

TESTOWANIE METOD I ALGORYTMÓW KLASYFIKACJI WYSOKOROZDZIELCZYCH ZOBRAZOWAŃ SATELITARNYCH PUSZCZY NIEPOŁOMICKIEJ

TESTING OF METHODS AND CLASSIFICATION ALGORITHMS OF THE VHR SATELLITE IMAGES OF THE NIEPOLOMICE PRIMEVAL FOREST

Piotr Wężyk, Paweł Bednarczyk

Laboratorium GIS i Teledetekcji,
Katedra Ekologii Lasu, Wydział Leśny
Akademia Rolnicza w Krakowie

Słowa kluczowe: QuickBird, klasyfikacja, segmentacja
Keywords: QuickBird, classification, segmentation

Wstęp i cel pracy

Od kilku lat komercyjne systemy satelitarne oferują zobrazowania o wysokiej rozdzielczości terenowej rzędu 1-4 m (np. IKONOS, QuickBird, OrbView, EROS), co dla leśników oznacza zupełnie nowe możliwości kartowania drzewostanów (Toutin i in. 2002; Kayitakire i in. 2002; Kristóf i in. 2002; Sasakawa i in. 2003; Zajączkowski i in. 2004). W zależności od klasy wieku czy fazy rozwojowej drzewostanu pojedyncze korony drzew mogą być rejestrowane na obrazie i w konsekwencji rozumiane jako piksele (reprezentujące poszczególne drzewa), a nie „mixele” jak w przypadku poprzednich systemów jak Landsat TM czy IRS (Zawiła-Niedźwiedzki 1994). Zwiększenie rozdzielczości terenowej w połączeniu z 11 bitową rozdzielczością radiometryczną poszerza w zdecydowany sposób potencjał interpretacyjny obrazu (Zajączkowski i in. 2004; Kurczyński, Wolniewicz 2002; Wężyk i in. 2004).

Nowa, obowiązująca Instrukcja Urządzania Lasu (IUL 2003), zaleca wykorzystywanie danych teledetekcyjnych w procesie inwentaryzacji lasu i tworzenia opracowań kartograficznych. Zmieniona w niej została definicja *składu gatunkowego* drzewostanu. Rozumie się ją obecnie jako stosunek powierzchni zajmowanej przez dany gatunek bądź liczbę drzew w odniesieniu do powierzchni pododdziału. Otwiera to nowe możliwości stosowania zobrazowań satelitarnych w leśnictwie, w tym określania składu gatunkowego drzewostanów. Na obecnym etapie trudno jednak mówić o doborze takiej metody klasyfikacji, która z dokładnością wymaganą przez IUL (do 10%) mogłaby dostarczać wymaganych informacji. Ciągły

rozwój technologii oraz metod i algorytmów klasyfikacji (Sasakawa i in. 2003; Kayitakire i in. 2002; Kristóf i in. 2002; Dickson i in. 1999) zachęca jednak do ciągłych badań i udoskonalania stosowanych rozwiązań.

Celem pracy była ocena wyników algorytmów klasyfikacji nadzorowanej dostępnych w oprogramowaniu ER Mapper (ver. 6.4) pod kątem ich praktycznego zastosowania w procesie leśnej inwentaryzacji. W oparciu o zobrazowanie QuickBird-2 testowano możliwości dostępnych w programie algorytmów klasyfikacji koron poszczególnych gatunków drzew, przy czym założono, iż wynik powinien być jak najbardziej zbliżony do informacji zawartych na mapach gospodarczych (w bazie danych LAS/SILP). Dodatkowo autorzy postanowili przetestować możliwości automatycznej metody klasyfikacji obiektowej, do wykrywania klas „LAS” i „NIE-LAS”, w oparciu o program eCognition (Definiens), nie bazując na polach treningowych, a jedynie na określonych formułach empirycznych.

Teren badań

Testowanie algorytmów klasyfikacji przeprowadzono na obrazie satelitarnym QuickBird-2 obejmującym wschodnią część Puszczy Niepołomickiej położonej w dolinie Wisły, około 30 km na wschód od Krakowa (rys.1). Gatunkami dominującymi w drzewostanach analizowanego fragmentu Puszczy Niepołomickiej były: sosna pospolita (*Pinus sylvestris* L.; So) – 58%, dęby (*Quercus* sp.; Db) – 18%, olsza czarna (*Alnus glutinosa* L.; Ol cz) – 9%, brzoza brodawkowata (*Betula verrucosa* L.; Brz) – 5% oraz domieszkowo i pojedynczo: modrzew (Md), grab (Gb), jesion (Js), buk (Bk), lipa (Lp) oraz świerk (Św).

Material i metoda

Metodyka pracy wymuszała wykorzystywanie różnych źródeł informacji oraz posługiwanie się technologiami ich przetwarzania i integracji geodanych. Prace terenowe przeprowadzono dwukrotnie tj.: w sierpniu 2003 roku oraz lipcu 2004 roku. Lokalizacja poszczególnych pól treningowych (ROI) i obszarów testowych określana była na podstawie pomiaru DGPS (Pathfinder ProXRS z rejestratorem polowym TSC1; Trimble) korygowanego ze stacji bazowych ASG-PL (Wężyk 2004). Obszary testowe stanowiły jednogatunkowe drzewostany III (40-60 lat) lub starszych klas wieku. Ostateczny zasięg i rozmieszczenie pól treningowych i pól testowych został zweryfikowany na podstawie wizualnej interpretacji obrazu satelitarnego QuickBird.

Dla wytypowanych fragmentów drzewostanów skład gatunkowy oraz wiek odczytywano na podstawie informacji zawartej w bazie modułu LAS/SILP (stan 2001 r.).

Ważne źródło informacji stanowiła Leśna Mapa Numeryczna (LMN), którą Nadleśnictwo Niepołomice dysponuje od roku 2002 (wykonana na podstawie prac urzędniowych z 2001 roku), spełniająca tzw. *Standard LMN* wprowadzony Zarządzeniem Dyrektora Generalnego LP nr 74 w roku 2001 (IUL 2003).

W pracy wykorzystano obraz satelitarny QuickBird-2 zarejestrowany dnia 15 września 2003 roku i dostarczony jako produkt typu *Standard*.

Klasyfikację nadzorowaną zobrażenia QuickBird przeprowadzono w oparciu o następujące algorytmy, dostępne w programie ER Mapper 6.4 (ERM), tj.:

- równoległościaków (*Parallelepiped*);
- odległości Mahalanobisa (*Mahalanobis*);
- minimalnej odległości (*Minimum distance*);
- największego prawdopodobieństwa (*Maximum Likelihood*) w wariantach: Standard (*Standard*) oraz Wzmocnienie (*Enhanced*) w opcji:
 - z uwzględnieniem sąsiedztwa (*Neighbor*), oraz
 - bez uwzględnienia sąsiedztwa (*Neighbor*).

Ocenę wyników działania poszczególnych algorytmów klasyfikacyjnych przeprowadzono w oparciu o obszary testowe. Posłużono się zmodyfikowaną metodą wykorzystującą oprogramowanie ArcView ArcGIS oraz generowane z obserwacji terenowych i baz danych LAS/SILP warstwy rastrowe (GRID; ESRI). Wielkość piksela dla warstw typu GRID przyjęto zgodnie z rozdzielczością terenową kanałów spektralnych QuickBird-2, tj.: 2,4 m x 2,4 m.

Wyniki i dyskusja

Obraz QuickBird skalibrowano do układu współrzędnych PUWG 1992/19 (zgodny ze SLMN) w oparciu o punkty dostosowania (GCP) pomierzone w terenie metodą DGPS bądź pozyskane z ortofotomapy wygenerowanej ze zdjęć lotniczych z 1997 roku (z zasobów WODGiK). Średni błąd kwadratowy współrzędnych płaskich (RMS_{XY}) kształtował się na poziomie 1,85 metra (poniżej jednego piksela MS) co uznano za dopuszczalne w porównaniu do warstw referencyjnych, tj. LMN (przyjęto maks. 0,2 mm w skali mapy 1:10.000).

Na podstawie przeprowadzonych prac terenowych oraz wizualnej interpretacji obrazu (z wykorzystaniem wektora LMN oraz utworzonej relacji do bazy atrybutowej LAS/SILP) zdefiniowano pola treningowe (ROI) i obszary testowe reprezentujące klasy przedstawione w tabeli 1.

Tabela 1. Zestawienie powierzchni pól treningowych (ROI) i obszarów testowych (TA) wykorzystanych w procesie testowania algorytmów klasyfikacyjnych

Klasa	Pola treningowe (ROI)		Obszary testowe (TA)	
	[szt.]	[ha]	[szt.]	[ha]
<i>So</i>	74	111,08	10	26,58
<i>Db</i>	25	4,88	29	6,20
<i>Ol cz</i>	49	4,26	6	3,07
<i>Bk</i>	12	0,56	4	0,48
<i>Md</i>	8	0,97	3	0,43
<i>Brz</i>	20	1,19	2	1,10
<i>Polana</i>	7	32,39	7	1,40
<i>P_ uprawne</i>	6	6,19	3	5,38
<i>Cień</i>	13	0,47	3	0,07
<i>Zabudowa</i>	6	7,75	8	0,25

W procesie klasyfikacji pominięto kilka gatunków (jesion, lipa, grab, świerk) występujących na terenie Puszczy Niepołomickiej ze względu na ich znikomy udział powierzchniowy oraz obiektywną trudność wyznaczenia jednolitych ROI oraz TA reprezentujących te gatunki pod względem składu gatunkowego.

Wstępne wyniki klasyfikacji wykazywały, iż granica rolno-leśna była bardzo wyraźna w przypadku wszystkich stosowanych algorytmów. Wyjątek stanowił algorytm równoległościaków, którego wynikiem działania było poprawne określenie zaledwie dwóch klas, a mianowicie: *cień* i *zabudowa*. Z tego powodu algorytm ten został pominięty w dalszych analizach.

Stratyfikacja drzewostanów na określone typy, tj.: liściasty i iglasty, nie sprawiła w zasadzie większych problemów i we wszystkich przypadkach osiągnęto dużą dokładność. Przykładowe porównanie danych opisowych zawartych w bazach danych LAS/SILP z wynikami działania algorytmu klasyfikacyjnego: *maksymalnego prawdopodobieństwa* (wariant Standard z oknem 5x5 pikseli; 6 iteracji) zawarto w tabeli 2.

Tabela 2. Dokładność klasyfikacji nadzorowanej (algorytm maksymalnego prawdopodobieństwa w wariacie Standard; okno 5x5 pikseli, 6 iteracji) w stratyfikacji gatunków iglastych i liściastych

Typ drzewostanu	Powierzchnia według		Różnica	
	SILP	Klasyfikacja	[ha]	[%]
	[ha]	[ha]		
Gatunki liściaste	3033,52	2411,7	-621,82	-20,5
Gatunki iglaste	4806,96	4757,165	-49,80	-1,0
Suma	7840,46	7168,86	-671,62	-8,6

Różnice pomiędzy powierzchnią obliczoną na podstawie bazy danych LAS/SILP a klasyfikacją nadzorowaną *maksymalnego prawdopodobieństwa*, wynikają w pewnym stopniu z różnej metody opisywania składu gatunkowego. W atrybutowej bazie danych LAS/SILP udział poszczególnych gatunków podawany jest na podstawie miąższości, natomiast wynik klasyfikacji nadzorowanej opisuje powierzchnię rzutu koron drzew wchodzących w skład pierwszego piętra (pikseli rejestrowanego górnego pułapu drzewostanu). Różnica sumarycznej powierzchni gatunków liściastych i iglastych (-672,62 ha) wynika w dużej mierze z pominięcia w tabeli 2 klasy *cień* (313 ha), *polany* (wewnątrz kompleksów leśnych) czy *p_uprawne*. Do wymienionych klas zaliczono także: luki, drogi i inne powierzchnie nieporośnięte drzewami (nieudane uprawy czy też niezalesione zręby), a zaliczone wg LAS/SILP do powierzchni z roślinnością drzewiastą.

O wiele większe trudności napotkano w trakcie klasyfikacji pikseli pod kątem poszczególnych gatunków drzew. Dużym podobieństwem odbicia spektralnego cechowały się pary gatunków (wewnątrz typów drzewostanów) takie jak: sosna/modrzew oraz dąb/olsza. W celu poprawy wyników działania algorytmu klasyfikacji, kilkakrotnie modyfikowano ROI, np. poprzez usuwanie z ich obszaru niewielkich obszarów cienia tworzonego przez wysokie drzewa i luki w pułapie koron. W trakcie prac okazało się, iż dużą „mobilnością” (tj. dynamiką przechodzenia pomiędzy klasami), zarówno w kierunku gatunków iglastych jak i liściastych cechowała się brzoza. Wynikać to może przede wszystkim z budowy korony tego

drzewa. Brzoza charakteryzuje się bardzo dużą ażurowością korony (gatunek zaliczany jest do światłożądnych; Jaworski 1994), co powodowało zapewne „nakładanie się” odpowiedzi spektralnej: dolnych warstw drzewostanu, podszytu bądź nawet runa leśnego. Szczegółowa analiza wykazała, iż brzoza wykazuje pewne podobieństwo do charakterystyki koron sosny, co można ewentualnie wytłumaczyć stosunkowo późnym terminem pozyskania zobrażenia (początek przebarwiania się aparatu asymilacyjnego, zmiany w strukturze komórki i tym samym spadek odbicia w kanale bliskiej podczerwieni) (Węzyk 1998).

Dla gatunków liściastych problemem okazało się zaliczanie przez algorytm klasyfikacyjny, koron starszych drzew liściastych (dąb, olsza) do różnych klas. Przyczyna tkwiła prawdopodobnie w różnym stopniu oświetlenia poszczególnych części koron (kąt padania promieni słonecznych wynosił ok. 40°) lub występowaniem uszkodzeń koron (wiele wierzchołków; defoliacja koron dębu powodowana gradacjami zwójek). Częściowe wyeliminowanie tego problemu możliwe było dzięki zastosowaniu parametrów *sąsiedztwa*. W tym celu wykorzystano opcję *Neighbor filter* o wielkości okna 5x5 pikseli. Takie rozwiązanie spowodowało jednocześnie generalizację wyników, co zdecydowanie poprawiło czytelność kompozycji mapowej. Paradoksalnie, generalizacja bardzo szczegółowej informacji tkwi w preferencjach odbiorcy (leśnika), który od „zawsze” przyzwyczajony był do uproszczonej informacji na mapach leśnych (jedna barwa dla jednego wydzielenia reprezentująca gatunek główny).

Ocenę dokładności działania poszczególnych algorytmów przeprowadzono w oparciu o obszary testowe (tab.1, rys.1). Otrzymane wyniki (tab. 3) świadczą o dużej przydatności klasyfikacji zobrażeń satelitarnych do prac z zakresu inwentaryzacji lasu wykonywanej jak dotąd tradycyjnymi metodami.

Najbardziej poprawne rezultaty klasyfikacji osiągnęto w oparciu o stosowanie algorytmu *maksymalnego prawdopodobieństwa* (wariant Standard) z włączoną funkcją analizy sąsiedztwa. Reguła ta wykorzystuje zakładaną wartość prawdopodobieństwa przynależności danego piksela do określonej klasy. Bardzo duża liczba parametrów silnie uzależnia wynik od rozkładu danych w każdym kanale wejściowym. Największą poprawność uzyskano w przypadku drzewostanów sosnowych (klasa So aż 97,3%), gdy inne algorytmy generowały wynik na poziomie co najmniej 60%, jedynie w przypadku algorytmu *Mahalanobis'a* wynik był znacznie zaniżony osiągając zaledwie wartość 41% (So; tab.3).

Drzewostany modrzewiowe możliwe były do sklasyfikowania z dokładnością rzędu od 16,8% do 58,8%. Ogromnym zaskoczeniem okazał się jednak dla autorów wynik algorytmu *maksymalnego prawdopodobieństwa* (najbardziej odpowiedniego dla klasy So) dla klasy Md (wynik = 0%), który tłumaczyć można jedynie przebarwieniami aparatu asymilacyjnego modrzewia w okresie wykonywania zobrażenia (15.09.03) i bardzo dużą ażurowością korony jako gatunku wybitnie światłożądnego.

Bardzo ważnym z punktu widzenia praktyki leśnej było testowanie doboru algorytmu dla obszarów łąkowych (liściastych) kompleksów leśnych Puszczy Niepołomickiej. W przypadku dębu (zajmującego 18% powierzchni Puszczy Niepołomickiej) „najbardziej poprawny” wynik uzyskano w przypadku algorytmu *maksymalnego prawdopodobieństwa* w wariantcie *Standard* z uwzględnieniem *sąsiedztwa* (72,7%). W przypadku stosowania innych algorytmów wyniki oscylowały pomiędzy 14,7% do 33,6 %. Najczęściej błędnie interpretowany Dąb zastępowała klasa *Olsza czarna*. Najbardziej przydatnym w przypadku Olszy czarnej okazał się jednak inny algorytm tj. *maksymalnego prawdopodobieństwa* (wariant Wzmocnienie) z włączoną funkcją analizy sąsiedztwa (5x5 pikseli, 6 iteracji), który dawał

Tabela 3. Zestawienie wyników działania algorytmów klasyfikacyjnych

Algorytm	Cecha	So	Md	Db	Olcz	Bk	Brz	Cień	Polany	Z	P_U
MLSN	Zgodność (%)	97,3	-	72,7	63,3	88,5	18,4	100,0	48,0	100,0	99,9
	Błędnie zaliczono do klasy (%)	Md 1,2	So 00,0	Olcz 11,8	Db 36,1	Db 7,0	So 44,8	-	Z 16,7	-	Z 0,1
MLS	Zgodność (%)	62,1	58,8	27,9	65,5	57,4	25,0	100,0	41,7	92,9	99,4
	Błędnie zaliczono do klasy (%)	Md 27,8	So 31,8	Olcz 41,7	So 19,0	OI 14,5	So 23,2	-	Z 16,0	polany 3,9	Z 0,6
MLEN	Zgodność (%)	84,6	57,5	32,9	94,2	82,9	33,3	100,0	45,8	100,0	100,0
	Błędnie zaliczono do klasy (%)	Md 13,0	So 41,2	Olcz 46,1	So 4,7	Brz 10,0	Md 26,0	-	OI 16,9	-	-
MLE	Zgodność (%)	62,1	58,8	27,9	65,5	57,4	25,0	100,0	41,7	92,9	99,4
	Błędnie zaliczono do klasy (%)	Md 27,8	So 31,8	Olcz 41,7	So 19,0	Olcz 14,5	So 23,2	-	Z 16,0	polany 3,9	Z 0,6
MD	Zgodność (%)	69,1	31,2	14,7	46,1	53,2	12,5	100,0	35,8	18,7	95,6
	Błędnie zaliczono do klasy (%)	Md 17,8	So 41,5	Olcz 40,8	Brz 14,6	OI 23,2	Md 32,3	-	OI 28,2	P_U 62,0	Z 4,4
MDS	Zgodność (%)	62,0	31,1	15,2	47,9	53,9	15,1	98,4	5,7	99,1	41,5
	Błędnie zaliczono do klasy (%)	Md 23,8	Z 29,9	Olcz 35,6	Brz 17,3	Brz 17,7	Z 35,6	So 1,6	Z 70,3	polany 0,5	Z 58,5
MAH	Zgodność (%)	41,5	16,8	33,6	52,1	63,5	13,8	96,3	1,4	99,8	52,0
	Błędnie zaliczono do klasy (%)	Z 42,8	Z 65,1	Olcz 23,3	Z 16,7	Z 24,0	Z 75,9	Z 3,7	Z 81,1	P_U 0,2	Z 48,0

Oznaczenia algorytmów: MLSN – Maximum Likelihood Standard Neighbor (5x5 pikseli; 6 iteracji); MLS – Maximum Likelihood Standard; MLEN – Maximum Likelihood Enhanced Neighbor (5x5 pikseli, 6 iteracji); MLE – Maximum Likelihood Enhanced; MD – Minimum Distance; MDS – Minimum Distance (Std. Dev.); MAH – Mahalanobis.
Klasy: Z – zabudowa; P_U – pola uprawne

wyniki rzędu 94,2% znacznie przewyższając najwyżej notowany algorytm *maksymalnego prawdopodobieństwa* (wariant Standard) z włączoną funkcją analizy sąsiedztwa (tylko 63,3%).

Klasyfikacja obszarów o skrajnie odmiennych charakterystykach spektralnych (*cień, zabudowa, pola uprawne*) nie sprawiała większych problemów w przypadku wszystkich analizowanych algorytmów. Wynik oscylował nawet w granicach 100% dla klasy *cień* (poza MDS). Klasa *zabudowa* jedynie w przypadku algorytmu *minimalnej odległości* została określona poniżej oczekiwań (18,6%), ale nie była ona przedmiotem niniejszego opracowania.

Rezultaty otrzymane w przypadku klasy *polany* wynikają z dużej rozpiętości charakterystyki spektralnej, co wynika z zaliczeniem do tej klasy zarówno obszarów porośniętych krzewami czy trawami jak i z początkowymi stadiami sukcesji drzew leśnych na obszarach rolniczych.

Oceniając możliwości poszczególnych algorytmów należy stwierdzić, iż reguły klasyfikacyjne opierające się na wartościach pojedynczych pikseli (na podstawie ROI) charakteryzowały się wyraźną „ziarnistością” otrzymanych wyników. Częstym przypadkiem był problem zaliczania poszczególnych podkoron starszych drzew liściastych do klas innych gatunków. Bardzo zróżnicowany wynik otrzymywano również dla pikseli reprezentujących obrzeża koron i granice drzewostanów oraz obszarów pozbawionych drzew.

Osobnym etapem testowania metod klasyfikacji była próba wykorzystania klasyfikacji obiektowej do przetwarzania obrazów VHR QuickBird. Niestety ze względu na czasową licencję programu eCognition (ver. 4) udostępnioną przez Definiens, testowaniem objęto możliwość automatycznej klasyfikacji obszarów pozbawionych roślinności drzewiastej (wewnątrz kompleksów leśnych i poza kompleksami leśnymi).

Przewagi klasyfikacji obiektowej nad tradycyjną, bazującą na pojedynczych pikselach upatrywać można w tym, iż piksele grupowane są w obiekty, dla których już na pierwszym etapie (segmentacji) obliczane są liczne charakterystyki (Kristóf i in. 2002; Sasakawa i in. 2003; Burnett i in. 2003; Baatz i in. 2000; Blaschke i in. 2001). Umożliwia to wykorzystanie wybranych parametrów niedostępnych w tradycyjnych metodach klasyfikacji nadzorowanej. W prezentowanej pracy do testów wytypowano obszar o wielkości 5000 x 5000 pikseli na granicy rolno-leśnej w północnej części kompleksu głównego Puszczy Niepołomickiej.

W pierwszym etapie klasyfikacji obiektowej przeprowadzono segmentację obrazu, w wyniku której starano się otrzymać obiekty w maksymalnym stopniu reprezentujące poszczególne korony drzew. W procesie segmentacji wykorzystano nie tylko poszczególne kanały zobrażenia QuickBird, ale również dodatkowe obrazy powstałe w wyniku zastosowania filtru Lee-Sigma (dla kanału NIR oraz Red – obraz pozytywny i negatywny nazywane umownie *border* oraz *frame*). Wykorzystanie takiego zestawu danych pozwoliło na odzwierciedlenie w dużo lepszym stopniu kształtu pojedynczych koron na etapie segmentacji (Wężyk, de Kok 2005, Wężyk i in. 2004). Klasyfikację obiektową oparto o empiryczne formuły działające na zasadzie logiki rozmytej (*ang. Fuzzy logic*). W procesie klasyfikacji w programie eCognition wykorzystuje się tzw. hierarchię klas. W pierwszy etapie zdefiniowano klasy LAS (*pan_border_low*) oraz NIE_LAS (*pan_border_high*). Następnie w ramach klasy LAS wyróżniono dwie podklasy: obszarów zacienionych (*forest shadow*) oraz drzew (*trees*). Kolejne podklasy obejmowały drzewostany liściaste i iglaste w ramach klasy *trees*. Wykonana klasyfikacja bazowała na pierwszym poziomie segmentacji (rys.2). W następnym etapie wykonano ponownie segmentację opartą na tak przeprowadzonej wstępnie klasyfikacji. Posłużyło to do połączenia obiektów hierarchicznie reprezentujących drzewostany w jeden obiekt LAS. W kolejnych krokach uwzględniając parametry sąsiedztwa, rozgraniczono obszary pozbawione drzew na te położone wewnątrz oraz poza drzewostanem (rys. 3). Określenie wartości granicznych do klasyfikacji drzewostanów i obszarów nieleśnych możliwe było dzięki zastosowaniu dodatkowych obrazów wejściowych (pochodnych) stworzonych przy pomocy programu eCognition (de Kok 2005), tj.:

- *PAN_border* – wartość średnia segmentów w kanale PAN podzielona przez sumę wartości średniej dla warstw (obrazu) *border* i *frame* obrazu panchromatycznego, wykorzystana do rozgraniczenia obszarów nieleśnych i pokrytych drzewostanami, oraz
- *eratred*, opisaną funkcją eksponentylną, w wykładniku której znajduje się iloraz kanału Red i sumy wartości średnich kanałów PAN, Red oraz NIR. Zastosowano ją w celu separacji drzewostanów liściastych od iglastych.

Oprócz wyżej wymienionych obrazów pochodnych wykorzystano także w klasyfikacji znormalizowany indeks roślinności (NDVI) do wyłączenia obszarów zacienionych.

Przeprowadzona klasyfikacja obiektowa w bardzo krótkim czasie umożliwiła uzyskanie dokładnej mapy terenów pozbawionych wegetacji drzewiastej, z rozróżnieniem na obszary wewnątrz oraz poza lasem. Implementacja raz wypracowanych formuł na fragmencie obrazu o wielkości 5000 x 50000 pikseli, wraz z segmentacją zajmuje około 1 godziny. W porównaniu do tradycyjnych metod wymagających zastosowania ROI, metoda klasyfikacji obiektowej cechuje się oszczędnością czasu i pewną uniwersalnością. W przypadku wypracowania dobrych formuł, nie jest w zasadzie wymagana ingerencja użytkownika w proces klasyfikacji. Tego typu metody kartowania z wykorzystaniem wysokorozdzielczych obrazów satelitarnych powinny zostać wykorzystane w przypadku wystąpienia nagłych zdarzeń (takich jak huragany, pożary itp.) lub kartowania lasów na dużych obszarach (np. typów drzewostanów w całej Polsce). Innym potencjalnym zastosowaniem jest weryfikacja map gospodarczych tworzonych w procesie inwentaryzacji lasu w zakresie występowania luk, zrębów, czy też kontrolowania udatności upraw.

Wnioski

Klasyfikacja obrazu satelitarnego QuickBird może dostarczyć wielu informacji na temat środowiska leśnego. Pomimo wysokiej rozdzielczości terenowej obrazu (0,61 m), precyzyjne określenie składu gatunkowego drzewostanu, w dalszym ciągu napotykać może na trudności.

Spośród testowanych klasycznych algorytmów bazujących na wartościach pojedynczych pikseli, w przypadku obszarów leśnych, szczególną uwagę należy zwrócić na reguły wykorzystujące parametry sąsiedztwa. Ich stosowanie eliminuje liczne błędy i zdecydowanie poprawia czytelność wyników, jakich tradycyjnie oczekują odbiorcy map drzewostanowych. Algorytmy nie korzystające z opcji sąsiedztwa generują rezultaty o bardzo skomplikowanej strukturze (choć zgodnej z rzeczywistością) i bardzo często zdarzają się sytuacje błędnego zaklasyfikowania korony pojedynczego drzewa do wielu różnych klas.

Najlepsze rezultaty (zbliżone do danych referencyjnych pozyskiwanych tradycyjnymi metodami) osiąga się wykorzystując klasyfikację nadzorowaną dla drzewostanów o mało zróżnicowanej budowie piętrowej i gatunkowej. Bioróżnorodność polskich lasów rozumiana np. jako zmieszanie ze sobą wielu gatunków drzew i ceniona jako niezmiernie ważny element świadczący o naturalności i trwałości ekosystemu, w znaczący sposób utrudnia jednak klasyfikację obrazu. W przypadku drzewostanów o jednostkowej formie zmieszania, w procesie klasyfikacji zaniżany (lub nawet całkowicie pomijany) jest udział gatunków domieszkowych.

Paradoksalnie można mieć wrażenie, iż dawno oczekiwana wysoka rozdzielczość obrazów satelitarnych przyniosła ze sobą również określone problemy zbyt dużej ich szczegółowości. Teledetekcja może dostarczać informacji o zmieszaniu gatunków na podstawie udziału pikseli poszczególnych klas gatunków w pododdziale. Jak się jednak okazuje leśnicy nie są jeszcze przygotowani do użytkowania map w sposób realistyczny obrazujących rozmieszczenie poszczególnych koron drzew w pododdziałach. Przyczyna tego zjawiska tkwi w tradycji kartografii leśnej oraz metodach inwentaryzacji. Być może za kilka lub kilkanaście lat podejście do obecnych wyników dostarczanych przez klasyfikację obrazu zmieni się diametralnie i będzie można świadomie używać określenia „precyzyjne leśnictwo” mówiąc o poziomie pojedynczych koron drzew w lesie.

W dalszym ciągu jednak metody optyczne dostarczać mogą poprawnych informacji jedynie w przypadku drzewostanów o uproszczonej budowie piętrowej. Niebawem jednak pojawią się wysokorozdzielcze aktywne systemy teledetekcyjne (radar), które w znaczący

sposób przyczynią się do rozwiązania tego problemu. W dalszym ciągu również wybór terminu zobrażenia (głównie w przypadku systemów pasywnych) należy dostosowywać do lokalnych warunków fenologicznych w danym sezonie wegetacyjnym.

W przypadku klasyfikacji obiektowej rezygnacja z wykorzystania pól treningowych oraz oparcie się wyłącznie na empirycznych wartościach pozwala na zautomatyzowanie procesu kartowania drzewostanów i obszarów nieleśnych. Ma to duże znaczenie w przypadku potrzeby przeprowadzenia klasyfikacji dużej ilości scen satelitarnych w krótkim czasie. Posiadanie tego typu uniwersalnych formuł modyfikowanych nieznacznie dla poszczególnych scen (głównie ze względu na okres fenologiczny) może mieć w przyszłości pierwszorzędne znaczenie np. dla administracji Lasów Państwowych czy departamentów Ministerstwa Środowiska odpowiedzialnych za raportowanie do Komisji Europejskiej.

Literatura

- Baatz, M., Schäpe, A., 2000: Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. In: Strobl, J. and Blaschke, T. (Eds.): *Angewandte Geogr. Informationsverarbeitung XII*, Wichmann, Heidelberg, ss. 12-23.
- Blaschke, T., Hay, G. J., 2001: Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure. *Int. Archives Photogrammetry and Remote Sens.*, 34, part 4/W5, ss. 22-29.
- Burnett C., Blaschke T., 2003: A multi-scale segmentation/object relationship modeling methodology for landscape analysis *Ecological Modelling*, Volume 168, Issue 3, 15 October 2003, ss. 233-249
- De Kok R., 2005: eCognition – object oriented classification training. Training Manual. ProGea Consulting-landConsult. Krakow 2005.
- Dickson E., Franklin S.E., Moskal L.M., 1999: Monitoring of forest biodiversity using remote sensing: Forest stand (high spatial resolution) protocol and examples. Alberta Biodiv. Monitoring Prog. <http://www.abmp.arc.ab.ca/chapter09.pdf>, ss. 26.
- Instrukcja Urządzenia Lasu, 2003: Ministerstwo Ochrony Środowiska, Zasobów Naturalnych i Leśnictwa. Dyrekcja Generalna Lasów Państwowych. Warszawa.
- Jaworski A., 1994: Charakterystyka hodowlana drzew leśnych. Gutenberg, Kraków.
- Kayitakire F., Farcy C., Defourny P., Culvenor D.C., 2002: IKONOS-2 imagery potential for forest stands mapping. <http://www.enge.ucl.ac.be/staff/curr/kayitaki/forestsat.pdf>, ss. 11.
- Kristóf D., Csató E., Ritter D., 2002: Application of high-resolution satellite images in forestry and habitat mapping – evaluation of IKONOS images through a Hungarian case study; <http://www.isprs.org/commission4/proceedings/pdfpapers/349.pdf>
- Kurczyński Z., Wolniewicz W., 2002: Co oznacza piksel poniżej metra? [W:] *Geodeta – Magazyn Geoinformacyjny* 8(87).
- Sasakawa H., Tsuyuki S. 2003: Development of forest type classification technique for the mixed forest with coniferous and broad-leaved species using the high resolution satellite data; <http://definiens-imaging.com/documents/reference2003.htm>
- Toutin T., Cheng P., 2002: QuickBird – A Milestone for High Resolution Mapping, *Earth Observation Magazine*, vol. 11, no. 4, ss. 14-18.
- Wężyk P., 1998: Kompleksowe wykorzystanie informacji ze zdjęć lotniczych. Część III. Szczegółowe aplikacje zdjęć lotniczych w różnych dziedzinach gospodarki. Skrypt przygotowany na zamówienie Głównego Geodety Kraju w ramach projektu PHARE PL.9206-02-04/II. A3-10 – A3-37. Kraków-Sieradz.
- Wężyk P., 2004: GPS w leśnictwie i ochronie przyrody. Mity i fakty *Roczniki Geomatyki*, Tom II, Zeszyt 4, ss. 19- 32.
- Wężyk P., de Kok R., Zajaczkowski G., 2004: The role of statistical and structural texture analysis in VHR image analysis for forest applications. A case study on QuickBird data in the Niepolomice Forest. [In:] Strobl et al. Hrsg. *Angewandte Geoinformatik* 2004; ss. 770-775. Wichman. Heidelberg.
- Wężyk P., de Kok R., 2005: Automatic mapping of the dynamics of forest succession on abandoned parcels in south Poland. [In:] Strobl et al. Hrsg. *Angewandte Geoinformatik* 2005; ss. 774-779. Wichman. Heidelberg .

- Zajączkowski G., Wężyk P., 2004: Techniki teledetekcyjne w inwentaryzacji urządzeniowej lasu. *Roczniki Geomatyki*, Tom II, Zeszyt 4, ss. 41-50.
- Zawiła-Niedźwiedzki T., 1994: Ocena stanu lasu w ekosystemach zagrożonych z wykorzystaniem zdjęć satelitar-nych i systemu informacji przestrzennej. *Prace Instytutu Geodezji i Kartografii*, Tom XLI, Zeszyt 90.

Summary

Contemporary VHR satellite images very often offer resolution between 1 and 4 meters and very good dynamic range (11 bit). The new RS technology enables to extract new kind of information (especially thematic information) which can be used in the forest inventory process.

*This paper presents how two classification methods, i.e.: the "traditional" – supervised and the "newest" – object-oriented and different algorithms were tested on the example of QuickBird-2 images (ground resolution 2,44 m MS; 0,62 PAN; 11 bit), for the stand mapping purpose. The Niepolomice Primeval Forest was selected for the study. The 10.000 hectares forest complex is located in southern Poland and represents a lowland forest in the Vistula valley. The dominant tree species in the Niepolomice Primeval Forest are: pine (*Pinus sylvestris* L.), oak (*Quercus* sp.) – 18% and black alder (*Alnus glutinosa* L.) – 9%. The paper describes options of the ER Mapper 6.4 (Earth Resource Mapping Inc.) in the supervised classification. Usefulness of the algorithms: Maximum Likelihood (Standard and Enhanced both with and without Neighbor filter), Mahalanobis, Parallelepiped, Minimum Distance and Minimum Distance (Standard deviation) – were tested.*

The Regions of Interest (ROI) were created using DGPS receivers. Forest stand mapping in the Niepolomice Primeval Forest based on the QuickBird image from September 15th 2003 required following ROI: Pine (So), Oak (Db), Alder (Ol), Larch (Md), Beech (Bk), Birch (Brz), shadow (cien), clearing (polana), built up areas (zabudowa) and agriculture (p_uprawne). The best result of supervised classification proved the Maximum Likelihood Standard algorithm with Neighbor filter (5x5 pixels and 6 passes).

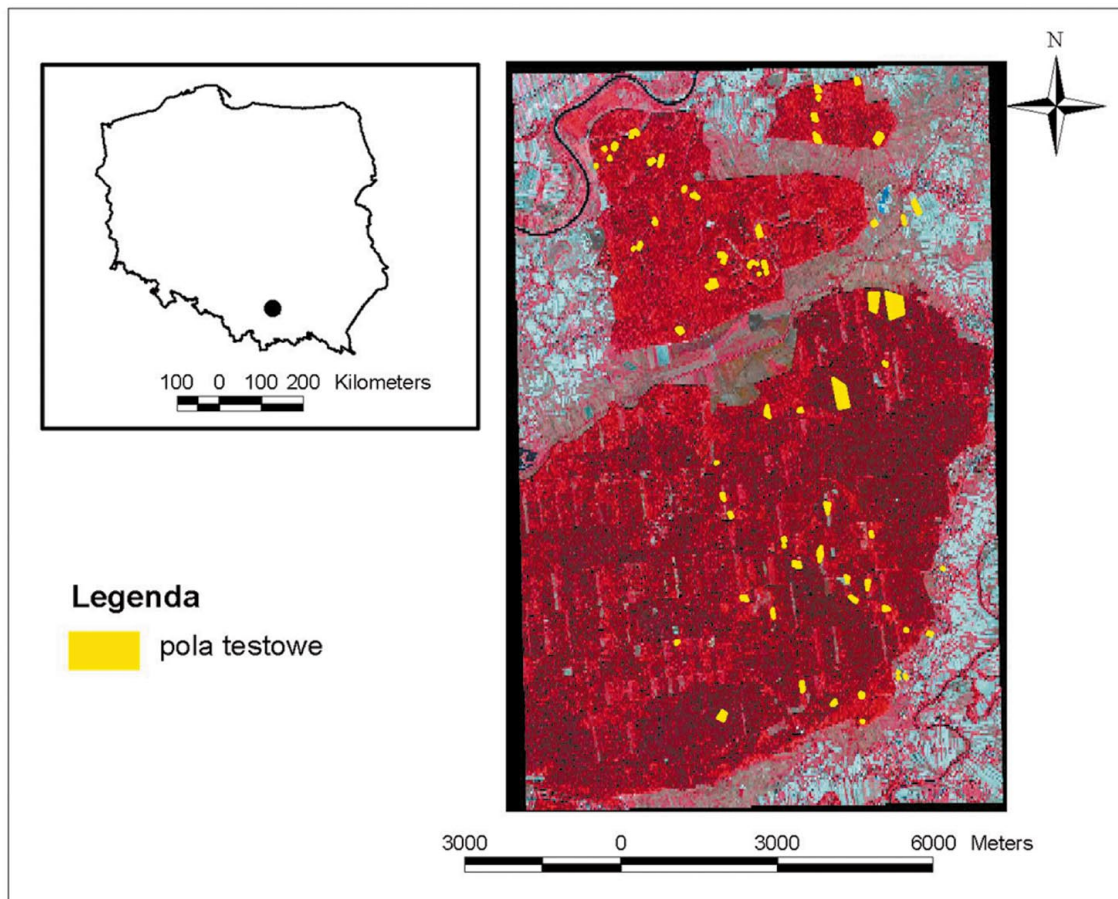
The classification accuracy of the Pine (So) was around 98% and of broad-leaves trees ca. 80%. However, the classification accuracy of species was good for pine (97%) and oak (73%). The result of the alder classification was only 63%. It was also proved that Parallelepiped algorithm was completely useless.

In this work, the authors also tested usefulness of the "newest" object-oriented (O.O.) classification in automatic mapping of the areas with- or without tree cover; inside and outside the forest. In this case ROI (samples) were not used, but only empirical expressions, which describe main features. This solution allows transferring of class hierarchy on other satellite images. These techniques can save time and money in the future. It is useful in verification of the Forest Digital Maps (LMN) during forest inventory works and it retrieves some important parameters like forest type, crown density, forest gaps, etc.

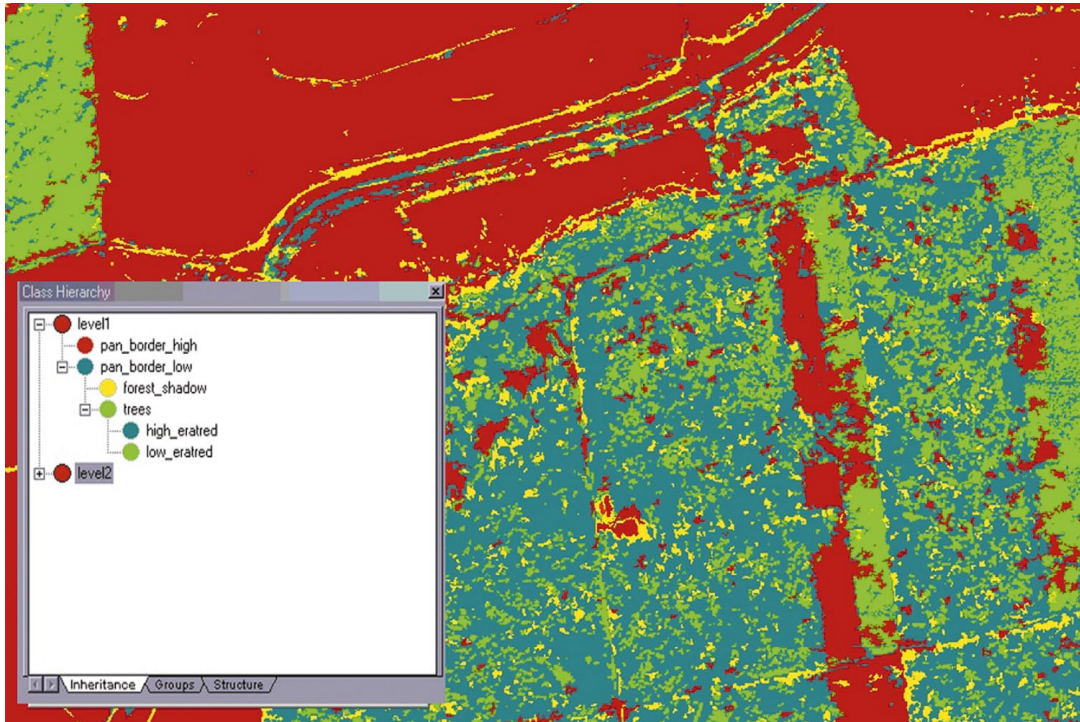
The research presented shows that modern RS techniques based on the VHR satellite images and image processing methods and algorithms are very useful for rapid semi- or fullautomatic forest mapping.

dr inż. Piotr Wężyk
rlwezyk@cyf-kr.edu.pl

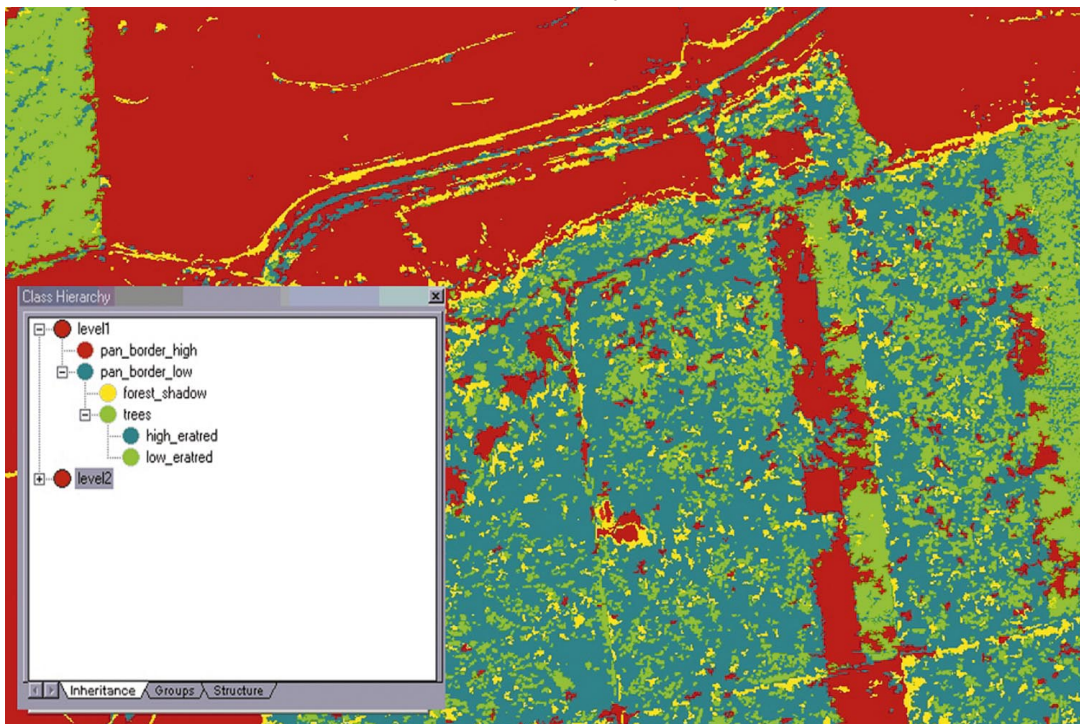
mgr inż. Paweł Bednarczyk
<http://argis.les.ar.krakow.pl>
tel./fax (0-12) 662 50 82



Rys. 1. Rozmieszczenie obszarów testowych na terenie badań w Puszczy Niepołomickiej (QuickBird-2; kompozycja kanałów 432_PAN; 15.09.2003)



Rys. 2. Wynik klasyfikacji obiektowej pierwszego etapu segmentacji: LEVEL 1 (kolor jasnozielony - drzewostany liściaste (Db, Ol cz), ciemnozielony – drzewostany iglaste (So), żółty – CIENÍ, czerwony – „NIE_LAS”) wraz hierarchią



Rys. 3. Wynik klasyfikacji obiektowej drugiego etapu segmentacji: LEVEL 2 (kolor seledynowy obszary „NIE_LAS” poza lasem, fioletowy – obszary „NIE_LAS” wewnątrz drzewostanów, zielono-niebieski – „LAS”) wraz hierarchią.