartościami zadanymi i wartościami otrzymanymi na wyjściach każdego neuronu wyjściowego). Jest to jedna z częściej, nie tylko w trakcie uczenia sieci neuronowych, stosowanych funkcji błędu. Jej wybór jest zalecany w większości problemów regresyjnych.

### 4. Analiza przydatności sieci neuronowej do identyfikacji stanu ostrza

Po przeprowadzeniu wielu analiz zdecydowanie najlepsza dla przeprowadzonych pomiarów skrawania nożem Boart hwf-100s okazała się sieć o strukturze MLP 5:5-8-1:1.

Efektywność wybranej sieci została zaklasyfikowana jako bardzo dobra, błąd RMS (pierwiastek z błędu średniokwadratowego) wyniósł 0,1265, a pole pod krzywą ROC 0,9207.



Rys. 2. Schemat sieci typu perceptron wielowarstwowy o architekturze MLP 6-5:8:1-1

Fig. 2. A scheme of multilayer perceptron MLP 6-5:8:1-1

Analizę wrażliwości sieci przedstawia tabela 1 ( $F_c$  - siły skrawania; odpowiednio: -maksymalna, średnia i resztkowa). RMS jest według [1] najczęściej stosowaną miarą jakości sieci neuronowej. Jest to sumaryczny błąd popełniany przez sieć na pewnym zbiorze danych (może to być zbiór uczący, testowy lub walidacyjny), wyznaczany poprzez sumowanie kwadratów błędów indywidualnych, podzielenie uzyskanej sumy przez liczbę uwzględnionych wartości i wyznaczenie pierwiastka kwadratowego z uzyskanego ilorazu.

W tabeli 2 przedstawiono statystyki klasyfikacyjne dla badanego zagadnienia. Zilustrowano, ile z przypadków zostało zidentyfikowanych prawidłowo, jaka ich część została rozpoznana błędnie, a ile sieć nie była w stanie zaklasyfikować w ogóle. Jak widać w tabeli, przypadków nieokreślonych nie było, a złe za-

klasyfikowanie stanu ostrza miało miejsce po jednym razie dla zbiorów testującego i walidacyjnego, oraz w trzech przypadkach dla zbioru uczącego.

### 5. Próby usprawnienia sieci poprzez zmniejszenie ilości danych wejściowych

Analizując wrażliwość badanej sieci łatwo zauważyć, iż zarówno w zbiorze uczącym, jak też walidacyjnym, ranga pierwszej zmiennej wejściowej, jaką jest maksymalna siła skrawania, jest najniższa. Co więcej, iloraz (wynik podzielenia pozycji „błąd” przez błąd otrzymany przy użyciu wszystkich zmiennych) tej zmiennej wejściowej znacznie odbiega od pozostałych zmiennych. Wprawdzie graniczną wartością, jeśli chodzi o przydatność danej zmiennej do uczenia sieci, jest 1 (jeżeli iloraz jest mniejszy od jeden, to usunięcie zmiennej poprawi działanie sieci), to jednak warto rozważyć możliwość usunięcia tej zmiennej z analizy przy uczeniu sieci, gdyż często zdarza się, że taki zabieg w znaczącym stopniu upraszcza, a co za tym idzie zwiększa szybkość działania sieci.

Mając na uwadze powyższe rozważania, ustalono próg wrażliwości na poziomie 2,3, co spowodowało odrzucenie wejść, które tą wrażliwość posiadały niższą. W badanej sieci była to zmienna  $F_{c \max}$ .

Usunięcie najmniej przydatnej zmiennej wejściowej sieci okazało się nietrafne. Zdecydowanie wzrosły błędy RMS zbiorów danych: uczącego do poziomu 0,5611, walidacyjnego 0,4998 oraz testującego 0,4248.

Tab. 1. Analiza wrażliwości dla sieci MLP 6-5:8:1-1

Tab. 1. Sensitivity analysis of neural network MLP 6-5:8:1-1

	FC_MAX	FC_ŚR	FC_MIN	G	T	Zbiór
Ranga	5	1	3	2	4	uczący
Błąd	0,3446097	0,7159145	0,5130001	0,5377643	0,4172563	
Iloraz	1,388452	2,884461	2,066907	2,166683	1,68115	
Ranga	5	1	4	3	2	walidacyjny
Błąd	0,24337	0,7359864	0,4191814	0,4972453	0,5091267	
Iloraz	2,263529	6,845244	3,898712	4,624767	4,735273	

Tab. 2. Statystyki klasyfikacyjne dla sieci perceptronowej MLP 6-5:8:1-1

Tab. 2. Classification statistics for multilayer perceptron MLP 6-5:8:1-1

Zbiór	uczący		walidacyjny		testujący	
	OSTRY	STĘPIONY	OSTRY	STĘPIONY	OSTRY	STĘPIONY
Razem	18	16	6	6	6	7
Poprawnie	17	14	5	6	6	6
Błędnie	1	2	1	0	0	1
Nieokreślone	0	0	0	0	0	0
OSTRY	17	2	5	0	6	1
STĘPIONY	1	14	1	6	0	6

Tab. 3. Analiza wrażliwości dla sieci MLP 6-5:8:1-1 po odrzuceniu zmiennej  $F_{c \max}$

Tab. 3. Sensitivity analysis of neural network MLP 6-5:8:1-1 excluding  $F_{c \max}$

	FC_ŚR	FC_MIN	G	T	Zbiór
Ranga	1	2	3	4	uczący
Błąd	0,6666812	0,6057476	0,5426925	0,4826357	
Iloraz	1,188163	1,079567	0,9671899	0,8601563	
Ranga	1	2	4	3	walidacyjny
Błąd	0,7532536	0,5572802	0,4486659	0,4999924	
Iloraz	1,506962	1,114897	0,897603	1,000287	

Tab. 4. Statystyki klasyfikacyjne dla sieci perceptronowej MLP 6-5:8:1-1 po odrzuceniu zmiennej wejściowej  $F_{c \max}$

Tab. 4. Classification statistics for multilayer perceptron MLP 6-5:8:1-1 excluding  $F_{c \max}$

Zbiór	uczący		walidacyjny		testujący	
	OSTRY	STĘPIONY	OSTRY	STĘPIONY	OSTRY	STĘPIONY
Razem	18	16	6	6	6	7
Poprawnie	8	13	3	6	4	6
Błędnie	10	3	3	0	2	1
Nieokreślone	0	0	0	0	0	0
OSTRY	8	3	3	0	4	1
STĘPIONY	10	13	3	6	2	6

## 6. Podsumowanie

Przeprowadzone badania sugerują, iż zastosowanie sieci neuronowej do identyfikowania stanu ostrza, przy wykorzystaniu pewnych, charakterystycznych sygnałów, jest racjonalne. Monitorowanie procesu, połączone z trafnym wychwytywaniem stanów niedopuszczalnego technologicznie stopnia ostrza, pozwoliłoby na znaczne usprawnienie procesu

urabiania. W odniesieniu do otrzymanych wyników trzeba stwierdzić, że zastosowana do uczenia sieci ilość pomiarów jest dalece niewystarczająca. Aby sieć osiągnęła wymagane parametry klasyfikacji, aco za tym idzie pozwoliła na bezpieczne zastosowanie w praktyce, należy przeprowadzić wiele prób i badań.

## 7. Literatura

- [1] StatSoft®: *STATISTICA Neural Networks*, 1998
- [2] Osowski S.: *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000 r.
- [3] Jonak J.: *Urabianie skał głowicami wielonarzędziowymi*, Wydawnictwo Naukowe „Śląsk”, Katowice 2001 r.
- [4] Jonak J.: *Identyfikacja stanu ostrza z wykorzystaniem sieci neuronowej*, IV Krajowa Konferencja MSK, Kraków 2003 r.

**Mgr inż. Jakub GAJEWSKI**

**Dr hab. inż. Józef JONAK, prof. PL**

*Katedra Podstaw Konstrukcji Maszyn*

*Wydział Mechaniczny,*

*Politechnika Lubelska*

*tel. (81) 5381499*

*e-mail: j.gajewski@pollub.pl*

*e-mail: j.jonak@pollub.pl*