

INTEGRACJA DANYCH LIDAROWYCH I FOTOGRAMETRYCZNYCH W PROCESIE AUTOMATYCZNEGO WYKRYWANIA OBIEKTÓW

INTEGRATION OF AIRBORNE LIDAR AND PHOTOGRAMMETRIC DATA IN THE PROCESS OF AUTOMATIC OBJECT EXTRACTION

Urszula Marmol

Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska,
Akademia Górniczo-Hutnicza

SŁOWA KLUCZOWE: integracja danych, lidar, ortofotomapa, wykrywanie obiektów

STRESZCZENIE: Artykuł przedstawia metodę integracji danych lidarowych i fotogrametrycznych w procesie automatycznego wykrywania obiektów. Zdjęcia lotnicze stanowią klasyczną metodę pozyskiwania informacji o przestrzeni. Ostatnie lata to coraz powszechniejsze stosowanie lidarów jako źródła informacji. Zdjęcia lotnicze cechują się możliwością wykrywania granic obiektów, ale w procesie ekstrakcji cech, często dochodzi do nadmiernego oszacowania lub zaniżenia liczby obiektów. Dane lidarowe dostarczają bezpośredniej informacji o wysokości obiektów, ale posiadają ograniczenia związane z dokładnym wyznaczeniem krawędzi obiektów. Można zatem powiedzieć, że techniki przetwarzania danych: fotogrametryczna i laserowa dostarczają danych komplementarnych, a ich integracja może przyczynić się do poprawy jakości uzyskiwanych wyników. W artykule przedstawiono badania nad integracją fotogrametrii i danych laserowych w procesie wykrywania obiektów 3D – budynków i drzew. W procesie automatycznej segmentacji zostały wykorzystane cechy teksturalne pochodzące ze zdjęć lotniczych. Obiekty 3D zostały wyodrębnione na podstawie danych lidarowych, jako różnica NMPT i NMT. Przeprowadzone badania ujawniły duży potencjał danych zintegrowanych w procesie automatycznego wykrywania obiektów.

1. WPROWADZENIE

Celem pracy jest oszacowanie na ile integracja danych lidarowych i fotogrametrycznych może przyczynić się do zwiększenia dokładności automatycznego wykrywania obiektów 3D – budynków i drzew. W obecnych systemach skanerowych równocześnie

z rejestracją laserową pozyskiwane są obrazy cyfrowe. Scalenie informacji pochodzących z tych dwóch technologii daje nowe możliwości w procesie przetwarzania i analizy danych. Postawiono tezę, że dane fotogrametryczne i lidarowe są komplementarne i mankamenty jednej metody mogą być niwelowane poprzez wykorzystanie danych pozyskanych drugą techniką.

2. DANE ŹRÓDŁOWE

2.1. Obszar badań

Obszar badawczy obejmuje fragment miasteczka Lewes w Anglii o powierzchni około 6 ha. Pole testowe charakteryzuje się bardzo urozmaiconą rzeźbą terenu. Obszar składa się z fragmentu drogi z elementami zabudowy oraz pojedynczymi drzewami, odcinku rzeki Ouse oraz kamieniołomu otoczonego gęstą roślinnością drzewiastą (Rys. 1).



Rys. 1. Prawdziwa ortofotomapa obszaru badawczego o wielkości piksela terenowego 0.10 m.

2.2. Dane laserowe

W listopadzie 2002 roku wykonano pomiar obszaru badawczego za pomocą lotniczego skanera laserowego TopEye (TopEye, 2009). Średnia gęstość skanowania dla wybranego pola badawczego wyniosła 25 punktów/m².

2.3. Dane obrazowe

Równocześnie z rejestracją laserową pozyskano dane obrazowe z wykorzystaniem kamery cyfrowej Hasselblad. Na podstawie zdjęć wygenerowano ortofotomapę prawdziwą (ang. *true ortho*) w barwach naturalnych o rozdzielczości przestrzennej 0.10 m.

3. ANALIZA DANYCH LASEROWYCH

3.1. Generowanie Znormalizowanego Numerycznego Modelu Pokrycia Terenu

Znormalizowany Numeryczny Model Pokrycia Terenu (ang. *normalized Digital Surface Model – nDSM*) został wygenerowany jako różnica pomiędzy NMPT i NMT.

W pierwszym etapie został wygenerowany Numeryczny Model Pokrycia Terenu (ang. *DSM*) według prostego algorytmu przedstawionego w artykule (Marmol, Będkowski, 2008).

W celu wyselekcjonowania punktów leżących na terenie, jako metodę filtracji wybrano algorytm aktywnego modelu TIN zaimplementowany w oprogramowaniu TerraScan firmy Terrasolid Corporation z Finlandii (Axelsson, 1999, 2000). Procedura ta pozwoliła na wyodrębnienie z chmury pomiarowej punktów związanych z przebiegiem powierzchni topograficznej.

Zostały wygenerowane dwa modele TIN odpowiadające odpowiednio NMPT i NMT. Znormalizowany model zNMPT powstał jako różnica dwóch modeli TIN, a następnie został zapisany w siatce regularnej o rozmiarze 1058x1485 i rozdzielczości przestrzennej 0.20 m (Rys. 2).



Rys. 2. Znormalizowany zNMPT (czarne piksele – brak danych laserowych).

4. ANALIZA DANYCH OBRAZOWYCH

4.1. Analiza teksturalna

Tekstura stanowi jedną z ważniejszych charakterystyk obrazu. Analizy teksturalne znajdują zastosowanie w wielu dziedzinach, gdzie kluczowym zagadnieniem jest wyodrębnienie obiektów m.in. w analizie obrazów biomedycznych (Rangayyan, 2005), obrazów radarowych (Paget, Longstaff, 1996), zdjęć lotniczych i satelitarnych (Faber, Förstner, 1999; Eckstein, Munkelt, 1995), w geologii i przemyśle, gdy istnieje konieczność badania powierzchni materiału. Tekstura jest wrodzoną własnością prawie wszystkich powierzchni (Malina, 2002). Dla człowieka określenie tekstury nie stanowi zazwyczaj problemu, jednakże jej opis ilościowy jest trudny do precyzyjnego zdefiniowania. W związku z tym stosowane są różne definicje, różne miary oraz różne techniki badania cech obrazu (Srinivasan, Shobha, 2008).

W niniejszym artykule skupiono się na metodzie analizy teksturalnej zaproponowanej przez Lawsa (Laws, 1980a, 1980b).

4.2. Teksturalne filtry Lawsa

Metoda zaproponowana przez Lawsa (Laws, 1980a, 1980b) oparta jest na klasyfikacji pikseli obrazu na podstawie miar lokalnej „energii teksturalnej”. Energia teksturalna reprezentuje ilość zmian wewnątrz rozpatrywanego okna na obrazach poddanych określonego wariantowi filtracji.

Podstawowe jednowymiarowe filtry Lawsa mają postać:

$$L3 = [1 \ 2 \ 1]$$

$$E3 = [-1 \ 0 \ 1]$$

$$S3 = [-1 \ 2 \ -1]$$

Okna 5-elementowe mogą być wygenerowane jako splot filtrów L3, E3, S3 w różnych kombinacjach. Najczęściej wykorzystywane są następujące filtry:

$$L5 = L3 * L3 = [1 \ 4 \ 6 \ 4 \ 1] \text{ – wyrównanie (ang. level)}$$

$$E5 = L3 * E3 = [-1 \ -2 \ 0 \ 3 \ 1] \text{ – pierwsza pochodna – wykrywanie krawędzi (ang. edge)}$$

$$S5 = -E3 * E3 = [-1 \ 0 \ 2 \ 0 \ -1] \text{ – druga pochodna – wykrywanie plam (ang. spot)}$$

$$W5 = -E3 * S3 = [-1 \ 2 \ 0 \ -2 \ 1] \text{ – wykrywanie zafalowań (ang. wave)}$$

$$R5 = S3 * S3 = [1 \ -4 \ 6 \ -4 \ 1] \text{ – wykrywanie zmarszczek (ang. ripple)}$$

Można uzyskać 25 dwuwymiarowych filtrów poprzez konwolucję filtrów 1D. Przykładowe filtry mają postać: $L5E5 = L5^T E5$ i są reprezentowane jako maska $A(i,j)$ – 5x5 pikseli.

W kolejnym etapie dokonywany jest splot masek filtrów z oryginalnym obrazem (Kumar, Ganesan, 2008):

$$(1) \quad F(i, j) = A(i, j) * I(i, j) = \sum_{p=-a}^a \sum_{l=-a}^a A(p, l) \cdot I(i + p, j + l)$$

gdzie:

$F(i,j)$ – obraz po filtracji ($i = 0.1 \dots N, j = 0.1 \dots M$)

$I(i,j)$ – obraz wejściowy

$A(i,j)$ – jądro filtra o rozmiarze $(2a+1) \times (2a+1)$

Przeprowadzana jest estymacja energii na otrzymanych obrazach, określana przez Laws'a jako „makrostatystyka”. Energia jest wyznaczana jako średnia różnica wartości bezwzględnych:

$$E(i,j) = \frac{1}{(2n+1)^2} \sum_{p=i-n}^{i+n} \sum_{l=j-n}^{j+n} |F(p,l) - M(i,j)| \quad (2)$$

gdzie:

$F(p,l)$ – obraz po filtracji

rozmiar okna $(2n+1) \times (2n+1)$

$$M(i,j) = \frac{1}{(2n+1)^2} \sum_{p=i-n}^{i+n} \sum_{l=j-n}^{j+n} F(p,l) \quad (3)$$


Średnia przyjmuje wartość 0 dla odpowiednio dużego rozmiaru okna w związku z tym można przyjąć następujące uproszczenie:

$$E(i,j) = \frac{1}{(2n+1)^2} \sum_{p=i-n}^{i+n} \sum_{l=j-n}^{j+n} |F(p,l)| \quad (4)$$

4.3. Praktyczna realizacja filtrów

Filtry Laws'a zostały zaprojektowane w środowisku MATLAB. Zastosowanie filtrów Laws'a do ortofotomapy prawdziwej pozwoliło na wygenerowanie 25 przefiltrowanych obrazów. W kolejnym etapie zostały wyznaczone obrazy zawierające wartości energii. Szczegółowa analiza uzyskanych danych pozwoliła wyodrębnić te, które w najlepszy sposób pozwalają na wyznaczenie budynków i drzew.

Analiza ujawniła przydatność filtracji S5S5, L5S5 i R5R5 w procesie wyodrębnienia drzew. Energia na tych obrazach dla pikseli opisujących drzewa jest zdecydowanie wyższa niż dla pozostałych obiektów i osiąga odpowiednio wartości 300÷650 dla obrazu S5S5 oraz 2000÷3600 dla obrazu L5S5. Z kolei filtry E5S5 i L5L5 w sposób jednoznaczny wyznaczyły płaszczyzny dachów budynków. Na analizowanym obszarze występowały dachy dwuspadowe, z których jedna połacie była intensywnie oświetlona, druga natomiast pozostawała w cieniu (patrz Rys. 1). W związku z tym na obrazach energii uzyskane wartości różniły się zasadniczo dla sąsiadujących połaci. Problem uwidocznił się także dla fragmentu kamieniołomu, który na wszystkich przefiltrowanych obrazach posiadał wartość energii zbliżoną do energii budynków. Możliwość włączenia w proces analizy danych laserowych, a dokładnie zNMPT, który dla kamieniołomu przyjmuje wartości 0, sprawiła, że błąd ten mógł zostać wyeliminowany.




Rys. 3. Wybrane obrazy po filtracji, odpowiednio z wykorzystaniem filtru S5S5, L5S5, E5S5 i L5L5.

4.4. Klasyfikacja na podstawie cech teksturalnych Lawsa

Obrazy powstałe po filtracji zostały wykorzystane w klasyfikacji nadzorowanej przeprowadzonej metodą najmniejszej odległości w programie IDRISI. Klasyfikacja miała na celu wyznaczenie trzech kategorii: „budynki”, „drzewa” i „inne”. Dla każdej klasy zostało wybranych po pięć pól treningowych. Po klasyfikacji powstał obraz z wyznaczonymi trzema kategoriami: „budynki”, „drzewa” i „inne”. Fragment obrazu po klasyfikacji

widoczny jest na Rys. 4 (po prawej). Dla porównania po lewej stronie zamieszczono prawdziwą ortofotomapę analizowanego fragmentu.



Rys. 4. Ortofotomapa fragmentu terenu z budynkiem oraz pojedynczymi drzewami (po lewej), kategorie: budynek (kolor czarny) i drzewa (kolor biały) wyznaczone na podstawie klasyfikacji obrazów teksturalnych (po prawej).

W wyniku klasyfikacji obrazów teksturalnych w zadawalający sposób zostały wydzielone pojedyncze drzewa. Ich liczebność oraz zasięg przestrzenny zgadzają się z wynikami wizualnej weryfikacji ortofotomapy. Należy jednak zwrócić uwagę, że do kategorii drzewa zostały błędnie zaklasyfikowane krawężniki, jasne fragmenty samochodów i latarnie.

Problemem okazało się wydzielenie budynków. Na analizowanym terenie znajdowały się budynki o dachach dwuspadowych, dla których jedna połać była oświetlona, druga natomiast pozostawała w cieniu. Energia tekstury obrazu dla części zacienionych pokrywała się z energią „tła” (czyli pozostałymi obiektami, które nie stanowiły tematu badań) i w wyniku procesu klasyfikacji zostały błędnie przydzielone do kategorii obiektów „innych”.

5. INTEGRACJA DANYCH LASEROWYCH I OBRAZOWYCH

Kolejny etap prac badawczych to scalenie informacji o budynkach i drzewach pochodzących z dwóch niezależnych źródeł, tj. lotniczego skaningu laserowego i prawdziwej ortofotomapy.

W wyniku przetwarzania chmury punktów laserowych został wyznaczony z NMPT. Natomiast na podstawie prawdziwej ortofotomapy została przeprowadzona klasyfikacja z wydzieleniem kategorii: „budynki”, „drzewa” i „inne”. Ze względu na rozbieżności

w rozdzielczości przestrzennej danych, dokonano zmiany rozdzielczości obrazów do piksela terenowego 0.20 m.

Scalenie informacji pochodzących z tych dwóch źródeł polegało na ustaleniu następujących warunków:

- 1) Piksele zNMPT przyjmują wartości z zakresu 5÷25 m.
- 2) Na obrazie ortofotomapy po klasyfikacji piksel odpowiada kategorii „budynki” lub „drzewa”
- 3) Minimalny rozmiar obiektu „drzewa” na obrazie przekracza wielkość 2 m².

Dla uzyskanego obrazu wynikowego przyjęto następujące założenia:

- 1) Jeśli ustalone warunki są spełnione – drzewa i budynki są wykryte w prawidłowy sposób.
- 2) Jeśli spełniony jest tylko warunek 1, a badany obszar przekracza wielkość 25 m² - obszar jest przeklasyfikowany do kategorii „budynek”.
- 3) Jeśli spełniony jest tylko warunek 2 - obiekt zostaje przeklasyfikowany do grupy obiektów „inne”.

Integracja danych pozwoliła na wykrycie i wyeliminowanie błędu związanego z zacięzionymi fragmentami budynków. Dzięki wykorzystaniu zNMPT udało się poprawnie zidentyfikować budynki, niemniej jednak nadal pozostały błędy związane z wyznaczeniem krawędzi.

Dane laserowe przyczyniły się także do wykrycia błędu związanego z zaklasyfikowaniem kamieniołomu do kategorii „budynki” (różnicowy model zNMPT dla obszaru kamieniołomu przyjmuje wartość 0).

Obrazy teksturalne pozwoliły na przeprowadzenie identyfikacji drzew. Niestety równocześnie do klasy drzew zostały zaklasyfikowane krawężniki, fragmenty samochodów i latarnie. Warunek 1 związany z analizą zNMPT pozwolił na automatyczne wyeliminowanie krawężników z kategorii „drzewa”. Z kolei warunek 3 pozwolił na usunięcie błędnie sklasyfikowanych latarni. Błędy związane z fragmentami samochodów nie zostały usunięte.

6. PODSUMOWANIE I WNIOSKI

Przeprowadzone badania potwierdziły stawianą hipotezę, że integracja danych pozwoli na bardziej precyzyjne wyznaczenie obiektów: budynków i drzew. Wybrane pole testowe posiadało liczne utrudnienia: duże deniwelacje terenu, obszar o skomplikowanej rzeźbie (kamieniołom) oraz rzekę. Przeprowadzone badania ujawniły, że dane laserowe i fotogrametryczne rzeczywiście są komplementarne i błędy jednej metody mogą być niwelowane drugą metodą. Automatyczne wykrycie kamieniołomu na ortofotomapie jest właściwie niemożliwe, gdyż wartości energii obrazów teksturalnych pokrywają się z wartościami dla zabudowy. Włączenie w proces analizy danych laserowych pozwoliło w sposób oczywisty pozbyć się tego problemu. Z kolei pomiar laserowy posiadał luki w danych źródłowych (patrz Rys. 2 - woda), co mogło zostać uzupełnione informacjami z ortofotomapy. Integracja zNMPT i prawdziwej ortofotomapy pozwoliła także na wyznaczenie drzew (wyeliminowanie błędnie sklasyfikowanych krawężników i latarni).

Na podstawie przeprowadzonych badań można sformułować następujące wnioski:

- 1) Teksturalne filtry Lawsa zastosowane do prawdziwej ortofotomapy wykazują przydatność w procesie wyodrębniania drzew.
- 2) Zaskakująco, problemem okazało się wyznaczenie budynków. Można jednakże przyjąć założenie, że spowodowane to było złą jakością zdjęć – szczegóły sytuacyjne były słabo czytelne w zacienionych partiach obrazu.
- 3) Jako metodę klasyfikacji obrazów teksturalnych przyjęto najprostsza metodę minimalnej odległości. Zastosowanie bardziej wyszukanych algorytmów np. klasyfikację obiektową przyczyniłoby się przypuszczalnie do poprawy wyników.

Podsumowując, przeprowadzone badania ujawniły potencjał tkwiący w integracji danych lidarowych i fotogrametrycznych. Wykorzystanie filtrów Lawsa wymaga dalszych analiz, gdyż na obecnym etapie badań sformułowanie ostatecznych wniosków nie jest jeszcze możliwe.

Praca została wykonana w ramach badań statutowych AGH nr 11.11.150.949

7. LITERATURA

Axelsson P., 1999. Processing of laser scanner data – algorithms and applications. *ISPRS Journal of Photogrammetry & Remote Sensing* 54, s. 138-147.

Axelsson P., 2000. DEM generation from laser scanner data using adaptive TIN models. *International Archives of Photogrammetry and Remote Sensing*, Amsterdam, Vol. XXXIII/4B, s. 110-117.

Eckstein W., Munkelt O., 1995. Extracting objects from digital terrain models. *Proc. SPIE*, 2572, s. 43-51.

Faber A., Förstner W., 1999. Scale characteristic of local autocovariances for texture segmentation. *International Archives of Photogrammetry and Remote Sensing*, Vol. 32, Part 7-4-3 W6.

Kumar S., Ganesan L., 2008. Texture classification using wavelet based Laws energy measure. *International Journal of Soft Computing*, 3 (4), s. 293-296.

Laws K. I., 1980a. *Texture image segmentation*. Ph.D. dissertation, Dept. Of Engineering, University of Southern California.

Laws K. I., 1980b. Rapid texture identification. *Proc. SPIE*, Vol. 238, s. 376-380.

Malina W., 2002. *Podstawy automatycznej klasyfikacji obrazów*. Wydawnictwo PG.

Marmol U., Będkowski K., 2008. Dokładność określenia wysokości drzew na podstawie Numerycznego Modelu Koron Drzew z w wykorzystaniem danych lotniczego skanowania laserowego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol.18.

Paget RD., Longstaff D., 1996. Terrain mapping of radar satellite. *Journal of Electronic Imaging*, 6 (2).

Rangayyan R. M., 2005. *Biomedical Image Analysis*. CRC Press.

Srinivasan G. N., Shobha G., 2008. Statistical Texture Analysis. *Proceedings of world academy of science, engineering and technology*, Vol. 36, s.1264-1269.

TopEye, 2009. <http://www.topeye.com>.

INTEGRATION OF AIRBORNE LIDAR AND PHOTOGRAMMETRIC DATA IN THE PROCESS OF AUTOMATIC OBJECT EXTRACTION

KEY WORDS: data integration, lidar, ortophoto, object extraction

SUMMARY: This paper describes a method of integrating LIDAR data and aerial images in the process of automatic object extraction. Aerial photos are classical method for obtaining spatial information. However, in recent years, LIDAR data has become more and more popular as a source of information. Aerial imagery has the ability to delineate object boundaries, but during feature extraction, the number of objects may be overestimated or underestimated. LIDAR data provide direct information about the height of an object, but have limitations when identifying boundaries. Therefore, we can say that photogrammetric sensors and LIDAR provide complementary data and their integration can improve the quality of the results. This paper presents a study of the integration of photogrammetry and LIDAR in the process of extraction of 3D objects: buildings and trees. Textural filters have been used in the automatic segmentation process. 3D objects have been separated from LIDAR data, as a DSM and DTM difference. The study has revealed the high potential and flexibility of integrated data in the automatic process of object extraction.

dr inż. Urszula Marmol
entice@agh.edu.pl
telefon: +48 12 6172302
fax: +48 12 6173826