

**PORÓWNANIE ALGORYTMÓW RANSAC ORAZ ROSNĄCYCH PŁASZCZYZN
W PROCESIE SEGMENTACJI DANYCH LOTNICZEGO
SKANINGU LASEROWEGO**

**COMPARISON OF RANSAC AND PLANE GROWING ALGORITHMS
FOR AIRBORNE LASER SCANNING DATA SEGMENTATION**

Małgorzata Jarząbek-Rychard, Andrzej Borkowski

Instytut Geodezji i Geoinformatyki, Uniwersytet Przyrodniczy we Wrocławiu

SŁOWA KLUCZOWE: segmentacja, skaniny laserowe, chmura punktów, RANSAC, rosnące płaszczyzny, modelowanie 3D

STRESZCZENIE: W ostatnich latach, wraz z osiągnięciem zdolności operacyjnej i wzrostem dostępności lotniczego skanowania laserowego (LIDAR) nastąpiło również zwiększenie zainteresowania opracowaniami 3D tworzonymi na podstawie danych pozyskanych z wykorzystaniem tej techniki. Jednym z centralnych zagadnień modelowania geoinformacji na podstawie danych LIDAR jest modelowanie zabudowy. W modelowaniu tym główny nacisk kładzie się na automatyzację procesów. Dostępne oprogramowanie komercyjne charakteryzuje się bowiem znacznym poziomem interaktywności – tworzenie modelu wymaga dużego udziału operatora. W procesie trójwymiarowego modelowania zabudowy wyróżnia się na ogół cztery podstawowe etapy, przy czym kluczowym wydaje się etap polegający na segmentacji punktów należących do budynku. W procesie tym ze zbioru zawierającego zarówno punkty obciążone błędami przypadkowymi jak i grubymi wyodrębniane zostają podzbiory punktów reprezentujących (modelujących) poszczególne płaszczyzny. Wynika to z faktu, iż budynki formowane są najczęściej jako kombinacja płaszczyzn w przestrzeni 3D. W pracy przedstawiono analizę dwóch, najczęściej wykorzystywanych w celu segmentacji algorytmów: RANSAC i rosnących płaszczyzn, przy czym w tym ostatnim, wprowadzono modyfikacje, uwzględniające topologię w zbiorze danych. Podano podstawowe informacje dotyczące omawianych metod. Testy numeryczne wykonano z wykorzystaniem zarówno syntetycznych jak i rzeczywistych danych skaningu laserowego. W wyniku przeprowadzonych eksperymentów można stwierdzić, że algorytm RANSAC charakteryzuje się krótkim czasem wykonania segmentacji dla nieskomplikowanych modeli. Potrafi jednak łączyć ze sobą odrębne w rzeczywistości obiekty leżące w tej samej płaszczyźnie; dobrze nadaje się do segmentacji standardowych dachów, złożonych z małej liczby elementów. Algorytm rosnących płaszczyzn jest bardziej odpowiedni dla modeli o większym stopniu skomplikowania. Poprawnie rozdziela odrębne obiekty leżące w tej samej płaszczyźnie. Czas wykonania zależy głównie od liczby punktów w zbiorze – nie zależy od liczby wyodrębnianych płaszczyzn.

1. WSTĘP

Lotniczy skaniny laserowe osiągnął zdolność operacyjną kilka lat temu, jednakże dopiero w ostatnich latach, wraz ze znacznym spadkiem cen na tego typu usługi, szczególnie w warunkach polskich, technologia ta stała się ogólnie dostępna. Jednocześnie zaobserwo-

wać można znaczne zmiany problematyki badawczej związanej ze skanowaniem laserowym. W początkowym okresie badania koncentrowały się wokół problemów rejestracji danych oraz wspólnego wyrównania poszczególnych pasów skanowania i eliminacji błędów, wynikających z procesu pozyskiwania danych. Kolejnym przedmiotem badań była problematyka budowy numerycznych modeli terenu (NMT) i, związanej z tym, filtracji danych skaningowych. Obecnie problemy te są w znacznym stopniu rozwiązane (Vosselman i Maas, 2010), a zagadnieniem kluczowym staje się trójwymiarowe modelowanie obiektów przestrzennych na podstawie nieuporządkowanej chmury punktów; ogólnie mówiąc – modelowanie geoinformacji. Jednym z jego elementów jest modelowanie zabudowy na podstawie danych lotniczego skaningu laserowego. Modelowanie takie stało się możliwe również dlatego, że wzrosła znacznie rozdzielczość skanowania, od początkowo około jednego punktu na metr kwadratowy, do kilku, kilkunastu, a nawet kilkudziesięciu punktów na metr kwadratowy obecnie.

W modelowaniu zabudowy główną uwagę poświęca się automatyzacji procesów. Dostępne oprogramowanie komercyjne charakteryzuje się bowiem znacznym poziomem interaktywności – tworzenie modelu wymaga dużego udziału operatora. Proces modelowania i zastosowane algorytmy zależą w znacznym stopniu od rodzaju dostępnych danych. Najczęściej łączone są dane skaningu oraz dodatkowe informacje z mapy katastralnej, czy też dane skaningu połączone z obrazami wielospektralnymi. Przykładem w tym zakresie może być aktualna praca (Awrangjeb *et al.*, 2010). W procesie trójwymiarowego modelowania zabudowy wyróżnia się na ogół cztery podstawowe etapy:

- identyfikacja zabudowy w chmurze punktów 3D,
- segmentacja punktów należących do budynku,
- ekstrakcja konturu przyziemia budynku,
- rekonstrukcja geometrii i topologii budynku.

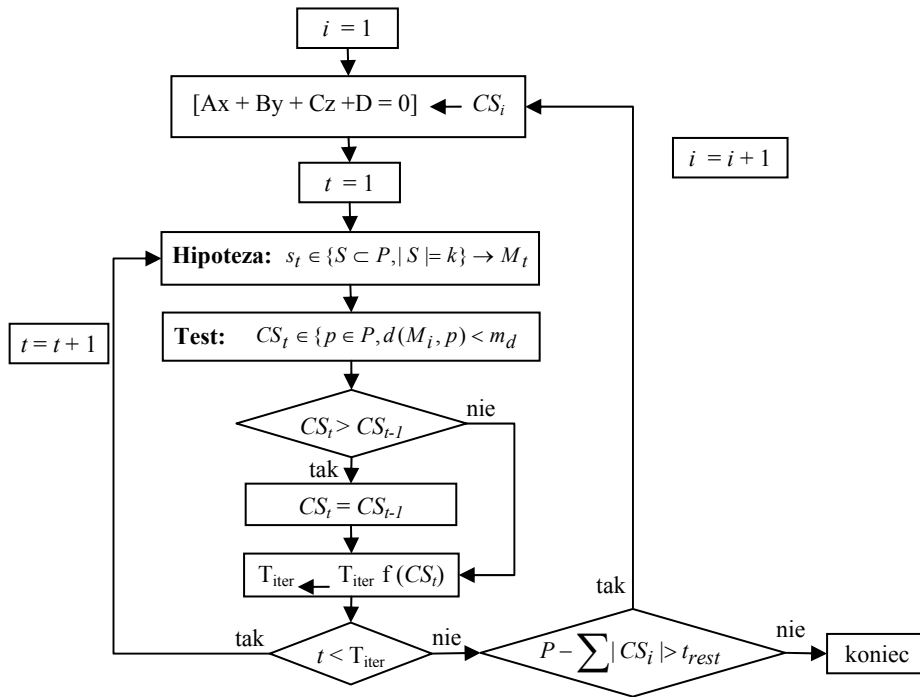
Przegląd metod, algorytmów i rozwiązań możliwych do zastosowania na poszczególnych etapach modelowania podano w pracy (Dorniger i Pfeifer, 2008). Na ostatnim etapie modelowania, budynki formowane są najczęściej jako kombinacja płaszczyzn w przestrzeni 3D. Z tego powodu, szczególnie istotny jest drugi etap procesu modelowania, w którym wyodrębniane zostają podzbiory punktów opisujących (modelujących) poszczególne płaszczyzny. Wykonanie tego zadania komplikuje obecność w zbiorze punktów obarczonych błędami. Na tym etapie wykorzystywane są najczęściej algorytmy: RANSAC, rosnących płaszczyzn, oraz transformacja Hough'a, z ewentualnymi modyfikacjami, przy czym dwie pierwsze z wyżej wymienionych metod są dominujące.

W pracy dokonano analizy algorytmów RANSAC i rosnących płaszczyzn; w tym ostatnim wprowadzono pewne modyfikacje uwzględniające topologię danych. Przeprowadzone testy numeryczne, z wykorzystaniem zarówno syntetycznych jak i rzeczywistych danych LIDAR, umożliwiają dostrzeżenie zalet i ograniczeń algorytmów oraz określenie zakresu ich zastosowań.

2. ALGORYTM RANSAC

Algorytm RANSAC (RANdom SAmple Consensus) pozwala na iteracyjne modelowanie płaszczyzn w zbiorze danych zawierających znaczną (nawet przekraczającą połowę obserwacji) liczbę błędów grubych, czyli punktów nienależących do modelowanej powierzchni. Metoda rozwinięta została początkowo dla celów widzenia komputerowego,

pozwalając na odporną identyfikację obiektów (Fischler, Bolles, 1981). W rozpatrywanym przypadku zaimplementowany algorytm umożliwia wyodrębnienie kolejnych płaszczyzn dominujących, reprezentowanych przez największą liczbę punktów. Zaletą metody jest jej odporność – punkty stanowiące przypadkowe odbicia od powierzchni bądź położone w bliskim sąsiedztwie estymowanej płaszczyzny, lecz należące do innego obiektu nie ulegają błędnej klasyfikacji. Działanie algorytmu (rys. 1) obejmuje dwa podstawowe, iteracyjnie powtarzane kroki: hipotezę oraz test.



Rys. 1. Algorytm RANSAC – diagram aktywności

Z etapem hipotezy związane jest pojęcie najmniejszego zbioru. Jest to najmniejsza liczba k danych niezbędnych do jednoznacznego zdefiniowania założonego modelu geometrycznego. W przypadku ekstrakcji płaszczyzn minimalny zbiór składa się z trzech punktów. Realizacja algorytmu rozpoczyna się od wylosowania wstępnie ustalonej liczby T_{iter} minimalnych zbiorów $s_t(1)$, która w trakcie algorytmu jest sukcesywnie modyfikowana.

$$s_t \in \{S \subset P, |S|=k\} \rightarrow M_t \quad (1)$$

W dalszej kolejności dla każdego ze zbiorów obliczane są parametry modelu M_t (w rozpatrywanym przypadku modelem jest płaszczyzna przechodząca przez trzy punkty). Zidentyfikowany model stanowi hipotezę, która podlega sprawdzeniu w następnym kroku – teście.

Etap testu wymaga ustalenia wartości parametru m_d , określającego maksymalną odległość testowanego punktu od hipotetycznego modelu. Jeżeli punkt spełnia kryterium odległości,

dodany zostaje do tzw. zbioru CS (Consensus Set). W tej pracy zbiór składa się z danych, które uznane zostały za należące do rozpatrywanej płaszczyzny:

$$CS_t \in \{p \in P, d(M_i, p) < m_d\}, \quad (2)$$

$$\text{gdzie} \quad d(M_i, p) \quad (3)$$

określa odległość punktu od założonego modelu (Vosselman, Maas, 2010).

Po wykonaniu testu (2) dla wszystkich danych, wybrany jest kolejny zbiór minimalny i w oparciu o niego powtórzona zostaje sekwencja dwóch kroków – hipotezy i testu. W przypadku znalezienia zbioru CS zawierającego większą liczbę punktów od poprzedniego, dotychczasowy zbiór zastąpiony zostaje liczniejszym i zmodyfikowana zostaje wartość T_{iter} (liczba próbek zbiorów minimalnych):

$$T_{iter} = \frac{\log \varepsilon}{\log(1-q)}, \quad (4)$$

gdzie ε oznacza prawdopodobieństwo identyfikacji niewłaściwej płaszczyzny, a q obliczane jest na podstawie następującego równania (Zuliani, 2009):

$$q = \left(\frac{N_I}{N} \right)^k, \quad (5)$$

w którym:

- N_I – liczba punktów należących do zidentyfikowanej płaszczyzny,
- N – liczba wszystkich punktów należących do wejściowego zbioru danych,
- k – najmniejsza liczba danych pozwalająca na jednoznaczne wyznaczenie modelu.

Po skończonej identyfikacji pierwszej płaszczyzny opisany proces zostaje powtórzony z wyłączeniem punktów do niej zakwalifikowanych. Identyfikacja kolejnych płaszczyzn zostaje zakończona, gdy liczba punktów niedodanych do żadnej z nich jest mniejsza od założonej wartości progowej t_{rest} .

3. METODA ROSNĄCYCH PŁASZCZYZN

Metoda jest uogólnieniem, na przestrzeni \mathfrak{R}^3 , algorytmu rosnących regionów, powszechnie wykorzystywanego w cyfrowym przetwarzaniu obrazów z \mathfrak{R}^2 . Celem algorytmu rosnących płaszczyzn jest ekstrakcja parametrów równania płaszczyzny wraz z identyfikacją punktów do niej należących. Punkty grupuje się na podstawie ustalonych parametrów określających ich wzajemne podobieństwo i położenie. Algorytm obejmuje dwa podstawowe etapy (rys. 2): przygotowanie danych polegające na ustaleniu ich topologii oraz proces identyfikacji i ekspansji płaszczyzn.

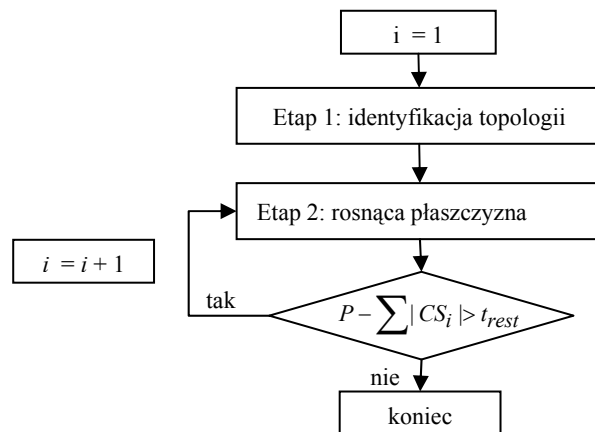
3.1. Identyfikacja topologii

Chmura punktów pomierzonych techniką skaningu laserowego charakteryzuje się brakiem uporządkowanej struktury, co zdecydowanie utrudnia jakiegokolwiek procesy identyfikacji znajdujących się w niej obiektów. Ustalenie topologii w zbiorze pozwala na wstępne opracowanie chmury punktów w celu jej segmentacji. Etap ten obejmuje stworzenie

struktury danych, a następnie wyszukanie dla każdego punktu w zbiorze ustalonej liczby n najbliższych sąsiadów.

Jedną z wielu rozwijanych w ostatnich latach strategii tworzenia hierarchicznej struktury danych jest podział przestrzeni z wykorzystaniem drzew binarnych. K-d (k-dimensjonal) drzewo jest jedną z odmian drzewa binarnego używaną w procesie strukturyzacji przestrzeni trójwymiarowej (Vosselman, Mass, 2009).

Procedura tworzenia kd -drzewa rozpoczyna się od podziału płaszczyzną całego zbioru punktów (korzenia) na dwie półprzestrzenie. W celu osiągnięcia zoptymalizowanej struktury drzewa oraz uniknięcia powstania komórek przestrzeni niezawierających żadnych punktów, płaszczyzna dzieląca wyznaczana jest w oparciu o obliczoną wartość mediany współrzędnych (de Berg *et al.*, 2007). W wyniku takiego podziału otrzymujemy dwa podzbiory o podobnej liczebności. Wskaźnik do listy punktów położonych po lewej stronie płaszczyzny zapamiętywany jest w lewym poddrzewie, wskaźnik do listy punktów znajdujących się po prawej stronie – w poddrzewie prawym. W korzeniu przechowywana jest informacja o parametrach płaszczyzny dzielącej. Rekurencyjnie każde poddrzewo dzielone jest następną płaszczyzną. W przypadku drzewa trójwymiarowego płaszczyzny dzielące wyznaczane są ortogonalnie, względem osi x , osi y oraz osi z . Wybór orientacji płaszczyzny dokonywany jest w wyniku identyfikacji najdłuższego wymiaru dzielonej komórki.




Rys. 2. Algorytm rosnących płaszczyzn. Diagram aktywności

Wykonywanie algorytmu wyszukiwania najbliższego sąsiada dla punktu P z wykorzystaniem struktury $k-d$ drzewa (Moore, 1991) rozpoczyna się określeniem węzła powiązanego z poddrzewem, zawierającym podany punkt. Następnie węzły sprawdzane są kolejno zgodnie z ustaloną wcześniej hierarchią. Pierwszy zidentyfikowany punkt uważany jest wstępnie za najbliższy punkt sąsiedni. Odległość między nim a punktem P wyznacza promień sfery z punktem środkowym usytuowanym w punkcie P . Jeżeli w obrębie sfery zostanie zidentyfikowany inny punkt, zastępuje on dotychczasowego najbliższego sąsiada oraz określa nową sferę. Proces zostaje przerwany, gdy wyznaczona sfera nie zawiera żadnego punktu z wyjątkiem P .

Z identyfikacją topologii związany jest proces przygotowania danych (rys. 3). Na podstawie wyodrębnionego zbioru najbliższych sąsiadów, dla każdego punktu wpasowy-

wana jest płaszczyzna lokalna. Metoda estymacji odpornej powala na uniknięcie błędów wpasowania płaszczyzny, w sytuacji, gdy w zbiorze najbliższych sąsiadów znajdują się punkty nienależące do danej powierzchni, lecz położone na pobliskich obiektach (np. ściana budynku i przylegające do niej gałęzie drzew). Następnie obliczana jest średnia odległość pomiędzy płaszczyzną lokalną a wszystkimi punktami użytymi do jej estymacji. Wartość ta pozwala określić dokładność wpasowania płaszczyzny lokalnej. Po zakończeniu procesu przygotowania danych, dla każdego punktu w zbiorze przechowywane są informacje zawierające wskaźniki do n liczby najbliższych sąsiadów, parametry płaszczyzny lokalnej, oraz średnie odległości punktów od płaszczyzny.




Rys. 3. Identyfikacja topologii oraz proces przygotowania danych

3.2. Rosnąca płaszczyzna

Proces identyfikacji płaszczyzny rozpoczyna się od wyszukania jednego punktu należącego do danego obiektu. W niniejszej pracy odbywa się to w wyniku analizy miar wpasowania lokalnych płaszczyzn. Punktem początkowym jest niezakwalifikowany dotąd punkt, dla którego średnia odległość pomiędzy punktami sąsiednimi a estymowaną przez nie płaszczyzną jest najmniejsza. Parametry bieżącej płaszczyzny podlegającej wzrostowi równe są parametrom lokalnie wpasowanej płaszczyzny punktu początkowego.

Następnie wszystkie punkty określone w poprzednim kroku mianem najbliższych sąsiadów wybranego punktu sprawdzane są pod względem sąsiedztwa. Jeżeli odległość między pierwszym punktem sąsiednim, a punktem początkowym jest mniejsza od założonej wartości progowej, punkt ten poddany zostaje kolejnym testom. Sprawdzane jest kryterium odległości od rosnącej płaszczyzny oraz różnicy pomiędzy wektorami normalnymi rosnącej płaszczyzny oraz lokalnej płaszczyzny sprawdzanego punktu. Drugie

kryterium ma istotne znaczenie w miejscach, gdzie stykają się dwie, nachylone do siebie płaszczyzny (np. kalenica dachu). Porównanie wektorów normalnych pozwala uniknąć połączenia jednej połaci dachu z leżącymi w pobliżu styku punktami, należącymi do drugiej z nich. Punkt, który spełnia wszystkie założone warunki dodany zostaje do rosnącej płaszczyzny, a następnie pierwszy z jego najbliższych sąsiadów zostaje poddany powyższym testom. W momencie, gdy badany punkt nie spełnia któregoś z kryterium, algorytm cofa się powracając do sprawdzania następnego z sąsiadów (rys. 4). Jeżeli żaden punkt nie spełnia podanych warunków, parametry płaszczyzny są obliczane kolejny raz przy użyciu wszystkich punktów do niej dodanych. Następnie nowy punkt początkowy zostaje wyszukany spośród punktów dotąd nie zakwalifikowanych i rozpoczęty zostaje proces wzrostu nowej płaszczyzny. Kolejne płaszczyzny identyfikowane są do momentu, gdy liczba punktów, niedodanych do żadnej z nich, jest mniejsza od założonej wartości progowej.



Rys. 4. Proces identyfikacji oraz ekspansji płaszczyzny

4. TESTY NUMERYCZNE

W celu oceny zastosowania zaimplementowanych algorytmów przeprowadzone zostały testy numeryczne, wykonane z wykorzystaniem zarówno syntetycznych jak i rzeczywistych danych skaningu laserowego.


4.1. Dane syntetyczne

Stworzenie syntetycznego modelu, o znanych parametrach geometrycznych, pozwala określić dokładność identyfikacji płaszczyzn. W tym celu wygenerowany został zbiór punktów należących do dwuspadowego dachu (w sztucznym modelu założono gładkość powierzchni, bez uwzględniania parametrów szorstkości pokryć dachowych) o kącie nachylenia 30° i ustalonych równaniach płaszczyzn obu połaci. Rozdzielczość zbioru wynosiła 10 punktów na metr kwadratowy. 10 procent danych obciążonych zostało losowo wybranymi wartościami błędów o wartościach od 30 cm do 1 m. Rezultaty segmentacji przedstawiono w tabeli 1 oraz na rysunku 5. Oba algorytmy pozwoliły wyznaczyć bardzo dokładnie orientację położenia połaci dachowych, niemniej jednak czas wykonywania algorytmu RANSAC jest niemal trzykrotnie krótszy niż w przypadku segmentacji metodą rosnące płaszczyzny. Wadą algorytmu RANSAC jest włączenie do zbiorów połaci dachowych punktów błędnych, położonych w tej samej płaszczyźnie, jednak nienależących do dachu.

Tab. 1. Model syntetyczny: porównanie rezultatów segmentacji

algorytm	połacie	pkt	d_{sr} [m]	$\delta_{d_{sr}}$ [m]	α [°]	czas [s]	ΔA	ΔB	ΔC	ΔD
RANSAC	lewa	509	0,003	0,007	29,8	0,156	0,000000	0,000159	0,010830	0,005113
	prawa	504	0,002	0,005	29,8		0,000000	0,000157	0,011636	0,005902
rosnące płaszczyzny	lewa	476	0,003	0,005	29,8	0,438	0,000000	0,000027	0,010905	0,004019
	prawa	485	0,003	0,004	29,8		0,000000	0,000168	0,011244	0,005718


d_{sr} – średnia odległość punktów od estymowanej płaszczyzny,
 $\delta_{d_{sr}}$ – odchylenie standardowe wyznaczone na podstawie średnich odległości,
 $\Delta A, \Delta B, \Delta C, \Delta D$ – różnice pomiędzy wartościami parametrów płaszczyzn syntetycznych oraz zidentyfikowanych.




Rys. 5. Model syntetyczny: porównanie rezultatów segmentacji

4.2. Dane rzeczywiste

Druga grupa testów numerycznych przeprowadzona została na danych rzeczywistych uzyskanych w wyniku pomiarów techniką skaningu laserowego. Rysunek 6 przedstawia budynek o prostym, dwuspadowym dachu, oraz wycinek powierzchni terenu. Algorytm RANSAC prawidłowo zakwalifikował punkty podłoża do jednego zbioru (rosnące płaszczyzny podzieliły je na kilka grup), lecz błędnie połączył połąć dachu z leżącymi w tej samej płaszczyźnie punktami należącymi do linii energetycznej. Drugi zbiór danych testowych obrazuje budynek o dachu bardziej skomplikowanym –zawierającym wiele małych płaszczyzn formujących lukarny (rys. 7). Algorytm rosnących płaszczyzn umożliwił prawidłowe wydzielenie punktów należących do każdego z elementów. W wyniku segmentacji metodą RANSAC identyfikacja dużych płaszczyzn przebiegła prawidłowo, jednakże zamiast lukarny wyznaczone zostały zbiory zawierające największą liczbę punktów położonych w tej samej płaszczyźnie.



Rys. 6. Dane rzeczywiste. RANSAC – połączenie połąć dachu z linią energetyczną



Rys. 7. Dane rzeczywiste. Identyfikacje lukarny: nieprawidłowa (RANSAC), poprawna (rosnące płaszczyzny)

Analiza rezultatów segmentacji obiema metodami poszerzona została o zestawienie czasu wykonywania algorytmów, przetwarzających zbiory danych o różnych rozmiarach i różnej liczbie płaszczyzn (tab. 2). Zaobserwować można zależność pomiędzy rozmiarem zbioru i wzrastającą liczbą zidentyfikowanych w nim płaszczyzn, a różnicą czasu wykonywania algorytmów. Dla prostych modeli RANSAC umożliwia wykonanie segmentacji zdecydowanie szybciej niż algorytm rosnących płaszczyzn. Jednakże, w przypadku zbiorów o większym stopniu skomplikowania sytuacja ta ulega odwróceniu.

Tab. 2. Zestawienie czasu wykonywania algorytmów

liczba punktów	RANSAC		SURFACE GROWING	
	liczba płaszczyzn	czas [s]	liczba płaszczyzn	czas [s]
1110	2	0,16	2	0,44
1494	7	0,33	7	1,52
1767	6	0,55	9	1,48
1916	11	2,39	8	1,98
7324	20	11,12	27	3,44

5. PODSUMOWANIE I WNIOSKI KOŃCOWE

W pracy przeprowadzono analizę sprawności algorytmu RANSAC i autorskiego, zmodyfikowanego algorytmu rosnących płaszczyzn, zastosowanych w celu segmentacji danych lotniczego skaningu laserowego. Proces segmentacji pozyskanego zbioru punktów jest niezbędnym etapem tworzenia wizualizacji 3D, znajdujących powszechne zastosowanie w wielu dziedzinach (jak np. tworzenie wirtualnych modeli miast, czy też inwentaryzacja obiektów przemysłowych). W wyniku zrealizowanych eksperymentów numerycznych można stwierdzić, że algorytm RANSAC charakteryzuje się krótkim czasem wykonania segmentacji dla nieskomplikowanych modeli; dobrze nadaje się do segmentacji standardowych dachów, złożonych z małej liczby elementów. Wadą jest możliwość łączenia ze sobą odrębnych obiektów leżących w tej samej płaszczyźnie. Algorytm rosnących płaszczyzn jest odpowiedniejszy dla bardziej skomplikowanych modeli. Poprawnie rozdziela obiekty leżące w tej samej płaszczyźnie, lecz wymaga dodatkowego czasu na odpowiednie przygotowanie danych. Całkowity czas wykonywania algorytmu zależy głównie od liczby punktów w zbiorze – nie zależy od liczby wyodrębnianych płaszczyzn. Reasumując, można stwierdzić, że w zadaniach segmentacji należy preferować algorytm rosnących płaszczyzn, bądź wyposażyć program w inteligentny moduł, dobierający odpowiedni algorytm, w zależności od struktury danych i stopnia skomplikowania modelowanych obiektów.

6. LITERATURA

Awrangjeb M., Ravanbakhsh, M., Fraser, C. S., 2010. Automatic detection of residential buildings using LIDAR data and multispectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65 (2010), 457–467.

Berg M. de, Kreveld M. van, Overmars M., Schwarzkopf O., 2007. *Geometria obliczeniowa*. Wydawnictwo Naukowo-Techniczne, Warszawa, s. 119–139.

Dorniger P., Pfeifer N., 2008. A comprehensive automated 3D approach for building extraction, reconstruction and regularization from air borne laser scanning point cloud. *Sensors*, vol. 8, 7323–7343.

Fischler, A., Bolles, C., 1981. *Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography*. Communications of the ACM, 24(6), s. 381–395.

Moore A.W., 1991. *An introductory tutorial on k-D trees. Extract from PhD Thesis: Efficient Memory-based Learning for Robot Control*. University of Cambridge, s. 6.5–6.9.

Vosselman G., Maas, H-G., 2010. *Airborne and terrestrial laser scanning*. Whittles Publishing, Dunbeath, s. 58–75, 317.

Zuliani M., 2009, *RANSAC*. <http://vision.ece.ucsb.edu/~zuliani/Research/RANSAC/docs/>

COMPARISON OF RANSAC AND PLANE GROWING ALGORITHMS FOR AIRBORNE LASER SCANNING DATA SEGMENTATION

KEY WORDS: segmentation, laser scanning, point cloud, 3D modeling

SUMMARY: In recent years, the LIDAR technique has undergone fast development. The increasing access and operating ability caused a growing interest in 3D processing of data acquired by LIDAR. One of the main tasks of geo-information modeling is to create virtual city models. As the available commercial softwares require a high level of user interactivity, the crucial issue of modeling is its automation. There are four main steps that comprise virtual building extraction. One of them, building point cloud segmentation, appears to be the core part of the whole modeling process. Segmentation allows partitioning of a data set, that contains points biased by random and gross errors, into smaller sets which represent different planes. This arises from the fact, that buildings are formed by a combination of planes in 3D space. The paper presents an analysis of two algorithms that are most commonly applied to segmentation: RANSAC and plane growing. The latter is modified, taking into consideration topology between points. The essential information about both algorithms is presented. Numerical tests based on synthetic and real laser scanning data are executed. It is inferred from the experiments that the RANSAC algorithm features short time performance for simple models. However, at times it merges different objects lying in the same plane. The algorithm is suited well for segmentation of standard roofs that contain small number of elements. The plane growing algorithm is more suitable for more complicated models. It separates different objects situated in the same plane. Time performance depends mostly on the number of points within a data set; it is not affected by the number of identified planes.

mgr inż. Małgorzata Jarzabek-Rychard
e-mail: malgorzata.jarzabek-rychard@up.wroc.pl
telefon: +71 3205687

dr hab. inż. Andrzej Borkowski
e-mail: andrzej.borkowski@up.wroc.pl
telefon: +71 3205609