

## OPRACOWANIE I OCENA SKUTECZNOŚCI DZIAŁANIA ALGORYTMU SEGMENTACJI SŁUPÓW TRAKCYJNYCH POMIĘRZONYCH TECHNIKĄ MOBILNEGO SKANINGU LASEROWEGO

### AUTOMATIC EXTRACTION OF TRACION POLES USING MOBILE LASER SCANNING DATA

Elżbieta Pastucha, Małgorzata Słota

AGH w Krakowie, Wydział Geodezji Górniczej i Inżynierii Środowiska, Katedra  
Geoinformacji, Fotogrametrii i Teledetekcji Środowiska

SŁOWA KLUCZOWE: mobilny skaningu laserowy, chmura punktów, detekcja obiektów, klasyfikacja, infrastruktura kolejowa

STRESZCZENIE: W artykule przedstawiono metodę detekcji kolejowych słupów trakcyjnych w oparciu o dane pochodzące ze skaningu laserowego. Głównymi założeniami podczas opracowywania algorytmu były uniwersalność metody, niezależność od parametrów definiowanych przez użytkownika oraz wysoki stopień automatyzacji. Z uwagi na objętość zbiorów danych ze skaningu laserowego i związanych z tym problemów z efektywnym przetwarzaniem chmur punktów, w proponowanym algorytmie obliczenia podzielono na dwa etapy. W etapie pierwszym wyznaczane są regiony, w których potencjalnie mogą występować słupy trakcyjne. Natomiast w etapie drugim weryfikowane jest położenie słupów w obszarach potencjalnych oraz wyszukiwane są punkty zarejestrowane na powierzchniach słupów. W celu uproszczenia obliczeń w pierwszym etapie analizowana jest różnica w gęstości punktów, znajdujących się bezpośrednio nad torami kolejowymi. W etapie drugim każdy z potencjalnych regionów analizowany jest indywidualnie. Po pierwsze wyznaczane są podzbiory punktów z wykorzystaniem kryterium wysokości. W podzbiórach w sposób iteracyjny odrzucane są punkty, których odległość do średniego położenia punktów w podzbiórce jest większa od przyjętej wielkości granicznej. W ten sposób usuwane są odbicia od obiektów znajdujących się w sąsiedztwie słupów takich jak drzewa czy lampy, natomiast zachowywane są punkty należące do poszukiwanych słupów trakcyjnych. Przeprowadzone badania potwierdziły skuteczność opracowanego algorytmu. Proponowana metoda pozwoliła na detekcję wszystkich rodzajów słupów, znajdujących się w obszarze zainteresowania.

#### 1. WSTĘP

W ostatnich latach w Polsce rozpoczęto proces modernizacji transportu kolejowego. Niezbędna okazała się inwentaryzacja stanu faktycznego linii kolejowych oraz obiektów i urządzeń infrastruktury kolejowej. Mając na uwadze bezpieczeństwo użytkowników, geometria linii kolejowych powinna być wyznaczona z wysoką dokładnością. Obecnie najbardziej odpowiednią do tego celu techniką pozyskiwania danych jest bez wątpienia skaningu laserowy, który w bardzo krótkim czasie pozwala uzyskać duże zbiory danych z bardzo wysoką dokładnością.

Automatyczne budowanie trójwymiarowych modeli obiektów kolejowych na podstawie chmury punktów z wykorzystaniem popularnych metod np. poprzez budowę siatki trójkątów nie sprawdza się, w przypadku skaningu linii kolejowych, z uwagi na wysoki stopień skomplikowania modelowanego obszaru. Niezbędne jest więc stworzenie metod dedykowanych modelowaniu obiektów infrastruktury kolejowej.

W artykule zaprezentowano metodę detekcji kolejowych słupów trakcyjnych w oparciu o dane pochodzące z mobilnego skaningu laserowego.

## 2. PRZEGLĄD ISTNIĄCYCH ALGORYTMÓW

Razem z powstaniem techniki skanowania laserowego pojawił się problem przetwarzania ogromnej ilości danych przez nią dostarczanych. Początkowo zaczęły się pojawiać rozwiązania pomagające uprościć i zautomatyzować wstępne przetwarzanie. Wlicza się w to wszelkiego rodzaju filtracje szumów czy niepotrzebnych danych, następnie wykrywanie gruntu i tworzenie Numerycznych Modeli Terenu, a ostatecznie klasyfikacje na podstawie parametrów położenia przestrzennego czy parametrów radiometrycznych. Jednak taka automatyzacja nie wystarcza do końcowego przetwarzania. Od kilkunastu lat pracuje się nad automatycznym wykrywaniem i modelowaniem obiektów z chmury punktów. Pierwsze próby wykrywania obiektów rozpoczęto od segmentacji. Jest to proces polegający na grupowaniu punktów, których otoczenie spełnia założone kryteria (Briese *et al.* 2008; Huang *et al.*, 2001; Lai *et al.*, 2010; Mehdi-Souzani *et al.*, 2010; Sithole *et al.*, 2003). Na tej zasadzie wykrywane są płaszczyzny, gdzie poprzez analizę otoczenia punktu obliczana jest jego normalna – jeżeli normalne punktów są jednakowe, punkty klasyfikowane są jako należące do jednej płaszczyzny. Podobnie wykrywa się również spady, nachylenia terenu, oraz krawędzie (jako przecięcie płaszczyzn) (Vosselman, 2009). Wykrywanie tych ostatnich stanowi potężną część aktualnie prowadzonych badań (Gumhold *et al.*, 2001; Pauly *et al.*, 2003; Weber *et al.*, 2010a; Weber *et al.*, 2010b; Yogeswaran *et al.*, 2009).

W przeciągu ostatnich lat zaczęto coraz częściej tworzyć algorytmy dedykowane konkretnym obiektom. Opisano procesy wykrywające podstawowe figury geometryczne, takie jak stożki, cylindry, sześciiany, prostopadłości, sfery i inne. Algorytmy te powinny dobrze działać w warunkach czystych, gęstych chmur punktów i najczęściej są testowane na danych ze skanowania małych przedmiotów przemysłowych (Mehdi-Souzani *et al.*, 2010; Yogeswaran *et al.*, 2009).

Wykrywanie obiektów pionowych, smukłych opisano w kilku publikacjach (Brenner, 2009; Golovinskiy *et al.*, 2009; Lehtomäki *et al.*, 2010; Pu *et al.*, 2011; Shi *et al.*, 2008). Claus Brenner (Brenner, 2009) opisał sposób wykrywania słupów na potrzeby wspomagania kierowcy. Autor zaprezentował podejście zakładające, że wokół słupa, pokrytego gęstą siatką punktów, znajduje się bufor w którym nie ma żadnych punktów. Obiekt jest analizowany na kilku poziomach wysokościowych. Jeżeli punkty w środku spełnią założenia, obiekt jest klasyfikowany jako słup. W ten sposób odnalezione zostają wszystkie elementy wysmukłe, jednak algorytm ma swoje wady i często, jak pisze autor, klasyfikuje drzewa jako słupy.

Również Lehtomäki *et al.* (Lehtomäki *et al.*, 2010) zaprezentowali swój algorytm do wykrywania obiektów cylindrycznych. Przetwarzanie opiera się na założeniu, że w rzutach przekrojów poziomych chmury, obiekty te będą miały powtarzający się kształt, w który łatwo jest wpasować okrąg. Wykrywając takie miejsca na kolejnych przekrojach, wykonując kolejne segmentacje i klasyfikacje, możliwym jest wykrycie słupa, znaku drogowego, czy też drzewa.

Wykrywaniem obiektów (w tym obiektów smukłych) na chmurach pochodzących z naziemnego i lotniczego skaningu laserowego zajęli się Golovinskiy *et al.* (Golovinskiy *et al.*, 2009). Wykrywanie odbywa się w kilku etapach. Najpierw wykrywane są potencjalne miejsca położenia obiektu, przy założeniu, że usunięto wszystkie punkty należące do terenu i w związku z czym, w tym miejscu jest większa gęstość punktów. Następnie wykonywany jest iteracyjny proces segmentacji i klasyfikacji, gdzie podstawą jest zestaw danych treningowych. System ma za zadanie wykrywać obiekty takie jak znaki, słupy, również samochody i inne obiekty znajdujące się w obrębie drogi. Wynikowy algorytm pozwala wykryć 65% szukanych obiektów.

Pu *et al.* (Pu *et al.*, 2011) pokazują swój system wykrywania słupów. W pierwszym etapie odfiltrowane są punkty terenu i punkty oderwane od terenu, tak żeby zmniejszyć ilość analizowanych punktów. Następnie wybierane są z grubsza miejsca, gdzie może znajdować się słup. Miejsce możliwego wystąpienia słupa jest dzielone na małe poziome klastry, gdzie w punkty wpasowywane są prostokąty. Jeżeli różnice pomiędzy środkiem i wielkością sąsiednich prostokątów nie przekraczają założonych norm punkty są klasyfikowane jako słup.

Słupy trakcyjne, których wykrywanie stanowi temat tej publikacji, zwykle mają kształt ściętego ostrosłupa. Często można spotkać się ze słupami zbudowanymi z kratownicy czy dwuteownika, dodatkowo słupy ulegają dużym deformacjom, przesunięciom, pochyleniom. Wpasowanie w nie konkretnego kształtu jest praktycznie niemożliwe. Ze względu na konieczność przetwarzania ogromnej ilości danych i szczególne cechy słupów trakcyjnych, opisane w wyżej wymienionych publikacjach algorytmy byłyby mało skuteczne i niezwykle czasochłonne. Zatem potrzebny jest algorytm dedykowany, konkretnie wykrywaniu słupów trakcyjnych w chmurze punktów pozyskanej ze skaningu mobilnego.

### 3. OPIS PROPONOWANEGO ALGORYTMU

Proponowany w tym artykule algorytm zakłada, iż dostępne są następujące dane wejściowe: chmura punktów ze sklasyfikowanym terenem oraz przybliżone położenie osi torów. W przypadku skaningu mobilnego przybliżona oś torów może być pozyskana bezpośrednio z pomiarów GPS.

Ze względów praktycznych związanych z efektywniejszym przetwarzaniem chmury punktów zdecydowano się na podział obliczeń na dwa etapy. Etap pierwszy obejmuje wstępne przetwarzanie danych, mające na celu wykrywanie obszarów, w których mogą potencjalnie występować słupy trakcyjne. Natomiast etap drugi wiąże się z właściwą detekcją punktów zarejestrowanych na słupach trakcyjnych.

### 3.1. Wyznaczenie obszarów potencjalnych

Budowa algorytmu została oparta na zależności pomiędzy wzrostem gęstości chmury punktów a położeniem słupów trakcyjnych. Ponieważ gęstość chmury punktów może również znacznie wzrastać w miejscach występowania innych obiektów takich jak lampy czy roślinność, zdecydowano, iż wstępna analiza powinna bazować na punktach leżących bezpośrednio nad torami kolejowymi. W związku z tym w pierwszym kroku wyznaczany jest podzbiór punktów o wysokości od 5.5m do 8m ponad terenem, znajdujących się sytuacyjnie w odległości mniejszej niż 1m od przybliżonej osi torów. W ten sposób wybór zawężony został do punktów zarejestrowanych na ramionach słupów trakcyjnych oraz do trakcji kolejowej. Rozmiar bufora został tak dobrany, żeby wykluczyć punkty na obiektach znajdujących się w pobliżu skrajni kolejowej.

W następnym kroku wyznaczana jest macierz gęstości podzbioru punktów. Macierz powstaje poprzez nałożenie na chmurę regularnej siatki (w płaszczyźnie XY) i zliczenie ilości punktów w każdym jej oczku (komórce macierzy). W przeprowadzonych badaniach przeanalizowano wpływ wielkości komórki, dla której obliczana jest gęstość na ilość poprawnie wyznaczonych obszarów potencjalnych. Wykazano, iż najlepsze rezultaty można uzyskać dla wielkości 0.5m i 0.7m, co jest związane z wielkością przekroju poprzecznego poszukiwanych obiektów. Szczegółowe wyniki zamieszczono w rozdziale 5.

Ponieważ wartość gęstości punktów znacznie wzrasta w miejscach występowania ramion słupów w porównaniu do lokalnego otoczenia, w kolejnym etapie dla każdej komórki macierzy obliczana jest różnica pomiędzy gęstością w danej komórce a średnią gęstością najbliższych komórek według wzoru (1):

$$R_x = \left| \rho_x - \frac{1}{8} \cdot \sum_{i=1}^8 \rho_{s_i} \right| \quad (1)$$

gdzie:  $R_x$  - różnica gęstości punktów dla komórki  $x$ ,

$\rho_x$  - gęstość punktów w komórce  $x$ ,

$\rho_{s_i}$  - gęstość punktów w komórkach sąsiednich.

Wyznaczenie obszarów potencjalnych odbywa się poprzez wybór maksymalnych wartości obliczonej według wzoru macierzy różnic gęstości. Ponieważ jednym z głównych założeń algorytmu jest uniwersalność i niezależność od parametrów definiowanych przez użytkownika, postanowiono definicję wielkości progowej oprzeć na parametrach statystycznych macierzy różnic gęstości, tzn. na wielkości średniej niezerowej różnicy gęstości oraz na odchyleniu standardowym. Próg określony został według wzoru (2):

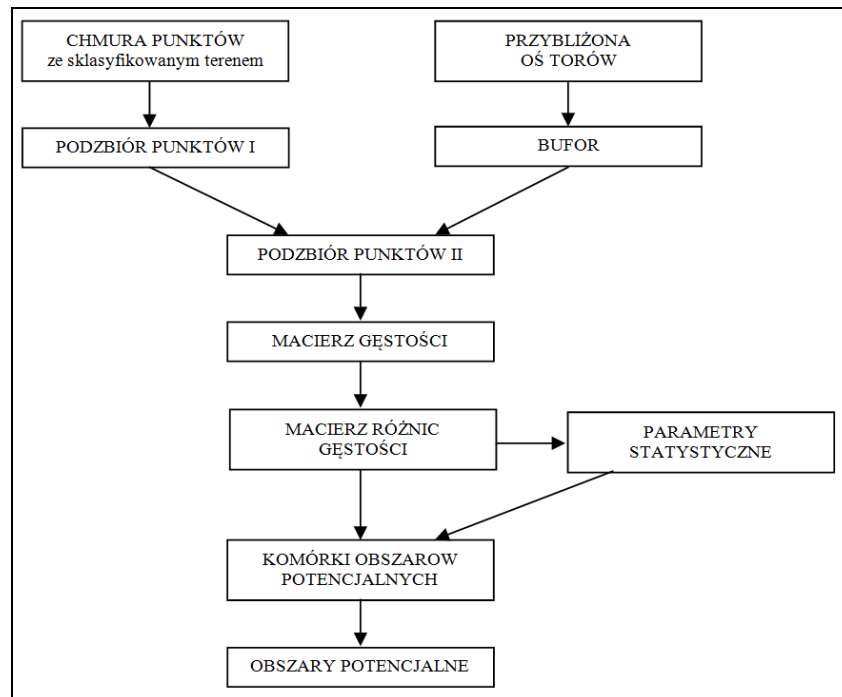
$$P = R_{sr} + 2\sigma_R \quad (2)$$

gdzie:  $R_x$  - wielkość progu,

$R_{sr}$  - średnia niezerowa różnica gęstości punktów,

$\sigma_R$  - odchylenie standardowe.

W wyniku progowania macierzy różnic gęstości wyznaczone są komórki potencjalne. Ostatnim krokiem podczas analizy wstępnej jest grupowanie komórek potencjalnych w obszary potencjalne. Schemat blokowy przedstawiający proces analizy wstępnej zamieszczono na rysunku 1.




Rys. 1. Schemat wyznaczania obszarów potencjalnych

### 3.2. Detekcja położenia słupów trakcyjnych

Podobnie jak w przypadku analiz wstępnych w celu redukcji liczby obliczeń w pierwszym kroku wybierane są podzbiory punktów na podstawie wyznaczonych obszarów potencjalnych. Każdy z potencjalnych regionów analizowany jest indywidualnie. Do badanego podzbioru zaliczane są punkty położone sytuacyjnie w odległości mniejszej niż 5m od danego centrum obszaru potencjalnego oraz jednocześnie leżące na wysokości od 3.5 do 4.5m ponad terenem. Wartości granic wysokościowych związane są ściśle z wysokością słupów trakcyjnych i próbą maksymalnego odfiltrowania licznie występujących obiektów niskich np. roślinności.

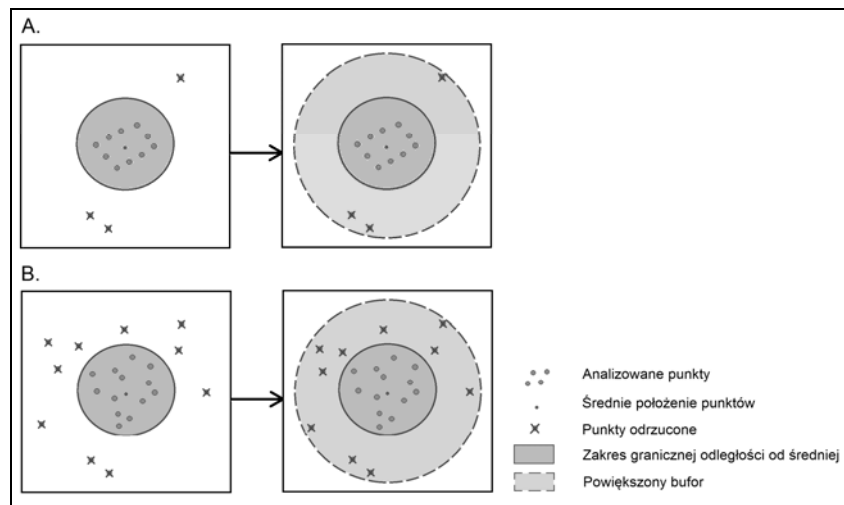
Następnie obliczane jest średnie położenie punktów w podziorze. Detekcja punktów należących do słupów trakcyjnych odbywa się w sposób iteracyjny. Ponieważ liczba równocześnie analizowanych punktów została znacznie zredukowana, wprowadzenie iteracji do obliczeń nie wpływa zasadniczo na wydajność algorytmu. Analizowane są odległości pomiędzy punktami a wyznaczonym średnim położeniem. Jeżeli w podziorze wstępują punkty położone dalej niż 50 cm od średniej, to w sposób iteracyjny punkty te są

usuwane i liczona jest nowa średnia do momentu gdy wszystkie punkty znajdują się w półmetrowym buforze (rys. 2).



Rys. 2. Wyznaczanie środka słupa trakcyjnego

Następnie sprawdzany jest warunek liczebności punktów zakwalifikowanych jako słup w stosunku do liczby punktów znajdujących się w najbliższym sąsiedztwie (bufor o promieniu 1 m). Poprzez analizę tych dwóch wielkości wykluczone zostają obiekty tj. drzewa błędnie sklasyfikowane jako słupy (rys. 3).



Rys. 3. Analiza liczebności punktów:

A) przykład poprawnie wykrytego słupa; B) przykład, gdy obiekt będący np. drzewem został sklasyfikowany jako słup trakcyjny

Na końcu wszystkie punkty, leżące w półmetrowym cylindrze wokół obliczonego średniego położenia punktów klasyfikowane są jako słup trakcyjny.

#### 4. CHARAKTERYSTYKA OBSZARU TESTOWEGO I DANYCH WYKORZYSTANYCH W BADANIACH

Dane wykorzystywane w badaniach pozyskano systemem skaningu mobilnego Riegl VMX-250 zamontowanego na samochodzie umieszczonym w tylnej części otwartego składu kolejowego. System składa się z dwóch skanerów ułożonych prostopadłe do siebie i pod kątem  $45^\circ$  do kierunku osi jazdy, skanujących w przekrojach nachylonych do poziomu o  $55^\circ$ , oraz czterech aparatów cyfrowych. Pomiar punktu wykonywany był co 7-8 mm na odległości 2 m, przekrój co 20 cm. W rezultacie osiągnięto gęstość ok.  $700 \text{ pkt/m}^2$  w obrębie torowiska.


Obszar testowy przyjęty na potrzeby niniejszych badań obejmował pas 1,5 km na trasie Kraków – Warszawa, fragment w Smrokowie pomiędzy Słomnikami a Miechowem.

Na analizowanym odcinku, przy torze którym poruszał się pociąg, znajduje się 26 słupów trzech rodzajów (rys.4 i 5):

- słup kratowy przestrzenny ze skratowaniem przekątniowym (12),
- słup dwuteowy betonowy (11),
- słup betonowy prostopadłościenny (3).



Rys. 4. Słup dwuteowy betonowy (a), słup betonowy prostopadłościenny (b), słup kratowy przestrzenny ze skratowaniem przekątniowym (c)



Rys. 5. Fragment chmury punktów obejmującej słup trakcyjny, kolor nadany w zależności od intensywności odbicia

## 5. WYNIKI

Skuteczność algorytmu została sprawdzona na obszarze testowym zawierającym 3 rodzaje słupów trakcyjnych. Przeprowadzone zostały badania wpływu rozmiaru komórki macierzy, dla której wyznaczana jest gęstość punktów, na ilość poprawnie wyznaczonych obszarów potencjalnych. Analizę wykonano dla sześciu różnych rozmiarów komórek: 20x20cm, 30x30cm, 40x40cm, 50x50cm, 70x70cm oraz 1x1m. Dla każdej z tych wartości wyznaczone zostały macierze gęstości, macierze różnic gęstości i obliczone zostały parametry statystyczne i wielkość progu. Następnie dla każdego słupa trakcyjnego odczytana została wielkość różnicy gęstości i porównana została z parametrami statystycznymi całej macierzy. Sumaryczne wyniki z podziałem na rodzaje słupów zamieszczono na rysunku 6. W tabeli 1 przedstawiono wyniki wstępnej analizy z uwzględnieniem wpływu wielkości komórki, dla której liczona jest gęstość i różnica gęstości punktów.

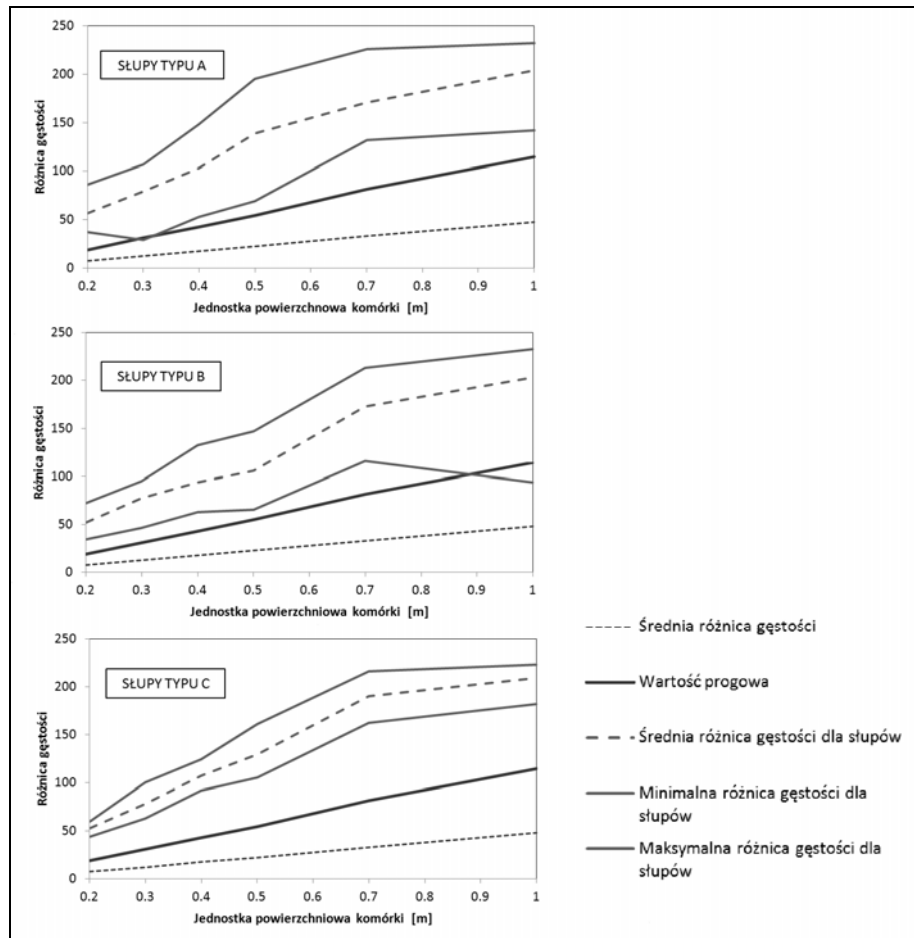
Tabela 1. Wpływ rozmiar jednostki powierzchniowej na liczbę poprawnie wyznaczonych obszarów potencjalnych

	Wielkość komórki [m]					
	0.2	0.3	0.4	0.5	0.7	1.0
Próg	19	31	43	55	81	114
Liczba wykrytych komórek obszarów potencjalnych	228	123	76	64	56	48
Liczba poprawnie wykrytych obszarów potencjalnych	26	25	26	26	26	25

Na podstawie rysunku 6 można wnioskować, iż największy wzrost gęstości punktów w stosunku do otoczenia zarejestrowano dla słupów betonowych prostopadłościennych (typu C). Z badań wynika, że detekcja tego rodzaju słupów jest możliwa dla wszystkich analizowanych jednostek powierzchni. Jednak liczba słupów typu C, biorących udział




w analizie jest zbyt mała, żeby sformułować ogólny wniosek. Dalsze analizy muszą być przeprowadzone na większym zbiorze danych w celu potwierdzenia wyników. Najlepsze rezultaty przy detekcji obszarów potencjalnych dla wszystkich rodzajów słupów uzyskano dla wielkości komórki 50 i 70 cm. Dla tych jednostek wszystkie regiony, w których występują słupy, zostały prawidłowo wykryte przy niedużej liczbie obszarów dodatkowych, błędnie zakwalifikowanych (tabela 1). Przebieg linii kolejowej z zaznaczonymi obszarami potencjalnymi, wyznaczonymi dla komórki 50x50 cm przedstawia rysunek 7. Dla tej jednostki powierzchniowej niepoprawnie wyznaczone zostały dwa obszary, w których słupy nie występują, jednak gęstość punktów ponad torami kolejowymi wzrasta z powodu występujących połączeń trakcji kolejowych.



Rys. 6. Wpływ jednostki powierzchniowej na wielkość różnicy gęstości dla 3 rodzajów słupów trakcyjnych: typu A – słupy przestrzenne ze skratowaniem przekątniowym, typu B – dwuteowe betonowe, typu C – betonowe prostopadłościenne

Dalsze analizy właściwe zostały przeprowadzone dla obszarów potencjalnych, obliczonych z wykorzystaniem komórki 50x50 cm. Wokół obszarów potencjalnych zdefiniowane zostały bufora sytuacyjno-wysokościowe oraz w sposób iteracyjny wyznaczane zostały średnie położenia punktów w podzbiórach. W przypadku błędnie wyznaczonych obszarów potencjalnych określone podzbiory były puste, co pozwoliło w prosty sposób je wyeliminować.

W wyniku analizy właściwej poprawnie wyznaczono wszystkie słupy trakcyjne na obszarze testowym.



Rys. 7. Wynik analizy wstępnej dla komórki 50x50 cm

## 6. LITERATURA

Brenner C., 2009. Extraction of Features from Mobile Laser Scanning Data for Future Driver Assistance Systems. *Advances in GIScience. Lecture Notes in Geoinformation and Cartography*. Springer, pp. 25–42.

Briese C., Pfeifer N., 2008. Towards automatic feature Line model ling from terrestrial laser Scanner data. *XXIst ISPRS Congress: Commission V, WG 3*, Beijing, pp.463–468.

Golovinskiy A., Kim V.G., Funkhouser T., 2009. Shape-based recognition of 3D point clouds in urban environments. *Proceedings of the 12th International Conference on Computer Vision (ICCV09)*.

Gumhold S., Wang X., MacLeod R., 2001 Feature extraction from point Cloud. *In Proc. 10th International Meshing Roundtable*.

- Huang J., Menq C-H., 2001. Automatic data segmentation for geometric feature extraction from unorganized 3-d coordinate points. *IEEE Transactions on Robotics and Automation*.
- Lai K., Fox D., 2010. Object Recognition in 3D Point Clouds Using Web Data and Domain Adaptation. *The International Journal of Robotics Research*, 29, pp.1019–1037.
- Lehtomäki M., Jaakkola A., Hyyrö J., Kukko A., Kaartinen H., 2010. Detection of vertical pole-like objects in a road environment using vehicle-based laser scanning data. *Remote Sensing* 2 (3), pp.641–664.
- Mehdi-Souzani C., Digne J., Audfray N., Lartigue C., Morel J.-M., 2010. Feature extraction from high- density point clouds: toward automation of an intelligent 3D contactless digitizing strategy. *Computer-Aided Design and Applications*, Vol. 7:6, pp. 863-874.
- Paulv M., Keiser R., Gross M., 2003. Multi-scale feature extraction on point-sampled surfaces. *Computer Graphics Forum* 22.
- Pu S., Rutzinger M., Vosselman G., Oude Elberink S., 2011. Recognizing basic structures from mobile laser scanning data for road inventory studies *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (6 SUPPL.), pp. S28-S39.
- Shi, Y., Shibasaki, R., Shi, Z., 2008. Towards automatic road mapping by fusing vehicle-borne multi-sensor data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (Part B5), pp. 867- 872.
- Sithole G., Vosselman G., 2003. Automatic Structure Detection In a Point-Cloud of an Urban Landscape. *2nd GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas*.
- Vosselman, G., 2009. Advanced point cloud processing. *Photogrammetric week* pp. 137–146.
- Weber C., Hahmann S., Hagen H., 2010a. Methods for Feature Detection In Point Clouds. *Shape Modeling International Conference (SMI)*.
- Weber C., Hahmann S., Hagen H., 2010b Sharp feature detection in point clouds. *Shape Modeling International Conference (SMI)*.
- Yogeswaran A., Paveur P., 2009. Features extraction from point clouds for automated detection of deformations on automotive body parts. *Proc. of the IEEE Intl. Workshop on Robotic and Sensor Environments*, Lecco, Italy.

Prace zrealizowane w tym artykule wykonano w ramach grantów dziekańskich 15.11.150/204 i 15.11.150/129.

## **AUTOMATIC EXTRACTION OF TRACION POLES USING MOBILE LASER SCANNING DATA**

KEY WORDS: mobile laser scanning, point cloud, object detection, segmentation, railway infrastructure

### **Summary**

In the last few years in Poland the railway infrastructure modernization program was lounged. It requires fast and precise technique to acquire data sets. Mobile laser scanning could be implemented, however automatic modeling methods from point cloud data sets are not suitable for geometrically complex railway infrastructure equipment such as traction poles.

The main object of this study is the development of automatic traction poles extraction algorithm from laser scanning data. The flexibility of the method and independence from user-defined parameters were the main algorithm objectives. Because of the laser scanning data volume, simple calculations on point cloud subsets should be used to assure processing efficiency.

In this study the combination of density and distance analysis was used. Proposed algorithm has been divided into two stages. In the first step regions of interest are selected by analysis of density difference for points located directly above the railway tracks. The influence of point density bin size on the number of correctly classified region was tested. In the second stage, each of the potential regions is analyzed individually. Iterative method of rejecting points based on distance criteria was used to extract traction poles points.

In the study the point cloud from mobile laser scanner with density of 700 points/m<sup>2</sup> was used. The test area covers 1.5 km railroad section between Miechow and Slomniki in Poland and contains 26 traction poles.

All traction poles within study area were detected. It was proved that by appropriate combination of density and distance analysis, accurate traction poles extraction is possible even in complex regions with many surrounding objects.

Dane autorów:

Elzbieta Pastucha

e-mail: epast@agh.edu.pl

telefon/fax: 12 617 39 93

Małgorzata Słota

e-mail: mslota@agh.edu.pl

telefon/fax: 12 617 39 93