



Określenie wpływu jakości atrybutu RGB powiązanego z danymi naziemnego skaningu laserowego na proces segmentacji

BARTŁOMIEJ KRASZEWSKI

Instytut Geodezji i Kartografii, Zakład Systemów Informacji Przestrzennej i Katastru,
02-679 Warszawa, ul. Modzelewskiego 27, bartlomiej.kraszewski@o2.pl

Streszczenie. W artykule zostały przedstawione wyniki badań wpływu jakości radiometrycznej atrybutu RGB chmury punktów z naziemnego skaningu laserowego na proces jej segmentacji. W badaniach wykorzystano chmurę punktów ze skanera FARO Photon 120 o rozdzielczości 5 mm, opisującą fragment pomieszczenia biurowego, oraz cyfrowe zdjęcia barwne wykonane różnymi aparatami cyfrowymi. Zdjęcia zrobiono lustrzanką cyfrową Nikon D3X, lustrzanką Canon D200 zintegrowaną ze skanerem laserowym, aparatem kompaktowym Panasonic TZ-30 oraz aparatem cyfrowym w telefonie komórkowym Samsung. Informację barwną ze zdjęć cyfrowych powiązano z chmurą punktów w oprogramowaniu Faro SCENE. Segmentację danych testowych po atrybucie RGB wykonano w opracowanej autorskiej aplikacji „RGB Segmentation”. Aplikacja bazowała na ogólnodostępnych bibliotekach Point Cloud Library (PCL). Umożliwiała wyodrębnienie ze źródłowej chmury punktów podzbiorów spełniających założone kryteria segmentacji z wykorzystaniem metody rosnących regionów. Wykorzystując opracowaną aplikację, wykonano segmentację czterech testowych chmur punktów zawierających atrybuty RGB z różnych źródeł. Ocena procesu segmentacji została przeprowadzona na podstawie porównania podzbiorów uzyskanych przy wykorzystaniu wspomnianej aplikacji i pogrupowanych manualnie przez operatora. Porównaniu podlegały: liczba uzyskanych segmentów, liczba poprawnie zidentyfikowanych obiektów oraz procent właściwie posegmentowanych punktów. Największy procent poprawnie posegmentowanych punktów i największą liczbę zidentyfikowanych obiektów uzyskano przy zastosowaniu danych skanerowych z atrybutem RGB ze zdjęć wykonanych Nikonem D3X. Na podstawie badań stwierdzono również, że jakość atrybutu RGB chmury punktów wpływa tylko na liczbę zidentyfikowanych obiektów. Wynik procesu segmentacji zbioru punktów skaningu laserowego nie jest funkcją obrazu RGB powiązanego z tym zbiorem.

Słowa kluczowe: naziemny skaningu laserowy, segmentacja, RGB, metoda rosnących regionów, zdjęcia cyfrowe, chmura punktów

DOI: 10.5604/12345865.1157316

1. Wstęp

Naziemny skaniny laserowy (NSL) stał się w ostatnich latach popularną technologią pomiarową. Zyskała ona popularność w szczególności dzięki możliwości pomiaru milionów punktów w niespełna kilka sekund, co w efekcie pozwala na skrócenie do minimum czasu potrzebnego na wykonanie pomiaru. Pozyskany zbiór pomiarowy opisuje w sposób ciągły obiekty znajdujące się w otoczeniu skanera. W zbiorze tym utrudniona jest jednak możliwość identyfikacji pojedynczych obiektów. Oznacza to, że nie jesteśmy w stanie w sposób jednoznaczny stwierdzić, czy dany punkt należy do konkretnego obiektu. We współczesnych opracowaniach kładzie się wyjątkowy nacisk na automatyzację procesów opracowania modeli 3D, konieczne staje się zastosowanie metod identyfikacji pozwalających na ekstrakcję poszczególnych obiektów z zbioru punktów pomiarowych. Ekstrakcję taką nazywamy procesem segmentacji. Segmentacja umożliwia wyodrębnienie podzbiorów z chmury punktów charakteryzujących się pewnymi jednakowymi właściwościami [6]. W większości opisanych w literaturze metod segmentacja wykonywana jest na podstawie atrybutów geometrycznych zbioru punktów NSL. Atrybutami tymi są współrzędne przestrzenne, wartości wektora normalnego i odległość od lokalnej płaszczyzny wyliczone dla każdego punktu chmury. W przypadku wspomnianych atrybutów selekcja dokonywana jest poprzez wpasowanie modelu parametrycznego w źródłowe dane, np. algorytmem RANSAC [2], lub też analizę lokalnej zmiany atrybutów według założonego kryterium, tworząc segmenty z wykorzystaniem metody rosnących regionów [5]. Typowym zastosowaniem dla dwóch wspomnianych metod segmentacji jest wydzielenie z danych skaningu laserowego grup punktów należących do płaszczyzny [3]. Ze zbiorem danych przestrzennych powiązane są również atrybuty niegeometryczne, tj. intensywność odbicia wiązki laserowej i kolorystyka barwna ze zdjęć cyfrowych. Użycie tych atrybutów w procesie segmentacji nie jest powszechne. Wstępne badania nad zastosowaniem segmentacji danych NSL opartej na atrybucie RGB przedstawiono w publikacji [7]. Autorzy publikacji twierdzą, że zastosowanie atrybutów RGB umożliwia segmentację skomplikowanych geometrycznie elementów (architektura chińska) i tam, gdzie wykorzystanie atrybutów geometrycznych nie daje pożądaných efektów. Zastosowanie w segmentacji tego atrybutu pozwala kontrolować błędy spowodowane nadsegmentacją i podsegmentacją, jednak w końcowym efekcie trudno jest uzyskać dobry rezultat ekstrakcji dla całego zbioru.

Segmentację wykorzystującą atrybut RGB można zastosować do opracowania danych opisujących wnętrza budynków, gdzie występuje duża liczba infrastruktury o prostych i skomplikowanych kształtach i utrudnione jest zastosowanie metod bazujących na atrybutach geometrycznych. Przy tego typu obiektach poza obiektami płaszczyznowymi (ściany) występują również elementy infrastruktury, które operator jest w stanie odróżnić jedynie dzięki dodatkowym atrybutom niegeometrycznym. W przypadku tego i wielu innych obiektów końcowy wynik segmentacji

uzależniony jest nie tylko od parametrów przyjętych w algorytmach procesu, lecz także od jakości zastosowanych danych wejściowych. Sama informacja barwna (RGB) może pochodzić ze zdjęć wykonanych różnego rodzaju aparatami cyfrowymi. W zależności od klasy urządzenia dane obrazowe charakteryzują się lepszą lub gorszą jakością radiometryczną. Celowe zatem jest określenie wpływu jakości atrybutów RGB na proces segmentacji.

W artykule zaprezentowane zostały wyniki badań mających na celu określenie wpływu jakości informacji barwnej powiązanej z danymi NSL na segmentację poszczególnych obiektów. W ramach badań pozyskane zostały dane obrazowe o różnej jakości radiometrycznej, które powiązane zostały z chmurą punktów z naziemnego skaningu laserowego. Tak przygotowane dane poddano segmentacji, a następnie analizie efektywności tego procesu.

2. Charakterystyka danych testowych

W badaniach wykorzystano zbiory punktów 3D pozyskane w pomieszczeniu testowym skanerem fazowym FARO Proton 120. Skanowanie wykonano z jednego stanowiska skanera w pełnym zakresie jego pola widzenia. W czasie skanowania pozyskano również zdjęcia ze zintegrowanej ze skanerem lustrzanki cyfrowej Canon D200. Dane poddano filtracji w celu usunięcia błędnie pomierzonych punktów przestrzennych w oprogramowaniu FARO Scene. Z całego pozyskanego zbioru do testów wybrano fragment składający się z 224 tys. punktów opisujących kilka obiektów pomieszczenia. Przeciętna rozdzielczość przestrzenna (odległość pomiędzy sąsiednimi punktami zbioru) wybranego fragmentu wynosiła 5 mm. Dla wybranego zbioru testowego wykonano również zdjęcia z wykorzystaniem innych aparatów cyfrowych:

- profesjonalnej lustrzanki cyfrowej Nikon D3X wyposażonej w pełnoklatkową matrycę cyfrową. Zdjęcia wykonano z rozdzielczością 6048×4032 (24 megapikseli),
- aparatu kompaktowego Panasonic TZ-30 z rozdzielczością 3240×4320 (14 megapikseli),
- aparatu cyfrowego stanowiącego wyposażenie telefonu komórkowego Samsung Galaxy Ace z rozdzielczością 1920×2560 (5 megapikseli).

Pozyskane zdjęcia były rzutowane na chmurę punktów w oprogramowaniu Faro SCENE. Zdjęcia wykonane ze zintegrowanej ze skanerem lustrzanki cyfrowej powiązane z chmurą punktów w sposób automatyczny dzięki znajomości ich orientacji zewnętrznej zapisane w pliku projektowym. Pozostałe zobrazowania dopasowano do punktów 3D poprzez identyfikację punktów homologicznych [1]. Punkty homologiczne stanowiły szczegóły terenowe jednoznacznie identyfikowalne na obu typach danych. Przykładowy zestaw punktów homologicznych przedstawiony został na rysunku 1.



Rys. 1. Punkty homologiczne wykorzystane do powiązania danych rastrowych z aparatu kompaktowego Panasonic TZ30 z testowym zbiorem punktów 3D


Przeciętna dokładność wpasowania zdjęć w chmurę punktów NSL wyniosła 3,4 piksela. Najwyższą dokładność wpasowania 2,5 piksela otrzymano dla niskorozdzielczych danych z aparatu, w który wyposażony był telefon komórkowy. Zdjęcia z Nikonu D3X i Panasonic TZ30 powiązane ze zbiorem danych 3D z dokładnością wynoszącą ok. 4 piksele. Wszystkie uzyskane wyniki zestawione zostały w tabeli 1. W wyniku rzutowania poszczególnych pikseli obrazowych na zbiór danych przestrzennych każdemu z punktów zbioru zostały przypisane wartości R, G, B odczytane z obrazu.

W wyniku połączenia danych skanerowych z rastrowymi powstały cztery zbiory testowe, z których każdy charakteryzował się inną jakością atrybutów związanych z informacją barwną. Pokolorowane zbiory punktów przestrzennych przedstawione zostały na rysunku 2. Na każdym ze zbiorów widoczne są różnice radiometryczne atrybutu RGB pochodzącego z różnych źródeł.

TABELA 1

Dokładność wpasowania zdjęć w testowy zbiór danych skanerowych

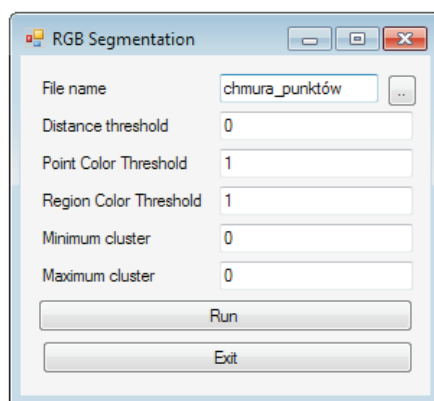
Rodzaj aparatu	Liczba punktów homologicznych	Dokładność [piksele]
Nikon D3X	13	3,6
Panasonic TZ30	13	4,0
Samsung	12	2,5



Rys. 2. Dane z naziemnego skanera z nałożoną informacją barwną z: a) z lustrzanki cyfrowej zintegrowanej ze skanerem; b) z lustrzanki cyfrowej Nikon D3X; c) z aparatu kompaktowego Panasonic TZ-30; d) z aparatu w telefonie komórkowym

3. Aplikacja do segmentacji danych względem parametru RGB

Z powodu braku dostępności narzędzia komercyjnego umożliwiającego segmentację danych z wykorzystaniem dodatkowej informacji barwnej ze zdjęć została opracowana własna aplikacja realizująca ten proces. Aplikacja została napisana w języku C++ z wykorzystaniem procedur dostępnych w ramach bibliotek *Point Cloud Library*. W szczególności wykorzystano biblioteki zawierające procedury do segmentacji i wizualizacji chmur punktów [4]. Do aplikacji został opracowany Graficzny Interfejs Użytkownika umożliwiający łatwą modyfikację parametrów segmentacji (rys. 3).



Rys. 3. Główne okno programu RGB Segmentation

Zastosowany w aplikacji algorytm umożliwia kontrolowanie wyniku segmentacji przez użytkownika poprzez modyfikację parametrów:

- *Distance threshold* — parametr określający zakres poszukiwań najbliższych sąsiadów analizowanego punktu;

- *Point Color Threshold* (PCT) — parametr definiujący wartość różnicy atrybutów RGB między analizowanymi pojedynczymi punktami chmury testowanej w pierwszym etapie algorytmu. W momencie, gdy wartość różnicy koloru pomiędzy punktami jest mniejsza niż wartość progowa, wtedy punkt zostaje przyłączony do tego samego regionu;
- *Region Color Threshold* (RCT) — parametr definiuje różnicę kolorów pomiędzy sąsiednimi regionami. W momencie gdy wartość różnicy kolorów pomiędzy regionami jest mniejsza niż założona wartość progowa, wtedy regiony zostają ze sobą połączone;
- *Minimum cluster* — minimalna liczba punktów, które powinien zawierać pojedynczy podzbiór po procesie segmentacji danych;
- *Maximum cluster* — maksymalna liczba punktów, które powinien zawierać pojedynczy podzbiór po procesie segmentacji danych.

Działanie zaimplementowanego w aplikacji algorytmu segmentacji bazuje na metodzie rosnących regionów. Opiera się ona na sprawdzeniu różnicy kolorystycznej pomiędzy sąsiadującymi punktami i tworzeniu na podstawie punktów spełniających założone kryterium regionów o jednakowych właściwościach. Proces segmentacji składa się z dwóch etapów. W pierwszym etapie:

1. W pierwszej kolejności wybierany jest punkt startowy $P_0 = [x_0, y_0, z_0, R_0, G_0, B_0]$;
2. Następnie wyznaczane są na podstawie zdefiniowanej przez użytkownika odległości punkty stanowiące najbliższe sąsiedztwo punktu startowego i dla każdego z nich sprawdzany jest warunek:

$$\sqrt{(R_s - R_0)^2 + (G_s - G_0)^2 + (B_s - B_0)^2} < PCT, \quad (1)$$

gdzie punkt sąsiedni $P_s = [x_s, y_s, z_s, R_s, G_s, B_s]$.

3. Punkty sąsiadujące spełniające wyrażenie (1) są dodawane do zbioru (regionu), w którym znajduje się punkt startowy, a następnie analizowane jest ich sąsiedztwo, aż do momentu, w którym żaden z sąsiadujących punktów regionu nie będzie spełniał warunku (1). W takim przypadku region zostaje zamknięty, a z nieposegmentowanego zbioru danych wybierany jest kolejny punkt startowy. Algorytm wykonywany jest iteracyjnie, aż do momentu, w którym wszystkie punkty zostaną przypisane do poszczególnych regionów lub uzyskane regiony będą mniejsze od założonego parametru *Minimum cluster*.

W drugim etapie algorytmu porównywane są ze sobą średnie wartości atrybutów R, G, B między uzyskanymi w pierwszym etapie sąsiadującymi ze sobą regionami. Przyjmijmy, że region S1 ma średnie wartości parametrów R_1, G_1, B_1 , a sąsiadujący z nim region S2 wartości R_2, G_2, B_2 .


To, jeżeli spełniony jest warunek

$$\sqrt{(R_2 - R_1)^2 + (G_2 - G_1)^2 + (B_2 - B_1)^2} < RCT, \quad (2)$$

wtedy regiony są ze sobą łączone.

Aplikacja po zakończonym procesie segmentacji pozwala na wstępną weryfikację wyniku ekstrakcji regionów w oknie podglądu (rys. 4). Poszczególnym regionom przypisane zostają losowe barwy w celu możliwości ich identyfikacji. Jednocześnie aplikacja zapisuje uzyskane wyniki segmentacji w postaci:

- pliku XYZ zawierającego wszystkie punkty segmentowanej chmury wraz z nadaniem kolorystyki barwnej dla poszczególnych podzbiorów punktów,
- plików XYZ zawierającego poszczególne podzbiory punktów.



Rys. 4. Okno podglądu wyniku segmentacji


4. Segmentacja danych testowych

Segmentację danych z naziemnego skaningu laserowego wykonano z zastosowaniem opracowanej aplikacji. Segmentacja miała pogrupować zbiory punktów pomiarowych na podzbiory opisujące poszczególne elementy wnętrza testowego. Do kontroli procesu segmentacji wykorzystano manualnie pogrupowany zbiór przestrzennych danych testowych (rys. 5). W wyniku manualnej segmentacji wydzielono podzbiory punktów opisujących 20 obiektów.

W pierwszym etapie badań przeprowadzono segmentację jednego z czterech testowych zbiorów danych pomiarowych ze zmiennymi parametrami aplikacji. Do testowej segmentacji wybrano zbiór punktów zintegrowany z danymi obrazowymi najlepszej jakości z profesjonalnej lustrzanki cyfrowej Nikon D3X. Na rysunku 6 przedstawiono wpływ zmiany wartości parametru PCT na wynik segmentacji. Drugi z parametrów RCT zdefiniowany w algorytmie programu ustawiono domyślnie na 0.



Rys. 5. Dane referencyjne będące wynikiem segmentacji manualnej źródłowych danych testowych



Rys. 6. Wyniki segmentacji chmury punktów pokolorowanej obrazem z Nikonu D3X przy różnej wartości parametru *Point Color Threshold*

Na podstawie uzyskanych wyników stwierdzono, że pojedyncze grupy obiektów można zidentyfikować dopiero od wartości $PCT = 2$. Przy $PCT = 3$ widoczne jest również łączenie punktów charakteryzujących się podobną kolorystyką (np. ściany) w większe grupy obiektów. Przy różnych współczynnikach PCT widoczne jest natomiast wyodrębnienie mniejszych elementów umieszczonych na ścianach, takich jak gniazdka elektryczne.

Posegmentowane zbiory porównano z manualnie podzielonym zbiorem referencyjnym. Porównaniu podlegały:

- liczba uzyskanych segmentów,
- liczba poprawnie zidentyfikowanych obiektów,
- poprawność segmentacji wyrażona poprzez przeciętny procent punktów poprawnie opisujących poszczególne obiekty,
- błąd nadsegmentacji wyrażający przeciętny procent punktów opisujących błędnie poszczególne obiekty,
- brak w segmentach punktów do nich należących (opisujących obiekty).

TABELA 2

Wynik segmentacji z uwzględnieniem parametru *Point Color Threshold*

Wartość parametru	Liczba segmentów	Poprawnie zidentyfikowane obiekty	Poprawność segmentacji punktów	Nadsegmentacja	Brak
1	854	0/20	0,0%	0,0%	0,0%
2	107	12/20	94,8%	5,2%	13,6%
3	32	12/20	95,3%	4,7%	7,0%
4	28	14/20	94,8%	5,2%	12,7%
5	26	13/20	91,8%	8,2%	13,2%
6	25	12/20	91,5%	8,5%	14,3%

W tabeli 2 zaprezentowano porównanie wyników segmentacji ze zbiorem referencyjnym. Po porównaniu wyników stwierdzono, że największą liczbę obiektów zidentyfikowano przy $PCT = 4$. Z niezmiennym parametrem $PCT = 4$ przeprowadzono następnie weryfikację zmiany parametru RCT . Zmiana tego parametru nie wpłynęła znacząco na wynik segmentacji, dlatego proces segmentacji oparto tylko na parametrze PCT . Zauważyć należy również, że wraz ze wzrostem wartości parametru PCT powyżej 3 maleje poprawność wykonanej segmentacji kosztem wzrostu pozostałych błędów.

Drugim etapem badania była segmentacja danych skanerowych z nałożonymi danymi rastrowymi z różnych źródeł z niezmiennymi parametrami segmentacji. W programie ustawiono parametr $PCT = 4$ oraz $RCT = 0$, a następnie przeprowadzono segmentację czterech zbiorów danych testowych. W tabeli 3 zestawiono wyniki segmentacji.

Na podstawie uzyskanych wyników stwierdzono, że w przypadku punktów pomiarowych z atrybutem RGBz Nikona D3X uzyskano najwyższą poprawność segmentacji, jak również wyekstrahowano największą liczbę elementów. Wraz ze spadkiem jakości rzutowanych na zbiór przestrzenny zobrazowań możliwość

identyfikacji poszczególnych elementów maleje. Wpływ jakości danych obrazowych na proces segmentacji nie jest widoczny w przypadku błędów nadsegmentacji i braków punktów należących do obiektów.

TABELA 3
Analiza wyników segmentacji czterech zbiorów testowych dla wartości *Point Color Threshold* = 4

Wartość parametru	Liczba segmentów	Poprawnie zidentyfikowane obiekty	Poprawność segmentacji punktów	Nadsegmentacja	Brak
Canon	25	11/20	88,4%	11,6%	8,0%
Nikon	28	14/20	94,8%	5,2%	12,7%
Panasonic	27	12/20	90,8%	9,2%	13,8%
Samsung	36	10/20	91,4%	8,6%	6,6%

5. Podsumowanie

Przy opracowywaniu dużych zbiorów danych przestrzennych pozyskanych z wykorzystaniem naziemnego skaningu laserowego proces segmentacji obok filtracji i rejestracji staje się jednym z najważniejszych etapów przetworzenia danych. Przy jego wykorzystaniu mamy możliwość automatyzacji lub wspomagania pracy przy modelowaniu 3D wszelkiego rodzaju obiektów. Został zbadany wpływ jakości informacji barwnej powiązanej z chmurą punktów na segmentację obiektów po tym atrybucie.

Na podstawie badań stwierdzono, że przy stosowaniu segmentacji chmury punktów wzrost parametru PCT powyżej pewnej wartości powoduje zwiększenie się błędów poprawnej klasyfikacji punktów do obiektu (nadsegmentacji i brak punktów opisujących obiekt). Wprowadzenie do segmentacji parametru RCT nie wpływa znacząco na jej wynik.

Wyniki badań pozwoliły stwierdzić, że jakość danych obrazowych powiązanych z chmurą punktów ma wpływ tylko na liczbę zidentyfikowanych obiektów. W przypadku zarówno poprawności segmentacji, jak również jej błędów nie ma widocznej zależności pomiędzy jakością informacji barwnej a wynikiem procesu.

Należy stwierdzić, że użycie w procesie segmentacji po informacji barwnej innych atrybutów powiązanych z chmurą punktów mogłoby przynieść wzrost efektywności tego procesu. W szczególności pozwoliłoby na wyeliminowanie łączenia w regiony punktów o podobnych atrybutach, ale należące do innych obiektów (np. ściany).

Publikacja była współfinansowana przez Unię Europejską w ramach środków Europejskiego Funduszu Społecznego.

Artykuł wpłynął do redakcji 9.10.2014 r. Zweryfikowaną wersję po recenzji otrzymano 5.03.2015 r.

LITERATURA

- [1] ABDELHAFIZ A., RIEDEL B., NIEMEIER W., *Towards a 3D True Colored Space by the Fusion of Laser Scanner Point Cloud and Digital Photos*, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. 36, part 5/W17, Venice, Italy, 2005.
- [2] FISCHLER M.A., BOLLES R.C., *Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography*, Communications of the ACM, vol. 24, issue 6, 1981, 381-395.
- [3] JARZĄBEK-RYCHARD M., BORKOWSKI A., *Porównanie algorytmów RANSAC oraz rosnących płaszczyzn w procesie segmentacji danych lotniczego skaningu laserowego*, Archiwum Fotogrametrii, Kartografii i Teledetekcji, vol. 21, 2010, 119-129.
- [4] Point Cloud Library, <http://www.pointclouds.org>, 2013.
- [5] PU S., VOSSELMAN G., *Automatic extraction of building features from terrestrial laser scanning*, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. 36, Dresden, Germany, 2006.
- [6] RABBANI T., VAN DEN HEUVEL F.A., VOSSELMAN G., *Segmentation of point clouds using smoothness constraints*, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. 36, part 5, 2006, 248-253.
- [7] ZHAN Q., LIANG Y., XIAO Y., *Color-based segmentation of point clouds*, International Archives of Photogrammetry and Remote Sensing, vol. 38, part 3/W8, 2009, 248-252.

B. KRASZEWSKI

Determination of the impact of RGB points cloud attribute quality on color-based segmentation process

Abstract. The article presents the results of research on the effect that radiometric quality of point cloud RGB attributes have on color-based segmentation. In the research, a point cloud with a resolution of 5 mm, received from FARO Photon 120 scanner, described the fragment of an office's room and color images were taken by various digital cameras. The images were acquired by SLR Nikon D3X, and SLR Canon D200 integrated with the laser scanner, compact camera Panasonic TZ-30 and a mobile phone digital camera. Color information from images was spatially related to point cloud in FARO Scene software. The color-based segmentation of testing data was performed with the use of a developed application named "RGB Segmentation". The application was based on public Point Cloud Libraries (PCL) and allowed to extract subsets of points fulfilling the criteria of segmentation from the source point cloud using region growing method.

Using the developed application, the segmentation of four tested point clouds containing different RGB attributes from various images was performed. Evaluation of segmentation process was performed based on comparison of segments acquired using the developed application and extracted manually by an operator. The following items were compared: the number of obtained segments, the number of correctly identified objects and the correctness of segmentation process. The best correctness of segmentation and most identified objects were obtained using the data with RGB attribute from Nikon D3X images. Based on the results it was found that quality of RGB attributes of point cloud had impact only on the number of identified objects. In case of correctness of the segmentation, as well as its error no apparent relationship between the quality of color information and the result of the process was found.

Keywords: terrestrial laser scanning, color-based segmentation, RGB attribute, region growing method, digital images, points cloud

