

**Dariusz Prostański
Józef Jonak**



**SIECI NEURONOWE
W BADANIACH PROCESU
URABIANIA SKAŁ
STOŻKOWYMI NOŻAMI
OBROTOWYMI**

**Prace naukowe - Monografie
CMG KOMAG**



Dariusz PROSTAŃSKI

Józef JONAK

**SIECI NEURONOWE
W BADANIACH PROCESU
URABIANIA SKAŁ STOŻKOWYMI
NOŻAMI OBROTOWYMI**

Copyright by
Centrum Mechanizacji Górnictwa KOMAG, Gliwice 2003

ISBN 83-913228-0-4

Wydawca:
Centrum Mechanizacji Górnictwa KOMAG
ul. Paszczyńska 37, 44-100 Gliwice

Komit t redakcyjny:

prof. dr hab. in . Adam Klich
prof. dr hab. in . Zdzis aw K eczek
prof. dr in . W odzimierz Sikora

Recenzenci:

prof. dr hab. in . Dionizy Dudek
prof. dr hab. in . Krzysztof Krauze
dr hab. In . Jerzy Kwa niewski

Sekretarz redakcji:

mgr in . Romana Zaj c

*Prac  zrealizowano w CMG KOMAG w ramach
projektu badawczego nr 8T12 A 021 21
finansowanego przez Komitet Bada  Naukowych*

** Prace zrealizowane*

Copyright by
Centrum Mechanizacji G rnictwa KOMAG, Gliwice 2003

ISBN 83-919228-0-4

Wydawca:
Centrum Mechanizacji G rnictwa KOMAG
ul. Pszczy ska 37, 44-100 Gliwice

Spis treści

	Str.
Wstęp	
1. Wprowadzenie	1
1.1. Przyczyny i uzasadnienie podjęcia badań	3
1.2. Cel i zakres badań	5
2. Stożkowe noże obrotowe, głowice urabiające	6
3. Metody modelowania i identyfikacji procesu urabiania stożkowymi nożami obrotowymi	12
3.1. Teoretyczne modele mechaniczne strefy skrawania	13
3.2. Modele empiryczne	18
4. Sztuczna sieć neuronowa, geneza, rodzaje, właściwości	23
4.1. Sieci neuronowe klasyczne	24
4.1.1. Perceptrony wielowarstwowe	30
4.1.2. Sieci Kohonena	33
4.2. Sieci neuronowe rozmyte (neuro-fuzzy network)	34
4.3. Przeuczenie sieci	37
4.4. Kryterium jakości sieci	37
4.5. Podsumowanie	38
5. Wykorzystanie sieci neuronowych w branży górniczej - stan wiedzy	38
5.1. Wykorzystanie sieci neuronowych w badaniach procesu urabiania skał	40
6. Wstępne badania numeryczne, nad wykorzystaniem sieci neuronowych w badaniach procesu urabiania skał	41
6.1. Poszukiwania optymalnej struktury sieci neuronowej	42
7. Rozszerzony model procesu urabiania skał stożkowym nożem obrotowym	48

8. Uzupełniające badania stanowiskowe procesu urabiania skał stożkowymi nożami obrotowymi	49
8.1. Stanowisko o prostoliniowej trajektorii skrawania	49
8.1.1. Warunki realizacji badań na strugarce	51
8.2. Stanowisko o łukowej trajektorii skrawania	53
8.2.1. Przebieg badań	58
9. Analiza numeryczna wyników badań stanowiskowych z wykorzystaniem sieci neuronowej	63
9.1. Struktura sieci wykorzystanej do neuronowej aproksymacji wyników badań zasadniczych	63
9.2. Weryfikacja przyjętej struktury sieci	75
10. Graficzna ilustracja wyników aproksymacji neuronowej danych pomiarowych urabiania skał stożkowymi nożami obrotowymi	76
11. Podsumowanie i wnioski	91
11.1. Wnioski dotyczące możliwości stosowania sieci neuronowych w badaniach procesu urabiania skał stożkowymi nożami obrotowymi	94
12. Kierunki dalszych badań	95
Literatura	98

Wstęp

Wykorzystanie stożkowych noży obrotowych w technologii górniczej ma już kilkudziesięcioletnią historię. Z uwagi na konstrukcję tych noży, proces urabiania jest bardziej złożony niż w przypadku noży płaskich [27]. Liczba czynników istotnych dla tego procesu jest bardzo duża, stąd też próby tworzenia modeli matematycznych opisujących ten proces, napotykają różnorodne trudności.

Z kolei uproszczone modele procesu urabiania skał nożami stożkowymi, mają z reguły ograniczoną przydatność w modelowaniu urabiania całą głowicą [9, 27]. Stąd też ciągle jeszcze istnieje potrzeba prowadzenia badań nad mechanizmem urabiania skał stożkowymi nożami obrotowymi.

Gwałtowny rozwój informatyki, jaki następuje w ostatnich latach, pozwala mieć nadzieję na szybsze rozwiązanie nurtujących problemów. Jednym z narzędzi badawczych, jakie mogą być tutaj użyteczne, są sztuczne sieci neuronowe, algorytmy genetyczne czy systemy rozmyte, zaliczane do narzędzi tzw. sztucznej inteligencji.

Jak się oczekuje, pozwoli to znacznie przyspieszyć badania, ograniczyć ich koszty, lepiej określić efekty urabiania, pomimo niepełnych danych pomiarowych oraz optymalnie sterować przebiegiem procesu urabiania daną głowicą.

1. Wprowadzenie

Analiza dotychczasowych prac teoretycznych i badań doświadczalnych wykazuje, że przebieg jak i opór urabiania skały F , głowicą uzbrojoną w stożkowe noże obrotowe, zależy od szeregu czynników, co można zapisać:

$$F = f(S, N, G, T_e) \quad (1.1)$$

gdzie:

S - zespół parametrów charakteryzujący rodzaj i właściwości urabianej skały:

$$S = f(r_s, d_z, h_{sz}, \zeta, R_c, R_r, \kappa, w, s, n, u, \Psi, \dots) \quad (1.2)$$

gdzie:

r_s - rodzaj skały np. wapien, piaskowiec (opis lingwistyczny uwzględniający skład mineralogiczny skały, zwięźłość, teksturę itp.),

d_z - średnia średnica ziarna,

h_{sz} - twardość,

ζ - ciężar objętościowy skały,

R_c, R_r - wytrzymałość skały na jednoosiowe ściskanie oraz rozciąganie,

κ - wskaźnik asymetrii wytrzymałości skały, $\kappa = R_c/R_r$,

w - wilgotność skały,

s - szczelinowatość skały,

n - porowatość skały,

u - uwarstwienie,

Ψ - kąt bocznego rozkruszania skały.

N - zespół parametrów charakteryzujący cechy konstrukcyjne narzędzia:

$$N = f(\alpha, \beta, \gamma, \delta, \rho, VB), \quad (1.3)$$

gdzie:

α - kąt przyłożenia,

β - kąt ostrza,

γ - kąt natarcia,

δ - kąt ustawienia,

ρ - kąt obrotu noża stożkowego,

VB - stępienie ostrza.

G - zespół parametrów charakteryzujący głowicę:

$$G = f(w_g, z, n_i, L, R_i, z_s, \lambda, \varphi, v_c, v_f, z_s..) \quad (1.4)$$

gdzie:

w_g - głębokość wcięcia głowicy,

z - zabiór głowicy,

n_i - liczba noży w linii skrawania,

L - długość głowicy,

R_i - promień rozmieszczenia noży,

λ - posuw na jeden obrót,

φ - podziałka kątowna,

v_c - prędkość skrawania,

v_f - prędkość posuwu,

z_s - liczba spiral, na których rozmieszczono noże na głowicy.

T_e – zespół parametrów charakteryzujący technologię urabiania:

$$T_e = f(k, r_p) \quad (1.5)$$

gdzie:


k - orientacja kierunku urabiania (ruch pionowy lub poziomy, wcinanie głowicy),

r_p - rodzaj procesu (formowanie obrysu, podstawowy ruch roboczy głowicy).

Mając na uwadze powyższe czynniki można zauważyć, jak duża liczba parametrów wpływa na kształtowanie się obciążenia głowicy. Wpływ każdego z nich jest często bardzo złożony, nie do końca poznany i z wielu powodów trudny do oszacowania. Analizując szczegółowo zależności wynikające ze wzoru Evansa, na kształtowanie się siły obciążającej ostrze noża stożkowego, zależnie od jego wybranych parametrów geometrycznych oraz kilku tylko, wybranych parametrów określających właściwości skrawanej skały stwierdzono [40], że nawet w obrębie tej samej grupy skał, zależnie od wartości wskaźnika asymetrii wytrzymałości, należy oczekiwać znacznie różniących się wartości, np. siły skrawania, co ilustruje rysunek 1.1.

Biorąc pod uwagę jedynie parametry uwzględnione w tej analizie, łatwo zauważyć, jak trudno jest zgromadzić odpowiednią bazę danych

pomiarowych, aby z użyciem tradycyjnych metod badawczych (używając np. metod aproksymacji czy regresji), przewidywać w szerszym zakresie, kształtowanie się obciążenia noży stożkowych. Na dzień dzisiejszy, z uwagi na koszty badań, dostępne są jedynie wybiórczo udokumentowane zależności, gdyż najczęściej zagadnienia te traktowane są wyrywkowo, tj. bada się wpływ jedynie wybranych czynników na przebieg procesu urabiania.



Rys.1.1. Parametry skał istotne dla urabiania nożami stożkowymi w świetle teorii Evansa [40, 66]

Zmieniając zestaw parametrów, sukcesywnie analizuje się indywidualnie, wpływ każdego czynnika na przebieg urabiania. Na każdym etapie badań najczęściej dokonuje się mniejszych lub większych założeń upraszczających określone zjawisko, stąd też trudności w kompleksowym opisie procesu urabiania, oraz ciągła potrzeba prowadzenia dalszych, szczegółowych badań, z wykorzystaniem coraz doskonalszych metod badawczych (np. sztucznych sieci neuronowych), które pozwoliłyby np. prognozować przebieg procesu urabiania, pomimo niekompletności danych pomiarowych.

1.1. Przyczyny i uzasadnienie podjęcia badań

Jedną z przyczyn podjęcia tematu w przyjętej formie, były ograniczenia modelu empirycznego (przedstawionego w pracy [26]), uniemo-

zliwiające przewidywanie parametrów technologicznych i konstrukcyjnych noży stożkowych, w szerszym zakresie warunków urabiania. Jak wynika z modelu Evansa (rys. 1.1), już dla tego samego gatunku skał, spektrum możliwych obciążeń noża stożkowego jest bardzo duże, stąd też zachodziła potrzeba uzupełnienia dostępnych badań, między innymi o inny rodzaj skały jak i inny rodzaj stanowiska badawczego (w tym zwłaszcza o łukowej trajektorii skrawania), oraz ewentualną weryfikację parametrów urabiania, wynikających z omawianego modelu [26].

Kolejną przesłanką, która przyczyniła się do podjęcia badań, był gwałtowny rozwój sieci neuronowych, w tym zwłaszcza ich potencjalne możliwości uogólniania wiedzy, nawet niekompletnej i rozmytej, co jest w podjętych badaniach bardzo istotne. Z powodzeniem stosuje się je w zagadnieniach predykcji szeregów czasowych, klasyfikacji, identyfikacji, filtracji sygnałów, sterowaniu procesami itp.

Polański [65] stwierdza, że nawet rozwój teorii eksperymentu zmierza w kierunku aproksymacji neuronowej. To oznacza, że badacz może zrezygnować z doboru funkcji aproksymującej na rzecz aproksymacji neuronowej, zapewniającej aproksymację ...bez funkcji. Jednak, gdy istnieje taka potrzeba można sieć neuronową wygenerować w postaci kodu w jednym ze standardowych języków programowania, który można kompilować i dołączać do własnych programów.

Uwzględnianie w modelu procesu tworzonego z wykorzystaniem sieci neuronowych, wejściowych zmiennych skorelowanych ze sobą, daje możliwość uzyskania pełniejszego opisu procesu jak też indywidualnego wpływu każdej z tych zmiennych, podczas gdy w klasycznych procedurach statystycznych, podstawowym zaleceniem jest odrzucenie zmiennych wejściowych zależnych. Dodatkową, ogromną zaletą tych sieci jest także fakt, że pozwalają one na poszukiwanie modeli dla procesów lub zjawisk, których struktura lub prawa działania nie zostały poznane i opisane w sposób pozwalający na budowę ich modelu, przy czym użytkownik sieci nie musi deklarować żadnej, z góry zadanej formy poszukiwanego modelu, a nawet nie musi być pewny, że w ogóle jakaś dająca się matematycznie modelować zależność ma miejsce [90]. Dlatego założono, że sieć neuronowa może stanowić o wiele prostsze i dokładniejsze niż dotychczas stosowane, narzędzie do modelowania obciążenia stożkowego noża obrotowego w procesie skrawania skał.

Z dokonanego przeglądu literatury, nad zagadnieniem wykorzystania sztucznych sieci neuronowych w badaniach procesów urabiania skał wynika, że w literaturze polskiej brak jest takich opracowań, a w literaturze światowej zagadnienia te poruszano marginalnie.

1.2. Cel i zakres badań

W ramach podjętej tematyki, celem głównym badań, było:

- określenie wpływu uwzględnienia w modelu urabiania stożkowym nożem obrotowym, opracowanym przez Jonaka [26], parametrów charakteryzujących skałę, takich jak: wytrzymałość na jednoosiowe ściskanie R_c , wytrzymałość na jednoosiowe rozciąganie - R_r , wartość proporcji R_c/R_r oraz gęstość skały ζ , na kształtowanie się obciążenia tych noży.

Realizację postawionego zadania oparto o przyjęte cele szczegółowe pracy, tj.:

- przeprowadzenie badań urabiania wybranych skał (wapienia i skały cementowo-piaskowej) o określonych parametrach wytrzymałościowych, na stanowisku o prostoliniowej trajektorii skrawania oraz o łukowej trajektorii skrawania, nożami stożkowymi o zdefiniowanej geometrii ostrza, dla założonych parametrów urabiania. Założono przeprowadzenie badań jedynie dla noży technicznie ostrych,
- numeryczną analizę uzyskanych wyników, z wykorzystaniem sztucznych sieci neuronowych.

Celem sprawdzenia możliwości uogólniania wiedzy przez badaną sieć, wymagane jest testowanie jej na danych pomiarowych, uzyskanych z odmiennych źródeł, oczywiście z zakresu, jaki został wykorzystany do budowy ostatecznej jej postaci. Stąd też w badaniach założono wykorzystanie aż dwóch stanowisk badawczych o odmiennych trajektoriach skrawania.

Celami dodatkowymi badań było:


- ewentualna weryfikacja zalecanych parametrów technologicznych urabiania i konstrukcyjnych stożkowych noży obrotowych, podanych w pracy [26],
- określenie stopnia przydatności klasycznych sieci neuronowych w badaniach i identyfikacji procesu urabiania skał tymi nożami, tj. procesu stochastycznego, nie zawsze scharakteryzowanego kompletem niezbędnych informacji pomiarowych (z zakresu parametrów kon-

strukcyjnych i technologicznych stosowanych aktualnie w maszynach drążących). W tym przypadku, z uwagi na cel podstawowy badań, zagadnienie wykorzystania sieci neuronowych w opracowywaniu wyników badań, odpowiada zagadnieniu aproksymacji danych pomiarowych wykonywanej klasycznymi metodami statystyki matematycznej.

2. Stożkowe noże obrotowe, głowice urabiające


Stożkowe noże obrotowe (rys. 2.3) używane do skrawania ośrodków skalnych są najbardziej rozpowszechnione w procesie frezowania, realizowanym w wyniku złożenia ruchu obrotowego i posuwistego.

Typowe rozwiązania głowic urabiających stosowanych do urabiania kamienia oraz zwięzłych węgli, przedstawiono na rysunkach 2.1, 2.2. Do nowszych zastosowań stożkowych noży obrotowych, należy zaliczyć ich wykorzystanie np. w koronkach wiertniczych [3].




Rys. 2.1. Głowica poprzeczna kombajnu KR-250


Organy urabiające skałę metodą frezowania są wyposażone w noże skrawające usytuowane na powierzchni zewnętrznej bryły obrotowej. W zależności od potrzeby mogą to być bryły w kształcie walca (kombajny ścianowe), walca ze stożkowym zakończeniem, stożka, półkuli i podobnych (kombajny chodnikowe) (rys. 2.4) [2].



Rys.2.2. Głowica wzdłużna kombajnu KR-150




Rys.2.3. Usytuowanie noża obrotowego na głowicy urabiającej (β - kąt ostrza, g - głębokość skrawania, D_s - średnica rozmieszczenia ostrzy noży, v_c - prędkość skrawania, F_c , F_n - składowe siły na ostrzu, odpowiednio skrawania i normalna)



Rys.2.4. Przykładowe kształty głowic frezujących a) w kształcie walca, b) w kształcie walca ze stożkowym zakończeniem, c) w kształcie dwóch półkul

Proces frezowania z zastosowaniem tych głowic, realizowany jest w trzech najważniejszych kombinacjach ruchów obrotowego i posuwistego, tj.:

- ruch obrotowy główny głowicy i obrotowy ruch posuwisty wysięgnika, na którym zamocowana jest głowica (tzw. głowice poprzeczne) (rys. 2.5c).
- ruch obrotowy główny głowicy skrawającej i obrotowy ruch posuwisty wysięgnika (wraz z zamocowaną głowicą), oś obrotu głowicy jest równoległa do osi wysięgnika (tzw. głowice wzdłużne) (rys. 2.5b).
- ruch obrotowy głowicy oraz postępowy (zazwyczaj prostoliniowy) jej ruch posuwisty (tzw. głowice walcowe lub o zbliżonym do walca kształcie, bądź też ślimakowe).




Rys.2.5. Kinematyka ruchu głowicy urabiającej: a) poprzecznej, b) wzdłużnej, v_f – prędkość posuwu, n_s – prędkość obrotowa

Warto tutaj zauważyć, że na dzień dzisiejszy nie opracowano i nie wdrożono na skalę przemysłową systemu automatycznego sterowania pracą głowicy urabiającej kombajnu chodnikowego. Sterowanie to odbywa się ręcznie, według subiektywnych odczuć operatora [27, 79].

Stożkowy nóż obrotowy (rys. 2.6) posiada osiowo symetryczną budowę. Według założeń taka konstrukcja narzędzia, z jednej strony ma umożliwić jego swobodny obrót, z drugiej zaś równomierne jego zużywanie się (co często traktowane jest jako proces „samoostrzenia” narzędzia). „Punktowe” zakończenie ostrza ma służyć do skoncentrowanego przekazywania energii od narzędzia do skały, powodując lepsze nis-

czenie jej struktury niż ma to miejsce w innych konstrukcjach noży. W budowie stożkowego noża obrotowego wyróżnić można (rys. 2.6) cylindrycznie ukształtowany trzon noża mocowany w uchwycie - 1, korpus części skrawającej - 2 oraz ostrze noża - 3 wykonane z odpowiedniej do warunków skrawania, wkładki z węgliku spiekanego. Podobieństwo do noża stycznego polega na sposobie ustawienia noża wraz z uchwytem na kadłubie głowicy.



Rys.2.6. Schemat zamocowania stożkowego noża obrotowego i uchwytu do organu urabiającego: 1 – uchwyt, 2 – korpus części skrawającej, 3 – ostrze (węglik spiekany), 4 – kadłub głowicy, α_n – konstrukcyjny (spoczynkowy) kąt przyłożenia, β_n – kąt ostrza, γ_n – konstrukcyjny kąt natarcia, H_n – wysokość noża w uchwycie mierzona od podstawy uchwytu, L_n – długość części skrawającej

W Polsce, jak i na świecie, do głowic kombajnów najczęściej stosuje się i produkuje noże z wkładkami z węglików spiekanych o kącie ostrza $\beta_n = 93^\circ$ (rys. 2.6). Stosowane są również noże o kącie ostrza $\beta_n = 90, 96, 100, 105^\circ$. Ostrza wykonane są z różnych gatunków węglików spiekanych, najczęściej B2 lub B45. Dobór narzędzia o odpowiednim kącie ostrza i gatunku węgliku spiekanego jest uzależniony tak od urabialności skały, jak również od rodzaju kombajnu.

Drugim ważnym parametrem jest długość korpusu L_n (rys. 2.6). Produkuje się noże o długości L_n od 40 do 125 mm. Stosowanie odpowiednich długości korpusu narzędzi zależy od warunków górniczo-geologicznych, jak również rodzaju kombajnu. Noże o długości $L_n = 40 \div 70$ mm stosowane są głównie w głowicach kombajnów chodnikowych, o $L_n = 70 \div 122$ mm w głowicach kombajnów ścianowych.

Optymalne parametry charakteryzujące stożkowy nóż obrotowy i jego ustawienie nie są dokładnie określone. Stąd zachodzi potrzeba przeprowadzenia szerszych badań z uwzględnieniem kątów ostrza, długości części skrawającej, kątów ustawienia, czy też kątów obrotu. Badania należy prowadzić biorąc pod uwagę wszystkie te parametry, gdyż są one ze sobą ściśle powiązane.

W przypadku stożkowego noża obrotowego niemożliwe jest określenie głównej krawędzi skrawającej, tak jak ma to miejsce dla klinowych noży promieniowych i stycznych. W trakcie urabiania calizna atakowana jest częściowo wierzchołkiem, a częściowo powierzchnią boczną stożka ostrza. Nóż wierzchołkiem ostrza wciska się w caliznę, wywołując złożony stan naprężenia skały [26]. Ze względu na kształt powierzchni ostrza, część skały, która nie zostaje urobiona na skutek wnikania ostrza, zostaje zmiażdżona. Jest to zjawisko niekorzystne, nie tylko ze względu na znaczne straty energetyczne procesu urabiania, ale również z uwagi na występujące duże siły reakcji [37].

Dlatego też kształt noża oraz sposób jego ustawienia na organie względem urabianej płaszczyzny wymaga precyzyjnego określenia wartości kątów ustawienia uchwytów nożowych. Z teorii skrawania wynika, że ruchowy kąt przyłożenia powinien być zawsze większy od zera, a kąt ostrza noża winien mieć taką wartość by zapewnić jak największą trwałość nożom. Natomiast ruchowy kąt natarcia powinien być tak dobrany, by zapewnić minimalną wartość siły oporu urabiania [37]. Powyższa uwaga odnosi się tak do noży promieniowych, stycznych jak i stożkowych noży obrotowych. W każdym z tych przypadków należy tak dobrać kąty spoczynkowe ostrza noża by w czasie urabiania zachodził prawidłowy proces skrawania.

Na korpusy noży przeznaczonych do skrawania skał i minerałów stosuje się głównie stale o dużej odporności na ścieranie, oraz dużej udarności i wytrzymałości. Są to zazwyczaj stale o podwyższonej zawartości manganu, molibdenu, chromu, niklu oraz boru. Oprócz tego stale mogą być poddawane procesowi nawęglania (celem poprawienia odporności warstwy wierzchniej) lub też obrabiane cieplnie. Należy jednak zaznaczyć, iż stale na omawiane narzędzia, wykorzystywane są głównie jako materiały konstrukcyjne, których zadaniem jest jedynie przytrzymanie elementu skrawającego, jakim jest wkładka z węgliku spiekane [27]. Cechami charakterystycznymi węglików spiekanych są: wysoka twardość i odporność na ścieranie, wysoka odporność na ściskanie, ciągliwość. Z kolei wzrost temperatury, prowadzi do zdecydowanego pogorszenia się właściwości węglików, istotnych z punktu widzenia ich trwałości [28].

Osiągnięcia współczesnej technologii umożliwiają stosowanie na ostrza narzędzi skrawających, zupełnie nowej generacji materiałów o bardzo dużej twardości, odporności na ścieranie i temperaturę pracy rzędu 1200–1400°C. Należą do nich tzw. ceramiki. W ostatnich latach podejmowane są próby wykorzystania materiałów syntetycznych, np. tzw. polikryształów diamentu (skrót ang. PDC lub niem. PKD) [27]. Najczęstszymi przyczynami zużycia ostrzy noży zbrojonych wkładkami z materiałów ceramicznych, jest mechaniczne wykruszanie materiału wkładki lub jej pękanie wskutek rozrastających się rys i pęknięć. Jedną z przyczyn tego zjawiska jest gwałtowne nagrzewanie i chłodzenie nagranych powierzchni. W konsekwencji powoduje to powstawanie naprężeń rozciągających na powierzchni wkładki, które są bardziej groźne od ściskających. Ich stosunkowo wysoka kruchość wynika także z porowatości i mikroszczelin charakterystycznych dla tych materiałów [26].

Przebieg urabiania jak również zużycia narzędzia skrawającego zależą też od takich czynników, jak:

- wytrzymałość skały na ściskanie R_c oraz jej zwięzłość,
- kruchość lub własności plastyczne skały,
- cechy spójności i niejednorodności, tj. łupliwość, uławicenie, szczelinowatość skały itp.,

- własności ściernie skały w stosunku do narzędzia,
- stan skały w pokładzie (wilgotność i inne),
- parametry skrawania (podziałka i głębokość skrawania),
- prędkości obrotowe organów urabiających,
- rodzaj kombajnu.

Wyniki prac wielu autorów dotyczące stożkowych noży obrotowych [6, 26, 27, 37, 38, 57] wskazują, że kąt ostrza β_n powinien zawierać się w przedziale $60 \div 95^\circ$, sporadycznie 110° , natomiast kąt przyłożenia α_n sugerowany jest w przedziale $0 \div 7^\circ$. Jeśli chodzi o kąt natarcia γ_n , niektórzy autorzy proponują by kąt ten wynosił $10 \div 12^\circ$ [20] lub $5 \div 10^\circ$ [73]. Wielkość kąta natarcia γ_n jest w tym przypadku wynikiem przyjętych kątów α_n i β_n (rys.2.6).

Uzyskanie zalecanych wartości kątów α_n , β_n i γ_n wynika z przyjętych wymiarów konstrukcyjnych stożkowych noży obrotowych i powinno zapewnić w czasie ich pracy prawidłowy przebieg procesu skrawania. Jednak, jak już wcześniej zaznaczono, przyjęcie spoczynkowych kątów α_n , β_n i γ_n musi również uwzględniać parametry konstrukcyjne uchwytu nożowego i kinematykę ruchu ostrza noża. Dotychczas w literaturze brak jest odpowiednich metod lub reguł pozwalających w przypadku stożkowych noży obrotowych na prawidłowy dobór narzędzi skrawających uwzględniających wcześniej wspomniane parametry. Dlatego też podejmowane są na drodze analitycznej próby określenia wartości ruchowych kątów skrawania w zależności od parametrów konstrukcyjnych i kinematycznych narzędzia, uchwytu i organu [37, 38]. Uzyskanie prawidłowej realizacji procesu skrawania wymaga wyboru odpowiednich parametrów kinematycznych i konstrukcyjnych frezującego organu [79].

3. Metody modelowania i identyfikacji procesu urabiania stożkowymi nożami obrotowymi

Wysokie koszty nowoczesnych maszyn drążących oraz narzędzi skrawających sprawiają, że koszty odchylenia warunków urabiania od optymalnych, pociągają znaczący przyrost kosztów drążenia. Szczegółowe analizy wykazują, że dobór narzędzi oraz parametrów technolo-

gicznych urabiania, do lokalnych warunków urabiania, nie jest prawidłowy. Jednym z istotnych powodów, jest brak właściwych modeli procesów urabiania, umożliwiających przewidywanie ich wyników. Sprzyja to z kolei wzrostowi zainteresowania zagadnieniami modelowania procesu urabiania, w tym zwłaszcza formowania wióra czy kształtowania się obciążenia ostrza zależnie od parametrów urabiania czy właściwości urabianych skał. Znaczne zużycie stożkowych noży obrotowych, szczególnie w przypadku skrawania skał twardych, wymusza dodatkowo podjęcie problemu optymalizacji doboru parametrów samego narzędzia jak też poszukiwania aktywnych metod monitorowania pracy całej głowicy. Zagadnienia te znajdują także swe odzwierciedlenie w pracach nad zwiększeniem trwałości, zapewnieniem optymalnych parametrów konstrukcyjnych oraz roboczych noży obrotowych a zwłaszcza w badaniach nad opracowaniem pełnego modelu urabiania skał tymi nożami.


3.1. Teoretyczne modele mechaniczne strefy skrawania

W przypadku skrawania skał, powstają wióry odrywane (elementowe). Mechanizm tworzenia wióra zależy od wielu czynników, np. od geometrii ostrza czy właściwości skały (w tym jej porowatości, współczynnika asymetrii wytrzymałości skały, itd.). W przypadku skrawania skał, hipotezy opisujące w sposób teoretyczny mechanizm odspajania elementów wióra, dzieli się na trzy grupy, tj.: hipotezy nawiązujące do teorii skrawania metali (zmodyfikowany model Merchanta [67], model Nishimatsu [55]), hipotezy zakładające krzywoliniowy kształt pęknięcia pod wpływem naprężeń ścinających lub rozciągających (np. model Evansa [11]), oraz hipotezy zakładające, że podstawową rolę w procesie skrawania odgrywa „strefa sprasowania” a o odspojeniu decydują naprężenia ścinające lub rozciągające (zależnie od wartości kąta natarcia ostrza) [4]. Ponieważ najczęściej zagadnienia analizowane są jako płaskie skrawanie ortogonalne (celem uproszczenia analizy), w większości modeli zakłada się płaską powierzchnię natarcia, nieskończoną szerokość ostrza, idealnie ostre narzędzie oraz głównie prostoliniową trajektorię odspojenia (oprócz łukowej w modelu Evansa). Kąt trajektorii odspojenia wyznacza się korzystając z zasady minimum energii w procesie skrawania.

Zależnie od geometrii ostrza oraz parametrów wytrzymałościowych skały, wyznacza się maksymalne rozmiary elementu wióra oraz minimalną siłę odspajania, traktowaną jako siła skrawania.

a)

b)



Rys.3.1. Model skrawania 2D Evansa
a) dla klina symetrycznego wg [11], b) klina asymetrycznego [73]

Tak np. w klasycznym już modelu Evansa (rys. 3.1), przy wciskania klina asymetrycznego, z uwzględnieniem sił tarcia oraz dla dowolnej szerokości ostrza b , korzystając z odpowiednich warunków równowagi wióra, wartość siły skrawania wyznaczana jest z zależności [73]:

$$F_{c \min} = \frac{2R_r g b \sin \frac{1}{2} \left(\frac{\pi}{2} - \gamma + \Theta \right)}{1 - \sin \frac{1}{2} \left(\frac{\pi}{2} - \gamma + \Theta \right)} \quad (3.1)$$

gdzie:

R_r - wytrzymałość skały na rozciąganie,

B - szerokość ostrza,

G - głębokość skrawania,

γ - kąt natarcia ostrza,

Θ - kąt tarcia wióra o powierzchnię natarcia.

W modelu 3D, opracowanym przez Evansa specjalnie dla noży stożkowych [12] (rys. 3.2), w oparciu o zagadnienie Lamé'go, wartość siły skrawania wyznaczana jest z kolei, z zależności:

$$F_c = \frac{16\pi}{\cos^2 \beta} \frac{R_r}{R_c} R_r g^2 \quad (3.2)$$

lub

$$F_c = \frac{16\pi R_r g^2}{\kappa \cos^2 \beta} \quad (3.3)$$


gdzie:

$\kappa = R_o/R_r$ - wskaźnik asymetrii wytrzymałości skały,

R_c - wytrzymałość skały na jednoosiowe ściskanie,

β - kąt połowy stożka,

g - głębokość skrawania.




Rys.3.2. Model skrawania nożem stożkowym (3D), według Evansa [12]

Ponieważ od szeregu lat, rosną możliwości obliczeniowe oraz stopień integracji systemów CAD oraz MES, stąd też propozycja wykorzystania do prowadzenia analiz, systemu metody elementów skończonych [21, 24÷27, i inni]. Wykorzystanie tych systemów oraz niektórych osiągnięć wiedzy z dziedziny mechaniki ośrodków ciągłych, pozwala mieć nadzieję, na znaczący postęp w poznaniu mechanizmów rządzących procesem pęknięcia materiału w strefie skrawania, a zatem prowadzić ten proces przynajmniej w części, w sposób zamierzony, oraz projektować maszyny i narzędzia, optymalnie do warunków skrawania.

Z uwagi na dużą liczbę czynników mających wpływ na przebieg i efekty procesu skrawania skał, zachodzącego w rzeczywistych warunkach urabiania, istnieje konieczność selektywnego rozpatrywania ich wpływu. Stąd też dla uproszczenia, w badaniach np. [24, 25, 64], analizie poddano proces skrawania ortogonalnego, którego model mechaniczny procesu, przyjęto jak na rys. 3.3. Zadanie może być wtedy analizowane jako płaskie zagadnienie kontaktowe, rozpatrywane w płaskim stanie odkształcenia.

Z uwagi na występowanie w rzeczywistym procesie skrawania, pomiędzy ostrzem a litą skałą, przejściowej warstwy materiału utwo-

rzonyj ze zmiążdżonej skały, materiał skrawany potraktowano jako dwuwarstwowy [24]. Aby uprościć nieco zagadnienie, przyjęto stałą grubość warstwy kontaktowej, w całej strefie styku ostrza i skały, równą 0,1 mm. Dla noży płaskich, zagadnienie odpowiadało więc skrawaniu ortogonalnemu ostrzem o pewnym promieniu zaokrąglenia krawędzi skrawającej r_n (0,1 mm), z głębokością skrawania g (12 mm), w pewnej odległości l (rys. 3.3a) od brzegu próbki (na tyle dużej, aby zachować jednorodność rozkładu naprężeń).




Rys. 3.3. a) model mechaniczny strefy skrawania, b) sposób jego dyskretyzacji. Model 2D, wyznaczanie reakcji skały na ostrze [27]

Sposób dyskretyzacji modelu elementami skończonymi oraz utwierdzenia węzłów brzegowych (stałymi podporami) przyjęto [24, 64] jak na rys. 3.3b. Zagęszczono siatkę w strefie oddziaływania krawędzi skrawającej, stopniowo ją rozrzedzając, w miarę oddalania się od tejże krawędzi. Rozmiary obszaru modelu przyjęto doświadczalnie tak, aby zminimalizować wpływ podpór elementów brzegowych, na rozkład naprężeń w całym obszarze, oraz na tyle duży, aby zapewnić odpowiednią ilość miejsca na hipotetyczne odspojenie wióra charakterystycznego dla przyjętej głębokości skrawania. Węzłom podstawy ostrza, narzucono warunki brzegowe, tak jak na rys. 3.3b, tj. w postaci podpór przesuwnych, pozostawiając mu tym samym jeden stopień swobody, tj. możliwość ruchu wzdłuż założonego kierunku prędkości urabiania v_c , pod wpływem całkowitej siły wymuszającej ΣF_{ci} , skierowanej zgodnie z kierunkiem wspomnianej prędkości (dla zwiększenia jednorodności obciążenia ostrza, w węzłach jego podstawy przyłożono elementarne siły wymuszające F_{ci} podobnie do działania obciążenia ciągłego. Symulowano w ten sposób

oddziaływanie uchwytu noża). Obciążenie noża zadawano krokowo, z przyrostem 5% w każdym następnym kroku. W wyniku badań przeanalizowano kształtowanie się sił reakcji skały na ostrze, zależnie od parametrów wytrzymałościowych skały, geometrii ostrza, warunków tarcia w strefie skrawania. W badaniach tych stosowano warunek plastyczności Podgórskiego [63]. Dla analizowanych przypadków wyznaczono także rozmiary głównego elementu wióra (rys. 3.4).

Ponieważ liczba czynników wpływających na przebieg procesu urabiania skały jest bardzo duża (wartość wskaźnika asymetrii wytrzymałości materiału, parametry geometryczne ostrza: wartość kąta natarcia i przyłożenia, promień zaokrąglenia krawędzi skrawającej, wilgotność skały wpływająca na zmianę wartości współczynnika tarcia materiału o ostrze, spękanie, uwarstwienie i niejednorodność struktury materiału skalnego, wartość modułu Younga i liczby Poissona, itd.), powoduje to, że proces modelowania jest bardzo utrudniony oraz wymaga przeprowadzenia znacznej liczby symulacji. Zdaniem autorów tych badań, dopracowanie procedur, powinno jednak ułatwić to zadanie.

W ostatnich latach podejmowane są próby badań numerycznych, dla skrawania 3D (np. [21, 27]). Oczekuje się, że tylko takie badania, powinny maksymalnie przybliżyć wyniki symulacji, do rzeczywistych warunków, jakie zachodzą w rzeczywistym procesie urabiania skał nożami stożkowymi.



Rys.3.4. a) trajektoria szczeliny pierwotnej oraz rozkład przemieszczeń wypadkowych w okolicy ostrza dla $\phi = 1^\circ$, b) penetracja szczeliny i rozkład przemieszczeń wypadkowych, w strefie krawędzi skrawającej w przypadku zwiększonego tarcia wióra o pow. natarcia ostrza $\phi = 30^\circ$ [27]



Rys.3.5. Rozkład naprężeń zredukowanych Hubera, w ostrzu noża stożkowego [27]. Model 3D, przekrój osiowy ostrza, aksonometria

3.2. Modele empiryczne

Celem prac doświadczalnych, jest między innymi uchwycenie korelacji pomiędzy parametrami konstrukcyjnymi ostrza, parametrami technologicznymi urabiania i właściwościami urabianych skał a kształtowaniem się wskaźników skrawania (właściwa energia urabiania, wartości składowych siły obciążającej ostrze). Realizowana jest więc w tym przypadku identyfikacja wielkości wyjściowych procesu urabiania (np. siły skrawania), z dowolną cechą procesu tj. np. wielkościami wejściowymi, w tym przypadku parametrami technologicznymi urabiania, parametrami geometrycznymi ostrza, czy parametrami wytrzymałościowymi skały.

Zdaniem Polańskiego [65], badania empiryczne stanowią podstawową metodę kreowania funkcji opisujących procesy rzeczywiste. Stanowią one jak dotąd najważniejszą metodę pozyskiwania informacji o zachodzących procesach. Z kolei funkcje aproksymujące, poprzez zastosowanie matematycznych procedur ich optymalizacji, służą do określania optymalnych parametrów procesów. W określonych warunkach, można wyznaczyć minimum funkcji aproksymującej, stanowiącej np. funkcję celu optymalizacji. Celowość wyznaczania funkcji aproksymujących uzasadnia fakt numerycznego sterowania przez komputery, współczesnymi maszynami roboczymi, a komputery do optymalnego sterowania, muszą dysponować określonymi funkcjami. Funkcja aproksymująca określa odpowiedź, czyli zmiany wielkości wyjściowej, spowodowane zmianami wielkości wejściowych. Stąd metody badań doświadczalnych stanowią podstawę do wyznaczania „powierzchni odpowiedzi” (response surface methodology) [65].

Wraz z rozwojem metod teorii eksperymentu oraz techniki komputerowej, budowano coraz bardziej złożone wzory empiryczne opisujące uzyskiwane wyniki badań doświadczalnych. Stąd też w przypadku noży stożkowych, do niedawna operowano jedynie prostymi zależnościami opisującymi kształtowanie się siły skrawania jedynie np. w funkcji głębokości i podziałki skrawania (np. [20, 66]). Były to więc zależności typu:

$$F_c = a \cdot g^b \quad (3.4)$$

$$F_c = a t^b g^c \quad (3.5)$$

lub

$$F_c = k_1 + k_2 \cdot A \quad (3.6)$$

gdzie:

a, b, c – wykładniki potęgowe

k_1, k_2 – współczynniki proporcjonalności,

t, g – podziałka i głębokość skrawania.

Ponieważ takie zależności stosunkowo słabo opisują proces urabiania skał nożami stożkowymi, poszukiwano bardziej doskonałych metod opisu tego procesu. Stąd też w oparciu o wnioski wynikające z aktualnego stanu wiedzy, w pracy [26] stwierdzono, iż dla badań laboratoryjnych, wielkościami charakteryzującymi jakościowy model procesu skrawania skał nożem stożkowym powinny być:

- **wielkości wejściowe:**

- $x_1 = t$ (podziałka skrawania),
- $x_2 = g$ (głębokość skrawania),
- $x_3 = \beta$ (kąt ostrza),
- $x_4 = \delta$ (kąt ustawienia),
- $x_5 = \rho$ (kąt obrotu),

- **wielkości wyjściowe:**

- $z_1 = F_c$ (siła skrawania),
- $z_2 = F_n$ (składowa normalna),
- $z_3 = F_b$ (składowa boczna),
- $z_4 = e_c$ (jednostkowa energia skrawania),


- **wielkości stałe:**

- c_1 = rodzaj skrawanej skały (scharakteryzowany jej wytrzymałością na ściskanie - R_c , gęstością i wilgotnością, określonymi w skali „makro”),
- $c_2 = v_c$ (prędkość skrawania),
- c_3 = stan ostrza (z uwagi na przewidywany czas pracy przeznaczony na realizację badań, pomija się tępienie ostrza. Ewentualne objawy tępienia będą usuwane na bieżąco, poprzez ostrzenie narzędzia)

- **wielkości zakłócające:**

- h_1 - lokalne zaburzenia struktury skrawanej skały (scharakteryzowane zmianą jej wytrzymałości, gęstości czy lokalnymi wtrąceniami, tj. zaburzeniami struktury i właściwości, rozpatrywanymi w skali „mikro” a mającymi wpływ na efekt skrawania w danym momencie czasowym).

Przyjęty w pracy [26], model procesu urabiania skał stożkowymi nożami obrotowymi, przedstawia rys.3.6.



Rys.3.6. Model procesu urabiania skał stożkowymi nożami obrotowymi [26]

W przeprowadzonej przez Jonaka [26] analizie wielkości stałe wyłączono z relacji opisującej jakościowy model obiektu badań. Przyjmując, że wielkości wyjściowe stanowią wielkości losowe, a wielkości stałe można pominąć, relację pomiędzy zmiennymi wejściowymi i wyjściowymi sprowadzono do postaci [26]:

$$F_z(x_1, x_2, \dots, x_5, z_1, z_2, \dots, z_4) = 0 \quad (3.7)$$

Po zastosowaniu dekompozycji obiektu badań z uwagi na istniejącą liczbę wielkości wyjściowych, uzyskano obiekty badań, z których każdy scharakteryzowany jest tylko jedną wielkością wyjściową, uzyskując w efekcie relacje:

$$\begin{aligned}
 F_{z1}(x_1, x_2, \dots, x_5, z_1) &= 0, \\
 F_{z2}(x_1, x_2, \dots, x_5, z_2) &= 0, \\
 F_{z3}(x_1, x_2, \dots, x_5, z_3) &= 0, \\
 F_{z5}(x_1, x_2, \dots, x_5, z_4) &= 0,
 \end{aligned} \tag{3.8}$$

czyli:

$$\begin{aligned}
 F_{Fc}(t, g\beta, \delta, \rho, F_c) &= 0, \\
 F_{Fn}(t, g, \beta, \delta, \rho, F_n) &= 0,
 \end{aligned} \tag{3.9}$$

$$F_{ec}(t, g, \beta, \delta, \rho, e_c) = 0.$$

Przyjmując oznaczenia: $z = z_p$, $p = 1, 2, \dots, 4$, uzyskano relację [26] typu:

$$z = F(x_1, x_2, \dots, x_4), \tag{3.10}$$

tj. funkcję aproksymującą, obiektu badań, którą wyznaczono jako zależność aproksymującą wyniki przeprowadzonych pomiarów.

Do wyznaczania zależności statystycznych pomiędzy rozpatrywanymi czynnikami badanymi i wynikowymi, wykorzystano narzędzie matematyczne w postaci analizy regresji.

Wielkość rozbieżności pomiędzy wartościami czynnika wynikowego wyznaczonego z modelu a wartością rzeczywistą tegoż czynnika wyznaczonymi doświadczalnie, oszacowano korzystając ze współczynnika korelacji wielokrotnej R [jak wiadomo, jeśli $R = 1.0$, oznacza to, że wartości z_i przewidywane na podstawie równania regresji są równe wartościom z_i uzyskanym z pomiarów. „Jakość” otrzymanego równania regresji można ocenić np. na podstawie kwadratu współczynnika korelacji wielokrotnej (R^2), istotności całego równania regresji czy odchylenia standardowego błędu liczonego jako procent średniej zmiennej zależnej (z_i)].

Jako kryterium optymalizacji przyjęto minimum sił i energii właściwej skrawania, tj.:

$$K \equiv z_i = F(x_1, x_2, \dots, x_5) \rightarrow \min; \tag{3.11}$$

Ponieważ rozpatrywany proces, można traktować jako wielowymiarowy obiekt nieliniowy, do analizy zaproponowano funkcję regresji w postaci wielomianu stopnia drugiego postaci:

$$z = a_0 + a_1x_1 + \dots + a_ix_i + a_{11}x_1x_1 + \dots + a_{ii}x_ix_i; \tag{3.12}$$

gdzie:

$x_1, \dots, x_i$ - zmienne niezależne (czynniki badane, wejściowe),
 z - badana zmienna zależna (czynnik badany, wyjściowy),
 $a_0, \dots, a_{ij}$ - współczynniki regresji.

Albo:

$$z = a_0 + \sum_{i=1}^5 (a_i \cdot x_i + a_{ii} \cdot x_i^2) + \sum_{i=1}^4 \sum_{j=i+1}^5 a_{ij} \cdot x_i \cdot x_j, \quad (3.13)$$

czyli:

$$z = a_0 + a_1 x_1 + a_{11} x_1^2 + a_2 x_2 + a_{22} x_2^2 + \dots + a_{45} x_4 x_5, \quad (3.14)$$

gdzie:


$x_1, \dots, x_j$ - zmienna niezależna,
 z - badana zmienna zależna,
 $a_0, \dots, a_i, a_j$ - współczynniki regresji.

Korzystając z uzyskanej funkcji regresji, wyznaczono optymalne z punktu widzenia obciążenia ostrza, a zwłaszcza energii właściwej skrawania, przedziały rozpatrywanych parametrów eksploatacyjnych (t, g) oraz konstrukcyjnych ostrza (β, δ, ρ). W wyniku przeprowadzonych obliczeń numerycznych, dla każdej zmiennej wyznaczono [26] aż 18 współczynników regresji, stąd też bezpośrednie wykorzystanie tej zależności może być bardzo trudne do realizacji. Jak można także zauważyć, większość współczynników regresji nie posiada fizycznego sensu (wymiar nie jest zgodny z układem jednostek SI).

Dla tak przeprowadzonej analizy, uzyskano zależności przedstawione jako „powierzchnie odpowiedzi”, których przykład ilustruje rys. 3.7

a)

b)



Rys.3.7. Powierzchnie odpowiedzi wynikające z analizy statystycznej i ilustrujące wpływ: a) kątów ostrza i ustawienia oraz b) kątów ostrza i obrotu noża stożkowego, na kształtowanie się siły skrawania [26]

Podsumowując można stwierdzić, że uzyskiwane w tym przypadku, za pomocą analizy statystycznej, zależności, z uwagi na dużą liczbę współczynników są uciążliwe w praktycznym wykorzystaniu. Postać funkcji aproksymującej dane pomiarowe często dobierana jest intuicyjnie. Taki model zależności nie pozwala także przewidywać np. efektów urabiania, dla parametrów, których wpływ na proces urabiania nie był szczegółowo przebadany, lub także poza badanym zakresem.

4. Sztuczna sieć neuronowa, geneza, rodzaje, właściwości

W chwili obecnej, obserwuje się gwałtowny rozwój badań nad sieciami neuronowymi oraz ich praktycznym wykorzystaniem [5, 7, 13, 15, 19, 29, 30, 31, 33, 39, 42, 45, 48, 49, 51, 52, 53, 62, 72, 74, 75, 76, 77, 83, 84, 87, 89, 90, 96, 97, 98, 104, 105]. Istnieje już szeroka gama tych sieci, o różnorodnej budowie jak i przeznaczeniu [32, 46-48, 53, 88, 89, 104]. Wśród tzw. klasycznych sieci neuronowych, bazujących w swoim działaniu na logice Boolowskiej (zero-jedynkowej), wyróżnić można sieci jednokierunkowe wielowarstwowe typu sigmoidalnego, sieci radialne, sieci specjalizowane typu Fahlmana czy Volterry, sieci rekurencyjne jako pamięci asocjacyjne, sieci rekurencyjne tworzone na podstawie perceptronu czy sieci samoorganizujące się na zasadzie współzawodnictwa. Zależnie od realizowanych funkcji, wyróżnia się sieci probabilistyczne, do regresji uogólnionej, realizujące regresję liniową itd., [58-60, 76]. Pewnym uogólnieniem sieci neuronowych, są sieci neuronowe rozmyte (fuzzy neural network) oparte o logikę rozmytą [15, 53, 60, 76, 99, 100, 101].

W praktyce, sieci neuronowe znajdują zastosowanie do:


- monitorowania stanu urządzeń (rozpoznawanie sytuacji awaryjnych na podstawie wibracji lub sygnałów akustycznych, umożliwiające podejmowanie działań zaradczych,
- prognozowania losowych szeregów czasowych,
- sterowania procesami (np. monitorowania aparatury przemysłowej i regulowania na bieżąco parametrów zachodzącego procesu),
- sterowania pracą silnika,
- generowania mowy na podstawie tekstu pisanego,
- rozpoznawania i oceny zjawisk medycznych,
- przetwarzania obrazów,
- rozpoznawania wzorców optycznych, itd.

Z uwagi na podjętą tematykę, poniżej omówiono jedynie wybrane zagadnienia dotyczące sieci neuronowych, istotne z punktu widzenia poruszanych zagadnień.

4.1. Sieci neuronowe klasyczne


Sztuczne sieci neuronowe to zazwyczaj oprogramowanie komputerowe lub urządzenia techniczne, których działanie naśladuje układ nerwowy [87, 89, 90]. Znane już od lat 40-tych ubiegłego wieku, znalazły swoje pierwsze praktyczne zastosowanie w przełomie lat 50-tych i 60-tych zeszłego stulecia w prostych układach elektromechanicznych lub elektrochemicznych, lecz dopiero w latach 80-tych, można zaobserwować zaangażowanie laboratoriów badawczych oraz firm elektronicznych w budowie i zastosowaniu sieci. Składa się ona z pojedynczych neuronów (węzłów obliczeniowych) połączonych w sieć [32, 49, 58, 87, 89, 90, 105]. Dostosowanie sieci neuronowej do rozwiązywania problemów polega na uczeniu jej przy użyciu ciągu typowych pobudzeń i odpowiadających im pożądanym reakcji (nie poprzez sprecyzowanie algorytmu i zapisanie go w postaci programu). Powoduje to, że sieci neuronowe mogą być stosowane tam, gdzie zastosowanie tradycyjnych metod nie jest możliwe, szczególnie w zadaniach wymagających kojarzenia informacji, jak na przykład prognozowanie, rozpoznawanie, klasyfikowanie i diagnostyka [32, 41, 46, 49, 56, 58-60, 87-90, 102, 104]. W sieciach symulowanych komputerowo stosowane algorytmy są często prostsze od rozwiązujących to samo zadanie algorytmów realizowanych drogą bezpośredniego programowania modelu, stąd czas i koszty wdrażania systemu zawierającego metody oparte o sieci neuronowe są znacznie mniejsze.

Tak więc sztuczna sieć neuronowa jest zespołem połączonych ze sobą *elementów przetwarzających zwanych neuronami*. Zasadniczym celem neuronu jest przetworzenie informacji wejściowej (dostarczanej w postaci wartości $x_1, x_2, \dots, x_n$) w wartość wyjściową $\tilde{z}$. Z każdym wejściem neuronu związany jest współczynnik zwany *wagą*. Współczynniki wagowe neuronu są podstawowymi parametrami wpływającymi na sposób funkcjonowania sztucznej komórki nerwowej. Przetwarzanie informacji przez sztuczny neuron składa się z dwóch etapów. Pierwszym z nich jest *agregacja danych wejściowych*, zaś drugim *wyznaczenie wartości wyjściowej* neuronu.



Rys.4.1. Struktura sztucznego neuronu nieliniowego [65, 90]

Agregacja danych wejściowych ma na celu przetworzenie wektora wejściowego $\mathbf{x} = (x_1, x_2, \dots, x_n)$ w pojedynczą wartość (zagregowaną wartość wyjściową, z). Na rezultat tej transformacji w zasadniczy sposób wpływają wartości wag. Spośród wielu sposobów agregacji największą popularnością cieszy się wyznaczanie wartości zagregowanej poprzez zsumowanie iloczynów wartości wejściowych i odpowiadających im wag (rys. 4.1). W niektórych zastosowaniach stosowana jest inna formuła agregacji, prowadząca do obliczenia kwadratu odległości Euklidesa pomiędzy wektorem wejściowym $\mathbf{x}$ i wektorem wag $\mathbf{w}$. Neurony, które dokonują agregacji zgodnie z drugą z przedstawionych formuł, nazywane są *neuronami radialnymi*.



Rys.4.2. Wykresy funkcji przejścia: a) sigmoidalnej, b) progowej [90]

Sieci z progową funkcją aktywacji sprawiają kłopoty podczas uczenia [90], dlatego w sztucznych sieciach neuronowych częściej stosuje się funkcje aktywacji dostarczające sygnałów o wartościach zmieniających się w sposób ciągły. Najczęściej wykorzystuje się funkcję aktywacji w postaci tzw. *sigmoidy*.

Drugim etapem w funkcjonowaniu neuronu jest wyznaczenie jego wartości wyjściowej. Elementem odpowiedzialnym za wykonanie tej czynności jest *funkcja aktywacji*. Jest to funkcja przekształcająca wyznaczoną wcześniej zagregowaną wartość wejściową w wartość wyjściową

neuronu. Najprostszym rodzajem funkcji aktywacji jest *funkcja liniowa*. Jej zastosowanie powoduje, że na wyjściu neuronu pojawia się zagregowana wartość wejściowa przemnożona przez pewien stały współczynnik.

Jak już wspomniano, koncepcja budowy sztucznej sieci neuronowej oparta jest na wykorzystaniu analogii do działania mózgu człowieka [46, 65, 90, i inni] gdzie:

1. Tworzy się pewien model pojedynczego neuronu uwzględniający:

- wiele sygnałów wejściowych przekazywanych do neuronu, symbolicznie oznaczanych jako x ,
- parametry modyfikujące każdy sygnał, czyli tzw. wagi (weight), oznaczane jako w ,
- pobudzenie (e) neuronu (net value) będące rezultatem sumowania iloczynu sygnałów (x) i odpowiednich wag (w); czasami uwzględniając dodatkową stałą w_0 stanowiącą wartość progową (*bias*), co zapisywane jest symbolicznie:

$$e = \left\{ \begin{array}{l} \sum w \cdot x \\ \sum w \cdot x + w_0 \end{array} \right. \quad (4.1)$$

- pobudzenie neuronu (e) stanowiące sygnał wyjściowy ($e \equiv z$), który jest przekazywany do innych neuronów (dla liniowego modelu neuronu). Dla nieliniowego neuronu uwzględnia się różne postacie dalszej modyfikacji sygnałów, przez wprowadzenie tzw. *funkcji aktywacji* (transfer function) stanowiącej charakterystykę neuronu określającą ostatecznie sygnał wyjściowy pojedynczego neuronu:

$$z = \varphi(e) \quad (4.2)$$

Jak wspomniano, najczęściej stosowane funkcje aktywacji, to: *funkcja skoku jednostkowego*, *funkcja liniowa*, *funkcja sigmoidalna*, *zmodyfikowana funkcja signum* oraz *bipolarna funkcja sigmoidalna*. Przykłady funkcji aktywacji przedstawia rysunek 4.2. Dla *funkcji sigmoidalnej*, można zapisać:


$$z = \varphi(e) = \frac{1}{1 + \exp(-\beta e)} \quad (4.3)$$

gdzie: β - stała.

2. Tworzy się sieć neuronową stanowiącą połączenie pojedynczych neuronów. O ile model pojedynczego neuronu może być prosty, o tyle ich liczba i wzajemne połączenia mogą być bardzo złożone.


Każdą sieć neuronową cechuje zatem określona *struktura sieci*, utworzona przez wybrany schemat przepływu sygnałów od wejścia (x) do wyjścia (z) przez sieć połączeń, z których każde cechuje określona wartość wagi (w) i *rozmiary* sieci, czyli liczba warstw neuronów oraz liczba neuronów w każdej warstwie.

Neurony wejściowe, ukryte i wyjściowe muszą zostać wzajemnie połączone, co stawia przed twórcą sieci problem wyboru jej **struktury**. Kluczową kwestią przy wyborze struktury sieci jest występowanie lub brak w tej strukturze **sprzężenia zwrotnego** [90]. Proste sieci mają strukturę jednokierunkową (tzw. *feedforward*): sygnał przepływa w nich tylko w jednym kierunku - od wejść, poprzez kolejne neurony ukryte, osiągając ostatecznie neurony wyjściowe. Strukturę taką charakteryzuje zawsze stabilne zachowanie, co jest jej zaletą.




Rys.4.3. Schematyczna budowa typowej sieci neuronowej wielowarstwowej, jednokierunkowej [90]

Jednak jeśli sieć ma wbudowane sprzężenie zwrotne (tzn. zawiera połączenia powrotne od późniejszych do wcześniejszych neuronów), to wówczas może wykonywać bardziej skomplikowane obliczenia, w szczególności takie, które mają charakter rekurencyjny (rys. 4.4). Sieci takie pracują niestabilnie [90].



Rys.4.4. Przykładowa struktura sieci rekurencyjnej [90]

Są tutaj jednak i pewne wyjątki. Dość dużą użytecznością praktyczną cechują się sieci mające wyjątkowo dużo sprzężeń zwrotnych, konkretnie – sieci, w których **wszystkie** połączenia mają charakter sprzężeń zwrotnych. Sieci takie są znane jako tzw. sieci Hopfielda i znajdują liczne zastosowania - m.in. jako tzw. pamięci asocjacyjne [90].




Rys.4.5. Struktura prostej sieci Hopfielda [90].

Każda sieć zdeterminowana jest przez strukturę połączeń, z których każde związane jest z wartością wagi (w) oraz cechy pojedynczych neuronów połączonych w sieć, a w tym postać funkcji aktywacji. Aby jednak sieć rozwiązała postawione zadanie, musi uprzednio zostać nauczona. W procesie uczenia sieci neuronowej wprowadza się dane stanowiące tzw. zbiór uczący, przy czym zawsze są to zbiory wartości wejść $\{x_1^{(u)}, x_2^{(u)}, \dots, x_k^{(u)}, \dots, x_i^{(u)}; u = 1, 2, \dots, n\}$ uzupełnione o odpowiadające im poprawne (wzorcowe) wartości wyjść $\{z^{(u)}\}$ (tzw. *uczenie z nauczycielem*) lub też bez wyjść (samouczenie, *bez nauczyciela*).


Uczenie sieci stanowi proces zmian wartości wag aż do chwili, gdy zadanie postawione sieci zostanie pozytywnie rozwiązane, np. wyznaczone zostaną poprawne wartości wyjścia $\left(\begin{matrix} \hat{z}^{(u)} \\ z^{(u)} \end{matrix} \approx z^{(u)} \right)$.

Procedura zmiany wag w procesie uczenia sieci (rys. 4.6) - tworzy jej warstwę logiczną i ta nazywana jest często *algorytmem uczenia* sieci neuronowej.

Proces uczenia sieci może być zatem interpretowany jako metoda automatycznego poszukiwania takiego zestawu współczynników wagowych występujących we wszystkich neuronach całej sieci, który gwarantuje najmniejszą wartość sumarycznego błędu popełnianego przez sieć (sumowanie odbywa się po zbiorze różnych zadań stawianych sieci).



Rys.4.6. Istota metody zmiany wektora wag podczas uczenia sieci [90]



Rys. 4.7. Kierunki przepływu sygnału w sieci z wsteczną propagacją błędów

W badaniach sieci wyróżnia się tym samym etap uczenia sieci oraz etap testowania sieci. Nauczona sieć tworzy zintegrowany zespół cech charakteryzujących pojedyncze neurony oraz strukturę sieci jako całości, łącznie ze zbiorem wszystkich wartości wag na połączeniach. Nauczona sieć może być przekazana do użytkowania.


Prawidłowo skonstruowana sieć neuronowa może służyć do rozwiązywania wielu typów zagadnień [47]. Do najpopularniejszych zastosowań sieci należy zaliczyć budowane przy ich wykorzystaniu **modele rozwiązujące problemy regresyjne (aproksymacyjne)**- sieci typu MLP, RBF, GRNN, liniowe; **problemy klasyfikacyjne** – sieci MLP, RBF, PNN, Kohonena, liniowe; oraz **problemy prognostyczne**. W **problemach regresyjnych** użytkownik modelu neuronowego oczekuje, że posiadana przez niego sieć będzie w stanie opisywać zależności pomiędzy zmiennymi, przy czym zakłada się, że zmienna objaśniana (zmienna objaśniana) ma charakter ciągły. W **problemach klasyfikacyjnych** sieć neuronowa stanowi narzędzie umożliwiające zaklasyfikowanie badanych obiektów do właściwych klas. Jeżeli wzorce klas są znane przed rozpoczęciem badań, to rozwiązywany problem określany jest mianem **klasyfikacji wzorcowej**, w przeciwnym przypadku rozwiązywane zagadnienie jest przykładem problemu **klasyfikacji bezwzorcowej**. W problemach klasyfikacyjnych informacja wyjściowa sieci zwykle ma postać zmiennej nominalnej, której poszczególne wartości reprezentują klasy, do których przypisywane są obiekty. W **problemach prognostycznych** celem stosowania modeli neuronowych jest wyznaczenie przyszłej wartości szeregu czasowego. Sieć rozwiązująca zagadnienia tego typu korzysta z bieżących oraz przeszłych wartości tego samego szeregu jak również z bieżących i przeszłych wartości innych zmiennych.

4.1.1. Perceptrony wielowarstwowe

Jednokierunkowe sieci wielowarstwowe (*perceptrony wielowarstwowe, sieci MLP – Multi Layer Perceptrons*) należą do najlepiej poznanych i najczęściej wykorzystywanych architektur sieciowych [47, i inni]. Do podstawowych własności jednokierunkowych sieci wielowarstwowych (rys. 4.8) należą:

- posiadanie architektury warstwowej - wyróżnia się warstwy: wejściową, ukryte oraz wyjściową,

- połączenia umożliwiające komunikację pomiędzy neuronami znajdującymi się w sąsiadujących ze sobą warstwach,
- dokonywanie agregacji danych wejściowych przez wszystkie neurony wchodzące w skład sieci poprzez wyznaczenie sumy ważonych wejść (przy pomocy liniowej formuły agregacji),
- liniowy charakter funkcji aktywacji neuronów wejściowych oraz nieliniowy neuronów ukrytych (często tangensoidalny, zwany „s”-kształtny), zaś neuronów wyjściowych liniowy bądź nieliniowy,
- z uwagi na występujący w „s”-kształtnych funkcjach aktywacji poziom nasycenia, dane przetwarzane przez sieć wymagają odpowiedniego przeskalowania.



Rys.4.8. Sieć typu perceptron wielowarstwowy posiadająca jedną warstwę ukrytą z pięcioma neuronami

Proces uczenia perceptronów wielowarstwowych, posiada charakterystyczne cechy [47]:

- uczenie polega na próbie wyznaczenia minimum funkcji błędu; zwykle stosuje się techniki wyznaczania minimum oparte na gradiencie (metoda wstecznej propagacji błędów i jej modyfikacje), hesjanie (metoda Newtona, Levenberga-Marquardta) lub przybliżeniu odwrotności hesjanu (metody quasi-Newtona) - wszystkie te metody nie są odporne na zatrzymywanie się w minimach lokalnych funkcji błędu,
- stosowany jest tryb uczenia z nauczycielem (zbiór uczący zawiera przykładowe zestawy danych wejściowych i odpowiadających im danych wyjściowych),
- czas uczenia perceptronów wielowarstwowych jest długi w porównaniu z nakładami czasowymi niezbędnymi do przeprowadzenia uczenia innych typów sieci,
- stosowanie w procesie uczenia globalnych metod optymalizacji jest możliwe, lecz zazwyczaj nieefektywne.

W przypadku sieci wielowarstwowych, strategię doboru wag najczęściej określa algorytm wstecznej propagacji błędów. Jego podstawę, jak już zostało omówione, stanowi funkcja celu, definiowana jako suma kwadratów różnic między aktualnymi wartościami sygnałów wejściowych sieci a wartościami zadanymi [58]. W przypadku pojedynczej próbki uczącej $(\mathbf{x}, \mathbf{d})$ funkcję celu definiuje się w postaci:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{k=1}^M (y_k - d_k)^2 \quad (4.4)$$

W przypadku wielu próbek uczących j ($j = 1, 2, \dots, p$) funkcję celu stanowi suma E po wszystkich próbkach:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^M (y_k^{(j)} - d_k^{(j)})^2 \quad (4.5)$$

W uproszczeniu można założyć, że celem uczenia sieci jest określenie wartości wag neuronów wszystkich warstw sieci w taki sposób, aby przy zadanym wektorze wejściowym $\mathbf{x}$ uzyskać na wyjściu sieci wartości sygnałów wyjściowych y_i , odpowiadające z dostateczną dokładnością wartościom zadanym d_i , dla $i = 1, 2, \dots, M$.

Oceniając model np. regresyjny szczególną uwagę należy zwrócić na mierniki pozwalające ocenić dokładność oszacowań dokonanych przez sieć (uzyskiwane na podstawie statystyk regresyjnych). Mierniki te wyznacza się osobno dla zbioru uczącego, walidacyjnego oraz testowego. W przypadku zbioru uczącego, pozwalają one na ocenę posiadanej przez sieć zdolności do aproksymacji. Zdolność do generalizacji sieci może być oceniana i wyznaczana na podstawie zbioru testowego. Zbiór walidacyjny stanowi podstawę do obliczania mierników jakości służących do monitorowania przebiegu uczenia (identyfikację przeuczenia sieci).

Wśród tych wskaźników wyznaczanych przez niektóre programy, np. Statistica Neural Networks 4.0PL, ważniejszą rolę pełnią [47, 85]:

- *S.D. Ratio* (iloraz odchylenia standardowego błędów i odchylenia standardowego wartości zmiennej objaśnianej) - miernik ten przyjmuje zawsze wartości nieujemne. Mniejsza jego wartość świadczy o lepszej jakości modelu. Dla bardzo dobrego modelu miernik ten osiąga wartość z przedziału od 0 do 0,1. Jeśli wartość *S.D. Ratio* jest

większa od jedności, to korzystanie z skonstruowanego modelu jest nieuzasadnione, gdyż dokładniejszym oszacowaniem wartości zmiennej objaśnianej jest jej średnia arytmetyczna wyznaczona na podstawie zbioru uczącego;

- *Correlation* (współczynnik korelacji Pearsona liczony pomiędzy rzeczywistymi i obliczonymi przez model wartościami zmiennej objaśnianej) - miernik ten przyjmuje wartości z przedziału od 0 do 1. Wyższa wartość miernika świadczy o lepszej jakości modelu.

4.1.2. Sieci Kohonena

Sieć zaproponowana przez T.Kohonena [29, 30] ma bardzo prostą strukturę (rys. 4.9a). W skład sieci tego typu wchodzi dwie warstwy neuronów: warstwa wejściowa i warstwa wyjściowa. Występujące w sieci połączenia mają charakter *każdy z każdym*. Sieć Kohonena charakteryzuje się jednokierunkowym przepływem informacji: od warstwy wejściowej do warstwy wyjściowej. Specyficzną cechą sieci Kohonena jest zaproponowany przez jej twórcę *sposób uporządkowania neuronów* warstwy wyjściowej. Zwykle nie są one uporządkowane liniowo (jak w sieci perceptronowej), lecz rozlokowane są w różnych punktach dwuwymiarowej płaszczyzny. Najprostsze rozwiązanie polega na umieszczeniu neuronów w polach znajdujących się na przecięciu kolejnych wierszy i kolumn wyznaczonych na płaszczyźnie.

Uczenie sieci Kohonena realizuje się *bez nauczyciela*. Podstawą uczenia jest zbiór uczący, którego każdy element jest wektorem o liczbie elementów odpowiadającej liczbie neuronów w warstwie wejściowej sieci [47]. Cechą charakterystyczną sieci Kohonena jest to, że proces modyfikacji wag neuronu przeprowadzany jest nie tylko dla neuronu zwycięskiego, ale również dla wszystkich neuronów wchodzących w obręb sąsiedztwa zwycięzcy.

Proces uczenia prowadzi do utworzenia *mapy topograficznej*. Posiada ona zdolność odwzorowywania zależności zachodzących pomiędzy obiektami - obiektom podobnym odpowiada ten sam obszar (neuron) na mapie lub obszary położone blisko siebie. Obiekty znacznie różniące się od siebie powodują uaktywnienie neuronów znajdujących się w odległych od siebie obszarach mapy.

4.2. Sieci neuronowe rozmyte (neuro-fuzzy network)

Sieci neuronowe rozmyte ([15, 58, 60, 76], Jang [22]), są pewnym uogólnieniem omówionych już sieci klasycznych (bazujących w swym działaniu na logice Boolowskiej, tzw. „zero-jedynkowej”, operującej ostrymi pojęciami prawdy i nieprawdy). Sieci rozmyte wykorzystują zasady logiki rozmytej, których podstawą jest pojęcie niepełnej przynależności do zbioru. Twórcą zbiorów rozmytych i **logiki rozmytej (fuzzy logic)** jest Zadeh [101]. Z kolei Takagi, Seguno oraz Kang [91] sformułowali podstawowe prawa, umożliwiające wykorzystanie tej logiki w praktyce.

Wnioskowanie oparte na logice **ostrej** przedstawić można za pomocą **reguły** np. postaci:

IF prędkość skrawania < 50 m/s **THEN** moc skrawania < 20 W

W tym przypadku mamy do czynienia z wyraźnie określonymi granicami. Gdy granice te nie są wyraźnie określone, tj. w przypadku reguły:


IF prędkość skrawania jest mała **AND** posuw mały **THEN** moc skrawania mała, mamy do czynienia z **wnioskowaniem rozmytym**.

W procedurach wnioskowania nieostrego (rozmytego) stosowane są pojęcia **liczb rozmytych**. Liczbą rozmytą L , nazywany jest taki zbiór rozmyty z przestrzeni $\mathcal{R}$, że istnieje dokładnie jedno $x_0 \in \mathcal{R}$, dla którego $\mu_L(x_0) = 1$. Wartość x_0 nazywana jest średnią wartością L . Zbiory B i liczby rozmyte L reprezentowane są w różny sposób, przy czym w uproszczeniu postać funkcji przynależności (membership function), może być definiowana (funkcja trójkątna oraz trapezoidalna) jako:


$$\begin{aligned} \mu_B(x) = \mu_L(x) &= 0 \quad \text{dla } x < \alpha \\ \mu_B(x) = \mu_L(x) &= (x - \alpha) / (a - \alpha) \quad \text{dla } x \in [\alpha, a] \\ \mu_B(x) = \mu_L(x) &= 1 \quad \text{dla } x \in [a, b] \\ \mu_B(x) = \mu_L(x) &= (\beta - x) / (\beta - b) \quad \text{dla } x \in (b, \beta] \\ \mu_B(x) = \mu_L(x) &= 0 \quad \text{dla } x > \beta \end{aligned} \quad (4.6)$$

co ilustruje rysunek 4.10.

Na podstawie teorii zbiorów rozmytych i wywodzącego się z niej pojęcia liczb rozmytych opracowano koncepcję wnioskowania rozmytego. Dla dwóch reguł R_1 i R_2 , przykład takiego wnioskowania przedstawia rysunek 4.11.



Rys.4.10. Wykres funkcji przynależności dla: a) zbioru rozmytego, b) liczby rozmytej




Rys.4.11. Przykład wnioskowania rozmytego

Tak więc elementy zbiorów rozmytych, reguły implikacji oraz rozumowania rozmytego tworzą system wnioskowania rozmytego. Wyróżnić w nim można [58] zbiór reguł rozmytych wykorzystywanych w systemie, bazę danych opisujących postacie funkcji przynależności oraz mechanizm wnioskowania i agregacji, na który składają się zastosowane reguły implikacji.

W przypadku zastosowań technicznych, wielkościami wejściowymi i wyjściowymi są zwykle wartości pomierzone, przyporządkowujące w sposób ścisły wielkościom wejściowym odpowiednie wielkości wyjściowe. W celu umożliwienia współdziałania tych dwóch rodzajów zbiorów jak i realizacji przetwarzania danych rozmytych przez systemy komputerowe, wprowadzono system rozmyty z tak zwanym fuzyfikatorem (układem rozmywania) na wejściu i defuzyfikatorem (układem wyostrzania) na wyjściu. Schemat takiego układu ilustruje rysunek 4.12.

Procedurę defuzyfikacji można wykonać, korzystając z jednej z metod np. wyznaczania środka ciężkości (center of gravity). Polega ona na wyznaczeniu wartości z_0 jako środka ciężkości figury (rys. 4.11), która powstała jako rezultat wnioskowania rozmytego, tj:

$$z_0 = \frac{\int_U z \mu(z) dz}{\int_U \mu(z) dz} \quad \text{lub} \quad z_0 = \frac{\sum_{i=1}^l z_i \mu(z_i)}{\sum_{i=1}^l \mu(z_i)} \quad (4.7)$$



Rys.4.12. Schemat układu rozmytego z fuzyfikatorem i defuzykatorem [58]

W chwili obecnej istnieje szereg odmian systemów rozmytych. Jedną z nich są sieci neuronowe rozmyte, będące de facto układem adaptacyjnym o budowie warstwowej, dużej równoległości działania poszczególnych jednostek i podlegających uczeniu analogicznie do sieci neuronowych z wykorzystaniem zbiorów uczących [60]. Posiadają one wszystkie cechy sieci neuronowych, choć w swoim działaniu wykorzystują inne zasady wnioskowania oparte właśnie na logice rozmytej. Spośród takich sieci, do bardziej znanych należą sieci bazujące na regułach wnioskowania Takagi, Sugeno i Kanga [22, 60, 91], w skrócie zwane TSK.

Sieć typu TSK charakteryzuje struktura warstwowa jak dla klasycznej sieci neuronowej. Funkcje pełnione przez poszczególne neurony są jednak inne. Warstwa pierwsza dokonuje rozmywania (fuzyfikacji) zmiennych wejściowych typu ostrego. W warstwie drugiej dokonywane jest uzgadnianie (agregacja) funkcji przynależności poszczególnych zmiennych tworzących wektor wejściowy $\mathbf{x}$ dotyczący poprzednika. W warstwie trzeciej następuje generacja funkcji liniowych TSK i pomnożenie ich przez odpowiednie poziomy zapłonu reguł wnioskowania. W warstwie czwartej dokonuje się normalizacja sygnałów, a w warstwie piątej generowany jest wynik końcowy $y = f(\mathbf{x})$.

Szczególną przewagę w stosunku do sieci klasycznych, sieci rozmyte wykazują w przypadku danych tworzących zbiory częściowo zachodzące na siebie. Dobrze nadają się do przetwarzania informacji lingwistycznej, z uwagi na wbudowane mechanizmy reprezentacji wiedzy. Przy czym za zmienne lingwistyczne przyjmuje się takie zmienne, które przyjmują jako swoje wartości, słowa lub zdania wypowiedziane w języku naturalnym [76], np. „mała prędkość”. Sieci rozmyte znajdują zastosowanie w układach regulacji automatycznej, estymacji, identyfikacji oraz klasyfikacji.

4.3. Przeuczenie sieci

Przeuczenie sieci to zjawisko pojawiające się w trakcie uczenia sieci, polegające na zbytym dopasowaniu się sieci do punktów uczących, któremu towarzyszy błędne działanie sieci dla danych nie prezentowanych w trakcie uczenia. Przeuczenie pojawia się w przypadku zbyt długiego uczenia lub wówczas, gdy zastosowana sieć jest zbyt złożona w porównaniu ze złożonością problemu lub liczbą dostępnych danych uczących.

4.4. Kryterium jakości sieci

Kryterium jakości sieci promuje minimalną liczbę połączeń synaptycznych η oraz czas uczenia sieci $t(A)$ (w sensie liczby iteracji) [82]:

$$J_T = \beta\eta(A) + \gamma t(A) \quad (4.8)$$

gdzie:

η - liczba połączeń synaptycznych,

β, γ - są parametrami wagowymi decydującymi, które z kryteriów jest dla nas bardziej istotne: minimalizacja liczby połączeń czy minimalizacja czasu uczenia.

4.5. Podsumowanie

Wymienione typy i budowa sieci są jedynie niewielką częścią istniejących odmian sieci neuronowych. Ich mnogość podyktowana jest różnym zastosowaniem i przeznaczeniem, zarówno do projektowania, analiz, jak i do procesów optymalizacyjnych. Sieć neuronowa może zastąpić jedynie pojedyncze procesy myślowe i w zależności od potrzeb dobierany jest jej typ i dokonywana jest jej mutacja.


Wykorzystanie sieci polega na wytrenowaniu jej na pewnym zbiorze danych, aby potem, za jej pomocą móc przewidywać określone dane wyjściowe. Jest to zatem związane z procesem prognozowania. Istotnym jest to, że sieć nabiera zdolności do przewidywania wyłącznie na podstawie dostarczonych danych, nie podaje się jej natomiast żadnych wzorów lub teorii o związkach pomiędzy danymi, a prognozowanymi wynikami.

Ogromną zaletą sieci neuronowych jest fakt, że pozwalają one na poszukiwanie modeli dla procesów lub zjawisk, których struktura lub praca działania nie zostały poznane i opisane w sposób pozwalający na budowę ich modelu, przy czym użytkownik sieci nie musi deklarować żadnej, z góry zadanej formy poszukiwanego modelu, a nawet nie musi być pewny, że w ogóle jakaś dająca się matematycznie modelować zależność ma miejsce [90]. Dlatego sieć neuronowa może stanowić o wiele prostsze i dokładniejsze niż dotychczas stosowane, „narzędzie” badawcze, w tym zwłaszcza np. do identyfikacji obciążenia stożkowego noża obrotowego w procesie skrawania skał.

5. Wykorzystanie sieci neuronowych w branży górniczej - stan wiedzy

Zastosowanie sieci neuronowych, w poszczególnych gałęziach branży górniczej, nie jest równomierne. Chyba najbardziej gwałtowny rozwój ich wykorzystania obserwuje się w petrografii, zagadnieniach mechaniki pęknięcia, prognozowaniu parametrów wytrzymałościowych skał, prognozowaniu sedymentacji skał osadowych oraz stanu nasycenia ich ropą naftową [6, 8, 14, 54, 78, 80, 81]. Przy wykorzystaniu sieci neuronowych podejmowane są próby modelowania procesów flotacji [92] oraz np. zjawisk trybologicznych zachodzących w hamulcach maszyn wyciągowych [17, 18]. Zadowalające wyniki uzyskano przy badaniach wpływu wydobywania na sejsmiczność w kopalniach węgla kamiennego [36].

W pracy [50], wykazano znacznie lepsze możliwości predykcji jednoosiowej wytrzymałości skał, w oparciu o takie parametry jak gęstość, porowatość, twardość, wielkość ziarna i rodzaj skały, przy wykorzystaniu sieci neuronowej (rys.5.1a), niż można to uzyskać z wykorzystaniem klasycznych metod statystycznych.



Rys.5.1. Model sieci neuronowej użytej do predykcji parametrów wytrzymałościowych skał - (a) oraz wpływ rozpatrywanych czynników na wynik prognozowania - (b) [50]


Jak wynika z rysunku 5.1b, wpływ rozpatrywanych czynników charakteryzujących skałę na jej wytrzymałość, nie jest jednakowy. Twardość jak i gęstość skały, mają dodatni wpływ na wzrost jej wytrzymałości (tzn., że jeśli np. gęstość rośnie, rośnie też wytrzymałość skały). Porowatość oraz wielkość ziarna mają ujemny wpływ na wytrzymałość skały, co znaczy, że gdy te parametry rosną, wytrzymałość maleje. Przed wprowadzeniem do sieci, opis lingwistyczny typu skały, uwzględniający podział na kategorie skał np. piaskowiec, wapień, dolomit itp., oraz jej zwięzłość np. ekstremalnie mocna, słaba, bardzo zwięzła (mocna) zostały zamienione na odpowiednie wartości numeryczne. W końcowym efekcie stwierdzono, że im skała mniej zwięzła, tym jej wytrzymałość na ściskanie maleje.

Ostatnie lata charakteryzują się także rosnącym zainteresowaniem systemami sterowania według logiki rozmytej [10, 60, 76, 91, 99, 101] w tym zwłaszcza układach sterowania czasu rzeczywistego [31]. Przykładem może być tutaj próba optymalizacji pracy koparek z użyciem sterownika opartego na logice rozmytej (Szalek, Szlagowski [86]). Zastosowanie takiego systemu sterowania eliminuje potrzebę budowania modeli

matematycznych, które dla optymalizacji procesu urabiania są bardzo skomplikowane i przez to mogą być bezużyteczne w czasie rzeczywistym. Spowodowane jest to nieliniowym charakterem obiektu rzeczywistego. Z uwagi na charakter procesu urabiania gruntu, określono go jako niemożliwy do przewidzenia przy ekstremalnie zmiennych warunkach środowiska, w którym on zachodzi. Stąd powstała koncepcja wykorzystania w procesie automatyzacji sterowania tym procesem, logiki rozmytej.


5.1. Wykorzystanie sieci neuronowych w badaniach procesu urabiania skał

Stosunkowo mało prac znaleźć można z tematyki sieci neuronowych w zagadnieniach urabiania, maszyn drążących czy kombajnów ścianowych. Interesującą próbę wykorzystania sieci neuronowych rozmytych (FNN), do prognozowania godzinowego postępu drążenia pełno-przekrojowego (H), maszyną typu TBM, zależnie od wytrzymałości skał na ściskanie (R_c), szczelinowatości skały (s), prędkości obrotowej głowicy (n_o), średnicy głowicy (D), oraz posuwu na jeden obrót głowicy (f), przedstawiono w pracy [16]. Algorytm poszukiwania optymalnego rozwiązania przedstawia rysunek 5.2.



Rys.5.2. Algorytm poszukiwania optymalnych parametrów maszyny typu TBM [16]

Autorzy wstępnych badań modelowania i identyfikacji procesu urabiania skał nożami płaskimi [103] zaproponowali uproszczone modele sieci neuronowej służące do identyfikacji procesu skrawania skał. Przeprowadzone symulacje dały dość obiecujące wyniki. Generalnie jednak, wykorzystanie sieci neuronowych do badania i identyfikacji procesów urabiania skał, nie było jak dotąd w Polsce stosowane, a i na świecie, próby takie były przeprowadzone jedynie w ograniczonym zakresie.



Rys.5.3. Struktura sieci FNN (ANFIS) do prognozowania postępu drażenia maszyną typu TBM, dla 5 parametrów wejściowych oraz 4 reguł (1÷5 numery warstw: 1 - wejściowa, 2 - wejść funkcji przynależności, 3 - reguł rozmytych, 4 - wyjść funkcji przynależności, 5 - sumowania wag. R_c - wytrzymałość skały na ściskanie, f - posuw głowicy na 1 obrót, s - szczelinowatość skały, D - średnica głowicy, n_o - prędkość obrotowa głowicy, H - postęp drażenia

6. Wstępne badania numeryczne nad wykorzystaniem sieci neuronowych w badaniach procesu urabiania skał

Modele charakteryzujące proces skrawania skał oparte przede wszystkim o analizę statystyczną (np. [26]), są uciążliwe w praktycznym zastosowaniu do badania efektów urabiania, oraz mało wiarygodne dla parametrów, których wpływ nie był szczegółowo przebadany. Z uwagi na opisane nowe trendy w analizie wyników badań, podjęto próbę wykorzystania neuronowej aproksymacji [68-70], wyników badań charakterystycznych dla skrawania piaskowca, przedstawionych w pracy [26].

Przyjęto założenie, że sztuczne sieci neuronowe umożliwią (na podstawie przeprowadzonych badań) skutecznie identyfikować proces urabiania skał, bez konieczności znajomości praw rządzących tym procesem,

a jedynie na podstawie zadanych wielkości wejściowych oraz pomierzonych wielkości wyjściowych. W analizie statystycznej w przeciwieństwie do sieci neuronowej zakładana jest postać funkcji odwzorowującej zachodzące relacje. W przypadku sieci neuronowej nie ma wymogu znajomości charakteru zachodzących procesów ani opisującej je funkcji.

6.1. Poszukiwania optymalnej struktury sieci neuronowej

Jakość modelu rozwiązywanego zagadnienia zależy przede wszystkim od architektury sieci, w tym m.in. od typu sieci, sposobu jej uczenia, metody obliczania błędu, liczby warstw sieci i zawartych w niej neuronów oraz prezentowanych danych wejściowych i wyjściowych.

Wykorzystując wyniki skrawania piaskowca [26], poczynając od prostych sieci neuronowych, przez sieci wielowarstwowe przebadano wpływ architektury sieci na kształtowanie się możliwości wykorzystania sieci neuronowych do zagadnień aproksymacji wspomnianych wyników badań.

Z uwagi na jeden z podstawowych celów pracy, jakim było porównanie wyników działania sieci oraz wyników modelowania procesu klasycznymi metodami matematycznymi, mając także na uwadze dostępność baz danych oraz w oparciu o wiadomości literaturowe nt. stosowania sieci neuronowych, do badań wstępnych przyjęto założenie, że właściwym jest zastosowanie modelu sieci neuronowej, zbudowanego w oparciu o dane wejściowe i wyjściowe zastosowane w analizie statystycznej [26], które to zostały opisane w rozdziale 3. Parametry te stanowiły podstawę do poszukiwania właściwej architektury sieci i jej cech zarówno ze względu na uzyskiwaną w dotychczasowych badaniach dużą zgodność wyników, jak i na możliwość pozyskania i wykorzystania istniejących baz danych pomiarowych.

Zastosowane w modelu sieci neuronowej, w pierwszej fazie badań, wielkości wejściowe i wyjściowe przedstawiono na rysunku 6.1. Są to:

Przyjęte zmienne wielkości wejściowe:

parametry technologiczne pracy ostrza:

t - podziałka skrawania [mm],

g - głębokość skrawania [mm],

m - masa zeskrwanego materiału w jednym przejściu ostrza [g],

parametry geometryczne ostrza:


β - kąt ostrza [$^{\circ}$],

δ - kąt ustawienia [$^{\circ}$],

ρ - kąt obrotu [$^{\circ}$].


Wielkości wyjściowe: F_c – siła skrawania [kN], F_n – siła normalna skrawania [kN], F_b – siła boczna [kN], e_c – jednostkowa energia skrawania [MJ/m^3],

Taki model sieci neuronowej charakteryzuje się złożonym procesem uczenia (np. metoda wstecznej propagacji błędów) a wielkość zbioru uczącego może być w takich przypadkach niewystarczająca aby można mówić o reprezentatywności wyników.



Rys.6.1. Wstępny model sieci neuronowej do badania procesu skrawania skał nożem stożkowym [68]

W związku z tym doprowadzono do dekompozycji sieci celem uproszczenia jej modelu oraz możliwości użycia szybszej i sprawniejszej metody uczenia. W jej wyniku otrzymano osobną sieć dla każdej wielkości wyjściowej, jak na rysunku 6.2.




Rys.6.2. Dekompozycja modelu sieci neuronowej [68]

Sieć z jedną wielkością wyjściową osiąga lepsze parametry, zarówno ze względu na prędkość uczenia, jak i dokładności symulacji. Dla odpowiedniej wielkości wyjściowej możemy stosować odpowiedni model sieci, indywidualnie dobierać metodę uczenia jak i liczbę epok uczenia.

Wytypowano parametry służące do uczenia sieci przy założeniu, że w przyjętym modelu, prezentacji określonych danych wejściowych będzie towarzyszyła jedna oczekiwana wielkość wyjściowa. Założono, że ciągi uczące będą budowane na podstawie wyników pomiarów dla kombinacji tych parametrów. Na podstawie wstępnych wyników symulacji określano jakość przyjętego modelu oraz metody jego uczenia.

Proponowany model sieci neuronowej można uczyć prostszymi metodami np. *Levenberga-Marquardta* lub *gradientów sprzężonych*. W wyniku prowadzonych z wykorzystaniem programu *STATISTICA Neural Networks 4.0PL* [85] analiz, przyjęto model *sieci perceptronowej wielowarstwowej* posiadającej sześć neuronów w warstwie wejściowej odpowiadających wielkościom t , g , m , δ , β , ρ , określoną liczbę neuronów w jednej lub dwóch warstwach ukrytych oraz jeden w warstwie wyjściowej reprezentujący odpowiednio jedną z wielkości F_c , F_n , F_b , lub e_c . Masę m wprowadzano opcjonalnie, na wejście sieci przeznaczonej do badania kształtowania się energii jednostkowej.

Sprawą niezwykle istotną dla pracy sieci, jest np. liczba warstw ukrytych, liczba neuronów w warstwie, czy liczba epok. W efekcie poszukiwania właściwej architektury sieci wygenerowano model, którego błąd uczenia zawierał się w granicach 4÷8% (rys.6.3) w odniesieniu do wyników rzeczywistych wartości F_c . W zaprezentowanym przypadku sieć uczono w przedziale 1000 epok metodą *Levenberga-Marquardta*. Podobny błąd uczenia wykazuje ten model sieci uczony metodą *gradientów sprzężonych*, jednak zbiór uczący często zatrzymywał się w minimum lokalnym. Wprowadzenie do zbioru wielkości wejściowych, dodatkowej wielkości, tj. masy zeskrawanego materiału, obniżyło błąd uczenia sieci do około 2÷3%. Ponieważ masa jest funkcją gęstości skały, może to świadczyć, że siły również zależą od gęstości skały, czego dotąd nie uwzględniano w klasycznych modelach, budowanych w oparciu o statystykę matematyczną.



Rys.6.3. Wykres błęd uczenia metodą Levenberga-Marquardta, sieci perceptronowej wielowarstwowej z jedną 9-neuronową warstwą ukrytą

Poruszane zagadnienie, to typowy problem optymalnego doboru zbioru wejść sieci. Wybór ten jest zawsze trudny, gdyż należy rozważyć szereg przesłanek¹:


- *Problem wymiarowości.* Każdy dodatkowy neuron wejściowy w sieci powoduje zwiększenie wymiaru przestrzeni, w której znajdują się przypadki danych. Komplikuje to strukturę sieci, a także stwarza większe wymagania odnośnie zbiorów uczących. Należy bowiem pamiętać o konieczności zapewnienia dostatecznej liczby punktów uczących, które w wystarczającym stopniu wypełnią N -wymiarową przestrzeń sygnałów wejściowych. Musi być tych punktów uczących na tyle dużo, żeby wystarczająco gęsto wypełniły przestrzeń wejść, tak aby możliwe było "zobaczenie" istniejącej struktury danych i wierne odwzorowanie jej właściwości. Liczba punktów niezbędnych do tego rośnie bardzo szybko, wraz z wymiarem przestrzeni sygnałów wejściowych. Szacunkowo można podać, że liczba punktów (elementów zbioru danych) potrzebnych do odpowiednio wiernego odwzorowania zasadniczych cech tworzonego modelu jest rzędu $2N$. Oznacza to, że nie można bezkarnie powiększać liczebności wejściowego wektora danych, gdyż trzeba wtedy mieć bardzo wiele obserwacji, aby uzyskać w miarę reprezentatywne dane. Wymagania można czasem nieco złagodzić. Większość typów sieci neuronowych (w szczególności sieci MLP) w rzeczywistości jest jednak w mniejszym stopniu podatna na problemy związane z wymiarem przestrzeni.

[1]¹ Wójtowicz P.: Polska wersja STATISTICA Neural Networks.
http://www.statsoft.pl/stat_nn.html.

- *Współzależności pomiędzy zmiennymi.* Gdyby istniała możliwość niezależnej oceny użyteczności każdej potencjalnej zmiennej wejściowej, to wówczas można by było wybrać na wejścia sieci tylko te spośród nich, które są najbardziej przydatne. Niestety, taka możliwość istnieje rzadko, gdyż zwykle istotne dodatkowe informacje mieszczą się we współwystępowaniu zmiennych. Chodzi mianowicie o to, że dwie lub większa liczba współzależnych zmiennych może razem dostarczać istotnych informacji, podczas gdy każdy podzbiór takiego zestawu zmiennych informacji tych już nie zawiera.
- *Redundancja zmiennych.* Często w zadaniach rozwiązywanych za pomocą sieci neuronowych zdarza się, że liczne zmienne mogą dostarczać na różne sposoby tych samych informacji. W przypadku, kiedy zmienne wejściowe są silnie skorelowane, wystarczy użyć w charakterze wejść pewnego ich podzbioru. Przewaga stosowania podzbioru skorelowanych zmiennych zamiast korzystania z pełnego ich zbioru jest oczywistą konsekwencją dyskutowanego wyżej problemu wymiaru wejściowego wektora danych. Dokonując opisanej w poprzednim punkcie redukcji danych, musimy być pewni, że w rozważanym problemie nie pojawia się merytoryczna potrzeba uwzględnienia wzajemnych relacji lub proporcji skorelowanych zmiennych.

Przyjęty do badań wstępnych, model sieci neuronowej (rys. 6.2), odwzorowujący przebieg procesu skrawania skał, ze średnim błędem odtworzenia 4÷8%, potwierdzał zasadność prowadzonych prac. Ponieważ jednak badanie skrawania innego rodzaju skały za pomocą omawianego modelu, może wykazać większy błąd uczenia, stąd też zaplanowano przeprowadzenie rozszerzonych badań zasadniczych, tak laboratoryjnych urabiania, jak i numerycznych, z wykorzystaniem sieci neuronowych o zmienionej odpowiednio konfiguracji.


Kreując najwłaściwszy model sieci, eksperymentowano na różnorodnych układach warstw i neuronów. Ograniczając do minimum liczbę wejść (rys. 6.4) otrzymywano duży (około 15%) błąd odwzorowania procesu skrawania skał.



Rys.6.4. Najprostsza struktura sieci neuronowej testowana w badaniach wstępnych [68]

Porównując jednak otrzymane powierzchnie odpowiedzi (rys. 6.5) z wynikami uzyskanymi w oparciu o analizę statystyczną [26] (lub rozdział 3, rys. 3.7a), stwierdzono stosunkowo dobrą zgodność kształtowania się tak powierzchni odpowiedzi jak i przewidywanych wartości siły F_c .

Masę urobku (m) początkowo wprowadzano jedynie opcjonalnie, podczas badania przebiegów jednostkowej energii urabiania (e_c). Okazało się jednak, że uwzględnienie jej również w modelu opisującym składowe siły na ostrzu, sprzyja lepszemu dopasowaniu odpowiedzi sieci do rzeczywistych wyników pomiarów. Błąd uczenia sieci nie przekraczał w tym przypadku 2÷3%. Był więc zdecydowanie mniejszy, niż uzyskiwano to w badaniach prowadzonych w oparciu o klasyczne, statystyczne metody analizy wyników [26], gdzie błąd ten wahał się na poziomie 10%.




Rys.6.5. Powierzchnie odpowiedzi kształtowania się siły skrawania F_c sieci neuronowej (według rys. 6.2), zależnie od: a) kątów: ostrza β i ustawienia δ , b) podziałki t i głębokości g

Wyniki przeprowadzonych badań wstępnych wykazały potencjalną możliwość zastosowania sieci neuronowych jako efektywnego sposobu prognozowania obciążenia noża stożkowego w procesie urabiania. Stwierdzono, że efektywne zastosowanie sztucznej sieci neuronowej do badań obciążeń noży zależy będzie przede wszystkim od prawidłowo zidentyfikowanych wielkości fizycznych biorących udział w procesie skrawania oraz odpowiedniej architektury sieci i metody jej uczenia.

Z uwagi na tak obiecujące wyniki powyższych analiz, przy realizacji dalszych badań założono wykorzystanie aproksymacji neuronowej, jako podstawowego narzędzia wspomagającego proces opracowywania wyników badań procesu urabiania skał stożkowymi nożami obrotowymi.


7. Rozszerzony model procesu urabiania skał stożkowym nożem obrotowym

Najważniejsze parametry konstrukcyjne ostrza oraz technologiczne urabiania nożem obrotowym, ilustruje rysunek 7.1.



Rys.7.1. Parametry konstrukcyjno-technologiczne istotne dla procesu urabiania skał, nożami stożkowymi [26] (t , g - podziałka i głębokość urabiania, β , δ , ρ - kąty: ostrza, ustawienia oraz obrotu) przyjęte w dalszej analizie zagadnienia

Mając na uwadze przesłanki wynikające z teorii Evansa, dotyczącej urabiania skał stożkowymi nożami obrotowymi, zaproponowano rozszerzenie empirycznego modelu urabiania podanego w pracy [26], do postaci przedstawionej na rysunku 7.2.



Rys. 7.2. Wielkości charakteryzujące poszerzony model procesu urabiania skał nożem stożkowym: x - wielkości wejściowe, z - wielkości wyjściowe, c - wielkości stałe, h - wielkości zakłócające, x_7 , x_8 , x_9 - dodatkowe wielkości wejściowe proponowane w modelu, ζ - gęstość skały

Oznaczenia poszczególnych zmiennych przyjęto jak w modelu przedstawionym na rysunku 3.6. Jak już sygnalizowano, w procesie urabiania skał maszynami drążącymi, prędkość skrawania jest prawie niezmienna, stąd w modelu traktowana jest jako wielkość stała.


8. Uzupełniające badania stanowiskowe procesu urabiania skał stożkowymi nożami obrotowymi

Z uwagi na możliwość identyfikacji modelu procesu, zaproponowanego na rysunku 7.2, oraz przyjęte cele badań, badania zasadnicze (rozszerzające bazę niezbędnych danych pomiarowych), przeprowadzono na dwóch stanowiskach badawczych, o odmiennej zasadzie działania, dla dwóch rodzajów skał.


8.1. Stanowisko o prostoliniowej trajektorii skrawania

W skład tego stanowiska (rys. 8.1), wchodziła strugarka poprzeczna SP-800 oraz siłomierz tensometryczny umożliwiający pomiar równocześnie trzech składowych siły działającej na ostrze (F_c , F_b , F_n).

Siłomierz tensometryczny był zaprojektowany i wykonany w Politechnice Lubelskiej. Pomiary sił były realizowane w układzie pełnego mostka tensometrycznego. W skład aparatury pomiarowej wchodził ponadto, sterowany komputerem (z użyciem karty C/A typu LC-055-PIO) wzmacniacz tensometryczny typu AMP-UNI.01, który przekazywał odpowiednio wzmocnione sygnały elektryczne na kartę pomiarową A/C typu LC-011-1612. Za pomocą wspomnianej karty A/C, sygnały analogowe przetwarzane były na sygnały cyfrowe i przekazywane do komputera. Schemat stanowiska pomiarowego przedstawia rysunku 8.2. Po przeskalowaniu sygnałów pomiarowych, wyznaczano wartości średnie badanych wielkości. Mocowanie noża w uchwycie siłomierza pozwalało na swobodny obrót noża stożkowego, wokół jego osi. Skalowania układu pomiarowego dokonano przy użyciu siłomierza optycznego typu KMPo, o zakresie pomiarowym $0 \div 20$ kN. Stała prędkość skrawania wynosiła $0,45$ m/s. Wyzwalanie pomiarów odbywało się zdalnie i automatycznie. Czas pomiaru ustalony był programowo, poprzez zadeklarowanie okresu próbkowania oraz liczby próbek. Skrawaniu poddawano skałę wapienną w blokach o wymiarach $\sim 300 \times 400 \times 600$ mm.



Rys.8.1. Stanowisko badawcze
o prostoliniowej trajektorii
skrawania



Rys. 8.2. Schemat stanowiska badawczego o prostoliniowej trajektorii skrawania

8.1.1. Warunki realizacji badań na strugarce

Z uwagi na podstawowy cel badań, w badaniach zasadniczych realizowanych na strugarce, zastosowano identyczne parametry noży urabiających jak w pracy [26], tj.:

- kąt ostrza $\beta = 75^\circ, 80^\circ, 85^\circ$,
- kąt ustawienia $\delta = 40^\circ, 45^\circ, 50^\circ$,
- kąt obrotu $\rho = -20^\circ, -10^\circ, 0^\circ, 10^\circ, 20^\circ$.

Podobnie, parametry procesu urabiania, które zastosowano w badaniach zasadniczych skrawania wapienia to:

- głębokość skrawania $g = 6 \text{ mm}, 12 \text{ mm}, 18 \text{ mm}$,
- podziałka skrawania $t = 10 \text{ mm}, 15 \text{ mm}, 20 \text{ mm}, 25 \text{ mm}, 30 \text{ mm}, 35 \text{ mm}, 45 \text{ mm}, 55 \text{ mm}, 60 \text{ mm}, 70 \text{ mm}$.

Ponieważ z danych literaturowych wynika, że dla badanych noży minimum właściwej energii skrawania występuje dla $t/g = \sim(2+3)$, stąd podziałkę skrawania dobrano odpowiednio dla:

- $g = 6$ mm, przyjęto $t = 10, 15, 20, 25, 35$ mm,
- $g = 12$ mm, przyjęto $t = 20, 25, 30, 35, 45, 55, 60$ mm,
- $g = 18$ mm, przyjęto $t = 25, 30, 35, 45, 55, 60, 70$ mm.

Parametry skrawanego wapienia wynosiły:

- wytrzymałość na jednoosiowe ściskanie $R_c \approx 7,4$ MPa,
- współczynnik asymetrii wytrzymałości $R_o/R_r \approx 8,1$,
- gęstość ośrodka skalnego $\varsigma \approx 1,64$ g/cm³.


Celem zgodności metodyk badawczych, w prowadzonych badaniach, dla każdej serii pomiarowej przyjęto wykonanie 5 powtórzeń (jak w pracy [26]). Liczba ta wynikała z niezbędnej liczby pomiarów wyznaczonej dla skróconego testu t-Studenta.

Skrawki wykonywano z wyrównanej powierzchni. W trakcie badań zbierano urobek, którego masa, wraz z założoną długością drogi skrawania, służyła do wyznaczenia jednostkowej energii skrawania.

a)





b)



Rys.8.3. Obraz powierzchni obrobionej przy skrawaniu wapienia nożem o geometrii: a) $\rho = -10^\circ, \beta = 80^\circ, \delta = 50^\circ$, b) $\rho = -10^\circ, \beta = 80^\circ, \delta = 45^\circ$

a)





Rys.8.4. Typowy przebieg czasowy składowych siły na ostrzu noża stożkowego, charakterystyczny dla skrawania wapienia na strugarce SP-800, nożem stożkowym o parametrach: a) $\beta = 85^\circ$, $\delta = 45^\circ$, $\rho = 20^\circ$, $t = 55$ mm, $g = 18$ mm, b) $\beta = 85^\circ$, $\delta = 45^\circ$, $\rho = -10^\circ$, $t = 55$ mm, $g = 12$ mm

Jak wynika z rysunku 8.4, obciążenie noża stożkowego zmienia się zależnie od geometrii ostrza, jak i parametrów technologicznych urabiania. Jak stwierdzono w badaniach zasadniczych, dla noży stożkowych charakterystyczne jest to, że składowa normalna rośnie gwałtownie, gdy nóż ulega skręceniu wierzchołkiem ostrza w stronę powierzchni obrobionej (ujemne wartości kąta bocznego wychylenia), przewyższając znacznie wartości siły skrawania. W podobny sposób zmienia się składowa boczna.

Po wyznaczeniu wartości średnich z kolejnych pomiarów, dokonano odpowiedniego zestawienia uzyskanych wyników badań laboratoryjnych (nie zamieszczone w niniejszym opracowaniu, z uwagi na swą obszerność).

8.2. Stanowisko o łukowej trajektorii skrawania


W tej serii badań, wykorzystano stanowisko będące na wyposażeniu Katedry Maszyn Górniczych, Przeróbczych i Transportowych Wydziału Inżynierii Mechanicznej i Robotyki AGH.

Pomiary zostały dokonane w oparciu o technikę tensometryczną. Wielkościami mierzonymi były trzy składowe siły na nożu oraz wartości ciśnienia zasilania i spływu. Wartości ciśnienia zostały wykorzystane przy wyznaczaniu jednostkowej energii urabiania. Do wzmacniania sygnałów został użyty tensometryczny wzmacniacz pomiarowy. Jako urządzenie rejestrujące zastosowany został komputer przenośny z oprogramowaniem ESAM 3000. Program ten poprzez kartę pomiarową umożliwia zapisanie i wstępne opracowanie rejestrowanych wartości badanych wielkości.

W skład stanowiska badawczego wchodziły cztery dające się wyróżnić zespoły:


- przyrząd badawczy,
- głowica pomiarowa,
- agregat zasilający,
- zestaw aparatury pomiarowej.

Ogólny widok stanowiska przedstawiono na rysunkach 8.5, 8.6. Jest to urządzenie, które symuluje pracę noża skrawającego na organie urabiającym. Zapewnia ono przemieszczenie się narzędzia umieszczonego w uchwycie po łuku i zagłębienie się w caliznę 8 na głębokość g .



Rys.8.5. Stanowisko badawcze o łukowej trajektorii skrawania
- widok od strony bocznej

Przyrząd składa się z ramy nośnej, której boczne listwy w kształcie ceowników, stanowią prowadnice 1. W prowadnicach przemieszcza się płyta wzdłuż prowadników ślizgowych 2. Na płycie umiejscowiony jest mechanizm napędu przyrządu, który stanowi hydrauliczny silnik wahadłowy 7, którego tłoczysko w postaci zębátky przenosi napęd na koło zębate znajdujące się pod pokrywą 6, zamocowane na wale napędzającym bęben 3. Obrót bębna powoduje ruch ramienia 4, z podstawą 5 stanowiącą suport narzędziowy. Na podstawie mocowana jest głowica pomiarowa wraz z narzędziem. Konstrukcja przyrządu zapewnia ustawienie żądanej głębokości g i podziałki skrawania t . Służą temu mechanizmy śrubowe 9 i 10.




Rys.8.6. Stanowisko badawcze o łukowej trajektorii skrawania
- widok od czoła

Schemat głowicy pomiarowej przedstawiono na rysunku 8.6, a jej widok ogólny na rysunku 8.7. Złożona jest ona z trzech funkcjonalnych zespołów: chwytowego, pomiarowego oraz mocującego.


Zespół chwytowy stanowi wymienny uchwyt do mocowania noży promieniowych i obrotowych. Uchwyty osadzone są w przygotowanym gnieździe głowicy.

Zespół pomiarowy stanowi wałek, na którym naklejono tensometry czynne w połączeniu półmostkowym dla sił F_c i F_b oraz w połączeniu mostkowym dla siły F_n .

Zespołem mocującym jest podstawa łącząca w sposób mechaniczny głowicę z podstawą przyrządu.



Rys.8.7. Schemat głowicy pomiarowej: 1 – uchwyt, 2 – wałek pomiarowy, 3 – podstawa, 4 – tensometry




Rys.8.8. Widok ogólny głowicy z narzędziem: 1 – głowica pomiarowa, 2 – podstawa pod głowicę

Widok ogólny agregatu zasilającego przedstawiono na rysunku 8.9. Agregat zasilający stanowi pompa zębata o stałej wydajności $V = 100$ [l/min], dająca maksymalne ciśnienie 10MPa, napędzana silnikiem asynchronicznym. Medium robocze tłoczone jest ze zbiornika poprzez rozdzielacz trójpołożeniowy do komór cylindra silnika wahadłowego. Rozdzielacz trójpołożeniowy przesterowywany jest elektrohydraulicznie. Zasilanie układu i uruchomienie przyrządu realizowane jest zdalnie, za pomocą przycisków umiejscowionych na skrzynce zaciskowej przyrządu. W układzie znajduje się zawór bezpieczeństwa, zabezpieczający przed wzrostem ciśnienia ponad wartość dopuszczalną oraz regulator przepływu.

Aparaturę pomiarową stanowią: wzmacniacz wzmacniający sygnały z układów mostków tensometrycznych i czujników ciśnienia, karta pomiarowa zamieniająca sygnały analogowe na cyfrowe oraz przenośny komputer rejestrujący wyniki badań.

Jako układ połączeń tensometrów wykorzystano mostek Wheatstone'a, który jest najczęściej stosowany w urządzeniach pomiarowych.



Rys.8.9. Widok ogólny agregatu zasilającego

Schemat toru pomiarowego jest przedstawiony na rysunku 8.10. Do pomiaru trzech składowych siły urabiania wykorzystano połączenia półmostkowe i mostkowe tensometrów oporowych typu Pb Kn 10-130 o parametrach:


- oporność $R = 133,1 \text{ } [\Omega]$,
- współczynnik $k = 2,52$,
- baza pomiarowa – 10 [mm] ,
- szerokość całkowita – 4 [mm] .

Do pomiarów odkształceń pochodzących od sił zginających F_c oraz F_b zastosowano mostki reagujące na składowe zginające, natomiast do pomiaru odkształceń pochodzących od siły docisku F_n zastosowano mostek reagujący na składową osiową.

Przy łączeniu tensometrów dla poszczególnych sił (zginającej i osiowej) kierowano się zasadą, że dla tensometrów umieszczonych w sąsiednich gałęziach mostka, jednakowe znaki odkształceń powoduje zmniejszenie sygnału wyjściowego mostka, w przypadku tensometrów włączonych do przeciwległych gałęzi mostka uzyska się efekt odwrotny.

W związku z tym dla sił zginających i układów półmostkowych w dwóch sąsiednich gałęziach połączono tensometry czynne, które jednocześnie kompensują wpływ temperatury. Natomiast dla siły osiowej i pełnego mostka w dwóch przeciwległych gałęziach połączono tensometry czynne, w pozostałych dwóch tensometry kompensacyjne, które nie ulegają odkształceniom. Układ zapewnia także kompensację tempe-

ratury. Mostki tensometryczne połączone kablami ekranowymi ze wzmacniaczem, który z kolei połączono z kartą pomiarową. Urządzeniem rejestrującym był przenośny komputer, połączony z kartą pomiarową.



Rys.8.10. Schemat układu pomiarowego stanowiska o łukowej trajektorii skrawania

8.2.1. Przebieg badań


Badania oporów skrawania przeprowadzono na stanowisku pomiarowym w kopalni doświadczalnej AGH. Pomiarów dokonano na bloku betonowym. Parametry skały poddanej skrawaniu to: gęstość $\zeta \approx 2 \text{ Mg/m}^3$ i wytrzymałość na ściskanie $R_c \approx 12 \text{ MPa}$.

Przed przystąpieniem do badań właściwych sprawdzono stan techniczny stanowiska, sprawność układu zasilającego. Głowicę pomiarową oraz przetworniki ciśnienia połączono poprzez wzmacniacz i kartę pomiarową z komputerem.

Do badań został użyty stożkowy nóż obrotowy (rys. 8.11), zamocowany w specjalnie zaprojektowanym uchwycie. Uchwyt oprócz funkcji mocującej spełnia także funkcję pomiarową.

Parametry geometryczne ostrza przyjęto:

- kąt ostrza $\beta = 93^\circ$,



Rys.8.11. Nóż stożkowo obrotowy użyty do badań na stanowisku o łukowej trajektorii skrawania

- kąt ustawienia $\delta = 45^{\circ}, 49^{\circ}$,
- kąt obrotu $\rho = 0^{\circ}, 10^{\circ}, 20^{\circ}$,

Parametry technologiczne pracy ostrza przyjęto:

- głębokość skrawania $g = 3\text{ mm}, 6\text{ mm}, 9\text{ mm}$,
- podziałka skrawania $t = 5\text{ mm}, 10\text{ mm}, 15\text{ mm}$.

Następnie wykonano skrawy, które posłużyły do określenia niezbędnej liczby pomiarów. Wobec faktu, że siła skrawania jest alternatywna w stosunku do ciśnienia zasilającego, postanowiono do oszacowania liczby tych pomiarów wykorzystać wartości ciśnienia. Liczba niezbędnych pomiarów można wyznaczyć według wzoru:

$$n = \frac{t^2 \cdot s^2}{d^2}$$

(8.1)

gdzie:

- t – wartość zmiennej t –Studenta,
- s – estymator wariancji,
- d – założony dopuszczalny błąd.

W wyniku wstępnych pomiarów uzyskano wartości ciśnień, które podano w tabeli 8.1.

Zestawienie wartości ciśnienia urabiania podczas pomiarów weryfikujących

Tabela 8.1

Lp.	Bez obrotu		Obrót względny y t _s = 25 mm		Obrót względny y t _s = 46 mm		Obrót względny x t _s = 25 mm		Obrót względny x t _s = 50 mm	
	p _i	S ²	p _i	s ²	p _i	s ²	p _i	s ²	p _i	s ²
1	22,2	2,01	21,3	2,83	17,4	2,15	29,1	2,52	26	1,59
2	20,4		26,9		18,3		24,2		26,3	
3	24,4		23,3		14,2		27,7		23,4	

p_i – ciśnienie [daN/cm²],
s² – odchylenie standardowe.

Z tablic odczytano parametr $t = 4,303$ i przyjęto dopuszczalny błąd $d = 4$ [daN/cm²]. Wobec tego otrzymano dla poszczególnych ustawień noża następujące liczby pomiarów:

$$n_1 = \frac{4,303^2 \cdot 2,01}{4^2} = 2,32$$

$$n_2 = \frac{4,303^2 \cdot 2,83}{4^2} = 3,28$$

$$n_3 = \frac{4,303^2 \cdot 2,15}{4^2} = 2,49$$

$$n_4 = \frac{4,303^2 \cdot 2,52}{4^2} = 2,92$$

$$n_5 = \frac{4,303^2 \cdot 1,59}{4^2} = 1,85$$

Na podstawie pomiarów wstępnych przyjęto $n = 3$ jako niezbędną liczbę powtórzeń pomiarów. Z uwagi na moc urządzenia zasilającego i moment na wale napędowym można było wykonać skraw o maksymalnej głębokości $g = 9$ mm. Wobec tego postanowiono, że głębokość skrawania zmieniać się będzie od $g = 3$ do $g = 9$ mm. Podziałka skrawania będzie zmieniana od $t = 5$ do $t = 15$ mm.

Zestawienie parametrów skrawania w pomiarach weryfikujących

Tabela 8.2


g [mm]	t [mm]
3	5
6	10
9	15

W trakcie pomiarów zmieniano wartości parametrów eksploatacyjnych (t – podziałki skrawania, g – głębokości skrawania), a także kątów: obrotu ρ – będącego rzutem osi noża na płaszczyznę xy , oraz ustawienia δ mierzonego pomiędzy osią noża a osią y przyjętego układu odniesienia. W trakcie badań wyznaczano także masę urobku dla poszczególnych skrawów, która jest pomocna dla określenia energii urabiania.

Dla porównania, badania zostały przeprowadzone dla noża bez obrotu, następnie z obrotem uchwytu wraz z nożem względem osi z (rys. 8.12). Stąd też nóż był wychylony o kąt $\delta_{xy} = 22,5^\circ$ ($t_s = 25$ mm) i ustawiony pod kątem $\delta_{xy} = 45^\circ$ ($t_s = 46$ mm), oraz odpowiednio z wychYLENIEM o kąt $\delta_{zx} = 10^\circ$ ($t_s = 25$ mm) i kątem ustawienia $\delta_{zx} = 20^\circ$ ($t_s = 50$ mm).

Rozpoczynając pomiary ustawiono przyrząd w skrajnym położeniu, ustawiając żadaną głębokość skrawania ($g = 3$ mm). W ten sposób przeprowadzono skraw otwierający.

Po wykonaniu skrawu otwierającego, nóż przesunięto o ustaloną wartość podziałki skrawania ($t = 5$ mm) i wykonano oraz zarejestrowano skraw, zwany skrawem półotwartym. Powtórzono tę czynność trzykrotnie. Po wykonaniu tychże skrawów zebrano urobek, który następnie był ważony i przesiewany w celu określenia przekroju ziarna. Następnie nie zmieniając głębokości skrawania zwiększono podziałkę skrawania do wartości $t = 10$ mm, a później $t = 15$ mm i powtórzono powyższe czynności.



↑ Rys.8.12. Obrót noża względem osi z : t_s – podziałka wynikająca z obrotu noża o kąt δ_{xy}


➔ Rys.8.13. Obrót noża względem osi z : t_s – podziałka wynikająca z obrotu noża o kąt δ_{xy}

Po zrealizowaniu wszystkich założonych podziałek skrawania, zwiększono głębokość skrawania do $g = 6$ mm i wykonano pomiary dla tychże podziałek. W takiej samej kolejności wykonano pomiary dla głębokości skrawania $g = 9$ mm.

Wyjściowe ustawienie (bez obrotu) posłużyło jako porównawczy wskaźnik dla kolejnych badań. Rozpoczęto je obracając głowicę o kąt $\delta_{zx} = 22,5^\circ$ ($t_s = 25$ mm) względem osi z (na podstawie) i mocując ją śrubami w takiej pozycji (rys. 8.12). Pomiary wykonano dla wyżej przyjętych głębokości i podziałek skrawania. Następnie powtórzono serię badań przy obrocie głowicy o kąt $\delta_{xy} = 45^\circ$ ($t_s = 46$ mm).

Aby obrócić głowicę względem osi z należało posłużyć się specjalnymi podkładkami, które były mocowane pomiędzy głowicą a podstawą. Podkładki były wykonane w taki sposób by ich kąt wynosił odpowiednio $\delta_{zx} = 10^\circ$ ($t_s = 25$ mm) i $\delta_{zy} = 20^\circ$ ($t_s = 50$ mm). Na podstawie zarejestrowanych wyników badań dla wszystkich ustawień przeprowadzono analizę wyników.

Sygnały z głowicy i czujników ciśnienia poprzez wzmacniacz i kartę pomiarową zostały rejestrowane na komputerze. W wyniku przeprowadzonych pomiarów zarejestrowano, do każdego skrawu, wartości trzech sił składowych oraz ciśnienia spływu i zasilania. Różnica między ciśnieniem zasilania i spływu umożliwiała dokładniejsze określenie ciśnienia całkowitego.



Rys.8.14. Typowy przebieg czasowy składowych siły na ostrzu noża stożkowego, podczas skrawania skały piaskowo-cementowej, na stanowisku o łukowej trajektorii skrawania

Jak wynika z rysunku 8.14, cechą charakterystyczną tej serii badań, była stosunkowo wysoka wartość składowej bocznej, co można tłumaczyć stosunkowo małymi podziałkami skrawania. Narzędzie stożkowe jest wtedy silnie odpychane od obrabianej powierzchni. W trakcie badań określano masę zeskrwanego materiału celem wyznaczenia właściwej energii skrawania e_c na podstawie zależności:

$$e_c = \frac{\bar{F}_c \cdot l \rho}{m} \quad (8.2)$$

gdzie:

e_c - energia jednostkowa urabiania; [MJ/m^3],

$\bar{F}_c$ - średnia wartość siły skrawania; [kN],

l - długość skrawu pomiarowego; [m],

m - masa zeskrwanego materiału danej próby; [g],

ρ - gęstość właściwa skały; [Mg/m^3].


9. Analiza numeryczna wyników badań stanowiskowych z wykorzystaniem sieci neuronowej

Zagadnienia aproksymacji są jedną z wielu dziedzin, w których z powodzeniem są stosowane sieci neuronowe, w tym przypadku tzw. sieci statyczne. Trzeba jednak mieć na uwadze, że w przypadku wykorzystania sieci neuronowych do zagadnień aproksymacji, funkcja aproksymująca wyniki badań nie jest prezentowana w sposób jawny (co wynika z teorii tych sieci). Sieć pełni rolę tzw. „czarnej skrzynki”, do której na wejściu podawane są wartości wielkości wejściowych, na wyjściu (wyniku złożonych procedur) uzyskiwane są wartości interesujących nas wielkości wyjściowych, które można oglądać na odpowiednich wykresach. Nie jest ujawniona zatem tutaj postać modelu procesu.

9.1. Struktura sieci wykorzystanej do neuronowej aproksymacji wyników badań zasadniczych

W oparciu o doświadczenia zdobyte w czasie wstępnych badań numerycznych (rozdział 6), uzupełniając wykorzystane tam dane, o właściwości parametrów wytrzymałościowych piaskowca, tj.: gęstość $\zeta \approx 2,85 \text{ Mg/m}^3$, wytrzymałość na ściskanie $R_c \approx 37,5 \text{ MPa}$ i wartość proporcji $R_o/R_r \approx 15$, oraz biorąc pod uwagę wyniki badań uzupełniających, dotyczących urabiania wapienia, wykorzystując „Automatycznego Projektanta Sieci” pakietu Statistica Neural Network PL, uzyskano strukturę sieci neuronowej (rys. 9.1) adekwatną do zaproponowanego modelu procesu urabiania przedstawionego na rysunku 7.2. Sieć ta ma strukturę trójwarstwową. W warstwie pierwszej znajduje się dziewięć neuronów odpowiadających wielkościom wejściowym przyjętego na rysunku 7.2, modelu urabiania. W warstwie ukrytej znajduje się pięć neuronów. W warstwie wyjściowej znajduje się tylko jeden neuron reprezentujący jedną z badanych wielkości wyjściowych przyjętego modelu urabiania skał. Strukturę tej sieci otrzymano w wyniku wielokrotnych eksperymentów, między innymi ze zwiększaniem liczby wejść sieci, gdyż wtedy osiągnięto najlepsze wyniki identyfikacji.

Warstwę ukrytą stanowi pięć neuronów ukrytych reprezentujących tak zwane dane wtórne, tzn. wytwarzane przez warstwę wejściową sieci, stanowiące pośrednią formę kodowania danych wejściowych, wykorzystywaną wewnątrz sieci jako informacja poprzedzająca końcowy wynik uzyskiwany na wyjściu sieci. Warstwę wyjściową stanowi tylko jeden neuron wyjściowy, który prezentuje wynik symulacji obciążony pewnym błędem odwzorowania wartości: F_c , F_n , F_b , lub e_c .




Rys.9.1. Struktura sieci neuro-
nowej uzyskana w wyniku ba-
dań numerycznych, prowadzo-
nych dla danych dotyczących
piaskowca i wapienia

Podczas testowania sieci dokonywano doboru optymalnej struktury (ze względu na: wielkość błędu, czas trwania procesu uczenia oraz liczbę epok po której nastąpiła stabilizacja pracy sieci). W procesie uczenia użyto trzech metod uczenia, tj: klasycznej - wstecznej propagacji błędów oraz dwóch uproszczonych: metody gradientów sprzężonych i metody Levenberga-Marquardta. Dwie pierwsze metody odrzucono, ponieważ w przypadku wstecznej propagacji błędów, proces uczenia trwał najdłużej spośród pozostałych metod, mimo stabilnego przebiegu procesu uczenia. Natomiast w przypadku gradientów sprzężonych, mimo szybkiego przebiegu procesu uczenia, cały proces zatrzymywał się w minimum lokalnym. Metoda Levenberga-Marquardta zapewniła oba warunki optymalnej pracy sieci, tj. szybkie i niezawodne uczenie. Mając na uwadze wielkość błędu oraz epokę ustabilizowania się błędu uczenia sieci, wszystkie metody prezentują porównywalne wartości, nie przekraczające 10% odchylenia względem siebie.

Założono, że sieć jest nauczona, kiedy osiągnie odpowiednio niski błąd uczenia, tzn., że nie tylko zakładany błąd powinien być niższy od 10%, bo za to jest odpowiedzialna głównie struktura sieci, ale wykres błędu w następujących po sobie epokach uczenia powinien być względnie ustabilizowany bez tendencji do wychyleń. Wartość błędu uczenia jest prezentowana na wykresie błędu uczenia, który przedstawia błąd RMS (pierwiastek błędu średniokwadratowego) sieci w kolejnych


epokach uczenia, przeprowadzanego przy zastosowaniu metod iteracyjnych. Uzyskane w procesie uczenia, wartości odchyłeń od wartości rzeczywistych, w momencie nauczania się sieci wyniosły odpowiednio:

- dla siły skrawania F_c
 $RMS_u = 5,9\%$ dla zbioru uczącego oraz $RMS_w = 5,4\%$ dla zbioru walidacyjnego, w około 100 epoce uczenia (rys. 9.2),
- dla składowej F_n
 $RMS_u = 6,8\%$ dla zbioru uczącego oraz $RMS_w = 6,6\%$ dla zbioru walidacyjnego, w około 100 epoce uczenia (rys. 9.3),
- dla składowej F_b
 $RMS_u = 8,8\%$ dla zbioru uczącego oraz $RMS_w = 7,7\%$ dla zbioru walidacyjnego, w około 120 epoce uczenia (rys. 9.4),
- dla właściwej energii skrawania e_c
 $RMS_u = 4,2\%$ dla zbioru uczącego oraz $RMS_w = 3,4\%$ dla zbioru walidacyjnego, w około 260 epoce uczenia (rys. 9.5).




Rys.9.2. Wykres błędów uczenia metodą Levenberga- Marquardta, dla siły skrawania F_c , sieci perceptronowej trójwarstwowej z jedną 5-neuronową warstwą ukrytą


W procesie poszukiwania najlepszej sieci neuronowej, osiągnięto błąd odtworzenia rzędu 3÷9% (zależnie od badanej wielkości wyjściowej), w zależności od zastosowanej metody uczenia oraz struktury sieci.



Rys.9.3. Wykres błędu uczenia metodą Levenberga-Marquardta, dla składowej normalnej F_n sieci perceptronowej trójwarstwowej, z jedną 5-neuronową warstwą ukrytą



Rys.9.4. Wykres błędu uczenia metodą Levenberga-Marquardta, dla składowej bocznej F_b sieci perceptronowej trójwarstwowej z jedną 5-neuronową warstwą ukrytą



Rys.9.5. Wykres błędu uczenia metodą Levenberga-Marquardta dla właściwej energii skrawania e_c , sieci perceptronowej trójwarstwowej z jedną 5-neuronową warstwą ukrytą

W przypadku przewidywanych wielkości wyjściowych: F_c , F_n , F_b , e_c (tabela 9.1) można mówić o sukcesie zadania regresyjnego, gdyż odchylenie przewidywanych wartości jest nie większe jak w przypadku zastosowania modelu matematycznego opracowanego na podstawie analizy statystycznej [26], w której przewidywane wartości były zbliżone do wartości rzeczywistych na poziomie około 90%. Dla przewidywanych wartości F_c , F_n , oraz e_c współczynnik korelacji mieści się w zakresie 0,959÷0,985. Dla składowej F_b współczynnik korelacji był znacznie niższy i wyniósł dla zbioru uczącego 0,85; natomiast dla zbioru walidacyjnego i testowego około 0,65.

Statystyki regresyjne wartości F_c , F_n , F_b , e_c , dla badań zasadniczych

Tabela 9.1

	F_c			F_n		
	zbiór uczący	zbiór walidacyjny	zbiór testujący	zbiór uczący	zbiór walidacyjny	zbiór testujący
Średnia	6,66879	6,15584	6,61192	8,37044	7,69878	8,1282
Odchylenie standardowe	4,23369	4,26122	4,39835	5,95466	6,08047	5,97785
Średni błąd	-0,0002	-0,0947	-0,0362	1,09E-05	-0,1813	0,01601
Odchylenie standardowe błędów	1,16837	1,07276	1,22261	1,61609	1,5633	1,69267
Średni błąd bezwzględny	0,76093	0,68973	0,81332	1,03104	0,97248	1,02252
Iloraz odchyleń standardowych	0,27597	0,25175	0,27797	0,2714	0,2571	0,28316
Korelacja	0,96117	0,96806	0,96065	0,96247	0,96676	0,9592

	F_b			e_c		
	zbiór uczący	zbiór walidacyjny	zbiór testujący	zbiór uczący	zbiór walidacyjny	zbiór testujący
Średnia	1,486329	1,16683	1,46988	15,0915	13,0564	14,0227
Odchylenie standardowe	1,910513	1,4976	1,92321	15,8648	14,6253	15,2992
Średni błąd	-0,00001038	0,15233	0,03267	-0,0001	-0,0852	-0,1394
Odchylenie standardowe błędów	0,9922203	1,2574	1,54077	3,10907	2,48152	2,81745
Średni błąd bezwzględny	0,6395467	0,68132	0,8216	1,75073	1,43059	1,67546
Iloraz odchyłeń standardowych	0,5193476	0,83961	0,80114	0,19597	0,16967	0,18416
Korelacja	0,8545631	0,64326	0,65479	0,98061	0,98552	0,98308

Prawidłowość modelu najprościej oszacować przez wyznaczenie wartości średniej z wartości wyjściowych zawartych w zbiorze uczącym, i wykorzystanie jej jako wartości predykcji dla wszystkich nie prezentowanych wcześniej przypadków. Zaprzecza to idei modelu (sygnały wejściowe, podawane do sieci, nie mają tu żadnej roli), ale przy braku innych przesłanek szacowanie nieznanej odpowiedzi systemu, że będzie ona przeciętna (to znaczy właśnie równa wartości średniej) jest uzasadnione [46, 47, 85, 88, 90].

Oczekiwany średni błąd odwzorowania przy zastosowaniu statystyk regresyjnych, jest równy odchyleniu standardowemu obliczonemu dla wartości wyjściowej w zbiorze uczącym, walidacyjnym i testowym (tabela 9.1), który wyniósł odpowiednio:

- dla siły skrawania $F_c = 4,23 \div 4,40$;
- dla składowej normalnej $F_n = 5,95 \div 6,08$;
- dla składowej bocznej $F_b = 1,50 \div 1,92$;
- dla właściwej energii skrawania $e_c = 14,62 \div 15,86$.

Dlatego też celem tworzenia modelu identyfikacji procesu skrawania z zastosowaniem sieci regresyjnej, jest wyznaczenie takiego szacunku, który posiada znacząco niższe odchylenie standardowe, wyznaczone na podstawie rzeczywistych wartości błędów popełnianych przez sieć a znacznie niższe niż odchylenie standardowe sygnału wyjściowego wyznaczone dla danych uczących, walidacyjnych i testowych. Na tym stwierdzeniu opiera się właśnie metoda oceny jakości modelu regresyjnego zastosowana z użyciem sieci neuronowej. Średnie odchylenie standardowe rozumiane jest jako moduł różnicy pomiędzy zadaną wartością wyjściową i wartością uzyskaną na wyjściu [46, 47, 85, 88, 90].

Średnie wartości wyznaczone za pomocą statystyk regresyjnych i popołnione przez sieć dla zbiorów: uczącego, walidacyjnego i testowego wyniosły odpowiednio:

- dla siły skrawania F_c
-0,0002 dla zbioru uczącego; -0,0947 dla zbioru walidacyjnego;
-0,0362 dla zbioru testującego,
- dla składowej normalnej F_n
0,00001 dla zbioru uczącego; 0,1813 dla zbioru walidacyjnego;
0,1601 dla zbioru testującego,
- dla składowej bocznej F_b
-0,00001 dla zbioru uczącego; 0,1523 dla zbioru walidacyjnego;
0,0326 dla zbioru testującego,
- dla właściwej energii skrawania e_c
0,0001 dla zbioru uczącego; 0,0852 dla zbioru walidacyjnego;
0,1374 dla zbioru testującego,

W procesie uczenia jest również uwzględniane (obliczane) średnie odchylenie standardowe bezwzględne, które jest różnicą pomiędzy wartością zadaną i wartością uzyskaną na wyjściu. Wartości średniego odchylenia standardowego bezwzględnego wyniosły odpowiednio:

- dla siły skrawania F_c
0,76093 dla zbioru uczącego; 0,68973 dla zbioru walidacyjnego;
0,81332 dla zbioru testującego,
- dla składowej normalnej F_n
1,03104 dla zbioru uczącego; 0,97248 dla zbioru walidacyjnego;
1,02252 dla zbioru testującego,
- dla składowej bocznej F_b
0,6395467 dla zbioru uczącego; 0,68132 dla zbioru walidacyjnego;
0,8216 dla zbioru testującego,
- dla właściwej energii skrawania e_c
1,75073 dla zbioru uczącego; 1,43059 dla zbioru walidacyjnego,
1,67546 dla zbioru testującego,

Za pomocą statystyk regresyjnych został obliczony iloraz odchyżeń standardowych dla błędów i dla danych. Iloraz ten wskazuje, czy próba budowy modelu regresyjnego się udała. Wartość większa lub równa 1.0 oznacza, że model realizowany przez sieć nie daje lepszych rezultatów niż "model" podający na wyjściu zawsze ten sam przewidywany sygnał, będący po prostu średnią obserwowanych wcześniej wartości wyjściowych. Wartości mniejsze od wspomnianego ilorazu świadczą o lepszym oszacowaniu wyjścia systemu uzyskiwanym za pomocą sieci [46, 47, 85, 88, 90].


W przypadku siły skrawania F_c oraz składowej normalnej F_n iloraz odchyłeń standardowych wyniósł nie więcej niż 0,28. Dla właściwej energii skrawania nie przekroczył wartości 0,20; niezależnie od rodzaju zbioru danych. Natomiast dla składowej bocznej osiągnął nawet wartość równą 0,84.

W ramach statystyk regresyjnych (tab. 9.1) wyświetlany jest również standardowy współczynnik korelacji R-Pearsona pomiędzy obliczonymi i rzeczywistymi wartościami wyjściowymi. Idealna prognoza charakteryzowałaby się współczynnikiem korelacji 1,0; co niekoniecznie oznacza idealną prognozę a jedynie dokładnie liniowo skorelowaną z aktualnymi wartościami wyjściowymi, jakkolwiek w praktyce współczynnik korelacji jest dobrym wskaźnikiem jakości sieci. Dla przewidywanych wartości F_c , F_n , oraz e_c współczynnik korelacji mieści się w zakresie 0,959÷0,985. Dla składowej F_b współczynnik korelacji był znacznie niższy i wyniósł 0,85 dla zbioru uczącego, natomiast dla zbioru walidacyjnego i testowego około 0,65.


Wszystkie dane pomiarowe biorące udział w procesie uczenia z użyciem sztucznych sieci neuronowych mają większy lub mniejszy wpływ na jakość modelu sieciowego. Czyli decydują one między innymi w której epoce nastąpi stabilizacja błędu uczenia oraz oczekiwany maksymalny poziom błędu uczenia. Niektóre dane wejściowe i wyjściowe (często większość dostarczonych danych) są odrzucane przez sieć jako wartości błędne i nieprzydatne dla niej, podczas procesu uczenia, z powodu niemożliwości dostosowania się do kreowanego modelu sieci. Pakiet Statistica Neural Networks PL umożliwia graficzną prezentację błędów poszczególnych przypadków w postaci wykresu słupkowego. Błędy wyznaczane są automatycznie po zakończeniu uczenia i po uruchomieniu sieci dla całego zbioru danych. Błędy jednostkowe wyświetlane są dla przypadków wchodzących w skład zbioru uczącego, walidacyjnego i testowego, bo tylko dla tych przypadków mogą one być wyznaczone.

Wykres błędów jednostkowych (rys. 9.6÷9.9) dostarcza istotnych informacji dotyczących sposobu uczenia sieci, a jego sporządzenie i analiza może być na przykład wykorzystana do obserwacji niestabilnych zachowań sieci (np. pojawiających się w procesie uczenia gwałtownych oscylacji w wartościach błędów dla poszczególnych przypadków), które mogą wskazywać na zachodzącą potrzebę modyfikacji parametrów algorytmu uczenia. Wykres błędów jednostkowych pozwala na zlokalizo-



wanie przypadków bądź grup przypadków, które są szczególnie trudne do przetworzenia przez sieć, które można odrzucić ze zbioru danych dla osiągnięcia bardziej równomiernego procesu uczenia i lepszego wyniku końcowego. Dzięki słupkowemu wykresowi błędów możemy na przykład określić procentowy udział danych pomiarowych, których błąd uczenia jest większy od średniego błędu uczenia zbiorów uczącego, walidacyjnego i testowego [46, 47, 85, 88, 90].



Rys.9.6. Wykres jednostkowych błędów odtworzenia siły F_c .



Rys.9.7. Wykres jednostkowych błędów odtworzenia siły F_n .

Rys.9.8. Wykres jednostkowych błędów odtworzenia F_b Rys.9.9. Wykres jednostkowych błędów odtworzenia e_c

Średni błąd uczenia zbiorów: uczącego walidacyjnego i testowego jest ilorazem średniego odchylenia standardowego bezwzględnego oraz wartości średniej [46, 47, 85, 88, 90]. Obliczony średni błąd RMS dla analizowanych zbiorów wyniósł odpowiednio:

- dla siły skrawania F_c
 $\text{Śr.RMS}_u=11,41032\%$ dla zbioru uczącego, $\text{Śr.RMS}_w=11,20448\%$ dla zbioru walidacyjnego, $\text{Śr.RMS}_t=12,30081\%$ dla zbioru testującego,
- dla składowej normalnej F_n
 $\text{Śr.RMS}_u=12,31763\%$ dla zbioru uczącego, $\text{Śr.RMS}_w=12,63161\%$ dla zbioru walidacyjnego, $\text{Śr.RMS}_t=12,57991\%$ dla zbioru testującego,
- dla składowej bocznej F_b
 $\text{Śr.RMS}_u=43,02861\%$ dla zbioru uczącego, $\text{Śr.RMS}_w=58,39068\%$ dla zbioru walidacyjnego, $\text{Śr.RMS}_t=55,89572\%$ dla zbioru testującego,
- dla właściwej energii skrawania e_c
 $\text{Śr.RMS}_u=11,60077\%$ dla zbioru uczącego, $\text{Śr.RMS}_w=10,957\%$ dla zbioru walidacyjnego, $\text{Śr.RMS}_t=11,9482\%$ dla zbioru testującego.

Na podstawie wykresu błędów jednostkowych, przyrównując pojedyncze wartości błędów do średniego błędu uczenia RMS zauważamy, że udział procentowy przewidywanych wartości wyjściowych z błędem niższym niż błąd średni wyniósł odpowiednio:

- dla siły skrawania F_c
 $93,14\%$ dla zbioru uczącego, $92,74\%$ dla zbioru walidacyjnego, $94,34\%$ dla zbioru testującego,
- dla składowej normalnej F_n
 $93,67\%$ dla zbioru uczącego i walidacyjnego, $93,94\%$ dla zbioru testującego,
- dla składowej bocznej F_b
 $99,40\%$ dla zbioru uczącego, $99,66\%$ dla zbioru walidacyjnego i testującego,
- dla właściwej energii skrawania e_c
 $99,00\%$ dla zbioru uczącego, walidacyjnego, testującego,

Przyjęty próg odrzucenia nie musi decydować o eliminacji przewidywanych wartości wyjściowych, jednak obrazuje nam pewną relację. W przeprowadzonej analizie można by również przyjąć maksymalną akceptowaną przez nas wartość błędu RMS, który stanowiłby próg odrzucenia, jednak celem analizy z użyciem wykresu błędów jednostkowych było praktyczne przedstawienie jednej z możliwości wykorzystania tego narzędzia. W powyższych rozważaniach nie uwzględniono podziału odrzucanych wartości na zbiory uczący walidacyjny i testowy; podział taki prawdopodobnie obniżyłby próg odrzucenia wartości ze zbyt wysokim błędem.

Informacji o danych wejściowych i ich przydatności oraz wpływie na proces uczenia jak i sprawność działania sieci dostarcza nam analiza

wrażliwości. Analiza wrażliwości (tabela 9.2) wejść sieci neuronowej pozwala odróżniać ważne zmienne od takich, które niewiele wnoszą do wyniku działania sieci [46, 47, 85, 88, 90]. Analiza taka nie daje jednak bezwzględnej oceny użyteczności zmiennych. W stosowaniu jej należy być ostrożnym, jednak należy mieć na uwadze jej dużą przydatność w szacowaniu wpływu poszczególnych wejść na ostateczny wynik uczenia.

Zmienne wejściowe, zazwyczaj nie są niezależne. Analiza wrażliwości szacuje stratę jaką ponosimy odrzucając konkretną zmienną. Jednak biorąc pod uwagę, że istnieją zależności pomiędzy zmiennymi wejściowymi, wskaźnik ten może nie znaleźć potwierdzenia w rzeczywistej sytuacji. Może również mieć miejsce sytuacja, że będą występować zależne od siebie zmienne użyteczne tylko razem. Wszystkie te zmienne, dadzą dużą wrażliwość. Jednak po usunięciu którejś, wrażliwość pozostałych zmiennych, będzie zerowa. Im wyższa wartość rangi danej wejściowej, tym dana ta jest mniej potrzebna do utrzymania żądanej sprawności sieci. Pod wartością rangi, w wierszu błąd, szacowana jest wielkość błędu nauczania sieci przy braku danej zmiennej. Jak można zauważyć, wpływ danego rodzaju wielkości wejściowej jest podobny w zbiorze uczącym i walidacyjnym tak jak i sama ranga. Świadczyć to może o tym, że przebieg uczenia sieci przebiega w sposób zbliżony, co z kolei sugeruje prawidłowość generowanego modelu identyfikacji procesu skrawania skał z użyciem stożkowych noży obrotowych.

Analiza wrażliwości zmiennych wejściowych (badania zasadnicze)

Tabela 9.2

		m [g]	t [mm]	g [mm]	β [°]	δ [°]	ρ [°]	Rc	Rc/Rr	ζ [g/cm ³]
F_c										
Zbiór uczący	Ranga	6	7	9	5	8	4	1	3	2
	Błąd	1,54614	1,40733	1,32409	1,73074	1,33803	1,81208	5,60046	3,64357	5,0814
Zbiór walidacyjny	Ranga	6	8	9	4	7	5	1	3	2
	Błąd	1,43476	1,28097	1,24667	1,66691	1,36634	1,43948	5,99348	3,71298	5,39701
F_n										
Zbiór uczący	Ranga	8	6	9	4	7	5	1	2	3
	Błąd	1,87165	2,00266	1,70274	3,23777	1,99165	2,39553	6,3781	4,69205	4,44664
Zbiór walidacyjny	Ranga	8	7	9	4	5	6	1	3	2
	Błąd	1,72431	1,93459	1,71986	3,42771	2,0761	1,94134	6,83341	4,52524	4,77441
F_b										
Zbiór uczący	Ranga	2	1	3	9	7	4	8	6	5
	Błąd	3,44538	3,67154	2,21479	1,01539	1,09212	1,79561	1,04815	1,18637	1,43778
Zbiór walidacyjny	Ranga	1	2	3	8	6	5	9	4	7
	Błąd	2,97447	2,65218	2,184	1,27069	1,37171	1,37614	1,25939	1,43714	1,33874

e _c										
Zbiór uczący	Ranga	1	7	3	4	8	6	2	9	5
	Błąd	14,5014	4,2621	6,97713	5,15987	3,63954	4,68246	10,7948	3,35389	4,84493
Zbiór walidacyjny	Ranga	1	6	3	4	7	8	2	9	5
	Błąd	13,1937	3,47053	6,30471	5,17313	3,46069	3,33351	10,134	2,82176	4,25488

Z przedstawionej analizy wrażliwości (tabela 9.2) wynika, że właściwości skał (R_c , R_c/R_r , ζ) mają duży wpływ na wielkość błędu odwzorowania siły F_c oraz składowej F_n w procesie urabiania. Nadana im odpowiednio ranga ważności 1, 2, 3 świadczy o tym, że w przypadku badania kilku rodzajów skał, konieczne jest dostarczanie informacji o ich właściwościach, aby prawidłowo przewidzieć efekty skrawania.

9.2. Weryfikacja przyjętej struktury sieci

W przypadku wyboru do aproksymacji neuronowej, określonej struktury sieci, przed jej końcową akceptacją, podstawowym zaleceniem jest jej ostateczne testowanie (egzaminowanie) na zbiorze danych pomiarowych, nie biorących udziału w uczeniu i podstawowym testowaniu sieci. Celem tego zabiegu jest określenie możliwości uogólniania wiedzy przez daną sieć, w skrajnych warunkach symulacji. W tym między innymi celu, wykonano ograniczone badania na stanowisku o łukowej trajektorii skrawania (patrz rozdział 8.2), dla nieco odmiennych niż na strugarce, parametrów realizacji procesu urabiania, jednak z zakresu objętego przez sieć o przyjętej strukturze. Zestawienie statystyk regresyjnych dla tego zadania, ilustruje tabela 9.3.

Statystyki regresyjne siły skrawania F_c dla badań weryfikujących

Tabela 9.3

	F _c		
	zbiór uczący	zbiór walidacyjny	zbiór testujący
Średnia	6,641234	6,373929	1,072746
Odchylenie standardowe	4,391181	4,165816	0,523704
Średni błąd	-0,00421	0,05059	-0,142361
Odchylenie standardowe błędu	1,311399	1,293902	0,488852
Średni błąd bezwzględny	0,921921	0,910597	1,123611
Iloraz odchyłeń standardowych	0,298644	0,3106	0,63345
Korelacja	0,954366	0,951	0,793

Jak wynika z tabeli 9.3, uzyskano stosunkowo dobre prognozy wartości współczynnika korelacji rzędu 0,95÷0,79, co czyni model sieci wiarygodnym. Biorąc pod uwagę, że wyniki te uzyskano dla danych do-

tyczących ośrodka skalnego o odmiennych właściwościach, na stanowisku o odmiennej zasadzie działania, oraz w oparciu o ograniczoną bazę danych pomiarowych, można stwierdzić, że próba identyfikacji procesu urabiania skał stożkowymi nożami obrotowymi, z użyciem sztucznych sieci neuronowych, zakończyła się sukcesem.

Wykonana analiza wrażliwości wykazała, że w tym przypadku, najbardziej istotną zmienną wejściową jest kąt ostrza β (ranga 1), której brak zwiększyłby błąd prognozy, do około 32%. W statystyce regresyjnej według tabeli 9.2, najbardziej istotną zmienną jest R_c . W poniższej statystyce (tabela 9.4) jest ona mniej istotna i posiada rangę 8.

Analiza wrażliwości zmiennych wejściowych odwzorowujących F_c dla badań weryfikujących


Tabela 9.4

		m [g]	t [mm]	g [mm]	β [°]	δ [°]	ρ [°]	R_c	R_c/R_r	ζ [g/cm ³]
Zbiór uczący	Ranga	9	6	5	1	7	4	8	2	3
	Błąd	1,452295	1,599237	1,629519	3,21009	1,550692	1,784488	1,546199	1,961489	1,791029
	Iloraz	1,108124	1,220244	1,243349	2,44935	1,183203	1,361593	1,179774	1,496648	1,366584
Zbiór walidacyjny	Ranga	9	5	6	1	8	3	7	2	4
	Błąd	1,431396	1,588436	1,529535	3,241838	1,481474	1,763985	1,506889	1,922864	1,754437
	Iloraz	1,106193	1,227571	1,182051	2,505349	1,144909	1,363238	1,16455	1,486023	1,355859

10. Graficzna ilustracja wyników aproksymacji neuronowej danych pomiarowych urabiania skał stożkowymi nożami obrotowymi

W przypadku sieci neuronowej nie uzyskuje się jawnej postaci funkcji aproksymującej dane pomiarowe, można jednak dokonać prezentacji graficznej zachowania się nauczonego modelu sieci neuronowej, nazywanej powierzchniowym wykresem odpowiedzi. Zmienna wyjściowa sieci może być rozpatrywana jako funkcja n zmiennych wejściowych. W układzie kartezjańskim, powierzchnię odpowiedzi można narysować tylko dla dwóch zmiennych wejściowych, a pozostałe wejścia będą wartościami stałymi. Powierzchnia odpowiedzi nauczonej sieci, z wybraną liczbą wielkości wejściowych, daje wtedy obraz wpływu tych wielkości, na kształtowanie się wartości wyjścia (wielkości wyjściowej).

Badając wpływ podziałki t i głębokości skrawania g , na podstawie powierzchni odpowiedzi sieci można stwierdzić, że siła skrawania F_c gwałtownie rośnie wraz ze wzrostem podziałki, (rys. 10.1a). Obserwując przebieg siły skrawania przy wzrastających wartościach podziałki skrawania t i kąta ostrza β (rys. 10.1b) obserwujemy asymptotyczny wzrost siły F_c . Wzrost siły skrawania następuje do momentu przejścia noży do skrawów otwierających. W przypadku wpływu kąta ustawienia δ (rys. 10.2a), siła narasta również w sposób asymptotyczny.




Rys.10.1. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się siły skrawania F_c zależne od: a) głębokości skrawania g i podziałki t , b) kąta ostrza β i podziałki t


Zupełnie inny charakter ma przebieg siły F_c w zależności od zmian kąta obrotu ρ i podziałki skrawania t (rys. 10.2b). Siła F_c rośnie w przy rosnącej podziałce t w pełnym zakresie oraz przy malejącym kącie obrotu ρ w zakresie 15° – 20° . Dla wartości kąta obrotu 15° – 20° i podziałce 10 – 15 mm zmiany wartości siły F_c są niewielkie.

Z rysunku 10.3 wynika, że siła F_c rośnie prawie liniowo wraz ze wzrostem kąta ostrza β noża skrawającego oraz kąta ustawienia noża δ , Siła skrawania rośnie przy malejącym kącie obrotu ρ (rys. 10.4a) najgwałtowniej w zakresie 0° – 20° .

W przypadku badania wpływu kątów ostrza β i ustawienia δ (rys. 10.4b) na siłę F_c , można stwierdzić, że narasta ona szybciej przy wzroście kąta ostrza i wykazuje niewielki, prawie liniowy wzrost pod wpływem wzrostu kąta ustawienia.




Rys. 10.2. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się siły skrawania F_c zależne od: a) kąta ustawienia δ i podziałki t , b) kąta obrotu ρ i podziałki t




Rys. 10.3. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się siły skrawania F_c zależne od: a) kąta ostrza β i głębokości skrawania g , b) kąta ustawienia δ i głębokości skrawania g .

Siła F_c osiąga wartości minimalne przy małych wartościach kątów ostrza i ustawienia; dla wartości kątów ustawienia $40 \div 46^\circ$ oraz ostrza $75 \div 77^\circ$, wahania siły F_c są niewielkie i z minimalnym przyrostem. Dla wartości kąta ustawienia $49 \div 50^\circ$ i kąta ostrza $80 \div 85^\circ$, siła F_c przyjmuje wartości maksymalne.



Rys.10.4. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się siły skrawania F_c zależne od: a) kąta obrotu ρ i głębokości skrawania g , b) kąta ustawienia δ i kąta ostrza β

Uwzględniając wpływ kąta obrotu ρ i ostrza β na omawianą siłę (rys. 10.5a) obserwuje się niewielki przyrost siły F_c w zakresie kąta obrotu $-20 \div 20^\circ$ i wartości kąta ostrza $75 \div 78^\circ$. Wzrost kąta ostrza powoduje wzrost siły skrawania, przy czym siła skrawania rośnie najszybciej w zakresie kątów ostrza $82 \div 85^\circ$, przy małym kącie obrotu $-18 \div -20^\circ$, gdzie osiąga maksymalne wartości.




Rys.10.5. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się siły skrawania F_c zależne od: a) kąta obrotu ρ i kąta ostrza β , b) kąta obrotu ρ i kąta ustawienia δ

Dla rosnących kątów obrotu i przy wzroście kąta ostrza obserwujemy zmniejszoną dynamikę wzrostu siły F_c .


Zupełnie inny charakter na kształtowanie się siły F_c ma wpływ kąta ustawienia δ i obrotu ρ (rys. 10.5b). Siła F_c rośnie równomiernie wraz ze wzrostem kąta ustawienia δ i zmniejszającym się kącie obrotu ρ . Dla wartości kąta obrotu $\rho = 0 \div 20^\circ$ oraz kąta ustawienia δ około $40 \div 45^\circ$ siła skrawania wykazuje wartości minimalne z przyrostem bliskim zeru, natomiast w przedziale wartości $\rho = -15 \div -20^\circ$ oraz δ około $47 \div 50^\circ$ siła F_c rośnie najgwałtowniej osiągając maksymalne wartości.

Analizując wpływ podziałki t i głębokości skrawania g zauważamy, że składowa normalna F_n (rys. 10.6), podobnie jak siła F_c (rys. 10.1a), gwałtownie rośnie wraz ze wzrostem podziałki. Przebieg ten ma charakter asymptotyczny. Głębokość skrawania wpływa w niewielkim stopniu na przebieg składowej normalnej przy zmiennej podziałce t , jednakże widoczny jest jej szybszy wzrost dla rosnących głębokości skrawania g . Obserwując przebieg składowej F_n przy wzrastających wartościach podziałki skrawania t i kąta ostrza β (rys. 10.6b), zauważamy asymetrię jej przyrostu. Składowa F_n szybciej wzrasta przy rosnącym kącie ostrza, niż wzrastającej podziałce.

a)




b)



Rys. 10.6. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej normalnej F_n zależne od: a) głębokości skrawania g i podziałki t , b) kąta ostrza β i podziałki t

Składowa F_n przy wzrastających wartościach podziałki skrawania t i kąta ustawienia δ (rys. 10.7a) ma symetryczny charakter przyrostu, tzn. jej zależność od kąta ustawienia i podziałki jest podobna. Zupełnie inny charakter ma przebieg składowej F_n w zależności od zmian kąta obrotu ρ i podziałki skrawania t (rys. 10.7b) - podobnie jak w przypadku prze-

biegu siły F_c (rys. 10.2b). Składowa F_n rośnie przy rosnącej podziałce t w pełnym zakresie oraz malejącym kącie obrotu ρ w zakresie $0 \div -20^\circ$. Dla wartości kąta obrotu $0 \div 20^\circ$ i podziałce $10 \div 15$ mm F_n przyjmuje minimalne wartości.





Rys. 10.7. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej normalnej F_n zależne od: a) kąta ustawienia δ i podziałki t , b) kąta obrotu ρ i podziałki t

Z rysunku 10.8 wynika, że powierzchnia odpowiedzi składowej F_n stanowi wycinek płaszczyzny odpowiednio nachylonej pod wpływem kąta ostrza β i głębokości skrawania g , oraz kąta ustawienia noża δ i głębokości skrawania g . Fragment płaszczyzny obrazujący przyrost składowej normalnej (rys. 10.8a) jest dolną krawędzią nieznacznie wychylony od osi wartości g i wznosi się wraz ze wzrostem kąta ostrza, gdzie F_n osiąga wartości maksymalne. Nachylenie powierzchni odpowiedzi składowej F_n (rys. 10.8) zależy głównie od wzrostu kąta ustawienia, jednak jest również nieznacznie wychylana ku górze wraz z malejącą głębokością skrawania g , osiągając maksymalne wartości przy kącie $\delta = 49 \div 50^\circ$ i głębokości $g = 6 \div 9$ mm.

W zależności składowej F_n od głębokości skrawania g i kąta obrotu ρ (rys. 10.9a) obserwuje się występowanie pewnego lokalnego minimum, które występuje dla kąta obrotu $0 \div 50^\circ$ i głębokości skrawania $15 \div 18$ mm.


W przypadku badania wpływu kątów ostrza β i ustawienia δ (rys. 10.9b) można stwierdzić, że składowa F_n , narasta szybko przy wzroście kąta ostrza i wykazuje nieco wolniejszy wzrost pod wpływem rosnącego kąta ustawienia. Siła F_n osiąga wartości minimalne przy małych wartościach kątów ostrza i ustawienia. Przyrost składowej F_n jest równomierny, choć nie ma liniowego przebiegu.



Rys. 10.9. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej normalnej F_n zależne od: a) kąta obrotu ρ i głębokości skrawania g , b) kąta ustawienia δ i kąta ostrza β

Analizując wpływ kąta obrotu ρ i ostrza β na omawianą składową F_n (rys. 10.10a) obserwuje się jej przyrost wraz ze zmniejszaniem się kąta obrotu i wzrostem kąta ostrza.

Nieco inaczej kształtuje się przebieg składowej F_n pod wpływem kąta ustawienia δ i obrotu ρ (rys. 10.10b). Składowa normalna rośnie wraz ze wzrostem kąta ustawienia δ i zmniejszającym się kącie obrotu ρ , jednak wzrost ten obserwowany jest dopiero w obszarze kąta obrotu $-3 \div -20^\circ$ oraz kąta ustawienia $43 \div 50^\circ$. W pozostałym obszarze przyjmuje ona wartości minimalne.




Rys. 10.10. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej normalnej F_n zależne od: a) kąta obrotu ρ i kąta ostrza β , b) kąta obrotu ρ i kąta ustawienia δ


Składowa boczna F_b w zależności od wpływu odpowiednich wielkości wejściowych przejawia zróżnicowany przebieg, co objawia się różnymi kształtami powierzchni odpowiedzi. Siła ta maleje do pewnej wartości, gdy podziałki t osiągają duże wartości, a głębokość skrawania g jest odpowiednio mała (rys. 10.11a). W pewnym zakresie dużych podziałek i małych głębokości mamy do czynienia z prawie stałą minimalną wartością składowej bocznej. Analogicznie zachowuje się składowa F_b w przeciwnym krańcu powierzchni odpowiedzi gdzie zauważamy zmniejszanie a w konsekwencji brak przyrostu składowej F_b , po osiągnięciu proporcji $t/g = \sim 1,5$.

Składowa boczna F_b nie wykazuje istotnej zależności od kąta ostrza β przy zmiennej podziałce skrawania t (rys. 10.11b). Dla dużych podziałek prezentuje wartości minimalne, rosnąc od pewnego zakresu zmniejszającej się podziałki, do wartości maksymalnych.

Inaczej kształtuje się składowa F_b w zależności od zmian podziałki skrawania t i kąta ustawienia δ (rys. 10.12a). Możemy zaobserwować pewne minimum lokalne utworzone przez wąski pas płaszczyzny leżący na linii łączącej punkty maksymalnej podziałki i kąta obrotu na osiach wykresu. Poza tym obszarem rozpatrywana składowa rośnie gwałtownie, zarówno w kierunku rosnących jak i malejących wartości t i g . Bardzo podobny kształt powierzchni F_b obserwujemy pod wpływem zmian kąta obrotu ρ i podziałki skrawania t (rys. 10.12b).



Rys.10.11 Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej bocznej F_b zależne od: a) głębokości skrawania g i podziałki t , b) kąta ostrza β i podziałki t .




Rys.10.12. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej bocznej F_b zależne od: a) kąta ustawienia δ i podziałki t , b) kąta obrotu ρ i podziałki t

W rozpatrywanych powyżej powierzchniach odpowiedzi, możemy zauważyć dość istotny wpływ podziałki skrawania t , który jest spowodowany nadaniem przez sieć neuronową najwyższej rangi wartości t (tabela 9.2). Przewidywany przez sieć błąd uczenia przy pominięciu tej wartości wyniósłby około 36%. Nieco niższa ranga została nadana głębokości skrawania g , której strata zwiększyłaby błąd uczenia do około 22%. Wyraźny wpływ głębokości skrawania możemy zaobserwować na poniższych powierzchniach odpowiedzi.

Kąt ostrza β przy zmiennej głębokości skrawania g (rys. 10.13a) podobnie jak przy podziałce t (rys. 10.12b) nie ma większego wpływu na przebieg składowej bocznej F_b . Rośnie ona wraz ze wzrostem głębokości skrawania g , nieznacznie szybciej dla mniejszych wartości kąta ostrza.


Inny kształt powierzchni odpowiedzi składowej F_b (rys. 10.13b) możemy obserwować w zależności od głębokości skrawania g oraz kąta ustawienia δ . Rosnąca od wartości minimalnych głębokość skrawania g , równoległe ze wzrostem kąta ustawienia, sprzyja najmniejszym wartościom składowej bocznej. Składowa ta swoje maksima ma dla wartości $g = 18 \text{ mm}$ i $\delta = 40^\circ$ oraz $g = 6 \text{ mm}$ i $\delta = 50^\circ$.

Wpływ głębokości skrawania g i kąta obrotu ρ (rys. 10.14a) na składową F_b ma nieco inny charakter niż poprzednie powierzchnie. F_b przyjmuje minimalne wartości dla kąta obrotu $-5 \div 5^\circ$ w całym zakresie głębokości skrawania. Jej minimum dla $\rho = -5^\circ$ występuje przy głębokości $g = 6 \text{ mm}$ i przesuwa się do $\rho = 5^\circ$ i $g = 18 \text{ mm}$. Poza tym wąskim obszarem obserwujemy przyrost składowej bocznej po obu stronach przedziałów ρ , przy czym swoje maksymalne wartości przyjmuje dla wartości kąta obrotu $-15 \div -20^\circ$ i głębokości skrawania $15 \div 18 \text{ mm}$.




Rys.10.13. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej bocznej F_b zależne od: a) kąta ostrza β i głębokości skrawania g , b) kąta ustawienia δ i głębokości skrawania g

W zależności składowej bocznej od kątów ostrza β i ustawienia δ (rys. 10.14b), możemy zaobserwować jak wcześniej (rys. 10.11b, 10.13a) brak większego wpływu kąta ostrza na kształtowanie się powierzchni F_b . Siła ta rośnie wraz ze zmniejszaniem δ od wartości 48° i osiąga wysokie wartości dla kąta 40° przyjmując najwyższe wartości dla $\beta = 75^\circ$.



Rys.10.14. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej bocznej F_b zależne od: a) kąta obrotu ρ i głębokości skrawania g , b) kąta ustawienia δ i kąta ostrza β

Zależność składowej bocznej od kątów: obrotu ρ i ostrza β przedstawia kolejny raz brak większego wpływu kąta ostrza na jej kształtowanie się (rys. 10.15a). Możemy natomiast zaobserwować symetrię kształtowania się powierzchni F_b , której niekiedy minimum jest umieszczona w okolicach kąta obrotu $\rho = 5 \pm 7^\circ$. F_b rośnie oddalając się od tych wartości.




Rys.10.15. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się składowej bocznej F_b zależne od: a) kąta obrotu ρ i kąta ostrza β , b) kąta obrotu ρ i kąta ustawienia δ .

Nieco większy wpływ na kształtowanie się składowej bocznej ma kąt ustawienia δ przy zmiennym kącie obrotu ρ (rys. 10.15b). Niekiedy

minimum lokalnego jest umieszczona w zakresie kąta obrotu $\rho = 5^\circ$ i kąta $\delta = 40^\circ$ oraz przesuwu się w kierunku $\rho = -5^\circ$ i $\delta = 50^\circ$.


Zaobserwowany niewielki wpływ kąta ostrza β ma związek z nadaniem najniższej rangi wagi wartości wejściowej według przeprowadzonej analizy wrażliwości (tabela 9.2) i przewidywany błąd uczenia nieznacznie wzrósł przy wyeliminowaniu tej danej.

Wpływ masy zeskrwanego materiału m na kształtowanie się właściwej energii skrawania e_c w zależności podziałki t (rys. 10.16a), głębokości g (rys. 10.16b), kątów: ostrza β (rys. 10.17a), ustawienia δ (rys. 10.17b) i obrotu ρ (rys. 10.18a) jest bardzo podobny. Właściwa energia skrawania osiąga wartości minimalne dla największych zeskrwanych mas materiału i rośnie proporcjonalnie do spadku tej masy. Powierzchnie odpowiedzi różnią się dynamiką przyrostu właściwej energii skrawania e_c .




Rys.10.16. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się właściwej energii skrawania e_c zależne od: a) podziałki t i masy odspojonego materiału m , b) głębokości skrawania g i masy odspojonego materiału m

Właściwa energia skrawania e_c rośnie wraz ze wzrostem głębokości skrawania g , oraz wykazuje o wiele wolniejszy wzrost pod wpływem rosnącej podziałki skrawania t (rys. 10.18b). Energia skrawania rośnie do wartości g około 15 mm, po czym jej wartość zaczyna się zmniejszać. Energia skrawania charakteryzuje się nieco szybszym przyrostem dla większych podziałek.



Rys.10.17. Powierzchnia odpowiedzi przebiegu właściwej energii skrawania e_c zależne od: a) kąta ostrza β i masy odspojonego materiału m , b) kąta ustawienia δ i masy odspojonego materiału m



Rys.10.18. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się właściwej energii skrawania e_c zależne od: a) kąta obrotu ρ i masy odspojonego materiału m , b) głębokości skrawania g i podziałki t

Wpływ na e_c kąta ostrza β przy zmiennej podziałce skrawania t (rys. 10.19a) jest podobny jak podziałki g (rys. 10.18b), przy czym, przyrost e_c przy zmiennym kącie ostrza ma charakter liniowy.


Właściwa energia skrawania rośnie natomiast proporcjonalnie wraz z wzrostem kąta ustawienia δ i podziałki t (rys. 10.19b). Powierzchnia odpowiedzi ma symetryczny przebieg z asymptotycznym charakterem maksimum wartości e_c , w maksymalnych wartościach δ i t .

Zależność właściwej energii skrawania e_c od kąta obrotu ρ i podziałki skrawania t (rys.10.20a) przedstawia duży wpływ ρ na przyrost e_c . Energia skrawania przyrasta w sposób prawie jednostajny przyjmując

wartości minimalne dla $\rho = 20^\circ$ i rośnie do wartości kąta $\rho = -20^\circ$. Na kształt i nachylenie tej powierzchni w niewielkim stopniu wpływa podziałka skrawania t , powodując przy ujemnych wartościach kąta obrotu szybszy przyrost e_c dla większych podziałek.

a)

b)




Rys.10.19. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się właściwej energii skrawania e_c zależne od: a) kąta ostrza β i podziałki t , b) kąta ustawienia δ i podziałki t

Właściwa energia skrawania wykazuje bardzo silne związki ze zmianami głębokości skrawania g oraz kątem ostrza β (rys. 10.20b), podobnie jak w przypadku zmian głębokości g oraz kąta ustawienia δ (rys. 10.21a). Równoczesny przyrost g i β oraz g i δ powoduje wzrost energii skrawania e_c . Wzrasta ona nieco szybciej pod wpływem zwiększanej głębokości skrawania, jednak tylko do wartości około 15 mm a później zaczyna nieznacznie maleć.


Mniejszą zależność od głębokości skrawania energia skrawania e_c wykazuje przy zmiennym kącie obrotu ρ (rys. 10.21b). Energia skrawania rośnie dla małych głębokości, tj. 6÷10 mm. Dla g większych, prawie nie wzrasta. Przy zmniejszającym się kącie obrotu od 20° do -20° energia skrawania wzrasta, osiągając najwyższe wartości dla $\rho = -18^\circ$ do -20° oraz $g = 10$ ÷18 mm.

Przy zmiennym kącie ustawienia δ właściwa energia skrawania e_c rośnie wraz ze wzrostem kąta ostrza β (rys. 10.22a). Jej przyrost jest znacznie mniejszy przy rosnącym kącie ustawienia δ .

a)




b)




Rys.10.20. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się właściwej energii skrawania e_c zależne od: a) kąta obrotu ρ i podziałki t , b) kąta ostrza β i głębokości skrawania g

a)




b)



Rys.10.21. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się właściwej energii skrawania e_c zależne od: a) kąta ustawienia δ i głębokości skrawania g , b) kąta obrotu ρ i głębokości skrawania g

Wpływ kątów: ostrza β (rys. 10.22b) oraz ustawienia δ (rys. 10.22c) na energię skrawania e_c przy zmiennym kącie obrotu ρ jest podobny jak w zależności (rys. 10.20a). Wzrost kątów ostrza β oraz ustawienia δ przy zmiennym kącie obrotu ρ powodują przyrost energii skrawania większy dla malejących ρ . Minimalne e_c występuje dla ρ około -18° przy najmniejszych wartościach β i δ .



Rys.10.22. Powierzchnie odpowiedzi według sieci neuronowej kształtowania się właściwej energii skrawania e_c zależne od: a) kąta ustawienia δ i kąta ostrza β , b) kąta obrotu ρ i kąta ostrza β , c) kąta obrotu ρ i kąta ustawienia δ

11. Podsumowanie i wnioski

Z przeprowadzonych badań i analiz wynika, że zaproponowany, rozszerzony model urabiania skał, w stosunku do dotychczas funkcjonującego modelu empirycznego [26], lepiej opisuje proces urabiania stożkowymi nożami obrotowymi, między innymi z uwagi na lepsze dopasowanie wartości zmiennych wyjściowych modelu przewidywanych przez sieć, do rzeczywistych danych pomiarowych.

Właściwości skrawanych skał (Rc , Rc/Rr , ζ) są niezbędne do budowy modelu skrawania opartego o wyniki badań więcej niż jednego rodzaju skał. Analiza wrażliwości opracowanego za pomocą sieci neuronowych modelu skrawania pokazuje, że informacje o właściwościach

skrawanych skał są istotne dla lepszego objaśniania procesu z wykorzystaniem tego modelu.

Biorąc pod uwagę kształtowanie się siły skrawania F_c zależnie od badanych parametrów, z porównania wyników uzyskanych opisanymi metodami wynika, że:

- kąty: ustawienia δ i bocznego wychylenia ρ powinny mieścić się (według powierzchni odpowiedzi dla modelu rozszerzonego) odpowiednio w przedziale $40 \div 43^\circ$ i $10 \div 20^\circ$, aby osiągnąć minimalne wartości siły skrawania, podczas gdy z modelu uproszczonego [26] wynika, że powinny one wynosić odpowiednio $39 \div 47^\circ$ i $-5 \div 25^\circ$,
- kąty: ustawienia δ i ostrza β według powierzchni odpowiedzi sieci neuronowej, powinny wynosić odpowiednio $40 \div 46^\circ$ i $75 \div 77^\circ$, gdyż siła skrawania przyjmuje wtedy wartości najmniejsze, zakresy te są zbliżone do otrzymanych w modelu uproszczonym, w którym wynoszą one odpowiednio $38 \div 44^\circ$, $74 \div 82^\circ$,
- kąty: bocznego wychylenia ρ i ostrza β według powierzchni odpowiedzi, powinny wynosić odpowiednio $-20 \div 15^\circ$ i $75 \div 78^\circ$, dla których siła skrawania przyjmuje wtedy wartości najmniejsze. Zakresy minimalnych wartości sił otrzymanych w modelu uproszczonym wynoszą odpowiednio $-5 \div 25^\circ$, $74 \div 80^\circ$. W modelu rozszerzonym, występuje szerszy przedział kąta obrotu dla występowania minimalnych wartości F_c , co może wynikać z uwzględnienia innych warunków skrawania np. wapienia (nieuwzględnianego w modelu matematycznym),
- wzrost siły skrawania w całym rozpatrywanym przedziale, podobnie jak w modelu uproszczonym, zależy w szczególności od rosnącej podziałki t oraz w mniejszym stopniu od głębokości skrawania g .

Z uwagi na składową normalną:

- wzrost składowej normalnej w całym rozpatrywanym przedziale, podobnie jak w modelu uproszczonym, zależy przede wszystkim od rosnącej podziałki t a także głębokości skrawania g ,
- kąty: ustawienia δ i ostrza β według powierzchni odpowiedzi modelu rozszerzonego, powinny wynosić odpowiednio $40 \div 44^\circ$ i $75 \div 77^\circ$, gdyż składowa normalna przyjmuje wtedy wartości najmniejsze, zakresy te mieszczą się w zakresach odpowiedniej powierzchni odpowiedzi wynikającej z modelu uproszczonego, w którym wynoszą one odpowiednio $38 \div 44^\circ$, $74 \div 82^\circ$,

- kąty: bocznego wychylenia ρ i ostrza β według powierzchni odpowiedzi sieci, powinny wynosić odpowiednio $20 \pm 5^\circ$ i $75 \pm 78^\circ$, gdyż składowa normalna przyjmuje wtedy wartości najmniejsze. Zakresy minimalnych wartości sił otrzymanych w modelu uproszczonym, wynoszą odpowiednio $-15 \pm 25^\circ$, $74 \pm 79^\circ$ i obejmują swym zakresem wyniki modelu rozszerzonego,
- kąty: ustawienia δ i bocznego wychylenia ρ powinny mieścić się (według powierzchni odpowiedzi modelu rozszerzonego) odpowiednio w przedziale $40 \pm 47^\circ$ i $-5 \pm 20^\circ$, aby osiągnąć minimalne wartości składowej normalnej. Z modelu uproszczonego wynika, że powinny one wynosić odpowiednio $39 \pm 47^\circ$ i $-5 \pm 17^\circ$, a więc mieszczą się w bardzo podobnych przedziałach, jak w modelu rozszerzonym.

Z uwagi na składową boczną:

- według powierzchni odpowiedzi modelu rozszerzonego, składowa boczna osiąga minimalne wartości zwłaszcza dla dużych podziałek i małych głębokości skrawania, podobnie jak w modelu uproszczonym,
- brak jest istotnego wpływu parametrów konstrukcyjnych ostrza na wielkość składowej bocznej, choć można zaobserwować jej minimum dla kąta obrotu około 7° (podobnie jak w modelu uproszczonym) oraz obserwuje się niewielki wpływ zmian kąta ostrza na kształtowanie się tej składowej.

Z uwagi na właściwą energię skrawania:

- kąty: ustawienia δ i bocznego wychylenia ρ powinny mieścić się (według powierzchni odpowiedzi sieci neuronowej) odpowiednio w przedziale $40 \pm 49^\circ$ i $-5 \pm 20^\circ$, aby osiągnąć minimalne wartości właściwej energii skrawania. Z modelu uproszczonego wynika, że powinny one wynosić odpowiednio $41 \pm 49^\circ$ i $-5 \pm 20^\circ$, a więc zakresy tych wartości są zbieżne,
- kąty: ustawienia δ i ostrza β według powierzchni odpowiedzi sieci, powinny wynosić odpowiednio $40 \pm 45^\circ$ i $75 \pm 76^\circ$, gdyż energia skrawania przyjmuje wtedy wartości najmniejsze, zakresy te częściowo mieszczą się w zakresach odpowiedniej powierzchni odpowiedzi wynikającej z modelu uproszczonego, w którym wynoszą one odpowiednio $38 \pm 41^\circ$, $74 \pm 75^\circ$.

- kąty: bocznego wychylenia ρ i ostrza β według powierzchni odpowiedzi, powinny wynosić odpowiednio $17 \div 20^\circ$ i $75 \div 77^\circ$, podobnie jak w modelu uproszczonym, gdyż energia skrawania przyjmuje wtedy wartości najmniejsze,
- istnieją różnice w zakresach pracy parametrów technologicznych pracy ostrza (głębokości i podziałki skrawania) dla występowania minimalnych wartości energii skrawania. Minimalne wartości energii skrawania dla rozszerzonego modelu (rys. 8.2) występują dla małych głębokości skrawania $6 \div 8$ mm dla proporcji $t/g = 1,5 \div 12$, średnio 5. W modelu uproszczonym (rys. 3.6), proporcja ta wynosi $t/g = 1,5 \div 5$, średnio 3,5.

11.1. Wnioski dotyczące możliwości stosowania sieci neuronowych w badaniach procesu urabiania skał stożkowymi nożami obrotowymi:

- Uwzględnianie wejściowych zmiennych skorelowanych ze sobą w modelu procesu tworzonego z wykorzystaniem sieci neuronowej, pozwoliło uzyskać pełniejszy opis procesu i indywidualnego wpływu każdej z tych zmiennych. W klasycznych procedurach statystycznych, podstawowym zaleceniem jest odrzucenie zależnych zmiennych wejściowych.
- Jak wynika z przeprowadzonych badań z wykorzystaniem sieci neuronowej, uzyskano znacznie lepsze dopasowanie modelu do danych pomiarowych (błąd dopasowania nawet rzędu $2 \div 3\%$) niż miało to miejsce w przypadku porównywanego modelu empirycznego [26].
- Model opracowany z wykorzystaniem sieci neuronowej pozwolił na uwypuklenie wpływu gęstości skały, na kształtowanie się obciążenia noża stożkowego, czego nie udawało się zidentyfikować w dotychczasowych, numerycznych modelach procesu urabiania skał nożami obrotowymi.
- Dla skrajnych warunków symulacji, tj dla testowania sieci z wykorzystaniem wyników badań z zupełnie innego stanowiska badawczego, dla zupełnie innej skały poddawanej badaniom urabiania oraz przy odmiennych parametrach konstrukcyjnych noży i technologicznych urabiania (mieszczących się jednak w obszarze symulacji sieci), przyjęty model sieci neuronowej wykazał duże możliwości adaptacyjne oraz dobre właściwości do uogólniania wiedzy.

- Przeprowadzone badania wykazały pełną przydatność klasycznych sieci neuronowych w identyfikacji procesu urabiania skał stożkowymi nożami obrotowymi.

12. Kierunki dalszych badań

Tematyka pracy nie ujmuje szeregu innych aspektów urabiania skał nożami stożkowymi. Wymienić tutaj można takie zagadnienia jak problematyka obracania się noża stożkowego, czy mechanika jego zużywania się. Szerszymi zagadnieniami, które do dzisiaj nie doczekały się pełnego rozwiązania, są np. zagadnienia optymalizacji urabiania skał głowicą wielonarzędziową, a zwłaszcza problematyka monitorowania urabiania i adaptacyjnego sterowania procesem urabiania taką głowicą (w którą wyposażone są kombajny chodnikowe).

Na dzień dzisiejszy prace te są realizowane w ograniczonym zakresie lub w ogóle nie są prowadzone. Diagnostyka kombajnu ogranicza się jedynie do śledzenia niektórych parametrów, takich jak: odpowiednie ciśnienie czy temperatura w wybranych podzespołach kombajnu. Sterowanie pracą głowicy kombajnu chodnikowego odbywa się ręcznie, według subiektywnych odczuć i doświadczenia operatora. Jak się przewiduje [1, 21, 26, 71], celem rozszerzenia zakresu stosowania kombajnów chodnikowych, niezbędna jest kompleksowa, prowadzona w czasie rzeczywistym, diagnostyka pracy kombajnu, monitorowanie stanu noży urabiających oraz wprowadzenie automatyzacji sterowania ruchem głowicy urabiającej. Ilość i wielowątkowość zbieranych informacji wpływowych oraz losowy charakter przebiegu procesu urabiania skał głowicą kombajnu chodnikowego, przemawia za wykorzystaniem inteligentnych systemów sterowania i nadzoru, np. logiki rozmytej (fuzzy logic) w tym zwłaszcza rozmytych sieci neuronowych, pełniących funkcję sterowników rozmytych.

Jak wykazują dotychczasowe badania przemysłowe, w tym zwłaszcza badania [9, 79], do monitorowania procesu urabiania głowicą kombajnu chodnikowego, jak i sterowania przebiegiem urabiania, mogą być

wykorzystane np. sygnały mocy urabiania oraz (lub) prądu (pomocniczo także napięcia) w układzie napędowym głowicy urabiającej. Badania wykazują, że proporcjonalnie do obciążenia głowicy, zmieniają się wymienione wcześniej wielkości.

Badania [79] potwierdzają, że tak wartość, amplituda jak i charakter zmian omawianych wielkości (w tym zwłaszcza prądu i mocy), zależą od szeregu czynników a w szczególności od:

- rodzaju urabianej skały, układu warstw skalnych w przekroju drążonego chodnika,
- technologii urabiania, tj.: rodzaju ruchów wykonywanych przez głowicę (wychylanie wysięgnika w poziomie bądź pionie, wcinanie głowicy, profilowanie),
- rodzaju głowicy i noży urabiających,
- stopnia stępienia noży.

Z przytoczonych przykładów wynika, iż aby sygnały te mogły brać udział w procesach sterowania czy monitorowania procesu urabiania, muszą być odpowiednio sklasyfikowane jak również poddane dyskretyzacji. Z badań nad inteligentnymi systemami sterowania wynika (np. Pająk [61]), że do takich celów mogą być przydatne sieci neuronowe, z uwagi na swe właściwości. Z uwagi jednak na aktualne ograniczenia tych sieci (stosunkowo duże błędy prognozy dla losowych przebiegów szybkozmiennych (np. Słomiński [82]), niezbędna jest dyskretyzacja tych sygnałów. Rozpatrując zagadnienie szeregu czasowego np. $I = f(t)$ (w dziedzinie czasu), procedura taka polega najczęściej na przeprowadzeniu analizy harmonicznej, w której określone są amplitudy i fazy dla częstości harmonicznych pewnej częstotliwości podstawowej. Do tego celu wykorzystywana jest Szybka Transformata Fouriera (FFT). W założonych odstępach czasowych, dla danego przebiegu czasowego, biorąc pod uwagę np. 10 harmonicznych funkcji $I_g = f(t)$, wartość średnią sygnału I_g (prądu silnika napędowego głowicy) można zbudować element sieci hybrydowej, odpowiedzialny za klasyfikację rodzaju pracy głowicy (wcinanie, ruch poziomy, ruch pionowy). Operowanie widmem sygnału jest znacznie prostsze, niż prognozowanie jego hipotetycznego przebiegu czasowego.

Kolejnym elementem, jaki powinien być monitorowany, zwłaszcza w głowicach do urabiania kamienia, jest stan noży, który ma istotny wpływ na kształtowanie się obciążenia głowicy, poziom generowanego hałasu jak i poziom drgań głowicy. Szereg badań wykazuje tutaj dużą przydatność analizy sygnałów emisji akustycznej i wibroakustycznej np. [23, 34, 35, 43, 44, 93, 95, 100].

Emisja akustyczna (AE – Acoustic Emission) jest to rozchodzenie się fal sprężystych generowanych w materiale wskutek wyzwania energii naprężeń wewnętrznych powodowanych przez odkształcenia. Nagromadzona energia wyzwala się w miejscu inicjacji naruszenia pierwotnych wiązań strukturalnych materiału. Zjawiska te coraz częściej są wykorzystywane w diagnostyce stanu narzędzi skrawających i procesu skrawania tak metali jak i ceramiki technicznej [94]. Użyteczny zakres częstotliwości wynosi 50 kHz do 2 MHz, a więc leży znacznie powyżej niż stosowane przy badaniach drgań hałasu. W odniesieniu do skał, takie badania muszą być przeprowadzone kompleksowo. W diagnozowaniu stanu ostrza, najczęściej wykorzystywanymi parametrami rozkładu wartości skutecznej EA, są wartość średnia RMS i odchylenie standardowe RMS (S_{RMS}).

Biorąc powyższe pod uwagę, w zagadnieniu wykorzystania sztucznych sieci neuronowych w analizach procesu urabiania skał stożkowymi nożami obrotowymi oraz głowicami wielonarzędziowymi, jako przyszłościowe kierunki badań pracy proponuje się:

- badania nad wykorzystaniem sztucznych sieci neuronowych do prognozowania zużycia stożkowych noży obrotowych, zależnie od parametrów konstrukcyjnych noża, i technologicznych urabiania oraz właściwości urabianych skał,
- badania nad identyfikacją procesu obracania się noża stożkowego w uchwycie, zależnie od parametrów technologicznych procesu urabiania, konstrukcyjnych noża oraz właściwości urabianych skał,
- badania eksploatacyjne organów frezujących jako układów stożkowych noży obrotowych, dla pozyskania niezbędnej bazy danych pomiarowych,
- zastosowanie sztucznych sieci neuronowych w identyfikacji procesu urabiania skał głowicą frezującą kombajnu chodnikowego, zależnie od kombinacji ruchów głowicy,
- badania nad zastosowaniem sieci neuronowej do monitorowania, diagnozowania oraz sterowania procesem urabiania głowicą wielonarzędziową kombajnu chodnikowego.

Literatura

- [1] Akerman J., Gerer R., Lammer E., Siebenhofer G.: The road ahead. World Mining Equipment, March 1999, pp. 29-34.
- [2] Bęben A.: Maszyny i urządzenia do wybranych technologii urabiania surowców skalnych. Wydawnictwo „Śląsk”, Katowice 1998.
- [3] Bęben A., Maziarz M., Tylek R., Wierzba T.: Wstępne badania przemysłowe koronki ϕ 216 z obrotowymi nożami stycznymi. II Międzynarodowa Konferencja „Techniki Urabiania 2002, Kraków-Krynica, 2002, s. 159-170.
- [4] Bieron A.I.: Ob osnovnykh eksperimentalno-analiticheskikh teorii riezania uгля i gornych porod. Sb. Sowierszenstwowanie razrabotki ugolnykh miestoroženij. Uglietechizdat, 1959.
- [5] Bishop, C.: Neural Networks for Pattern Recognition. University Press. Oxford.1995.
- [6] Boadu F.K.: Predicting oil saturation from velocities using petrophysical models an artificial neural networks. J. of. Petroleum Science& Engineering, 30, 2001, s. 143- 154.
- [7] Carling, A.: Introducing Neural Networks. Wilmslow, UK: Sigma Press.,1992.
- [8] Demicco R.V., Klir G.J.: Stratigrafic simulations using fuzzy logic to model sediment dispersal. J. of Petroleum Science& Engineering, 30, 2001, s. 135-155.
- [9] Dolipski M., Cheluszka P.: Doświadczalna weryfikacja modelu dynamicznego układu urabiania kombajnu chodnikowego. Przegląd Górniczy nr 6, 2000, s. 1-5.
- [10] Driankov D., Hellendoorn H., Reinfrank M.: Wprowadzenie do sterowania rozmytego. WNT, Warszawa 1996.
- [11] Evans I., Pomeroy C. D.: The strength, fracture and workability of coal. 1st Edn., Pergamon Press, London 1966.
- [12] Evans I.: Basic Mechanics of the Point-Attack Pick. Colliery Guardian, May 1984.
- [13] Fausett, L.: Fundamentals of Neural Networks. New York, Prentice Hall 1994.
- [14] Finol H., Guo Y.K., Jing X.D.: A rule based fuzzy model for prediction of petrophysical rock parameters. . J. of. Petroleum Science& Engineering 29, 2001, 97- 113.

- [15] Fuzzy Logic Toolbox, User Guide v.2. For Use with MATLAB. The MathWorks Inc.
- [16] Grima M. A., Bruines P.A., Verhoef P.N.W.: Modeling Tunnel Boring Machine Performance by neuro-fuzzy methods. Tunneling and Underground Space Technology, Vol. 15, No 3, 2000, pp. 259- 269.
- [17] Grzegorzek W., Ścieszka S.: Sieć neuronowa w analizie zjawisk trybologicznych TEMAG '99-Trwałość elementów i węzłów konstrukcyjnych maszyn górniczych. Ustroń 1999.
- [18] Grzegorzek W.: Zjawiska trybologiczne w hamulcach górniczych maszyn wyciągowych a sieć neuronowa w analizie TEMAG '99-Trwałość elementów i węzłów konstrukcyjnych maszyn górniczych. Ustroń 1999.
- [19] Haykin, S.: Neural Networks: A Comprehensive Foundation. New York: Macmillan Publishing, 1994.
- [20] Hurt K.G., Laidlaw D.D: Laboratory comparison of the rock cutting tools. Tunnels and Tunneling, May 1979.
- [21] *Improving the Capabilities of Cutting Tools and Cutting Systems for Hard Rock-ICACUTROC*. Eng. A Mining J. No 10, p. 46, October 1998.
- [22] Jang J.S., Sun C.T., Mizutani E.: Neuro-fuzzy and soft computing. Prentice Hall. N.J., 1997.
- [23] Jemielniak K.: Wykorzystanie sztucznych sieci neuronowych do diagnostyki zużycia ostrza. IV Ogólnokrajowa Konferencja Naukowo-Techniczna nt.: Postępy w technice wytwarzania maszyn. Kraków, 25-26.11.2001, s. 93-100.
- [24] Jonak J., Podgórski J.: Analiza zjawisk mających wpływ na przebieg mechanizmu formowania wióra w procesie skrawania naturalnych materiałów kruchych. Seminarium projektów badawczych finansowanych przez KBN w 1999 r. KBN, Zespół Mechaniki, Budownictwa i Architektury. Sekcja Technologii, Automatyzacji Maszyn i Produkcji. Warszawa, 20 stycznia 2000, s. 39-40.
- [25] Jonak J., Podgórski J.: Wybrane aspekty mechaniki skrawania skał. Sympozjum: "Zagadnienia mechaniki pękania i skrawania materiałów". Red. Z.Mróz, T.Sadowski. Kazimierz Dolny n. Wisłą. 22-24.10.1998. LTN, Lublin 1998.

- [26] Jonak J.: Teoretyczne podstawy urabiania skał stożkowymi nożami obrotowymi. Wydawnictwa Uczelniane Politechniki Lubelskiej. Lublin 1998.
- [27] Jonak J.: Urabianie skał głowicami wielonarzędziowymi. Wyd. Śląsk, Katowice 2001, s. 324.
- [28] Klich A., Kotwica K., Krawczyk S., Ptak J.: Zagadnienie zużycia ostrzy noży kombajnowych w zależności od temperatury i warunków skrawania skały. Mechanizacja i Automatyzacja Górnictwa. nr 9 (291), Katowice 1994.
- [29] Kohonen, T.: Improved versions of learning vector quantization. International Joint Conference on Neural Networks 1, 1990, pp. 545-550. San Diego, CA.
- [30] Kohonen, T.: Self-organized formation of topologically correct feature maps. Biological Cybernetics, 43,,1982, pp. 59-69.
- [31] Kołek K., Mitkowski W.: Dobór struktury sieci neuronowych w układach sterowania czasu rzeczywistego. Informatyka w technologii materiałów. No 1, T.1, 2001, s. 23-34.
- [32] Korbicz J., Obuchowicz A., Uciński D.: Sztuczne sieci neuronowe. Podstawy i zastosowania. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [33] Korbicz J.: Metody rozpoznawania obrazów w diagnostyce procesów przemysłowych. III Krajowa Konferencja N-T nt.: Diagnostyka Procesów Przemysłowych. 7-10.09.1998, Jurata/k Gdańska.
- [34] Kościelny J.M., Ostasz A.: Zastosowanie rozmytych sieci neuronowych do detekcji uszkodzeń urządzeń wykonawczych. III Krajowa Konferencja N-T nt.: Diagnostyka Procesów Przemysłowych. 7-10.09.1998, Jurata/k Gdańska.
- [35] Kosmol J., Sokołowski A.: Analiza wibroakustyczna w dziedzinie czasu jako metoda poszukiwania symptomów zużycia ostrza skrawającego. ZN Politechniki Śląskiej, s. Mechanika, z. 113, 1993, s. 185-191.
- [36] Kowalik S.: Wykorzystanie sieci neuronowej do badania wpływu wydobywania na sejsmiczność w kopalniach węgla kamiennego. Mech. i Automatyzacja Górnictwa, nr 12, 2001, s. 37- 40.
- [37] Krauze K.: Zagadnienie ustawienia noży styczno-obrotowych na frezującym organie ślimakowym. Archive of Mining Sciences 44, 3 (337 – 349), Kraków 1999.

- [38] Krauze K., Klempka R., Jankowski Z.: Wpływ geometrii noża styczno-obrotowego na ruchowe kąty skrawania. II Międzynarodowa Konferencja „Techniki Urabiania 2002, Kraków-Krynica, 2002, s. 415-426.
- [39] Kramer M.A.: Nonlinear principal components analysis using auto-associative neural networks. *AIChE Journal* 37 (2), 1991, pp. 233-243.
- [40] Lange W., Frenyo P.: Kryteria doboru kombajnów chodnikowych. Materiały Konferencyjne, CMG KOMAG, KBN, Komisja Współnot Europejskich, Szczyrk 1993, pp. 1-5.
- [41] Lennox B., Mantague G.A., Frith A.M., Gent Ch., Bevan V.: Industrial application of neural networks- an investigation. *Journal of Process Control* 11, 2001, s. 497- 507.
- [42] Levenberg K.: A method for the solution of certain non-linear problems in least squares. *Quarterly Journal of Applied Mathematics* II (2), 1944, pp. 164-168.
- [43] Li Xiaoli, Yuan Zhjeun : Tool wear monitoring with wavelet packet transform- fuzzy clusterig method. *Wear* 219, 1998, s. 145-154.
- [44] Li Xiaoli: A brief review acoustic emission method for tool wear monitoring during turning. *Int. J. Machine Tools & Manufacture*, 42, 2002, s. 157-165.
- [45] Lowe D.: Adaptive radial basis function non-linearities, and the problem of generalization. First IEEE International Conference on Artificial Neural Networks, 1989, pp. 171-175, London, UK.
- [46] Lula P.: Wykorzystanie sztucznej inteligencji w prognozowaniu. http://www.statsoft.pl/stat_nn.html.
- [47] Lula P.: Wybrane możliwości zastosowań sieci neuronowych i programu STATISTICA Neural Networks. http://www.statsoft.pl/stat_nn.html.
- [48] Marquardt, D.W.: An algorithm for least-squares estimation of non-linear parameters. *Journal of the Society of Industrial and Applied Mathematics* 11 (2), 1963, pp. 431-441.
- [49] Masters T.: Sieci neuronowe w praktyce. WNT, Warszawa 1996.
- [50] Meulenkamp F., Grima M.A.: Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness. *Int. J. Rock Mechanics and Mining Sciences*, 36, 1999, pp. 29-39.

- [51] Minsky, M.L. and Papert, S.A.: Perceptrons. Cambridge, MA: MIT Press, 1969.
- [52] Moody, J. and Darkin, C.J.: Fast learning in networks of locally-tuned processing units. *Neural Computation* 1 (2), 1989, pp. 281-294.
- [53] Neural Network Toolbox. User Guide, v. 4- For Use with MATLAB. The MathWorks Inc.
- [54] Nikraves M., Amnizadeh F.: Mining and fusion of petroleum data with fuzzy logic and neural network agents. *J. of. Petroleum Science& Engineering*, 29, 2001, s. 221-238.
- [55] Nishimatsu Y.: The mechanics of rock cutting. *Int. J. Rock Mech. Min. Sci.* 9, 261-270 (1972).
- [56] Obuchowicz A., Patan K.: Sieć neuronów dynamicznych jako generator residuów. *Optymalizacja architektury. III Krajowa Konferencja N-T nt.: Diagnostyka Procesów Przemysłowych. 7-10.09.1998, Jurata/k Gdańska.*
- [57] Opolski T.: Urabianie mechaniczne i fizyczne skał. Wydawnictwo „Śląsk”, Katowice 1982.
- [58] Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa 2000.
- [59] Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa 1996.
- [60] Osowski S.: Sieci neuronowe wykorzystujące systemy wnioskowania rozmytego. *Software* 2.0, 2/2001, s. 18-20.
- [61] Pająk E.: Zaawansowane technologie współczesnych systemów produkcyjnych. Wyd. Pol. Poznańskiej, 2000, s. 178.
- [62] Patterson, D.: Artificial Neural Networks. Singapore: Prentice Hall, 1996.
- [63] Podgórski J. : General Failure Criterion For Isotropic Media. *Journal of Engineering Mechanics*, Vol. 111, No 2, 1985, pp. 188-201.
- [64] Podgórski J., Jonak J.: Zagadnienie pękania w procesach skrawania skał. *ZN Politechniki Białostockiej*, s. Mechanika, z. 24, 2001.
- [65] Polański Z.: Sieci neuronowe i algorytmy genetyczne w empirycznych badaniach jakości. *Mat. II Ogólnopolskiej Konferencji Naukowej nt.: Problemy jakości stymulatorem rozwoju technologii bezodpadowych.* Kraków, 1999, s. 291-336.

- [66] Pomeroy C.D.: The Breakage of Coal by Wedge Action. Factors influencing breakage by any given shape of tool. Colliery Guardian, November 21, 1963, pp. 642-648.
- [67] Potts E. L. J., Shuttleworth P.: A study of ploughability of coal, with special reference to the effects of blade shape, direction of planing to the clat, planing speed and the influence of water infusion. Trans. Inst. Min. Engr., London, (1958), 117, pp. 520-548.
- [68] Prostański D., Jonak J.: Problemy wykorzystania sieci neuronowej do identyfikacji procesu skrawania skał nożami obrotowymi. Kwartalnik PAN, Niezawodność i Eksploatacja. Nr 5, 2001, s. 18-20.
- [69] Prostański D., Jonak J.: Wpływ wybranych parametrów sieci neuronowej na kształtowanie się błędu odwzorowania procesu urabiania skał. II Międzynarodowa Konferencja „Techniki Urabiania 2002”, Kraków-Krynica, 2002, s. 255-261
- [70] Prostański D.: Wybrane problemy identyfikacji procesu skrawania skał z użyciem sztucznej sieci neuronowej. Maszyny Górnicze, 2002.
- [71] Raport z pracy badawczej „Icacutroc”. Systemy urabiania do warunków skały twardej. <http://www.tamrock.com.pl/kont.htm>.
- [72] Rosenblatt, F.: The Perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review 65, 1958, pp. 386-408.
- [73] Roxborough F. F.: Cutting Rock with Picks. The Mining Engineer, June 1973.
- [74] Rumelhart, D.E. and McClelland, J. (eds.): Parallel Distributed Processing, Vol 1, 1986. Cambridge, MA: MIT Press.
- [75] Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: Learning internal representations by error propagation. In D.E. Rumelhart, J.L. McClelland (Eds.), Parallel Distributed Processing, Vol 1, 1986. Cambridge, MA: MIT Press.
- [76] Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. PWN, Warszawa- Łódź, 1999.
- [77] Shepherd, A. J.: Second-Order Methods for Neural Networks. New York: Springer. 1997.
- [78] Shyllon E.A., Olaleye J.B., Olunloyo V.O.S.: Litho-seismic data handling for hydrocarbon reservoir estimate: fuzzy system modeling approach. J. of Petroleum Science& Engineering.

- [79] Sikora W., Cheluszka P., Giza T., Sobota P., Mann R., Osadnik J.: Określenie sił i energochłonności urabiania nożami stożkowymi. Wyd. Pol. Śląskiej, Gliwice 2000, s. 331.
- [80] Singh V.K., Singh D., Singh T.N.: Prediction of strength properties of some schistose rocks from petrographic properties using artificial neural networks. I. J. Rock Mechanics and Mining Sciences, 38, 2001, s. 269-284.
- [81] Sirat M., Talbot C.J.: Application of artificial neural networks to fracture analysis at the Äspö HRL, Sweden: fracture sets classification. Int. J. of Rock Mechanics & Mining Sciences 38, 2001, s. 621-639.
- [82] Słomiński T., Kwiesielewicz M.: Porównanie efektywności wybranych metod prognozowania zapotrzebowania na wodę w miejskich sieciach wodociągowych. Mat. konferencji nt.: Polioptymalizacja i CAD'2001. Politechnika Koszalińska, ZN Wydziału Mechanicznego nr 28, s. 367-374.
- [83] Speckt, D.F.: A Generalized Regression Neural Network. IEEE Transactions on Neural Networks 2 (6), 1991, pp. 568-576.
- [84] Speckt, D.F.: Probabilistic Neural Networks. Neural Networks 3 (1), 1990, pp. 109-118.
- [85] STATISTICA Neural Networks 4.0 PL. StatSoft 2001.
- [86] Szalek A., Szlagowski J.: Optymalizacja pracy koparki z użyciem sterownika opartego na logice rozmytej. XIV Konferencja Naukowa nt. Problemy rozwoju maszyn roboczych. Zakopane 22-25.01.2001. ZN Pol. Opolskiej, s. Mechanika z. 64, 2001, s. 403-407.
- [87] Tadeusiewicz R.: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Akademicka Oficyna Wydawnicza PLJ. Warszawa 1998.
- [88] Tadeusiewicz R.: Problemy wyboru właściwej architektury sieci neuronowej. Informatyka w technologii materiałów. No 1, T.1, 2001, s. 3-22.
- [89] Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza. Warszawa 1993.
- [90] Tadeusiewicz R.: Wprowadzenie do praktyki stosowania sieci neuronowych. http://www.statsoft.pl/stat_nn.html.
- [91] Takagi T., Sugeno M.: Fuzzy identification of systems and its application to modeling and control. IEEE Trans. On SMC 15, 1985.
- [92] Trybalski K., Wszolek W.: Modelowanie przemysłowych procesów flotacji przy pomocy sieci neuronowych. Międzynarodowa Konferencja Sekcji Cybernetyki w Górnictwie Komitetu Górnictwa PAN. Szczyrk 2000.

- [93] Twardowski P.: Emisja akustyczna w procesie toczenia różnych materiałów konstrukcyjnych. *Archiwum Technologii Maszyn i Automatyzacji*, Vol. 19, nr 2, 1999, s. 139- 146.
- [94] Twardowski P.: Emisja akustyczna w procesie toczenia twardej ceramiki technicznej. *Mat. VI Konf. nt.: Kształtowanie materiałów niemetalowych - NM'2001*. Zakopane, wrzesień 2001, s. 33-38.
- [95] Twardowski P.: Skuteczność różnych modeli diagnostycznych określających stan ostrza skrawającego. *V Międzynarodowe Sympozjum OsiN'97- Krynica*, 4-6.12.1997.
- [96] Weigend, A.S., Rumelhart, D.E. and Huberman, B.A.: Generalization by weight-elimination with application to forecasting. In R.P. Lippmann, J.E. Moody and D.S. Touretzky (Eds.) *Advances in Neural Information Processing Systems 3*, 1991, pp. 875-882. San Mateo, CA: Morgan Kaufmann.
- [97] Werbos, P.J.: Beyond regression: new tools for prediction and analysis in the behavioural sciences. Ph.D. thesis, Harvard University, Boston, MA, 1974.
- [98] Widrow, B., and Hoff Jr., M.E.: Adaptive switching circuits. *IRE WESCON Convention Record*, 1960, pp. 96-104.
- [99] Yager R. R, Filev D. P.: *Podstawy modelowania i sterowania rozmytego*. WNT, Warszawa 1996.
- [100] Yingxue Yao, Xiaoli Li, Zhejun Yuan: Tool wear detection fuzzy classification and wavelet fuzzy neural network. *Int. J. of Machine Tools & Manufacture* 39, 1999, s. 1525-1538.
- [101] Zadeh L.: Fuzzy sets. *Information and control*. 1965, pp. 338.
- [102] Zalecki W.: Zastosowanie sieci neuronowych do klasyfikacji jakości wlewków w procesie ciągłego odlewania stali. *Informatyka w technologii materiałów*. Wydawnictwo Naukowe AKAPIT. Kwartalnik nr 1 t.1 Kraków 2001.
- [103] Zubrzycki J., Jonak J.: Analiza możliwości badania obciążenia noży płaskich z wykorzystaniem sztucznych sieci neuronowych. *Zbiór ref. nt.: Technologiczne systemy informacyjne w inżynierii produkcji i kształceniu technicznym*. Red. A. Świć. LTN, Lublin, 2001, s. 298-302.
- [104] Zweig, M.H. and Campbell, G.: Receiver-Operating Characteristic (ROC) Plots: A Fundamental Evaluation Tool in Clinical Medicine. *Clin. Chem* 39 (4), 1993 pp. 561-577.
- [105] Żurada J., Barski M., Jędruch W.: *Sztuczne sieci neuronowe*. PWN, Warszawa 1996.

Streszczenie:

W pracy przedstawiono rozszerzony model urabiania skał stożkowymi nożami obrotowymi. Do identyfikacji modelu wykorzystano sztuczne sieci neuronowe. Cechą nowości opracowanego modelu było uwzględnienie w nim większej liczby wielkości wejściowych, tj. właściwości skrawanego materiału skalnego oraz uwzględnienie w modelu większej liczby rodzajów skał, niż uwzględniono to w dotychczasowych modelach opracowanych, z wykorzystaniem analizy statystycznej. Z wykorzystaniem modelu "neuronowego" zweryfikowano optymalne parametry, z jakimi powinien przebiegać proces urabiania z uwagi na wartości sił obciążających nóż oraz jednostkową energię urabiania. W zakończeniu pracy przedstawiono propozycje dalszych kierunków badań ze szczególnym uwzględnieniem obrotu noża i aspektów zużycia.

Praca skierowana jest do biur konstrukcyjnych i ośrodków badawczo-rozwojowych, zajmujących się projektowaniem głowic urabiających wyposażonych w stożkowe noże obrotowe. Ponadto może być przydatna dla studentów i kadry naukowo-dydaktycznej Wydziałów Górniczych i Mechanicznych Szkół Wyższych, zajmujących się zagadnieniami urabiania skał głowicami wielonarzędziowymi.

Abstract:

Enlarged model of rock cutting by the conical rotating bits have been presented in the work. Artificial neural networks were used to identify the model. A novelty of the developed model was an implementation in it a greater number of data input, that is the properties of cut rock material as well as an implementation in the model a greater number of the rock types than in the present model developed by using the statistical analyses. Optimal parameters, with which the cutting process should run with regard to the values of forces loading the bit and the unit cutting energy, were verified by using the "neural" model. At the end of the work the proposals for directions of further research work with a special regard to the rotation of the bit and a wear aspect were given.

The work is directed to the engineering and R & D centers, which deal with a designing of the cutting heads equipped with the conical rotational bits. Besides it can be of interest for students and scientific and didactic staff of the Mining and Mechanical Departments of Universities dealing with the problems of cutting rocks with multi-tools heads.

ISBN 83-919228-0-4