

Aldona Krawczykowska, Kazimierz Trybalski*, Damian Krawczykowski**

WYKORZYSTANIE MODELI SIECI NEURONOWYCH DO IDENTYFIKACJI SKŁADU LITOLOGICZNEGO RUDY MIEDZI**

1. Wstęp

Artykuł stanowi kontynuację publikacji, związanych z tematyką identyfikacji składu litologicznego krajowej rudy miedzi kierowanej do procesu wzbogacania flotacyjnego, podjętą przez autorów. Część wyników badań została opublikowana w artykułach [2, 3]. W niniejszym artykule zostaną zaprezentowane końcowe wyniki badań, wskazujące na możliwość efektywnej identyfikacji rudy miedzi (składu litologicznego) przy zastosowaniu nowoczesnych technik modelowania sieciami neuronowymi.

2. Modele sieci neuronowych

Nieodłącznym elementem badań są procedury i techniki przetwarzania uzyskanych w trakcie badań wyników, pozwalające na wydobycie z nich informacji niedostępnych przy obróbce tradycyjnej. Wśród tych procedur często wykorzystywane są tzw. procedury inteligentne, do których zaliczane są m.in. sieci neuronowe [4, 5].

Autorzy wykorzystali więc sieci neuronowe do budowy modeli klasyfikujących przynależność ziaren do określonych typów litologicznych rudy miedzi, a w konsekwencji do identyfikacji jej składu litologicznego.

Rozpatrywano dwa zagadnienia modelowania: trójstanowe zagadnienie klasyfikacji — identyfikujące trzy typy rud: węglanową, łupkową i piaskowcową oraz dwustanowe zagadnienie klasyfikacji — identyfikujące dwa typy rud: węglanowo-łupkową i piaskowcową.

* Wydział Górnictwa i Geoinżynierii, Akademia Górniczo-Hutnicza, Kraków

** Publikację przygotowano w ramach pracy statutowej AGH nr 11.11.100.276

TABELA 1
Podsumowanie charakterystyk najefektywniejszych modeli sieci neuronowych dla wszystkich badanych przypadków

Numer sieci	Klasa μm	Wejścia	Neurony ukryte	Jakość uczenia	Jakość walidacji	Jakość testowania	Błąd uczenia	Błąd walidacji	Błąd testowania
Trójstanowe zagadnienie klasyfikacji									
6	0÷45	7	58	0,8536	0,8508	0,7956	0,3005	0,3188	0,3346
6	45÷71	13	58	0,8087	0,7747	0,7582	0,3260	0,3508	0,3650
9	71÷100	11	101	0,9202	0,9107	0,8884	0,2388	0,2738	0,2837
Zespół	0÷100	10	[5]	0,7375	0,7071	0,6840	0,3564	0,3827	0,3927
Dwustanowe zagadnienie klasyfikacji									
8	0÷45	10	110	0,9475	0,8950	0,8895	0,2425	0,3286	0,3282
9	45÷71	10	44	0,8251	0,8462	0,8571	0,3494	0,3608	0,3628
10	71÷100	12	106	0,9665	0,9596	0,9552	0,2079	0,2365	0,2430
Zespół	0÷100	6	[5]	0,7911	0,7714	0,7627	0,3801	0,4084	0,4057

W artykule [3] szczegółowo została omówiona procedura tworzenia oraz diagnostyki modeli sieci neuronowych, a także jakościowa i predykcyjna ocena sieci. W tabelach 1 i 2 przedstawiono podsumowanie oceny najefektywniejszych sieci neuronowych dla wszystkich badanych przypadków.

TABELA 2

Podsumowanie zgodnych klasyfikacji realizowanych przez najefektywniejsze modele sieci neuronowych dla wszystkich badanych przypadków

Klasa ziarnowa, μm	Poprawne klasyfikacje, %				
	trójstanowe zagadnienie klasyfikacji			dwustanowe zagadnienie klasyfikacji	
	ruda węglanowa	ruda łupkowa	ruda piaskowcowa	ruda węglanowo-łupkowa	ruda piaskowcowa
0÷45	83,33	74,63	87,19	92,94	91,21
45÷71	80,74	69,12	81,17	85,96	81,17
71÷100	94,67	81,85	94,30	98,17	93,08
0÷100	69,03	61,58	80,80	79,01	78,15

Z analizy powyższych tabel wynika, że dla wszystkich badanych przypadków uzyskano dobre wyniki modelowania. Poziomy poprawnych klasyfikacji realizowane przez modele dla poszczególnych zagadnień są wysokie, jedynie identyfikacja rudy łupkowej sprawiała modelom wyraźny problem. Szczegółowe wnioskowanie przeprowadzono w artykule [3].

3. Mieszanki typów litologicznych rud

Ruda miedzi wzbogacana w Oddziałach ZWR stanowi mieszaninę trzech odmian litologicznych rudy. Różne udziały typów litologicznych w nadawie kierowanej do poszczególnych procesów technologicznych determinują odmienny charakter jej przerobu.

Symulując udziały poszczególnych odmian, odzwierciedlające rzeczywisty skład litologiczny rudy kierowanej do procesów przeróbki, a przy tym uwzględniając aktualnie stosowaną technologię odrębnej przeróbki dwóch typów litologicznych rud (piaskowcowa i węglanowo-łupkowa), przygotowano do badań odpowiednie mieszanki litologiczne rudy miedzi.

Wykonano po dwie mieszanki w każdej klasie ziarnowej składające się z trzech typów litologicznych rud miedzi: mieszankę nr 1 — o zdecydowanej przewodzie rudy piaskowcowej (zbliżonej do rudy przerabianej w Rejonie Lubin O/ZWR) oraz mieszankę nr 2 — o przewodzie rud węglanowej i łupkowej (zbliżonej do rudy przerabianej w Rejonie Polkowice O/ZWR).

Zawartości poszczególnych typów litologicznych w mieszankach wynosiły:

- mieszanka 1: 15% rudy węglanowej, 15% rudy łupkowej, 70% rudy piaskowcowej (przewaga rudy piaskowcowej),
- mieszanka 2: 35% rudy węglanowej, 35% rudy łupkowej, 30% rudy piaskowcowej (przewaga rudy węglanowo-łupkowej).

Poniżej w tabelach 3–5 przedstawiono statystyki zbiorów danych uzyskanych z analizy zdjęć wykonanych przy pomocy mikroskopu skaningowego przykładowej mieszanki 1 w różnych klasach ziarnowych. Dane charakteryzują kształty oraz intensywność szarości ziaren stanowiących mieszankę.

Sposób wyznaczania i charakterystyka współczynników kształtu K oraz parametrów statystycznych poziomów szarości I zostały omówione szczegółowo w pracy [1, 2].

TABELA 3

Statystyki opisowe parametrów uzyskanych z analizy zdjęć mieszanki 1 w klasie ziarnowej $0\div 45\ \mu\text{m}$

Zmienne	N ważnych	Średnia	Minimum	Maksimum	Odch.Std.
K_1	594	0,619	0,278	0,891	0,114
K_2	594	0,695	0,459	0,891	0,073
K_3	594	1,025	1,000	1,163	0,031
K_{Cl}	594	0,728	0,289	0,987	0,144
K_Z	594	0,567	0,228	0,836	0,118
K_{Cr}	594	16,578	7,164	76,048	10,113
K_E	594	0,488	0,013	0,946	0,241
$I_{Kurt.}$	594	1,448	-1,571	10,957	1,907
$I_{Max.}$	594	215,141	157,000	255,000	26,253
$I_{Śr.}$	594	162,121	124,090	243,246	19,754
$I_{Min.}$	594	113,434	61,000	162,000	16,813
I_{σ}	594	16,180	5,686	43,124	6,111
$I_{Skoś.}$	594	0,405	-3,187	2,554	0,825
K_S	594	0,024	-0,544	0,568	0,183
K_{β}	594	2,366	1,522	5,581	0,611
K_{α}	594	1,764	1,000	4,122	0,703
K_W	594	1,527	1,234	2,362	0,185
K_F	594	1,035	0,270	3,500	0,466

TABELA 4

**Statystyki opisowe parametrów uzyskanych z analizy zdjęć mieszanki 1
w klasie ziarnowej 45÷71 μm**

Zmienne	N ważnych	Średnia	Minimum	Maksimum	Odch.Std.
K_1	663	0,612	0,252	0,881	0,115
K_2	663	0,690	0,449	0,881	0,075
K_3	663	1,018	1,000	1,137	0,027
K_{C1}	663	0,729	0,297	0,995	0,135
K_Z	663	0,570	0,245	0,851	0,114
K_{Cr}	663	27,022	10,309	93,836	15,944
K_E	663	0,493	0,028	0,964	0,224
$I_{Kurt.}$	663	2,395	-1,624	11,821	2,269
$I_{Max.}$	663	231,026	188,000	255,000	17,358
$I_{\acute{S}r.}$	663	185,234	164,382	246,848	13,299
$I_{Min.}$	663	142,261	110,000	176,000	10,994
I_{σ}	663	12,622	6,441	35,608	4,092
$I_{Sko\acute{s}.}$	663	0,445	-3,299	2,548	0,918
K_S	663	-0,015	-0,455	0,504	0,172
K_{β}	663	2,350	1,496	5,204	0,614
K_{α}	663	1,755	1,000	5,521	0,687
K_W	663	1,522	1,223	2,281	0,183
K_F	663	1,120	0,313	2,850	0,454

TABELA 5

**Statystyki opisowe parametrów uzyskanych z analizy zdjęć mieszanki 1
w klasie ziarnowej 71÷100 μm**

Zmienne	N ważnych	Średnia	Minimum	Maksimum	Odch.Std.
K_1	436	0,618	0,268	0,899	0,104
K_2	436	0,688	0,450	0,899	0,071
K_3	436	1,018	1,000	1,097	0,023
K_{C1}	436	0,724	0,330	0,994	0,119
K_Z	436	0,573	0,250	0,841	0,103

TABELA 5 cd.

Zmienne	N ważnych	Średnia	Minimum	Maksimum	Odch.Std.
K_{Cr}	436	62,625	17,506	158,708	32,604
K_E	436	0,483	0,030	0,942	0,218
$I_{Kurt.}$	436	5,640	-1,171	33,810	5,841
$I_{Max.}$	436	213,138	137,000	255,000	30,259
$I_{Śr.}$	436	152,625	118,485	228,319	18,010
$I_{Min.}$	436	123,748	86,000	169,000	15,069
I_{σ}	436	11,926	3,453	27,059	5,070
$I_{Sktoś.}$	436	1,545	-2,911	4,485	1,123
K_S	436	-0,012	-0,537	0,535	0,182
K_{β}	436	2,308	1,514	5,087	0,504
K_{α}	436	1,718	1,000	4,693	0,626
K_W	436	1,511	1,231	2,255	0,155
K_F	436	1,122	0,292	3,444	0,496

Dane charakteryzujące mieszanki w klasie ziarnowej $0 \div 100 \mu\text{m}$ stanowią uśrednione wartości z poszczególnych wąskich klas ziarnowych.

Wygenerowane w procedurze analizy obrazów powyższe dane wykorzystano do weryfikacji zdolności predykcyjnych najefektywniejszych modeli sieci neuronowych scharakteryzowanych w tabeli 1.

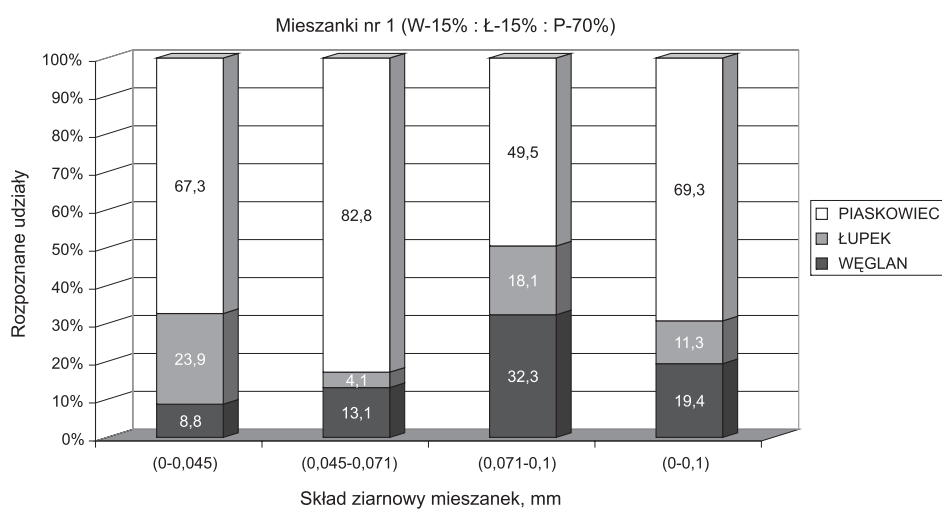
4. Przewidywanie udziałów typów rud w produktach przeróbki rud miedzi

Weryfikacja zdolności predykcyjnych najskuteczniejszych modeli sieci neuronowych opracowanych dla dwóch zagadnień klasyfikacji w poszczególnych klasach ziarnowych, polegała na uruchomieniu sieci na nowych danych charakterystycznych dla poszczególnych mieszanek, które to mieszanki odpowiadały rzeczywistym produktom przeróbki rud miedzi oraz na porównaniu i ocenie uzyskanych przewidywań z rzeczywistymi udziałami poszczególnych typów rud miedzi w analizowanych mieszankach.


Wyniki przewidywań dla nowych danych uwzględniają określoną skuteczność działania sieci związaną z ich jakością oraz generowanymi błędami, a także błędy związane z reprezentatywnością, dokładnością i powtarzalnością przygotowania próbek, wykonania zdjęć mikroskopowych i analizy obrazów (zdjęć).

Poniżej na rysunkach 1–6 przedstawiono wyniki przewidywań udziałów w mieszance odmian litologicznych rud miedzi dla trójstanowego i dwustanowego zagadnienia klasyfikacji.

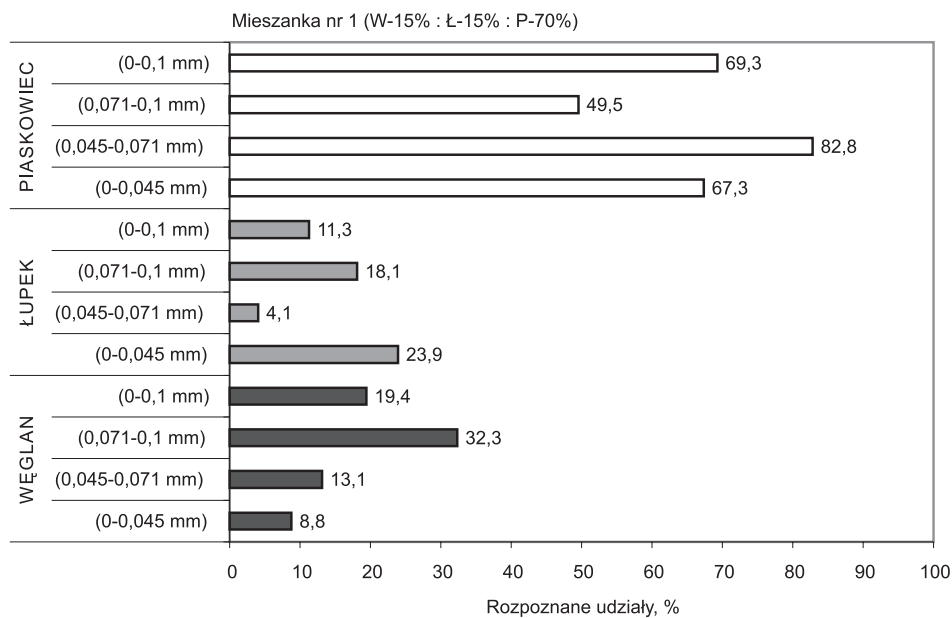
Przewidywanie udziałów typów rud dla trójstanowego zagadnienia klasyfikacji



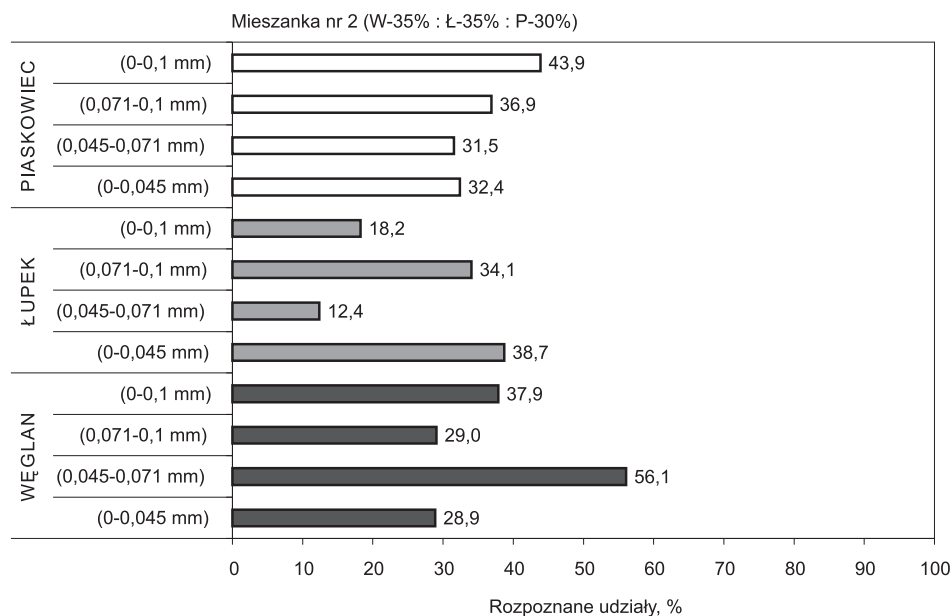
Rys. 1. Rozpoznane udziały trzech typów rud w mieszankach z przewagą rudy piaskowcowej w różnych klasach ziarnowych



Rys. 2. Rozpoznane udziały trzech typów rud w mieszankach z przewagą rudy węglanowo-łupkowej w różnych klasach ziarnowych



Rys. 3. Porównanie rozpoznanych udziałów trzech typów rud z rzeczywistymi w mieszankach o przewadze rudy piaskowcowej dla różnych klas ziarnowych



Rys. 4. Porównanie rozpoznanych udziałów trzech typów rud z rzeczywistymi w mieszankach o przewadze rudy węglanowo-łupkowej dla różnych klas ziarnowych

Jak wynika z analizy powyższych wykresów, w mieszankach nr 1 najbardziej zbliżone wyniki do rzeczywistych osiągnęła sieć w klasie ziarnowej 0÷100 µm, czyli model o stosunkowo gorszych parametrach w porównaniu z modelami dla wąskich klas ziarnowych, natomiast bardziej odbiegające wyniki od założonych uzyskano dla modelu najefektywniejszego — w klasie ziarnowej 71÷100 µm, model przewidział 49,5% udziału rudy piaskowcowej, 18,1% rudy łupkowej i 32,3% rudy węglanowej.

Rosnąca tendencja przewidywać udziałów typów rud w mieszankach nr 1 była więc przeciwnie skorelowana ze wzrostem efektywności poszczególnych modeli.

Dla przewidywać typów rud w mieszankach nr 2 (przewaga rudy węglanowo-łupkowej) najbardziej zbliżone wyniki do rzeczywistych osiągnęły modele sieci neuronowych w klasach ziarnowych 0÷45 µm i 71÷100 µm, a więc modele ocenione jako najefektywniejsze, natomiast bardziej odbiegający wynik od rzeczywistego uzyskano dla modelu w stosunku do mieszanki o szerokiej klasie ziarnowej, czyli modelu o stosunkowo gorszych parametrach. Tendencja przewidywać była więc zgodna z efektywnością poszczególnych sieci. Można więc stwierdzić, że modele realizujące trójstanowe zagadnienie klasyfikacji dla mieszanek nr 2, skutecznie przewidywały udziały poszczególnych typów rud, jedynie model sieci dla klasy ziarnowej 45÷71 µm wykazywał słabość w identyfikacji odmiany węglanowej (56,1%) i łupkowej (12,4%).

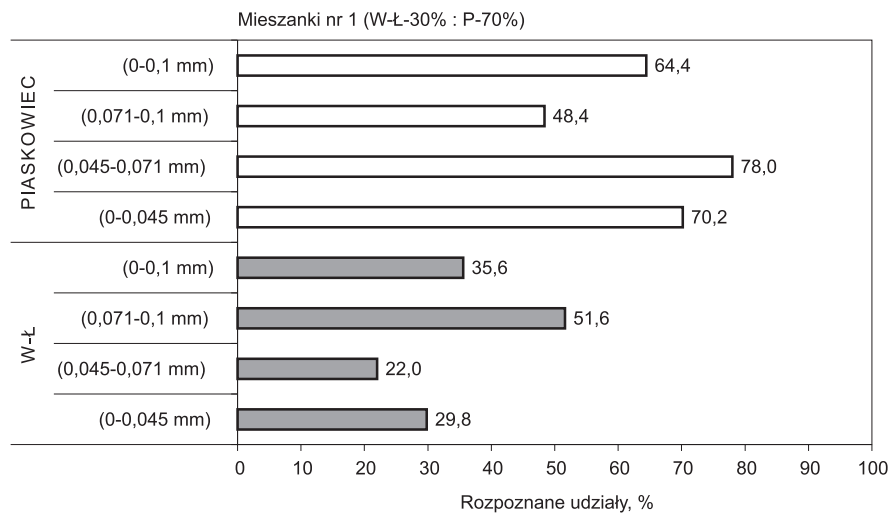
Na podstawie powyższych informacji można wnioskować, że w rzeczywistości udziały poszczególnych typów litologicznych w badanych próbkach mieszanek nr 1 mogły różnić się od tych w przygotowanych mieszankach, co może wynikać z niedostatecznej reprezentatywności udziałów typów rud w analizowanych próbkach mieszanek, wielkość tych próbek ograniczają wymagania preparatyki mikroskopowej. Należy jednak dodać, że wyniki przewidywać dla mieszanek nr 1 potwierdziły przewagę w niej rudy piaskowcowej, co wskazuje mimo wszystko na zadowalającą dokładność procedur.

Analizując powyższe wykresy można również zauważyć, że wyniki przewidywać udziałów szczególnie rudy piaskowcowej dla poszczególnych klas ziarnowych w mieszankach nr 2, są bardziej wyrównane w stosunku do dość niestabilnych wyników osiągniętych przez identyczne modele dla mieszanek nr 1. Zjawisko to potwierdza problem reprezentatywności udziałów typów rud w preparatach mikroskopowych.

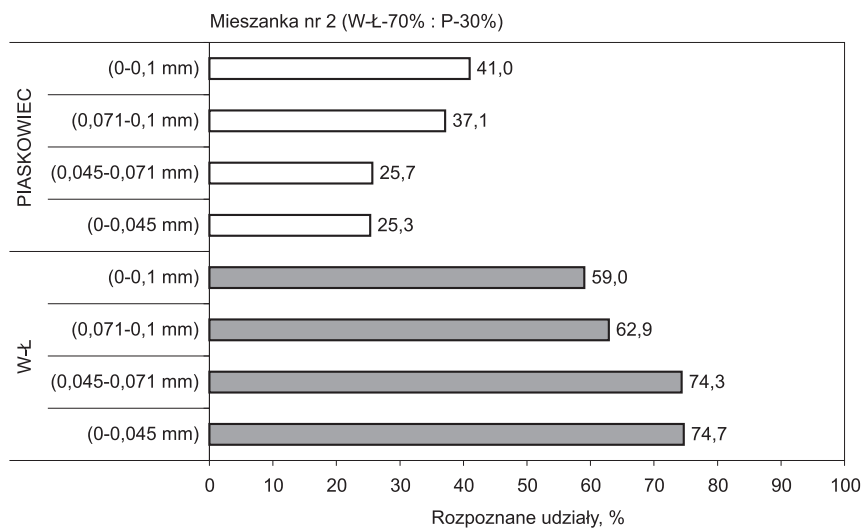
Przewidywanie udziałów typów rud dla dwustanowego zagadnienia klasyfikacji

Spostrzeżenia sformułowane przy okazji analizy wyników przewidywać udziałów typów rud dla trójstanowego zagadnienia klasyfikacji potwierdzają się również w trakcie analizy wyników dla zagadnienia dwustanowego, pomimo iż modele w obu zagadnieniach były odrębnie opracowywane. Uwiarygodnia to sformułowaną powyżej interpretację wyników.

Potwierdziła się, w zagadnieniu rozpoznawania dwóch typów rud dla mieszanek nr 2, tendencja do skuteczniejszego przewidywania udziałów rud przez efektywniejsze modele sieci neuronowych (w wąskich klasach ziarnowych mieszanek) oraz tendencja do gorszego przewidywania udziałów typów rud w mieszankach nr 1 przez model o najlepszych parametrach działania (w klasie 0÷100 µm).



Rys. 5. Porównanie rozpoznanych udziałów dwóch typów rud z rzeczywistymi w mieszankach o przewodzie rudy piaskowcowej dla różnych klas ziarnowych



Rys. 6. Porównanie rozpoznanych udziałów dwóch typów rud z rzeczywistymi w mieszankach o przewodzie rudy węglanowo-łupkowej dla różnych klas ziarnowych

W zagadnieniu dwustanowym zauważyć można również podobną tendencję do zaobserwowanej w zagadnieniu trójstanowym, polegającą na uzyskiwaniu przez modele w mieszankach nr 2 stabilniejszych wyników przewidywań udziałów rud.

5. Podsumowanie

Podsumowując wyniki przewidywania udziałów typów rud w poszczególnych mieszankach dla rozważanych zagadnień klasyfikacji można stwierdzić, że pomimo zauważalnych problemów dokładności i precyzji procedur badawczych ujawnionych przez bardzo efektywne modele, wyniki przewidywań są dobre i potwierdzają w stopniu dobrym, umożliwiającym praktyczne wykorzystanie, przewagę litologiczną określonych odmian rud w badanych mieszankach.

Szczególnie istotny z technologicznego punktu widzenia jest wysoki stopień trafności przewidywań typów rud dla szerokiej klasy ziarnowej, która odpowiada zazwyczaj rzeczywistemu składowi ziarnowemu nadawy do procesu flotacji. Trafność tych przewidywań jest większa dla mieszanek z przewagą rudy piaskowcowej.

Pomimo, iż modele realizujące zagadnienie klasyfikacji dwóch typów rud, charakteryzują się lepszymi parametrami działania niż modele dla trójstanowego zagadnienia klasyfikacji, nie zaobserwowano jednoznacznych różnic w przewidywaniu udziałów odmiany piaskowcowej rudy miedzi w mieszankach dla poszczególnych zagadnień. Można więc stwierdzić, w nawiązaniu do stosowanej w praktyce zakładów wzbogacania rudy miedzi technologii odrębnego przerobu rudy piaskowcowej i węglanowo-lupkowej, że nie ma znaczenia które zagadnienie klasyfikacji będzie wykorzystane przez modele sieci neuronowych w procedurze rozpoznawania udziałów typów rud.

Zastosowane w niniejszych badaniach sieci neuronowe typu RBF (sieci o radialnych funkcjach bazowych) okazały się najefektywniejszymi strukturami do realizacji zagadnień klasyfikacji typów rud miedzi, mogą one modelować dowolną funkcję nieliniową za pomocą pojedynczej warstwy ukrytej, przez co zostaje wyeliminowana konieczność podejmowania decyzji dotyczących liczby warstw na etapie projektowania sieci.

LITERATURA

- [1] *Krawczykowska A.*: Rozpoznawanie obrazów w identyfikacji typów rud i ich właściwości w produktach przeróbki rud miedzi. Praca doktorska, Wydział Górnictwa i Geoinżynierii AGH, Kraków, 2007, Praca niepublikowana
- [2] *Krawczykowska A., Trybalski K.*: Rozpoznawanie udziałów typów rud miedzi w mieszance z wykorzystaniem analizy obrazu i sieci neuronowych. Materiały XIV Konferencji „Automatyzacja Procesów Przeróbki Kopaliny”, Szczyrk, 2008, s. 133–147
- [3] *Krawczykowska A., Trybalski K., Krawczykowski D.*: Zastosowanie sieci neuronowych w zagadnieniach klasyfikacji typów rud miedzi. Wydawnictwo Politechniki Śląskiej, Górnictwo i Geologia, t. 3, z. 3, Gliwice, 2008, s. 27–39
- [4] *Tadeusiewicz R.*: Wprowadzenie do sieci neuronowych. StatSoft Polska Sp. z o.o., Kraków, 2001
- [5] Sieci neuronowe. Materiały konferencyjne z seminarium organizowanego przez StatSoft Polska Sp. z o.o., Warszawa, 1999