

**KARTOWANIE POKRYCIA TERENÓW
ZURBANIZOWANYCH PRZY ZASTOSOWANIU
KLASYFIKACJI OBIEKTOWEJ ZINTEGROWANYCH
GEODANYCH LOTNICZEGO SKANOWANIA
LASEROWEGO ORAZ ZOBRAZOWAŃ GEOEYE-1***

URBAN LAND COVER MAPPING WITH OBJECT-BASED
IMAGE CLASSIFICATION OF INTEGRATED AIRBORNE
LASER SCANNING DATA AND GEOEYE-1 IMAGES

Piotr Tompalski, Piotr Wężyk

Laboratorium GIS i Teledetekcji, Wydział Leśny, Uniwersytet Rolniczy w Krakowie

Słowa kluczowe: OBIA, ALS, VHRS, klasyfikacja obiektowa, roślinność miejska
Keywords: OBIA, ALS, VHRS, object-based classification, urban green

Wstęp

Nowoczesne technologie teledetekcyjne, w tym lotnicze skanowanie laserowe (ang. ALS – *Airborne Laser Scanning*) oraz wysokorozdzielcze zobrazenia satelitarne (ang. VHRS – *Very High Resolution Satellite images*), są coraz częściej wykorzystywane w praktyce, a ich wzajemna integracja w środowisku GIS otwiera całkowicie nową przestrzeń we wdrożeniach oraz badaniach naukowych nad zmianami zachodzącymi w środowisku.

Zobrazowania satelitarne wykorzystywane są szeroko do określania wybranych cech zbiorowisk roślinności na drodze klasyfikacji obrazu (Adamczyk, Będkowski, 2005; Ciołkosz, 2005; Lillesand i in., 2007), w tym również roślinności obszarów zurbanizowanych (Rashed, Jürgens, 2010). Coraz bardziej popularna technologia lotniczego skanowania laserowego pozwala również na wysoce zautomatyzowaną detekcję obiektów, w tym różnych typów roślinności (np. wysokiej i niskiej), a dodatkowo na ocenę jej charakterystyk, w tym struktury przestrzennej (Haala, Brenner 1999; Elberink, Maas, 2000; Meinel, Hecht, 2005; Shan, Toth, 2008; Wężyk, 2008). Technologia ALS, pomimo że niezmiernie bogata w informację geometryczną o strukturze 3D obiektów, w wymiarze radiometrycznym ogranicza się

* Badania zostały zrealizowane dzięki środkom finansowym w ramach Stypendium im. Anny Pasek, edycja 2009/2010 (www.annapasek.org).

zazwyczaj jedynie do wykorzystania wartości intensywności odbicia, co nie jest jeszcze powszechnie wykorzystywane. Dużym niedomaganiem w klasyfikacji obiektów w chmurze punktów jest właśnie brak informacji wielospektralnej jaką oferują cyfrowe zdjęcia lotnicze lub inne zobrazowania wielo- i hiperspektralne (Wężyk i in., 2003).

Wśród wielu tradycyjnych metod przetwarzania obrazów najbardziej powszechną jest tzw. klasyfikacja pikselowa. Polega ona na przypisaniu pikselom obrazu odpowiedniej, zdefiniowanej przez użytkownika, klasy pokrycia terenu (Pratt, 2001; Chen, 2007; Scott, 2007). Tradycyjnie stosowane algorytmy klasyfikacyjne opierają się na analizie sygnatur, tj. odpowiedzi spektralnej pikseli, których wartość zapisana jest w poszczególnych kanałach obrazu. Zastąpienie tradycyjnej klasyfikacji przez analizy zgrupowań pikseli (Baatz, Schape, 2000), pozwala na wprowadzenie do analiz nowych cech (właściwości) związanych z tymi obiektami. Wyodrębnienie w procesie segmentacji homogenicznych fragmentów obrazu (segmentów, obiektów), pozwala wykorzystać w procesie ich klasyfikacji nie tylko charakterystyki spektralne, lecz również cechy związane z ich: wielkością, kształtem czy sąsiedztwem (Blaschke, Strobl, 2001; Adamczyk, 2006; Navulur, 2007; Blaschke, 2010), czyniąc te analizy skuteczniejszymi w realizacji niż na przykład w przypadku wykorzystania operacji morfologicznych wspierających klasyfikację pikselową (Kupidura i in., 2010). Klasyfikacja obiektowa obrazu (ang. OBIA – *Object Based Image Analysis*) opiera się właśnie na podziale obrazu na obiekty (segmenty) odzwierciedlające ich cechy (tzw. *meaningful image objects*) i umożliwiające ocenę ich atrybutów: przestrzennych, spektralnych lub czasowych (Hay, Castilla, 2006).

Klasyfikacja obiektowa obrazów (zwana potocznie klasyfikacją zorientowaną obiektowo) może być z powodzeniem stosowana w badaniach związanych z detekcją różnych zbiorowisk roślinnych, jak i w klasyfikacji pokrycia terenu w miastach (Syed i in., 2005; Wężyk i in., 2007), przyczyniając się do podniesienia dokładności klasyfikacji nawet o około 30% (Chen, 2009).

Metody analizy obrazów bazujące na uprzednio utworzonych obiektach można podzielić na takie, w których klasyfikacja oparta jest na cechach reprezentatywnych dla danej klasy obiektów, tj. polach treningowych (tzw. *sample based methods*) lub na takie, które opierają się jedynie na wiedzy i doświadczeniu operatora (tzw. *knowledge based*). Te drugie są wprowadzenie trudniejsze do praktycznego wdrożenia, lecz pozwalają na uzyskanie większej uniwersalności i skracają czas przetwarzania dużych zbiorów danych poprzez uniezależnienie od wspomnianych pól treningowych. W procesie obiektowej analizy obrazu wyróżnia się kilka przeplatających się ze sobą etapów, wśród których pierwszym jest zawsze segmentacja. Utworzone obiekty (segmenty) mogą być poddawane klasyfikacji, być łączone z innymi, modyfikowany może być ich kształt lub mogą być poddawane dodatkowemu procesowi segmentacji (np. bardziej szczegółowemu lub przy zastosowaniu innego algorytmu segmentacji). Ten wieloetapowy proces tworzony jest przez użytkownika w taki sposób, aby był jak najbardziej uniwersalny i tym samym mógł być stosowany dla kolejnych podobnych zestawów danych.

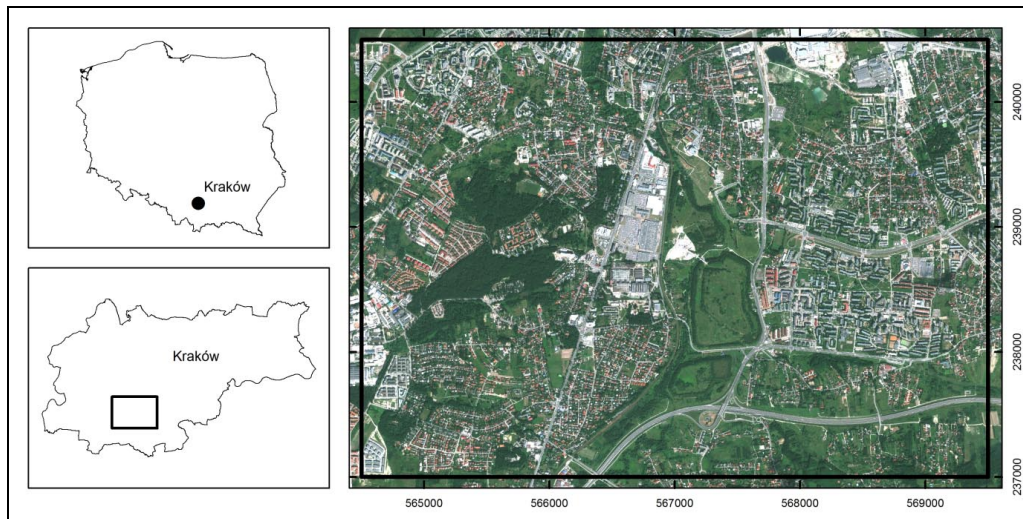
Głównym celem prezentowanych badań było opracowanie zautomatyzowanej metody kartowania klas pokrycia terenu występujących w przestrzeni miejskiej, na drodze integracji komplementarnych technologii, tj.: wysokorozdzielczych zobrazowań satelitarnych (GeoEye-1) oraz chmur punktów lotniczego skanowania laserowego (ALS). Cel cząstkowy polegał również na porównaniu dokładności klasyfikacji OBIA zbiorowisk roślinnych w oparciu o różne zestawy danych wejściowych, w stopniu możliwie maksymalnie zautomatyzowa-

nym, bez stosowania jakichkolwiek pól treningowych. Jednocześnie autorzy postawili sobie za cel przedstawienie statystyk przestrzennych opisujących zieleń miejską w wymiarze 3D i zaproponowali szersze wykorzystanie danych ALS.

Metodyka

Teren badań

Terenem testowym prezentowanych badań naukowych był fragment Krakowa, o powierzchni wynoszącej ok. 17,5 km² (3,5 x 5,0 km) zlokalizowany w południowej części miasta. Teren analizy wybrano tak, aby obejmował zarówno obszary bardzo zwartej zabudowy wysokiej (tzw. blokowiska), jak i niskiej (zabudowa willowa) oraz towarzyszące im obszary parków i innych typów zieleni miejskiej (rys. 1).



Rys. 1. Teren badań: z lewej – mapa przeglądowa Polski oraz granice miasta Krakowa wraz z wielobokiem obszaru opracowania, z prawej – kompozycja RGB GeoEye-1 (PUWG1992)

Wykorzystane dane przestrzenne

Dane źródłowe do opracowania metody integrującej technologie ALS i VHRS stanowiły: chmura punktów pochodząca z lotniczego skanowania laserowego z listopada 2006 roku (udostępniona dzięki uprzejmości Biura Planowania Przestrzennego Urzędu Miasta Krakowa) oraz wysokorozdzielcze i wielospektralne obrazy satelitarne GeoEye-1 (GeoEye).

Chmura punktów ALS została wykonana z poziomu śmigłowca przy zastosowaniu skanera FLI-MAP (Jędrychowski, 2007). Średnia gęstość punktów dla analizowanego obszaru była wysoka i wyniosła 22 punkty/m². Należy zaznaczyć, iż udostępniona chmura punktów ALS nie posiadała przypisanej informacji na temat numeru odbicia (*First/Last Echo*), ani też jego intensywności (ang. *intensity*).

Dane ALS zostały poddane przetwarzaniu wsadowemu w celu eliminacji punktów o błędnym położeniu (tzw. *low points* i *air points*), a także klasyfikacji gruntu. Na podstawie wygenerowanego numerycznego modelu terenu (Axelsson, 2000; algorytm zaimplementowany w oprogramowaniu Terrasolid) przeprowadzono normalizację chmury punktów. Proces ten miał na celu transformację współrzędnych wysokościowych bezwzględnych punktów (rzędna Z) na wartości względne, odniesione do poziomu terenu. Dzięki temu określenie wysokości obiektów (np. drzew czy budynków) oraz określanie statystyk przestrzennych było znacznie uproszczone. Tak przygotowane dane posłużyły do wygenerowania pochodnych warstw rastrowych wykorzystanych kolejno w procesie klasyfikacji OBIA (rys. 2):

- maksymalna wartość współrzędnej Z punktów w danej komórce rastra (nDSM);
- minimalna wartość współrzędnej Z punktów w danej komórce rastra (nMin);
- odchylenie standardowe współrzędnych Z punktów w danej komórce rastra (SD);
- warstwa reprezentująca brak danych (*NoData*).

Rozmiar piksela dla wszystkich warstw przyjęto na poziomie 1 m. Rasteryzacji chmury punktów dokonano w oprogramowaniu FUSION/LDV (McGaughey, 2007).

Zobrazowanie satelitarne GeoEye-1 zostało pozyskane w dniu 17.08.2010 r., w czterech kanałach spektralnych: RGB oraz NIR. Rozdzielczość terenowa kanału panchromatycznego wynosi 0,5 m, natomiast pozostałych kanałów wielospektralnych 2,0 m. Z powodu metodyki ortorektyfikacji obrazu GeoEye-1 na modelu NMT dochodziło do lokalnych przesunięć ortoobrazu (wysokie budynki, drzewa) w stosunku do danych ALS. W celu usunięcia tych niedoskonałości dokonano manualnej transformacji w oparciu o szczegóły terenowe (np. wysokie budynki) (rys. 3).

Ze względu na różnicę czasu jaki upłynął od pozyskania danych ALS do wykonania zobrazowania VHRS (około 3 lata) z analiz wyłączono obszary, na których nastąpiły zmiany w sposobie pokrycia i użytkowania terenu (nowe inwestycje budowlane).

Oprogramowanie

W celu przeprowadzenia zaawansowanego przetwarzania chmury punktów ALS wykorzystano moduł TerraScan programu Terrasolid (ver. 011) oraz wolne oprogramowanie FUSION (USDA Forest Service) i biblioteki Lastools. Do analiz z zakresu OBIA wykorzystano program eCognition Developer 8.64 (Trimble). Wyniki poszczególnych analiz zaprezentowano przy wykorzystaniu oprogramowania ArcGIS ESRI (9.3).

Klasyfikacja obiektowa

Metodyka analiz zakładała wyróżnianie typów, tzn. klas wysokościowych zieleni miejskiej, w tym roślinności: niskiej (do 1 m), średniej (1- 3 m) oraz wysokiej (>3 m), a także klas: „zabudowa” i „woda”. Podejście obiektowe pozwala wykorzystać w procesie klasyfikacji obrazu nie tylko wartość odbicia spektralnego obiektów, lecz również cechy geometryczne ich zgrupowań.

Analizy OBIA przeprowadzono w trzech wariantach, tj.:

- A – rozwiązanie bazujące wyłącznie na danych ALS,
- B – wykorzystujący tylko zobrazowanie satelitarne GeoEye-1,
- C – integrujący dane ALS oraz GeoEye-1.

Dla każdego z wariantów zastosowano odmienne reguły klasyfikacyjne dostosowane do specyfiki danych wejściowych. Wprowadzenie trzech wariantów klasyfikacji OBIA miało na

celu ocenę możliwości oraz porównanie dokładności klasyfikacji pokrycia terenu, przy wykorzystaniu wybranych danych przestrzennych lub ich integracji.

Proces przetwarzania danych OBIA przebiegał kilkietapowo i hierarchicznie. W kolejnych etapach skupiano się na określaniu zasięgu poszczególnych klas, wykorzystując w tym celu np. wartości współczynnika NDVI lub wartości wysokości względnej (znormalizowana chmura punktów). Analizy rozpoczynano od wyróżnienia tzw. klas ogólnych (nadrzędnych, zazwyczaj tymczasowych), z których w kolejnych etapach wyodrębniano klasy bardziej szczegółowe. Dzięki temu uzyskiwano większą przejrzystość tworzonych reguł klasyfikacyjnych i podniesienie dokładności metody poprzez możliwość szczegółowej reedycji każdego z jej etapów.

Wariant A

Utworzone na podstawie chmur punktów ALS pochodne warstwy rastrowe – reprezentujące: wysokość maksymalną, wysokość minimalną, odchylenie standardowe wysokości obiektów oraz obszary o braku danych (*NoData*) – zostały wykorzystane do sklasyfikowania tzw. zieleni średniej i wysokiej, zabudowy oraz wód.

Wyróżnienie poszczególnych klas pokrycia terenu oparto na ich cechach przestrzennych (wymiarze) reprezentowanych przez poszczególne pochodne warstwy rastrowe (rys. 4). Wyróżnienie klasy „woda” oparto np. na warstwie *NoData*, wykorzystując fakt pochłaniania impulsów lasera przez wody powierzchniowe. Klasę „zabudowa” oparto na wartościach wysokości minimalnej punktów (warstwa *nMin*). Minimalna wysokość punktów dla klasy „zabudowa” jest znacznie wyższa niż dla klasy „roślinność średnia” i „roślinność wysoka”, w przypadku której impulsy lasera często penetrują przez korony drzew lub krzewów do gruntu. Zmienność tej wartości związana jest przede wszystkim z terminem wykonania skanowania (drzewa w stanie bezliśnym) oraz z dużą gęstością punktów.

Klasy: „roślinność wysoka” i „roślinność średnia” wyróżniono na podstawie maksymalnej wysokości (*nDSM*) oraz wysokiej wartości odchylenia standardowego znormalizowanej wysokości punktów (*SD*), która jest znacznie większa niż w przypadku powierzchni planarnych dachów czy placów i dróg.

Ze względu na brak informacji na temat intensywności odbicia, nie było możliwe zweryfikowanie przydatności jej użycia w klasyfikacji roślinności niskiej (np. trawników). W efekcie klasa „roślinność niska” nie była możliwa do wyróżnienia, ze względu na brak jakiegokolwiek informacji spektralnej, a inne charakterystyki przestrzenne oparte na cechach geometrycznych okazały się niewystarczające.

Wariant B

Wykorzystanie do analizy jedynie obrazów satelitarnych GeoEye-1, przy założeniu braku stosowania jakichkolwiek pól treningowych przez operatora, było dużym wyzwaniem dla autorów. Brak informacji o wysokości klasyfikowanych obiektów powodował, że ich przypisanie do konkretnej klasy pokrycia terenu wymagało skomplikowanych procedur, bazujących w dużej mierze na kształcie i sąsiedztwie, tym bardziej, iż wielokrotnie obiekty należące do różnych klas charakteryzowały się bardzo podobną charakterystyką spektralną (np. sygnatury dróg i dachów niektórych budynków, wody i cienia).

Analizy OBIA rozpoczęto od wstępnego przypisania obiektów powstałych z segmentacji do klas „roślinność” lub „brak roślinności” na podstawie wartości wskaźnika NDVI (Carl-

son, Ripley, 1997). Następnie, wewnątrz klasy „roślinność” wydzielono „niską roślinność” oraz „średnią i wysoką roślinność” – jedynie na podstawie wartości w poszczególnych kanałach spektralnych (barwy) oraz tekstury obiektów. Szczegółowy podział roślinności na podstawie wysokości na klasy: „roślinność średnia” i „roślinność wysoka” nie był możliwy w tym wariancie. Z tymczasowej klasy „brak roślinności” wydzielono „wodę”, wykorzystując do tego celu wskaźnik NDVI (McFeeters, 1996), oraz kształt obiektów. Rozróżniano w ten sposób spektralnie podobne do klasy „woda” obiekty będące cieniem wysokich budynków lub drzew.

W przypadku tego wariantu najbardziej problematyczna okazała się detekcja budynków (klasa „zabudowa”). Ostatecznie klasę tę uzyskano w kilkietapowym procesie opartym na zastosowaniu algorytmów: wykrywania krawędzi, analizy barwy, kształtu obiektów lub ich sąsiedztwa z tymczasową klasą „cień” (przy zadanym kącie azymutalnym i odległości).

Wariant C

W wariancie tym klasyfikacja OBIA przeprowadzona była na zintegrowanych w jednej przestrzeni geograficznej: geodanych z lotniczego skanowania laserowego i zobrazowaniu satelitarnym GeoEye-1. Poszczególne klasy wyróżniane były hierarchicznie poprzez kombinację informacji geometrycznych zawartych w pochodnych warstwach rastrowych wygenerowanych na podstawie chmur punktów ALS oraz informacji spektralnej z poszczególnych kanałów spektralnych zobrazowania GeoEye-1.

Podobnie jak w przypadku wariantu B, analizy rozpoczęto od wstępnego przypisania obiektów do klas: „roślinność” oraz „brak roślinności”. Następnie z klasy „roślinność” wydzielono podklasy: „niska roślinność”, „średnia roślinność” i „wysoka roślinność” na podstawie informacji z warstwy *nDSM*. W podobny sposób poszczególne segmenty z tymczasowej klasy „brak roślinności” przypisano do klasy „zabudowa”, na podstawie charakterystyk geometrycznych (wysokie obiekty). Klasę „woda” wydzielano analogicznie jak w poprzednich wariantach na podstawie wskaźnika NDVI oraz warstwy *NoData*.

Należy zaznaczyć, że w procesie segmentacji, który poprzedzał opisaną wyżej klasyfikację, wykorzystywane były zarówno pochodne chmur punktów, jak i poszczególne kanały spektralne zobrazowania satelitarnego. Ponadto, w analizach wykorzystane zostały algorytmy pozwalające na łączenie obiektów spełniających zdefiniowane kryteria podobieństwa. W rezultacie, wynikowe segmenty charakteryzowały się homogenicznością pod względem wysokości względnej, jak i radiometrii (barwy), dzięki czemu odzwierciedlały one możliwie wiernie faktyczne zróżnicowanie przestrzenne (wysokościowe) i gatunkowe roślinności oraz różne typy zabudowy.

Statystyki przestrzenne roślinności wysokiej

Wygenerowane w ramach wariantu C obiekty przypisane do klas „roślinność średnia” lub „roślinność wysoka”, zostały zapisane jako warstwa wektorowa (SHAPE ESRI) i użyte do obliczenia wybranych statystyk przestrzennych chmury punktów ALS. W tym celu opracowany został skrypt w środowisku statystycznym R (R Development Core Team, 2009), który w sposób w pełni automatyczny przetwarzał podzbiory chmur punktów, których zasięg wyznaczały sklasyfikowane segmenty. Działanie skryptu polegało na obliczeniu wybranych statystyk przestrzennych dotyczących rozkładu pionowego punktów (rzędna *Z*), w tym: średniej, odchylenia standardowego, współczynnika zmienności, kurtozy, skośności,

mediany i innych. Były one obliczane w różnych wariantach progu wysokościowego definiowanego przez użytkownika (np. odchylenie standardowe wysokości punktów ALS powyżej 1 m nad gruntem). Ponadto, skrypt pozwalał na określenie objętości roślinności na podstawie tzw. voxeli (pikseli 3D), których rozmiar i warunek zawierania się w nim minimalnej liczby punktów ALS mogły być modyfikowane przez operatora. Wygenerowane statystyki mogą być podstawą dalszych analiz (modelowanie statystyczne) lub wizualizacji. Na ich podstawie generowane mogą być dalsze pochodne wskaźniki przestrzenne, np. wskaźnik V/A przedstawiający stosunek objętości roślinności do zajmowanej przez nią powierzchni (Mücke i in., 2010).

Ocena dokładności klasyfikacji OBIA

Dla potrzeb przeprowadzenia oceny poprawności klasyfikacji, wygenerowano 5000 punktów o losowym położeniu, pokrywających cały obszar analiz. Każdemu z punktów operator manualnie przypisał odpowiednią klasę pokrycia terenu opierając się na: aktualnych ortofotomapach lotniczych, serwisach mapowych (Geoportal, Google Maps, Bing Maps) wspieranych informacją wysokościową zaczerpniętą z chmur punktów ALS oraz dokumentacją fotograficzną sporządzoną w terenie (zdjęcia naziemne z pozycją GPS, tzw. geotagowane).

Wyniki

Klasyfikacja w wariancie A, oparta jedynie na analizach danych ALS, pozwoliła na wyróżnienie klas: „roślinność średnia”, „roślinność wysoka”, „zabudowa” oraz „woda” (tab. 1). Okazało się, że wyodrębnienie klasy „roślinność niska” jest w tym wariancie niemożliwe, ze względu na brak informacji radiometrycznej (brak informacji o intensywności sygnału odbitego). Na uwagę zasługuje stosunkowo niski błąd pominięcia (ang. *error of omission*, 1 – dokładność producenta) wszystkich klas oraz niski błąd przeszacowania (ang. *error of commission*, 1 – dokładność użytkownika) dla klas „roślinność wysoka” i „zabudowa”. Stosunkowo wysoką dokładność przeprowadzonej klasyfikacji w wariancie A potwierdza także wizualna ocena rezultatu (rys. 6).

Tabela 1. Wyniki klasyfikacji – wariant A

		Liczba punktów testowych dla klasy wg danych referencyjnych						Dokładność użytkownika
		roślinność średnia	roślinność wysoka	zabudowa	woda	inne	razem	
Wynik klasyfikacji OBIA	roślinność średnia	218	138	24	1	141	522	0,42
	roślinność wysoka	4	1052	17	1	22	1096	0,96
	zabudowa	3	27	731	0	15	776	0,94
	woda	1	6	2	30	3	42	0,71
	niesklasyfikowane	47	193	36	3	2285	2564	0,89
	razem	273	1416	810	35	2466	5000	
Dokładność producenta		0,80	0,74	0,90	0,86	0,93		

Klasyfikacja OBIA przeprowadzona wyłącznie w oparciu o dane GeoEye-1 (wariant B, tab. 2) charakteryzowała się trochę mniejszą dokładnością niż w przypadku wariantu A. W przeciwieństwie do niej, nie było możliwe wydzielenie różnych typów (klas) wysokościowych, tj.: „roślinności średniej” i „roślinności wysokiej”, co skutkowało ich połączeniem w jedną klasę „roślinność średnia i wysoka”. Sukcesem zakończyło się natomiast wyróżnienie klasy „roślinność niska”, która pod kątem spektralnym była wyraźnie zróżnicowana od pozostałej roślinności.

Obliczone współczynniki dokładności klasyfikacji, tj.: użytkownika i producenta, odzwierciedlają pewne problemy w sytuacji przeprowadzania w pełni automatycznej klasyfikacji OBIA, niewykorzystującej żadnych pól treningowych. Dla wariantu B, wartości współczynników dokładności klasyfikacji były tylko nieznacznie niższe w przypadku klas roślinności oraz znacząco niższe w przypadku klasy „woda” – błąd pominięcia wynosi ponad 0,80, co wynika z błędnego sklasyfikowania tej klasy jako klasy „cień”. Pozostałe klasy charakteryzują się wartościami błędów pominięcia i przeszacowania w zakresie 0,3-0,4, co nie do końca satysfakcjonuje autorów.

Tabela 2. Wyniki klasyfikacji – wariant B

		Liczba punktów testowych dla klasy wg danych referencyjnych						Dokładność użytkownika
		roślinność niska	roślinność średnia i wysoka	zabudowa	woda	inne	razem	
Wynik klasyfikacji OBIA	roślinność niska	1093	450	37	5	61	1646	0,66
	roślinność średnia i wysoka	350	1167	1	8	1	1527	0,76
	zabudowa	3	5	460	1	134	603	0,76
	woda	0	0	0	7	0	7	1,0
	niesklasyfikowane	84	67	312	15	739	1217	0,61
	razem	1530	1689	810	36	935	5000	
Dokładność producenta		0,71	0,69	0,57	0,19	0,79		

W wyniku przeprowadzonej klasyfikacji OBIA oraz analiz statystycznych, stwierdzono jednoznacznie, że w przypadku integracji różnych komplementarnych w stosunku do siebie technologii, tj.: ALS i VHRS, dokładność klasyfikacji znacznie się zwiększyła (rys. 5-8, tab. 1-4 zawierające macierze błędów wg Congaltona, 1991). Potwierdza ten fakt zarówno najwyższa wartość współczynnika Kappa (Cohen, 1960), współczynnika ogólnej dokładności klasyfikacji oraz współczynników: średniej dokładności użytkownika oraz średniej dokładności producenta, które dla wariantu C przyjmują najwyższe wartości (tab. 4).

W przypadku wariantu C (tab. 3), wartości błędów przeszacowania i pominięcia były zasadniczo niższe niż w poprzednich wariantach. Najwyższą wartością błędów pominięcia charakteryzowała się klasa „woda”. Wynikać to może z faktu, iż punktom referencyjnym przypisano klasę głównie na podstawie ortofotomapy lotniczej, charakteryzującej się większą dokładnością przestrzenną (większa szczegółowość, piksel 0,25 m) niż zobrazowanie GeoEye-1. W przypadku wąskich cieków wodnych, mogło zdarzyć się, iż wartość spektralna piksela z kanałów MS (rozdzielczość przestrzenna 2 × 2 m) zobrazowania GeoEye zdomino-

Tabela 3. Wyniki klasyfikacji – wariant C

		Liczba punktów testowych dla klasy wg danych referencyjnych						Dokładność użytkownika	
		roślinność niska	roślinność średnia	roślinność wysoka	zabudowa	wody	inne		razem
Wynik klasyfikacji OBIA	roślinność niska	1392	45	109	13	7	55	1621	0,86
	roślinność średnia	45	184	98	6	3	3	339	0,54
	roślinność wysoka	26	32	1170	16	2	1	1247	0,94
	zabudowa	2	1	8	702	0	3	716	0,98
	wody	0	0	0	0	15	0	15	1,00
	niesklasyfikowane	65	11	31	73	9	873	1062	0,82
	razem	1530	273	1416	810	36	935	5000	
Dokładność producenta		0,91	0,67	0,83	0,87	0,42	0,93		

wana była przez roślinność porastającą brzeg ciek i tym samym ciek nie został poprawnie zaklasyfikowany jako „woda”. Fakt, iż z 36 punktów testowych aż 12 zostało zaklasyfikowanych jako roślinność wydaje się potwierdzać tę tezę.

Dodatkowo, na podstawie wygenerowanych statystyk przestrzennych dla chmur punktów ALS, dla każdego z homogenicznych spektralnie i wysokościowo segmentów tworzących klasę „roślinność średnia” oraz „roślinność wysoka” dokonano wizualizacji czterech z nich (statystyk lub wskaźników, rys. 9).

Współczynnik V/A prezentujący stosunek objętości roślinności do zajmowanej przez nią powierzchni, przyjmuje wysokie wartości w przypadku dużej objętości zajmującej niewielką powierzchnię terenu (np. grupy bardzo wysokich drzew o długich i wąskich koronach), a niskie wartości w przypadku niewysokich, ale rozległych płatów roślinności w niewielkim stopniu wypełniających przestrzeń (np. zarośla krzewiaste) lub wysokich drzew o ażurowych lub wysoko osadzonych koronach.

Pozostałe przykłady statystyk informują o pionowym zróżnicowaniu rozkładu punktów z chmury ALS wewnątrz segmentów. Zróżnicowanie rozkładu obrazuje odchylenie standardowe oraz tzw. rozstęp ćwiartkowy. Obydwa ww. wskaźniki wygenerowane zostały z założeniem progu pominięcia punktów ALS poniżej 1 m wysokości względnej. Podział pionowy chmury punktów ALS na 3 równe części płaszczyznami prostopadłymi do osi Z, pozwala na określenie procentowej liczby punktów w każdej z tych warstw wysokości: L1 (0 - 1/3), L2 (1/3 - 2/3) i L3 (2/3 - 3/3) (Mücke i in., 2010) informując jednocześnie o pionowym ich rozkładzie (rys. 9).

Tabela 4. Ocena zbiorcza dokładności klasyfikacji OBIA w poszczególnych wariantach

	Wariant klasyfikacji OBIA		
	A	B	C
Ogólna dokładność klasyfikacji	0,863	0,693	0,867
Średnia dokładność producenta	0,846	0,592	0,771
Średnia dokładność użytkownika	0,785	0,760	0,857
Współczynnik Kappa	0,791	0,580	0,827

Dyskusja i wnioski

Na podstawie przedstawionych wyników można wnioskować, iż integracja technologii lotniczego skanowania laserowego oraz wysokorozdzielczych zobrażeń satelitarnych GeoEye-1 pozwala na wyeliminowanie niedoskonałości każdej z nich, tj. braku informacji spektralnej w przypadku chmur punktów ALS i braku charakterystyk przestrzennych 3D w przypadku zobrażeń optycznych VHRS. Tym samym możliwe jest osiągnięcie o wiele większej dokładności klasyfikacji na drodze w pełni automatycznej obiektowo zorientowanej analizy obrazu (OBIA).

Opracowane metody klasyfikacji OBIA, jako zbiór reguł klasyfikacyjnych (ang. *rule set*) w oprogramowaniu eCognition (Trimble), charakteryzują się wysoką uniwersalnością i nie wymagają stosowania pól treningowych. Przygotowanie takiego rozwiązania metodycznego jest niewątpliwie trudniejsze i bardziej czasochłonne niż tradycyjna klasyfikacja „pikselowa”, ale w konsekwencji pozwala na szybkie przetwarzanie dużej liczby zbiorów danych w trybie wsadowym bez udziału operatora. Reguły klasyfikacyjne są na tyle niezależne od danych wejściowych, że ich wykorzystanie w przypadku analiz innego zestawu danych wejściowych wymaga jedynie dostosowania kilku parametrów (np. wartości progowej współczynnika NDVI dla klasyfikacji roślinności, itp.).

Zbliżone wartości współczynników charakteryzujących dokładność klasyfikacji OBIA, tj.: dokładność producenta (ang. *accuracy*) oraz dokładność użytkownika (ang. *reliability*) dla klas: „roślinność wysoka”, „roślinność średnia” i „zabudowa” pozwalają stwierdzić, iż możliwe jest uniezależnienie poprawnej detekcji tych klas od informacji spektralnej zawartej w zobrażeniach satelitarnych (np. GeoEye-1). W przypadku klasyfikacji pokrycia terenu, w której nacisk położony jest jedynie na detekcję ww. klas, możliwe jest oparcie analiz OBIA jedynie na chmurach punktów ALS.

Z drugiej jednak strony, wizualna ocena rezultatów klasyfikacji dla ww. klas, wskazuje na niewielką przewagę klasyfikacji przeprowadzonej w wariancie C, integrującym dane geometryczne (ALS) i radiometryczne (VHRS), głównie z uwagi na fakt, iż segmentacja wykonywana jest nie tylko w oparciu o podobieństwo wysokości/odchylenia standardowego punktów lub jedynie w oparciu o wartość jaskrawości pikseli zobrażenia, lecz o obie te informacje jednocześnie. Z tego powodu można twierdzić, iż utworzone obiekty przedstawiają homogeniczny płat roślinności, zarówno pod względem składu gatunkowego, jak i wymiarów jego zasięgu.

Jedynie integracja zobrażenia satelitarnego z informacją zawartą w chmurach punktów ALS pozwoliła na pełną detekcję wszystkich klas pokrycia terenu będących przedmiotem opracowania, stanowiąc doskonały przykład wartości dodanej dwóch komplementarnych technologii. Dane ALS obszaru testowego, ze względu na brak jakiegokolwiek informacji spektralnej (nawet intensywności), nie pozwoliły na wyróżnienie klasy „roślinność niska”. Z drugiej strony, zobrażenie satelitarne GeoEye-1 nie pozwalało na sklasyfikowanie roślinności średniej, wyróżnianej jedynie na podstawie wysokości, a rozróżnianie klas na podstawie tekstury obrazu lub informacji o sąsiedztwie okazało się mniej dokładne niż w przypadku chmury punktów ALS.

Badania potwierdziły, iż integracja wielu źródeł informacji o różnej rozdzielczości przestrzennej i spektralnej stwarza nowe możliwości w podejściu obiektowym klasyfikacji pokrycia terenu. Wskazane byłoby stosowanie synchronizowanych czasowo zestawów geodanych, tj. pochodzących z nieodległych przedziałów czasowych. Z drugiej strony skanowanie poza okresem wegetacji (ang. *leave off*) daje znacząco bogatszą informację o struktu-

rze pionowej roślinności wysokiej i średniej. Optymalne wydaje się posiadanie zestawu danych ALS z okresu wegetacji oraz poza nią (np. naloty jesienno-wiosenne).

Wykorzystanie syntetycznych wskaźników przestrzennych pozwala opisywać przestrzeń wypełnioną roślinnością oraz jej strukturę pionową, co ma bardzo duże znaczenie w badaniach środowiskowych, szczególnie w aspekcie oceny dzielnic miasta pod kątem szeroko rozumianego wskaźnika zieleni jako elementu podnoszącego komfort życia. W artykule przedstawiono jedynie kilka przykładowych wskaźników, które są aktualnym przedmiotem badań autorów i będą wykorzystane w procesie automatycznego określania wybranych parametrów roślinności wysokiej w miastach oraz w naturalnych ekosystemach.

W Polsce wdrażany jest projekt ISOK (Informatyczny System Osłony Kraju), który stawia sobie za cel pokrycie niemal 200 000 km² kraju chmurami punktów ALS o bardzo dużej gęstości, wraz z informacją radiometryczną (niestety jedynie RGB ze zdjęć lotniczych). Informacje te będą umieszczone w państwowym zasobie geodezji i kartografii (PZGiK).

Autorzy pokładają duże nadzieje w tym, że dostęp do tych zasobów przyczyni się do rozwoju projektów i konkretnych wdrożeń – otworzy się całkowicie nowa przestrzeń badawcza w zakresie automatycznej detekcji klas pokrycia terenu, analizy ich struktury przestrzennej i generowania map ich zmian w różnych przedziałach czasowych.

Literatura

- Adamczyk J., 2006: Obiektowa analiza obrazów. *Roczniki Geomatyki* t. 4, z. 3: 11-22, PTIP Warszawa.
- Adamczyk J., Będkowski K., 2005: Metody cyfrowe w teledetekcji. Wydawnictwo SGGW, Warszawa.
- Axelsson P., 2000: DEM generation from laser scanner data using adaptive TIN models. *ISPRS Journal of Photogrammetry & Remote Sensing* 54, 138-147.
- Baatz M., Schape A., 2000: Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. XII Angewandte Geographische Informationsverarbeitung, Wichmann-Verlag, Heidelberg, 12-23.
- Blaschke T., 2010: Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65, 2-16.
- Blaschke T., Strobl J., 2001: What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. Was ist mit den Pixeln los? Neue Entwicklungen zur Integration von Fernerkundung und GIS 14, 12-17.
- Carlson T.N., Ripley D.A., 1997: On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment* 62, 241-252.
- Chen C.H., 2007: Image processing for remote sensing. CRC Press.
- Chen Y., 2009: Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas. *Advances in space research* 43, 1101-1110.
- Ciołkosz A., 2005: Teledetekcja satelitarna źródłem informacji o obiektach, zjawiskach i procesach zachodzących na Ziemi. *Nauka* 4, 51-70.
- Cohen J., 1960: A coefficient of agreement for nominal scales. *Educ. Psychol. Measurement* 20 (1), 37-46.
- Congalton, R.G., 1991: A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment* 37, 35-46.
- Elberink S.O., Maas H.G., 2000: The use of anisotropic height texture measures for the segmentation of airborne laser scanner data. *International Archives of Photogrammetry and Remote Sensing* 33, 678-684.
- Haala N., Brenner C., 1999: Extraction of buildings and trees in urban environments. *ISPRS Journal of Photogrammetry and Remote Sensing* 54, 130-137.
- Hay G., Castilla G., 2006: Object-based image analysis: strengths, weaknesses, opportunities and threats (SWOT). W: Lang S., Blaschke T., Schöpfer E. (Eds.), 1st International Conference on Object-based Image Analysis (OBIA 2006), Workshop proceedings, Salzburg.
- Jędrzychowski I., 2007: Lotnicze skanowanie laserowe Krakowa. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 17a.


- Kupidura P., Koza P., Marciniak J., 2010: *Morfologia matematyczna w teledetekcji*. Wydawnictwo Naukowe PWN SA, Warszawa.
- Lillesand T.M., Kiefer R.W., W. Chipman J., 2007: *Remote Sensing And Image Interpretation*, 5th ed. Wiley India Pvt Ltd.
- McFeeters S.K., 1996: The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing* 17, 1425-1432.
- McGaughey R.J., 2007: *FUSION/LDV: Software for LIDAR Data Analysis and Visualization*. Software Manual. USDA Forest Service. Pacific Northwest Research Station.
- Meinel G., Hecht R., 2005: Reconstruction of Urban Vegetation Based on Laser Scan Data at Leaf-Off Aerial Flight Times ISPRS International WG I/2 Workshop 2005: 3D Mapping from InSAR and LiDAR, Banff, Alberta, Canada, 7-10 June, 2005.
- Mücke W., Hollaus M., Prinz M., 2010: Derivation of 3D landscape metrics from airborne laser scanning data, Silvilaser 2010, Freiburg, Germany.
- Navulur K., 2007: *Multispectral Image Analysis Using the Object-Oriented Paradigm*. CRC Press.
- Pratt W.K., 2001: *Digital Image Processing 3ed*. John Wiley & Sons, Inc.
- R Development Core Team, 2009: *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, <http://www.R-project.org>
- Rashed T., Jürgens C., 2010: *Remote Sensing of Urban and Suburban Areas*. Springer.
- Scott J.R., 2007: *Remote Sensing: The Image Chain Approach*. Oxford University Press.
- Shan J., Toth C.K., 2008: *Topographic Laser Ranging and Scanning: Principles and Processing*. CRC Press Taylor & Francis Group.
- Syed S., Dare P., Jones S., 2005: Automatic Classification of Land Cover Features with High Resolution Imagery and LiDAR Data: An Object-Oriented Approach. http://www.ecognition.com/sites/default/files/266_0185.pdf.
- Wężyk P., 2008: Modelowanie chmury punktów ze skaningu laserowego w obszarze koron drzew. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 18a, 685-695.
- Wężyk P., Kok R., Szombara S., 2007: Zastosowanie obiektowo zorientowanej analizy obrazu (OBIA) wysokorozdzielczych obrazów satelitarnych w klasyfikacji obszaru miasta Krakowa. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 17b, 791-800.
- Wężyk P., Wertz B., Waloszek A., 2003: Skaner hiperspektralny AISA (Airborne Imaging Spectrometer for Applications) jako narzędzie pozyskiwania informacji o ekosystemie leśnym. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 13b, 485-496.

Abstract

The paper presents first results of advanced research concerning the use of integrated airborne laser scanning data and high resolution satellite images for the purpose of urban land cover mapping, particularly vegetation. Object-based image analysis was used for data processing, without any training areas and with three different approaches: A – only ALS data; B – based on GeoEye-1 satellite image only; C – based on both integrated datasets. Using integrated point clouds with spectral information stored in GeoEye-1 bands resulted in the best classification outcome ($Kappa = 0.83$), allowing detection of all classes that were the subject of analysis. Vertical structure assessment possibilities with the use of point cloud data were also shown in the paper.

mgr inż. Piotr Tompałski
piotr.tompalski@ur.krakow.pl
+48 12 6625076


dr inż. Piotr Wężyk
rlwezyk@cyf-kr.edu.pl
+48 12 6625082




Rys. 2. Pochodne warstwy rastrowe wygenerowane na podstawie chmur punktów ALS dla fragmentu terenu badań: od lewej – nDSM, nMin, SD (objaśnienia w tekście)



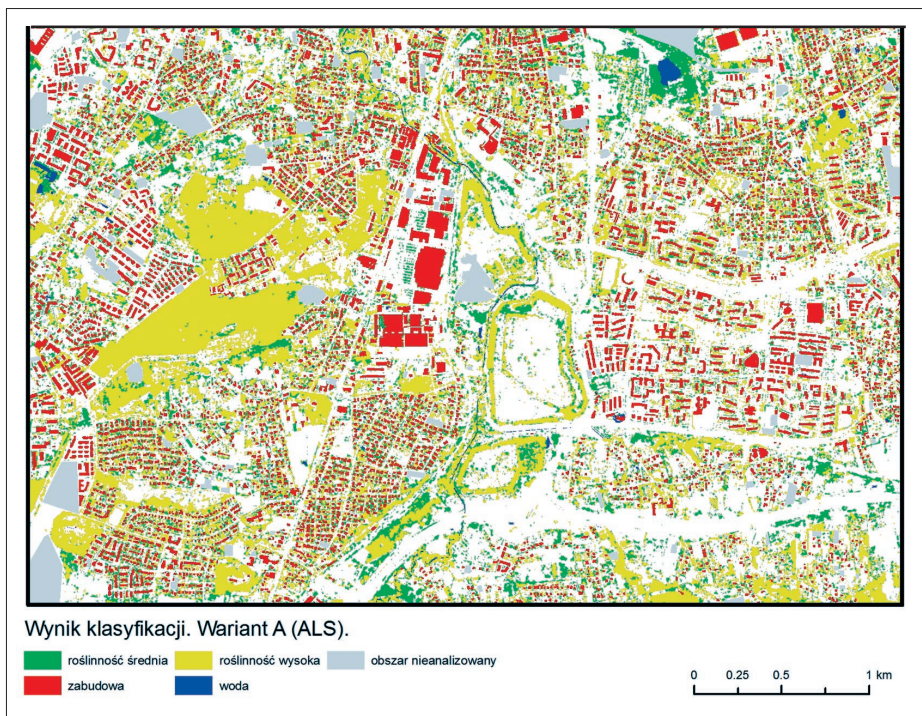
Rys. 3. Fragment zobrazowania GeoEye-1: od lewej – kanał panchromatyczny (PAN), kompozycja RGB (321), kompozycja CIR (432)



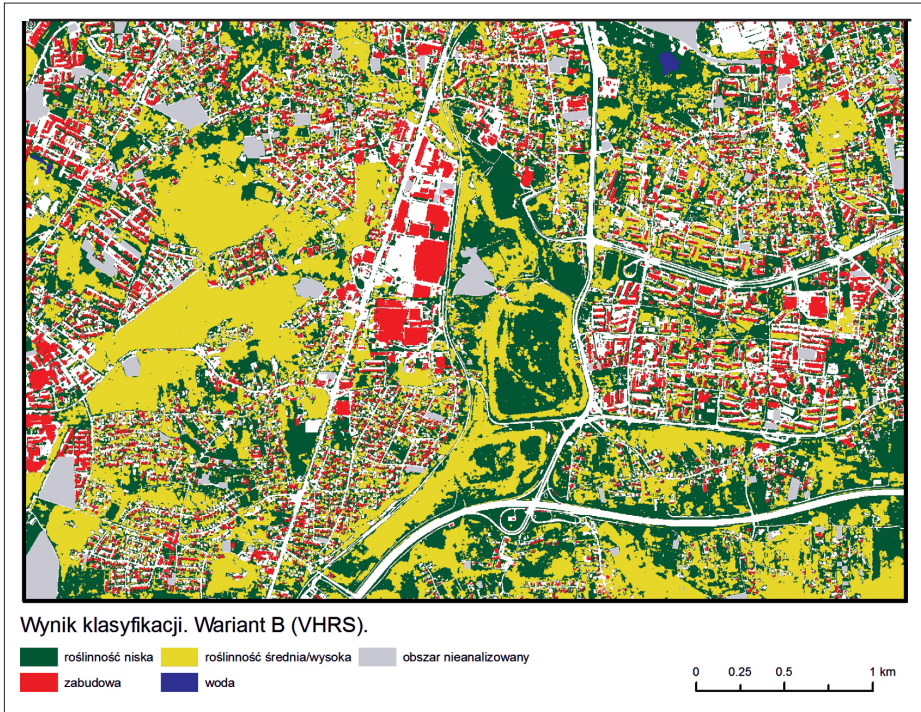
Rys. 4. Profil poprzeczny przez fragment znormalizowanej chmury punktów ALS; linią przerywaną przedstawiono wartość minimalnej znormalizowanej wysokości punktów – wyraźnie wyższe wartości nMin obserwowane są dla powierzchni dachów



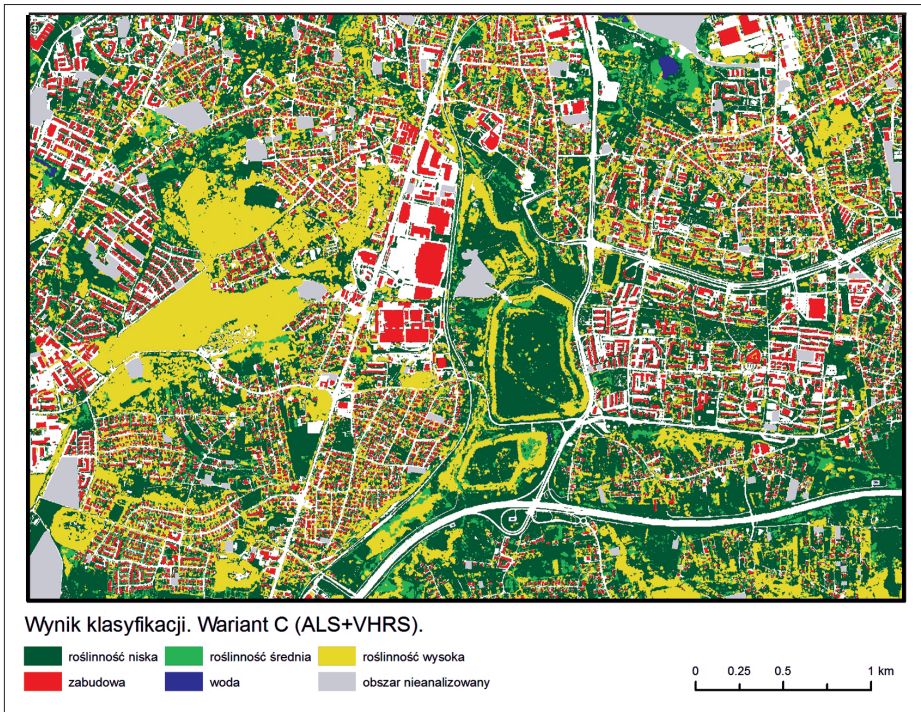
Rys. 5. Wyniki analiz klasyfikacji OBIA dla fragmentu obszaru badań: od lewej warianty: A (ALS), B (VHRS) i C (ALS + VHRS)



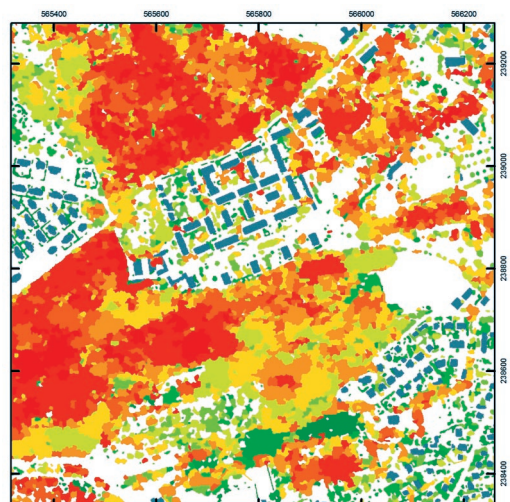
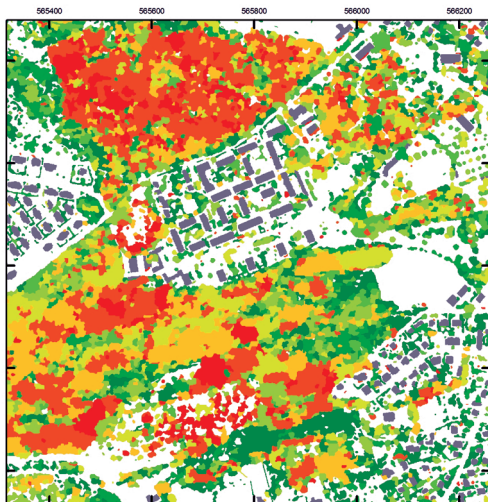


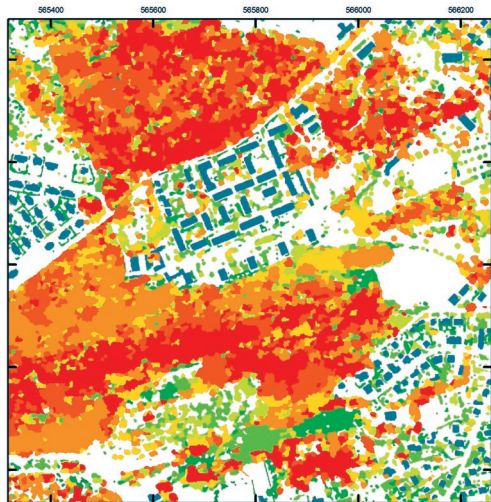
Rys. 6. Mapa pokrycia terenu przy zastosowaniu wariantu A (ALS)



Rys. 7. Mapa pokrycia terenu przy zastosowaniu wariantu B (VHRS)



Rys. 8. Mapa pokrycia terenu w wariacie C (opartym o dane ALS i zobrazowanie satelitarne)



Rys. 9. Wybrane wskaźniki i statystyki przestrzenne wygenerowane na podstawie chmur punktów ALS dla segmentów „roślinności średniej” i „roślinności wysokiej”