

**WZMOCNIENIE PROCESU KLASYFIKACJI OBIEKTOWEJ  
WIELOSPEKTRALNYCH ORTOFOTOMAP LOTNICZYCH DANYMI  
Z LOTNICZEGO SKANOWANIA LASEROWEGO**

**ENHANCING THE OBIA CLASSIFICATION OF MULTISPECTRAL AERIAL  
ORTHOIMAGES USING AIRBORNE LASER SCANNING DATA**

**Piotr Wężyk<sup>1</sup>, Jakub Mlost<sup>2</sup>, Marcin Pierzchalski<sup>2</sup>,  
Anna Wójtowicz-Nowakowska<sup>2,3</sup>, Piotr Szwed<sup>2</sup>**

<sup>1</sup> Laboratorium GIS i Teledetekcji, KEKL, Wydział Leśny, UR w Krakowie

<sup>2</sup> ProGea Consulting, ul. Pachońskiego 9, 31-223 Kraków

<sup>3</sup> Zakład Systemów Informacji Geograficznej, Kartografii i Teledetekcji, IGiGP UJ

**SŁOWA KLUCZOWE:** klasyfikacja obiektowa, ortofotomapy cyfrowe, lotniczy skaning laserowy, projekt ISOK

**STRESZCZENIE:** Klasyfikacja obiektowa (OBIA, ang. *Object Based Image Analysis*) jest nowatorską metodą analizy obrazów teledetekcyjnych, w której homogeniczne obiekty (segmenty), na które podzielony został obraz (za pomocą specyficznych algorytmów) poddawane są klasyfikacji. Dotychczasowe projekty wykazały, iż OBIA przeprowadzana na wysokorozdzielczych i wielospektralnych lotniczych ortofotomapach cyfrowych, wspierana modelami wysokościowymi, prowadzi do uzyskania bardzo dokładnych wyników. Stosunkowo niewiele prac koncentruje się na określeniu wpływu produktów pochodnych chmury punktów lotniczego skanowania laserowego (ang. *Airborne Laser Scanning*), takich jak wartość: odchylenia standardowego wysokości, gęstości punktów czy intensywności odbicia, na poprawę wyników klasyfikacji OBIA. W prezentowanej pracy poddano ocenie wzmocnienie procesu klasyfikacji OBIA danymi ALS na podstawie dwóch transektów badawczych („A” oraz „B”) o powierzchni 3 km<sup>2</sup>, położonych w okolicach Włocławka. Celem końcowym procesu analizy OBIA było uzyskanie aktualnej mapy klas pokrycia terenu. W opracowaniu wykorzystano lotnicze ortofotomapy cyfrowe oraz dane z lotniczego skaningu laserowego, pozyskane na przełomie sierpnia i września 2010 roku. Na podstawie punktów danych ALS wygenerowano warstwy pochodne takie jak: liczba odbić, intensywność, odchylenie standardowe, jak również wygenerowano znormalizowany Numeryczny Modelu Powierzchni Terenu (zNMPT). W wariantcie pierwszym „I” wykorzystano dane uzyskane wyłącznie w nalicie fotogrametrycznym, tj. wielospektralne ortofotomapy lotnicze (kamera Vexcel) oraz indeksy roślinności (w tym NDVI i in.). Wariant drugi prac „II” zakładał wykorzystanie dodatkowo danych z lotniczego skaningu laserowego. Określona dokładność klasyfikacji OBIA wykonanej w oparciu o cyfrową ortofotomapę lotniczą wyniosła 91.6% dla transektu badawczego „A” oraz 93.1% dla transektu „B”. Użycie danych ALS spowodowało podniesienie dokładności ogólnej do poziomu 95.0% („A”) oraz 96.9% („B”). Praca wykazała, iż zastosowanie danych ALS podnosi dokładność klasyfikacji segmentów o bardzo zbliżonych właściwościach spektralnych (np. rozróżnienie powierzchni dużych, płaskich dachów budynków od parkingów czy klas roślinności niskiej od średniej i wysokiej). Wprowadzenie warstw pochodnych ALS do procesu segmentacji poprawia także kształt powstających obiektów a tym samym klas końcowych. Analiza „surowych” danych ALS w postaci plików w formacie LAS otwiera

dotatkowe możliwości, których nie daje wykorzystywanie rastrowych warstw takich jak zNMPT. Pojawiająca się w nowej wersji oprogramowania eCognition (TRIMBLE) możliwość operowania segmentami przestrzennymi jeszcze te możliwości klasyfikacji podnosi. Niewątpliwie sporym problemem w integracji informacji spektralnej (ortoobraz) oraz geometrycznej (ALS) jest efekt rzutu środkowego skutkujący przesunięciami radialnymi dla wysokich obiektów leżących w znacznej odległości od punktu głównego zdjęcia.

## 1. WSTĘP

Klasyfikacja metodą obiektową (OBIA, ang. *Object Based Image Analysis*) to nowoczesne podejście do analizy danych teledetekcyjnych, które bazuje nie tylko na jaskrawości pikseli (jak w przypadku tradycyjnej klasyfikacji pikselowej), ale także na cechach geometrycznych ich spójnych grup (obiektów, segmentów). Wysoką skuteczność analizy obiektowej zapewnia wykorzystanie nie tylko właściwości fizycznych obiektów (własności spektralne), ale także ich tekstury, kształtu, wielkości oraz wzajemnych relacji takich jak sąsiedztwo, hierarchia i in. (Wężyk *et al.*, 2006 i 2007; deKok *et al.*, 2005; Wężyk *et al.*, 2004). Klasyfikacja OBIA umożliwia wykorzystanie danych obrazowych z zakresu optycznego (np. lotnicze ortofotomapy cyfrowe), wektorowych i rastrowych z systemów GIS, jak również geodanych pochodzących z lotniczego skanowania laserowego (ALS – ang. *Airborne Laser Scanning*) szerzej znanego pod akronimem LiDAR (ang. *Light Detection And Ranging*). Zalicza się ją do aktywnych technologii teledetekcyjnych i w zależności od lokalizacji emitera i detektora fal świetlnych, można poza ALS wyodrębnić także satelitarne (SLS, ang. *Satellite Laser Scanning*) oraz naziemny (TLS, ang. *Terrestrial Laser Scanning*) skanowanie laserowe (Wężyk, 2006). Ten ostatni w sytuacji umieszczenia skanera na platformie ruchomej (np. samochód) i integracji z urządzeniami: GPS i INS oraz kamerami cyfrowymi (ang. *Inertial Navigation System*) tworzy moduł mobilny (MMS; ang. *Mobile Mapping System*). Podstawowym produktem lotniczego skanowania laserowego są tzw. chmury punktów (ang. *point cloud*) o określonych współrzędnych (XYZ), będących miejscami odbić promienia lasera od obiektów. Rejestrowane mogą być: kolejne echa sygnału jak i intensywność (ang. *intensity*) sygnału. Chmury ALS zapisywane są w kolejnych realizowanych podczas nalotu szeregach o pokryciu poprzecznym do 25÷30% charakteryzujących się gęstością od jednego do kilkunastu odbić w zależności od charakteru projektu (Będkowski, Wężyk, 2010).

Dotychczas opublikowane prace wskazują, iż klasyfikacja metodą obiektową przeprowadzana na cyfrowych, wysokorozdzielczych i wielospektralnych (R, G, B, NIR) ortofotomapach lotniczych, wspierana modelami wysokościowymi, prowadzi do uzyskania znacznie dokładniejszych wyników (Li *et al.*, 2008; Rottensteiner *et al.*, 2005) szczególnie w przypadku klas pokrycia terenu, trudno od siebie rozróżnialnych bez udziału operatora. Natomiast stosunkowo niewiele prac dotyczy jeszcze wpływu wsparcia OBIA produktami pochodnymi ze skanowania laserowego, za jakie można uznać zarówno obrazy rastrowe (np. numeryczne modele wysokościowe: NMT, NMPT oraz zNMPT; odchylenie standardowe wysokości względnej poszczególnych odbić plamki lasera, gęstość skanowania czy intensywność odbicia), jak i w postaci statystyk „surowej” chmury punktów, na poprawę wyników klasyfikacji. Nowe wersje oprogramowania eCognition (TRIMBLE Geospatial) umożliwiają zarówno wczytywanie rastrowych produktów ALS jak i danych surowych (chmur zapisanych w formacie binarnym LAS).

Celem prezentowanej pracy było wykazanie możliwości wzmocnienia automatycznego procesu klasyfikacji OBIA obrazów fotolotniczych (wysokorozdzielczych i wielospektralnych ortofotomap cyfrowych) danymi z lotniczego skanowania laserowego (ALS) pod kątem tworzenia aktualnych map pokrycia terenu.

## 2. TEREN BADAŃ

Badania zrealizowano na dwóch obszarach testowych (tzw. transektach badawczych) o powierzchni około 3.0 km<sup>2</sup> każdy, usytuowanych na terenie miasta Włocławek (Rys. 1). Przy ich wyborze kierowano się przede wszystkim kryterium występowania stosunkowo wysokiej różnorodności klas użytkowania i pokrycia terenu.

Obszary testowe cechowały się odmienną charakterystyką występowania klas użytkowania (pokrycia) terenu. Transekt badawczy „A” ulokowano na obszarze o przeważającym udziale klas związanych z zabudową miejską i infrastrukturą towarzyszącą miastu. Transekt „B” natomiast zdominowany był przez elementy krajobrazu podmiejskiego, tj. klasy świadczące o użytkowaniu rolniczym czy też tereny leśne i zabudowę luźną.




Rys. 1. Lokalizacja transektów badawczych we Włocławku („A” – obszary z zabudową i infrastrukturą miejską; „B” – obszary rolnicze, leśne i zabudowy rozproszonej)

## 3. METODYKA PRAC

Testowe dane fotolotnicze (zarówno ortofotografie cyfrowe jak i ALS) wykorzystane w prezentowanej pracy uzyskano dzięki uprzejmości firmy COMPASS PGI realizującej na tym terenie projekt środowiskowy. Lotnicze ortofotografie cyfrowe (GSD 0.2 m; PUWG 1992) wygenerowano w oparciu o zdjęcia z cyfrowej kamery lotniczej VEXCEL (UltraCam XP) rejestrującej obrazy w zakresach RGB oraz NIR (GSD 0.2 m; rozdzielczość spektralna 8 bit) oraz NMT (Numeryczny Model Terenu) pochodzący z lotniczego skanowania laserowego. Naloty nad terenem badań realizowano na przełomie sierpnia/września 2010 r.

Chmurę pktów ALS pozyskano przy wykorzystaniu nowoczesnego skanera typu tzw. fali ciągłej (ang. *full waveform*) firmy RIEGL Q680i. Gęstość chmury punktów wynosiła 6 pkt/m<sup>2</sup> a liczbę odbić ograniczono do dwóch ech sygnału (ang. *first/last echo*). Łączenie, wyrównanie i nadanie bezwzględnej georeferencji przeprowadzono w odpowiednich modułach oprogramowania Terrasolid. Dane ALS posłużyły przede wszystkim w pierwszej kolejności do wygenerowania referencyjnego Numerycznego Modelu Terenu (NMT; ang. DTM – *Digital Terrain Model*), a w następnym kroku do uzyskania Numerycznego Modelu Pokrycia Terenu (NMPT; DSM – ang. *Digital Surface Model*). Na podstawie tych dwóch modeli warstw wygenerowano znormalizowany Numeryczny Model Pokrycia Terenu (zNMPT; ang. zNMPT – *normalised Digital Surface Model*). Referencyjny NMT, uzyska-

ny na drodze aktywnego trójkątowania TIN (Axelsson 2000; Terrascan, Terrasolid) posłużył też do normalizacji chmury punktów ALS, co doprowadziło do zmiany rzędnej wysokościowej z wartości bezwzględnych (Kronsztad, 1986) na wysokości względne obiektów. Dane ALS zapisano do binarnego formatu LAS (ver. 1.2. ASPRS), co umożliwiło ich bezpośrednie wczytywanie do oprogramowania eCognition Developer ver. 8 (TRIMBLE Geospatial) nadając rozdzielczość przestrzenną równą 1.0 m generowanym z niej warstwom rastrowym. Chmura punktów została przez program eCognition tymczasowo zrasteryzowana do zadanego rozmiaru przestrzennego (1.0 m), po czym pozyskano z niej takie informacje, jak np.: liczba poszczególnych odbić, ich intensywność, wartość odchylenia standardowego. Należy jednak podkreślić, iż ta rasteryzacja jest wyłącznie tymczasowa, na potrzeby wyświetlania danych; program korzysta jednak cały czas z surowej chmury punktów \*.LAS.




Rys. 2. Fragment geodanych wykorzystanych w klasyfikacji OBIA: (od lewej u góry) ortofotomapa lotnicza RGB (GSD 0.2 m), zNMPT, chmura punktów (wysokość pierwszego odbicia), liczba kolejnych odbić promienia lasera

Na podstawie wielospektralnych cyfrowych ortofotomap lotniczych wygenerowano warstwy pochodne, takie jak: raster będący wynikiem działania filtru krawędziowego Laplace (okazał się bardzo istotny w przypadku rozróżniania klas zabudowy od zbliżonych spektralnie klas gleby pozbawionej warstwy roślinności oraz do „wyostrzenia” granic między segmentami poszczególnych klas), czy znormalizowany wskaźnik wegetacji NDVI

(ang. *Normalized Difference Vegetation Index*) wykorzystując do tego celu oprogramowanie ERDAS IMAGINE 2010. Przed rozpoczęciem właściwej klasyfikacji w programie eCognition Developer ver. 8.0 (Trimble Geospatial) wygenerowano dodatkowo wiele wskaźników oraz warstw pomocniczych, takich jak m.in.: *Ratio Green*, *Ratio NIR*, „zabud”, *Vegetation Index Green*, *Chlorophyl Index Red* (Auynirundronkool *et al.*; Lewiński, 2006).

Dane referencyjne (pola testowe) służące ocenie jakości klasyfikacji OBIA, dla klasy zabudowa (budynki, dachy) wygenerowano automatycznie przy wykorzystaniu modułu TerraScan (Terrasolid; Rys. 3). Funkcja automatycznej detekcji budynków wykryła obiekty o odpowiedniej wysokości i planarnych powierzchniach. W założeniu metodycznym odróżnienie dachów obiektów od roślinności wysokiej odbywa się nie po wartości wysokości (mogą być zbliżone do wysokości około 30 m) ale na podstawie różnej liczby odbić promienia lasera (liczba ech) i odchylenia standardowego (promień lasera może penetrować koronę drzewa na znaczną głębokość w zależności od gatunku drzewa i jego kondycji). Pozostałe referencyjne powierzchnie testowe dla klas pokrycia terenu pozyskano za pomocą manualnej wektoryzacji ekranowej ortofotomap lotniczych.



Rys. 3. Przykład automatycznej detekcji budynków w oprogramowaniu TerraScan (Terrasolid); z lewej profil przez sklasyfikowaną chmurę punktów ALS; z prawej: wektor obrysu brył budynków na tle ortofotomapy lotniczej


Proces analizy OBIA składa się z dwóch zasadniczych etapów, tj.: segmentacji oraz właściwej klasyfikacji segmentów przy wykorzystaniu specjalnych reguł decyzyjnych. Dla każdego transektu badawczego przeprowadzono dwa warianty klasyfikacji OBIA.

Pierwszy z nich (wariant I) zakładał wykorzystanie wyłącznie danych z nalotu fotogrametrycznego, czyli cyfrowych ortofotomap wielospektralnych oraz wygenerowane w oparciu o nie warstwy pochodne takie jak: NDVI, SAVI (*Soil-Adjusted Vegetation Index*, filtr Laplace). Drugi (wariant II) poza danymi z wariantu I, zakładał wykorzystanie dodatkowo danych pochodzących z lotniczego skaningu laserowego (ALS).

Segmentacja danych została przeprowadzona przy wykorzystaniu algorytmu tzw. *multiresolution segmentation*. Jego działanie polega na podziale całego obrazu na wewnętrznie spójne, ale zarazem różniące się pomiędzy sobą segmenty (Trimble eCognition, 2010), na podstawie dwóch kryteriów, tj.: koloru i kształtu tworzonych obiektów. W projekcie przyjęto następujące wartości parametrów segmentacji obrazu: skala (ang. *scale*) = 10, kształt (ang. *shape*) = 0.5 oraz kompaktowość (ang. *compactness*) = 0.5. Pierwszą segmentację (wariant I) przeprowadzono wyłącznie na 4 kanałach spektralnych ortofotomapy lotniczej (GSD 0.2 m), a drugą (wariant II) dodatkowo na danych wysokościowych z zNMPT. Stworzone wcześniej wskaźniki, takie jak np. *NDVI*, *Ratio NIR*, były wykorzystywane w procesie klasyfikacji już po stworzeniu segmentów. W obydwu przypadkach liczba wygenerowanych segmentów była ze sobą porównywalna. W przypadku transektu

badawczego „A” z zabudową miejską uzyskano prawie 1 000 000 obiektów, a dla transektu „B” z terenami leśnymi i rolniczymi ponad 300 000 segmentów. Zaistniała więc pilna potrzeba ograniczenia liczby generowanych segmentów, ze względu na późniejsze możliwości użycia oprogramowania GIS.

Kolejnym krokiem analizy OBIA, było przeprowadzenie drugiej segmentacji, tzw. *spectral difference segmentation*, której celem było połączenie obiektów (segmentów) o stosunkowo niewielkiej różnicy spektralnej (Trimble eCognition, 2010). Za najbardziej optymalny przyjęto parametr o wartości = 10. W wyniku tego kroku liczba segmentów została ograniczona do około 400 000 szt. (transekt „A”) oraz 130 000 (transekt „B”). Porównanie wyników segmentacji opartej wyłącznie na danych z ortofotomapy oraz wspomaganej modelem zNMPT zobrazowano poniżej (Rys. 4).



Rys. 4. Porównanie dwóch rodzajów segmentacji; od lewej: ortofotografia przed segmentacją; segmentacja oparta wyłącznie na ortofotomapie (wariant I); segmentacja oparta na ortofotomapie oraz zNMPT (wariant II)

Po operacji segmentacji transektów „A” oraz „B” przystąpiono do ich właściwej klasyfikacji. Rozpoczęto ją od operacji przeprowadzanych na wartościach spektralnych segmentów (obiektów), wykorzystując w tym celu wygenerowane wcześniej obrazy rastrowe współczynników (np. *Ratio blue*, *zabud*, *NDVI*, filtr krawędziowy Laplace). Tworząc tzw. *rule set* operowano zarówno wartościami średnimi dla segmentów, jak i wartościami odchylenia standardowego.

Kolejnym etapem było zastosowanie reguł wykorzystujących położenie i kształt segmentów, czyli opcje stanowiące w rzeczywistości o unikatowości klasyfikacji OBIA. Wykorzystywano na tym etapie m.in. takie cechy obiektów jak: powierzchnia segmentu, współczynnik długości boku do szerokości segmentu, długość granicy segmentu, kompaktowość (zwartość) czy tzw. wskaźnik kształtu. Posłużyły one przede wszystkim do wyeliminowania drobnych, niewielkich obiektów generowanych wewnątrz większych. Do nich zaliczyć można było błędnie przypisaną klasę gruntów ornych wewnątrz kompleksów leśnych (np. obszary zrębów z odkrytą glebą) czy też zakwalifikowanie obiektów o długich i wąskich kształtach błędnie przypisanych jako place i parkingi, a znajdujące się wewnątrz klasy grunty orne. Ten etap klasyfikacji miał na celu wyróżnienie następujących klas pokrycia terenu: wody (ID = 10); place, parkingi, drogi wraz z zabudową (ID = 20); roślinność (ID = 30) oraz klasa gruntów ornych (ID = 40).

Ostatnim etapem klasyfikacji OBIA wspartej danymi z ALS było uwzględnienie zarówno wysokości względnej obiektów (na podstawie modelu zNMPT), jak i innych charakterystyk uzyskanych „w locie” w programie eCognition bezpośrednio z chmury punktów ALS, takich jak intensywność odbicia, czy zróżnicowanie na pierwsze i ostatnie

odbicia. Na podstawie względnej wysokości obiektów rozróżniono zabudowę na klasy: niską ( $zNMPT \geq 1.3$  m oraz  $zNMPT < 10$  m; ID = 22) oraz wysoką ( $zNMPT \geq 10$  m; ID = 23). Dla roślinności zastosowano przedziały: zieleń niska ( $zNMPT < 1.0$  m; ID = 31), zieleń średniej wysokości ( $zNMPT \geq 1.0$  m oraz  $zNMPT < 7.0$  m; ID = 32) oraz zieleń wysoka ( $zNMPT \geq 7.0$  m; ID = 33). Dodatkowo wykorzystano informację wysokościową dla odróżnienia klasy „zabudowa” od klasy „place i parkingi” ( $zNMPT < 1.3$  m; ID = 21).

#### **4. WYNIKI**

Ocenę dokładności klasyfikacji OBIA przeprowadzono na danych referencyjnych, pozyskanych przez operatora, tj. dla klas: woda (ID = 10), place, parkingi, drogi oraz zabudowa (klasa 20), zieleń niska, średniej wysokości i wysoka (ID = 30), oraz grunty orne (ID = 40). Ogólna dokładność klasyfikacji dla wariantu I (dane wyłącznie na podstawie ortofotomapy cyfrowej) wyniosła 93.1% (transekt „A”) oraz 91.6% (transekt „B”). Wzmocnienie procesu segmentacji i klasyfikacji danymi z nalotu ALS podniosło kilka procent wynik dokładności uzyskiwanych klas do poziomów 96.9% (transekt „A”; wzrost o +3.8%) oraz 95.0% (transekt „B”; wzrost dokładności o +3.4%). Szczegółowe wyniki klasyfikacji OBIA dla transektów „A” oraz „B” przedstawiono poniżej (Tab. 1 oraz Tab. 2).

W przypadku obszarów miejskich (transekt „A”) różnice pomiędzy wartościami sumarycznymi powierzchni uzyskanych klas, są mniejsze niż w przypadku obszarów rolniczych (transekt „B”). Sumaryczna powierzchnia zieleni niskiej (198.26 ha – wariant I; 86.98 ha – wariant II) w sytuacji wzmocnienia klasyfikacji OBIA danymi ALS zmniejsza się kosztem pojawienia się klasy roślinności wysokiej (0.00 ha w wariantcie I do 51.66 ha w wariantcie II) i roślinności średniej wysokości (odpowiednio dla wariantu I oraz II) wzrost z poziomu 0.00 ha do 59.73 ha. Jest to spowodowane przede wszystkim nieznacznym przesunięciem ortofotomapy cyfrowej względem modelu  $zNMPT$  (różnice wynikają z technologii rzutu środkowego zdjęcia lotniczego), przez co bezpośrednie sąsiedztwo roślinności wysokiej na ortofotomapie (np. trawnik) może otrzymać wysokość np. krawędzi dachu budynku czy korony drzewa), zamiast właściwej zbliżonej do zera. Różnice spowodowane przesunięciem radialnym obiektów wysokich na ortofotografii lotniczej daje się stwierdzić również wewnątrz samej klasy zabudowa. Powierzchnia łączna placów, parkingów i dróg (69.24 ha – wariant I; 60.72 – wariant II) zmniejsza się przy zastosowaniu danych ALS głównie na rzecz zabudowy wysokiej (0.00 ha – wariant I; 16.33 ha – wariant II).

W przypadku klasyfikacji OBIA dla transektu „B” (obszar rolniczy i leśny) zwraca uwagę przeszacowana wielkość powierzchni gruntów ornych w przypadku wariantu I (z zastosowaniem wyłącznie lotniczej ortofotografii cyfrowej 69.96 ha). Wzmocnienie procesu klasyfikacji danymi ALS skutkuje spadkiem powierzchni tej klasy do 65.31 ha (-4.65 ha) znacznie przybliżając ją do wartości referencyjnych (63.59 ha). Przyczyną tego przeszacowania był fakt podobieństw charakterystyk spektralnych 8 bitowych obrazów ortofotografii lotniczej wydzielonych segmentów tworzących dachy budynków oraz place i parkingi do klasy grunty orne (bez pokrywy wegetacji).

Wykorzystanie danych ALS w procesie segmentacji obrazów ortofotografii lotniczej pozwoliło znacznie poprawić kształty generowanych segmentów (por. Rys. 4), zwłaszcza w przypadku klasy zabudowy, która była często łączona we wspólne segmenty z klasą grunt.

Tab. 1. Wyniki klasyfikacji OBIA dla transektu badawczego „A” – tereny miejskiej zabudowy

Klasa (identyfikator)	Powierzchnia klasy [ha]					
	Wariant I: klasyfikacja OBIA bez danych ALS		Wariant II: klasyfikacja OBIA wsparta danymi ALS		Dane referencyjne wektoryzacja ekranowa	
	klasy oddzielnie	klasy połączone	klasy oddzielnie	klasy połączone	klasy oddzielnie	klasy połączone
woda (10)	0.24	0.24	0.26	0.26	0.27	0.27
place, parkingi, drogi (21)	69.24	101.50	60.72	101.37	58.01	99.98
zabudowa niska (22)	32.26		24.32		22.85	
zabudowa wysoka (23)	0.00		16.33		19.12	
zieleń niska (31)	198.26	198.26	86.98	198.37	96.54	199.75
zieleń średnia (32)	0.00		59.73		55.05	
zieleń wysoka (33)	0.00		51.66		48.16	
grunty orne (41)	0.00	0.00	0.00	0.00	0.00	0.00
Łącznie	300.00	300.00	300.00	300.00	300.00	300.00

Tab. 2. Wyniki klasyfikacji OBIA dla transektu badawczego „B” – obszary rolnicze i leśne

Klasa (ID)	powierzchnia klasy [ha]					
	Wariant I: klasyfikacja OBIA bez danych ALS		Wariant II: klasyfikacja OBIA wsparta danymi ALS		Dane referencyjne wektoryzacja ekranowa	
	klasy oddzielnie	klasy połączone	klasy oddzielnie	klasy połączone	klasy oddzielnie	klasy połączone
wody (10)	2.95	2.95	2.95	2.95	2.95	2.95
place, parkingi, drogi (21)	11.60	13.72	8.04	16.37	12.26	21.28
zabudowa niska (22)	2.12		8.16		8.91	
zabudowa wysoka (23)	0.00		0.17		0.11	
zieleń niska (31)	138.84	213.37	79.37	215.37	75.39	212.18
zieleń średnia (32)	0.00		74.62		71.56	
zieleń wysoka (33)	74.53		61.38		65.23	
grunty orne (41)	69.96	69.96	65.31	65.31	63.59	63.59
Razem	300.00	300.00	300.00	300.00	300.00	300.00

## 5. DYSKUSJA I WNIOSKI

Przeprowadzone analizy pozwalają stwierdzić, iż wykorzystanie danych z lotniczego skanowania laserowego w postaci znormalizowanej chmury punktów do wzmocnienia procesu w klasyfikacji OBIA wysokorozdzielczych wielospektralnych ortofotomap lotniczych, pozwala na uzyskanie lepszych wyników. Rozumie się przez to zarówno podniesienie ogólnej jakości (dokładności) klasyfikacji jak i wyróżnienie dodatkowych klas (lub hierarchicznych podklas) pokrycia terenu takich jak roślinność średnia i wysoka czy zabudowa (różne klasy wysokościowe).



Wykorzystanie danych ALS do analizy OBIA umożliwia także identyfikację klas nie-  
możliwych wcześniej do wykrycia, takich jak napowietrzna infrastruktura (np. sieć ener-  
getyczna, telekomunikacyjna) czy też piętrowość klasy średniej i wysokiej roślinności (np. klasy  
las). Wykorzystanie danych lotniczego skaningu laserowego o odpowiedniej gęstości poprawia  
także wyraźnie granice automatycznie tworzonych segmentów a następnie zasięgów klas.

Zaprezentowane prace badawcze przeprowadzone zostały z wykorzystaniem chmury  
punktów ALS analizowanej w sposób tzw. dwuwymiarowy (2D). Dynamika rozwoju opro-  
gramowania eCognition (TRIMBLE GEOSPATIAL) powoduje pojawienie się dalszych  
możliwości obiektowej klasyfikacji segmentów przestrzennych, co w przyszłości pozwoli  
na jeszcze pełniejsze wykorzystanie zalet klasyfikacji OBIA w odniesieniu do danych ALS.

Dla podniesienia jakości wyników klasyfikacji OBIA, poza wzmocnieniem jej danymi  
ALS, autorzy sugerują pilną potrzebę generowania tzw. prawdziwej ortofotografii (ang. *true  
ortho*), która pozwoli na wyeliminowanie niepożądanego efektu rzutu środkowego obecnego  
na ortofotografiach lotniczych, skutkującego przesunięciami radialnymi wysokich obiektów  
a tym samym problemami z klasyfikacją wzmocnianą informacją wysokościową.

Pełne zautomatyzowanie analiz chmur punktów ALS oraz wzmocnianie klasyfikacji  
OBIA zdjęć lotniczych danymi ALS stają się pilną potrzebą w sytuacji masowego pojawia-  
nia się coraz większej liczby bardzo dokładnych danych teledetekcyjnych, związanych  
choćby z realizacją projektu Informatyczny Systemem Osłony Kraju przed nadzwyczajnymi  
zagrożeniami (ISOK). Pozyskiwane i generowane w ramach niego geodane (chmury  
punktów, modele wysokościowe, zdjęcia lotnicze i ortofotografie lotnicze) pokrywają nieba-  
wem niemal 2/3 powierzchni Polski. Dane spełniać będą bardzo wysokie standardy, tj.:  
gęstość skanowania (standard I – 4 pkt., Standard II – 12 pkt na 1 m<sup>2</sup>) rejestracji co  
najmniej czterech odbić, intensywności odbitych sygnałów, klasyfikacji czy atrybutów  
RGB (przypisane ze zdjęć lotniczych) i stanowić będą bardzo cenny zasób geodanych.  
Jedynie dalece zautomatyzowane procedury automatycznej analizy danych, takie jak OBIA,  
mogą zapewnić szerokie wykorzystanie potencjału gromadzonych w PZGiK geodanych  
przy nieznacznych modyfikacjach parametrów klasyfikacyjnych.

## 6. LITERATURA

- Auynirundronkool K., Deeudomchan K., Prakobya A., Jarnkoon V., Tintarasara M., Seechan M.  
Analysis of Economic Crop Reflectance by Field Spectral Signature: Case Study Sugarcane.  
<http://www.a-a-r-s.org/acrs/proceeding/ACRS2008/Papers/TS%2013.6.pdf>
- Będkowski K., Wężyk P. 2010. Lotniczy skaningu laserowy. Teledetekcja i fotogrametria  
obszarów leśnych. *Geomatyka w Lasach Państwowych – cz. I podstawy*. Centrum Informa-  
cyjne Lasów Państwowych, Warszawa, s. 326–343.
- deKok R., Koziół K., Wężyk P., 2005. Zastosowanie klasyfikacji obiektowej wysoko-  
rozdzielczych obrazów teledetekcyjnych oraz analiz przestrzennych GIS w kartowaniu  
drzewostanów. *Roczniki Geomatyki*, 3 (4), s. 99–108.
- Lewiński S., 2006. Rozpoznanie form pokrycia i użytkowania ziemi na zdjęciu satelitarnym  
Landsat ETM+ metodą klasyfikacji obiektowej. *Roczniki Geomatyki*, 4 (3), s. 139–152.
- Li Y., Lin Z. L., Shimamura H., 2008. Integrated method of building extraction from Digital  
Surface Model and imagery. *The International Archives of the Photogrammetry, Remote  
Sensing and Spatial Information Sciences*, Vol. XXXVII. Part B3b, s. 81–86.
- Rottensteiner F., Trinde J., Clode S., Kubik K., 2005. Using the Dempster-Shafer method  
for the fusion of LIDAR data and multi-spectral images for building detection. *Information  
Fusion*, 6, s. 283–300.

Trimble eCognition Developer 8.64.0 Reference Book, 2010. s. 27–45.

Wężyk P., deKok 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. *Angewandte Geoinformatik*, s. 770–775.

Wężyk P., 2006. Wprowadzenie do technologii skaningu laserowego w leśnictwie. *Roczniki Geomatyki*, 4 (4), s. 119–132.

Wężyk P., deKok R., Koziół K., 2006. Application of the Object Based Image Analysis of VHR satellite images in land-use classification. *Roczniki Geomatyki*, 4 (3), s. 227–238.

Wężyk P., de 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, s. 791–800.

### **SUPPORT OF OBIA OF MULTISPECTRAL AERIAL ORTHOIMAGES BY USING DATA FROM AIRBORNE LASER SCANNING**

**KEYWORD:** Object Based Image Analysis (OBIA), digital aerial orthophoto, Airborne Laser Scanning, ISOK.

**SUMMARY:** Object Based Image Analysis (OBIA) is an innovative method of analyzing remote sensing data based not on the pixels, but on homogenous features (segments) generated by specific algorithms. OBIA based on high-resolution aerial orthophotography and powered by digital terrain models (nDSM) brings high accuracy analysis. Not many scientific papers brings implementation of ALS point cloud directly into OBIA image processing. Paper present study done on two test areas of approx. 3 km<sup>2</sup>, situated close to Wloclawek, representing different land use classes (transect “A” – urban area; transect “B” – rural and forest landscape). Geodata (digital aerial orthophotographs and Airborne Laser Scanning data) were captured almost at the same time (September 2010). Different raster layers were created from \*. LAS file, like: intensity, number of returns, normalized elevation (nDSM). Two version (I and II) of OBIA classification were performed. First version (I) based only on aerial orthophotographs and different coefficients (like NDVI). Second variant of OBIA (variant II) based additionally on ALS data. Total accuracy of variant I was 94.1% (transect “A”) and 92.6% (transect “B”). OBIA classification powered by ALS data provide to increase of the results up to 96.9% (transect “A”) and 95.0% (transect “B”) as well. Classification of objects with similar type of surface properties (like buildings and bare soil) was much better using ALS information. The ALS data improve also the shape of objects, that there are more realistic. Data fusion in OBIA processing brings new capabilities. These capabilities are bigger thanks to processing based on 3-dimensional segments. The results of analysis would be more accurate, when orthoimages (“true ortho”) would be used, instead of standard orthophotographs. The running ISOK project in Poland will bring soon a huge data set (approx. 150 TB) of ALS and photogrammetry connected products. This situation requires suitable software to analyze it fast and accurate on the full automatic way. The OBIA classification seems to be a solution for such challenge.

dr inż. Piotr Wężyk  
rlwezyk@cyf-kr.edu.pl  
tel.: +48-12-662-5082  
fax: +48-12-662-5082