

# Porównanie skuteczności wybranych klasyfikatorów neuronowych w identyfikacji grup macerałów węgla kamiennego oraz materii nieorganicznej

MARTA SKIBA, MARIUSZ MŁYNARCZUK

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

## Streszczenie

Jednym z podstawowych zastosowań sztucznych sieci neuronowych jest rozpoznawanie i klasyfikacja wzorców. W ramach pracy przeprowadzono automatyczną identyfikację grup macerałów oraz materii nieorganicznej za pomocą trzech klasyfikatorów neuronowych: dwuwarstwowej sieci jednokierunkowej (*Multi-Layer Perceptron*, MLP), sieci o radialnych funkcjach bazowych (*Radial Basis Function*, RBF) oraz samoorganizującej mapy Kohonena (*Self-Organizing Maps*, SOM). Do analiz wykorzystano zbiór 3000 mikroskopowych zdjęć próbek węgla kamiennego. Każde z nich opisano 12 – wymiarowym wektorem cech. Dla każdej z rozpatrywanych sieci dokonano 100 – krotnego powtórzenia losowego wyboru ciągu uczącego, treningu sieci oraz rozpoznania badanych obiektów. Analizy wykazały wysoką skuteczność zastosowanych klasyfikatorów neuronowych w identyfikacji grup macerałów oraz materii nieorganicznej. Najlepsze rezultaty, na poziomie przekraczającym 98% poprawnych rozpoznań, uzyskano dla klasyfikatorów bazujących na uczeniu nadzorowanym (MLP oraz RBF). Nieznacznie niższą skuteczność rozpoznań otrzymano w przypadku sieci SOM – 95,9% klasyfikacji zgodnych z decyzjami obserwatora.

**Słowa kluczowe:** sztuczne sieci neuronowe, grupy macerałów, uczenie nadzorowane, uczenie nienadzorowane MLP, RBF, SOM

## 1. Wstęp

Sztuczna sieć neuronowa (SSN) jest matematycznym modelem biologicznej sieci neuronowej, wykorzystywanym w postaci programu komputerowego lub specjalnie zaprojektowanego układu scalonego naśladującego zdolność ludzkiego mózgu do klasyfikacji wzorców, sporządzania prognoz lub podejmowania decyzji na bazie przeszłych doświadczeń (Tadeusiewicz i Lula, 2001). Mózg odbiera i przetwarza bodźce nerwowe otrzymane ze zmysłów, podobnie jak SSN, z tą różnicą, że w przypadku sieci neuronowych są to zdigitalizowane zbiory danych w postaci wektorów określających konkretne porcje informacji (Muszyński i Knapik, 2007).

Jednym z podstawowych zastosowań sztucznych sieci neuronowych jest rozpoznawanie i klasyfikacja wzorców (Bishop, 1995). W zadaniu klasyfikacji sieć uczy się podstawowych cech tych wzorców, takich jak odwzorowanie geometryczne układu pikseli, rozkładu składników głównych wzorca, składników transformacji Fouriera czy innych jego właściwości. W uczeniu podkreślane są różnice występujące w różnych wzorcach, stanowiące podstawę podjęcia decyzji przypisania ich do odpowiedniej klasy (Osowski, 2006).

Na przestrzeni ostatnich lat w Instytucie Mechaniki Górotworu PAN prowadzone są badania dotyczące wykorzystania sieci neuronowych do opisu węgla kamiennego z punktu widzenia jego cech petrograficznych oraz strukturalnych (Skiba i Młynarczuk, 2015a; Młynarczuk i in., 2015). Jednym z kierunków prowadzonych badań było opracowanie metodyki, umożliwiającej automatyczną identyfikację grup macerałów, tj. grupy wityritu, inertynitu oraz liptynitu. Dotychczasowe wyniki na poziomie 99%, uzyskane z wykorzystaniem perceptronu wielowarstwowego (MLP), wskazują na dużą skuteczność klasyfikatorów neuronowych w identyfikacji omawianych struktur (Skiba i Młynarczuk, 2015b).

Celem pracy było porównanie skuteczności wybranych klasyfikatorów neuronowych w procesie identyfikacji grup macerałów. W badaniach uwzględniono sieci uczone w trybie nadzorowanym, a także sieć neuronową bazującą na uczeniu nienadzorowanym, której zastosowanie może ujawnić pewne cechy w zbiorze danych, które są często niedostrzegalne w wypadku użycia sieci neuronowej uczonej z nauczycielem.

## 1. Materiał pomiarowy


Próbki węgla przeznaczone do badań pochodziły z obszaru Górnośląskiego Zagłębia Węglowego, z pokładu o średnim stopniu uwęglenia ( $R_o = 0,91$ ). W przypadku takich węgli poszczególne grupy macerałów są dobrze rozpoznawalne, co jest istotne z punktu widzenia prowadzonych analiz. Próbki wykorzystane do analiz pobrane zostały w kopalni „Budryk” (pokład 358/1). Następnie zostały one przesiane, a klasę ziarnową 0,5-1,0 mm przeznaczono do wykonania zglądów, które stanowiły podstawę dalszych analiz.

Na zglądach, za pomocą mikroskopu polaryzacyjnego, wykonano serię zdjęć w immersji olejowej. Stosowano powiększenie 500 $\times$ , zgodne z procedurą wykonywania analiz węgla kamiennego zawartą w normie PN-ISO 7404-3:2001. W badaniach rozpoznawano 5 klas obiektów: grupę wityrynit, inertynit, liptynit, minerały oraz klej, w którym zatopione były ziarna węgla.

## 2. Metodyka badań

Badania prowadzono w oparciu o metodykę opisaną w pracy Skiba i Młynarczuk (2015b). W przywołanej pracy podjęto próbę klasyfikacji grup macerałów z wykorzystaniem sieci MLP. W ramach obecnie prowadzonych badań sprawdzono natomiast jak rozpatrywane zagadnienie klasyfikacji zinterpretowane zostanie przez inne klasyfikatory neuronowe, w tym także klasyfikator wykorzystujący uczenie nienadzorowane.

W tym celu na wcześniej sporządzonych zdjęciach mikroskopowych losowo zaznaczono zbiór punktów, po czym dokonano ich klasyfikacji do jednej z pięciu grup. Dla każdego punktu zapisano jego położenie i klasyfikację nadaną przez obserwatora. Następnie, dla każdej z rozpatrywanych klas wybrano po 600 punktów, które stanowiły centra kwadratowych pól pomiarowych o boku 41 pikseli, na bazie których decydowano o przynależności punktu do danej klasy. Porównując decyzje uzyskane za pomocą sieci neuronowych z decyzjami wskazanymi przez obserwatora oceniano poprawność działania wybranego klasyfikatora neuronowego. Przykłady punktów poddanych analizie zaprezentowano na rysunku 1.



Rys. 1. Przykłady obszarów obejmujących wityrynit i inertynit, pole pomiarowe o rozmiarze 41 $\times$ 41 pikseli

W badaniach zastosowano analogiczne parametry przestrzeni cech jak opisane w pracy Skiba i Młynarczuk (2015b), tj.: średni poziom szarości obrazu oraz jego gradientu (parametr 1 i 2) oraz odchylenie standardowe dla poziomu szarości obrazu i dla jego gradientu (parametr 3 i 4), które zostały wyznaczone dla 3 kanałów modelu barw CIELab. W celu uniknięcia dominacji któregoś z wyznaczonych cech, wartości parametrów unormowano w przedziale [0, 100]. W ten sposób uzyskano 12 – wymiarową przestrzeń cech, która stanowiła wektor wejściowy dla zastosowanych klasyfikatorów neuronowych.

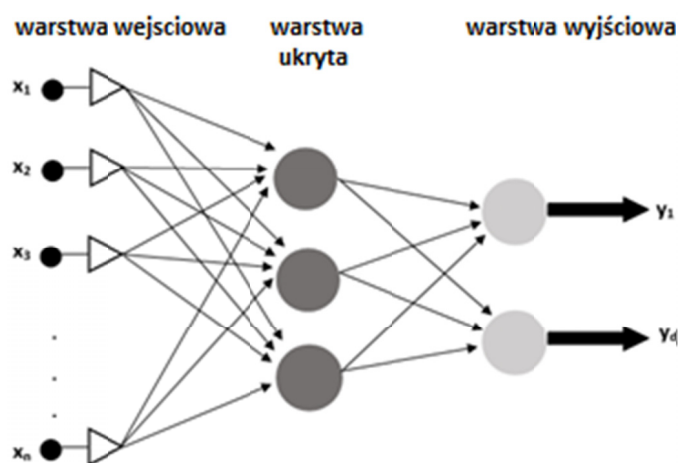
### 3. Wykorzystane klasyfikatory neuronowe

Automatyczna klasyfikacja badanych struktur przeprowadzona została za pomocą trzech sieci neuronowych o różnej architekturze i odmiennym algorytmie działania. Do badań wytypowano 2 sieci uczone w trybie nadzorowanym, tj. dwuwarstwową sieć jednokierunkową (*Multi-Layer Perceptron*, MLP) i sieć o radialnych funkcjach bazowych (*Radial Basis Function*, RBF), a także sieć wykorzystującą uczenie nie-nadzorowane – samoorganizującą mapę Kohonena (*Self Organizing Map*, SOM).

Analizy oraz symulacje dotyczące działania wybranych klasyfikatorów neuronowych przeprowadzono w programie MATLAB ver. 8.5.

#### 3.1. Dwuwarstwowa sieć jednokierunkowa

Perceptron wielowarstwowy MLP jest siecią jednokierunkową, która oprócz warstwy wejściowej i wyjściowej posiada co najmniej jedną warstwę ukrytą neuronów (Tadeusiewicz, 1998) – Rys. 2. Uczenie perceptronu wielowarstwowego odbywa się najczęściej z nauczycielem. Zbiór uczący zawarty jest w dwóch macierzach: pierwsza z nich zawiera zestawy wejść dla kolejnych przykładów uczących, druga – odpowiadające tym przykładom wartości wyjść, jakimi powinna odpowiedzieć sieć (Tadeusiewicz, 1993; Korbicz i in., 1994).



Rys. 2. Przykładowa sieć MLP z jedną warstwą ukrytą neuronów

W badaniach wykorzystano sieć zawierającą jedną warstwę ukrytą. Każdy przykład opisano 12-elementowym wektorem cech, w warstwie ukrytej zastosowano 12 neuronów, a na wyjściu sieci 5 neuronów (odpowiadających licznie rozpoznawanych klas). W warstwie ukrytej sieci użyto tangensoidalną funkcję aktywacji, natomiast w warstwie wyjściowej – funkcję liniową. Do treningu sieci wybrano algorytm Levenberga – Marquardta.

#### 3.2. Sieć o radialnych funkcjach bazowych

Sieć radialna z definicji jest siecią zawierającą jedną warstwę ukrytą neuronów radialnych. Sieć RBF stosuje lokalną funkcję aktywacji neuronów, najczęściej w postaci funkcji gaussowskiej –  $G(r)$ , opisaną wzorem (Osowski, 2006):

$$G(r) = \exp\left(\frac{-r^2}{2\sigma^2}\right) \quad (1)$$

gdzie:  $r = \|x - c\|$ ,  $x$  – wektor wejściowy,  $c$  – centrum neuronu radialnego,  $\sigma > 0$  – parametr.

Posiada ona warstwę wyjściową zawierającą neurony liniowe z liniową funkcją aktywacji (Haykin, 1994; Bishop, 1995). Działanie sieci polega na wielowymiarowej aproksymacji przez złożenie lokalnych odpowiedzi neuronów ukrytych. Proces uczenia sieci neuronowych RBF jest bardziej złożony niż sieci MLP,

co jest związane z odmienną budową obu typów sieci neuronowych. Ogólna procedura trenowania sieci RBF składa się z kilku etapów obejmujących wyznaczenie centrów neuronów radialnych oraz obliczenie wartości biasu, parametrów odpowiadających szerokości funkcji radialnych poszczególnych neuronów ukrytych, współczynników wagowych pomiędzy warstwą ukrytą a wyjściową.

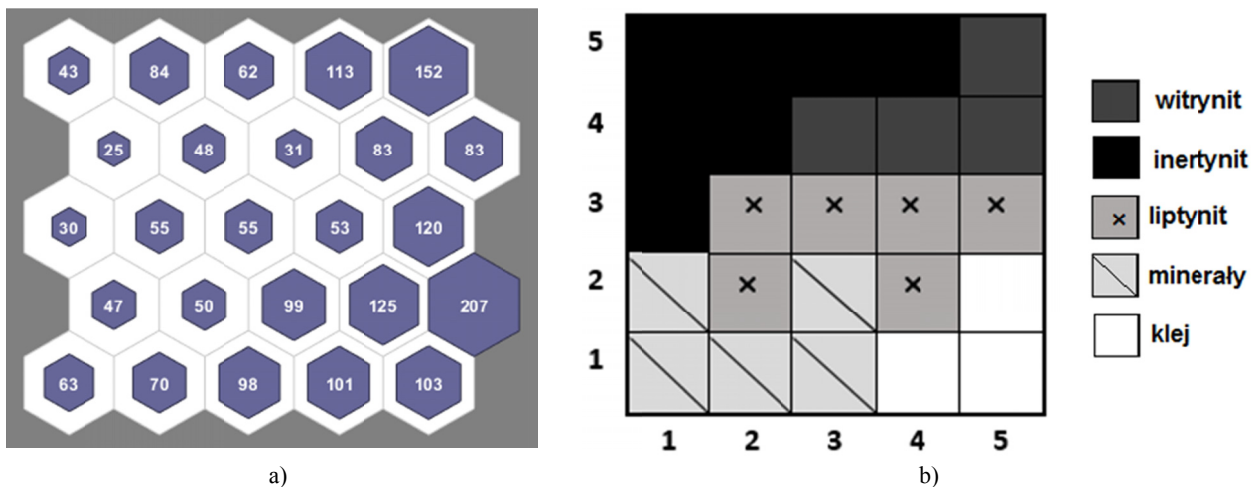
W przeprowadzonych badaniach z użyciem sieci RBF, podobnie jak dla sieci MLP, każdy z analizowanych obiektów opisano 12 – wymiarowym wektorem cech. W warstwie ukrytej zastosowano neurony radialne typu gaussowskiego. Optymalna wartość parametru  $\sigma$  (szerokość funkcji radialnej) dla rozpatrywanego zadania klasyfikacji wyniosła 20, co związane było z zastosowaniem 98 neuronów w warstwie ukrytej. Dla mniejszej liczby neuronów sieć nie jest w stanie poprawnie dopasować się do danych uczących, natomiast w przypadku większej liczby neuronów zmniejszeniu ulegają zdolności generalizacyjne sieci.

### 3.3. Samoorganizująca mapa Kohonena

Sieć SOM jest siecią neuronową uczoną w trybie nienadzorowanym (bez nauczyciela). Wykorzystywany zbiór uczący obejmuje wyłącznie wartości zmiennych wejściowych i nie zawiera żadnych wiadomości dotyczących wartości oczekiwanych na wyjściach sieci.

Sieć Kohonena posiada prostą strukturę – zbudowana jest z 2 warstw tj. warstwy wejściowej i warstwy wyjściowej. Przepływ sygnału w tego typu sieci przebiega jednokierunkowo, od wejścia do wyjścia sieci neuronowej. Ważną kwestią w przypadku sieci samoorganizujących jest nadmiarowość danych uczących (Kohonen, 1995). Bez zapewnienia odpowiedniej ilości danych uczących, zawierających wielokrotne powtórzenia podobnych wzorców, proces uczenia sieci byłby niemożliwy. Podstawą algorytmu uczenia stosowanego w sieci SOM jest konkurencja oraz przeprowadzanie modyfikacji wag, nie tylko dla neuronu zwycięskiego, lecz również dla jego sąsiadów, zgodnie z regułą Kohonena (Kohonen, 1982).

Istotnym zagadnieniem podczas projektowania sieci samoorganizującej jest właściwy dobór liczby neuronów w warstwie wyjściowej. Ważne jest uaktywnienie wszystkich neuronów, co zapewnia, że błąd kwantyzacji będzie dużo mniejszy, niż w przypadku występowania pojedynczych neuronów pasywnych. Liczba użytych neuronów nie powinna być także zbyt mała, ponieważ niektóre klasy mogą zostać pominięte i włączone do większych grup obiektów. W przypadku sieci SOM, ze względu na nienadzorowany algorytm uczenia sieci, zwykle stosuje się liczbę neuronów większą niż ilość rozpoznawanych klas. W przeprowadzonych badaniach dotyczących klasyfikacji grup macerałów, po przeprowadzeniu szeregu prób jako optymalną wybrano sieć o wymiarach  $5 \times 5$ . Na rysunku 3a zaprezentowano otrzymaną mapę topologiczną zawierającą informacje o częstości zwycięstw każdego z 25 neuronów. Następnie, na podstawie informacji, które elementy z ciągu uczącego spowodowały uaktywnienie konkretnego neuronu, poszczególne neurony zostały przypisane do jednej z pięciu klas. Na tej podstawie uzyskano rozmieszczenie analizowanych skupisk obiektów w obrębie mapy – rysunek 3b.

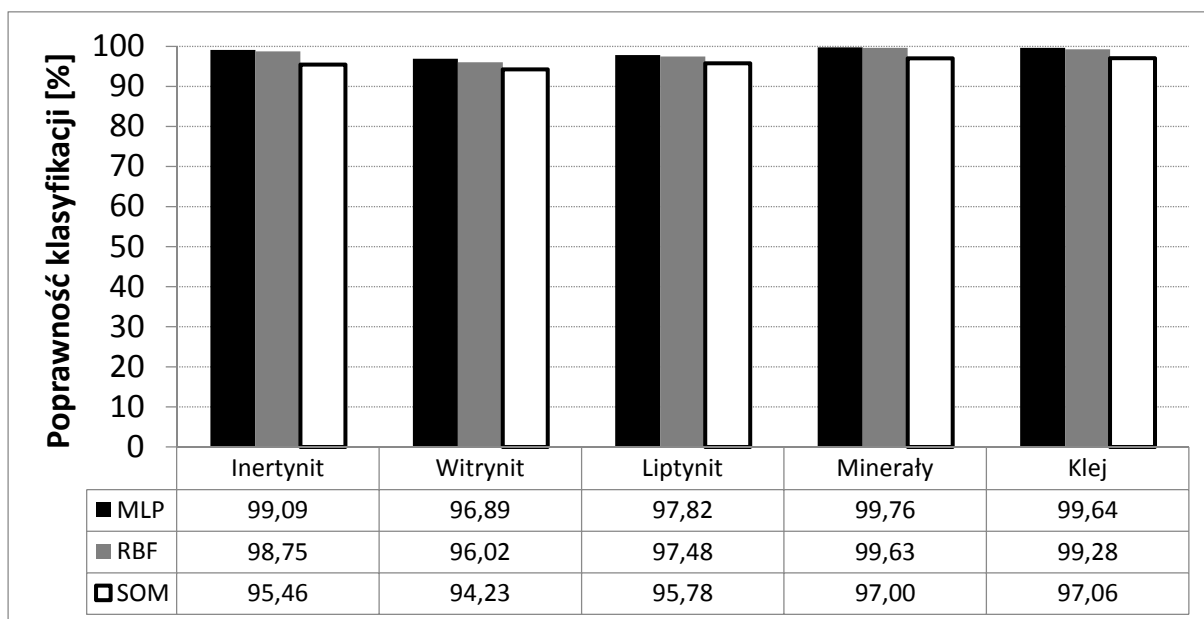


Rys. 3. Schemat pobudzenia neuronów dla sieci SOM o optymalnej wielkości (a) oraz rozmieszczenie poszczególnych skupisk obiektów (b)

#### 4. Wyniki badań

W przypadku każdej z zastosowanych sieci neuronowych do treningu wykorzystano ciąg uczący zawierający po 400 elementów, losowo wybranych z każdej klasy. Pozostałe obiekty, po 200 dla każdej z rozpatrywanych grup obiektów, poddano procesowi rozpoznawania. O poprawności rozpoznań automatycznych wnioskowano na podstawie zgodności pomiędzy klasyfikacjami uzyskanymi za pomocą sieci neuronowych, a rozpoznaniem wskazanymi przez obserwatora.

Wyniki skuteczności poszczególnych sieci neuronowych w klasyfikacji badanych struktur zestawiono na rysunku 4 oraz w tabeli 1. Zaprezentowane rezultaty podano jako wartości średnie, uzyskane w wyniku 100 powtórzeń losowania ciągu uczącego oraz treningu danej sieci neuronowej.



Rys. 4. Zestawienie wyników klasyfikacji badanych grup obiektów, przeprowadzonych za pomocą wybranych sieci neuronowych

Tab. 1. Porównanie wyników średniej skuteczności wybranych sieci neuronowych w klasyfikacji poszczególnych grup obiektów

|                           | MLP   | RBF   | SOM   |
|---------------------------|-------|-------|-------|
| Poprawne klasyfikacje [%] | 98,64 | 98,23 | 95,91 |

Analiza otrzymanych wyników wskazuje, że każda z zastosowanych sieci neuronowych bardzo dobrze poradziła sobie z opisaniem zadaniem klasyfikacji. Dla każdej z badanych grup obiektów sieci uczone w trybie nadzorowanym (MLP oraz RBF) zwracały lepsze wyniki klasyfikacji niż sieć o nienadzorowanym algorytmie uczenia (SOM). Najlepiej rozpoznawanymi grupami obiektów były minerały oraz klej, natomiast najczęściej błędnych rozpoznań zaobserwowano w przypadku witrynit (Rys. 4). Na uwagę zasługuje jednak fakt, że błędy te, w zależności od zastosowanej sieci neuronowej, dotyczyły jedynie ok. 3-6% obiektów wspomnianej grupy. Dla klasyfikatorów neuronowych uczonych z nauczycielem uzyskano zbliżone wartości średniej skuteczności klasyfikacji, na poziomie przekraczającym 98% poprawnych rozpoznań. Nieco niższy rezultat – 95,91% poprawnych klasyfikacji – otrzymano w przypadku mapy samoorganizującej (Tab. 1). Należy jednak mieć na uwadze, że SOM jest siecią uczoną we trybie bez nauczyciela, co oznacza, że sieci nie podaje się informacji dotyczących oczekiwanych odpowiedzi.

## 5. Podsumowanie

W pracy porównano skuteczność wybranych klasyfikatorów neuronowych w klasyfikacji grup mace-  
rałów oraz materii nieorganicznej. Wszystkie z zastosowanych sieci neuronowych w zadowalającym stopniu  
poradziły sobie z postawionym zadaniem klasyfikacji. Najlepsze rezultaty, na poziomie przekraczającym  
98% poprawnych rozpoznań, uzyskano dla klasyfikatorów bazujących na uczeniu nadzorowanym (MLP  
oraz RBF). Sieć o radialnych funkcjach bazowych stanowi alternatywę dla klasycznej sieci MLP, upraszcza  
dobór struktury sieci oraz znacznie skraca czas jej treningu. Nieznacznie mniejszą poprawność rozpoznań  
otrzymano dla sieci samoorganizującej (SOM). W tym przypadku średnia skuteczność sieci wyniosła 95, 91%.  
Z uwagi na nienadzorowany tryb uczenia tego typu sieci, uzyskany rezultat należy uznać za satysfakcjonujący.

Praca została wykonana w roku 2016 w ramach prac statutowych realizowanych w IMG PAN w Krako-  
wie, finansowanych przez Ministerstwo Nauki i Szkolnictwa Wyższego.

### Literatura

- Bishop Ch., 1995: *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford.
- Haykin, S., 1994: *Neural Networks: A Comprehensive Foundation*. New York: Macmillan Publishing.
- Kohonen T., 1982: *Self-organized formation of topologically correct feature maps*. Biological Cybernetics, 43:59-69.
- Kohonen T., 1995: *Self-organizing maps*. Springer Verlag, Berlin.
- Korbicz J., Obuchowicz A., Uciński D., 1994: *Sztuczne sieci neuronowe. Podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- Młynarczyk M., Godyń K., Skiba M., 2015: *Wykorzystanie sztucznych sieci neuronowych do klasyfikacji struktur odmienio-  
nych węgla kamiennego w strefach przyuskokowych*. Przegląd Górniczy, n. 11, s 15-20.
- Muszyński K., Knapik K., 2007: *Metoda SSN w bieżącym prognozowaniu zapotrzebowania na wodę*. IV Ogólnopolska  
Konferencja Naukowo-Techniczna „Aktualne zagadnienia w uzdatnianiu i dystrybucji wody”, Szczyrk 10-12 maj 2007.
- Osowski S., 2006: *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- PN-ISO 7404-3, 2001: *Metody analizy petrograficznej węgla kamiennego (bitumicznego) i antracytu*. Polski Komitet Nor-  
malizacyjny.
- Skiba M., Młynarczyk M., 2015a: *Możliwości wykorzystania sztucznych sieci neuronowych do identyfikacji mace-  
rałów grupy inertynitu*. Prace Instytutu Mechaniki Górotworu PAN, Vol. 17, No. 3-4.
- Skiba M., Młynarczyk M., 2015b: *Możliwości wykorzystania sztucznych sieci neuronowych w badaniach petrograficznych  
węgla kamiennego*. 10. czesko-polska konferencja „Geologia Zagłębi Węglonośnych”, Documenta Geonica, Ostrava.
- Tadeusiewicz R., 1993: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa.
- Tadeusiewicz R., 1998: *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. Akademicka  
Oficyna Wydawnicza, Warszawa.
- Tadeusiewicz R., Lula P., 2001: *Wprowadzenie do sieci neuronowych*. StatSoft, Kraków.

## Comparison of the effectiveness of selected neural classifiers for maceral groups and inorganic matter identification

### Abstract

One of the main applications of artificial neural networks is the recognition and classification of different pat-  
terns. In the framework of the work an automatic identification of maceral groups and inorganic matter was carried.  
Three neural classifiers were used: a Multi-Layer Perceptron (MLP), a network of Radial Basis Function (RBF)  
and Kohonen Self-Organizing Maps (SOM). For the purposes of the analysis a collection of 3,000 images of mi-  
croscopic samples of coal was used. Each image was described by 12-dimensional feature vector. For each network  
were carried out: a hundredfold draw of learning set, the network training and classification of objects under study.  
The analyses have shown high effectiveness of the neural classifiers used to identify maceral groups and inorganic  
matter. The best results were obtained for the classifiers based on supervised learning (MLP and RBF). They were  
at a level exceeding 98% of correct diagnoses. Slightly lower efficiency of diagnosis was obtained in the case of  
SOM network – 95.9% of classification compatible with the observer decisions.

**Keywords:** artificial neural network, macerals groups, supervised learning, unsupervised learning, MLP, RBF, SOM