



Mariusz MŁYNARCZUK\* , Marzena BIELECKA\* , Bartłomiej ŚLIPEK\*

## ***Klasyfikacja mikroskopowych obrazów skał przy wykorzystaniu sieci neuronowych***

Streszczenie: Klasyfikacja skał stanowi ważny aspekt w wielu zagadnieniach górnictwa i geologii inżynierskiej. Automatyzacja procesu klasyfikacji mikroskopowych obrazów skał może przyczynić się do usprawnienia przetwarzania ogromnych zbiorów fotografii skał, poprzez jego przyspieszenie i wyeliminowanie wpływu subiektywnej oceny obserwatora na końcowy wynik klasyfikacji. Podczas pierwszego etapu badań opisanych w tym artykule wykorzystano zbiór 2700 mikroskopowych obrazów szlifów cienkich 9 skał, różniących się od siebie cechami petrograficznymi. Próbkę skał zostały opisane 13-wymiarowym wektorem cech. Przy użyciu trzech różnych sieci neuronowych: dwuwarstwowej sieci jednokierunkowej (*multi-layer feed-forward perceptron*, MLP), samoorganizującej mapy Kohonena (*self organizing Kohonen maps*, SOM) oraz kwantyzacji wektorowej (*learning vector quantization*, LVQ), fotografie, po wcześniejszym treningu sieci odseparowanymi podzbiórami próbek, zostały poddane procesowi automatycznej klasyfikacji. Stukrotne powtarzanie losowania podzbiórów wykorzystywanych do treningu sieci oraz powtarzanie algorytmu uczenia sieci i rozpoznawania zdjęć pozwoliło na uzyskanie statystycznie wiarygodnych wyników, których wartość średnia wyniosła 99,4%. Następnie zbiór skał został zwiększony do łącznej wielkości 6300 zdjęć reprezentujących 21 różnych skał, a badania zostały powtórzone z zachowaniem wektora cech oraz parametrów nauki sieci. Wynik średni poprawnych klasyfikacji dla powiększonego zbioru obrazów wyniósł 98,30%.

Słowa kluczowe: automatyczna klasyfikacja skał, obrazy mikroskopowe, sieci neuronowe, sztuczna inteligencja, SOM, MLP, LVQ

## ***Classification of the microscopic images of rocks with the use of neural networks***

Abstract: Rock classification is an inherent part of numerous aspects of geology and engineering geology. Automating the classification of the microscopic images of rocks may result in improvements in analyzing vast sets of rocks' images by speeding up their recognition and eliminating the influence of the observer's subjective judgment

---

\* AGH Akademia Górniczo-Hutnicza, Wydział Geologii, Geofizyki i Ochrony Środowiska, Katedra Geoinformatyki i Informatyki Stosowanej, Kraków; e-mail: mlynar@agh.edu.pl

in the final classification results. A set of 2,700 microscopic images of thin sections of 9 rocks, which differ in petrographic features, was used during the first step of the study described in the following article. Samples were displayed in a thirteen-dimensional feature space. With the use of three different neural networks multi-layer feed-forward perceptron (MLP), self-organizing Kohonen maps (SOM), and learning vector quantization (LVQ) ? images were subjected to an automated classification process preceded by the network's training with the use of isolated subset samples. Centuple repetition of subset drawings, which were used to train the network by repeating the self-learning network and images recognition algorithm, led to the achievement of statistically trustworthy results with a mean at the level of 99.4 %, and for the best drawing at 99.71%. Afterwards, the rocks set was extended to a total volume of 6,300 images of 21 different rocks, and the test was repeated preserving the feature space and self-learning network parameters. The average score of correct classifications for the extended images set was 98.30%, with the best score at 98.95%.

Key words: automatic classification of rocks, microscopic images, neural networks, artificial intelligence, SOM, MLP, LVQ

## **Wprowadzenie**

Rozkwit komputeryzacji pozwolił na rozwój i stosowanie metod sztucznej inteligencji w zagadnieniach górnictwa i geologii inżynierskiej. Wykorzystywana ona była m.in. do budowy systemów wspomagających decyzje dotyczące rewitalizacji kopalni odkrywkowych [7], czy też przewidywania i eliminowania zagrożeń wynikających z gromadzenia się gazów kopalnianych [8], lub też do predykcji zagrożeń wyrzutami gazów i skał [5]. Metody sztucznej inteligencji były również wykorzystywane w badaniach dotyczących odnajdywania obrazów podobnych struktur skalnych [3] lub podobnych sygnałów sejsmicznych [4].


Jedną z głównych gałęzi sztucznej inteligencji stanowią sieci neuronowe [9]. Wykorzystywane są z powodzeniem w wielu dziedzinach nauki i techniki. Również w zagadnieniach górniczych, geotechnicznych [17], geofizycznych [10] oraz ochrony środowiska [12]. Mało jest jednak prac zajmujących się wykorzystaniem sieci neuronowych do automatycznego rozpoznawania i klasyfikacji mikroskopowych zdjęć skał, czyli zagadnienia będącego tematem opisywanych w niniejszym artykule badań. Jednym z przykładów podobnych prac może być artykuł Marmo i inni [14], w którym autorzy wykorzystali wielowarstwowy perceptron w celu automatycznej identyfikacji zdjęć skał węglanowych. Znane są również przykłady zastosowania sieci neuronowych do badań, mających na celu automatyczne rozpoznawanie i klasyfikację minerałów widocznych na szlifach cienkich [15, 16].

### **1. Cel badań i materiał badawczy**

Celem opisywanych badań było sprawdzenie możliwości wykorzystania sieci neuronowych do automatycznej klasyfikacji mikroskopowych zdjęć skał. Podstawę materiału badawczego stanowiły mikroskopowe zdjęcia szlifów cienkich wybranych skał. Uzyskane one zostały za pomocą polaryzacyjnego mikroskopu Zeiss z zamontowaną kamerą CCD (ang. *Charge Coupled Device*) dedykowaną do akwizycji zdjęć mikroskopowych. Zdjęcia wykonano z różnymi, optymalnymi dla każdej ze skał parametrami (powiększenie, natężenie światła), a warunki akwizycji były niezmiennie dla danej skały. Rozdzielczość zdjęć wynosiła 1280 × 960 pikseli. Fotografie wykonano w przestrzeni barw RGB, jednak zgodnie z wynikami uzyskanymi w [1] zostały one przekonwertowane do przestrzeni barw CIELab,

która w świetle prac wielu badaczy zajmujących się tematyką analizy mikroskopowych zdjęć struktur geologicznych powinna przyczynić się do uzyskania lepszych rezultatów automatycznego rozpoznawania i klasyfikacji zdjęć [20].

Do pierwszego etapu prac wykorzystano zbiór 9 skał różniących się od siebie cechami petrograficznymi (fot. 1): dolomit z Laskowej Góry, dolomit z Rędzin, granit ze Strzelina, kwarcyt z Wiśniówki, marmur Biała Marianna, piaskowiec z Tumlina, porfir z Miękini, wapień z Buszewa, wapień z Czatkowic.



Fot. 1. Mikroskopowe zdjęcia 9 skał analizowanych w pierwszym etapie badań

Phot. 1. Microscopic images of 9 rocks analyzed in the first stage of the study

W drugim etapie badań do opisanej grupy 9 skał dodano 12 nowych szlifów. Materiał badawczy w drugim etapie badań stanowiły więc próbki 21 skał. Należy podkreślić, że niektóre z tych skał były do siebie wizualnie podobne, co stanowiło dodatkowe wyzwanie dla algorytmów klasyfikacji. Końcową grupę stanowiły skały takie jak: anhydryt, porfir, sjenit, marmur, dolomit (4 rodzaje), granit (2 rodzaje), łupek (2 rodzaje), piaskowiec (3 rodzaje) i wapień (6 rodzajów).

## 2. Przestrzeń cech

Wyznaczenie ilościowych parametrów charakteryzujących każdą fotografię umożliwiło zastosowanie automatycznych metod klasyfikacji. Na ilościowy opis składało się 13 parametrów:

- parametry 1 do 3 – średni poziom szarości pikseli (wyznaczony kolejno dla 3 kanałów przestrzeni barw CIELAB),
- parametry 4 do 6 – odchylenie standardowe średniego poziomu szarości (wyznaczony kolejno dla 3 kanałów przestrzeni barw CIELAB),
- parametry 7 do 9 – średni poziom szarości pikseli na obrazie gradientu morfologicznego (wyznaczony dla 3 kanałów L, a oraz b),
- parametry 9 do 12 – odchylenie standardowe z gradientu morfologicznego (wyznaczony dla 3 kanałów L, a oraz b),
- parametr 13 – wariogram obliczany dla składowej luminancji.

Aby zapobiec dominacji jednej cechy nad drugą, wartości wszystkich parametrów poddano normalizacji w przedziale [0, 1].

Autorzy zdają sobie sprawę z faktu, że niektóre cechy mogą być ze sobą mocno skorelowane. Jednym z możliwych rozwiązań problemu korelacji może być zastosowanie metody PCA (ang. *Principal Component Analysis*), za pomocą której wielowymiarowe tablice skorelowanych elementów są transformowane do postaci tablic o mniejszej liczbie wymiarów, niosących ze sobą taką samą informację o opisywanym obiekcie. Po wyznaczeniu wektora cech możliwe stało się umieszczenie wszystkich próbek w 13-wymiarowej przestrzeni cech. Każda cecha stanowi tutaj jeden wymiar. Podczas prezentacji rozmieszczenia próbek posłużono się tylko dwoma wymiarami dobranymi tak, aby zachować jak najlepszą czytelność rysunku.

## 3. Wykorzystane sieci neuronowe

Automatyczna klasyfikacja zdjęć, a więc ich rozpoznanie, a następnie przypisanie do jednej z określonych wcześniej grup, zostało zrealizowane za pomocą trzech sieci neuronowych, różniących się architekturą i sposobem działania. Były to:

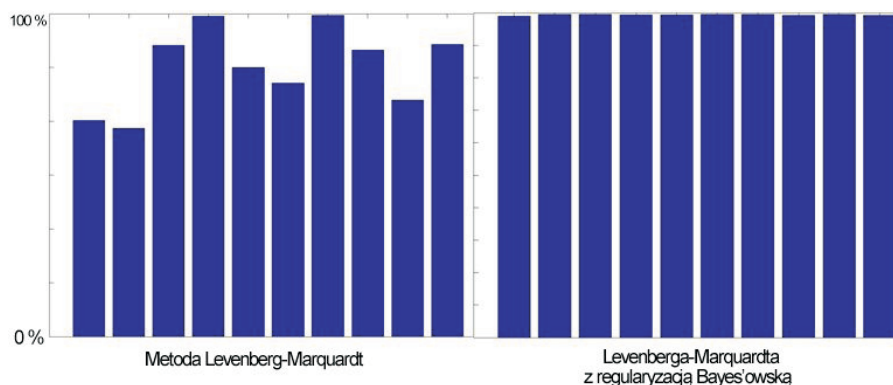
- dwuwarstwowa sieć jednokierunkowa (perceptron) (ang. *multi-layer perceptron*, MLP),
- kwantyzacja wektora uczącego (ang. *learning vector quantization*, LVQ),
- samoorganizująca mapa Kohonena (ang. *self organizing map*, SOM).

### 3.1. Dwuwarstwowa Sieć Jednokierunkowa

Perceptron wielowarstwowy MLP jest siecią jednokierunkową, składającą się z neuronów typu sigmoidalnego ułożonych w warstwach. Oprócz warstwy wejściowej i wyjściowej MLP posiada przynajmniej jedną warstwę ukrytą. Przepływ sygnałów w tych sieciach odbywa się tylko w jednym kierunku od wejścia do wyjścia [21, 22]. Uczenie perceptronu wielowarstwowego odbywa się z nauczycielem, a podstawą uczenia jest zbiór par uczących

( $x$ ,  $d$ ), w których  $x$  jest wektorem wejściowym, a  $d$  zadany wektorem wyjściowym [9]. W badaniach wykorzystano wersję MLP zawierającą dwie warstwy neuronów. Wektor wejściowy jest 13-elementowy, w warstwie ukrytej znajduje się 20 neuronów, a na wyjściu 9 lub 21 (odpowiadających liczbie rozpoznawanych skał w pierwszym i drugim etapie badań). Zarówno w warstwie ukrytej jak i wyjściowej użyto neuronów typu sigmoidalnego. Do uczenia sieci wykorzystano algorytm wstecznej propagacji błędów Levenberg-Marquardt z regulacją Bayes'owską [25, 26].

Wykorzystana metoda nauczania sieci nie jest metodą standardową, zaimplementowaną w środowisku Matlab, w którym wykonywane były obliczenia. Wykorzystanie standardowego algorytmu Levenberg-Marquardt odznaczało się dużą niestabilnością procesu nauki (rys. 1). Przez niestabilność rozumieć należy wrażliwość sieci na małe zmiany w ciągu uczącym (dane treningowe), co w konsekwencji prowadziło do obniżenia średniego wyniku liczby poprawnych klasyfikacji dla tej sieci. Zastosowanie metody opartej na twierdzeniu Bayesa pozwoliło na ustabilizowanie procesu nauki sieci oraz uzyskanie lepszych wyników, zarówno średnich jak i najlepszych.




Rys. 1. Porównanie działania metod propagacji wstecznej błędów: Levenberg-Marquardt oraz odmiany tej metody z regulacją Bayes'owską.  
Na osi X – powtórzenia automatycznej klasyfikacji wraz z losowaniem ciągu uczącego,  
na osi Y – procent prawidłowej klasyfikacji

Fig. 1. Comparison of backward propagation of errors method: Levenberg-Marquardt and variation of this method with the Bayesian regulation.  
On the X axis – repetition of automated classification with drawing of the self-learning training data; on the Y axis – percentage of correct classification

### 3.2. Kwantyzacja wektora uczącego

Kwantyzacja wektora uczącego polega, w dużym uproszczeniu, na zastąpieniu całego ciągu wektorów uczących (próbek) przez kilka reprezentacyjnych. W badaniach ciąg uczący zawierający 50 elementów (dla każdej skały) zastąpiono ciągiem 3-elementowym. Algorytm działania tej metody jest dosyć prosty. W początkowej fazie z ciągu uczącego wybiera się określoną liczbę wektorów (w opisywanych badaniach 3 z 50), które stanowiąc będą tzw.

wektory kodujące danej klasy (skały). Następnie dla każdego z pozostałych elementów ciągu (wektora uczącego) ( $50 - 3 = 47$  elementów) szukany jest najbliższy sąsiad. Jeśli etykieta wektora uczącego jest zgodna z etykietą wektora kodującego, tj. jeśli wektor kodujący i uczący reprezentują tę samą grupę (skałę), obliczana jest odległość obu wektorów od siebie (z zachowaniem odpowiedniej metryki, w opisywanym przypadku – euklidesowej). Odległość ta przemnożona przez współczynnik uczący (w niniejszych badaniach równy 0,01 i zmniejszany w miarę postępu uczenia) zostaje dodana do wektora kodującego. W przypadku niezgodności klas odległość jest odejmowana. Innymi słowy, wektor kodujący jest przyciągany przez wektory uczące ze zgodną klasą, a odpychany przez inne (rys. 2). Należy pamiętać, że przedstawiona na rysunku 2 sytuacja przedstawia tylko 2 z 13 wymiarów przestrzeni, przy czym odległość liczona jest dla wszystkich 13 wymiarów.



Rys. 2. Obserwacja położenia neuronów kodujących w przestrzeni 2 wymiarowej, na tle wektorów ciągu uczącego, w fazie przed i po treningu sieci.

Na osi X – wariogram obliczany dla obrazu w skali szarości, na osi Y – średni poziom szarości dla pierwszego kanału. Wartości znormalizowane w skali od 0 do 1

Fig. 2. Observation of the coding neurons' positions in the two-dimensional space referring to self-learning data vectors in phase, before and after network training.


On the X axis – variogram calculated for the image in gray-scale; on the Y axis – average level of grayness for the first channel. Values normalized in the 0–1 scale

Algorytm ten, podobnie jak proces nauki sieci MLP, jest algorytmem nadzorowanym (z nauczycielem), ponieważ w procesie uczenia wymagane jest rozróżnienie elementów wektora kodującego i uczącego na poszczególne klasy (skały).

### 3.3. Samoorganizująca mapa Kohonena

Sieci SOM są specjalnym typem sieci, w których uczenie odbywa się bez nadzoru. Oznacza to, że do dyspozycji mamy jedynie wzorce wejściowe. Są to zwykle sieci jedno-warstwowe, w których każdy neuron połączony jest ze wszystkimi składowymi wektora wejściowego. Ważną rolę ogrywa nadmiarowość danych uczących, które zawierają wielokrotne powtórzenia podobnych wzorców [5]. Podstawą uczenia SOM jest konkurencja między neuronami. Neuron zwycięzca i wszystkie neurony w obszarze sąsiedztwa podlegają adaptacji, tzn. ich wektory wag są zmieniane zgodnie z regułą Kohonena [6].

Prawidłowy dobór wielkości mapy (liczby neuronów w sieci) stanowi istotny problem podczas stosowania narzędzi tego typu. Sieć powinna być skonstruowana w taki sposób, aby nie pozostawiać neuronów pasywnych, czyli niepobudzonych. Liczba neuronów nie powinna być też zbyt mała, gdyż grozi to pominięciem niektórych klastrów (grup) i włączeniem ich do większych skupisk. W przypadku opisywanych badań minimalną liczbę neuronów łatwo było ustalić; była ona równa liczbie badanych skał (9 lub 21). Ponieważ SOM jest algorytmem nienadzorowanym, bezpieczniej było przyjąć większą liczbę neuronów. W przeciwnym przypadku algorytm mógł podzielić grupy próbek niektórych skał na mniejsze skupiska, tak aby lepiej dopasować wagi sieci do danych wejściowych. Na rysunku 3 można zaobserwować nadmiarowość neuronów (3a), kiedy część neuronów pozostaje pasywna (niepobudzona, na rysunku neuron biały), oraz sieć bez neuronów pasywnych, z równomiernie pobudzonymi wszystkimi neuronami (3b). W niniejszych badaniach, po przeprowadzeniu wielu prób, zdecydowano się na wykorzystanie sieci o wymiarach  $5 \times 4$  dla 9 skał, oraz  $6 \times 6$  dla 21 skał.



Rys. 3. Prezentacja pobudzenia neuronów, w ilości nadmiarowej (3a) oraz optymalnej (3b), w sieci SOM

Fig. 3. Presentation of neural excitation in SOM network: in excessive manner (3a) and optimal manner (3b)

Ponieważ SOM jako wynik działania zwraca neuron, który został najmocniej pobudzony przez dany wektor wejściowy, istniała potrzeba przyporządkowania tego neuronu do jednej z 9 lub 21 klas (skał). Rozważmy przypadek, kiedy SOM zwróci na wyjściu neuron nr 2. Aby przyporządkować konkretny neuron do danej klasy należało sprawdzić, które wektory z ciągu uczącego spowodowały wzbudzenie neuronu nr 2. Możliwa była sytuacja, w której wektor nr 2 wzbudzony został przez jeden lub więcej wektorów uczących, należących do klasy odpowiadającej np. piaskowcowi z Tumlina. W takim przypadku decyzja była prosta – wektor nr 2 odpowiada klasie piaskowca z Tumlina. W przypadku, kiedy wzbudzenie neuronu powodowały wektory z różnych klas autorzy zdecydowali się na obliczenie mody etykiet tych wektorów. Przez modę należy rozumieć wartość najczęściej występującą. Dla przykładu możemy założyć, że wzbudzenie neuronu nastąpiło dla dwóch wektorów piaskowca z Tumlina i jednego wektora opisującego Dolomit z Rędzin. W tym przypadku moda obliczonych etykiet wskazuje na piaskowiec z Tumlina, a więc uznajemy, że neuron nr 2 odpowiada właśnie tej skale. Opisana metoda, stosowana na potrzeby niniejszych badań, zwracała bardzo dobre wyniki poprawnej klasyfikacji.

#### **4. Metodyka badań**

Bazując na opisanych w poprzednim rozdziale metodach, przystąpiono do zasadniczych pomiarów. Każde ze zdjęć zostało opisane wektorem w 13-wymiarowej przestrzeni cech. Każdy z wymiarów przestrzeni został unormowany w przedziale  $[0,1]$ . Każdą klasę, a więc każdą skałę, reprezentowało 300 fotografii.

Do treningu sieci wykorzystano ciąg uczący składający się z 50 elementów, losowo wybranych z każdej klasy. Próbkę wybrane do ciągu uczącego nie wchodziły później w skład zbioru próbek służących do testowania metody.

Teoretycznie, ciąg uczący stanowić powinny próbki najbardziej reprezentacyjne dla danej klasy. Jednak określenie takiego zbioru jest trudne i stanowić może osobną tematykę badań. Dlatego też, aby otrzymać statystycznie wiarygodny wynik, stosowano stukrotne powtórzenia losowania ciągu uczącego.


Po wytrenowaniu sieci, procesowi rozpoznawania poddawane było pozostałe 250 zdjęć każdej skały. Poprawna klasyfikacja wszystkich 250 zdjęć nie była znana dla algorytmu, ale znana była autorom. Zgodność pomiędzy klasyfikacją wyznaczoną automatycznie przez algorytm a rzeczywistą świadczyła o poprawności rozpoznań. Jako wynik podana została procentowa liczba poprawnie zaklasyfikowanych próbek. W wynikach badań podano dwie wartości: uśrednioną i najlepszą. Wartość uśredniona dotyczyła wszystkich 100 powtórzeń w/w procesu, a więc losowania ciągu uczącego i treningu sieci. Wartość najlepsza dotyczyła najlepszego wyniku ze wszystkich 100 losowań.

##### **4.1. Wyniki uzyskane dla 9 skał**

Badania przeprowadzone zostały w dwóch etapach. Etapy różniły się od siebie tylko i wyłącznie liczbą skał biorących w nich udział: 9 i 21. Pozostałe parametry, takie jak wektor cech oraz parametry nauki sieci, zostały zachowane.



W pierwszym etapie badano skały, które wizualnie różnią się od siebie. Ich rozróżnienie nie stanowi większego problemu dla obserwatora. Na rysunku 4 zestawiono wyniki poprawnych klasyfikacji w grupie tych 9 skał, z podziałem na wynik średni ze wszystkich 100 losowań oraz wynik najlepszy.



Rys. 4. Wynik poprawnej klasyfikacji, wykonanej za pomocą różnych sieci neuronowych, dla 9 wybranych skał. Na osi X – prawidłowe rozpoznanie

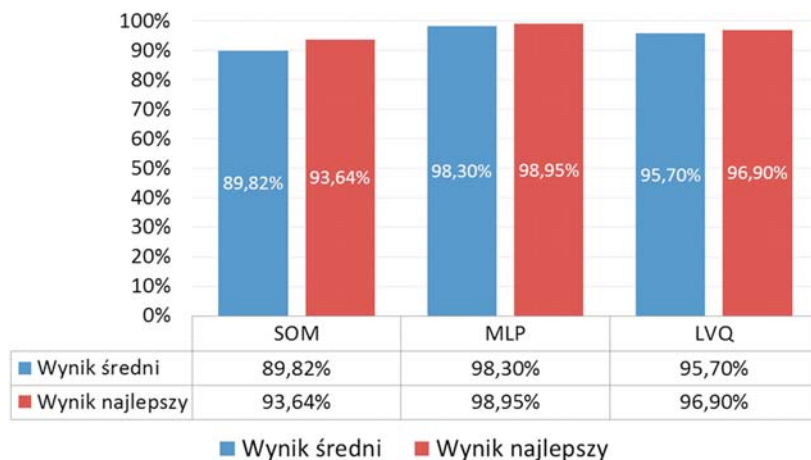
Fig. 4. Results of correct classification performed using various neural networks for 9 selected rocks. On the X axis – correct recognition

Analizując wykres z rysunku 4 można zauważyć, że wszystkie sieci poradziły sobie z problemem klasyfikacji bardzo dobrze. Średnie wyniki poprawnej klasyfikacji oscylowały na poziomie 97,80%. Najlepszy uśredniony wynik, równy 99,4%, uzyskała sieć MLP. Najgorszy uśredniony wynik, równy 96,06, jest rezultatem działania sieci SOM. Różnica pomiędzy wynikiem najlepszym a najgorszym, mimo że wynosi tylko 3,34%, jest jednak znacząca przy tak wysokiej poprawności klasyfikacji.

Wyniki dla najlepszego losowania ciągu uczącego (wektora treningowego) są bardzo podobne. Najlepiej poradziła sobie sieć MLP – 99,73, najgorzej sieć SOM 97,87%. Należy jednak zauważyć, że sieć SOM jest typem sieci bez nauczyciela. Oznacza to, że sieć nie wymaga na wejściu podania wektorów ciągu uczącego.

#### 4.2. Wyniki uzyskane dla 21 skał

Automatyczna klasyfikacja 21 skał stanowiła większe wyzwanie dla zastosowanych neuronalnych systemów klasyfikacji wzorców. Należy podkreślić, że wykorzystane w pierwszej części badań skały były wizualnie dość zróżnicowane, jednak obrazy w drugiej części badań pochodziły często od skał do siebie podobnych. Wykorzystano np. 6 rodzajów wapieni o zbliżonym do siebie wyglądzie. Pogorszenie wyników stanowi więc oczekiwany rezultat przy tego typu powiększaniu liczby badanych skał. Jednak wyniki przedstawione na wykresie z rysunku 5 wydają się być bardzo zadowalające. Należy wspomnieć, że w przypadku



Rys. 5. Wynik poprawnej klasyfikacji, wykonanej za pomocą różnych sieci neuronowych, dla 21 wybranych skał. Na osi X – prawidłowe rozpoznanie

Fig. 5. Results of correct classification performed using various neural networks for 21 selected rocks. On the X axis – correct recognition

metod klasyfikacji opartych na rozpoznawaniu obrazów (patrz [1]) wynik ten pogarszał się w sposób liniowy, proporcjonalnie do wzrostu liczby badanych skał.

Najlepszy średni wynik poprawnych klasyfikacji uzyskała sieć MLP – 98,3%, również do tej sieci należy najlepszy rezultat ze wszystkich losowań, równy 98,95%. Wynik średni i najlepszy są bardzo zbliżone. Wskazuje to na stabilność sieci. Najgorszy wynik ponownie uzyskała samoorganizująca sieć SOM – średni równy 89,82 i najlepszy ze wszystkich losowań równy 93,64. Pomiędzy tymi metodami plasuje się sieć LVQ z wynikiem średnim równym 95,7% i najlepszym równym 96,9%.

Należy zwrócić uwagę, że w porównaniu do 9 skał, najlepszy wynik dla sieci MLP pogorszył się tylko o 0,78%. Różnica wyników najlepszych dla 9 i 21 skał równa 4,23%, jest bardziej znacząca w przypadku sieci SOM. Sieć LVQ pogorszyła swój wynik najlepszy nieznacznie, a różnica wyniosła 1,03%.

Opisywane badania stanowią kontynuację badań przedstawionych w pracy [1], w których autorzy wykorzystali metody rozpoznawania obrazów do automatycznej klasyfikacji podobnego zbioru mikroskopowych obrazów skał. Uzyskane w tamtych badaniach wyniki klasyfikacji były zbliżone do tych uzyskanych w niniejszych badaniach. Najlepszy uzyskany w badaniach opisanych w [1] wynik poprawnych klasyfikacji wynosił 99,8% dla 9-elementowej grupy skał. Jednak zwiększenie grupy badanych skał do zbioru 21-elementowego pogorszyło wyniki o około 1,5%. Możliwe jest więc stwierdzenie, że dla badanej grupy skał metody bazujące na wykorzystaniu sieci neuronowych są mniej podatne na pogorszenie rezultatów klasyfikacji spowodowane zwiększeniem zbioru analizowanych skał.

## Podsumowanie

Opisane badania wykazały, że automatyczna klasyfikacja skał (w obrębie grupy), przy użyciu metod sztucznej inteligencji, takich jak sieci neuronowe, jest możliwa i daje satysfakcjonujące wyniki na poziomie 99%. Wynik taki uzyskała sieć MLP, wytrenowana za pomocą ciągu uczącego złożonego z 50 elementów dla każdej skały. Klasyfikacja dotyczyła 250-elementowego zbioru testowego dla każdej skały.

Podczas badań wykazano również, że ponad dwukrotne zwiększenie liczby badanych obiektów pogorszyło wynik automatycznej klasyfikacji tylko o około 1%. Należy także podkreślić, że sieć SOM, mimo że osiągnęła najgorsze wyniki, jest perspektywiczna w kontekście systemów klasyfikacyjnych stosowanych do zadań, w których liczba klastrów może się zwiększać w trakcie działania sieci. Do realizacji tego typu klasyfikacji służą sieci rezonansowe typu ART [23, 24], w których sieci Kohonena są ich podukładami.

*Pracę wykonano w ramach prac statutowych Wydziału Geologii, Geofizyki i Ochrony Środowiska AGH nr 11.11.140.032.*

## Literatura

- [1] Młynarczuk, M., Górszczyk, A. i Ślpek, B. 2013. The application of pattern recognition in the automatic classification of microscopic rock images. *Computers & Geosciences* Vol. 60, 126–133.
- [2] Babanouri, N., Karimi Nasab, S. i Sarafrazi, S. 2013. A hybrid particle swarm optimization and multi-layer perceptron algorithm for bivariate fractal analysis of rock fractures roughness. *International Journal of Rock Mechanics and Mining Sciences* Vol. 60, 66–74.
- [3] Młynarczuk, M. i Ładniak, M. 2014. Wykorzystanie metod sztucznej inteligencji do wyszukiwania obrazem wybranych struktur skał. *Przegląd Górniczy* Vol. 70, 58–64.
- [4] Leśniak, A. 2014. Identyfikacja sejsmicznych zjawisk podobnych rejestrowanych w kopalniach podziemnych. *Przegląd Górniczy* Vol. 70, 34–40.
- [5] Wierzbicki, M. i Skoczylas, N. 2006. Potencjalne możliwości zastosowania logiki rozmytej w ocenie zagrożenia wyrzutowego w kopalniach. *Przegląd Górniczy* vol. 12, 12–17.
- [6] Kohonen, T. 1995. *Self-organizing maps*. Springer Verlag, Berlin.
- [7] Bielecka, M. i Król-Korczak, J. 2010. Hybrid expert system aiding design of post-mining regions restoration. *Ecological Engineering* Vol. 36, Issue 10, 1232–1241.
- [8] Özgen Karacan, C. 2007. Development and application of reservoir models and artificial neural networks for optimizing ventilation air requirements in development mining of coal seams. *International Journal of Coal Geology* Vol. 72, Issues 3–4, 22, 221–239.
- [9] Tadeusiewicz, R. 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa.
- [10] Jarzyna, J., Opyrchał, A. i Mozgowej, D. 2007. Sztuczne sieci neuronowe dla uzupełnienia danych w geofizyce otworowej – wybrane przykłady. *Kwartalnik AGH Geologia* vol. 33, 81–102.
- [11] Villmann, Th. 2002. Neural maps for faithful data modelling in medicine — state-of-the-art and exemplary applications, *Neurocomputing* Vol. 48, Issues 1–4, 229–250.
- [12] Atakan, Kurt, Ayşe, Betül Oktay. 2010. Forecasting air pollutant indicator levels with geographic models 3 days in advance using neural networks. *Expert Systems with Applications* Vol. 37, Issue 12, 7986–7992.
- [13] Ghielmi, L. i Eccel, E. 2006. Descriptive models and artificial neural networks for spring frost prediction in an agricultural mountain area. *Computers and Electronics in Agriculture* Vol. 54, Issue 2, 101–114.
- [14] Marmo, R., Amodio, S., Tagliaferri, R., Ferreri, V. i 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.
- [15] Baykan, N. i Yılmaz, N. 2010. Mineral identification using color spaces and artificial neural networks. *Computers & Geosciences* Vol. 36, Issue 1, 91–97.

- [16] Thompson, S., Fueten, F. i Bockus, D. 2001. Mineral identification using artificial neural networks and the rotating polarizer stage. *Computers & Geosciences* Vol. 27, Issue 9, 1081–108.
- [17] Gajewski, J., Jedliński, Ł. i Jonak, J. 2013. Classification of wear level of mining tools with the use of fuzzy neural network. *Tunnelling and Underground Space Technology* Vol. 35, 30–36.
- [18] Bishop, Ch. 1998. *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford.
- [19] Luukka, P. 2009. PCA for fuzzy data and similarity classifier in building recognition system for post-operative patient data. *Expert Systems with Applications* Vol. 36, Issue 2, 1222–1228.
- [20] Obara, B. 2007. Identification of transcrystalline microcracks observed in microscope images of a dolomite structure using image analysis methods based on linear structuring element processing. *Computers & Geosciences* Vol. 33, Issue 2, 151–158.
- [21] Osowski, S. 2006. *Sieci neuronowe do przetwarzania informacji*. OWP, Warszawa.
- [22] Rutkowski, L. 2005. *Metody i techniki sztucznej inteligencji*. PWN, Warszawa.
- [23] Carpenter, G.A., Grossberg, S. i Reynolds, J.H. 1991. ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks* Vol. 4, 565–588.
- [24] Carpenter, G.A., Grossberg, S. i Rosen, D.B. 1991. Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Networks* Vol. 4, 759–771.
- [25] MacKay, D. 1992. *Neural Computation* Vol. 4, No. 3, 415–447.
- [26] Foresee, D. i Hagan, M. 1997. *Proceedings of the International Joint Conference on Neural Networks*.