

Wykorzystanie metod sztucznej inteligencji do wyszukiwania obrazem wybranych struktur skał

The use of artificial intelligence to search by image for the selected structures of rocks



*Dr hab. inż. Mariusz Młynarczyk, prof. AGH**



*Mgr inż. Magdalena Ładniak**

Treść: W artykule przedstawiono koncepcję systemu informatycznego, którego celem jest wyszukiwanie w multimedialnych bazach danych obrazów konkretnej struktury skalnej. Poszukiwanie opiera się wyłącznie na zapytaniu w postaci obrazu, natomiast system w odpowiedzi zwraca zbiór fotografii przedstawiających tę samą strukturę skalną. Zaproponowana konstrukcja systemu bazuje na wykorzystaniu analizy obrazu oraz zagadnień sztucznej inteligencji, a w szczególności metod grupowania i klasyfikacji danych. Jako materiał do prowadzenia badań wybrano 600 zdjęć przedstawiających mikroskopowe obrazy różnych skał. Decyzje dotyczące klasyfikacji oparto na różnych metodach klasyfikacji i grupowania danych. W efekcie badań wykazano, że metody takie jak MEC oraz bazujące na naiwnym klasyfikatorze Bayesa, a także metoda k-najbliższych sąsiadów uzyskują bardzo dobre wyniki klasyfikacji, sięgające dla niektórych z badanych skał nawet 100% poprawnych decyzji.

Abstract: This paper presents the concept of IT system developed to search in multimedia databases for the images of particular rock structures. The search is based only on the query in the form of the image, while in response, the system returns a collection of photographs representing the same structure of the rock. The proposed project is based on the methods of image analysis and the artificial intelligence, in particular, on the methods of data clustering and classification. To conduct the research, the authors selected 600 photographs of microscopic images of six different rocks. Decisions concerning the classification were based on six different methods of clustering and classification of data. As a result of the study it was proved that methods such as MEC or those based on the naive Bayes classifier as well as the method of the k-nearest neighbors, have very good classification results reaching up to 100% of correct decisions for some of the studied rocks.

Słowa kluczowe:

wyszukiwanie obrazem, sztuczna inteligencja, analiza skupień, analiza danych, przetwarzanie obrazów.

Key words:

search by image, artificial intelligence, cluster analysis, data analysis, image processing

1. Wprowadzenie

Postęp technologiczny w prowadzeniu prac górniczych i geotechnicznych wymaga dokładnego rozpoznania skał i masywu skalnego. Rozpoznanie takie często wymaga wyznaczenia parametrów stereologicznych struktur skalnych obserwowanych w zakresie powiększeń mikroskopowych. Zastosowanie analizy stereologicznej w górnictwie i geologii jest tematyką stale rozwijaną w nauce polskiej od lat 60. XX

wieku [2, 7]. Dynamiczny rozwój komputeryzacji zapoczątkował w latach dziewięćdziesiątych rozkwit badań nad automatyzacją tego typu pomiarów, poprzez wykorzystanie do tego celu analizy obrazu [10, 11]. Prowadzenie automatycznych pomiarów na obrazach struktur skalnych powoduje, że do dyspozycji badaczy dostępne są coraz większe bazy danych cyfrowych materiałów fotograficznych. Bazami tymi mogą być zarówno zbiory fotografii cyfrowych na indywidualnych dyskach komputerowych, jak również obrazy umieszczone na serwerach, w klasycznych bazach danych. Niestety, lawinowo rosnąca liczba zdjęć w tego typu zbiorach powoduje trudności w wyszukiwaniu obrazów poszczególnych struktur

* AGH w Krakowie

skalnych. (dzieje się tak nawet, pomimo starannego opisu poszczególnych obrazów). Autorzy sądzą, że sytuacja taka będzie się pogłębiać. Szczególny na to wpływ może mieć coraz powszechniejsza praca w dużych grupach badaczy lub nawet w dużych konsorcjach naukowo-przemysłowych. Połączenie w jedną całość zbiorów obrazów pochodzących od poszczególnych współpracowników, a w szczególności proces ich sortowania, może okazać się niezmiernie trudny. Natomiast skuteczna eksploracja takich, multimedialnych baz danych, wymaga pełnej wiedzy o klasyfikacji wszystkich analizowanych obrazów.


W niniejszym artykule autorzy proponują wspomoczenie procesu klasyfikacji zdjęć poprzez wykorzystanie metod sztucznej inteligencji do odnajdywania wizualnie podobnych zobrazowań w bazie danych. Przy czym kluczem wyszukiwania jest tylko i wyłącznie obraz przedstawiający szukaną strukturę. Takie podejście pozwoli na wykorzystanie opracowanego systemu nawet przez operatorów nieposiadających żadnej wiedzy z dziedziny przetwarzania i analizy obrazów oraz sztucznej inteligencji.

2. Wyszukiwanie obrazem - opis zagadnienia

W literaturze popularne są dwa podejścia do zagadnienia wyszukiwania obrazem. Pierwsze polega na wyszukiwaniu obrazów na podstawie opisujących je metadanych, drugie bazuje na podobieństwie treści obrazów [16]. Wyszukiwanie na podstawie parametrów obrazu, takich jak rozmiar, słowny opis zawartości, itp. wydaje się być niewystarczający dla realizacji zagadnienia wyszukiwania i rozpoznawania struktur skalnych. Podejście bazujące na analizie treści obrazów, w znacznym stopniu odzwierciedla sposób w jaki porównywane są zdjęcia przez ludzki umysł [1]. Wydzielane są pewne cechy charakterystyczne obrazu, dla których dokonuje się porównania. W ostatnich czasach dużą popularność, dzięki swojej użyteczności, zyskały programy, które bazując na treści obrazu cyfrowego, dopasowują według własnej oceny trafności, wyniki w postaci zestawu innych obrazów. Przykładem

takiego programu jest wyszukiwarka udostępniona przez serwis TinEye. Jako parametr wejściowy zadaje się szukane zdjęcie, natomiast rezultatem jest zestaw najlepiej dopasowanych obrazów, jakie algorytm odnalazł w sieci Internet. Innym przykładem programu do wyszukiwania obrazem, jest aplikacja udostępniona przez firmę Google - Google Search by Image, która w analogiczny technicznie sposób wyszukuje podobne obrazy. Różnica pomiędzy tymi programami przejawia się w efektach, jakie one zwracają. Wyszukiwarka TinEye wydaje się skupiać na podobieństwie w sensie odwzorowania obiektów, zwracając tym samym nieznacznie zmodyfikowane wersje szukanego obrazu. Wyszukiwarka firmy Google zwraca zobrazowania podobne do wzorca, np. pod względem kolorystyki - nie są to jednak jego kopie. Szczegółowy aparat matematyczny, wykorzystany do realizacji opisanych przykładów nie jest powszechnie znany. Niestety, korzystanie z ogólnodostępnych wyszukiwarek dla celów innych niż przeszukiwanie całej sieci Internet (czyli np. jako narzędzia do wyszukiwania w prywatnej bazie danych), wiąże się z koniecznością udostępnienia analizowanych zdjęć serwisom prowadzącym wyszukiwanie. Dodatkowo, algorytmy wyszukiwania wykorzystywane przez te serwisy są bardzo ogólne i nie są zoptymalizowane pod kątem tak specyficznych obiektów jak obrazy struktur skalnych. Ze względu na powyższe, autorzy zdecydowali się podjąć tematykę wyszukiwania obrazem, do zastosowań geologicznych i górniczych, przedstawiając tym samym własną koncepcję realizacji tego tematu.

Zaproponowane rozwiązanie bazuje na: wykorzystaniu metod przetwarzania i analizy obrazów cyfrowych, metodach sztucznej inteligencji oraz algorytmach eksploracji danych. Zagadnienie przetwarzania obrazów rozwija się i w artykule odwołano się do istniejących już publikacji [9] [14]. Użytkownik zaproponowanego systemu umieszcza klucz wyszukiwania (zapytanie) w postaci obrazu. System wyszukiwania bazując na metodach sztucznej inteligencji podejmuje zaś decyzję, które, spośród umieszczonych w bazie danych obrazów, wykazują najlepsze dopasowanie. Graficzna prezentacja tego podejścia została ujęta na rysunku 1.



Rys. 1. Graficzny schemat proponowanego rozwiązania (źródło własne)

Fig. 1. Graphic scheme of the proposed solution (own source)

Autorzy proponują, aby do realizacji opisanego procesu decyzyjnego wykorzystywać algorytmy sztucznej inteligencji w postaci metod klasyfikacji oraz grupowania danych.

3. Pozyskiwanie wiedzy na temat podobieństwa treści obrazów cyfrowych – zaproponowany przykład systemu wyszukiwania obrazem

3.1. Akwizycja danych


Obrazy stanowiące podstawę do opisywanych badań zostały zarejestrowane pod mikroskopem optycznym przy świetle spolaryzowanym [11]. Baza zdjęć, na której wykonywano pomiary, liczyła 600 obrazów cyfrowych. Obrazy te przedstawiały pięć typów skał: dolomit z Laskowej Góry (DLG), dolomit z Rędzin (DR), marmur Biała Marianna (MBM), piaskowiec z Tumlina (PT) oraz porfir z Miękinii (PM). Szóstą grupą były zdjęcia wykonane na zglądach koncentratu miedzi (KM). Na rysunkach 2 i 3 zaprezentowano losowo wybrane obrazy, dla każdej z rozpatrywanych grup.

3.2. Wybór parametrów definiujących przestrzeń cech

Kolejnym etapem procesu wyszukiwania obrazem jest odwzorowanie obiektów w przestrzeni cech. Przestrzeń cech może być traktowana jako n wymiarowa przestrzeń Euklidesowa, w której można prowadzić dalsze obliczenia. Jako obiekt, w kontekście niniejszego badania, rozumiany jest pojedynczy obraz. Obraz ten jest odwzorowywany jako wektor cech, którego składowymi są wartości określające miary wybranych parametrów w przestrzeni cech. Należy zaznaczyć, że wybór parametrów definiujących przestrzeń cech w dużym stopniu zależy od pomysłowości operatorów

systemu, a także od własności obiektów poddawanych rozpoznawaniu. Autorzy, przy definiowaniu przestrzeni cech, kierowali się chęcią wyboru parametrów niosących ze sobą istotną informację na temat obiektów oraz tym, by punkty w przestrzeni cech grupowały się w skupiska możliwie zwarte i oddalone od skupisk reprezentujących inne klasy. Na podstawie powyższych założeń wyłoniono zestaw 24 parametrów opisujących analizowane obiekty (rysunki):

- średnia wartość poziomów szarości pikseli obrazu dla poszczególnych kanałów barwnych RGB oraz kanału luminancji,
- średnia wartość wszystkich poziomów szarości obrazu gradientu morfologicznego dla poszczególnych kanałów barwnych RGB oraz kanału luminancji [11];
- wartość funkcji semiwariogramu dla wybranego zakresu h wyliczona dla poszczególnych kanałów barwnych RGB oraz kanału luminancji [11];
- miara koncentracji rozkładu wartości poszczególnych poziomów szarości kanałów barwnych RGB oraz kanału luminancji - wskazuje na nierównomierne rozdysponowanie wartości cechy pomiędzy elementy próby losowej, (wykorzystano definicję kurtozy jako czwarty moment centralny dzielony przez kwadrat wariancji [3]);
- miara asymetrii rozkładu wartości poszczególnych poziomów szarości kanałów barwnych RGB oraz kanału luminancji - dostarcza informacji na temat symetrii rozkładu lub jej braku, (wykorzystano definicję współczynnika skośności jako trzeci moment centralny dzielony przez sześcian odchylenia standardowego [15]);
- miara odchylenia standardowego wartości poszczególnych kanałów barwnych RGB oraz kanału luminancji - oddaje zróżnicowanie wartości poziomów szarości poszczególnych kanałów barwnych.



Rys. 2. Dolomit z Laskowej Góry (a), dolomit z Rędzin (b), marmur Biała Marianna (c) (źródło własne)

Fig. 2. Dolomite from Laskowa Gora (a), dolomite from Redziny (b), marble Biała Marianna (c) (own source)



Rys. 3. Piaskowiec z Tumlina (e), porfir z Miękinii (f), ziarna koncentratu miedzi (g) (źródło własne)

Fig. 3. Sandstone from Tumlin (e), porphyry from Miekinia (f), copper concentrate (g) (own source)

3.3. Wstępne przetwarzanie danych

Przetwarzanie wstępne polegało na ustaleniu wartości wszystkich parametrów opisujących badane obiekty. Dokonano tego z wykorzystaniem komputerowych metod przetwarzania obrazów. Wartości tych parametrów stały się podstawą dalszych badań. Istotną wadą stosowania miar opisanych w rozdziale 3.2 jest tendencja do dominacji atrybutu o największych liczbowo wartościach nad pozostałymi. Rozwiązaniem stał się proces normalizacji wartości wszystkich parametrów, polegający na przeskalowaniu przedziałów, do których one należą [0,1].

3.4. Opis wykorzystanych metod klasyfikacji i grupowania danych

Pod pojęciem grupowania autorzy rozumieją proces polegający na podziale dowolnego zbioru elementów na pewne podzbiory. Cechą takich podzbiorów jest to, iż należące do niego elementy są do siebie podobne, tj. mają właściwości wyróżniające dany podzbiór (grupę) [6]. Elementy (obiekty) należące do jednej grupy tworzą zbiór, który określany będzie mianem klasy. Dołączanie kolejnych obiektów do takiej grupy rozumiane jest, w kontekście niniejszej pracy, jako klasyfikacja obiektu do danej grupy.

W pracy Autorzy przedstawili porównanie efektów, jakie uzyskano, korzystając z metod grupowania: k-means, jej optymalizacji metodą minimalnej entropii, k-centroidów, rozmytej analizy skupień, oraz klasyfikacji: metodą k-najbliższych sąsiadów i metodą naiwnej klasyfikacji Bayesa.

3.4.1. Algorytm k-means

Algorytm ten (w kontekście analizowanego przypadku) oblicza wektory średnich dla każdego wymiaru. Podobieństwo grupowanego wektora do wektora średnich obliczane jest za pomocą odległości euklidesowej. Wynikiem działania algorytmu jest zbiór k klastrów minimalizujący kryterium odchylenia wewnątrzklasowego (błędu średniokwadratowego). Istotnym jest tutaj fakt, iż algorytm w surowej postaci wymaga od użytkownika podania liczby klastrów, według której dokonuje podziału. Uniemożliwia to pełną automatyzację procesu wyszukiwania obrazem. Aby zapobiec temu zjawisku, autorzy zdecydowali się na wykorzystanie algorytmu GAP Statistic, który bazując na weryfikacji wewnętrznego zróżnicowania w skupieniu w stosunku do zmienności między skupieniami, estymuje pożądaną liczbę klastrów [5].

3.4.2. Algorytm minimalnej entropii MEC

Metodą poprawy jakości grupowania metodami k-means może być wykorzystanie innego algorytmu grupującego, który wymaga przypisania mu w fazie początkowej elementów do klastrów, czyli efektu grupowania przeprowadzonego, np. wcześniej opisaną metodą. Algorytm minimalnej entropii MEC polega na cyklicznym sprawdzaniu przynależności obiektów do innych grup, w celu minimalizacji całkowitej entropii zbioru grup [8].

3.4.3. Algorytm k-medoidów

Jest to odmiana algorytmu k-means, polegająca na wykorzystaniu medoidów, jako środków klastra. W każdej iteracji wybierany jest wektor reprezentujący środek klastra, gdzie suma odległości do innych wektorów w klasie jest najmniejsza. Medoid, w odróżnieniu od wartości średniej, jest zawsze elementem klastra [12].

3.4.4. Metoda rozmytej analizy skupień - algorytm C-średnich

Osobną klasę metod grupowania poprzez klasyfikację stanowią metody rozmytej analizy skupień. Spośród nich wybrano znaną metodę *fuzzy-c-means*. Metody rozmytej analizy skupień pozwalają stosować grupowanie do zadań kategoryzacji, czyli przydziału elementu do więcej niż jednej kategorii (w klasycznej analizie skupień uzyskana klasyfikacja ma charakter rozłączny). W procesie klasteryzacji rozmytej każdemu punktowi przyporządkowywany jest stopień przynależności do każdego z klastrów. Klastry stają się więc zbiorami rozmytymi w badanej przestrzeni. Proces wyznaczania środków klastrów oraz przynależności poszczególnych obiektów do zdefiniowanych grup odbywa się w wyniku minimalizacji przyjętej funkcji celu [4].

3.4.5. Metoda klasyfikacji oparta o analizę odległości k-sąsiadów

Klasyfikator k-najbliższych sąsiadów należy do grupy algorytmów opartych o analizę odległości. Obiekt klasyfikowany jest jako należący do dominującej klasy w zbiorze k sąsiadów obiektu. W kontekście techniki wyszukiwania obrazem, metoda ta wydaje się ideowo odpowiadać potrzebom systemu. Użytkownik prosi system o odnalezienie k najbardziej podobnych mu zdjęć w całej dostępnej bazie danych. Istotnym dla skuteczności rozwiązań oraz złożoności obliczeniowej jest parametr k, określający ile najbliższych sąsiadów będzie branych pod uwagę przy klasyfikacji [17].

3.4.6. Metoda klasyfikacji wykorzystująca Naiwny klasyfikator Bayesa

Naiwny klasyfikator Bayes'a jest jedną z metod uczenia maszynowego, wykorzystywaną do rozwiązywania problemu sortowania i klasyfikacji. Jego zadaniem jest przyporządkowanie obiektu do jednej z klas decyzyjnych, na podstawie prawdopodobieństwa przynależności do danej grupy. Istotnym, ze względu na charakter metody jest, by zbiór klas decyzyjnych był skończony i zdefiniowany a priori. Naiwny klasyfikator Bayes'a zakłada, że warunkowe prawdopodobieństwa dla zmiennych niezależnych są wzajemnie, statystycznie niezależne [13].

4. Wyniki oraz ich interpretacja

Przeszukiwaną bazę danych stanowiło 600 zdjęć przedstawiających 6 różnych struktur (po 100 zdjęć na każdą strukturę). Poprawna klasyfikacja tych zdjęć nie była znana systemowi informatycznemu. Była natomiast znana autorom opracowania i stanowiła podstawę do oceny poprawności klasyfikacji. Proces rozpoznawania obrazem polegał na wybraniu jednego z posiadanych 600 zdjęć i wprowadzeniu go do programu jako wzorca, na podstawie którego wyszukiwane były podobne struktury. Tabela 1 przedstawia zbiorcze zestawienie wyników przeszukiwania bazy danych zadaniem obrazem przy wykorzystaniu 5 algorytmów: k-means, k-medoidów, C-średnich, minimalnej entropii MEC oraz naiwny klasyfikator Bayesa. W zestawieniu, jako miarę skuteczności działania systemu, podano średni procent pozytywnie zgrupowanych obiektów oraz średnie odchylenie standardowe pozytywnie zgrupowanych obiektów dla 100 powtórzeń każdej metody. Liczba klastrów k ustalona została w sposób automatyczny jako mediana ze 100 powtórzeń algorytmu estymacji liczby klastrów *GAP Statistic*. Dla badanego zestawu danych ustalono wartość $k = 6$.

Tablica 1. Wyniki poprawnego samoorganizowania danych
Table 1. Results of proper data self-organization [%]

		k-means	k-medoidów	c-średnich	MEC	klasyfikator Bayesa
DLG	śred.	98,03	96,69	99,99	100,0	99,00
	std.	6,48	11,21	0,10	0,0	0,0
DR	śred.	95,48	81,39	98,11	100,0	100,0
	std.	9,33	21,62	2,85	0,0	0,0
MBM	śred.	92,59	96,21	100,0	100,0	100,0
	std.	17,67	11,84	0,0	0,0	0,0
PT	śred.	92,38	92,51	93,73	98,00	99,00
	std.	13,53	13,45	11,92	0,0	0,0
PM	śred.	85,85	83,42	92,48	96,00	96,00
	std.	18,98	19,72	10,87	0,0	0,0
KM	śred.	95,91	94,79	100,0	100,0	100,0
	std.	9,58	12,22	0,0	0,0	0,0


Uzyskane wyniki wskazują na bardzo wysoki procent poprawnych klasyfikacji zobrazowań skalnych dokonanych jedynie na podstawie zadanego, przykładowego zdjęcia. Zaobserwowano również, iż algorytmy *k-means* oraz *k-medoids* są najbardziej czułe na dane zawierające punkty osobliwe, czyli obrazy, na których zarejestrowane obszary skały odbiegają swym wyglądem od innych obszarów tej samej struktury. Owe punkty osobliwe w istotny sposób wpływają na wartości środków klastrów, powodując ich zniekształcenie. Zdjęcia przedstawiające piaskowiec z Tumlina oraz porfir z Miękini posiadają takich osobliwości najwięcej, co jest powodem największej liczby błędnie sklasyfikowanych danych. Metody, dążące do minimalizacji wewnętrznej entropii, iteracyjnie dążą do najlepszej oczekiwanej skuteczności. Stabilność i powtarzalność efektów klasyfikacji odzwierciedlona jest odchyleniem standardowym wyników na poziomie 0%. Na podstawie przeprowadzonych badań ocenia się, iż najtrudniejsze w analizie są porfir z Miękini (PZM) oraz piaskowiec z Tumlina (PZT).

W tabeli 2 zaprezentowano wyniki metody opartej o analizę *k*-najbliższych sąsiadów dla *k* równego od 10 do 100, zmieniającego się z krokiem 10. Również w tej metodzie uzyskano bardzo dobre wyniki klasyfikacji. Poprawność klasyfikacji uzależniona jest od liczby poszukiwanych podobnych obrazów. Można stwierdzić, że dla *k* mniejszego lub równego 30 najbliższych sąsiadów skuteczność jest bliska 100%. Im wyższy parametr *k*, tym rozpoznawalność jest gorsza. Aczkolwiek nawet dla *k* = 100, czyli dla wyszuki-

wania wszystkich możliwych zdjęć danej skały, skuteczność metody jest zadowalająca i wynosi od 81,07% dla piaskowca z Tumlina do 95,37% dla koncentratu miedzi.

Rysunki 5 i 6 przedstawiają graficzne rezultaty najlepiej dopasowanych wyników klasyfikacji metodą opartą o analizę odległości *k*-sąsiadów, gdzie *k* = 9. Wybrano dwa przykłady struktur skalnych: dolomit z Laskowej Góry (rys. 4a) oraz porfir z Miękini (rys. 4b).

Kluczem wyszukiwania był obraz, w obu przypadkach, będący elementem bazy danych podlegającej rozpoznaniu. W obydwu przypadkach został zaklasyfikowany, jako najbliższy w badanej przestrzeni cech, co potwierdza prawidłowe działanie algorytmu.




Rys. 4. Klucz wyszukiwania dolomitu z Laskowej Góry (DLG) (a) oraz porfiru z Miękini (PM) (b) metodą *k* najbliższych sąsiadów (źródło własne)

Fig. 4. Key for the search of dolomite from Laskowa Gora (DLG) (a) and porphyry from Miękinia (PM) (b) by using *k*-nearest neighbors method (own source)


Tablica 2. Zestawienie prawidłowych klasyfikacji dla metody KNN w zależności od parametru *k* dla wszystkich obrazów z danej grupy zdjęć

Table 2. Compilation of faultless classifications for KNN method, depending on the *k*-parameter for each image of the given group [%]

k	DLG, %		DR, %		MBM, %		KM, %		PM, %		PT, %	
	śred.	std.	śred.	std.	śred.	std.	śred.	std.	śred.	std.	śred.	std.
10	99,80	1,40	99,80	1,41	99,78	2,00	100	0	98,2	10,76	99,00	7,58
20	99,35	3,38	99,75	4,64	99,45	2,45	100	0	97,55	12,99	98,13	8,54
30	99,00	4,84	99,66	4,6	99	3,52	100	0	97,3	14,05	97,85	9,36
40	98,75	5,94	99,20	2,86	98,55	4,68	100	0	97,05	14,92	97,22	10,09
50	98,58	6,55	98,28	5,29	98	5,44	100	0	96,92	15,33	96,38	10,99
60	98,37	7,01	97,33	7,20	97,6	6,19	100	0	96,76	15,56	94,81	11,33
70	98,09	7,43	96,22	8,65	96,75	6,76	99,86	0,62	96,64	15,61	92,01	11,85
80	97,66	8,08	94,61	9,80	95,65	7,54	99,68	1,11	96,41	15,58	87,17	12,43
90	96,91	8,53	92,14	11,15	93,93	7,84	98,97	1,62	95,88	15,80	87,17	12,26
100	94,42	8,75	87,84	11,42	90,7	7,93	95,37	3,97	92,86	15,32	81,07	11,18



Rys. 5. Rezultaty wyszukiwania $k=9$ najbliższych sąsiadów dla dolomitu z Laskowej Góry (DLG)
Fig. 5. Search results of $k=9$ nearest neighbors for the dolomite from Laskowa Gora (DLG) (own source)



Rys. 6. Rezultaty wyszukiwania $k=9$ najbliższych sąsiadów dla porfiru z Miękinia (PM)
Fig. 6. Search results of $k=9$ nearest neighbors for the porphyry from Miekini (PM) (own source)

5. Podsumowanie

W pracy wykazano, że zarówno metody samoorganizacji, jak i klasyfikacji danych, mogą być efektywnymi metodami matematycznymi wykorzystanymi w zagadnieniu wyszukiwania obrazem, zobrazowań przedstawiających struktury skalne. Zaproponowana koncepcja systemu, bazująca na zdefiniowanej przez autorów przestrzeni cech, dopasowuje obrazy do wzorca na bardzo dobrym poziomie. Uzyskana skuteczność poprawnych dopasowań jest na wysokim poziomie, wielokrotnie sięgającym 100%. Nietrafione klasyfikacje dotyczą jedynie obrazów, które w istotny sposób różnią się wizualnie od reszty grupy. Zaproponowany system ma na celu wspomaganie procesu decyzyjnego podczas określania podobieństwa badanych obiektów i według autorów spełnia wymagane kryteria. Może być więc stosowany w zagadnieniach wyszukiwania obrazów w bazach danych, przeszukiwania dysków w celu odnalezienia obrazów żądanych struktur skalnych oraz w zagadnieniach przeglądania sekwencji wideo w celu odnawiania klatek z określonymi strukturami. Należy zaznaczyć, że w opisywanych systemach wnioskujących istotne znaczenie ma ich złożoność obliczeniowa. Z tego względu autorzy w najbliższym czasie planują podjąć tematykę optymalizacji proponowanego rozwiązania poprzez zastosowanie redukcji liczby wymiarów zbioru treningowego.

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

Literatura

1. *Blitzer J., Kilian Q. W., Lawrence K. S.*: Distance metric learning for large margin nearest neighbor classification. *Advances in neural information processing systems* 2005.
2. *Bodziony J., Kraj W., Pindel Z., Ratajczak T., Wilczyński J.*: Analiza stereologiczna zespołu minerałów miedzionośnych białego spągowca. „Archiwum Górnictwa” 1979, nr 24.
3. *Budny K.*: Kurtoza wektora losowego. Uniwersytet Ekonomiczny we Wrocławiu. „Ekonometria” 2009, nr 26(76), s. 44-54.
4. *Cannon R. L., Jitendra V. D., Bezdek J. C.*: Efficient implementation of the fuzzy c-means clustering algorithms. *Pattern Analysis and Machine Intelligence, IEEE Transactions* 1986, 248-255.
5. *Tibshirani R., Walther G., Hastie, T.*: Estimating the number of clusters in a data set via the gap statistic. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 2001, 63(2), 411-423.
6. *Jain A. K., Narasimha M., Flynn P. J.*: Data clustering: a review. *ACM computing surveys* 1999, 31.3, 264-323.
7. *Kraj W., Kruszyński M.*: Wyznaczanie orientacji przestrzennej nieciągłości w skale na przykładzie granitu strzegomskiego. „Archiwum Górnictwa” 1981, nr 26(3).
8. *Li H., Keshu Z., Jiang T.*: Minimum entropy clustering and applications to gene expression analysis. *Computational Systems Bioinformatics Conference 2004, CSB 2004. Proceedings 2004 IEEE*.
9. *Matheron G.*: *Random Sets and Integral Geometry*. Wiley 1975.
10. *Młynarczuk M.*: Some Remarks on the Application of Image Analysis and Image Processing for the Description of the Geometrical Structures of Rock. *Physicochemical Problems of Mineral Processing* 1999, 33.
11. *Młynarczuk M.*: Możliwości wykorzystania metod analizy obrazu do opisu petrograficznego wybranych skał okruchowych. „Gospodarka Surowcami Mineralnymi” 2006, s. 135-144.
12. *Park H. S., Jun C. H.*: A simple and fast algorithm for K-medoids clustering. *Expert Systems with Applications* 2009, 36(2), 3336-3341.
13. *Rish I.*: An empirical study of the naive Bayes classifier. *IJCAI workshop on empirical methods in artificial intelligence* 2001.
14. *Serra J.*: *Image Analysis and Mathematical Morphology*. Academic Press 1982.
15. *Tatar J.*: O niektórych miarach rozproszenia rozkładów prawdopodobieństwa. „Przeгляд Statystyczny” 1996.
16. *Yee K. P., Swearingen K., Li K., Hearst M.*: Faceted metadata for image search and browsing. *Proceedings of the SIGCHI conference on Human factors in computing systems* 2003, 401-408.
17. *Yu C.*: Indexing the distance An efficient method to knn processing. *VLDB* 2001.