

**CYFROWA ANALIZA ZDJĘCIA SATELITARNEGO VHR DLA
POZYSKIWANIA DANYCH O POKRYCIU TERENU – PODEJŚCIE
OBIEKTOWE I PIKSELOWE**

**DIGITAL ANALYSIS OF VHR SATELLITE IMAGE FOR OBTAINING LAND
COVER DATA – OBJECT AND PIXEL-APPROACH**

Jerzy Chmiel, Anna Fijałkowska, Łukasz Woronkiewicz

Instytut Fotogrametrii i Kartografii, Politechnika Warszawska

SŁOWA KLUCZOWE: pokrycie terenu, klasyfikacja, analiza cyfrowa, zdjęcie satelitarne VHR, podejście obiektowe

STRESZCZENIE: Zdjęcia satelitarne o bardzo wysokiej rozdzielczości przestrzennej (VHR) stają się niezastąpionym w wielu zastosowaniach źródłem danych i informacji o powierzchni Ziemi ze względu na wysokie walory interpretacyjne i możliwe do uzyskania dokładności kartometryczne końcowych produktów. Ma to szczególne znaczenie dla aplikacji, gdzie przedmiotem zainteresowania są obszary o złożonej strukturze przestrzennej. Rosnące potrzeby w zakresie pozyskiwania ze zdjęć satelitarnych VHR różnorodnych informacji o powierzchni Ziemi, w tym o pokryciu terenu, wymagają jednakże wypracowania bardziej skutecznych i wydajnych metod analizy cyfrowej.

W przeciwieństwie do tradycyjnych metod cyfrowej klasyfikacji, które za jednostkę podstawową przetwarzania (analizy) przyjmują piksel, a zbiór cech wyróżniających definiowany jest zasadniczo w przestrzeni spektralnej, obiektowo zorientowane podejście do analizy pozwala rozszerzyć zbiór cech (wyróżniających obiekty) o elementy związane z teksturą, wielkością, kształtem, szeroko rozumianym sąsiedztwem, kontekstem. Obiektowe podejście często pozwala także w większym stopniu na swego rodzaju obejście pewnych problemów tradycyjnych metod klasyfikacji na poziomie piksela wynikających z wysokiej heterogeniczności wyróżnialnych powierzchni i częstej obecności tzw. statystycznego szumu jako konsekwencji wysokiej rozdzielczości przestrzennej. Wyłonione w wyniku analizy obiekty swoim rozkładem przestrzennym w bardziej naturalny sposób formują obraz rzeczywistości.

W niniejszym artykule prezentowane są określone wyniki z zakresu cyfrowej analizy zdjęcia satelitarnego VHR, której celem było pozyskanie danych o pokryciu terenu z wykorzystaniem zarówno pikselowego, jak i obiektowego podejścia do analizy. W pierwszym przypadku zastosowano nadzorowane podejście do klasyfikacji, wykorzystując znane w tym zakresie tradycyjne algorytmy. Podejście obiektowe realizowano w oparciu o funkcjonalność oprogramowania eCognition (Definiens). W tej części istotne było również włączenie do analizy określonych elementów wiedzy i innych informacji, co miało na celu podniesienie efektywności metody i poprawności końcowych wyników. Określone testy zostały przeprowadzone dla obszaru o zróżnicowanym stopniu złożoności charakterystyki przestrzennej. Dla terenów rolniczych dodatkowo ważne było także rozpoznanie upraw. Uzyskane wyniki podkreślają (przy określonych założeniach wstępnych) zalety i ograniczenia zastosowanych podejść i metod, wskazując jednakże pewne widoczne zalety podejścia obiektowego.

1. WSTĘP

Wysokie walory interpretacyjne zdjęć satelitarnych o bardzo dużej rozdzielczości przestrzennej (VHR) i możliwe do uzyskania dokładności kartometryczne końcowych produktów przetwarzania i analizy cyfrowej powodują, iż zdjęcia te stają się niezastąpionym w wielu zastosowaniach źródłem danych i informacji o powierzchni Ziemi. Ma to szczególne znaczenie dla aplikacji, gdzie przedmiotem zainteresowania są obszary o złożonej strukturze przestrzennej. Rosnące potrzeby w zakresie pozyskiwania ze zdjęć satelitarnych VHR różnorodnych informacji o powierzchni Ziemi, w tym o pokryciu terenu, inspirują różne ośrodki naukowo-badawcze do poszukiwania i rozwijania bardziej skutecznych i wydajnych metod analizy cyfrowej w tym zakresie. Wypada jednocześnie nadmienić, że tradycyjne metody klasyfikacji cyfrowej w zastosowaniu do zdjęć satelitarnych VHR napotykać często na pewne ograniczenia, zarówno te znane wcześniej i związane z podobieństwem odpowiedzi spektralnej różnych obiektów, jak również inne wynikające z dużej rozdzielczości przestrzennej samych zdjęć. Wysoka rozdzielczość przestrzenna, redukując niewątpliwie problem mikseli (znany ze zdjęć o niższej rozdzielczości), równocześnie znacznie podnosi wewnętrzną zmienność wyróżnialnych klas (skupisk pikseli), co może znacząco obniżać dokładność klasyfikacji przy zastosowaniu znanych, klasycznych algorytmów, które za podstawową jednostkę przetwarzania (analizy) przyjmują piksel, a zakres cech dyskryminujących zdefiniowany jest tylko w przestrzeni spektralnej. Wziąwszy pod uwagę występujące często podobieństwo wartości radiometrycznych pikseli nie przynależnych do jednej klasy informacyjnej i tym samym niejednoznaczność odpowiedzi spektralnej, tak zdefiniowane kryteria identyfikacji są często zawodne. Pewne aspekty rozważań na temat powyżej wspomnianych trudności zawierają między innymi prace: Schieve et al, 2001, Bauer and Steinnocher, 2001.

Wśród rozwijanych w ostatnich latach różnych metod i poszukiwanych rozwiązań zmierzających do polepszenia dokładności wyników klasyfikacji pokrycia terenu, szczególnie interesujące wydaje się być obiektowo zorientowane podejście do analizy. Pojawienie się na rynku kilka lat temu profesjonalnego oprogramowania eCognition (obecnie Definiens Professional) spowodowało wzrost zainteresowania analizą obiektową w zastosowaniach teledetekcyjnych. Istniejące opracowania i doniesienia w tym zakresie wskazują na określone zalety tego podejścia (np. Benz et al., 2004), które pozwala rozszerzyć zbiór cech wyróżniających obiekty w przestrzeni spektralnej o elementy związane z teksturą, wielkością, kształtem, szeroko rozumianym sąsiedztwem czy kontekstem. Pewnym podsumowaniem dotychczasowych osiągnięć i doświadczeń w zakresie analizy obiektowej była zorganizowana w 2006 roku w Salzburgu pierwsza w całości poświęcona tej tematyce międzynarodowa konferencja *1st International Conference on Object-based Image Analysis (OBIA 2006)*. Zarówno wspomniana konferencja, jak i inne doniesienia literaturowe (w tym np.: De Kok et al. 2005, Lewiński 2006) potwierdzają szereg niekwestionowanych zalet podejścia obiektowego i pewne możliwości w kierunku większego zakresu automatyzacji procesu pozyskiwania informacji tematycznej ze zdjęć satelitarnych, ale równocześnie nie wypada nie zauważyć, że w wielu opracowaniach podkreśla się również istnienie określonych ograniczeń omawianego podejścia, w tym zwraca się uwagę na większy stopień skomplikowania całego procesu analizy. Badania w obrębie tej tematyki są kontynuowane i prowadzone przez wiele

ośrodków, przynosząc kolejne doniesienia i powiększając dotychczasowe doświadczenia w praktycznym stosowaniu obiektowego podejścia do analizy cyfrowej zdjęć.

W niniejszym artykule prezentowane są określone wyniki z zakresu cyfrowej analizy zdjęcia satelitarnego VHR, której celem było pozyskanie danych o pokryciu terenu z wykorzystaniem zarówno pikselowego jak i obiektowego podejścia do analizy. Obiektową analizę realizowano w oparciu o funkcjonalność oprogramowania Definiens. Istotnym jest tu zarówno porównanie uzyskanych dokładności tematycznych, jak i ocena omawianych podejść, ze wskazaniem zalet i ograniczeń. Zawarte tu rozważania nawiązują w części do prowadzonych na szerszą skalę badań nad wykorzystaniem obiektowo zorientowanego podejścia w identyfikacji i delimitacji form pokrycia terenu ze zdjęć satelitarnych VHR.

2. PODSTAWOWE CECHY OBIEKTOWEGO PODEJŚCIA DO ANALIZY

Procedura obiektowo zorientowanej analizy wyróżnia zasadniczo dwa etapy. Pierwszy to segmentacja obrazu, czyli podział obrazu na obiekty. Drugi etap obejmuje natomiast klasyfikację w odniesieniu do wygenerowanych uprzednio obiektów. Jak już wspomniano wcześniej, na rynku oprogramowania w tym zakresie niekwestionowanym liderem jest oprogramowanie eCognition firmy Definiens (obecnie jest to m.in. Definiens Developer). Rozbudowywana w kolejnych wersjach funkcjonalność i liczne dostępne warianty zarówno dla segmentacji, jak i samej klasyfikacji sprawiają, że jest to istotnie profesjonalne oprogramowanie, które umożliwia przeprowadzenie obiektowo zorientowanej analizy w sposób całościowy i na zaawansowanym poziomie. Idea analizy obiektowej z uwzględnieniem implementacji dokonanej w oprogramowaniu eCognition, w tym podstawy procedur segmentacji i klasyfikacji zostały szczegółowo opisane między innymi w artykule Benz *et al* (2004). Wypada także wspomnieć, że dostępne są również inne pakiety oprogramowania pozwalające na przeprowadzenie procesu segmentacji, bądź też wykonanie obu wyróżnionych etapów tj. z klasyfikacją włącznie. Przegląd i porównanie tych narzędzi zawiera praca Meinela i Neuberta (2004). Zhang Y. & Maxwell T., 2006. Innym przykładem jest praca Zhang i Maxwell (2006) prezentująca możliwości wykorzystania logiki rozmytej na etapie segmentacji.

W dalszej części niniejszego rozdziału naszkicowana zostanie tylko ogólna charakterystyka obiektowego podejścia w cyfrowej analizie zdjęcia satelitarnego z nawiązaniem do procedur stosowanych w oprogramowaniu firmy Definiens.

2.1. Segmentacja obrazu, tworzenie obiektów

Segmentacja jest procesem podziału obrazu na grupy sąsiadujących ze sobą pikseli spełniających określone kryteria jednorodności. Tak utworzone grupy pikseli zwane są obiektami. Proces ten jest sterowany poprzez zdefiniowanie odpowiednich wartości kluczowych parametrów jak: 'kolor' (odniesienie do wartości spektralnych pikseli obiektu), 'kształt' obejmujący parametry składowe zwartości i gładkości tworzonych obiektów oraz 'skala' decydująca o wielkości powstających obiektów. Dla określonego zestawu danych w postaci kanałów spektralnych (z możliwym rozszerzeniem także o warstwy tematyczne) segmentacja może być wykonywana w wariantach jedno i wielopoziomowym, gdzie poziomy różni się wielkością obiektów w wyniku zastosowania różnych wartości

parametru 'skala'. Segmentacja wielopoziomowa pozwala na zbudowanie pionowych relacji między obiektami, co oznacza, że obiekty większe znajdujące się na wyższym poziomie obejmują położone w swych granicach obiekty mniejsze wydzielone na niższym poziomie segmentacji. Poza wyróżnionymi wyżej relacjami pionowymi istnieją również relacje poziome między obiektami danej segmentacji. Tak utworzona wielopoziomowa struktura ze zidentyfikowanymi relacjami między obiektami umożliwia przeprowadzenie na etapie klasyfikacji różnych wariantów analizy z wykorzystaniem zakodowanych relacji. Właściwy dobór parametrów segmentacji i poszczególnych poziomów ma istotny wpływ na jakość wykonywanej następnie klasyfikacji.

2.2. Klasyfikacja obiektowa, rozpoznanie obiektów


W klasycznych metodach klasyfikacji z pikselem jako podstawową jednostką analizy cechy wyróżniające i konsekwentnie funkcje decyzyjne znanych algorytmów odnoszą się wyłącznie do domeny spektralnej. Obiektowo zorientowane podejście do analizy pozwala rozszerzyć ten zbiór cech o elementy definiowane w domenie przestrzennej czyli związane z teksturą, wielkością, kształtem, szeroko rozumianym sąsiedztwem i kontekstem obiektów. Dodatkowo należy uwzględnić również informacje płynące z analizy relacji pionowych między obiektami z hierarchicznie utworzonych poziomów segmentacji. Tak rozbudowany zbiór cech wyróżniających obiekty i możliwe do wykonania warianty, czy schematy postępowania, ogólnie stwarzają podstawy do przeprowadzenia bardziej wydajnych i skutecznych analiz w zakresie klasyfikacji obiektów. Nie można oczywiście zakładać, że w każdym przypadku podejście obiektowe przyniesie jakościowo lepszy wynik klasyfikacji w porównaniu z klasycznymi metodami. Niemniej jednak, jak wskazują na to dotychczasowe doświadczenia oraz przegląd literatury, zalety obiektowego podejścia są w wielu przypadkach bardzo widoczne.

Proces klasyfikacji z wykorzystaniem oprogramowania Definiens oparty jest zasadniczo na logice rozmytej. Można przy tym wyróżnić dwa podstawowe schematy (metody) klasyfikacji: *sample-based (nearest neighbour)* oraz *knowledge-based*. Pierwsza metoda zwana metodą najbliższego sąsiada jest nadzorowanym podejściem do klasyfikacji wykorzystującym zbiór pól treningowych reprezentujących dane klasy. Klasyfikacja poszczególnych obiektów odbywa się poprzez porównanie ich określonych cech z cechami obiektów w odpowiedni sposób korespondujących swym położeniem do pól treningowych (odpowiedni % pokrywania się). Wspomniane porównywanie dotyczy odległości między położeniem danego obiektu, a obiektami treningowymi (wzorcowymi) obliczanych w n- wymiarowej przestrzeni cech. Druga metoda stanowiąca klasyfikację opartą na wiedzy eksperckiej przyjmuje, że każda klasa jest opisana poprzez reguły rozmyte, które bazują na jednowymiarowych funkcjach przynależności. Definiowanie dla każdej z klas określonych reguł, które odnoszą się zarówno do domeny spektralnej, jak i przestrzennej, odbywa się z wykorzystaniem fachowej wiedzy, która pozwala formułować przydatne zależności i relacje dla samych obiektów jak również związanych z nimi potencjalnych klas. Złożenie według odpowiednich zasad uprzednio zdefiniowanych funkcji przynależności pozwala w efekcie na dokonanie klasyfikacji obiektów. Należy dodać, iż możliwy jest także scenariusz postępowania uwzględniający kombinację funkcjonalności wymienionych wyżej w skrócie obu metod.

3. OPIS WYKONANYCH TESTÓW, UZYSKANE WYNIKI

3.1. Założenia

Określone testy zostały wykonane dla obszaru zlokalizowanego w okolicach Łowicza. Wykorzystano fragment (~5 x 6 km) sceny satelitarnej QuickBird zarejestrowanej 11 maja 2004r. (Rys. 1). Obszar badań stanowi typowo rolniczy krajobraz, nieznaczną powierzchnię mają obszary pokryte lasami oraz wiejska zabudowa. Satelitarne dane cyfrowe zastosowane w analizie są produktem w wersji pansharp, jako połączenie danych panchromatycznych (o lepszej rozdzielczości przestrzennej – 0,6 m) i multispektralnych (rozdzielczość – 2,4 m). Dodatkowe dane pomocnicze, to dane wektorowe zawierające informacje o identyfikacji upraw.



Rys. 1 Obszar badań; kompozycja standardowa QuickBird


Dla wskazanego wyżej obszaru testowego wykonana została analiza pokrycia terenu w podejściu nadzorowanym, przy zastosowaniu tradycyjnie stosowanych algorytmów (minimalna odległość, odległ. Mahalanobisa, maksymalne prawdopodobieństwo) z pikselem, jako jednostką odniesienia, a następnie przeprowadzono wielowariantową analizę obiektową w środowisku oprogramowania Definiens Professional, włączając również określone elementy wiedzy i informacji pomocniczych. Głównym celem było oszacowanie możliwego do uzyskania stopnia identyfikacji i delimitacji elementów pokrycia terenu dla obszaru o danym typie krajobrazu z wykorzystaniem wybranych metod i konkretnego zestawu danych wejściowych. We wszystkich wariantach analizy wykorzystywano ten sam zestaw wejściowy pól treningowych. Dokładność wyników klasyfikacji oceniano na tym samym zestawie pól testowych, poddając analizie kolejne macierze błędów i w szczególności porównując wartości podstawowych wskaźników

oceny dokładności takich jak: *Kappa*, dokładność użytkownika i producenta generowanych z macierzy błędów.

3.2. Klasyfikacja pikselowa

Przeprowadzona na etapie wstępnym szczegółowa analiza dostępnych danych o obszarze badań, w tym analiza kompozycji barwnych i wykonanych procedur klasteryzacji, były podstawą do zdefiniowania możliwych do uzyskania klas pokrycia terenu i pozyskania pól treningowych oraz testowych, które posłużyły do przeprowadzenia dalszych etapów analizy. Do wydzielenia wytypowane zostały następujące klasy pokrycia terenu: roślinność dobrze rozwinięta (zboża ozime, łąki, pastwiska), roślinność słabo rozwinięta (zboża jare), odkryta gleba wilgotna, odkryta gleba sucha, zabudowania, drogi, las liściasty, las iglasty, cieki i zbiorniki wodne, cienie. Data zarejestrowanej sceny powodowała, że łąki i zboża ozime stanowiły klasy o bardzo dużym podobieństwie spektralnym, dlatego też w prezentowanym wariancie analiz zostały one ujęte jako jedna klasa, co ostatecznie przyczyniło się do uzyskania bardzo wysokich wartości dywergencji przy badaniu rozłączności sygnatur.

Wyniki klasyfikacji pikselowej z wykorzystaniem algorytmów minimalnej odległości (*Kappa*: 0.60) oraz odległości Mahalanobisa (*Kappa*: 0.71) okazały się gorsze od wyniku uzyskanego z zastosowaniem algorytmu największego prawdopodobieństwa (*Kappa*: 0.86). Dlatego też ten ostatni wynik (Rys. 2) zostanie omówiony w zestawieniu z wynikami klasyfikacji obiektowej.



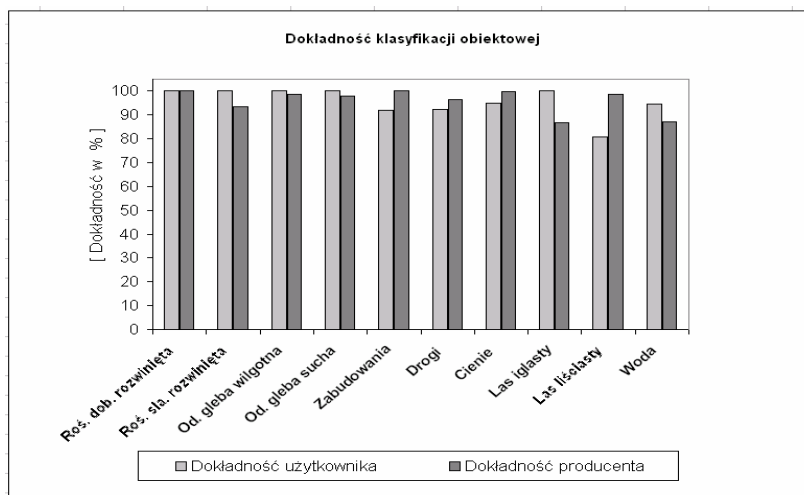
Rys. 2 Zestawienie dokładności użytkownika i producenta dla klasyfikacji z zastosowaniem algorytmu maksymalne prawdopodobieństwo. Obszar testowy Łowicz

Pobieżna analiza wykresu na Rys. 2 wskazuje, że część klas uzyskała wyraźnie słabsze dokładności, są to: lasy liściaste (z racji dużego podobieństwo odpowiedzi

spektralnej do roślinności we wczesnym okresie wegetacji), zabudowania (podobne odpowiedzi spektralne jak dla dróg).

3.3. Klasyfikacja obiektowa


Klasyfikacja obiektowa w środowisku oprogramowania Definiens przeprowadzona została według schematu postępowania, z zastosowaniem jako wiodącej, metody najbliższego sąsiada. Przed uzyskaniem satysfakcjonującego wyniku klasyfikacji obiektowej wykonano różnorakie próby, które ostatecznie wskazały dla przyjętego zestawu klas przydatny zbiór podstawowych cech (zasadniczo z domeny spektralnej) oraz konieczność rozwinięcia o cechy dodatkowe (z domeny przestrzennej), które przypisywano określonym klasom. Istotnym było tu także określenie parametrów funkcji przynależności odpowiednio opisujących wybrane cechy dla danej klasy. Przykładowe cechy dodatkowo zdefiniowane dla klas, które uzyskały niskie progi dokładności w klasyfikacji pikselowej (z zastosowaniem algorytmu maksymalne prawdopodobieństwo): dla dróg zdefiniowano odpowiednią funkcję przynależności dla cechy geometrycznej, określającej stosunek długości do szerokości; natomiast w przypadku zabudowy, po licznych próbach zastosowano cechy geometryczne i odpowiednie funkcje przynależności, odniesione do powierzchni i kształtu. Rys. 3 ilustruje uzyskane dla klasyfikacji obiektowej dokładności użytkownika i producenta; dla najlepszego wariantu uzyskano wartość $Kappa$ równą 0.96.



Rys. 3 Zestawienie dokładności użytkownika i producenta dla klasyfikacji obiektowej. Obszar testowy Łowicz

Uzyskane dość wysokie dokładności klasyfikacji obiektowej zostały dodatkowo potwierdzone poprzez wewnętrzne (opcje oprogramowania Definiens) względne oceny rezultatu klasyfikacji, w postaci statystyki ilustrującej tzw. stabilność klasyfikacji (rozkład

różnic pomiędzy współczynnikami przynależności dla najlepszego i drugiego wyniku przypisania danego obiektu do klasy) oraz wartości stopnia przynależności obiektów do klasy (najwyższa wartość dla każdego segmentu). Rys. 4 przedstawia przykładowe porównanie na wybranych fragmentach klasyfikacji pikselowej i obiektowej dla klas: zabudowa, woda i zadrzewienia liściaste. Wartości uzyskanych wskaźników dokładności dla klasyfikacji obiektowej wskazują dla części klas znaczną poprawę dokładności w stosunku do klasyfikacji pikselowej. Dotyczy to zwłaszcza klas: zabudowa, drogi, las liściasty i woda. Nie ulega wątpliwości, że zanotowana poprawa dokładności klasyfikacji obiektowej była możliwa dzięki możliwościom jakie wynikają ze specyfiki podejścia obiektowego, i w szczególności związanym z tym znacznym rozszerzeniem zbioru cech wyróżniających .



Rys. 4 Przykładowe porównanie klasyfikacji pikselowej i obiektowej dla klas: zabudowa, woda i zadrzewienia liściaste

4. PODSUMOWANIE WYNIKÓW I WNIOSKI

Uzyskane wyniki potwierdzają przydatność obiektowego podejścia w zastosowaniu do klasyfikacji pokrycia terenu, szczególnie jeśli rozpatruje się klasy, dla których tradycyjna klasyfikacja z pikselem, jako jednostką odniesienia przynosi nie najlepsze wyniki. Dokonując oczywiście oceny uzyskanych wyników wypada mieć na uwadze, że dotyczą one określonego zestawu danych satelitarnych, czasu rejestracji, specyfiki obszaru, określonego stanu rozwoju szaty roślinnej, a także przyjętych założeń i zastosowanych metod analizy. Na zaprezentowanym przykładzie, który z punktu widzenia możliwego stopnia rozbudowy i złożoności samego procesu klasyfikacji

w środowisku oprogramowania Definiens nie był zbyt skomplikowany, wyraźnie jednak widać, jak przydatne i obiecujące mogą być oferowane tam możliwości analizy.

Po stronie pewnych mankamentów, trzeba jednak zwrócić uwagę na fakt, że bardzo często uzyskanie dobrego wyniku klasyfikacji obiektowej jest bardzo czasochłonne i wymaga znacznej liczby niezbędnych prób i testów. Dodatkowo sam proces obliczeniowy przy rozbudowanym zakresie analizy i dużych zbiorach danych może zajmować dużo czasu pomimo stosowania coraz szybszych komputerów. Przykład oprogramowania Definiens wskazuje również, że dostępna rozbudowana funkcjonalność i olbrzymie możliwości, co do tworzenia reguł oraz wykorzystywania zakresu i liczby cech wyróżniających zarówno predefiniowanych, jak i nowo tworzonych pochodnych, daje z jednej strony potężne narzędzie analizy, ale równocześnie nietrudno zauważyć, że żmudnie wypracowane dla konkretnego obszaru i zestawu danych pewne rozwiązania określonych problemów, nie muszą koniecznie być łatwo powtarzalne i przeniesione dla podobnych przypadków, ale z nieco inną charakterystyką obszaru czy danych wejściowych. Pomimo tych wspomnianych minusów, wypada jednak stwierdzić, że jest to już w dużej mierze sprawdzony w praktyce bardzo ważny kierunek rozwoju w zakresie metod analizy obrazów.

5. LITERATURA

Benz U.C., Hofmann P., Willhauck G., Lingenfelder L., Heynen M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry & Remote Sensing* 58, pp. 239-258.

Chmiel J., 2004. Comparison of different methods for supervised digital classification of VHR images. *Proceedings of the 10th Annual Conference on Control with Remote Sensing of Area-based Subsidies*, 25-27 November 2004, Budapest, Hungary. Directorate General JRC ISPR, Institute for the Protection and Security of the Citizen., 2005, pp. 292-313. S.P.I. 66502.

Blundell J.S. and Opitz D., 2006. Object-recognition and feature extraction from imagery: The Feature Analyst Approach. *Proceedings of 1st International Conference on Object-based Image Analysis (OBIA 2006)*, S. Lang, T. Blaschke & E. Schöpfer (Editors), ISPRS, Volume no. XXXVI – 4/C42.

De Kok R., Koziol K., Wezyk P., 2005. Zastosowanie klasyfikacji obiektowej wysokorozdzielczych obrazów teledetekcyjnych oraz analiz przestrzennych GIS w kartowaniu drzewostanów. *Roczniki Geomatyki*. Tom III, Zeszyt 4, s. 99-108.

Hay G. & Castilla G., 2006. Object-based image analysis: strengths, weaknesses, opportunities and threats (SWOT). *Proceedings of 1st International Conference on Object-based Image Analysis (OBIA 2006)*, S. Lang, T. Blaschke & E. Schöpfer (Editors), ISPRS, Volume no. XXXVI – 4/C42.

Lewinski S., 2006. Applying fused multispectral and panchromatic data of Landsat ETM+ to object oriented classification. In: *Proceedings of the 26th EARSeL Symposium, New Developments and Challenges in Remote Sensing* May 29-June 2, 2006, Warsaw, Poland.

Meinel G. & Neubert M., 2004. A comparison of segmentation programs for high resolution remote sensing data. XXth International Archives of Photogrammetry and Remote Sensing (ISPRS) Congress, Turkey, July 12-23, pp. 1097-1102.

Woronkiewicz Ł., 2006. Zastosowanie obiektowo zorientowanej analizy w cyfrowej klasyfikacji pokrycia terenu na przykładzie zdjęcia VHR. *Praca dyplomowa magisterska*, Wydział Geodezji i Kartografii PW.

Zhang Y. & Maxwell T., 2006. A fuzzy logic approach to supervised segmentation for object-oriented classification. In *Proceedings of ASPRS Annual Conference*, Reno, Nevada, 1-May 2006.

DIGITAL ANALYSIS OF VHR SATELLITE IMAGE FOR OBTAINING LAND COVER DATA – OBJECT AND PIXEL-APPROACH

KEY WORDS: land cover, classification, digital analysis, VHR satellite image, object-approach

SUMMARY: Very high resolution satellite images with their valuable photo-interpretation properties and potential high level of geometric accuracy of end products are considered in many applications as a crucial source of data and information about the Earth surface. It is of special importance for such applications in which the area of interest is characterised by complex spatial structure. Growing needs for obtaining diverse categories of information about Earth surface, including land cover, require effective and efficient methods of digital analysis to be worked out. In contrast to traditional methods of digital classification, which use pixel as a reference unit of processing and the frame of discriminating features is basically defined in spectral space, the object-based approach allows to increase the set of discriminating features, including new elements related to texture, size, shape, widely understood neighbourhood, and context. Object-based approach often allows, to a large extent, to avoid some problems of traditional pixel-based classifiers, which result from high level of heterogeneity of identified areas and the frequent presence of so-called statistical noise, which is considered as a consequence of high spatial resolution. The finally created and identified objects in object-based analysis, in their spatial distribution form more natural image of reality.

In the present paper, certain results are presented from a range of digital analysis of VHR satellite image, where the main goal was to achieve land cover data applying pixel and object-based approach. In first case, the supervised approach was used with known traditional algorithms. The object-based approach was adopted based on Definiens Professional set of tools. In the latter approach, the essential was also to include certain elements of knowledge and ancillary information with the aim to improve efficiency of the method and accuracy of final results.

Given tests were performed for the terrain of diverse levels of spatial complexity. For the rural areas, an important issue was also to recognize the crops. The results showed (with the certain input assumptions) the positive aspects and limitations of applied approaches and methods, pointing at some visible advantages of the object-based approach.

dr inż. Jerzy Chmiel
e-mail: j.chmiel@gik.pw.edu.pl
telefon: 022 2347358

mgr inż. Anna Fijałkowska
e-mail: af@gik.pw.edu.pl
telefon: 022 234735
fax: 022 2345389

mgr inż. Łukasz Woronkiewicz
telefon: 022 2347358