

## MULTIFRAKTALNA ANALIZA ZOBRAZOWAŃ SATELITARNYCH

### MULTIFRACTAL ANALYSIS OF SATELLITE IMAGES

Anna Wawrzaszek<sup>1</sup>, Michał Krupiński<sup>1</sup>, Wojciech Drzewiecki<sup>2</sup>,  
Sebastian Aleksandrowicz<sup>1</sup>

<sup>1</sup> Centrum Badań Kosmicznych Polskiej Akademii Nauk, Warszawa

<sup>2</sup> AGH w Krakowie, Wydział Geodezji Górniczej i Inżynierii Środowiska,  
Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska

SŁOWA KLUCZOWE: obrazy satelitarne, hiperspektralne obrazy lotnicze, wymiar fraktalny, poziom multifraktalności, klasyfikacja

STRESZCZENIE: Przedstawione prace badawcze dotyczyły oceny skuteczności stosowania opisu multifraktalnego jako narzędzia do wydobywania informacji z bardzo wysokorozdzielczych zobrażeń satelitarnych, prezentujących głównie obszary Polski. Przeanalizowano duże zestawy danych panchromatycznych, zarejestrowanych przez satelity WorldView-2 i EROS-A. Wyniki analiz potwierdziły wyższość multifraktali jako globalnych charakterystyk zobrażeń nad standardowym opisem fraktalnym, a także użyteczność stosowania parametrów multifraktalnych jako charakterystyk w klasyfikacji zdjęć satelitarnych przy użyciu klasyfikacyjnych drzew decyzyjnych. Porównano również cechy multifraktalne z szeroko stosowanymi parametrami teksturalnymi w kontekście skuteczności klasyfikacji zdjęć satelitarnych i przeanalizowano wpływ filtracji na wyznaczone charakterystyki multifraktalne, w szczególności w kontekście poprawy skuteczności klasyfikacji. Przeprowadzono również wstępne badania dotyczące możliwości wykorzystania fraktali w analizach lotniczych danych hiperspektralnych. Przeprowadzone analizy wykazały użyteczność multifraktali w wielu obszarach badań teledetekcyjnych, a wypracowana metodologia może być z powodzeniem dalej rozwijana i stosowana do bardziej ukierunkowanych zadań, takich jak analiza zmian lub ocena przydatności kanałów spektralnych.

### 1. WSTĘP

Formalizm fraktalny, rozwinięty i rozpowszechniony dzięki pracom Mandelbrota (1982), znalazł szerokie zastosowanie w analizie różnego typu danych, w tym obrazowych. W teledetekcji satelitarnej podejście to wykorzystywane było w szczególności do charakteryzowania pewnych aspektów teksturalnych obrazów teledetekcyjnych (Sun *et al.*, 2006). W wielu jednak przypadkach własności teledetekcyjnych obrazów powierzchni Ziemi odbiegały w znaczący sposób od założeń idealnego monofraktala (De Cola, 1993). Z tego też powodu intensywnie rozwijano metody fraktalne, bądź zaczęto przechodzić na bardziej zaawansowany opis multifraktalny. Przeglądu literatury na temat użyteczności opisu fraktalnego i multifraktalnego w zagadnieniach teledetekcyjnych dokonano m.in. w pracach (Sun *et al.*, 2006; Wawrzaszek *et al.*, 2013a).

Niniejsza praca wpisuje się w przedstawioną powyżej tematykę stanowiąc przegląd i podsumowanie wybranych badań prowadzonych w ramach projektu realizowanego w latach 2013-2015 (finansowanego przez Narodowe Centrum Nauki), w ramach którego poddano ocenie użyteczność opisu multifraktałnego jako narzędzia do wydobywania wiedzy z wysokorozdzielczych obrazów satelitarnych i lotniczych, prezentujących głównie obszary Polski. W szczególności, w ramach poniższej pracy przedstawiono próby klasyfikacji jednorodnych próbek danych o bardzo dużej rozdzielczości przestrzennej w oparciu o parametry multifraktałne (Drzewiecki *et al.*, 2012). Następnie porównano użyteczność parametrów multifraktałnych z wymiarem fraktalnym (Wawrzaszek *et al.*, 2013b) i innymi parametrami teksturalnymi (Drzewiecki *et al.*, 2013a; Drzewiecki *et al.*, 2013b; Pyka *et al.*, 2014). Praca przedstawia również wpływ procesu filtracji zdjęć na wartości wyznaczanych parametrów fraktalnych i multifraktałnych (Wawrzaszek *et al.*, 2014). Na koniec zaprezentowano wyniki fraktalnego opisu hiperspektralnych danych lotniczych, (Krupiński *et al.*, 2014).

## 2. DANE

Do analiz wybrano panchromatyczne zdjęcia satelitarne o bardzo dużej rozdzielczości przestrzennej (WorldView-2, EROS-A) oraz zdjęcia hiperspektralne, wykonywane z poziomu lotniczego sensorem AVIRIS. Badania przeprowadzono na wyselekcjonowanych fragmentach zdjęć prezentujących jednorodne formy pokrycia terenu (pola uprawne, lasy, wodę, tereny zurbanizowane i góry). Dane zostały zaklasyfikowane do poszczególnych klas na podstawie interpretacji wizualnej wykonanej przez dwóch niezależnych specjalistów.

Tabela 1. Zestawienie danych użytych w analizach

sensor	rozmiar próbki	liczba próbek	rozdzielczość przestrzenna	rozdzielczość spektralna	udział dominującej klasy pokrycia
WorldView-2	512×512 1024×1024	159 964	0.5 m	450-800 nm	> 90%
EROS-A	512×512	1214	2.0 m	500-900 nm	> 50%
AVIRIS	512×512	4	15 m	366-2500 nm	> 90%

W przeprowadzanych analizach fragmenty zdjęć satelitarnych o bardzo dużej rozdzielczości nie były poddawane żadnym korekcjom. Z kolei w przypadku danych hiperspektralnych (lotniczych) rozważono zarówno dane przed jak i po korekcji atmosferycznej. Tabela 1 zawiera zbiorcze zestawienie wyselekcjonowanych danych oraz ich podstawowe parametry. W sumie przeanalizowano 2341 fragmentów zdjęć. W badaniach za jednorodne próbki uznano te, na których dominująca klasa pokrycia terenu obejmuje co najmniej 90% powierzchni. Część analiz prowadzona była również dla prognozy wynoszącej 50%.

### 3. METODOLOGIA

W ramach przeprowadzanych badań zastosowano dwa podejścia. W pierwszym ujęciu, zdjęcia satelitarne (lub ich fragmenty) analizowane były jako struktury fraktalne opisywane za pomocą jednej liczby – wymiaru fraktalnego (ang. *fractal dimension*). Wymiar fraktalny, oznaczany jako  $D_F$ , określa samopodobieństwo na różnych skalach fraktala. Istnieje wiele metod jego wyznaczenia, głównie dla obrazów binarnych (Sun *et al.*, 2006). W naszych badaniach aby uniknąć binaryzacji i bezpośrednio analizować obrazy w skali szarości, zaimplementowano metodę zaproponowaną w pracy (Sarkar i Chaudhuri, 1994), tzw. *Differential Box-Counting* (DBC). Szczegółowy opis metody wyznaczenia wymiaru fraktalnego przedstawiono w pracach (Sarkar i Chaudhuri, 1994; Chaudhuri i Sarkar, 1995; Wawrzaszek *et al.*, 2014; Krupiński *et al.*, 2014).

W drugim podejściu, rozwijanym w ramach projektu, interpretacja tych samych zdjęć opierała się na założeniu, że do opisu niejednorodnego rozkładu intensywności na obrazie konieczne jest zastosowanie wielu nietrywialnie połączonych fraktali – multifraktali (Wawrzaszek *et al.*, 2013b). Należy jednak podkreślić, że podejście to stosowano z dużą ostrożnością, mając na uwadze, że nie wszystkie zobrazowania satelitarne muszą prezentować naturę multifraktalną. Na potrzeby badań zaimplementowano metodę, tzw. *Box-Counting Based Moment Method* (Halsey *et al.*, 1986), szerzej opisaną w artykule Wawrzaszek *et al.* (2014). Metoda ta, zastosowana głównie do zobrazowań panchromatycznych, pozwoliła na wyznaczenie funkcji i parametrów multifraktalnych z obrazów monochromatycznych. Obraz pokrywano jedną z trzech miar: miarą sumującą wartości pikseli w danym otoczeniu (SUM), miarą określającą największe wartości pikseli (MAX) oraz miarą badającą odchylenia poziomów szarości (BCD). Następnie rozważano własności skalowania danej miary na różnych rozmiarach boków, od boków o rozmiarze piksela do rozmiaru całego obrazu. Analiza skalowania miary weryfikowała możliwość stosowania opisu multifraktalnego i w konsekwencji prowadziła do wyznaczenia dwóch funkcji multifraktalnych dla badanego obrazu: wymiarów uogólnionych i widma multifraktalnego. Analiza tych funkcji z kolei pozwalała na wyznaczenie multifraktalnych parametrów liczbowych, stosowanych do opisywania treści zdjęć satelitarnych. Najczęściej stosowanym parametrem multifraktalnym był poziom multifraktalności (ang. *degree of multifractality*), oznaczany dalej symbolem  $\Delta$ .

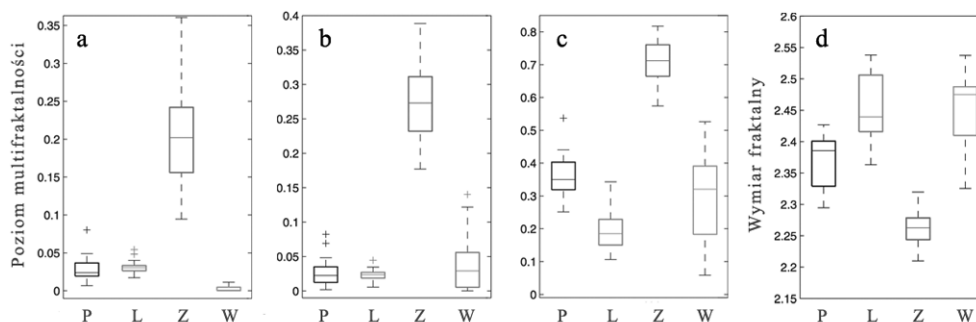
Przyjęta metodologia została zweryfikowana na sztucznych obrazach multifraktalnych (Perfect *et al.*, 2009). Najpierw wygenerowano sztuczne obrazy o zadanych parametrach multifraktalnych, a następnie stosując metodę przedstawioną powyżej udało się te parametry odtworzyć. Galeria ze sztucznymi obrazami multifraktalnymi została udostępniona na stronie: <http://zoz.cbk.waw.pl/multifraktale/>.

### 4. ANALIZY

#### 4.1. Poziom multifraktalności a formy pokrycia terenu

Ocenę przydatności parametrów multifraktalnych w kontekście opisu danych teledetekcyjnych o bardzo dużej rozdzielczości rozpoczęto od badania zależności pomiędzy wartościami parametrów multifraktalnych a formą pokrycia terenu prezentowaną na zdjęciu

(Drzewiecki *et al.*, 2012, Wawrzaszek *et al.*, 2013a). W tym celu, dla wyselekcjonowanych próbek danych VHR z jednorodnymi formami pokrycia terenu zdefiniowano miary SUM, MAX, BCD (opisane w rozdziale 3) i przy ich zastosowaniu wyznaczono ilościowe parametry multifraktalne. Wyniki analiz udowodniły wyraźną zależność pomiędzy badanymi formami okrycia terenu a wartościami parametru  $\Delta$ . Rysunek 1 (a, b, c) prezentuje przykładowe wyniki dla różnych miar wykorzystanych do obliczenia poziomu multifraktalności. W ramach dalszej części eksperymentu do oceny możliwości automatycznego rozpoznania dominującego na badanym fragmencie obrazu pokrycia terenu zastosowano algorytm klasyfikacyjny C5.0. Porównano kilka różnych zestawów cech klasyfikacyjnych, biorąc oprócz parametrów multifraktalnych także cztery pierwsze momenty statystyczne. Do oceny wyników wykorzystano dokładność całkowitą klasyfikacji, a także precyzję i czułość (ang. *recall*), dla poszczególnych form pokrycia terenu. Miary te są powszechnie stosowane w systemach wyszukiwania obrazów na podstawie zawartości (ang. *Content-Based Image Retrieval*) i rozpoznawania wzorców (ang. *Pattern Recognition*) (Smeulders *et al.*, 2000). Badania pokazały, że formalizm multifraktalny umożliwił osiągnięcie wysokiej precyzji, a wynik zależy od liczby użytych parametrów. Najbardziej przydatne okazały się w tym przypadku miary SUM i BCD.



Rys. 1. Wykresy pudełkowe prezentujące wartości poziomu multifraktalności  $\Delta$  (a, b, c) i wymiaru fraktalnego  $D_F$  (d), wyznaczone dla czterech form pokrycia terenu ( pola – P, lasy – L, zabudowa – Z, woda – W ) z obrazów WoldView-2 (Wawrzaszek *et al.*, 2013b). Parametr  $\Delta$  wyznaczono przy zastosowaniu miary SUM (a), MAX(b) i BCD (c)

Warto podkreślić porównanie pomiędzy wartościami wymiaru fraktalnego a wartościami poziomu multifraktalności dla czterech form pokrycia terenu (pól uprawnych, lasów, zabudowy i wody), jakie przeprowadzono na prawie 400 próbkach. Rysunek 1 prezentuje rozkład wartości poszczególnych parametrów w postaci wykresów pudełkowych.

Zgodnie z wynikami analiz, wartości wymiaru fraktalnego (rys. 1d) wyznaczone dla poszczególnych form pokrycia terenu nachodzą na siebie nie pozwalając na ich rozróżnienie. W przypadku poziomu multifraktalności (rys. 1a, b i c) zaobserwowano wyraźniejszy związek z formami pokrycia terenu. Najwyższe wartości otrzymano dla terenów zabudowanych (rys. 1c), a najniższe dla wody (rys. 1a). W ogólności analizy pokazały, że wyznaczenie poziomu multifraktalności przy użyciu miary SUM pozwala

odseparować wodę od zabudowy. Poziom multifraktalności z miary BCD jest natomiast najlepszy do rozróżniania pól od lasów (Wawrzaszek *et al.*, 2013b).

#### 4.2. Porównanie z parametrami teksturalnymi

Kolejnym krokiem była analiza porównawcza cech multifraktalnych z szeroko stosowanymi parametrami teksturalnymi w kontekście skuteczności klasyfikacji zdjęć satelitarnych WorldView-2 (Drzewiecki *et al.*, 2013a). Porównano wymiar fraktalny, poziom multifraktalności, parametry histogramowe (4 parametry) i charakterystyki teksturalne takie jak: parametry związane z macierzą zdarzeń (220 parametrów), macierzą rozkładu długości pasm (20 parametrów), macierzą gradientu (5 parametrów), modelem autoregresji (5 parametrów), analizą falkową (33 parametry). Razem rozważono 294 cechy klasyfikacyjne. Klasyfikację przeprowadzono przy wykorzystaniu drzew decyzyjnych i algorytmu C5.0. Dodatkowo, przeprowadzono klasyfikacje dla każdej z grup parametrów teksturalnych rozszerzonej o parametry histogramowe. Dopelnieniem testów była klasyfikacja z wykorzystaniem wszystkich parametrów teksturalnych z i bez parametrów histogramowych. Zestawienie uzyskanej dokładności klasyfikacji prezentuje tabela 2. Jak widać, najwyższą dokładność klasyfikacji (99.6%) otrzymano przy wykorzystaniu wszystkich parametrów. Drugi najlepszy wynik dały wszystkie parametry teksturalne, a trzeci wynik osiągnięto poprzez połączenie parametrów multifraktalnych i histogramowych. Same parametry multifraktalne dały nieco słabszy wynik (o 4.3%). Spośród badanych grup parametrów teksturalnych (stosowanych bez uwzględnienia parametrów histogramowych), najlepszy wynik osiągnęły parametry związane z modelem autoregresji.

By potwierdzić użyteczność testowanych parametrów, porównano ich wartości również dla danych z innego sensora – EROS-A (Drzewiecki *et al.*, 2013b). Fragmenty zdjęć w tym przypadku miały wymiary 512×512 pikseli i reprezentowały jedną z trzech form pokrycia terenu: pola uprawne, lasy lub zabudowę. Przyjęto również mniej restrykcyjny próg określający klasę dominującą – przynajmniej 50% powierzchni powinno reprezentować jedną z wyżej wymienionych klas. Klasyfikację przeprowadzono dla trzech różnych wariantów danych uczących i testowych. W dwóch z nich najlepsze rezultaty uzyskane zostały w oparciu o wszystkie teksturalne cechy klasyfikacyjne bez parametrów histogramowych, w jednym - przy wykorzystaniu cech gradientowych łącznie z cechami histogramowymi. Porównując poszczególne grupy cech teksturalnych, należy stwierdzić, iż w przypadku analizy danych EROS-A najlepsze wyniki otrzymano dla parametrów macierzy gradientu (Drzewiecki *et al.*, 2013b). Warto przy tym zauważyć, że parametry macierzy gradientu zastosowane łącznie z cechami histogramowymi zarówno w klasyfikacji EROS-A jak i we wcześniej opisanych analizach dla WorldView-2 dały zbliżone poziomy błędów klasyfikacji. Dla pozostałych grup parametrów teksturalnych uzyskano dokładność klasyfikacji niższą dla analiz danych EROS-A (w ogólności najwyższa osiągnięta dokładność wyniosła 96.2% w porównaniu z 99.6% dla WorldView-2). Można doszukiwać się różnych przyczyn takiego wyniku. Po pierwsze, WorldView-2 ma mniejszy rozmiar piksela (0.5m w porównaniu do 2.0m EROS-A), jak również większą rozdzielczość radiometryczną. Wyższy poziom szumów na zdjęciach EROS-A może być przyczyną obniżenia jakości miar teksturalnych, na co wydają się być

odporne parametry macierzy gradientu. Po drugie, wpływ może mieć zawartość analizowanych fragmentów zdjęć. Dla WorldView-2 próbki zawierały przynajmniej 90% danej klasy; dla EROS-A było to przynajmniej 50%. W przypadku obu badanych sensorów, parametry multifrakalne, znalazły się również w grupie najużyteczniejszych cech klasyfikacyjnych wybranych przez algorytm w trybie selekcji cech.

Tabela 2. Zestawienie błędów klasyfikacji dla poszczególnych grup parametrów wyznaczonych dla danych z WorldView-2(Drzewiecki *et al.*, 2013a)

zestaw parametrów	liczba parametrów	błąd [%]
wszystkie parametry	294	0.4
wszystkie parametry poza histogramowymi	290	1.0
parametry multifrakalne i histogramowe	10	1.2
parametry modelu autoregresji	5	2.1
parametry modelu autoregresji i histogramowe	9	2.5
wymiar fraktalny i parametry histogramowe	5	3.0
parametry macierzy zdarzeń i histogramowe	224	3.1
parametry z analizy falkowej	33	4.2
parametry macierzy rozkładu długości pasm i histogramowe	24	4.4
parametry histogramowe	4	5.0
parametry multifrakalne	6	5.5
parametry z analizy falkowej i histogramowe	37	6.3
parametry macierzy gradientu i histogramowe	9	7.2
parametry macierz zdarzeń	220	8.5
parametry macierzy rozkładu długości pasm	20	10.9
parametry macierzy gradientu	5	15.2

#### 4.3. Wpływ filtracji na wartości parametrów fraktalnych i multifrakalnych

W ramach projektu przeprowadzono również analizę wpływu filtracji na wyznaczone charakterystyki multifrakalne, w szczególności w kontekście poprawy skuteczności klasyfikacji, jak również wydobywania szumów i brzegów z obrazu. Po pierwsze, zbadano zachowanie wymiaru fraktalnego i poziomu multifrakalności przed i po filtracji zarówno filtrami górno- jak i dolnoprzepustowymi. Filtr medianowy usuwający szumy z obrazu powodował zmniejszanie się poziomu multifrakalności podczas gdy filtry wydobywające brzegi, kontury, np. Kirch, Sigma czy Laplasjan prowadziły do jego zwiększenia dla różnych form pokrycia terenu.

Tabela 3. Zestawienie parametrów wykorzystanych w kolejnych klasyfikacjach (Wawrzaszek *et al.*, 2014)

numer zestawu	średnia		$D_F$		$\Delta$	
	dane oryginalne	dane filtrowane	dane oryginalne	dane filtrowane	dane oryginalne	dane filtrowane
1	✓	✓	✓	–	–	–
2	✓	✓	✓	✓	–	–
3	✓	✓	✓	–	✓	–
4	✓	✓	✓	✓	✓	✓

Najbardziej skutecznym podejściem przy separacji czterech podstawowych form pokrycia terenu (wody, zabudowy, terenów rolniczych i lasów) okazało się zastosowanie filtra Sigma i filtra medianowego przed wyznaczeniem charakterystyk multifraktalnych. Dokładniej, wykonane analizy pokazały, że w celu wyodrębnienia zabudowy najlepszym rozwiązaniem jest użycie filtra Sigma, a dopiero potem wyznaczenie poziomu multifraktalności. Z kolei przy odseparowywaniu wody od innych klas, zwłaszcza od lasów, powinno się stosować filtr medianowy (Wawrzaszek *et al.*, 2014).

Aby ocenić liczbowo, jak filtracja wpływa na użyteczność parametrów fraktalnych i multifraktalnych w klasyfikacji treści zdjęć satelitarnych, przygotowano cztery zestawy parametrów (tabela 3). Klasyfikację przeprowadzono na danych testowych w dwóch wariantach – najmniejszej odległości i znormalizowanej najmniejszej odległości (tabela 4). Całą procedurę powtórzono jeszcze raz używając jako uczących, danych testowych i jako testowych, danych uczących (wartości w nawiasach). W obu wariantach wyniki były bardzo zbliżone.

Tabela 4. Wyniki klasyfikacji w oparciu o cztery zestawy parametrów opisanych w tabeli 3 (Wawrzaszek *et al.*, 2014)

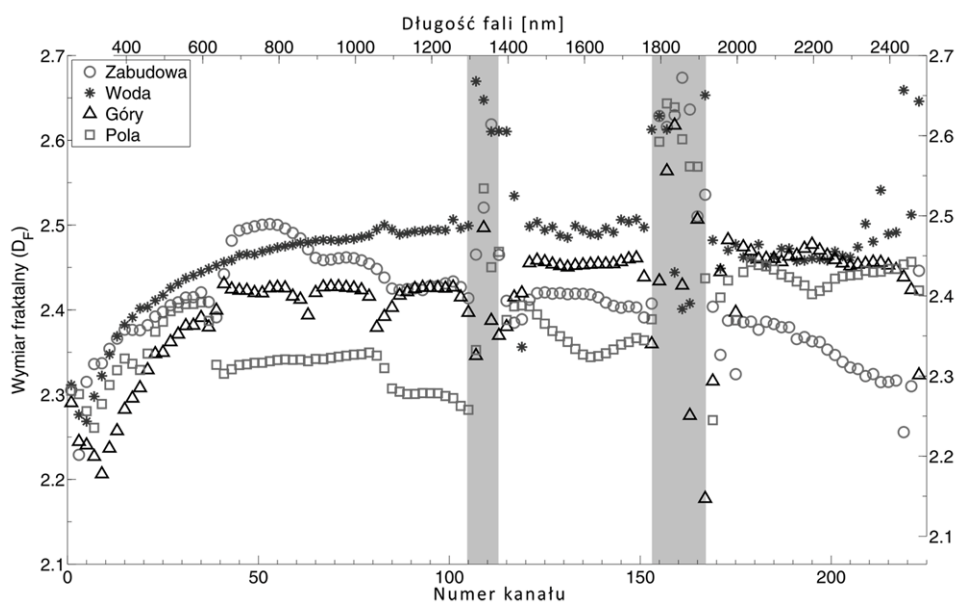
algorytm klasyfikacyjny	zestaw 1	zestaw 2	zestaw 3	zestaw 4
najmniejszej odległości	68.9% (-)	87.2% (88.9%)	97.3% (91.9%)	99.1% (99.0%)
znormalizowanej najmniejszej odległości	72.1% (-)	88.1% (88.4%)	98.6% (96%)	98.6% (99.0%)

#### 4.4. Analiza danych hiperspektralnych

Dodatkowym zagadnieniem, które rozważono w badaniach była możliwość wykorzystania wymiaru fraktalnego do analizy lotniczych danych hiperspektralnych (Krupiński *et al.*, 2014). Analizie poddano jednorodnie pod względem formy pokrycia terenu fragmenty zdjęć zarejestrowane przez sensor AVIRIS. Wybrane fragmenty przedstawiały cztery formy pokrycia terenu: wodę, góry, pola uprawne i tereny zabudowane z okolic Los Angeles (USA). Przeanalizowano dane przed i po korekcji atmosferycznej. Każde zdjęcie sensora AVIRIS składa się z 224 kanałów odpowiadających różnym zakresom rejestrowanego promieniowania elektromagnetycznego z zakresu od 400nm do 2500nm. Dla każdego kanału wyznaczone zostały wartości wymiary fraktalnego

wraz z błędami wyznaczenia. Przeprowadzone analizy pozwoliły ocenić zalety i ograniczenia stosowania opisu fraktalnego w analizie danych hiperspektralnych. Zauważono znaczącą zmienność wartości wymiaru fraktalnego w funkcji długości fali promieniowania elektromagnetycznego. Najmniejszą zmiennością charakteryzowała się woda. Ponadto poszczególne formy pokrycia terenu w wybranych fragmentach promieniowania elektromagnetycznego osiągały różne wartości wymiaru fraktalnego, co pozwalało na wykorzystanie wymiaru fraktalnego jako parametru określającego treść zobrazowania hiperspektralnego. Stwierdzono również znaczące różnice pomiędzy danymi bez i z korekcją atmosferyczną, szczególnie w kanałach odpowiadających zakresowi widzialnego promieniowania elektromagnetycznego. Korekcja atmosferyczna wpłynęła na zwiększenie wartości wymiaru fraktalnego, co może być interpretowane jako wzrost zawartości informacyjnej poszczególnych kanałów poddanych korekcji. Dodatkowo zauważono zaburzenia w wartościach wymiaru fraktalnego w kanałach zasumionych w wyniku silnej absorpcji promieniowania przez cząsteczki wody (rys. 2). Wymiar fraktalny może więc stanowić parametr określający jakość danych hiperspektralnych.

Wstępne wyniki wykazały, iż podobne wartości wymiaru fraktalnego otrzymano dla mniejszych fragmentów zdjęć:  $256 \times 256$ ,  $128 \times 128$  i  $64 \times 64$  piksele.



Rys. 2. Wartości wymiaru fraktalnego dla 224 kanałów, czterech fragmentów zdjęć AVIRIS (Krupiński *et al.*, 2014)

## 5. PODSUMOWANIE I WNIOSKI

Przedstawione wyniki analiz dowodzą użyteczności wymiaru fraktalnego i poziomu multifraktalności jako parametrów opisujących zawartość zdjęć satelitarnych i lotniczych.



W szczególności, wykazano zależność pomiędzy podstawowymi formami pokrycia terenu (pola uprawne, tereny zabudowane, lasy i woda) a wartościami poziomu multifraktalności. Parametr ten może być wykorzystywany jako dodatkowy atrybut w klasyfikacji zdjęć satelitarnych i lotniczych, co wykazano testując jego użyteczność w porównaniu z powszechnie stosowanymi parametrami teksturalnymi. Ponadto badania wpływu filtracji na wartości parametrów fraktalnych i multifraktalnych, potwierdziły hipotezę, iż filtracja może znacząco poprawić wyniki klasyfikacji. Z kolei analiza danych hiperspektralnych wykazała szeroki potencjał wykorzystania wymiaru fraktalnego, m.in. w ocenie jakości korekcji atmosferycznej i zawartości informacyjnej poszczególnych kanałów.

Podsumowując, warto podkreślić, że przeprowadzone do tej pory multifraktalne analizy danych z różnych sensorów, przy wsparciu różnych algorytmów klasyfikacji, wykazały użyteczność multifraktali w wielu obszarach badań teledetekcyjnych, a wypracowana metodologia może być z powodzeniem dalej rozwijana i stosowana do bardziej ukierunkowanych zadań, przykładowo do analizy zmian czy opisu danych hiperspektralnych.

## LITERATURA

Chaudhuri B.B., Sarkar N., 1995. Texture segmentation using fractal dimension, *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 17(1), s. 72–77.

De Cola L., (1993). Multifractals in image processing and process imaging. *Fractals in Geography*, N.S.-N. Lam, L. De Cola (Eds), New Jersey: Prentice Hall, s. 282–304.

Drzewiecki W., Wawrzaszek A., Aleksandrowicz S., Krupiński M., 2012, Initial evaluation of the applicability of multifractal measures as global content-based image descriptors, *Proc. of ESA-EUSC-JRC 8th Conference on Image Information Mining*, DLR, 2012, DOI: 10.2788/49465.

Drzewiecki W., Wawrzaszek A., Aleksandrowicz S., Krupinski M., Bernat K., 2013a, Comparison of selected textural features as global content-based descriptors of VHR satellite image. *Geoscience and Remote Sensing Symposium (IGARSS)*, 2013 IEEE International.

Drzewiecki W., Wawrzaszek A., Krupiński M., Aleksandrowicz S., Bernat K., 2013b, Comparison of selected textural features as global content-based descriptors of VHR satellite image – the EROS-A study. 2013 Federated Conference on Computer Science and Information.

Frigge M., Hoaglin D. C., Iglewicz B., 1989, Some implementations of the boxplot, *The American Statistician*, vol. 43, no. 1, s. 50–54.

Halsey, T.C., Jensen, M.H., Kadanoff, L.P., Procaccia, I., Shraiman, B.I., 1986: Fractal measures and their singularities: The characterization of strange sets. – *Physical Review A* 33 (2), s. 1141–1151.

Krupiński M., Wawrzaszek A., Drzewiecki W., Aleksandrowicz S., 2014. Usefulness of the fractal dimension in the context of hyperspectral data description, 14th International Multidisciplinary Scientific GeoConference SGEM 2014, [www.sgem.org](http://www.sgem.org), *SGEM2014 Conference Proceedings*, ISBN 978-619-7105-12-4 / ISSN 1314-2704, June 19-25, 2014, Book 2, Vol. 3, s. 367-374.

Mandelbrot B., 1982, *The Fractal Geometry of Nature*. – Freeman, New York, NY, USA.

- Nussbaum S., Niemeyer I., Canty M. J., 2006. SEATH – A new tool for automated feature extraction in the context of object-oriented image analysis. – 1st International Conference on Object-based Image Analysis (OBIA 2006). *The International Archives of the Photogrammetry*. – Remote Sensing and Spatial Information Sciences XXXVIII-4/C42.
- Perfect E., Tarquis A. M., Bird N. R. A., 2009. Accuracy of generalized dimensions estimated from grayscale images using the method of moments, *Fractals*, Vol. 17, No. 3, s. 351-363.
- Pyka K., Drzewiecki W., Bernat K., Wawrzaszek A., Krupiński M., 2014. Usefulness of wavelet-based features as global descriptors of VHR satellite images. *Proc. SPIE 9244, Image and Signal Processing for Remote Sensing XX*, 92441D (October 13, 2014).
- Quinlan J.R., 1993. C4.5: Programs for Machine Learning, Morgan Kaufmann, San Mateo.
- Sarkar, N., Chaudhuri B.B., 1995. An efficient differential box-counting approach to compute fractal dimension of image, *IEEE Transactions on Systems, Man and Cybernetics* 24, s. 115-120.
- Smeulders, A. W. M., M. Worring, S. Santini, A. Gupta, Jain R., 2000. Content-Based Image Retrieval at the End of the Early Years, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(12), s. 1349-1380.
- Sun W., Xu G., Gong P., Liang S., (2006). Fractal analysis of remotely sensed images: A review of methods and applications. *International Journal of Remote Sensing*, Vol. 27, No. 22, s. 4963-4990.
- Swain P.H. Davis S.M., 1978, *Remote sensing: The quantitative approach*. – McGrawHill, Whitby, ON, Canada.
- Wawrzaszek A., Krupiński M., Aleksandrowicz S., Drzewiecki W., 2013a. Formalizm multifraktalny w analizie obrazów satelitarnych, *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 25, s. 261 – 272.
- Wawrzaszek A., Krupiński M., Aleksandrowicz S., Drzewiecki W., 2013b, Fractal and multifractal characteristics of very high resolution satellite images, *Proc. of IGARRS 2013*, <http://dx.doi.org/10.1109/IGARSS.2013.6723071>.
- Wawrzaszek A., Aleksandrowicz S., Krupiński M., Drzewiecki W., 2014, Influence of Image Filtering on Land Cover Classification when using Fractal and Multifractal Features. *PFG Photogrammetrie, Fernerkundung, Geoinformation Jahrgang Heft 2* (2014), s. 101-115, doi: 10.1127/1432-8364/2014/0212.

## PODZIĘKOWANIA

Niniejsza praca przeprowadzona została przy wsparciu Narodowego Centrum Nauki (NCN) grant NN 526 1568 40.

Autorzy serdecznie dziękują Sarah R. Lundeen i zespołowi AVIRIS z NASA Jet Propulsion Laboratory za udostępnienie wysokiej jakości danych hiperspektralnych.

## MULTIFRACTAL ANALYSIS OF SATELLITE IMAGES

KEY WORDS: satellite image, airborne hyperspectral image, fractal dimension, degree of multifractality, classification

### Summary

Research presented in this paper is focused on the efficiency assessment of multifractal description as a tool for Image Information Mining. Large datasets of very high spatial resolution satellite images (WorldView-2 and EROS-A) have been analysed. The results have confirmed the superiority of multifractals as global image descriptors in comparison to monofractals. Moreover, their usefulness in image classification by using decision trees classifiers was confirmed, also in comparison with textural features. Filtration process preceding fractal and multifractal features estimations was also proved to improve classification results. Additionally, airborne hyperspectral data have been initially analysed. Fractal dimension shows high potential for the description of hyperspectral data. To summarise all conducted tests indicate the usefulness of multifractal formalism in various aspects of remote sensing. Prepared methodology can be further developed and used for more specific tasks, for example in change detection or in the description of hyperspectral data complexity.

#### Dane autorów:

Dr Anna Wawrzaszek  
e-mail: [sanna@cbk.waw.pl](mailto:sanna@cbk.waw.pl)  
telefon: (+48 22) 496 64 07  
fax: (+48 22) 840 31 31

Michał Krupiński  
e-mail: [mkrupinski@cbk.waw.pl](mailto:mkrupinski@cbk.waw.pl)  
telefon: (+48 22) 496 62 05

Dr inż. Wojciech Drzewiecki  
e-mail: [drzewiec@agh.edu.pl](mailto:drzewiec@agh.edu.pl)  
telefon: (+48 12) 617 22 88  
fax: (+48 12) 617 39 93

Sebastian Aleksandrowicz  
e-mail: [saleksandrowicz@cbk.waw.pl](mailto:saleksandrowicz@cbk.waw.pl)  
telefon: (+48 22) 496 63 88

Przesłano 7.10.2015  
Zaakceptowano 21.11.2015