

**WYKORZYSTANIE DANYCH LOTNICZEGO SKANINGU LASEROWEGO
I ZDJĘĆ LOTNICZYCH DO KLASYFIKACJI POKRYCIA TERENU**

**LAND COVER CLASSIFICATION USING AIRBORNE
LASER SCANNING DATA AND AERIAL IMAGES**

Andrzej Borkowski, Przemysław Tymków

Instytut Geodezji i Geoinformatyki, Uniwersytet Przyrodniczy we Wrocławiu

SŁOWA KLUCZOWE: lotniczy skaningu laserowego, zdjęcia lotnicze, klasyfikacja nadzorowana, sztuczne sieci neuronowe, metoda największej wiarygodności, metoda k-najbliższych sąsiadów

STRESZCZENIE: Informacja bezpośrednia i pośrednia dotycząca powierzchni terenu i jego pokrycia zawarta w danych skaningu laserowego może być wykorzystana do klasyfikacji form pokrycia terenu. W artykule podjęto próbę oceny przydatności tego typu danych jako źródła informacji uzupełniających wektor cech, zbudowany na podstawie obrazów lotniczych, w procesie klasyfikacji pokrycia terenu. Wykorzystano dane skanowania laserowego pozyskane za pomocą systemu ScaLARS. Przeprowadzono szereg eksperymentów numerycznych polegających na klasyfikacji fragmentu obszaru doliny rzeki Widawy za pomocą różnych algorytmów klasyfikacji oraz przy różnych kombinacjach wektora cech branych pod uwagę. W testach wykorzystano jednokierunkowe sztuczne sieci neuronowe, metodę największej wiarygodności, oraz metodę k-najbliższych sąsiadów. Porównano jakość klasyfikacji opartej o następujące cechy: wartości kanałów RGB, parametry charakteryzujące teksturę, informacje o wysokości form pokrycia terenu estymowane na podstawie numerycznego modelu terenu oraz numerycznego modelu pokrycia terenu, model charakteryzujący rozrzut wartości wysokości danych skaningu zarejestrowanych na jednostce powierzchni oraz intensywność promienia laserowego. Ilościową ocenę dokładności oparto o macierz niezgodności, obliczaną na podstawie porównania otrzymanego wyniku klasyfikacji dla wektora testowego do wzorca wykonanego manualnie metodą digitalizacji. Najlepsze wyniki klasyfikacji otrzymano za pomocą klasyfikatora neuronowego. Stwierdzono ponadto, że zastąpienie modelu numerycznego pokrycia terenu wariancją wysokości surowych danych lotniczego skaningu laserowego daje poprawne rezultaty klasyfikacji przy znacznej redukcji obliczeń.

1. WPROWADZENIE

Dane lotniczego skanowania laserowego wykorzystywane są głównie do budowy numerycznych modeli terenu względnie numerycznych modeli pokrycia terenu. Potencjał informacyjny tych danych jest jednak większy. Informacja bezpośrednia i pośrednia o powierzchni terenu i jego pokryciu zawarta w zbiorach danych skaningu laserowego umożliwia również wykorzystanie tych danych do klasyfikacji form pokrycia terenu.

Z drugiej strony kategoryzacja treści zobrazowań lotniczych i satelitarnych oparta na analizie charakterystyki spektralnej czy teksturze może okazać się niewystarczającą

w niektórych zagadnieniach. Przykładem może być zadanie klasyfikacji pokrycia terenu ze względu na gęstość wegetacji poniżej poziomu koron drzew na obszarach porośniętych zwartym lasem. Penetracja obszarów leśnych przez promień lasera stwarza możliwość rejestracji cech form pokrycia terenu niewidocznych na klasycznych zdjęciach lotniczych i obrazach satelitarnych. Ponadto, w trakcie skanowania laserowego wraz ze współzrzednymi punktów $\{x,y,z\}$ rejestrowana jest wartość intensywności odbicia promienia, która również niesie pewną porcję informacji o pokryciu terenu.

Badania wykorzystujące w klasyfikacji informacje związane z pomiarem laserowym, takie jak: znormalizowana wysokość – czyli różnica pomiędzy numerycznym modelem terenu (NMT) a numerycznym modelem pokrycia terenu (NMTP), tekstura – wyznaczana na podstawie lokalnej zmiany wysokości, różnica wysokości pomiędzy pierwszym a ostatnim impulsem oraz intensywność odbicia prowadzili między innymi Charaniya *et al.* (2004). Wykorzystali oni te informacje do wydzielenia obszarów zadrzewionych za pomocą parametrycznej klasyfikacji nadzorowanej wykorzystującej model Gaussa oraz algorytm *Expectation-Maximization*. Uzyskane wyniki określili jako dobre. Autorzy zauważyli również, że rozszerzenie zbioru danych o zdjęcia lotnicze, wpłynęło na poprawę przeprowadzonej klasyfikacji.

Na potrzeby niniejszego opracowania autorzy przeprowadzili szereg eksperymentów numerycznych, z wykorzystaniem różnych metod klasyfikacji i w oparciu o różne kombinacje wektora cech. Badania miały na celu określenie zakresu i możliwości wykorzystania potencjału informacyjnego dotyczącego pokrycia terenu a zawartego w danych lotniczego skanowania laserowego. W pracy przedstawiono najbardziej reprezentatywne wyniki oraz wnioski szczegółowe; omówiono problemy związane z przygotowaniem danych.

2. CHARAKTERYSTYKA DANYCH

2.1. Dane wysokościowe skanowania laserowego

Przedstawione w pracy badania przeprowadzono z wykorzystaniem danych obejmujących zalesiony fragment doliny rzeki Widawy. Dane skaningu laserowego pozyskano w roku 2005, w ramach realizacji projektu badawczego, z wykorzystaniem systemu ScaLARS, bazującego na dalmierzu laserowym typu CW (*continuous wave*). Szczegóły związane z pozyskaniem danych przedstawiono w pracy (Borkowski *et al.*, 2006). Na podstawie bezpośrednich wyników skanowania, po eliminacji punktów będących efektem zjawiska wielotorowości, wyinterpolowano NMTP na regularnej siatce o boku 1 m. NMT wyinterpolowano na podstawie danych otrzymanych w wyniku filtracji danych nieprzetworzonych metodą ruchomych powierzchni wielomianowych (Borkowski i Józków, 2006). Reprezentujący pokrycie terenu model różnicowy pomiędzy NMPT a NMT przedstawiono na rysunku 1.

Opracowanie modeli NMPT i NMT wiąże się ze sporym nakładem pracy. Dlatego jako alternatywę dla modelu różnicowego zaproponowano wariację wysokości nieprzetworzonych danych skaningu laserowego, przypadającą na jednostkę powierzchni. Jako jednostkę powierzchni przyjęto, na drodze eksperymentalnej, kwadrat o boku 3 m. Wizualizację wariacji wysokości punktów pomiarowych przedstawiono na Rys. 1.



Rys. 1. Wizualizacja danych opisujących wysokości elementów pokrycia terenu: model różnicowy pomiędzy NMPT i NMT (po lewej) i wariancja wysokości punktów pomiarowych (po prawej stronie).

2.2. Intensywność odbicia skanowania i problemy związane z kalibracją

Systemy skaningu laserowego rejestrują oprócz wielkości geometrycznych również ilość energii promienia (impulsu) laserowego odbitą od powierzchni skanowanej. Wielkość ta przypisana jest do każdego punktu pomiarowego jako intensywność a interpolowana na regularną siatkę daje obraz intensywności. Obraz intensywności wykorzystywany był początkowo do (automatycznej) kalibracji systemu i łączenia poszczególnych skanów. W ostatnich latach obserwuje się w literaturze wzrost zainteresowania tą informacją i poszerzanie obszarów jej zastosowania. Zauważono na przykład, że na niektórych obszarach górskich o słabych warunkach oświetlenia obraz intensywności skaningu laserowego może być jedyną informacją o teksturze.

Badaniem przydatności intensywności odbicia w analizie obszarów leśnych zajmowali się między innymi Katzenbeisser (2003), Song *et al.* (2002) oraz Charaniya *et al.* (2004).

Przeprowadzone przez Katzenbeisser'a analizy zawierają szczegółowy opis sposobu rejestracji poszczególnych impulsów lasera dla obszarów z pokrywą roślinną. Badał on między innymi osłabienie intensywności odbicia pojedynczego impulsu wiązki padającej na teren zalesiony. Z analiz przeprowadzonych przez Katzenbeisser'a wynika, że wykorzystanie danych o intensywności odbicia jest trudne i skomplikowane. Jedyne dla powierzchni płaskich intensywność daje miarodajną informację o rejestrowanym obiekcie, natomiast dla terenów zalesionych, gdzie mamy do czynienia z częściowym odbiciem impulsu od kolejnych poziomów roślinności, analiza intensywności wymaga rozważenia szeregu dodatkowych parametrów. Trzeba jednak zauważyć, że zastosowany przez niego skaner charakteryzował się możliwością rejestracji wielu odbić jednego impulsu. Dane wykorzystane na potrzeby niniejszego artykułu pochodzą natomiast ze skanera typu CW.

Prace badawcze mające na celu wydzielenie poszczególnych klas użytkowania terenu na podstawie tylko informacji o intensywności odbicia prowadzili Song *et al.* (2002). Uzyskane wyniki, dla klasyfikacji terenów porośniętych roślinnością, nie były zadowalające. Jako przyczynę podano fakt, że wartość intensywności dla różnych typów roślinności (np. traw i drzew) jest zbliżona i wynosi około 50%. We wnioskach

stwierdzono jednak, że jakość klasyfikacji powinno znacząco poprawić uwzględnienie danych wysokościowych z pomiaru laserowego.

Problemy z efektywnym wykorzystaniem danych o intensywności wynikają z tego, że nie są to dane homogeniczne. Niejednorodność, w postaci nieliniowego przesunięcia, występuje głównie pomiędzy poszczególnymi skanami, ale również, w mniejszym lub większym stopniu, w zależności od konkretnego systemu skanowania, w ramach poszczególnych skanów. Homogeniczność widoczna jest natomiast na niewielkich obszarach, zwłaszcza w odniesieniu do poszczególnych obiektów. Nieprzetworzone dane dotyczące intensywności mogą być zatem wykorzystywane tylko w zastosowaniach ściśle lokalnych, na przykład do identyfikacji obrysu budynku w ramach tego samego skanu. W przeciwnym wypadku wymagają kalibracji. Kalibracja obrazu intensywności jest jednak zagadnieniem trudnym i wciąż otwartym.

Na ilość energii promienia laserowego powracającej do urządzenia rejestrującego mają wpływ trzy czynniki: a) odległość przestrzenna pomiędzy skanerem a skanowanym obiektem, b) właściwości fizyczne i topografia skanowanej powierzchni i c) czynniki atmosferyczne (energię źródła i ewentualne jej fluktuacje można pominąć, jeśli rozpatrujemy konkretny system). Istniejące modele teoretyczne tylko w pewnym stopniu i nie kompleksowo opisują wpływ różnych czynników na intensywność. Najlepsze rezultaty kalibracji uzyskuje się budując modele empiryczne oparte o dane – odwzorowanie tych samych jednoznacznie identyfikowalnych obiektów (najczęściej płaskiej powierzchni) w obrazach intensywności różnych skanów. Przegląd możliwości w tym zakresie oraz weryfikację różnych rozwiązań podano w aktualnej pracy Höfle i Pfeifer (2007).

Autorzy niniejszego opracowania testowali różne możliwości w zakresie kalibracji intensywności. Wszystkie te próby kończyły się mniejszym lub większym niepowodzeniem. Wynika to z tego, że obszar opracowania to głównie tereny zalesione bez możliwości wydzielenia obiektów referencyjnych. Doświadczenie to potwierdza pogląd wyrażony w pracy Höfle i Pfeifer (2007), że skuteczna kalibracja intensywności na terenach leśnych nie jest możliwa.

Ostatecznie przeprowadzono tylko normalizację intensywności pomierzonej I ze względu na odległość przestrzenną (por. np. Höfle i Pfeifer, 2007):

$$(1) \quad I(D_s) = \frac{I \cdot D^2}{D_s^2},$$

gdzie D jest pomierzoną odległością przestrzenną od skanera do punktu skanowanego, a D_s odległością standardową na którą przeprowadzono normalizację. Podejście to pozwoliło znacznie ujednoczyć obraz intensywności w ramach poszczególnych skanów. Niejednorodność wynika w tym przypadku ze specyfiki systemu. Wiązka lasera odchylana jest za pomocą lustra nutacyjnego co w złożeniu z ruchem samolotu daje efekt taki, że droga, którą pokonuje promień lasera jest różna dla punktów skanowania w przód i wstecz.

Na Rys. 2 przedstawiono znormalizowany obraz intensywności odbicia dla obszaru opracowania. Pomimo ułomności kalibracji (widoczne granice poszczególnych skanów), wyraźnie widoczne są na nim wody, a także granice obszarów zalesionych czy wały przeciwpowodziowe.

Obraz ten wykorzystano w procesie klasyfikacji wychodząc z założenia, że poprawi on identyfikację pewnych obiektów, natomiast widoczne granice skanów, mogące

prowadzić do wydzielenia dodatkowych klas, zostaną, w zderzeniu z innymi składowymi wektora cech, zakwalifikowane przez algorytm rozpoznawania jako szum.




Rys. 2. Obraz intensywności odbicia dla obszaru opracowania

2.3. Obrazy lotnicze i wzorzec klasyfikacji

W trakcie rejestracji danych skaningowych wykonywany jest często w celach interpretacyjnych zapis obrazu skanowanego terenu w postaci video lub zdjęć. W projekcie wykonano szereg niemetrycznych zdjęć aparatem cyfrowym Nikon d70, które poddano korekcji geometrycznej poprzez ich rejestrację w układzie współrzędnych 1992 za pomocą transformacji rzutowej stosując próbkowanie metodą najbliższego sąsiada (ang. *Nearest Neighbour*). Wykorzystano moduł *Image to Image* programu *Image Analyst* firmy Intergraph. Obrazy były transformowane za pomocą punktów dostosowania zidentyfikowanych na podstawie mapy topograficznej w skali 1:10 000. Dla pojedynczego zdjęcia wykorzystano przeciętnie 10 punktów dostosowania. Dokładność wpasowania wyrażona błędem standardowym wynosiła średnio około 3-4 metrów. Uznano to za dokładność wystarczającą. Duże błędy wpasowania wynikały z amatorskiej metody pozyskania obrazów. Nie rzutuje to jednak na metodykę klasyfikacji, choć ma wpływ na jej jakość. Poddane rejestracji obrazy mozaikowano za pomocą narzędzia *Mosaic Files* również z pakietu *Image Analyst*. Zastosowano standardową metodę wyrównania tonalnego. Rozdzielczość przestrzenną piksela określono na 1m. Wynik mozaikowania wraz z powiększeniem fragmentu przedstawia Rys. 3.

W celu pełniejszego wykorzystania informacji zawartych na zdjęciach lotniczych wykonano ekstrakcję cech teksturowych. Posłużono się w tym celu metodą macierzy sąsiedztwa (GLCM) (ang. *Grey Level Co-occurrence Matrix*). Macierz ta reprezentuje statystykę sąsiedzowania pikseli o różnych odcieniach w pewnej, ustalonej odległości od siebie. Sposób obliczenia macierzy GLCM podano w pracy (Tymków i Borkowski, 2006; por. również Iwaniak *et al.* 2005). Na podstawie macierzy GLCM obliczany jest szereg parametrów, których definicje i wizualizacje dla fragmentu zdjęcia przedstawiono w tabeli 1.



Rys. 3. Fragment mozaiki obrazów lotniczych

Tab 1. Wizualizacja parametrów obliczonych w oparciu o macierz GLCM (P_{ij} – element i -tego wiersza i j -tej kolumny macierzy sąsiedztwa poddanej wcześniej symetryzacji i normalizacji)

ASM	energia	entropia	kontrast	podobieństwo	zróżnicowanie
$\sum_{i,j=0}^{N-1} P_{i,j}^2$	\sqrt{ASM}	$\sum_{i,j=0}^{N-1} p_{i,j}(-\ln p_{i,j})$	$\sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2$	$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2}$	$\sum_{i,j=0}^{N-1} P_{i,j} i-j $



Rys. 4. Wzorec klasyfikacji

Wzorce klas stanowiły próbki pobrane manualnie poprzez wskazanie na obrazach jednorodnych fragmentów o wymiarach 100x100 m w terenie. Ponadto, aby umożliwić ilościową ocenę dokładności klasyfikacji wykonano drogą digitalizacji wzorzec obszaru testowego o wymiarach 1000x1000 m (Rys. 4).

3. METODY KLASYFIKACJI

Wykonano szereg eksperymentów polegających na klasyfikacji fragmentu obszaru opracowania (Rys. 3) za pomocą różnych algorytmów klasyfikacji oraz przy różnych kombinacjach wektora cech branych pod uwagę. W testach wykorzystano następujące klasyfikatory:

- jednokierunkową trójwarstwową sztuczną sieć neuronową (SSN) uczoną metodą wstecznej propagacji błędów (ang. *Standard Back-Propagation*),
- metodę największej wiarygodności opartą o model rozkładu normalnego gęstości cech w klasach (ang. *maximum likelihood*),
- metodę k-najbliższych sąsiadów (k-NN, k=5)

Dla każdej z metod zbadano jakość klasyfikacji przy zastosowaniu następujących wariantów wektora cech:

- | | |
|------------------------------------|--------------------------------|
| a) zdjęcie lotnicze (model RGB) | e) RGB+cechy tekstur (GLCM) |
| b) intensywność (INT) | f) RGB+GLCM+intensywność (INT) |
| c) INT+ różnica DSM-DTM (PT) | g) RGB+GLCM+INT+PT |
| d) INT+ wariancja wysokości (VarH) | h) RGB+GLCM+INT+VarH |

Jakościowa ocena dokładności klasyfikacji oparta została o ważony współczynnik κ (kappa) obliczany w oparciu o macierz niezgodności $A=[a_{ij}]$ określającą liczbę punktów należących do klasy j , które zostały zaklasyfikowane jako punkty należące do klasy i . Współczynnik κ zdefiniowany został między innymi w pracy (Iwaniak *et al.* 2005)

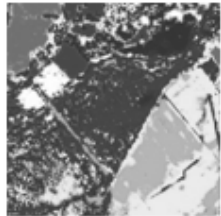
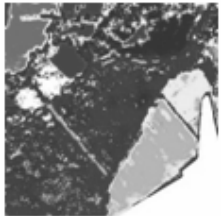
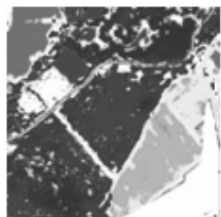
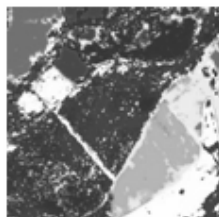
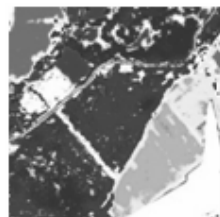
4. WYNIKI I PODSUMOWANIE

Spśród uzyskanych wyników najważniejsze przedstawiono w Tab 2 i Tab 3. Główne wnioski wynikające z przeprowadzonych badań można sformułować następująco:

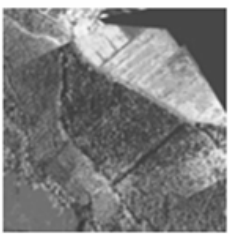
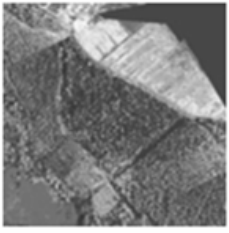
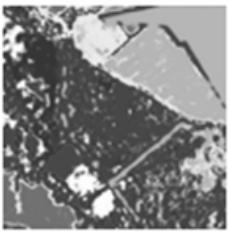
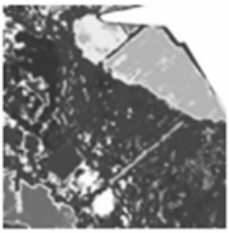
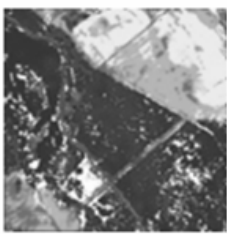
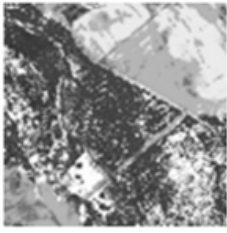
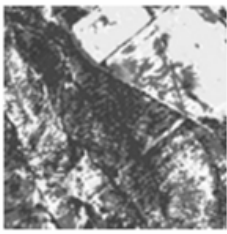
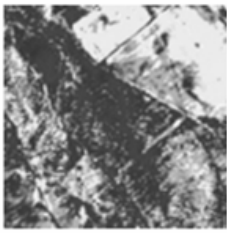
- Wykorzystanie danych wysokościowych wpływa na redukcję błędów klasyfikacji spowodowanych np. niedokładnością wyrównania tonalnego zdjęć.
- Zastosowanie wariancji wysokości w zamian za informacje o wysokościach form pokrycia estymowanych na podstawie modeli numerycznych daje porównywalne rezultaty, a uzyskanie tej cechy jest znacznie szybsze i proste obliczeniowo.
- Obraz intensywności nie wnosi istotnych informacji mogących poprawić klasyfikację obszarów leśnych, jest natomiast przydatny w rozpoznaniu obszarów pod wodami, nawet ukrytymi pod pokrywą roślinną.
- Najlepsze pod względem jakościowym oraz ilościowym wyniki otrzymano dla klasyfikatora neuronowego, klasyfikator największej wiarygodności nie mógł być stosowany dla danych zawierających modele charakteryzujące wysokości pokryci terenu ze względu na brak rozkładu gęstości cech w niektórych klasach. Metoda k-najbliższych sąsiadów daje niezadowalające rezultaty.

- Postulowane w literaturze np. (Song et al., 2002) zastosowanie wyłącznie danych charakteryzujących wysokości form pokrycia oraz intensywności do klasyfikacji terenu nie przyniosło zadowalających rezultatów w tym przypadku. Cechy te można jednak traktować jako cenne źródło informacji uzupełniającej dane pozyskane na podstawie zobrażeń lotniczych w zakresie widzialnym.

Tab 2. Wizualizacja najważniejszych wyników eksperymentów wraz z oceną jakości klasyfikacji (cz. 1)

Wektor cech	RGB+GLCM+INT		
Klasyfikator	SSN	Bayes	
Współczynnik κ	0,5121	0,5542	
Obraz			
Wektor cech	RGB+GLCM+INT+PT	RGB+GLCM+INT+VarH	RGB+GLCM+INT+PT
Klasyfikator	SSN	k-NN	SSN
Współczynnik κ	0,6122	0,6092	0,6122
Obraz			

Tab 3. Wizualizacja najważniejszych wyników eksperymentów wraz z oceną jakości klasyfikacji (cz. 2)

		RGB		RGB+GLCM	
Wektor cech		SSN	Bayes	SSN	Bayes
Klasyfikator					
Współczynnik κ		0,3011	0,2458	0,5423	0,5988
Obraz					
Wektor cech		INT+PT	INT+VarH	INT	
Klasyfikator				SSN	Bayes
Współczynnik κ		0,4785	0,4002	0,045	0,080
Obraz					

5. LITERATURA

- Borkowski A., Gołuch P., Wehr A., 2006. Rejestracja doliny rzeki Widawy z wykorzystaniem lotniczego skanowania laserowego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 16, s. 53-62.
- Borkowski A., Jóźków G., 2006. Wykorzystanie wielomianowych powierzchni ruchomych w procesie filtracji danych pochodzących z lotniczego skaningu laserowego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 16, s. 63-73.
- Charaniya A., Manduchi R., Lodha S., 2004. Supervised parametric classification of aerial lidar data. *Proceedings of the Conference on Computer Vision and Pattern Recognition Workshop (CVPRW'04)* Vol. 3, s. 30
- Höfle B., Pfeifer N., 2007. Correction of laser scanning intensity data: Data and model-driven approaches. *ISPRS Journal of Photogram. & Remote Sensing*, Vol. 62, s. 415-433.
- Iwaniak A., Kubik T., Paluszyński W., Tymków P., 2005. Classification of features in high-resolution aerial photographs using neural networks. *XXII Int. Cartographic Conference: Mapping Approaches Into A Changing World*, A Coruna (Spain), 9-16 July 2005, CD.
- Katzenbeisser R., 2003:Toposys gmbh technical note, <http://www.toposys.de/pdfext/>
- Song J., Han S., Kim Y., 2002. Assessing the possibility of land-cover classification using lidar intensity data. *International Archives of Photogrammetry and Remote Sensing, Graz*, Vol. XXXIV/3B: 259–262
- Tymków P., Borkowski A., 2006. Wykorzystanie danych lotniczego skaningu laserowego do klasyfikacji pokrycia terenu dla potrzeb modelowania hydrodynamicznego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 16, s. 537-546.

Praca naukowa finansowana ze środków na naukę w latach 2005-2007 jako projekty badawcze nr 4T12E01729 oraz 2P06S04229. Obliczenia wykonano częściowo w systemie MATLAB, licencja nr 101979, grant obliczeniowy Wrocławskiego Centrum Sieciowo-Superkomputerowego

LAND COVER CLASSIFICATION USING AIRBORNE LASER SCANNING DATA AND AERIAL IMAGES

KEY WORDS: airborne laser scanning, aerial images, supervised classification, artificial neural networks, maximum likelihood, k-nearest neighbour method

SUMMARY: The direct and indirect information about terrain surface and land use contained in laser scanning data sets allow to provide the automatic classification of land cover. An attempt of using scanning data as a supplementary source for such classification based on aerial photos was performed in this article. A continuous-wave (CW) ScaLARS laser system was used to receive scanning data. Numerous experiments consisting in the classification of a part of Widawa River valley were carried

out in order to find the best combination of data set and classification method. Three classification methods were used: multilayer neural networks, maximum likelihood classifier and k-nearest neighbour method. The classification was made and evaluated using: aerial images (RGB model), texture features, differential model of height of land cover, based on digital surface model (DSM), and digital terrain model (DTM), model of height dispersion represented by variance of measured points height in a regular grid and intensity image. In order to quantify the quality of the results, a confusion matrix was created for each testing pattern based on manual digitalized reference data. The best results are obtained by artificial neural network classifier. The use of variance of height, instead of differential model, gives satisfactory results, and the obtaining of this feature is easy and fast in comparison to DTM and DSM building process.

dr hab. inż. Andrzej Borkowski, prof. nadzw.
e-mail: borkowski@kgf.ar.wroc.pl
telefon: 071-3205609

dr. inż. Przemysław Tymków
e-mail: tymkow@kgf.ar.wroc.pl
telefon:071-3201953