

Możliwości wykorzystania sztucznych sieci neuronowych do identyfikacji macerałów grupy inertynitu

MARTA SKIBA, MARIUSZ MŁYNARCZUK

Instytut Mechaniki Górotworu PAN; ul. Reymonta 27, 30-059 Kraków

Streszczenie

Opisane w niniejszej pracy badania są kontynuacją prac, których celem jest opracowanie uniwersalnej oraz powtarzalnej metodyki umożliwiającej automatyczną identyfikację grup macerałowych, a także poszczególnych macerałów węgla kamiennego. W pracy skupiono się na identyfikacji macerałów grupy inertynitu tj. fuzynitu, semifuzynitu, sklerotynitu, makrynitu, mikrynitu oraz inertodetrynitu, zgodnie z klasyfikacją według Stopes-Heerlen System. Sprawdzone zostało wykorzystanie do tego celu sztucznych sieci neuronowych. Do klasyfikacji analizowanych macerałów wykorzystano perceptron wielowarstwowy (MLP). Badania prowadzono na mikroskopowych zdjęciach zglądów węgla. Każdy z analizowanych w pracy macerałów opisano 4-wymiarowym wektorem cech. Wykazano, że automatyczne rozpoznanie macerałów grupy inertynitu z wykorzystaniem zaproponowanej w pracy metodyki jest możliwe, z wynikiem na poziomie 88% rozpoznań zgodnych z rozpoznaniem obserwatora – petrografa. Uzyskany rezultat wskazuje na duży potencjał sztucznych sieci neuronowych w badaniach petrograficznych węgla.

Słowa kluczowe: grupy macerałowe węgla, macerały grupy inertynitu, sztuczne sieci neuronowe, perceptron wielowarstwowy (MLP)

1. Wstęp

Podstawowym składnikiem węgla kamiennego, rozpoznawalnym w powiększeniach mikroskopowych jest macerał. Tworzy on węgiel, tak jak minerały budują skały. Właściwości fizyczne i chemiczne macerałów są zmienne i zależą zarówno od stopnia metamorfizmu węgla, jak i od składu flory węglotwórczej (Nowak, 2012). Macerały obserwowane pod mikroskopem optycznym w świetle odbitym mogą się wyraźnie różnić. Różnice te obserwuje się m.in. w barwie, jej intensywności, refleksyjności, wielkości poszczególnych składników, fluorescencji czy też zróżnicowanym reliefie.

Klasyfikacja macerałów węgla obejmuje ich podział na trzy grupy: witynitu, liptynitu oraz inertynitu (tab. 1), uwzględniające pochodzenie oraz cechy optyczne, wśród których najistotniejsze znaczenie ma refleksyjność.

Tab. 1. Macerały węgla kamiennego (Manecki i Muszyński, 2008)

Grupa	Podgrupa	Macerał
1	2	3
witynit	telowitynit	telinit
		kolotelinit
	detrowitynit	witrodetrynit
		kolodetrynit
	żelowitynit	korpożelinit
		żelinit

1	2	3
liptynit		sporynit
		kutynit
		rezynit
		alginit
		liptodetrynit
		bituminit
		suberynit
inertynit		fuzynit
		semifuzynit
		mikrynit
		makrynit
		funginit
		sekretynit
		inetrodetrynit

Maceraty grupy wityrynytu reprezentują silnie skompresowany roślinny materiał drzewiasty, taki jak np. pnie, łodygi, korzenie i gałęzie drzew, oraz tkanki roślinne zbudowane z ligniny lub celulozy. Posiadają barwę od ciemnoszarej do jasnoszarej, zależną od stopnia uwęglenia. Zdolność odbicia światła wityrynytu w węglu kamiennym mierzona w imersji waha się od 0,5 do ok. 2,5%. Grupa ta w zasadzie nie wykazuje zjawiska fluorescencji podczas naświetlania światłem ultrafioletowym czy niebieskim (Nowak, 2012). Maceraty grupy wityrynytu są najbardziej kruche z wszystkich pozostałych grup, charakteryzują się występowaniem w nich prostopadłych do siebie spękań i szczelin (tzw. szczelinek kontrakcyjnych), tym wyraźniejszych im wyższy stopień uwęglenia. Szczelinki te zwiększają kruchość węgla wityrynitowego (Ryka i Maliszewska, 1991). Wityrynit jest głównym składnikiem mikroskopowym węgla karbońskich. W ich składzie macerałowym przeciętnie spotyka się od 60 do 80% wityrynytu (ICCP, 1998).

Grupę macerałów liptynytu tworzą spory, pyłki, żywice, woski. Liptynit w porównaniu z macerałami pozostałych dwóch grup wykazuje największą zawartość wodoru. W świetle odbitym maceraty tej grupy wykazują szarą i ciemnoszarą barwę, niekiedy o odcieniu brązowym, o wyraźnie zaznaczonej morfologii, zależnej od materiału wyjściowego danego macerału. Maceraty te są mikroskopowo rozpoznawalne w węglach o wartości refleksyjności wityrynytu poniżej 1,25% (granica to około 1,35÷1,45%). W wyższym stadium uwęglenia liptynit jest nierozpoznawalny i upodabnia się do wityrynytu. Grupa macerałów liptynytu wykazuje wyraźną fluorescencję (Maneck i Muszyński, 2008; Nowak, 2012).

Grupę inertynytu reprezentują maceraty inertne, tj. częściowo lub całkowicie obojętne na procesy technologiczne (koksowanie). Maceraty tej grupy w świetle odbitym białym wykazują barwy jasnoszare (zawsze jaśniejsze niż barwa wityrynytu w tym samym węglu), białoszare i białe z przejściami do żółtej. Cechuje je wysoka zdolność odbicia światła (Ryka i Maliszewska, 1991). Maceraty grupy inertynytu cechują się większą, w porównaniu do pozostałych dwóch grup twardością, a ich duża zawartość w pokładzie powoduje zwiększenie wytrzymałości mechanicznej (Olszewska i in., 1965).

Mikroskopowe analizy ilościowe węgla, których celem jest określenie składu macerałowego, prowadzone są zazwyczaj w sposób manualny. Istotną kwestią podczas takich analiz jest poprawna oraz powtarzalna identyfikacja poszczególnych cech petrograficznych. Dotychczasowe badania prowadzone w Instytucie Mechaniki Górotworu PAN wskazują, że nie jest to zagadnienie trywialne.

W pracy podjęto próbę wykorzystania sztucznych sieci neuronowych do identyfikacji wybranych macerałów węgla kamiennego. Zastosowana w badaniach metoda stanowi nowoczesną dziedzinę sztucznej inteligencji o wysokiej skuteczności. Sztuczne sieci neuronowe służą jako narzędzia statystyczne, wykorzystywane są do kojarzenia ze sobą wielu parametrów, identyfikacji cech, predykcji zjawisk oraz przetwarzania obrazów i sygnałów (Bishop, 1998). Wykorzystywane są w naukach przyrodniczych, medycznych, ekonomicznych i technicznych. Jako wciąż rozwijająca się dziedzina znajdują także zastosowanie w zagadnieniach górnictwa i geologii, m.in. do prognozowania odkształceń powierzchni wywołanych eksploatacją podziemną (Gruszczyński, 2007), identyfikacji litofacji w górnictwie naftowym i gazowym, szacowania zasobów złóż rud oraz wód podziemnych (Goldsztejn i in., 2005), a także identyfikacji skał (Marmo i in., 2005; Młynarczuk i in., 2014) oraz spękań (Młynarczuk i in., 2015).

Opisane w niniejszej pracy badania są kontynuacją dotychczasowych prac, których celem jest opracowanie uniwersalnej oraz powtarzalnej metodyki umożliwiającej identyfikację grup macerałowych (Młynarczuk i Godyń, 2012; Młynarczuk i in., 2013; Skiba i Młynarczuk, 2015), a także poszczególnych macerałów węgla kamiennego.

2. Materiał pomiarowy

Węgiel wykorzystany do badań pochodził z górnosląskich kopalń węgla kamiennego, z pokładów o niskim stopniu uwęglenia ($R_o = 0,65$). Próbkę do badań pobrano w KWK Brzeszcze (pokład 401, ściana 128a). Następnie zostały one przesiane, a do analiz wybrano klasę ziarnową $0,5\div 1,0$ mm. Ziarna zalano w kleju i wykonano zgłady, które były przedmiotem dalszych analiz.

Analizy wykonano z wykorzystaniem mikroskopu polaryzacyjnego AXIOPLAN firmy ZEISS, wyposażonego w kamerę CCD firmy Nikon, dedykowaną do obserwacji mikroskopowych. Zdjęcia poszczególnych macerałów wykonano w immersji olejowej, z zachowaniem jednolitych warunków ustawienia mikroskopu i aparatu cyfrowego. Stosowano powiększenie $500\times$, co jest zgodne z normą PN-ISO 7404-3:2001, dotyczącą petrograficznych analiz węgla kamiennego.

Ze względu na skład macerałowy badanych próbek węgla, w pracy skupiono się na identyfikacji macerałów grupy inertynitu. Pozostałe dwie grupy reprezentowane były w przeważającej ilości przez dwa macerały tj. kolotelinit w grupie wityrnytu oraz sporynit w grupie liptyrnytu. W przypadku grupy inetrynitu udało się zidentyfikować prawie wszystkie macerały tworzące tę grupę.

Z uwagi na fakt, że funginit oraz sekretynit posiadają drugorzędne znaczenie w składzie macerałowym węgla kamiennego – występują w niewielkich ilościach (Nowak, 2012), w badaniach posłużono się nieco wcześniejszą, niż opisana w tabeli 1, klasyfikacją macerałów według Stopes-Heerlen System (ICCP, 1975, 1985). Zgodnie z nią funginit i sekretynit tworzą jeden macerał – sklerotynit. Przykłady macerałów poddanych analizie zaprezentowano na rysunku 1.







3. Metodyka badań

Analizy prowadzono bazując na metodyce zaproponowanej w pracach Młynarczuk i in. (2013) oraz Skiba i Młynarczuk (2015). Zmianie uległa liczba rozpoznawanych klas (identyfikacji poddano sześć macerałów grupy inertynitu) oraz zmodyfikowana została architektura zastosowanej sieci neuronowej.

Na zdjęciach poddanych analizie, dla każdego rozpoznawanego macerału, zaznaczono po 300 punktów, dla których zapisano ich położenie (współrzędne XY) oraz nadano właściwą klasyfikację (fuzynit, semifuzynit, sklerotynit, makrynit, mikrynit, inertodetrynit). W ten sposób uzyskano 1800 punktów pomiarowych o znanych klasyfikacjach. Na bazie posiadanych współrzędnych tworzone obszary otaczające analizowany punkt, których analiza decydowała o przynależności punktu do danej klasy. Jako obszar pomiarowy obrano kwadrat o wielkości 51×51 pikseli z rozpoznawanym punktem w jego centrum. Działanie sieci neuronowej sprawdzano porównując decyzje uzyskane automatycznie z decyzjami podjętymi przez obserwatora – petrografa.

W opisywanych badaniach parametry definiujące przestrzeń cech wyznaczono dla kanału L modelu barw CIELab. Dla każdego obszaru pomiarowego wyznaczono 4 parametry, tj.: średni poziom szarości obrazu oraz jego gradientu (parametr 1 i 2), a także odchylenie standardowe dla poziomu szarości obrazu i dla jego gradientu (parametr 3 i 4). W rezultacie dysponowano 4 – wymiarową przestrzenią cech, która stanowiła wektor wejść sieci neuronowej.

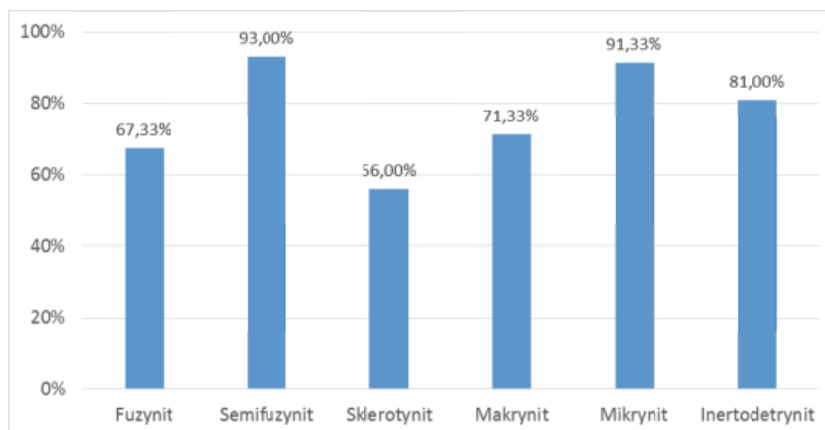
Do klasyfikacji analizowanych macerałów wykorzystano perceptron wielowarstwowy (MLP). Jest to sieć jednokierunkowa, która oprócz warstwy wejściowej i wyjściowej posiada co najmniej jedną warstwę ukrytą neuronów (Tadeusiewicz, 1998). Uczenie perceptronu wielowarstwowego odbywa się z nauczycielem. Ciąg uczący zawarty jest w dwóch macierzach, jedna zawiera zestawy wejść dla kolejnych przykładów uczących, druga – odpowiadające tym przykładom wartości wyjść, jakimi powinna odpowiedzieć sieć (Rutkowski, 2005).

**Fuzynit****Semifuzynit****Sklerotynit (funginit)****Makrynit****Mikrynit****Inertodetrynit****Rys. 1.** Przykłady macerałów grupy inertynitu poddanych analizie (pow. 500×, imersja)

4. Wyniki badań

W pierwszym etapie badań, bazując na doświadczeniach z rozpoznawania grup macerałowych (Skiba i Młynarczuk, 2015), wykorzystano sieć neuronową zbudowaną z 10 neuronów w warstwie ukrytej. Na wyjściu sieci zastosowano 6 neuronów, co odpowiada liczbie rozpoznawanych klas. W warstwie ukrytej sieci użyto tangensoidalną funkcję aktywacji, natomiast w warstwie wyjściowej funkcję liniową. Uczenie sieci przeprowadzono z wykorzystaniem algorytmu wstecznej propagacji błędów Lovenberga-Marquardta na ciągu uczącym składającym się z 360 elementów (po 60 dla każdej klasy). Pozostałe obrazy przeznaczono do rozpoznania. Analizy oraz obliczenia wykonano w programie MATLAB.

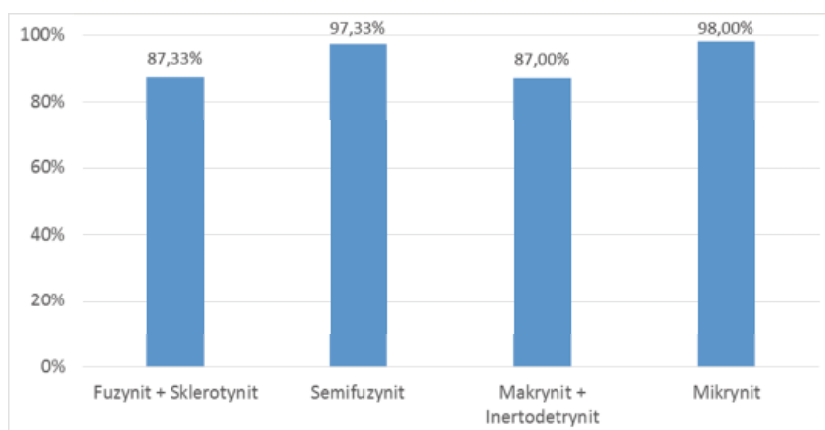
Wyniki poprawności klasyfikacji macerałów grupy inertynitu za pomocą rozpatrywanej sieci zebrano na wykresie z rysunku 2.



Rys. 2. Zestawienie wyników klasyfikacji poszczególnych macerałów grupy inertynitu

Otrzymane wyniki wskazują, że najlepiej klasyfikowanym macerałem jest semifuzynit (na poziomie 93% poprawnych rozpoznań) oraz mikrynit (ok. 91% poprawnych rozpoznań). Wyniki uzyskane dla pozostałych macerałów grupy inertynitu uznano za niezadowalające. Analizując wyniki cząstkowe stwierdzono, że główne błędy proponowanej analizy polegają na mylnej identyfikacji fuzynitu jako sklerotynitu i odwrotnie. Podobne spostrzeżenia dokonano dla makrynitru oraz inertodetrynitru. Błędy klasyfikacji wymienionych macerałów uzasadnić można ich dużym podobieństwem, które często utrudnia ich właściwą klasyfikację podczas analiz mikroskopowych.

Mając na uwadze otrzymane spostrzeżenia podjęto dwuetapową próbę klasyfikacji macerałów grupy inertynitu wydzielając najpierw 4 grupy, tj. wprowadzając grupy uzyskane z połączenia fuzynitu i sklerotynitu, oraz z połączenia makrynitru i inertodetrynitru. Analizy przeprowadzono z zastosowaniem analogicznych jak poprzednio parametrów sieci neuronowej (z tym, że w warstwie wyjściowej sieci zastosowano 4 neurony). Uzyskane wyniki zestawiono na wykresie z rysunku 3.

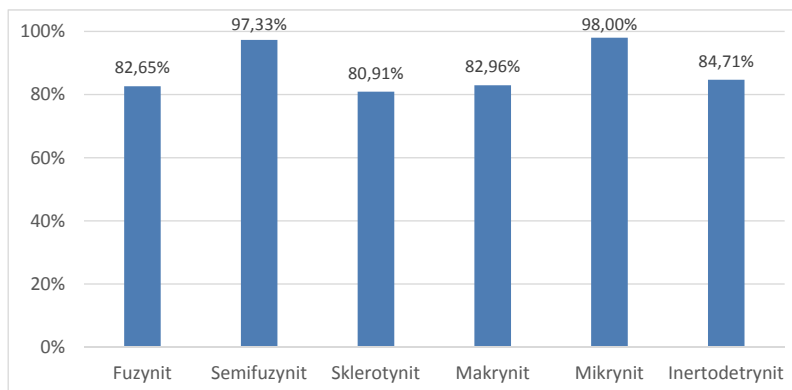


Rys. 3. Zestawienie wyników klasyfikacji macerałów grupy inertynitu (podział na 4 grupy)

Analizując otrzymane wyniki można zauważyć, że połączenie wybranych macerałów w grupy wyraźnie poprawiło średni odsetek poprawnych rozpoznania (przekraczający 92% poprawnych klasyfikacji).

Następnym etapem był podział połączonych w grupy macerałów. W tym celu zaprojektowano dwie sieci MLP. Pierwsza z nich wykorzystana została do wyodrębnienia fuzynitu oraz sklerotynitu. Do badań wybrano sieć zbudowaną z 18 neuronów w warstwie ukrytej. Jej zastosowanie skutkowało poprawnym rozpoznaniem wymienionych macerałów na poziomie 95% dla fuzynitu oraz 93% w przypadku sklerotynitu. Zadaniem drugiej sieci była identyfikacja makrynitru oraz inertodetrynitru. Bazując na wielu próbach ustalono, że optymalne wyniki w tym wypadku zwraca sieć neuronowa o 10 neuronach w warstwie ukrytej. Dla tak zaprojektowanej sieci otrzymano odpowiednio: 97% oraz 95% poprawnych rozpoznania.

Uwzględniając otrzymane wyniki oraz wcześniejsze rezultaty wyznaczono końcowe wyniki klasyfikacji badanych macerałów – rysunek 4.



Rys. 4. Zestawienie wyników klasyfikacji macerałów grupy inertynitu za pomocą sieci MLP

W rezultacie wykorzystania dwuetapowej analizy uzyskano znacznie wyższy odsetek poprawnych rozpoznania macerałów niż w pierwszym podejściu. Poprawne klasyfikacje analizowanych macerałów, wynoszą średnio 87,76%. Nawet w wypadku najgorzej identyfikowanego macerału – sklerotynitu, uzyskano wynik przekraczający 80% poprawnych rozpoznania. Ze względu na specyfikę badanych preparatów, wynik uznano za zadowalający.

5. Podsumowanie

W pracy opisano możliwości wykorzystania sztucznych sieci neuronowych do identyfikacji macerałów grupy inertynitu. Wykazano, że automatyczne rozpoznanie tych macerałów za pomocą perceptrona wielowarstwowego (MLP) jest możliwe z wynikiem na poziomie 88% poprawnych klasyfikacji. Uzyskany rezultat wskazuje na duży potencjał sztucznych sieci neuronowych w badaniach petrograficznych węgla, a wykorzystana w pracy metoda może stanowić wsparcie decyzji obserwatora – geologa podczas mikroskopowych analiz węgla.

Podziękowania

Autorzy pragną podziękować Pani dr Alenie Kožušnikovej z Instytutu Geoniki Czeskiej Akademii Nauk za wiele cennych uwag dotyczących identyfikacji macerałów.

Praca została wykonana w roku 2015 w ramach prac statutowych realizowanych w IMG PAN w Krakowie, finansowanych przez Ministerstwo Nauki i Szkolnictwa Wyższego.

Literatura

- Bishop Ch., 1998: *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford.
- Goldsztein P., Adamczyk-Lorenc A., Derkowska-Sitarz M., 2005: *Zastosowanie sieci neuronowych w geologii – przykłady z literatury światowej*. Prace Naukowe Instytutu Górnictwa Politechniki Wrocławskiej, nr 113, str. 63-73.
- Gruszczyński W., 2007: *Zastosowanie sieci neuronowych do prognozowania asymptotycznych odkształceń poziomych powierzchni wywołanych eksploatacją podziemną*. Wydawnictwa AGH, Kraków.
- ICCP (International Committee for Coal and Organic Petrology), 1975: *International handbook of coal petrography*. CNRS. 2nd Ed., 2nd Suppl., Paris.
- ICCP (International Committee for Coal and Organic Petrology), 1985: *International handbook of coal petrography*. CNRS. Suppls to 2nd Ed., Univ. of Newcastle upon Tyne, England.
- ICCP (International Committee for Coal and Organic Petrology), 1998: *The new vitrinite classification (ICCP System 1994)*, Fuel, vol. 77, pp 349-58.
- Manecki A., Muszyński M. (red.), 2008: *Przewodnik do petrografii*. Uczelniane Wydawnictwo Naukowo-Dydaktyczne AGH, Kraków.
- Marmo R., Alodio S., Tagliaferri R., Ferreri V., Longo G., 2005: *Textural identification of carbonate rocks by image processing and neural network: Methodology proposal and examples*. Computers & Geosciences Vol. 31, Issue 5, 649-659.
- Młynarczuk M., Godyń K., 2012: *Wykorzystanie metod rozpoznawania obrazów do wspierania procesu decyzyjnego dotyczącego klasyfikacji węgla ze względu na wybrane cechy petrograficzne*. Prace Instytutu Mechaniki Górnotworu PAN, Tom 14, nr 1-4, s. 3-14.
- Młynarczuk M., Godyń K., Aksamit J., 2013: *Optymalizacja procesu automatycznej klasyfikacji cech strukturalnych węgla z obszarów zagrożonych wyrzutami gazów i skał opartego na metodach rozpoznawania obrazów*. Prace Instytutu Mechaniki Górnotworu PAN, Tom 15, nr 1-2, s. 85-93.
- Młynarczuk M., Bielecka M., Ślipek B, 2014: *Klasyfikacja mikroskopowych obrazów skał przy wykorzystaniu sieci neuronowych*. Zeszyty Naukowe Instytutu Gospodarki Surowcami Mineralnymi i Energią PAN, Sympozja i Konferencje, nr 86, s. 27-38
- Młynarczuk M, Godyń K, Skiba M 2015: *Wykorzystanie sztucznych sieci neuronowych do klasyfikacji struktur odmienionych węgla kamiennego w strefach przyuskokowych*. Przegląd Górniczy, n. 11, s 15-20.
- Nowak G.J., 2012: *Węgiel kamienny Dolnośląskiego Zagłębia Węglowego w obrazach mikroskopowych*. Prace Państwowego Instytutu Geologicznego, Tom 197, Warszawa.
- Olszewska K., Magnes C., Ziółkowski J., Kuhl J., 1965: *Atlas petrograficzny górnośląskich kamiennych węgla humusowych*. Główny instytut Górnictwa. Wydawnictwo Śląsk, Katowice.
- PN-ISO 7404-3, 2001: *Metody analizy petrograficznej węgla kamiennego (bitumicznego) i antracytu*. Polski Komitet Normalizacyjny.
- Rutkowski L., 2005: *Metody i techniki sztucznej inteligencji*. PWN, Warszawa.
- Ryka W., Maliszewska A., 1991: *Słownik petrograficzny*. Wydawnictwa Geologiczne, Warszawa.
- Skiba M., Młynarczuk M., 2015: *Możliwości wykorzystania sztucznych sieci neuronowych w badaniach petrograficznych węgla kamiennego*. 10. czesko-polska konferencja „Geologia Zagłębia Węglonośnych”, Documenta Geonica, Ostrava.
- Tadeusiewicz R., 1998: *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. Akademicka Oficyna Wydawnicza, Warszawa.

The possibility of using artificial neural networks to identification of inertinite macerals

Abstract

The researches described in this paper are a continuation of work, aimed at developing a universal methodology that allows automatic identification maceral groups as well as individual coal macerals. The study focused on identifying inertinite macerals as classified by Stopes-Heerlen System. The study tested the possibility of using artificial neural networks for this purpose. In order to classify the macerals the Multilayer Perceptron (MLP) was used. Studies have been conducted on microscopic images of coal. Each maceral analyzed in the study was described in a 4-dimensional feature space. It was shown that the automatic recognition of inertinite macerals, using the proposed methodology, is possible with the score at 88% classification identical to the observer classifications. The result obtained shows the great potential of artificial neural network in coal petrography research.

Keywords: coal maceral groups, macerals of inertinite, artificial neural networks, multilayer perceptron