

# Optymalizacja procesu automatycznej klasyfikacji cech strukturalnych węgla z obszarów zagrożonych wyrzutami gazów i skał opartego na metodach rozpoznawania obrazów

MARIUSZ MŁYNARCZUK, KATARZYNA GODYŃ, JAROSŁAW AKSAMIT

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

## Streszczenie

W ramach prac kontynuowano rozpoczęte w roku 2012 badania pozwalające na wykorzystanie metod rozpoznawania obrazów do identyfikacji cech strukturalnych i petrograficznych węgla. Skoncentrowano się na automatycznej identyfikacji wityrnytu, inertyrnytu oraz kataklazy. Są to cechy petrograficzne i strukturalne węgla najczęściej analizowane w IMG PAN przy ocenie stanu zagrożenia wyrzutowego. W badaniach oceniono przydatność wybranych parametrów tworzących przestrzeń cech, zbadano wpływ wielkości okna pomiarowego na wynik rozpoznania, przebadano wpływ przestrzeni barw, w której prowadzone są pomiary oraz dokonano analizy wpływu metryki odległości, w której wykonywane są obliczenia. W wyniku przeprowadzonych analiz otrzymano wysoki odsetek poprawnych klasyfikacji badanych struktur sięgający ponad 95%. Potwierdza to przydatność metod sztucznej inteligencji do automatycznej identyfikacji wybranych cech petrograficznych i strukturalnych węgla.

**Słowa kluczowe:** rozpoznawanie obrazów, analiza ilościowa węgla, struktura węgla

## 1. Wstęp

W pokładach węgla dochodzi do lokalnych zmian w wewnętrznej strukturze węgla, obserwowanych w szczególności w zakresie powiększeń mikroskopowych. Te zmiany dotyczą przede wszystkim obszarów w których występują deformacje tektoniczne. Rejon wpływu takiej deformacji na pokład węgla (tzw. *share zone*) cechuje się wg Bodzionego i Lamy (1996) występowaniem węgla osłabionego strukturalnie, spękanego i pokruszonego. Bodziony i in. (1990) zwrócili uwagę, że analiza stereologiczna próbek węglowych w celu poszukiwania węgla strukturalnie odmienionego może być przyczynkiem do profilaktyki przeciwwyrzutowej. Podejmowane w późniejszych latach prace (Wierzbicki i Młynarczuk, 2006; Młynarczuk i Wierzbicki, 2009) potwierdzają to spostrzeżenie. Autorzy zwracają jednak uwagę na uciążliwość takich analiz. Mikroskopowe analizy ilościowe węgla prowadzone są zazwyczaj w sposób manualny, a jedną z kluczowych kwestii w tych badaniach jest poprawna i powtarzalna identyfikacja cech strukturalnych oraz petrograficznych. Wcześniej-sze badania wskazują, że nie jest to zagadnienie trywialne. Długofalowym celem opisywanych badań jest opracowanie uniwersalnej i powtarzalnej metodyki, która pozwoli zidentyfikować grupy macerałowe (być może także poszczególne macerały), oraz potrafi podjąć decyzję o stopniu zniszczenia struktury węgla.

Węgiel jest skałą, która posiada szczególne właściwości, wyróżniające się spośród innych typów skał osadowych. Podstawową cechą wyodrębniającą węgiel jest jego składnik elementarny – macerał, rozróżnialny jedynie pod mikroskopem. Macerały to utwory jednorodne pod względem morfologicznym, fizycznym i chemicznym. Rozróżnia się trzy podstawowe grupy macerałowe: wityrnytu (ICCP, 1998), inertyrnytu (ICCP, 2001) i liptyrnytu. W ramach badań opisanych w pracy Młynarczuk i Godyń (2012) prowadzono wstępne rozpoznanie dotyczące możliwości wykorzystania metod rozpoznawania obrazów w celu detekcji wityrnytu, inertyrnytu. W pracy tej starano się zidentyfikować również obszary występowania węgla osłabionego strukturalnie, spękanego i pokruszonego. Miejsca występowania takiego węgla (kataklazy) są niezwykle

niebezpieczne z uwagi na podwyższone ryzyko zaistnienia w tam niekontrolowanych zjawisk gazogeodynamicznych (Shepherd i in., 1980; Beamish i Crosdale, 1998; Cao i in., 2000; Li i in., 2003). Na obecnym etapie badań nie identyfikowano liptynitów oraz minerałów nieorganicznych, jako struktur stosunkowo rzadko występującego w analizowanych próbkach węgla. Należy jednak zaznaczyć, że jakkolwiek dodanie do badań klasy minerałów nieorganicznych nie powinno być procesem skomplikowanym, to autorzy sądzą, iż identyfikacja dodatkowego maceratu – liptynitów, może okazać się dużym wyzwaniem.

W celu przeprowadzenia badań zdefiniowano wielowymiarową przestrzeń cech, która pozwoliła w sposób automatyczny klasyfikować wspomniane struktury. W wyniku przeprowadzonych analiz otrzymano rezultaty wskazujące na to, że metody sztucznej inteligencji, pozwalają na identyfikowanie wybranych cech petrograficznych i strukturalnych węgla. Niniejsze badania mają na celu dogłębsze sprawdzenie możliwości zaproponowanej w pracy Młynarczuk i Godyń (2012) metody oraz jej optymalizację pod kątem praktycznego wykorzystania w pomiarach stereologicznych.


## 2. Materiał pomiarowy

W badaniach wykorzystano węgiel z górnośląskich kopalń węgla kamiennego. Pochodził on z KWK Zofiówka, KWK Pniówek, KWK Borynia-Zofiówka oraz KWK Budryk. Są to próbki identyczne do tych, analizowanych w pracy Młynarczuk, Godyń (2012). Tam też podana jest dokładna lokalizacja ich pobrania.

Do analiz zastosowano mikroskop polaryzacyjny AXIOPLAN firmy ZEISS. Stosowano powiększenie 500×, co jest zgodne z PN-ISO 7404-3: 2001, dotyczącą petrograficznych analiz węgla kamiennego. Do akwizycji wykorzystano kamerę CCD firmy Nikon, dedykowaną do obserwacji mikroskopowych. Wszystkie fotografie analizowane w niniejszej pracy wykonano przy użyciu immersji olejowej.

## 3. Metodyka badań

Metodyka wykorzystywana w badaniach opisanych w pracy Młynarczuk i Godyń (2012) polegała na zaznaczeniu prostokątnych obszarów, jednorodnych pod względem zajmowanej struktury. Obszary te były różnej wielkości, natomiast na całym ich obszarze znajdowały się wyłącznie wityrynit, inertynit, kataklaza oraz klej (składnik istotny z technicznego punktu widzenia). Takie, uproszczone założenie, przyjęto ze względu na pilotażowy charakter wspomnianych badań. Przykłady analizowanych we wspomnianej pracy obszarów zaprezentowano na rysunku 1.



Rys. 1. Przykłady obszarów obejmujących wityrynit i inertynit (Młynarczuk i Godyń, 2012). Powiększenie 500×. Imersja

Wykonywane obecnie badania różniły się sposobem wyboru pól do analizy. Zaproponowana metodyka bazująca na metodach stereologicznej analizy punktowej. Na analizowanych zdjęciach zaznaczono w sposób losowy zbiór punktów (około 10 000), dla których zapisano ich położenie (nr Zdjęcia oraz współrzędne XY na tym zdjęciu), oraz klasyfikację tego punktu (wityryni, inertynit, kataklaza lub klej) nadaną przez ob-

serwatora. Następnie (w sposób losowy) wyselekcjonowano z tego zbioru danych po 1300 punktów, które padły na każdą z analizowanych struktur. W rezultacie, we wszystkich opisywanych w niniejszej pracy analizach, dysponowano 5200 punktami pomiarowymi o znanych, poprawnych klasyfikacjach. Punkty te były środkami pól pomiarowych, poprzez analizę których podejmowano decyzję o przynależności punktu (obszaru) do jednej z 4 klas. Wyniki porównania decyzji automatycznych z decyzjami obserwatora świadczą o poprawności działania poszczególnych metod rozpoznawania obrazów.

W pracy skupiono się na 5 funkcjach przynależności a mianowicie: metodzie najbliższego sąsiada (NN), metodzie k najbliższych sąsiadów (kNN), metodzie optymalnych otoczeń kulistych (OOK), metodzie aproksymacji liniowej (AL) oraz metodzie aproksymacji kwadratowej (AK).

## 4. Wyniki badań

W pracy Młynarczuk i Godyń (2012), jako parametry definiujące przestrzeń cech wybrano wartości poziomów szarości pikseli na analizowanych obszarach oraz wielkości parametrach statystycznych opisujących rozkłady tych poziomów szarości, czyli:

1. Średni poziom szarości obrazu,
2. Odchylenie standardowe dla poziomu szarości obrazu
3. Średni poziom szarości obrazu gradientu,
4. Odchylenie standardowe dla poziomu szarości obrazu gradientu

Identyfikacja analizowanych klas odbywała się wyłącznie na bazie tych parametrów. Obliczano je dla każdej z trzech składowych RGB obrazu i unormowano do przedziału [0, 100]. W rezultacie czyli dysponowano 12 wymiarową przestrzenią cech. Wyniki rozpoznania przedstawiono w tabeli 1.

Należy wspomnieć, że w opisywanej pracy wykorzystywano również 24 wymiarową przestrzeń cech (wykorzystując parametry statystyczne skośności i kurtozy), co skutkowało niewielkim polepszeniem wyników rozpoznania (aż do 95,9% poprawnych klasyfikacji dla metody NN).

**Tab. 1.** Zestawienie wyników rozpoznania cech strukturalnych węgla (12 wymiarowa przestrzeń cech) dla 390 obszarów rozpoznawanych przy 200 elementowym ciągu uczącym. (Młynarczuk i Godyń, 2012)

Metoda	Brak rozpoznania	Błędne rozpoznanie	Poprawne rozpoznanie
NN	0%	5,6%	94,4%
kNN (K = 3)	0%	5,4%	94,6%
kNN (K = 5)	0,5%	4,4%	95,1%
kNN (K = 7)	0%	4,1%	95,9%
kNN (K = 11)	0%	5,4%	94,6%
NM	0%	13,85	86,2%
OOK	34,6%	0,8%	64,6%
AL	0%	11,0%	89,0%
AK	0%	6,7%	93,3%

### 4.1. Wstępne rezultaty dotyczące poprawności klasyfikacji

Jak wspomniano, główną modyfikacją w prowadzonej klasyfikacji było to, że posiadano zbiór 5200 punktów o znanej (dla obserwatora) poprawnej klasyfikacji. Na bazie tych punktów tworzone obszary o jednakowej wielkości w ramach jednego procesu rozpoznawania. Przy pierwszym podejściu (bazując na doświadczeniu zdobytym w dotychczasowych badaniach) wybrano kwadratowe pole o wielkości 41×41 pikseli. Skrajne naroża zdefiniowane były jako x-20, y-20 oraz x+20, y+20. Gdzie x oraz y były współrzędnymi analizowanego punktu i podawane są w pikselach. Należy zaznaczyć, że wielkość analizowanych obrazów wynosiła 1280×960 pikseli.

W tabeli 2 zestawiono wyniki klasyfikacji dla opisanego wcześniej 12 wymiarowej przestrzeni cech. Ciąg uczący stanowiło 50 losowo wybranych obiektów dla każdej klasy (w sumie 200 obiektów). Pozostałe 5000 obiektów traktowane jako nieznanne i poddano rozpoznaniu. W porównaniu z opisywanymi wcześniej badaniami (patrz tabela 1) zrezygnowano z metody najbliższej mody (NM) gdyż zazwyczaj dawała niezadowalające rezultaty oraz metody kNN dla k = 11 (zazwyczaj dawała gorsze rezultaty niż dla mniejszych k).

**Tab. 2.** Zestawienie wyników klasyfikacji cech strukturalnych węgla (12 wymiarowa przestrzeń cech) dla 5000 obszarów rozpoznawanych przy 200 elementowym ciągu uczącym. Wielkość pola 41×41 pikseli

Metoda	NN	kNN (k = 3)	kNN (k = 5)	kNN (k = 7)	OOK	AL	AK
Poprawne rozpoznanie [%]	91,36	92,48	92,66	92,12	75,10	91,48	91,82
Brak rozpoznania [%]	0	0,06	0,18	0,20	23,30	0	0

Otrzymane wyniki są nieco gorsze od tych, zaprezentowanych w tabeli 1. Jest to najpewniej związane z faktem, iż w tabeli 1 analizowano pola o jednorodnej strukturze. Klasyfikacja z tabeli 2 bazuje na analizie obrysowanych pól wokół punktów o znanej przynależności. Natomiast obrysowane wokół nich pola nie muszą już zawierać jednorodnych pod względem struktury obszarów.

Biorąc pod uwagę powyższe wyjaśnienia należy uznać, że poprawność klasyfikacji na poziomie powyżej 90% jest zadawalająca. Niemniej jednak, w dalszych badaniach poszukiwano sposobu na polepszenie tych wyników.

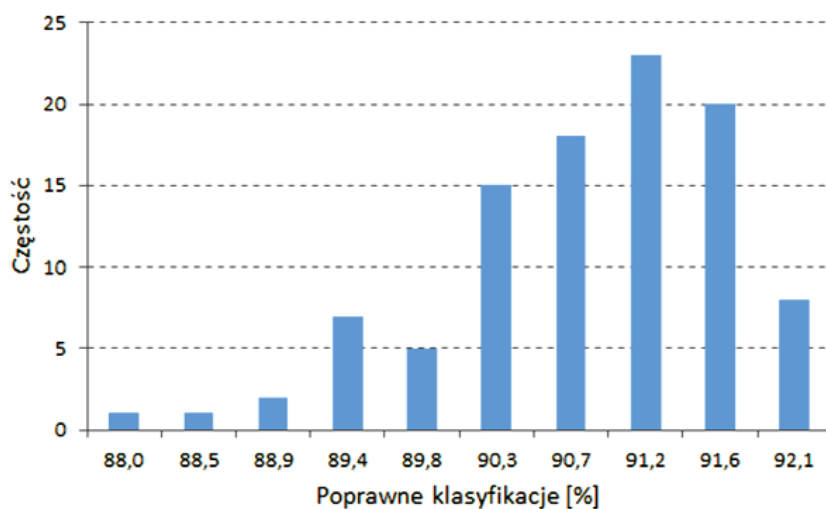
#### 4.2. Wpływ wyboru ciągu uczącego na wynik klasyfikacji

W swej, pionierskiej na polskim rynku książce pt. *Rozpoznawanie obrazów*, Tadeusiewicz i Flasiński (1991) piszą: „Wybór elementów należących do ciągu uczącego powinien zapewniać jego reprezentatywność. W praktyce jednak ciąg ten zazwyczaj stanowi próbkę losowo wybraną ze zbioru D” (gdzie przez D oznaczony jest zbiór obiektów podlegających rozpoznawaniu). Również w opisywanych badaniach dobór elementów ciągu uczącego był losowy. W badaniach sprawdzono jednak, jak losowość wybranego ciągu wpływa na poprawność rozpoznania.

Dla metody NN (najbardziej klasycznej i zwracającej dobre klasyfikacje) przeprowadzono rozpoznania przy 100 losowaniach 200-elementowego ciągu uczącego (po 50 elementów na klasę). Rezultaty pomiarów zestawiono w tabeli 3. Na rysunku 2 przedstawiono histogram poprawnych klasyfikacji dla analizowanego przykładu.

**Tab. 3.** Statystyka poprawności klasyfikacji dla 100 losowo wybranych ciągów uczących (metoda NN, wielkość obszaru 41×41 pikseli, 50 elementów ciągu uczącego)

Średnia	Wartość		Odchylenie standardowe	Współczynnik zmienności
	Maksymalna	Minimalna		
90,85%	92,30%	87,78%	0,886%	1%



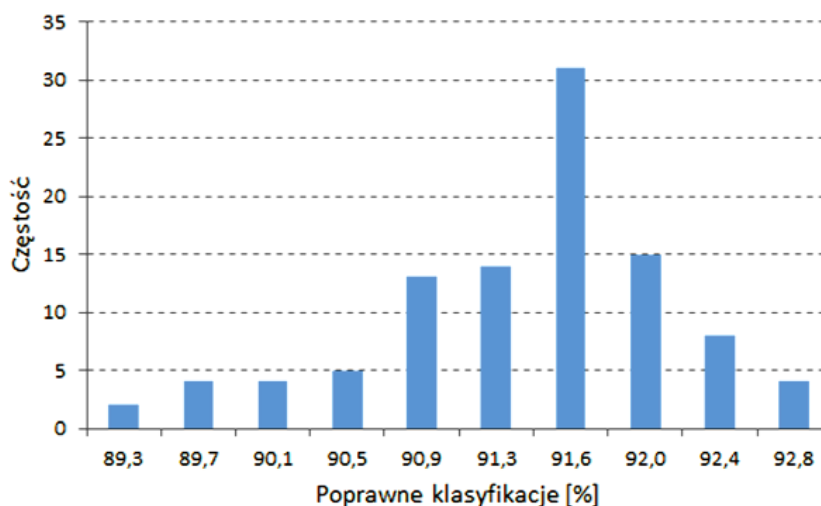
**Rys. 2.** Histogram poprawnych klasyfikacji dla 100 losowo wybranych ciągów uczących (metoda NN, wielkość obszaru 41×41 pikseli, 50 elementów ciągu uczącego)

### 4.3. Optimalizacja metody – zmiana przestrzeni barw rozpoznawanej struktury

Autorzy zajmujący się problematyką analizy obrazu w zastosowaniach geologicznych zwracają uwagę na fakt, że prowadzenie przekształceń obrazu w przestrzeni barw CIELab daje niekiedy lepsze wyniki, niż wykorzystywanie przestrzeni barw RGB (Obara, 2007). Podobne wnioski pojawiają się również w przypadku wykorzystania metod rozpoznawania obrazów do celów geologicznych (Młynarczyk i in, 2013). Bazując na tych spostrzeżeniach dokonano transformacji wykorzystywanych w pracy obrazów z przestrzeni barw RGB do przestrzeni CIELab. Korzystając z tego samego zbioru, 5200 punktów pomiarowych przeprowadzono analizę poprawności klasyfikacji metodą NN dla 100 losowań 50-elementowego ciągu uczącego. Wyniki przedstawiono w tabeli 4. Rysunek 3 przedstawiono histogram poprawnych klasyfikacji dla tego przykładu.

**Tab. 4.** Statystyka poprawności klasyfikacji dla 100 losowo wybranych ciągów uczących (metoda NN, wielkość obszaru 41×41 pikseli, 50 elementów ciągu uczącego, przestrzeń barw CIELab)

Wartość			Odchylenie standardowe	Współczynnik zmienności
Średnia	Maksymalna	Minimalna		
91,48%	93,00%	89,12%	0,78%	0,9%



**Rys. 3.** Histogram poprawnych klasyfikacji dla 100 losowo wybranych ciągów uczących (metoda NN, wielkość obszaru 41×41 pikseli, 50 elementów ciągu uczącego, przestrzeń barw CIELab)

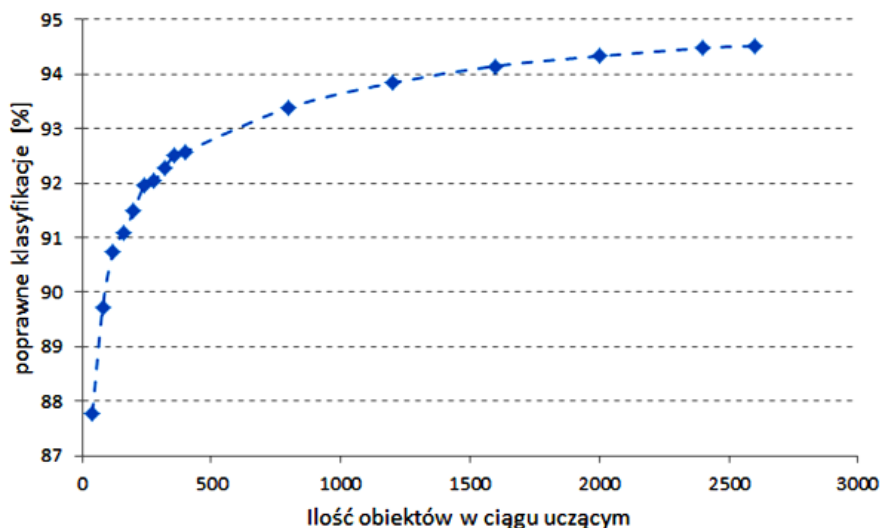
Otrzymane wyniki świadczą, że przejście z modelu barw RGB na model CIELab nieco poprawiło wyniki klasyfikacji. W tabeli 5 zestawiono rozpoznania poszczególnych metod dla przestrzeni RGB i CIELab. Wykorzystano ciąg uczący, który zwrócił najlepsze rozpoznania dla metody NN podczas badań, których wyniki zestawiono w tabeli 4.

**Tab. 5.** Zestawienie wyników klasyfikacji cech strukturalnych węgla (12 wymiarowa przestrzeń cech) dla 5000 obszarów rozpoznawanych przy 200 elementowym ciągu uczącym. Wielkość pola 41×41 pikseli. Przestrzeń barw CIELab. Optimalny ciąg uczący dla metody NN

Metoda	NN	kNN (k = 3)	kNN (k = 5)	kNN (k = 7)	AL	AK
Poprawne rozpoznanie (przestrzeń RGB) [%]	92,30	92,58	92,22	92,12	93,60	92,42
Poprawne rozpoznanie (przestrzeń CIELab) [%]	93,00	93,22	93,10	93,16	92,54	94,00

### 4.4. Wpływ wielkości ciągu uczącego na wynik klasyfikacji

Przyjmuje się, że jedną z metod polepszenia reprezentatywności losowanego ciągu uczącego, jest jego wydłużenie (Tadeusiewicz i Flasiński, 1991). Na wykresie z rysunku 4 zaprezentowano zmianę średnich poprawnych klasyfikacji dla metody NN, dla pola pomiarowego 41 pikseli i przestrzeni barw CIELab. Na



Rys. 4. Zależność pomiędzy wielkością ciągu uczącego a średnią ilością poprawnych klasyfikacji dla metody NN, dla pola pomiarowego 41 pikseli i przestrzeni barw CIELab

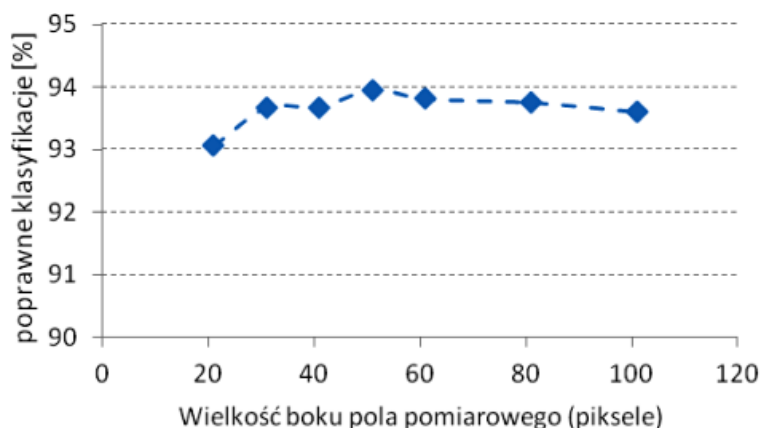
osi odciętych podano ilość obiektów w ciągu uczącym. Składały się na nią cztery, identyczne ilościowo grupy obiektów dla każdej z analizowanych klas.

Z wykresu widać, że procent poprawnych klasyfikacji rośnie, wraz ze wzrostem ilości obiektów w ciągu uczącym. Należy mieć jednak na uwadze, że wzrost wielkości ciągu uczącego pociąga za sobą zwiększenie czasu obliczeń. Dodatkowo, w omawianych pomiarach dysponowano 5200 obiektami. Obiekty te dzielono na obiekty ciągu uczącego oraz obiekty do rozpoznania. Tak więc zwiększenie długości ciągu uczącego wpływało na zmniejszenie liczby rozpoznawanych obiektów.

#### 4.5. Wpływ wielkości pola pomiarowego na wynik klasyfikacji

W dotychczasowych pomiarach wykorzystywano pole pomiarowe (wokół danego punktu pomiarowego) o wielkości 41 pikseli. W niniejszym rozdziale zilustrowana zostanie zmiana liczby poprawnych klasyfikacji dla różnych wielkości danego pola. Również w tych pomiarach ograniczono się do metody NN, przestrzeni barw CIELab, oraz (bazując na wynikach zaprezentowanych w poprzednim rozdziale) używano 1000 elementowego ciągu uczącego (po 250 obiektów na klasę). Rozpoznawano więc 4200 nieznanych (dla komputera) obiektów. Wyniki przedstawiono na rysunku 5.

Otrzymane rezultaty wskazują, że dla analizowanej struktury optymalną wielkością pola pomiarowego jest 51 pikseli, czyli, że jest ona zbliżona do tej, jaka dotychczas była rozpatrywana. W tabeli 6 zestawiono wyniki klasyfikacji dla różnych metod rozpoznawania obrazów przy wykorzystaniu pola o tej wielkości i przy optymalnym dla metody NN ciągu uczącym.



Rys. 5. Zależność pomiędzy wielkością pola pomiarowego a średnią ilością poprawnych klasyfikacji dla metody NN (dla ciągu uczącego o 1000 obiektach i przestrzeni barw CIELab)



**Tab. 6.** Zestawienie wyników klasyfikacji cech strukturalnych węgla (12 wymiarowa przestrzeń cech) dla 5000 obszarów rozpoznawanych przy 1000 elementowym ciągu uczącym. Wielkość pola 51×51 pikseli

Metoda	NN	kNN (k = 3)	kNN (k = 5)	kNN (k = 7)	OOK	AL	AK
Poprawne rozpoznanie [%]	94,71	94,83	94,69	94,86	71,24	93,83	95,33
Brak rozpoznania [%]	0	0,07	0,07	0,10	28,21	0	0

#### 4.6. Wpływ wyboru metryki odległości na wynik klasyfikacji

Metody rozpoznawania obrazów bazują na pojęciu odległości w przestrzeni cech. Intuicyjnie przyjmujemy, że jest to odległość w rozumieniu metryki euklidesowej. Jednakże nie musi tak być i niekiedy inne metryki dają inne (lepsze lub gorsze) wyniki klasyfikacji. W ramach prowadzonych badań przetestowano 6 metryk odległości. Badania prowadzono dla metody NN, przestrzeni barw CIELab oraz 1000 elementowego ciągu uczącego. Wyniki tych badań zestawiono w tabeli 7.

**Tab. 7.** Wpływ metryki odległości na wynik rozpoznania (12 wymiarowa przestrzeń cech, 1000 elementowy ciąg uczący. Wielkość pola 51×51 pikseli)

Metryka	Średni procent poprawnych klasyfikacji dla metody NN
Minkowskiego	93,70
Euklidesowa	93,63
Uliczna	93,68
Czebyszewa	92,99
Mahalanobiusa	90,81
Euklidesowa – unormowana	95,25

Pomiary wykazały, że dla rozpatrywanych danych istnieje stosunkowo niewielka różnica pomiędzy rozpoznaniem w metrykach euklidesowej, Minkowskiego, Uliczna i Czebyszewa. Natomiast dość dobrze wypada unormowana metryka euklidesowa. Wyniki rozpoznania dla tej metryki przy wykorzystaniu pola o wielkości 51 pikseli i przy optymalnym dla metody NN ciągu 1000 elementowym uczącym zestawiono w tabeli 8.

**Tab. 8.** Zestawienie wyników klasyfikacji cech strukturalnych węgla (12 wymiarowa przestrzeń cech) dla 5000 obszarów rozpoznawanych przy 1000 elementowym ciągu uczącym. Wielkość pola 51×51 pikseli. Przestrzeń euklidesowa unormowana

Metoda	NN	kNN (k = 3)	kNN (k = 5)	kNN (k = 7)	OOK	AL	AK
Poprawne rozpoznanie [%]	96,26	96,07	95,64	95,48	74,10	95,40	95,33
Brak rozpoznania [%]	0	0,12	0,14	0,07	25,67	0	0

#### 4.7. Zwiększenie wymiaru przestrzeni cech poprzez dodanie parametru opisującego ukierunkowanie struktury

Analizowana struktura charakteryzuje się pewnym ukierunkowaniem zarówno dla obszarów spękanych (katakłaza) jak i dla inertynitu. Postanowiono zwiększyć przestrzeń cech, w której prowadzone były pomiary, poprzez dodanie parametru opisującego ukierunkowanie. Parametr uzyskano, przeprowadzając na analizowanych wycinkach obrazu przekształcenie gradientu morfologicznego, a następnie operacje erozji w 4 kierunkach (0, 45, 90, 135 stopni). Dla każdego obszaru wyznaczono minimalną i maksymalną objętość obrazu po każdej z erozji kierunkowych. Ich stosunek przyjęto jako miarę ukierunkowania struktury na obszarze pomiarowym. Wyniki rozpoznania w rozszerzonej o ten parametr, 13-wymiarowej przestrzeni cech zestawiono w tabeli 9. Ogląd tabeli wskazuje, że dodanie tego parametru nie zwiększyło poprawności rozpoznania (np. w stosunku do wyników zestawionych w tabeli 8)

**Tab. 9.** Zestawienie wyników klasyfikacji cech strukturalnych węgla (13 wymiarowa przestrzeń cech) dla 5000 obszarów rozpoznawanych przy 1000 elementowym ciągu uczącym. Wielkość pola 51×51 pikseli

Metoda	NN	kNN (k = 3)	kNN (k = 5)	kNN (k = 7)	OOK	AL	AK
Poprawne rozpoznanie [%]	96,21	95,93	95,64	95,41	68,55	95,14	94,79
Brak rozpoznania [%]	0	0,14	0,07	0,02	31,29	0	0

#### 4.8. Analiza ilości błędnych klasyfikacji w zależności od rozpoznawanej struktury

Błędy rozpoznania dotyczą w różnej mierze różnych struktur. Wyniki pomiarów, zestawionych w tabeli 11 wskazują, że najlepiej, na poziomie bliskim 100% poprawnych rozpoznania, klasyfikowany jest klej. Również z dużą dokładnością, wynoszącą 99% klasyfikowany jest wityrynit. Jest to o tyle istotny wynik, że tego macerału jest w węglu najwięcej i jego poprawna klasyfikacja jest kluczowa z punktu widzenia poprawności całej analizy. Nieco gorzej, na poziomie ok. 95 procent rozpoznawana jest kataklaza. Najgorsze wyniki (89,4% poprawnych rozpoznania) otrzymujemy podczas analizy inertynitu. Z tabeli 10 można wyciągnąć wniosek, że główne błędy proponowanej analizy polegają na mylnym rozpoznaniu inertynitu jako kataklazy i odwrotnie.

**Tab. 10.** Zestawienie wyników klasyfikacji poszczególnych cech strukturalnych węgla (13 wymiarowa przestrzeń cech, 1000 elementowy ciąg uczący, wielkość pola 51×51 pikseli, metryka euklidesowa – unormowana)

	Wityrynit	Inertynit	Kataklaza	Klej
Wityrynit	99,05	0,1	0	0,85
Inertynit	1,14	89,43	9,43	0
Kataklaza	0,1	4,94	94,95	0
Klej	0,1	0,2	0	99,70

### 5. Podsumowanie

W pracy opisano badania mające na celu optymalny dobór parametrów, przy których powinna odbywać się automatyczna klasyfikacja wityrynytu, inertynitu, kataklazy oraz kleju – istotnych cech strukturalnych i petrograficznych węgla z punktu widzenia zagrożeń metanowych i wyrzutowych. Podczas badań wykazano, że dla analizowanej struktury oraz dla zdjęć wykonanych w sposób opisany w pracy, optymalnymi parametrami są: wykorzystanie przestrzeni barw CIELab, wykorzystanie 1000 elementowego ciągu uczącego, prowadzenie klasyfikacji w unormowanej przestrzeni euklidesowej oraz podejmowanie decyzji na bazie analizy pola pomiarowego w postaci kwadratu o boku 51 pikseli. Pewną niespodzianką był brak poprawy wyników rozpoznania po wprowadzeniu dodatkowego parametry opisującego ukierunkowanie struktury.

Prowadzenie klasyfikacji w proponowanych w pracy warunkach prowadzi do uzyskania poprawnych klasyfikacji na poziomie ponad 95%, a najlepszy osiągnięty wynik to 96,26% poprawnych klasyfikacji. Rezultaty te świadczą o możliwości wykorzystania metod sztucznej inteligencji do wspierania procesów rozpoznawania i klasyfikacji wybranych cech strukturalnych i petrograficznych węgla.

Praca została wykonana w roku 2013 w ramach prac statutowych realizowanych w IMG PAN w Krakowie, finansowanych przez Ministerstwo Nauki i Szkolnictwa Wzroszego.

### Literatura

- Beamish B., Crosdale P.J., 1998: *Instantaneous outbursts in underground coal mines: An overview and association with coal type*. International Journal of Coal Geology 35. 27-55.
- Bodziony J., Kraj W., Ratajczak T., 1990: *Zastosowanie stereologii w badaniach struktury węgla dolnośląskich*, [w:] Górotwór jako ośrodek wielofazowy – Wrzuty skalno-gazowe, Wydawnictwo AGH – Kraków.
- Bodziony J., Lama R.D., 1996: *Sudden outburst of gas and coal in underground coal mines*. Publisher Lama & Associates, 130 Brokers Road, Mt. Pleasant, NSW 2519, Australia.
- Cao Y., Mitchell G.D., Davis A., Wang D., 2000: *Deformation metamorphism of bituminous and anthracite coals from China*. International Journal of Coal Geology 43, 227-242.
- ICCP (International Committee for Coal and Organic Petrology), 1998, The New vitrinite classification (ICCP System 1994), Fuel, vol. 77, pp 349-58.
- ICCP (International Committee for Coal and Organic Petrology), 2001, The New inertynite classification (ICCP System 1994), Fuel vol. 80, pp 459-71
- Li H., Ogawa Y., Shimada S., 2003: *Mechanism of methane flow through sheared coals and its role on methane recovery*. Fuel 82, 1271-1279.
- Młynarczuk M., Wierzbicki M., 2009: *Stereological and profilometry methods in detection of structural deformations in coal samples collected from the rock and outburst zone in the "Zofiówka" Colliery*. Arch. Min. Sci., Vol. 54, No 2, p. 189-201.



- Młynarczyk M., Godyń K., 2012: *Wykorzystanie metod rozpoznawania obrazów do wspierania procesu decyzyjnego dotyczącego klasyfikacji węgla ze względu na wybrane cechy petrograficzne*. Prace Instytutu Mechaniki Górotworu PAN, Tom 14, nr 1-4, s. 3-14
- Młynarczyk M., Górszczyk A., Ślipek B., 2013: *The application of pattern recognition in the automatic classification of microscopic rock images*. Computers & Geosciences 60, 126-133,
- 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 and Geosciences 33 (2), 151-158.
- PN-ISO 7404-3:2001: *Metody analizy petrograficznej węgla kamiennego (bitumicznego) i antracytu – Metoda oznaczania składu grup maceratów*.
- Shepherd J., Rixon L.K., Creasey J.W., 1980: *Analysis and prediction of geological structures associated with outbursts at Collinsville, Queensland*. The Occurrence, Prediction and Control of Outbursts in Coal Mines Symposium, Australian Institute of Mining and Metallurgy, Parkville, Victoria, Australia, 159-171.
- Tadeusiewicz R., Flasiński M., 1991: *Rozpoznawanie obrazów*,
- Wierzbicki M., Młynarczyk M., 2006: *Microscopic analysis of structure of coal samples collected after an gas and coal outbursts in the gallery D-6, coal seam 409/4 in the „Zofiówka” coal mine (Upper Silesian Coal Basin)*. Arch. Min. Sci., Vol. 51, No 4, p. 577-588.

## **Optimisation of the automatic classification of structural parameters of coals from the areas threatened by rock and gas outbursts, based on the pattern recognition procedures**

### **Abstract**

In 2012 research work was undertaken aimed to utilise the pattern recognition methods in identification of structural and petrographic features of coal. This stage of the research program was focused on automatic identification of vitrinite, inertinite and cataclasis. These petrographic and structural features of coals are typically analysed at the Strata Mechanics Research Institute when evaluating the outburst hazard. The adequacy of parameters defining the features space as well as the influence of the measurement window size on the result of recognition was evaluated. Other issues addressed include the influence of the colour space in which the measurements are taken and the impact of distance metrics. Results include a high-proportion of correct classifications of investigated structures (over 95%), thus confirming the adequacy of AI methods in automatic identification of selected petrographic and structural features of coal.

**Keywords:** pattern recognition, quantitative analysis of coal, coal structure