

ZASTOSOWANIE PROFILU MORFOLOGICZNEGO I MAP GRANULOMETRYCZNYCH W WYODRĘBNIANIU BUDYNKÓW NA ZDJĘCIACH SATELITARNYCH O BARDZO DUŻEJ ROZDZIELCZOŚCI

MORPHOLOGICAL PROFILE AND GRANULOMETRIC MAPS IN EXTRACTION OF BUILDINGS IN VHR SATELLITE IMAGES

Przemysław Kupidura, Monika Skulimowska

Politechnika Warszawska, Wydział Geodezji i Kartografii,
Zakład Fotogrametrii, Teledetekcji i Systemów Informacji Przestrzennej

SŁOWAKLUCZOWE: teledetekcja, klasyfikacja, morfologia matematyczna, granulometria obrazowa, mapy granulometryczne, profil morfologiczny, tereny zabudowane.

STRESZCZENIE: Artykuł jest poświęcony badaniom możliwości wykorzystania metod analizy granulometrycznej: profilu morfologicznego oraz map granulometrycznych w wykrywaniu budynków na obrazach satelitarnych. Przedstawiono pokrótce podstawy teoretyczne analizy granulometrycznej obrazu i porównano dwie wykorzystywane w badaniach metody. Testy przeprowadzono na fragmencie sceny satelitarnej QuickBird – obrazie wielospektralnym, poddanym wyostrzeniu na podstawie obrazu panchromatycznego. Porównano 8 wariantów klasyfikacji, różniących się pod względem wykorzystywanych danych oraz zastosowanego modelu. Ocenę efektywności poszczególnych wariantów klasyfikacji oparto na analizie wartości współczynnika zgodności *kappa* oraz błędów nadmiaru i pominięcia. Uzyskane wyniki wskazują na istotny potencjał zaproponowanych metod, natomiast analiza zaobserwowanych niedoskonałości pozwala określić kierunki ich rozwoju.

1. WPROWADZENIE

Tekstura ma bardzo duże znaczenie podczas interpretacji obrazu, jest jedną z najważniejszych, obok koloru (lub tonu szarości), kształtu i rozmiaru, cech interpretacyjnych. Jest jednocześnie stosunkowo łatwa do określenia poprzez zastosowanie odpowiednich przetworzeń obrazu bez konieczności wcześniejszej segmentacji, tak jak ma to miejsce w procesie klasyfikacji obiektowej, pozwalającej uwzględnić m.in. cechy kształtu lub rozmiaru.

Jak pokazują wcześniejsze badania wykorzystanie wyników analizy teksturowej jako dodatkowych danych w procesie klasyfikacji obrazów satelitarnych pozwala znacząco podnieść dokładność klasyfikacji w stosunku do podejścia spektralnego, a więc opartego wyłącznie na danych spektralnych. Dotyczy to przynajmniej kilku metod analizy

teksturowej, poczynając od macierzy współwystępowania (ang. *Grey Level Co-occurrence Matrix*) i obliczanych na jej podstawie statystyk, której skuteczność stwierdzali m.in. Baraldi i Parmiggiani (1995), Haralick *et al.* (1979), czy Pathak i Dikshit (2010), poprzez analizę fraktalną (Lam, 1990; Wawrzaszek *et al.* 2014) aż po analizę granulometryczną (Kupidura, 2015). Znaczenie tekstury jako cechy interpretacyjnej wzrasta zwłaszcza w przypadku tych klas pokrycia lub użytkowania terenu, które nie cechują się dystyngtywnymi wartościami spektralnymi, co znacząco obniża dokładność ich delimitacji w procesie klasyfikacji spektralnej.

Przykładem takich klas terenu są tereny zabudowane lub budynki. W zależności od sposobu zdefiniowania jednej lub drugiej klasy, reprezentujące ją piksele przyjmują podobne wartości radiometryczne do pikseli przedstawiających odkryte gleby (pojedyncze budynki) lub dodatkowo również tereny pokryte roślinnością, drzewa itd. (całe tereny zabudowane, łącznie z przestrzenią pomiędzy budynkami). Jednocześnie cechują się charakterystyczną silną teksturą pozwalającą z dużą dokładnością wyodrębnić je spośród innych klas terenu, również tych o podobnych cechach spektralnych. Dużą skutecznością w tym zakresie wyróżnia się analiza granulometryczna (Pesaresi i Benediktsson; 2001; Mering i Chopin, 2002; Kupidura, 2010, 2014, 2015; Kupidura *et al.* 2010; Mura *et al.*, 2010, 2011).

Właśnie analiza granulometryczna jest głównym narzędziem wykorzystanym w przedstawionych poniżej badaniach. Ich celem jest przedstawienie propozycji metodyki wyodrębniania budynków na zdjęciach satelitarnych na podstawie dwóch rodzajów operacji opierających się na analizie granulometrycznej: map granulometrycznych (ang. *granulometric maps*) oraz profilu morfologicznego (ang. *morphological profile*), a także porównanie sposobu ich działania, efektywności oraz potencjalnych zastosowań. Ze względu na przeprowadzone wcześniej badania dotyczące wyodrębniania całych terenów zabudowanych na podstawie map granulometrycznych (m.in. Kupidura, 2015), główny nacisk przedstawionych badań położony został na wyodrębnianie pojedynczych budynków z wykorzystaniem profilu morfologicznego i map granulometrycznych.

2. PODSTAWY GRANULOMETRYCZNEJ ANALIZY OBRAZU

Analiza granulometryczna to przetworzenie morfologiczne, które zostało opracowane u zarania samej morfologii matematycznej (Haas *et al.*, 1967). Zasadne jest nawet stwierdzenie, że w pierwotnym zamierzeniu podstawowe operacje morfologiczne zostały opracowane na potrzeby analizy granulometrycznej. Polega ona na przeprowadzeniu sekwencji otwarć (lub domknięć) morfologicznych przy pomocy elementów strukturujących o zwiększającym się sukcesywnie rozmiarze.

Otwarcie morfologiczne można zdefiniować jako sekwencyjne złożenie operacji erozji i dylacji (Haralick *et al.* 1987):

$$\gamma_B(f) = \delta_B(\varepsilon_B(f)) \quad (1)$$

natomiast domknięcie, jako sekwencyjne złożenie dylacji i erozji (a więc w odwrotnej kolejności, niż w przypadku otwarcia):

$$\gamma_B(f) = \delta_B(\varepsilon_B(f)) \quad (2)$$

Erozję i dylację funkcji (obrazu) f przy użyciu elementu strukturującego B można zdefiniować według notacji Sternberga (1986) odpowiednio jako:

$$\varepsilon_B(f) = \inf\{g(f - y), y \in B\} \quad (3)$$

oraz

$$\delta_B(f) = \sup\{g(f + y), y \in B\} \quad (4)$$

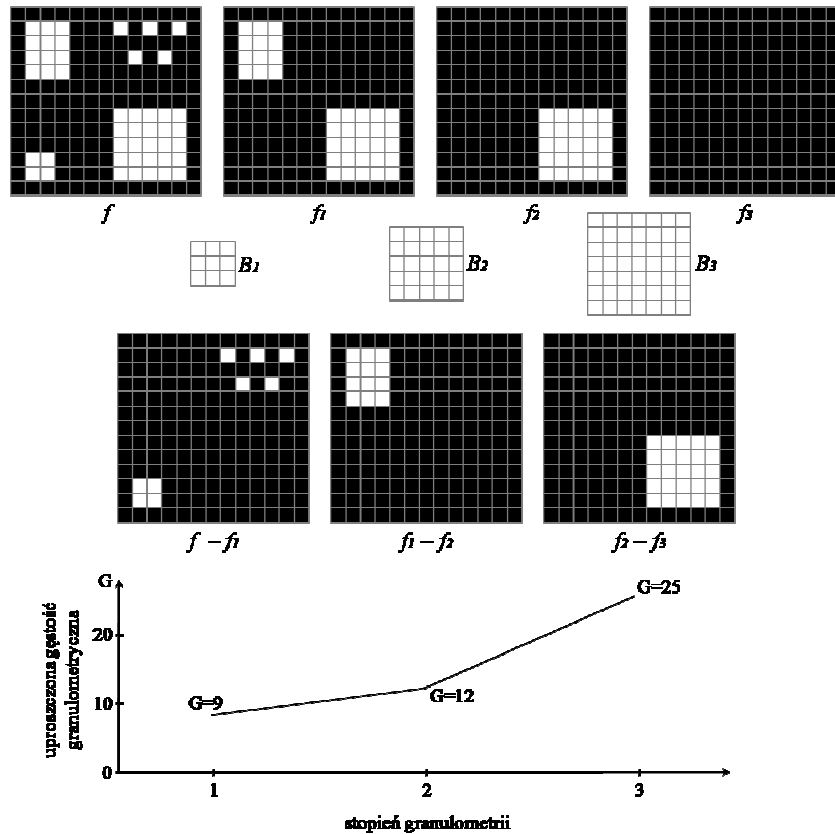
A zatem wynikiem erozji funkcji f jest funkcja najmniejszych wartości spośród wszystkich przesunięć funkcji f o elementy $-y$, będące elementami przeciwnymi do elementów tworzących element strukturujący B (będący pewnym podzbiorem obrazu określającym zasięg działania operacji), natomiast wynikiem dylacji jest funkcja największych wartości spośród wszystkich przesunięć funkcji f o elementy y , a więc należące do elementu strukturującego B (Kupidura *et al.*, 2010).

Analiza granulometryczna polega na sekwencyjnym otwieraniu (lub domykaniu) obrazu przy użyciu elementu strukturującego o coraz większym rozmiarze. Ideę tej operacji przedstawia rysunek 1. Obrazowi f przypisana została pewna funkcja, opisująca częstość występowania obiektów o danych rozmiarach, pozwalająca określić jego *skład granulometryczny*.

Zgodnie z pierwotnym zamysłem twórców tej metody granulometria wykonywana była na podstawie operacji otwarcia (analogiczną operację na podstawie domknięcia nazywa się czasami antygranulometrią) i dotyczyła całego obrazu (binarnego). Wynikiem analizy jest funkcja licznosci obrazu (w przypadku obrazów binarnych – liczby pikseli o wartości 1, w przypadku obrazów w skali szarości – sumy wartości wszystkich pikseli) względem kolejnego etapu granulometrii. Taka funkcja zwana funkcją gęstości granulometrycznej opisuje skład obrazu pod kątem obecności obiektów o odpowiednich rozmiarach.

Dwie porównywane w tym artykule operacje: mapy granulometryczne oraz profil morfologiczny różnią się od tej pierwotnej postaci analizy granulometrycznej tym, że nie przypisują tej funkcji globalnie całemu obrazowi (jak pokazuje to rysunek 1), ale poszczególnym pikselom. Z punktu widzenia przetwarzania obrazów tego typu funkcję najlepiej przedstawić przy pomocy szeregu obrazów, których piksele reprezentują poszczególne wartości tych funkcji.

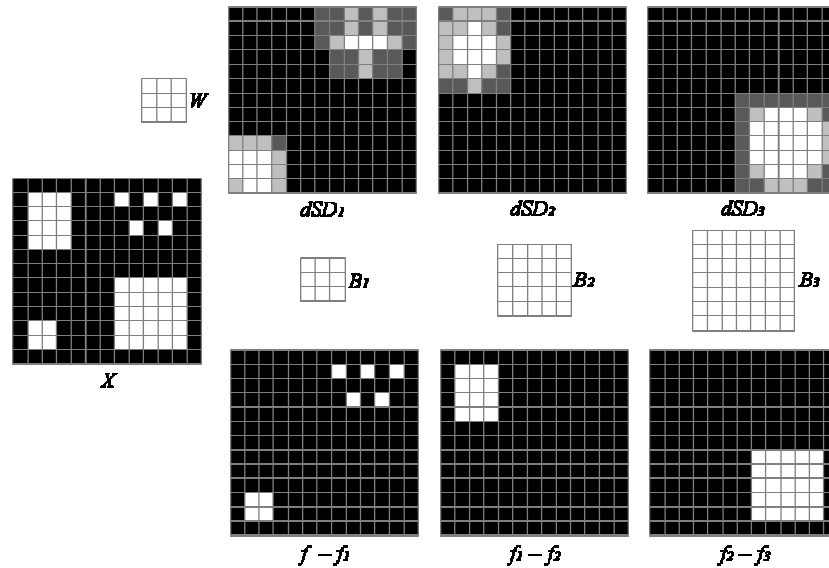
Różnice pomiędzy mapami granulometrycznymi i profilem morfologicznym są stosunkowo nieznaczne, jeśli chodzi samą operację. Mają one jednak istotne konsekwencje dla wyników i ich potencjalnych zastosowań. Mapy granulometryczne analizują lokalną granulometrię w określonym sąsiedztwie piksela zwanym oknem granulometrii (mogącym przyjmować dowolny kształt, m.in. pseudo-kolisty), natomiast profil morfologiczny – tylko na pojedynczym pikselu. Wynik profilu morfologicznego jest zatem tożsamy z mapami granulometrycznymi o oknie granulometrii o promieniu równym 0. Różnice te pokazuje rysunek 2. Przedstawia on wartości uproszczonej gęstości granulometrycznej, co do zasady bardzo zbliżonej do gęstości granulometrycznej w jej kanonicznej postaci (Kupidura, 2015).



Rys. 1. Schemat działania analizy granulometrycznej oraz wykres funkcji uproszczonej gęstości granulometrycznej

Jak pokazuje rysunek 2, mapy morfologiczne zawierają informację na temat tekstury w otoczeniu piksela, określonym oknem granulometrii, natomiast profil morfologiczny nie uwzględniający otoczenia przedstawia informację, którą można interpretować jako dotyczącą rozmiaru obiektu, do którego należy piksel (lub obiektów, ponieważ na obrazie w skali szarości piksel może należeć, w zależności od przestrzennej skali obserwacji, do kilku różnych obiektów). Dla przykładu, mapy granulometryczne mogą wskazywać całe obszary cechujące się charakterystyczną teksturą, jak lasy, sady czy tereny zabudowane, podczas gdy profil morfologiczny może wskazywać jedynie pojedyncze ziarna tej tekstury (porównaj obrazy dSD_1 oraz $f-f_1$ na rysunku 2). Z drugiej strony, przy wyodrębnianiu pojedynczych obiektów (np. budynków), mapy granulometryczne mogą cechować się pewnym błędem nadmiaru, ponieważ ślad obecności obiektu o danym rozmiarze pojawia się również w bezpośrednim otoczeniu tego obiektu, co widać zwłaszcza na obrazach dSD_2 oraz dSD_3 rysunku 2. Jak wynika z tej krótkiej analizy, przeznaczenie tych dwóch rodzajów operacji może być inne. W odniesieniu do tematu artykułu można więc mówić


o możliwości wyodrębniania całych terenów zabudowanych na podstawie map granulometrycznych oraz pojedynczych budynków na podstawie profilu morfologicznego.



Rys. 2. Porównanie map granulometrycznych (u góry) z obrazami profilu morfologicznego (u dołu)

3. METODYKA BADAŃ

W badaniach wykorzystano fragment sceny satelitarnej QuickBird wykonanej 4 maja 2004 roku o rozmiarze 2521x2817 pikseli. Obraz wielospektralny wyostrzono z wykorzystaniem metody mnożnikowej. Metodę wybrano ze względu na wizualne podobieństwo obrazu wynikowego do obrazu panchromatycznego pod kątem cech przestrzennych, określone na podstawie analizy wizualnej, istotnych z punktu widzenia analizy teksturowej, mimo stosunkowo niskiego stopnia korelacji cech spektralnych (Osińska-Skotak, 2006). Należy podkreślić, że głównym celem badań przedstawionych w niniejszym artykule była analiza możliwości wykorzystania operacji granulometrycznych w celu poprawy wyników klasyfikacji. Ostateczna bezwzględna dokładność samej klasyfikacji, jakkolwiek decydująca dla określenia skuteczności metody, w tym przypadku miała mniejsze znaczenie, niż zmiana dokładności pomiędzy badanymi wariantami, ze względu na porównawczy charakter analizy. Ponadto, wykorzystane metody analizy obrazu (granulometria obrazowa i profil morfologiczny), będące głównym przedmiotem badań, wykorzystują przestrzenne cechy obrazu. Z tego względu wybór metody wyostrzania (w tym jej znaczące wady z punktu widzenia radiometrii) nie miał decydującego znaczenia, przy czym należy zaznaczyć, że uzyskane wyniki odnoszą się wyłącznie do obrazów uzyskanych na podstawie tej metody wyostrzania.



Rys. 3. a) Obraz testowy; b) fragment przedstawiający obszar zabudowany dużymi budynkami; c) fragment przedstawiający obszar zabudowany małymi budynkami jednorodzinnymi oraz gospodarczymi

Obraz testowy (rysunek 3a) przedstawia krajobraz wiejski z dwoma osiedlami. Jedno położone na północy (rysunek 3b) składa się z budynków o dużych rozmiarach (od kilkunastu do 20 m szerokości), natomiast drugie, położone w południowym fragmencie obszaru testowego (rysunek 3c) to typowa zabudowa wiejska, złożona z niewielkich jednorodzinnych budynków mieszkalnych oraz zabudowań gospodarczych (od kilku do ok. 10 m szerokości).

W celu określenia efektywności map granulometrycznych oraz profilu morfologicznego w wyodrębnianiu terenów zabudowanych na zdjęciach satelitarnych zbadano i przeanalizowano kilka schematów klasyfikacji, opracowanych na podstawie wyników wcześniejszych badań dotyczących map granulometrycznych lub profilu morfologicznego (Pesaresi, Benediktsson, 2001; Mura *et al.*, 2010, 2011; Kupidura, 2010; 2015; Szeszko, 2014; Kupidura *et al.* 2015), ale również na podstawie teoretycznej analizy badanych operacji. –Wnioski płynące z tych badań są następujące:

- tereny zabudowane, zwłaszcza pojedyncze budynki wyróżniają się na obrazach satelitarnych cechami spektralnymi i teksturowymi oraz rozmiarami; same cechy spektralne są zazwyczaj niewystarczające do skutecznego wyróżnienia ich spośród innych klas (powierzchnie mineralne); podobnie – wyłącznie cechy teksturowe mogą prowadzić do mylenia tej klasy z innymi klasami terenu o wyraźnej teksturze (lasy, sady itp.);
- jako podstawa do opracowania map granulometrycznych bardzo dobrze sprawdzają się proste operacje otwarcia i domknięcia, natomiast w przypadku profilu morfologicznego – operacje przez rekonstrukcję (więcej w: Kupidura *et al.*, 2010);
- w przypadku dużej dysproporcji pomiędzy liczbą warstw teksturowych (map granulometrycznych lub obrazów profilu morfologicznego), a liczbą warstw spektralnych może wystąpić niedoszacowanie znaczenia tych drugich, tzn. różnice spektralne mogą zostać zdominowane przez różnice teksturalne.

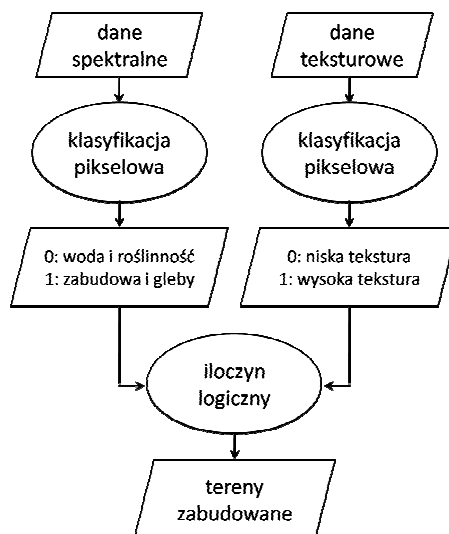
Na tej podstawie zdecydowano się na analizę efektywności różnych wariantów klasyfikacji:

- na podstawie danych spektralnych – przeprowadzona wyłącznie na obrazach spektralnych, głównie w celach porównawczych;
- na podstawie danych spektralnych i map granulometrycznych;
- na podstawie danych spektralnych i obrazów profilu morfologicznego;
- na podstawie danych spektralnych i map granulometrycznych oraz obrazów profilu morfologicznego.

Wykorzystano, zarówno w przypadku map granulometrycznych jak i profilu morfologicznego, po 10 pierwszych obrazów, uzyskanych na podstawie otwarcia i domknięcia z użyciem elementów strukturujących o rozmiarach od 1 do 10 (w sumie po 20 obrazów dla map i profilu). Mapy granulometryczne opracowano na podstawie obrazu panchromatycznego.

Każdą z klasyfikacji wykorzystujących mapy granulometryczne lub obrazy profilu morfologicznego przeprowadzono w dwóch wariantach. Jeden z nich opierał się na klasyfikacji nienadzorowanej wszystkich danych łącznie (jednego obrazu wielowarstwowego składającego się z wszystkich danych: spektralnych i teksturowych). Wybór algorytmu nienadzorowanego jako narzędzia klasyfikacji wynikał z postulatu uniezależnienia różnic dokładności uzyskanych wyników klasyfikacji od arbitralnie ustalonych pól treningowych. Jednocześnie, przeprowadzone wcześniej doświadczenia polegające na wykorzystaniu tych samych pól treningowych we wszystkich przypadkach nie zdały egzaminu ze względu na odmienny charakter wykorzystywanych danych wejściowych (z jednej strony obrazy spektralne, z drugiej – wyniki analizy granulometrycznej ujawniające cechy przestrzenne obrazu). Drugi wariant uwzględniający jedną z przedstawionych powyżej przesłanek polegał na przeprowadzeniu niezależnie klasyfikacji spektralnej i teksturowej. Klasyfikacja spektralna miała na celu wyodrębnienie pikseli o cechach spektralnych podobnych do terenów zabudowanych. Zgodnie z oczekiwaniami, taka klasa powinna cechować się dużym błędem nadmiaru i zawierać również obszary m.in. odkrytej gleby. Wyodrębnieniu samych terenów zabudowanych służyła natomiast klasyfikacja przeprowadzona wyłącznie na danych teksturowych, dzieląca obraz na obszary o wysokiej i niskiej teksturze. W dalszej części artykułu warianty klasyfikacji oparte na tym modelu nazywane są 2-etapowymi. Schemat modelu przedstawia rysunek 4.

Klasyfikację nienadzorowaną przeprowadzono w programie Erdas Imagine 9.1. – przy maksymalnej liczbie iteracji 30, progu zbieżności 99% oraz liczbie klastrów 100. Wynikowe klasy, niezależnie od podejścia, agregowano do dwóch klas tematycznych: budynków oraz pozostałych klas, traktowanych łącznie. Celem tak dużej inicjalnej liczby klastrów, zarówno w stosunku do ostatecznych klas tematycznych jak i rzeczywistych klastrów na obrazie, było zapewnienie poprawnej rozdzielności poszczególnych klas.



Rys. 4. Schemat modelu 2-etapowej klasyfikacji spektralno-teksturowej

Obrazem odniesienia dla oszacowania dokładności poszczególnych wariantów klasyfikacji była maska budynków wyodrębniona w procesie wizualnej interpretacji i ręcznej wektoryzacji oryginalnego zdjęcia. Pola testowe pokrywały więc cały obszar testowy i składały się z 66943 pikseli dla klasy budynków oraz 7034714 pikseli dla klasy nie budynków, co odpowiadało proporcjom występowania tych klas na obrazie. Oceny wyników dokonano na podstawie analizy macierzy błędów. Obliczono wartości współczynnika $kappa$ oraz błędy nadmiaru i pominięcia.

4. WYNIKI

Zgodnie z przedstawioną w poprzednim rozdziale metodyką uzyskano 7 różnych wariantów klasyfikacji: 1 dla klasyfikacji spektralnej oraz po 2 (na podstawie klasyfikacji jednoetapowej oraz dwuetapowej) dla trzech wariantów klasyfikacji opisanych w poprzednim rozdziale. Tabela 1. zawiera wartości określające dokładność poszczególnych wariantów, obliczone na podstawie porównania z referencyjną maską budynków. Klasyfikację 2-etapową na podstawie wszystkich przygotowanych rodzajów danych przeprowadzono w dwóch wariantach. Wariant W1 polegał na połączeniu najlepszych (pojedynczo) wyników klasyfikacji na podstawie obrazów map granulometrycznych oraz profilu morfologicznego (przedstawionych w tabeli pod numerami, odpowiednio, 5 i 6). Natomiast wariant W2 opierał się na wykorzystaniu takich częściowych wyników (czyli wyników pojedynczych etapów klasyfikacji na podstawie danych spektralnych, map granulometrycznych oraz profilu morfologicznego), które pozwoliły na zwiększenie dokładności klasyfikacji (stwierdzone w wyniku przeprowadzonych porównań z danymi referencyjnymi). Mówiąc inaczej, warianty W1 i W2 opierały się na tym samym schemacie, wykorzystywały jednak wyniki

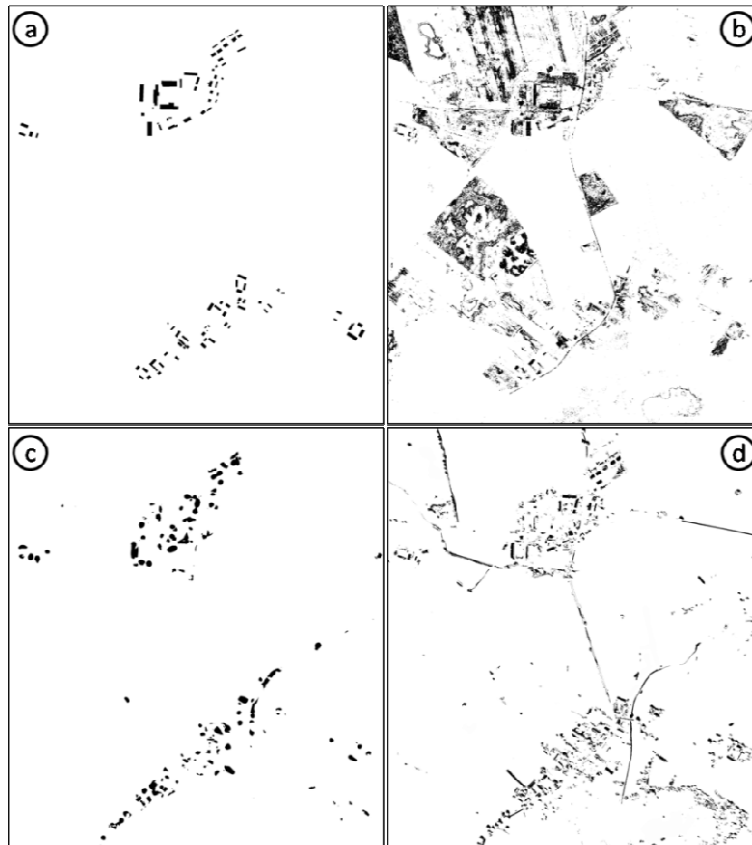
poszczególnych etapów klasyfikacji uzyskane na podstawie inaczej przeprowadzonej agregacji klastrów.

Tabela 1. Zestawienie dokładności badanych wariantów klasyfikacji

wariant klasyfikacji		współczynnik <i>kappa</i>	Błędy wyodrębnienia budynków		
			nadmiaru [%]	pominięcia [%]	
1	spektralna	0,133	91,6	37,7	
2	1-etapowa, dane: - spektralne - mapy granul.	0,285	80,7	62,4	
3	1-etapowa, dane: - spektralne - profil morf.	0,245	76,0	62,3	
4	1-etapowa, dane: - spektralne - mapy granul. - profil morf.	0,207	85,1	59,6	
5	2-etapowa, dane: - spektralne - mapy granul.	0,427	58,6	54,8	
6	2-etapowa, dane: - spektralne - profil morf.	0,341	56,2	71,4	
7	2-etapowa, dane: - spektralne - mapy granul. - profil morf.	W1	0,345	40,7	75,3
		W2	0,429	43,3	56,4

Jak wynika z powyższej tabeli, uzyskane rezultaty charakteryzują się niską dokładnością, jednak z punktu widzenia prowadzonych badań najbardziej istotne są różnice pomiędzy wynikami poszczególnych wariantów. Przede wszystkim należy podkreślić bardzo małą, zgodnie z oczekiwaniami, dokładność klasyfikacji spektralnej. Podobna charakterystyka spektralna zabudowy do charakterystyki odkrytej gleby jest przyczyną bardzo dużego błędu nadmiaru, ale również znaczącego błędu pominięcia i, w efekcie, bardzo niskiej wartości współczynnika zgodności *kappa*.

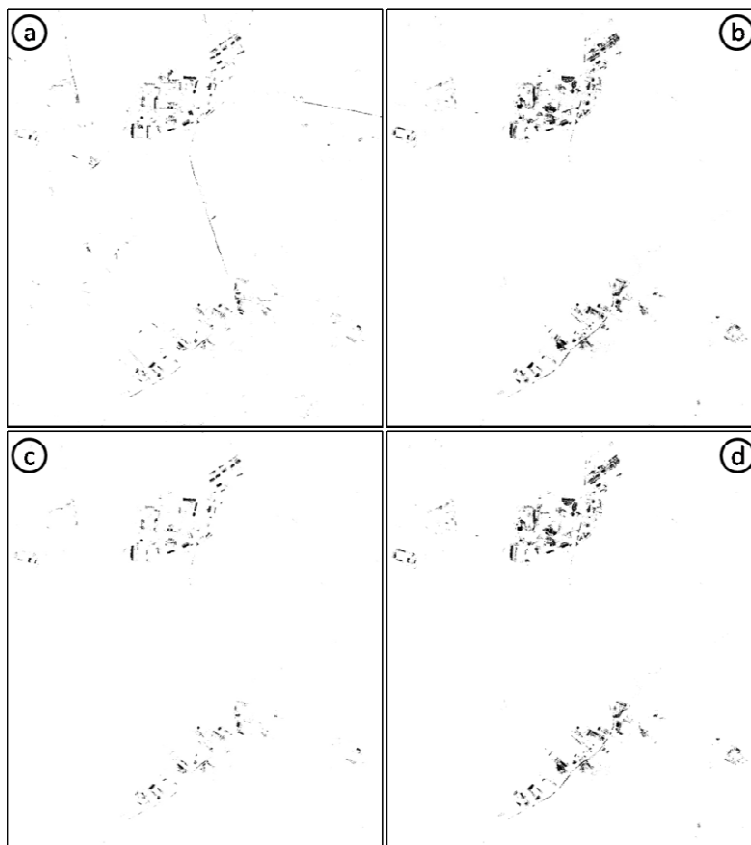
Dodatkowe wykorzystanie danych teksturowych pozwala zwiększyć dokładność klasyfikacji, jednak stopień poprawy jest różny, w zależności od wykorzystanych danych oraz zastosowanego modelu. Przede wszystkim, zastosowanie 1-etapowej klasyfikacji (wynikowe maski przedstawiono na rysunku 5), a więc modelu, według którego klasyfikacja dokonywana jest łącznie na wszystkich danych spektralnych i teksturowych nie spowodowało dużej poprawy dokładności.



Rys. 5. a) Referencyjna maska budynków oraz wyniki klasyfikacji 1-etapowej: b) spektralnej; c) z wykorzystaniem map granulometrycznych; d) z wykorzystaniem profili morfologicznych oraz map granulometrycznych

Potwierdza to, że nadmiar danych teksturowych względem spektralnych może doprowadzić do sytuacji, w której te ostatnie przestają mieć istotne znaczenie, a decydujące okazują się być cechy teksturowe. W badanych przypadkach duże błędy klasyfikacji wynikały z faktu, że wyraźnie różne spektralnie (choć dość zbliżone) obszary, a jednocześnie bardzo podobne pod względem tekstury, takie jak tereny zabudowane i obszary podmokłego, pozbawionego liści lasu (co znalazło wyraz w dużym podobieństwie wartości pikseli na mapach granulometrycznych), były przyporządkowywane do jednej klasy. Dodatkowe potwierdzenie tej przyczyny niskiej dokładności klasyfikacji można znaleźć w fakcie wyraźnie gorszych wyników uzyskanych na podstawie wszystkich rodzajów danych: spektralnych oraz map granulometrycznych i profilu morfologicznego. W tym przypadku wykorzystane zostały 4 warstwy spektralne i aż 40 warstw teksturowych (w dwóch pozostałych przypadkach, a więc gdy wykorzystywane były zamiennie mapy granulometryczne albo profil morfologiczny stosunek ten wynosił 4 do 20).

Zastosowanie 2-etapowego modelu pozwoliło podnieść dokładność klasyfikacji w znacznie większym stopniu (wyniki przedstawiono na rysunku 6).



Rys. 6. Wyniki klasyfikacji 2-etapowej: a) z wykorzystaniem profilu morfologicznego; b) z wykorzystaniem map granulometrycznych; c) z wykorzystaniem profilu morfologicznego oraz map granulometrycznych, wariant W1; d) z wykorzystaniem profilu morfologicznego oraz map granulometrycznych, wariant W2

Względnie dużą dokładnością cechuje się wariant opierający się na wykorzystaniu wyłącznie (obok danych spektralnych) map granulometrycznych. Wynik takiej klasyfikacji charakteryzuje się stosunkowo małymi (w porównaniu z innymi badanymi wariantami) błędami nadmiaru (58,6%) oraz pominięcia (54,8%). Z kolei wariant wykorzystujący obrazy profilu morfologicznego obok nieco mniejszego błędu nadmiaru (56,2%) wykazuje znacznie większy błąd pominięcia (71,4%), odbijający się w dużym stopniu na wyraźnie mniejszej dokładności klasyfikacji. Duży błąd pominięcia w przypadku tego wariantu spowodowany był dużym podobieństwem na obrazach profilu morfologicznego fragmentów dachów oraz fragmentów pól nie porośniętych roślinnością. Efekt potęgował fakt dużej niejednorodności obrazów dachów budynków, być może częściowo

spowodowany zastosowaną metodą wyostrenia obrazu. Należy jednak zaznaczyć, że ta niejednorodność zauważalna była również na obrazie panchromatycznym.

Wykorzystanie łącznie map granulometrycznych oraz obrazów profilu morfologicznego (wariant W1) zwiększyło dodatkowo błąd pominięcia (75,3%), jednak zgodnie z wcześniejszymi oczekiwaniami zmniejszyło błąd nadmiaru (40,7%). W efekcie uzyskana wartość $kappa$ sytuuje ten wariant jednak nieznacznie powyżej wariantu wykorzystującego jedynie dane spektralne i profil morfologiczny, jednak ze względu na zastosowany model i duży błąd pominięcia obserwowany w wyniku tego ostatniego wariantu, jest to dokładność wyraźnie mniejsza, niż dokładność wariantu wykorzystującego dane spektralne i mapy morfologiczne. Wariant W2, opierający się na mapach granulometrycznych oraz obrazach profilu morfologicznego o większych niż przedstawione w punktach 5 i 6 – błędach nadmiaru, uzyskał największą dokładność, choć nieznacznie tylko większą niż wariant oparty na danych spektralnych i mapach granulometrycznych. Ponownie możemy zaobserwować tu stosunkowo mały błąd nadmiaru (43,3%), ale także względnie nieduży błąd pominięcia.

Warto podkreślić, że stosunkowo mała dokładność klasyfikacji, nawet w najlepszych wariantach, wynika w dużej mierze z dużych błędów klasyfikacji osiedla w północnym fragmencie obrazu testowego. Błędy te wynikają przede wszystkim z dużych rozmiarów budynków, skutkujących dużym podobieństwem przedstawiających je grup pikseli do grup przedstawiających odkrytą glebę i to zarówno pod względem rozmiaru jak i tekstury. Dokładność badana z pominięciem tego obszaru jest nieco wyższa (dla wariantu 2-etapowej klasyfikacji na podstawie danych spektralnych i map granulometrycznych $kappa = 0,473$, natomiast dla wariantu na podstawie wszystkich danych - W2, $kappa = 0,463$).

5. WNIOSKI

Przeprowadzone badania pokazały, że łączne zastosowanie operacji profilu morfologicznego oraz map granulometrycznych ma potencjał pozwalający zwiększyć dokładność wyodrębniania terenów zabudowanych, zarówno względem klasyfikacji spektralnej, jak i klasyfikacji opartej na zastosowaniu pojedynczych operacji granulometrycznych. Jednocześnie nie udało się potwierdzić wysokiej dokładności wyodrębnienia budynków na podstawie danych profilu morfologicznego, uzyskiwanej m.in. w cytowanych wcześniej pracach Mury *et al.*, co wynika, przynajmniej częściowo, z mniejszej regularności obrazu terenów zabudowanych na wykorzystanym w niniejszym artykule obrazie testowym. Wstępna analiza tego problemu pozwala przypuszczać, że odpowiednia filtracja wykonana przed przystąpieniem do właściwej klasyfikacji mogłaby pozwolić na polepszenie obrazu pod tym kątem i, w efekcie, na zwiększenie dokładności całego procesu. Jest to kwestia, która będzie poddana analizie w dalszych badaniach w najbliższej przyszłości.

Innym aspektem zaproponowanej metody jest przedstawiony model połączenia danych spektralnych i teksturowych. Jak się okazuje, w wyniku prostych operacji logicznych uzyskane wyniki cechowały się stosunkowo dużym błędem pominięcia, znacząco wpływającym na obniżenie dokładności klasyfikacji. Przypuszczalnie inny model

połączenia różnego rodzaju danych, pozwalający na większą elastyczność procesu, mógłby skutkować większą efektywnością całego procesu.

Wreszcie, w przyszłych badaniach warto zwrócić uwagę na sam algorytm klasyfikacyjny. Należy rozpatrzyć również inne metody, łącznie z wybranymi metodami klasyfikacji nadzorowanej, które mogłyby pomóc w optymalizacji przedstawionego powyżej procesu.

LITERATURA

- Baraldi A., Parmiggiani F., 1995. An Investigation of the Textural Characteristics Associated with Gray Level Cooccurrence Matrix Statistical Parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), s. 293-304.
- Haralick R.M., 1979. Statistical and Structural Approaches to Texture. *Proceedings Of The IEEE*, 67(5), 786-804.
- Haralick R.M., Sternberg S.R., Zhuang X., 1987. Image Analysis using Mathematical Morphology. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9(4), s. 532-550.
- Kupidura P., 2010. Semi-automatic method for a built-up area intensity survey using morphological granulometry. *The Problems of Landscape Ecology*, 38, s. 271-277.
- Kupidura P., Koza P., Marciniak J., 2010. *Morfologia matematyczna w teledetekcji*. Wydawnictwo Naukowe PWN, Warszawa, ss. 250.
- Kupidura P., 2014. *Automatic extraction of built-up areas in satellite images using fractal analysis and morphological granulometry*. 34th EARSeL Symposium 2014, 16-20 czerwca, Warszawa.
- Kupidura P., 2015. *Wykorzystanie granulometrii obrazowej w klasyfikacji treści zdjęć satelitarnych*. Prace Naukowe, Geodezja z. 55, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Kupidura P., Kłębowski M., Ściana P., Truszkiewicz P., 2015. Analiza możliwości rozróżniania wybranych klas pokrycia terenu na zdjęciach satelitarnych z wykorzystaniem granulometrii obrazowej. *Wybrane problemy techniki*. Dzięgielewski A., Szychowski D., Wernik J. (red.), Drukarnia, Sierpc., s. 53-63.
- Lam, N.S.N., 1990. Description and Measurement of Landsat TM Images Using Fractals, *Photogrammetric Engineering and Remote Sensing*, 56(2), s. 187-195.
- Landis J.R.; Koch G.G., 1977. The measurement of observer agreement for categorical data. *Biometrics*, 33 (1), s. 159-174.
- Mering C., Chopin F., 2002. Granulometric maps from high resolution satellite images. *Image Analysis and Stereology*, 21, s. 19-24.
- Mura D.A., Benediktsson J. A., Bruzzone L., 2011. Self-dual Attribute Profiles for the Analysis of Remote Sensing Images. P. Soille, M. Pesaresi, and G.K. Ouzounis (red.), ISMM 2011, Sprigner-Verlag, Berlin, Heidelberg, s. 320-330.
- Mura D. A., Benediktsson J.A., Waske B., Bruzzone L., 2010. Morphological Attribute Profiles for the Analysis of Very High Resolution Images. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10), s. 3747-3762.

Osińska-Skotak K., 2006. *Potencjal interpretacyjny zdjęć wysokorozdzielczych – wpływ metody łączenia danych MS i PAN na wartość interpretacyjną zdjęć VHR*. Sesja Naukowa z okazji 85-lecia Wydziału Geodezji i Kartografii Politechniki Warszawskiej, styczeń 2006, Warszawa.

Pathak V., Dikshit O., 2010. A new approach for finding an appropriate combination of texture parameters for classification. *Geocarto International*, 25(4). 295-313.

Pesaresi M., Benediktsson J.A., 2001. A New Approach for the Morphological Segmentation of High-Resolution Satellite Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2), s. 309-320.

Sternberg S.R., 1986. Grayscale Morphology. *Computer Vision Graphics and Image Processing*, 35(3), s. 333-355.

Szeszko A., 2014. *Analiza rozwoju fragmentu zabudowy miasta Torunia na podstawie zdjęć z Landsat 7 z wykorzystaniem map granulometrycznych*. Praca inżynierska, Politechnika Warszawska.

Wawrzaszek A., Krupinski M., Drzewiecki W., Aleksandrowicz S., 2014. Influence of satellite image filtration on fractal and multifractal features in the context of land cover classification. *Photogrammetrie, Fernerkundung, Geoinformation*, 2, s. 101-115.

MORPHOLOGICAL PROFILE AND GRANULOMETRIC MAPS IN EXTRACTION OF BUILDINGS IN VHR SATELLITE IMAGES

KEY WORDS: remote sensing, classification, mathematical morphology, image granulometry, granulometric maps, morphological profile, built-up areas.

Summary

The article is focused on the analysis of possibilities of using granulometric analysis methods: the morphological profile, and granulometric maps in detecting buildings on satellite images. It briefly explains the theoretical basis for granulometric analysis of image and compares two methods used in research. Tests were carried out on a fragment of QuickBird satellite scene – pansharpened multispectral image. 8 variants of classification differing in terms of the data and the model of classification were compared. Evaluation of the effectiveness of the different options for classification based on the analysis factor $kappa$ values and omission and commission errors. The results indicate the significant potential of the proposed methods, and analysis of the observed imperfections allows to specify the possible fields of their development.

Dane autorów:

Dr hab. inż. Przemysław Kupidura
e-mail: p.kupidura@gik.pw.edu.pl
telefon: 22 234 7358

Inż. Monika Skulimowska
e-mail: m.a.skulimowska@gmail.com
telefon: 22 234 7358

Przesłano 30.09.2015
Zaakceptowano 30.12.2015