

**KLASYFIKACJA OBIEKTOWA NARZĘDZIEM
WSPOMAGAJĄCYM
PROCES INTERPRETACJI ZDJĘĆ SATELITARNYCH***

**OBJECT-ORIENTED CLASSIFICATION AS A TOOL
SUPPORTING
THE PROCESS OF SATELLITE IMAGE INTERPRETATION**

Stanisław Lewiński

Instytut Geodezji i Kartografii

Słowa kluczowe: klasyfikacja obiektowa, użytkowanie ziemi, ASTER

Keywords: object oriented classification, land use, ASTER

Wstęp

Powszechnie stosowana technika interpretacji wizualnej mimo swoich bezsprzecznych zalet nie jest optymalnym sposobem uzyskiwania informacji. Jej podstawową wadą jest duża czasochłonność. Pomijając proces samego rozpoznania, granice klas oraz ich kody (atrybuty) wprowadzane są ręcznie. Szybkość interpretacji zależy przede wszystkim od wprawy interpretatora i związana jest ona z naturalnymi ograniczeniami, których nie można przekroczyć.

Na początku lat dziewięćdziesiątych XX wieku w ramach programu CORINE opracowano bazę danych o użytkowaniu ziemi na obszarze całego kraju według jednolitej technologii i jednolitej legendy (Corine, 1993). Źródłem informacji były zdjęcia satelitarne wykonane przez satelitę Landsat TM. Bazę danych CORINE 1990 opracowano metodą interpretacji wizualnej wydrukowanych kompozycji barwnych zdjęć satelitarnych w skali 1:100 000. Baza danych o pokryciu terenu w Polsce powstała w wyniku kilkumiesięcznej pracy wieloosobowego zespołu (Baranowski, Ciołkosz, 1997).

Pod koniec roku 2002 rozpoczęto prace związane z CORINE 2000. Interpretację form pokrycia terenu wykonano również tradycyjną metodą wizualną, która została zmodyfikowana jedynie w ten sposób, że była wykonywana bezpośrednio na monitorze komputera. Jako materiał referencyjny wykorzystano bazę danych z roku 1990; granice wydzieleń oraz formy pokrycia terenu zostały zmodyfikowane zgodnie z aktualnym stanem. Realizacja programu CORINE 2000 w sposób praktyczny wykazała, że można przyspieszyć interpretację, jeżeli polega ona na aktualizacji już istniejącej bazy danych.

*Artykuł powstał w ramach projektu badawczego 5 T12E 023 25 finansowanego ze środków Komitetu Badań Naukowych.

Zautomatyzowanym odpowiednikiem interpretacji jest klasyfikacja zdjęcia satelitarnego. Tradycyjne techniki klasyfikacyjne rozwijane są od początku istnienia teledetekcji satelitarnej, jednakże ze względu na uzyskiwane wyniki ciągle nie mogą być alternatywnym rozwiązaniem dla interpretacji wizualnej.

Klasyfikacja obiektowa jest nową metodą klasyfikacyjną. W obiektowym podejściu klasyfikacyjnym nie są analizowane pojedyncze piksele, lecz tzw. obiekty będące grupami sąsiadujących pikseli spełniających zadane kryteria jednorodności. Analizowane są nie tylko wartości odbić spektralnych obiektów, ale również ich kształt, wielkość, relacje między sąsiednimi obiektami, ich tekstura oraz parametry statystyczne, które nie są dostępne w przypadku analizy pojedynczego piksela. Jak wykazały przeprowadzone prace, klasyfikacja obiektowa może w dużym stopniu wspomagać proces interpretacji wizualnej, a w niektórych przypadkach nawet ją zastąpić.

W prezentowanej pracy klasyfikację obiektową wykonano z zastosowaniem oprogramowania eCognition firmy Definiens Imagine.

Teren badań

Jako poligon badawczy został wybrany teren o powierzchni 795 km² położony w centralnej części Polski na Nizinie Mazowieckiej w pobliżu Warszawy. W jego centrum, między Wisłą i Narwią znajduje się miasto Legionowo (49 000 mieszkańców). Na poligonie badawczym występują lasy iglaste, liściaste, tereny rolnicze, łąki oraz zabudowa z przewagą zabudowy rozproszonej. Tereny rolnicze charakteryzują się dużym stopniem rozdrobnienia. Pola o małej powierzchni, często poniżej 1 ha, sąsiadują z użytkami zielonymi. Na rzece Narwi znajduje się sztuczny zbiornik, Zalew Zegrzyński, o powierzchni ponad 30 km².

Zdjęcie satelitarne ASTER

Prezentowane opracowanie zostało wykonane na podstawie zdjęcia ASTER zarejestrowanego 4 maja 2002 roku.

System skanerów ASTER zainstalowany na pokładzie satelity Terra rejestruje obraz powierzchni ziemi w 14 kanałach spektralnych (ASTER user's guide part 1, 2001). Trzy pierwsze kanały związane są z zakresem VNIR promieniowania widzialnego i bliskiej podczerwieni, kolejnych sześć kanałów pracuje w zakresie SWIR podczerwieni krótkofalowej, pięć ostatnich kanałów to podczerwień termalna TIR. Rozdzielczość przestrzenna kanałów nie jest jednakowa. Dla zakresu VNIR wielkość piksela wynosi 15 m, dla SWIR 30 m oraz 90 m dla zakresów TIR. Dane rejestrowane są z rozdzielczością radiometryczną 8 bitów w przypadku VNIR i SWIR, oraz 12 bitów dla TIR. Skaner ASTER można traktować jako następcę skanerów Landsat TM i ETM+ (Abrams, 2000).

Przetwarzanie zdjęcia satelitarnego ASTER rozpoczęto od wykonania geometryzacji do układu współrzędnych 1992. Następnie wykonano korekcję atmosferyczną zdjęcia. W tym celu wykorzystano algorytm ATCOR 2 oprogramowania PCI Geomatica. Skorygowane zostały wartości pikseli tworzących obrazy w zakresie VNIR, SWIR oraz kanał nr 13 zakresu TIR.

Algorytm wspomaganie procesu interpretacji zdjęć satelitarnych

Na przykładzie terenu badań zobrazowanego na zdjęciu ASTER opracowano algorytm postępowania mający na celu wspomaganie procesu interpretacji form pokrycia i użytkowania ziemi na zdjęciach satelitarnych. Jest on związany z klasyfikacją obiektową i składa się z pięciu podstawowych etapów:

1. Segmentacja zdjęcia satelitarnego
2. Klasyfikacja obiektowa
3. Generalizacja obrazu klasyfikacyjnego
4. Zmiana formatu obrazu klasyfikacyjnego z rastrowego na wektorowy
5. Weryfikacja klasyfikacji metodą interpretacji wizualnej

Pierwszym etapem algorytmu jest segmentacja zdjęcia satelitarnego. Jest ona integralną częścią klasyfikacji obiektowej jednakże została ona wyodrębniona ze względu na ważną rolę jaką odgrywa. Od sposobu wykonania segmentacji zależy jakość klasyfikacji. Nie jest możliwe wykonanie poprawnej klasyfikacji na podstawie nieodpowiedniej segmentacji. Kolejnym krokiem jest klasyfikacja obiektowa. Następnie obraz klasyfikacyjny jest generalizowany z zastosowaniem jednostki obniesienia, której wielkość zależy od rodzaju klasyfikowanego zdjęcia oraz od skali opracowania. Generalizację wykonano na danych w formacie rastrowym. Można wykonać ją także na podstawie danych wektorowych, przy takim rozwiązaniu należy zamienić kolejność etapów 3 i 4. Etap 4 związany jest ze zmianą formatu obrazu klasyfikacyjnego z rastrowego na wektorowy. Jest to stosunkowo prosty zabieg techniczny, jednakże w tym przypadku należy zastosować odpowiednie funkcje wygładzające granice obiektów. Ostatnim punktem proponowanego algorytmu jest weryfikacja klasyfikacji metodą interpretacji wizualnej, w wyniku której uzyskujemy poprawioną (bezbłędną) warstwę klasyfikacyjną form pokrycia i użytkowania ziemi.

Segmentacja

Segmentacja zdjęcia satelitarnego polega na podziale treści zdjęcia na tzw. obiekty, które są grupami pikseli spełniających zadane warunki jednorodności (eCognition, 2001).

W oprogramowaniu eCognition segmentację można wykonać na podstawie jednego lub kilku kanałów spektralnych. Wielkość obiektów i ich kształt zależy od tzw. współczynnika skalowego oraz od dwóch parametrów nazwanych *color* i *compactness* definiujących odpowiednio wagę wartości spektralnych oraz wagę kształtu obiektów. Obecnie w dostępnej literaturze nie można znaleźć jednoznacznie określonych zasad segmentacji, dobór parametrów całkowicie zależy od doświadczenia operatora.

Klasyfikacja zdjęcia ASTER została wykonana na podstawie trzystopniowej segmentacji (Lewiński, 2005). Pierwszy poziom segmentacji uzyskano wykorzystując do tego celu kanały 1, 2 i 3 oraz stosując współczynnik skalowy 10 z parametrem *color* 0.6 i *compactness* 1. Drugi i trzeci poziom segmentacji został utworzony na podstawie kanałów 3, 4 i 7 oraz współczynników skali 20 i 30. Zmieniono również *color* na 0.8 i 0.7 a *compactness* odpowiednio na 0.7 i 0.6. Na kolejnych poziomach segmentacji treść zdjęcia satelitarnego została

podzielona na 78254, 13832 i na 6418 obiektów. Parametry segmentacji ustalono na podstawie wielokrotnie przeprowadzonych prób. Analizowano kształt obiektów oraz parametry statystyczne, uzyskane w czasie wstępnych analiz zdjęcia ASTER (Lewiński, Ewiak, 2004).

Ostatni, czyli trzeci poziom segmentacji był podstawowym poziomem klasyfikacji zdjęcia ASTER. Przed klasyfikacją granice obiektów trzeciego poziomu zostały starannie przejrane, w kilkunastu przypadkach wykonano korektę ich przebiegu, gdyż jak już wspomniano, jakość segmentacji decyduje o wynikach późniejszej klasyfikacji.

Klasyfikacja

Na podstawie analizy wizualnej zdjęcia ASTER, przebiegu granic obiektów oraz przeprowadzonych prób klasyfikacji podjęto decyzję o klasyfikacji z podziałem na 19 klas (Lewiński, 2005). Klasy pokrycia i użytkowania ziemi pochodzą z 3 poziomu legendy programu CORINE oraz z 4 poziomu opracowanego w IGiK (Poławski, 2002). Pewną wadą takiego podejścia jest równoczesne rozpatrywanie różnych stopni szczegółowości, lecz równocześnie pozwala to na pełniejsze wykorzystanie możliwości klasyfikacyjnych (przejście z poziomu 4 na 3 jest prostym zabiegiem technicznym). Nazwy klas oraz związane z nimi kody legendy CORINE przedstawione są w tabeli 1.

W tradycyjnych metodach klasyfikacyjnych zdjęcia satelitarne klasyfikowane są w oparciu o wartości pikseli obrazu w poszczególnych kanałach spektralnych lub w oparciu o wartości współczynników obliczonych na ich podstawie. W klasyfikacji obiektowej oprogramowania eCognition mamy do dyspozycji nieporównywalnie większą liczbę informacji. Z każdym obiektem (na każdym poziomie segmentacji) związane są średnie wartości odbić spektralnych, wartości minimalne, maksymalne oraz odchylenia standardowe obliczone na podstawie pikseli tworzących obiekt. Dostępne są informacje o kształcie obiektu: wielkość, długość, szerokość, dopasowanie obiektu do kształtu prostokąta lub elipsy. Można również posługiwać się relacjami zachodzącymi między obiektami takimi jak: sąsiedztwo, długość wspólnej granicy, odległość od innych obiektów. Warstwowa struktura obiektów o różnej wielkości pozwala na analizę relacji zachodzących między obiektami z poszczególnych poziomów segmentacji. Istnieje możliwość definiowania własnych klasyfikatorów obliczanych na podstawie wszystkich dostępnych parametrów z udziałem funkcji matematycznych, w tym trygometrycznych. Prosty tego przykładem jest współczynnik NDVI, który został wykorzystany w prezentowanej klasyfikacji zdjęcia ASTER. Dostępne są również funkcje pozwalające na obliczenie tekstury obrazu na podstawie obiektów niższego poziomu oraz funkcji Haralick (Hall-Beyer, 2000).

W środowisku eCognition są do dyspozycji dwie metody klasyfikacyjne: popularna w teledetekcji satelitarnej metoda najbliższego sąsiada (*Nearest Neighbor – NN*) oraz funkcja przynależności (*Membership Function – MF*). Obie metody w tej implementacji wykorzystują teorię zbiorów rozmytych. Wyniki klasyfikacyjne przyjmują wartości z przedziału $\langle 0,1 \rangle$. Pozwala to na porównywanie przynależności obiektów do poszczególnych klas.

W klasyfikacji obiektowej zdjęcia ASTER nie wszystkie klasy zostały sklasyfikowane z zastosowaniem jednakowej metody (Lewiński, 2005). Klasę „wody” sklasyfikowano stosując funkcję przynależności. Wstępnie została ona podzielona na dwie podklasy, które później połączono: „wody głębokie” i „wody płytkie”. Pierwszą podklasę rozpoznano posługując się

Tabela 1. Klasy klasyfikowane na zdjęciu ASTER

Nr	Kod	Nazwa klasy	Nr	Kod	Nazwa klasy
1	1121	Zabudowa luźna typu blokowego	11	231	Łąki
2	1122	Zabudowa luźna wielorodzinna typu miejskiego	12	243	Tereny rolnicze z dużym udziałem roślinności naturalnej
3	1124	Zabudowa jednorodzinna typu wiejskiego	13	311	Lasy liściaste
4	121	Tereny przemysłowe lub handlowe	14	312	Lasy iglaste
5	133	Place budów	15	313	Lasy mieszane
6	1322	Zwałowiska odpadów płynnych – osadniki	16	324	Lasy w stanie zmian
7	1411	Parki miejskie i wiejskie	17	331	Plaże i piaski
8	1412	Zieleńce, skwery, trawniki	18	411	Bagna śródlądowe
9	211	Grunty orne	19	511	Wody
10	2113	Uprawy szklarniowe			

jedynie średnimi wartościami 3 kanału spektralnego. W przypadku drugiej podklasy zastosowano średnie wartości kanału 3, termalnego oraz wartości NDVI obiektów.

Funkcję przynależności (czyli podejście parametryczne) zastosowano również w przypadku klas związanych z zabudową. W pierwszym kroku rozpoznano klasę będącą sumą klas 1121, 1122 i 1124. Głównym parametrem klasyfikacji była GLCM Entropy 1 kanału oraz GLCM Dissimilarity kanałów 1, 3 i 4 (są to funkcje Haralick). Następnie z ogólnej klasy wyłoniono zabudowę blokową (1121) i luźną zabudowę miejską (1122). Zabudowa blokowa została sklasyfikowana z zastosowaniem dodatkowego podpoziomu segmentacji, który pozwolił na rozpoznanie cieni wysokich budynków. Natomiast do klasyfikacji zabudowy (1122) wykorzystano algorytm Standard NN kanałów 1, 3 i 4. Zabudowa niesklasyfikowana jako 1121 lub 1122 została zaliczona do jednorodzinnej zabudowy wiejskiej 1124.

Prawie wszystkie pozostałe klasy zostały sklasyfikowane metodą Standard NN na podstawie kanałów 2, 3, 4, 6, 7, 13, współczynnika NDVI oraz dodatkowych parametrów.

W procesie klasyfikacji klasy „grunty orne” i „łąki” zostały podzielone na dwie podklasy ze względu na różnice wynikające z intensywności pokrywy roślinnej. W przypadku klasy „parki miejskie i wiejskie” dodano warunki związane z graniczeniem z zabudową oraz zajmowaną powierzchnią. Natomiast „zieleńce, skwery, trawniki” zostały wyłonione z klasy „grunty orne” na podstawie warunków związanych z graniczeniem z zabudową i zajmowaną powierzchnią.

Klasa „las mieszany” w przeciwieństwie do klas „las liściasty” i „las iglasty” nie została sklasyfikowana w sposób bezpośredni. Została ona określona na podstawie obiektów sklasyfikowanych jako las iglasty lub liściasty charakteryzującymi się wysokimi wartościami odchylenia standardowego w 3 kanałach spektralnym. Taki sposób postępowania wydaje się być w pełni uzasadniony, gdyż klasa „las mieszany” pod względem spektralnym zawsze w dużym stopniu pokrywa się z klasami: las iglasty i las liściasty. Las mieszany został potraktowany jako niejednorodny las iglasty lub liściasty. Podobne podejście zastosowano w przypadku klasy „tereny rolnicze z dużym udziałem roślinności naturalnej” (243). Przyjęto, że

klasa ta zostanie wyłoniona z obiektów klasy „las liściasty” charakteryzujących się bardzo wysokim odchyleniem standardowym w 3 kanale.

Klasę „tereny przemysłowe lub handlowe” sklasyfikowano podobnie jak klasy „woda”, „grunty rolne” i „łąki” z podziałem na dwie podklasy. Pierwsza podklasa została sklasyfikowana metodą Standard NN, natomiast druga poprzez porównanie stopnia przynależności do pierwszej podklasy i do ogólnej klasy będącej sumą klas związanych z zabudową.

Generalizacja

Generalizacja jest często zaniebdywanym etapem pracy w czasie klasyfikacji obrazów satelitarnych. Najczęściej jest zastępowana filtracją, która jedynie zmniejsza występowanie na obrazie zjawiska pojedynczych pikseli sklasyfikowanych inaczej niż ich otoczenie. Natomiast w przypadku interpretacji wizualnej jednostki odniesienia są zawsze stosowane, gdyż określają stopień szczegółowości interpretacji.

Na podstawie zdjęcia ASTER, ze względu na rozdzielczość przestrzenną zakresu VNIR wynoszącą 15 m, można wykonać opracowanie w skali 1:50 000. W czasie generalizacji obrazu klasyfikacyjnego przyjęto wielkość jednostki odniesienia 4 ha, co odpowiada 178 pikselom obrazu ASTER. Dla klasy wód i klas związanych z zabudową przyjęto większą dokładność wynoszącą 1 ha. Zmiany kodów klasyfikacyjnych nastąpiły jedynie na 1,4% powierzchni całego obszaru badań. Świadczy to o odpowiednim doborze parametru skali klasyfikowanego poziomu segmentacji. Dzięki generalizacji rozwiązany został również problem kilku małych, niesklasyfikowanych obiektów, które zostały „wciągnięte” przez sąsiednie klasy.

W celu porównania, generalizacja wykonana została również dla przykładowej klasyfikacji nadzorowanej terenu badań. Podobnie jak w przypadku większości klasyfikacji wykonanych tradycyjną metodą, analizowany obraz charakteryzował się dużą ilością małych wydzielen składających się z pojedynczych pikseli. Po generalizacji zmianie uległo aż ponad 30% powierzchni terenu badań. Tak duże różnice w powierzchni klas są niedopuszczalne, gdyż generalizacja nie może zmieniać charakteru obrazu klasyfikacyjnego.

Zamiana obrazu klasyfikacyjnego na format wektorowy

Po generalizacji obraz klasyfikacyjny został zamieniony na format wektorowy. W wyniku konwersji danych powstała warstwa wektorowa składająca się z poligonów o granicach przebiegających wzdłuż granic klas sklasyfikowanego obrazu. Informacje o klasach zostały przeniesione do tabeli atrybutów warstwy wektorowej w postaci kodów klas.

W czasie zamiany formatów zastosowano funkcję wygładzającą granice poligonów (obiektów). Parametry wygładzania zostały dobrane w taki sposób, aby linie uzyskane w sposób automatyczny w możliwie dużym stopniu przypominały wynik interpretacji wizualnej. W przypadku niezastosowania funkcji wygładzającej granice poligonów przebiegałyby wzdłuż krawędzi pikseli obrazu.

Weryfikacja klasyfikacji metodą interpretacji wizualnej

Weryfikacja poprawności klasyfikacji wykonana została metodą interpretacji wizualnej, w ten sam sposób co w programie CORINE 2000 (Perdigao, Annoni, 1997). Interpretator wykonywał sprawdzenie/poprawę klasyfikacji na monitorze komputera widząc równocześnie obraz satelitarny oraz warstwę wektorową klasyfikacji. Sprawdzone zostały kody wydziałów oraz przebieg granic poligonów. W wyniku pracy interpretatora powstała wektorowa warstwa zmian zawierająca różnice między klasyfikacją i interpretacją wizualną. Warstwa zmian posłużyła do oceny klasyfikacji, gdyż zarejestrowane zmiany są informacją o błędach klasyfikacji. Na podstawie warstwy zmian utworzono poprawny obraz klasyfikacyjny.

Ocenę dokładności klasyfikacji przedstawiono w tabeli 2 (Lewiński, 2005). Zawiera ona w dwóch ostatnich kolumnach dokładność użytkownika i producenta, a poprzedza je zestawienie powierzchni klas, które zostały skorygowane w czasie interpretacji wizualnej. Kolumny tabeli nie zawierają klas 1121, 1322, 1411, 1412 i 2113, dla których uzyskano 100% dokładności użytkownika i producenta.

Największa ilość zmian nastąpiła w klasie „grunty orne” (211). Po interpretacji 5254 ha tej klasy przeszło do klasy „łąki” (231), zmiany te stanowią 6.6% powierzchni całego poligonu badawczego. Taka sytuacja związana jest przede wszystkim z terminem wykonania zdjęcia ASTER. W roku 2002 w Polsce sezon wegetacyjny rozpoczął się już w pierwszej dekadzie marca. Na początku maja uprawy ozime i niektóre uprawy jare znajdowały się już w fazie intensywnego rozwoju i pod względem spektralnym były zbliżone do użytków zielonych. Dodatkowym utrudnieniem jest wyjątkowo duże rozdrobnienie terenów rolniczych. Prawidłowe rozpoznanie tych klas było również kłopotliwe podczas interpretacji wizualnej.

Po interpretacji wizualnej wzrosła powierzchnia klasy „zabudowa jednorodzinna typu wiejskiego” (1124), która została błędnie sklasyfikowana głównie jako grunty orne (211) – 1135 ha, łąki (231) – 621 ha oraz lasy mieszane (313) – 210 ha. W sumie powierzchnia zabudowy jednorodzinnej typu wiejskiego zwiększyła się o 41.5% co stanowi 2.5% powierzchni terenu badań. Automatyczne rozpoznanie tej klasy nie jest proste ze względu na jej złożony charakter, gdyż obok niewielkich budynków występują pola, łąki i drzewa, których nie można jednoznacznie rozpoznać na zdjęciu satelitarnym średniej rozdzielczości.

Kolejną klasą, której powierzchnia uległa zmianie w istotnym stopniu są „tereny rolnicze z dużym udziałem roślinności naturalnej” (243). Błędy klasyfikacji tej klasy podobnie jak w przypadku poprzedniej związane są z rozdzielczością zdjęcia oraz definicją klasy.

Pozostałe zmiany przedstawione w tabeli 2 nie są tak bardzo istotne dla całego procesu klasyfikacji.

Zmiany dotyczyły obszaru 10 913 ha, co stanowi 13,7% całkowitej powierzchni poligonu badawczego. Uzyskany wynik całościowej oceny klasyfikacji, wynoszący 86.3%, należy uznać za dobry zwłaszcza, że około połowa błędów klasyfikacyjnych związana jest przede wszystkim z porą rejestracji zdjęcia (wiosna). Należy też zwrócić uwagę na stosunkowo dużą liczbę klas, które zostały rozpoznane dzięki metodzie klasyfikacji obiektowej.

Tabela 2. Ocena dokładności klasyfikacji metodą interpretacji wizualnej

Klasyfikacja	Kody klas po interpretacji wizualnej														Powierzchnia [ha]	Dokładność [%]		
	121	133	211	231	243	311	312	313	324	331	411	511	1122	1124		użytk.*	prod.*	
121	89														89	100	96,2	
133		109													109	100	42,3	
211		148	11 918	5254	252	21	58	48	31		4		38	1135	18907	63,0	96,9	
231			262	22 572	475	24	40	69						621	24062	93,8	80,1	
243					870			50						13	933	93,2	36,8	
311				71		2784	18	227	6						3107	89,6	90,6	
312							12 570	16							12586	99,8	98,5	
313			65	233	711	235	67	9004	113		15		4	210	10657	84,4	95,3	
324									87						87	100	36,7	
331						6				113				11	130	87,0	100	
411											37				37	100	35,6	
511											48	3809			3857	98,7	100	
1121															62	100	100	
1122			2		14			24						1630	60	1729	94,2	95,7
1124	4		48	61	40			10						31	2886	3079	93,7	58,4
1322															30	100	100	
1411															86	100	100	
1412															26	100	100	
2113															16	100	100	
Pow. [ha]	93	256	12 294	28 192	2362	3071	12 753	9448	236	113	105	3809	1703	4935		dokładność całkowita 86,3		
														całkowita powierzchnia		79 589		

* użyt. – użytkownik, prod. – producent

Podsumowanie

Przedstawiono propozycję algorytmu postępowania mającego na celu wspomaganie procesu interpretacji wizualnej zdjęć satelitarnych, który zastosowano do opracowania zdjęcia satelitarnego ASTER. Uzyskane wyniki potwierdziły słuszność założenia, że narzędziem wspomagającym może być nowa metoda klasyfikacji obiektowej.

W porównaniu z tradycyjnymi metodami klasyfikacji, w których klasyfikuje się pojedyncze piksele obrazu, użytkownik ma do dyspozycji o wiele większą liczbę parametrów charakteryzujących treść zdjęcia satelitarnego. Proces rozpoznania poszczególnych klas zbliżony jest w pewnym stopniu do zasad stosowanych przy interpretacji wizualnej. Uzyskana w wyniku klasyfikacji warstwa wektorowa o wygładzonych granicach poligonów stanowi bazę danych, która jest korygowana (aktualizowana) przez interpretatora, który nie jest zmuszony do rozpoczynania pracy „od początku”.

W przypadku poprawnie wykonanej klasyfikacji obiektowej rola interpretatora polega przede wszystkim na sprawdzeniu kodów i przebiegu granic wydzielen. Po weryfikacji uzyskuje się poprawną bazę danych, taką samą jak w przypadku interpretacji wizualnej.

Na podstawie prac wykonanych na przykładzie jednego zdjęcia trudno jest ocenić w sposób jednoznaczny korzyści wynikające z zastosowania wspomaganego interpretacji klasyfikacją obiektową. Można jednak oczekiwać, że w porównaniu z tradycyjnym sposobem postępowania czas wykonania opracowania będzie zredukowany nawet o 50%.

W celu efektywnego stosowania zaproponowanej metody konieczne jest opracowanie zasad klasyfikacji obiektowej poszczególnych rodzajów zdjęć satelitarnych, tak jak w przypadku opracowanego zdjęcia ASTER, na którym rozpoznano 19 klas pokrycia i użytkowania ziemi. Zasady klasyfikacji obiektowej niekoniecznie muszą obejmować wszystkie klasy pokrycia terenu. Prawidłowe automatyczne rozpoznanie nawet kilku klas pozwoli na przyspieszenie procesu tworzenia bazy danych o pokryciu terenu.

W klasyfikacji obiektowej zdjęcia ASTER zaproponowano oryginalną metodę klasyfikacji lasów mieszanych, które zostały rozpoznane jako lasy iglaste lub liściaste charakteryzujące się niskim poziomem jednorodności. Natomiast w celu rozpoznania zabudowy blokowej wykorzystano informację o cieniach budynków, które widoczne są na zdjęciu satelitarnym.

Literatura

- Abrams M., 2000: The advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER): data products for the high spatial resolution imager on NASA's Terra platform, *Int. J. of Remote Sensing*, Vol 21, No 5.
- ASTER user's guide part 1, general, 2001: ERSDAC.
- Baranowski M., Ciołkosz A., 1997: Opracowanie bazy danych pokrycia terenu Polski. *Prace Instytutu Geodezji i Kartografii*. Tom XLIV, zeszyt 95, s. 7-28.
- Corine land cover, technical guide, 1993.
- eCognition 2001: User Guide. Definiens Imaging.
- Hall-Beyer, M., 2000: GLCM Texture: a Tutorial. V.2.3. Department of Geography University of Calgary.
- Lewiński S., Ewiak I., 2004: Wstępna ocena przydatności zdjęć satelitarnych ASTER w teledetekcji i fotogrametrii. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 14, s.369-380.
- Lewiński S., 2005: Land use classification of ASTER image – Legionowo test site. Proc. “The 25th symposium of the European Association of Remote Sensing Laboratories”, Porto, Portugalia”, 6-9 czerwca 2005 r. Millpress (w druku)

Perdigao, V., Annoni, A., 1997: Technical and methodological guide for updating CORONE land cover data base, EUR 17288.

Poławski Z.F., 2002: Koncepcja i zakres tematyczny szczegółowej mapy użytkowania ziemi w skali 1:50 000. Instytut Geodezji i Kartografii. Seria monograficzna Nr 4, 59-89.

Summary

This paper presents the works performed during realisation of a project, which enabled designing an automatic support method of satellite image interpretation of land cover forms. The method is based on object-oriented classification and it comprises five basic stages: image segmentation, classification, generalisation, conversion of the classification images into vector format, verification of the classification using the method of visual interpretation.

Based on a study area of nearly 800 sq. km, rules of object-oriented classification of ASTER satellite images were defined. Object-oriented classification was carried out with a division into 19 classes of land cover and land use. The result of classification was generalised using a working unit of 4 hectares and 1 hectare for water and build-up areas (working units are connected with the scale of 1:50000). Next, raster classification images were converted into vector format. The polygon edges of the vector layer were smoothed in order to make them more similar to the borders identified during visual interpretation.

Assessment of classification was performed in order to verify correctness of classification codes and borders identified during visual interpretation. To this end, the procedure used in the CORINE 2000 programme was applied. Interpretation resulted in obtaining information about the differences between classification and interpretation. On the basis of these results, it was possible to precisely specify the accuracy of classification of all classes (within the entire study area) and to create an accurate database of land cover and land use.

In the process of object-oriented classification, diverse classification criteria were applied. The method of classification of mixed forest and apartment blocks is particularly interesting: mixed forests were classified as deciduous or coniferous forests characterised with high non-uniformity, while apartment blocks were identified according to shadows of high buildings.

During generalisation of the images, only 1.4% of the study area was changed, which indicates that satellite image segmentation was performed properly. Total accuracy of classification was over 86% and half of the classification mistakes occurred as a result of the fact that an image was taken in spring. The suggested method may accelerate interpretation of land cover and land use even by 50% and in some cases it may even replace visual interpretation.

The condition for the method to be effective is defining the rules of object-oriented classification for all types of satellite images, as it was done for the ASTER image. The rules of classification do not necessarily have to cover all classes of land cover (sometimes it may even be impossible). Correct automatic identification of even a few classes will accelerate the process of land cover database creation.

dr inż. Stanisław Lewiński
stanislaw.lewinski@igik.edu.pl
tel. (0-22) 329 19 76