

Sławomir ZATOR, Paweł MICHALSKI

POLITECHNIKA OPOLSKA,
Sosnkowskiego 31, 45-272 Opole

Metody wykrywania obiektów w chmurze punktów

Dr hab. inż. Sławomir ZATOR

Aktualnie prodziekan ds. nauki na Wydziale Inżynierii Produkcji i Logistyki Politechniki Opolskiej. Podstawowy obszar działalności naukowej obejmuje metrologię, w obszarze pomiaru wielkości nieelektrycznych oraz diagnostykę eksploatacyjną urządzeń i instalacji energetycznych. Autor dwóch monografii w obszarze pomiaru strumienia plynów. Członek Komisji Metrologii i Komisji Elektroniki Oddziału PAN w Katowicach.

e-mail: s.zator@po.opole.pl



Mgr inż. Paweł MICHALSKI

Ukończył studia w 2010 r. na Politechnice Opolskiej na kierunku informatyka o specjalności Komputerowe Wspomaganie Projektowania. W tym samym roku rozpoczął studia doktoranckie na Wydziale Elektrotechniki, Automatyki i Informatyki Politechniki Opolskiej.



e-mail: p.michalski@doktorant.po.opole.pl

Streszczenie

Artykuł prezentuje aktualny stan wiedzy w dziedzinie przetwarzania chmur punktów pod kątem wykrywania obiektów typu prymityw. Działanie algorytmu zostało zweryfikowane na podstawie danych rzeczywistych uzyskanych w wyniku skanowania obiektów rzeczywistych skanerem laserowym Trimble FX. Autorzy zaproponowali własną metodę hybrydową pozwalającą wykryć określone typy obiektów poprzez przetwarzanie pojedynczej linii skanu. Przedstawiono wady i zalety takiego podejścia.

Słowa kluczowe: Skaning laserowy, pomiary precyzyjne, pomiar odległości, detekcja obiektów, identyfikacja obiektów.

Point cloud object detecting methods

Abstract

In this paper the current state of knowledge in the field of point cloud processing for the detection of primitive objects is presented. The first section presents the main parameters of a scanning device and describes the methodology of making measurements. The next section provides an overview of the most popular methods for the certain shape objects detection in the point cloud. For each method, there are presented the basic principles that must comply with the data that can be used. The used data were a scene containing simple shaped objects such as a cylinder, a plane. The authors propose their own approach based on the processing of a single scan line. The method is based on the assumption that the scanned scene consists of a set of points forming lines parallel to each other. One line corresponds to one rotation of the scanning mirror furnishing. The lines are considered independently for the first stage of the algorithm. For each line the search step is performed, for a simple object such as a line or an arc. After suitable transformation of the coordinate system, each line can be simplified from 3D to 2D. The search is based on the usage of the Hough Transform for 2D objects. The results from the single lines are grouped into clusters, and then comparison with the results of the adjacent lines were made. The final step is to separate segments within the adjacent line. The result is a group of points corresponding to the set criterion.

Keywords: laser scanning, measurement precision, distance measurement, object detection, object identification.

1. Wprowadzenie

Chmury punktów są zbiorem nieuporządkowanych punktów w przestrzeni trójwymiarowej opisującym geometrię powierzchni badanego obiektu. Obecnie wykorzystywane urządzenia pomiarowe (skanery) są w stanie w bardzo krótkim czasie dokonać akwizycji punktów z bardzo rozległych scen, zachowując przy tym małą niepewność pomiaru ich położenia. Aparaturą, z której korzystano podczas realizacji prac badawczych był skaner Trimble FX, który pozwalał na uzyskanie niepewności pomiaru odległości rzędu 0,6 mm przy odległości 11 m do obiektu w trybie skanu pojedynczego oraz 0,45 mm przy skanie podwójnym. W tym miejscu należy wyjaśnić różnicę pomiędzy dwukrotnym skanem wykonywanym dla obiektu oraz skanem podwójnym, dostępnym w skanerze. W stosunku do pojedynczego skanu, który w tym przypadku będzie punktem odniesienia, niezależny skan

dwukrotny wynikowo daje dwukrotnie więcej punktów, natomiast skan podwójny generuje taką samą liczbę punktów jak skan pojedynczy, z tym że wynik pomiaru obarczony jest mniejszą niepewnością. Minimalna rozdzielcość kątowa skanu wynosiła 20 sekund. Tak precyzyjna i silnie zagęszczona chmura punktów stwarza znaczne problemy podczas jej przetwarzania. Dlatego też stosuje się metody uśredniania obszarów spełniających określone kryterium podobieństwa. Kryterium takim może być średnie nachylenie normalnej do powierzchni w punkcie lub też odległość do grupy najbliższych sąsiadów. Większość skanerów generujących chmury punktów, poza współrzędnymi punktu dostarcza również wartość współczynnika charakteryzującego intensywność odbitej wiązki od skanowanej powierzchni. Informacja ta również może zostać wykorzystana jako kryterium podobieństwa do wykonania klasyfikacji.

2. Aktualny stan wiedzy

Problematyka przetwarzania chmur punktów jest dziedziną, która rozwija się bardzo dynamicznie na wszystkich etapach, począwszy od samych maszyn, poprzez algorytm filtracji i segmentacji, a kończąc na dopasowywaniu modeli CAD do chmury punktów. Obiekty, które najczęściej zawierają największą liczbę punktów uzyskanych podczas pomiaru są płaszczyznami. Zatem, aby przyspieszyć wyszukiwanie pozostałych typów obiektów, na wstępny etapie należy wyszukać wszystkie płaszczyzny w scenie oraz wydzielić je z dalszego przetwarzania. Aktualnie stosuje się trzy grupy metod pozwalających na ekstrakcję parametrów równania płaszczyzny z chmury punktów.

2.1. Metoda rozrostu płaszczyzn

Metoda rozrostu płaszczyzn pozwala wyznaczyć parametry równania płaszczyzny oraz grupę punktów do niej należących. Metoda obejmuje dwa podstawowe etapy:

- ustalenie topologii,
- identyfikacja płaszczyzn.

Etap ustalania topologii najczęściej odbywa się z wykorzystaniem algorytmów kNN (ang. k Nearest Neighbor) lub FDN (ang. Fixed Distance Neighbor). Obie metody bazują na obliczaniu odległości do ustalonej liczby n najbliższych sąsiadów. Po zakończeniu etapu wyszukiwania najbliższych sąsiadów następuje proces przygotowywania danych polegający na dopasowywaniu płaszczyzny do zbioru najbliższych sąsiadów. Uzyskuje się w ten sposób płaszczyznę lokalną wokół każdego z punktów. Kolejnym etapem jest obliczenie odległości pomiędzy płaszczyzną lokalną a wszystkimi punktami użytymi do jej wyznaczenia. Etap identyfikacji płaszczyzn rozpoczęta się od wybrania pojedynczego punktu, którego płaszczyzna lokalna najlepiej odwzorowuje położenie zbioru sąsiadów. Następnie dla każdego z punktów sprawdzone zostają kryteria: odległości od płaszczyzny oraz różnice pomiędzy wektorem normalnym rosnącym płaszczyzną oraz lokal-

nej płaszczyzny wokół sprawdzanego punktu. Punkt spełniający oba kryteria zostaje dodany do rosnącej płaszczyzny, a następnie najbliższy z jego sąsiadów zostaje poddany sprawdzeniu kryteriów. W przypadku, gdy którykolwiek z kryteriów nie zostanie spełnione algorytm sprawdza kolejnego sąsiada punktu spełniającego kryteria. Algorytm wykonuje się do momentu przekroczenia zadanej wartości progowej określającej liczbę punktów niezaklasyfikowanych do żadnej płaszczyzny [1].

2.2. Algorytm RANSAC

Algorytm RANSAC (ang. Random Sample Consensus) jest skuteczną metodą iteracyjną pozwalającą na identyfikację obiektów opisanych modelem matematycznym w zbiorze punktów, w którym znaczny ich procent można zakwalifikować jako szum. Metoda przewiduje dwa podstawowe iteracyjnie powtarzane kroki:

- ustalenie hipotezy,
- test zbioru.

Podczas ustalania hipotezy definiuje się najmniejszy zbiór opisujący poszukiwany obiekt. Jest to najmniejsza liczba punktów pozwalających na jednoznaczne zdefiniowanie modelu. Dla płaszczyzny są to trzy punkty. W algorytmie występuje również ilość iteracji, która określa liczbę prób wyznaczenia najmniejszego zbioru takiego, aby uzyskać płaszczyznę zawierającą jak największą liczbę punktów do niej należących. W kolejnym kroku, dla każdego ze zbiorów wyznaczane są parametry modelu, które stają się hipotezą. Etap testowania polega na wyznaczeniu odległości od hipotetycznego modelu. W przypadku, gdy odległość punktu od płaszczyzny jest mniejsza od wcześniej założonej wartości progowej, to punkt zostaje dodany do zbioru punktów zaklasyfikowanych do obiektu. Po wykonaniu testu dla wszystkich punktów ponownie następuje etap hipotezy oraz wyznaczenia nowego modelu. W przypadku, gdy liczba punktów zaklasyfikowanych do nowego modelu jest większa od poprzedniego modelu, to zostaje on zaktualizowany. Po wykonaniu wszystkich iteracji algorytm wyznaczy parametry płaszczyzny, która posiada największą liczbę punktów spełniających kryterium odległości od płaszczyzny [2]. Opracowano narzędzie pozwalające na identyfikację cylindra w chmurze. Wyniki pomiarów dla cylindra o wymiarach $r = 53,5$ mm oraz długości 195 mm zamieszczone w tabeli 1.

Tab. 1. Zestawienie wyników obliczeń dla danych pomiarowych
Tab. 1. Comparison of the results for the measurement data

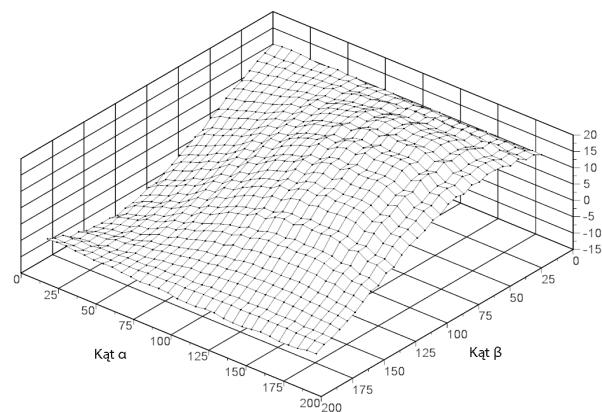
Różnica wektórow normalnych w punkcie %	Wyznaczony promień cylindra [mm]	Wyznaczona długość [mm]	Liczba punktów na zlokalizowanych na cylindrze
0,1	53,82	203,92	6407
0,09	53,8	203,94	6433
0,08	53,78	192,9	6085
0,07	53,77	203,98	6332
0,06	53,76	204	6257
0,05	53,74	193	6171
0,04	53,73	193,01	6122
0,03	53,72	193	6062
0,02	53,71	193,14	5951
0,01	53,7	189,27	5647
0,009	53,7	193,14	5878
0,008	53,7	193,06	5956

Różnice w wyznaczaniu długości cylindra wynikają z metody, którą przyjęto do jej obliczania. Wszystkie punkty zakwalifikowane jako elementy cylindra transformowane są tak, aby jego osi symetrii pokrywała się z osią układu współrzędnych. Następnie wyznaczana jest różnica współrzędnych punktów posiadająca min oraz max wartość współrzędnej z punktów zakwalifikowanych do cylindra.

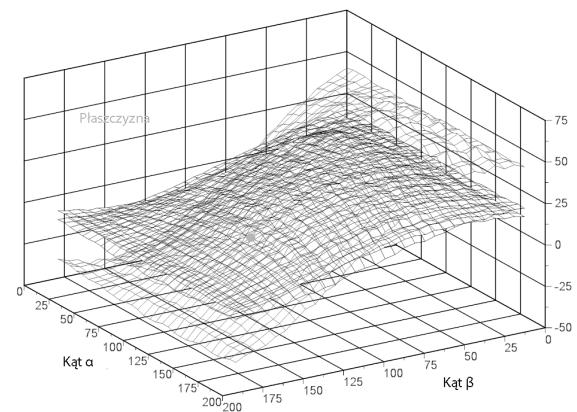
2.3. Transformata Hougha

Transformata Hougha jest metodą pozwalającą na wykrywanie określonych wzorców na obrazach binarnych. Warunkiem jej użycia jest określenie zbioru parametrów opisujących szukany wzorzec. Przestrzeń Hougha jest przestrzenią akumulacyjną, w której na poszczególnych osiach opisano kąty α, β oraz odległość r określającą odległość płaszczyzny od początku układu współrzędnych [3]. Przestrzeń Hougha posiada następujące właściwości w stosunku do układu kartezjańskiego:

- każdemu punktowi w przestrzeni 3D odpowiada sinusoida 3D (rys. 1),
- płaszczyzną w przestrzeni Hougha jest punkt przecięcia trzech sinusoid 3D (rys. 2).



Rys. 1. Reprezentacja punktu w przestrzeni Hougha
Fig. 1. Point representation in the Hough space



Rys. 2. Reprezentacja płaszczyzny w przestrzeni Hougha
Fig. 2. Plane representation in the Hough space

Transformata Hougha w przestrzeni sprowadza się do rozszerzenia przestrzeni Hougha o dodatkowy parametr, jakim jest kąt odchylenia wektora normalnego od osi z. Na listingu poniżej przedstawiono algorytm tzw. głosowania, które należy wykonać dla każdego z punktów. Można zauważyć, że jest to najbardziej czasochłonny etap metody.

Algorytm:

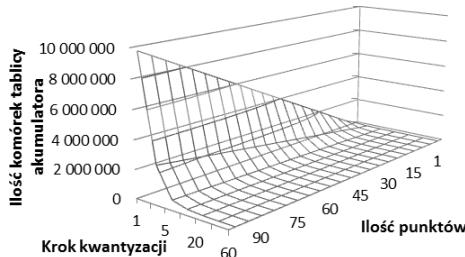
- 1: **for** wszystkie punkty P_i **in** zbiór X **do**
- 2: **for** wszystkie komórki (α, β, r) **in** akumulator A **do**
- 3: **if** punkt P_i leży na płaszczyźnie zdefiniowanej przez (α, β, r) **then**
- 4: **increment** komórka $A(\alpha, \beta, r)$
- 5: **end if**
- 6: **end for**
- 7: **end for**
- 8: *Wyszukaj komórki z najwyższą wartością akumulacji*

Długość wektora normalnego została obliczona korzystając z równania (1), w którym α reprezentuje odchylenie wektora normalnego do płaszczyzny w osi XY, β odchylenie wektora normalnego względem osi Z [4].

$$r = px \cdot \cos\alpha \cdot \sin\beta + py \cdot \sin\beta \cdot \sin\alpha + pz \cdot \cos\beta \quad (1)$$

(r, α, β) są biegowymi współrzędnymi punktu (x, y, z) względem punktu $(0, 0, 0)$.

Główną wadą metody jest jej wysoki nakład obliczeniowy oraz, w przypadku przestrzeni 3D, problem organizacji akumulatora, który w przypadku rozległych chmur punktów zajmuje znaczną ilość pamięci. Wykres na rys. 3 przedstawia przyrost tablicy akumulatora w zależności od ilości punktów oraz przyjętego kroku kwantyzacji.

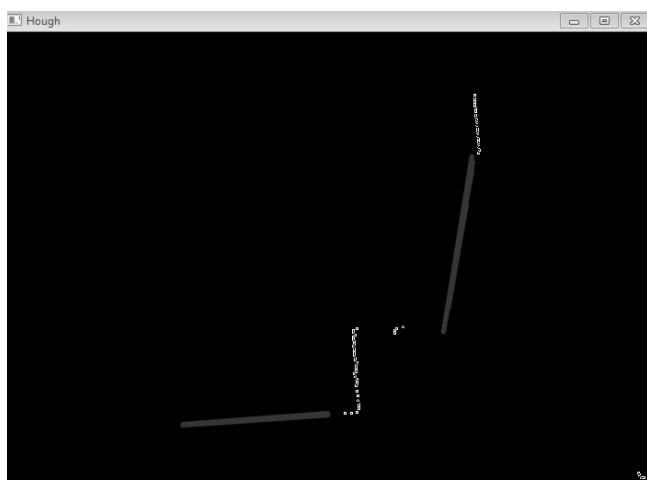


Rys. 3. Zależność ilości punktów oraz kroku kwantyzacji do wielkości tablicy akumulacji
Fig. 3. Dependence of the number of points and the quantization step size on the array accumulation

Można zauważyć, że dobór kroku kwantyzacji musi być kompromisem pomiędzy dokładnością wyznaczenia płaszczyzny a wielkością tablicy akumulatora.

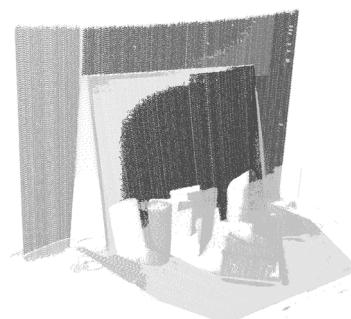
3. Przetwarzanie pojedynczej linii

Dla rozwiązywania problemów związanych z dużym nakładem obliczeniowym oraz wymaganiami sprzętowymi przedstawionych metod, zaproponowano modyfikacje algorytmów. Pierwszą propozycją jest ekstrakcja pojedynczej linii z skanowanej sceny, korzystając ze specyfiki skanera generującego zbiór punktów wzdłuż linii (pionowych). Pierwszym etapem jest przekształcenie punktów składowych linii z układu XYZ do układu XY, tak aby można było wykorzystać Transformatę Hougha dla obrazów 2D. Podejście takie pozwala na wyznaczenie odcinków liniowych znajdujących się na pojedynczej linii. Przykład wykorzystania metody transformaty Hougha dla pojedynczej linii przedstawiono na rys. 4.



Rys. 4. Przykład wykonania transformaty Hougha dla pojedynczej linii
Fig. 4. Example of the Hough Transform for the single line

W efekcie końcowym, po wykonaniu algorytmu dla wszystkich linii, otrzymuje się zbiór niezależnych wyników cząstkowych dla każdej z linii. Następnie w sposób iteracyjny następuje porównanie otrzymanych obiektów w celu wydzielenia segmentów równoległych do siebie. Porównanie odbywa się w sposób zbliżony do działania algorytmu rozrostu płaszczyzn, przez porównanie ze sobą sąsiednich linii, otrzymując zbiór klastrów składających się z segmentów cząstkowych równoległych do siebie. Klastry zawierają tylko niewielki procent skanowanej sceny, co pozwala na znaczne przyspieszenie wyszukiwania obiektów. Dla każdego z klastrów zostaje wykonany algorytm RANSAC, który wyznacza równanie płaszczyzny dla liniowych segmentów cząstkowych. Algorytm jest jeszcze w fazie implementacji, jednak częściowe wyniki dla przykładowej sceny przedstawiono na rys. 5.



Rys. 5. Przykład wykonania algorytmu dla sceny eksperymentalnej
Fig. 5. Example of the algorithm execution for the test data

4. Podsumowanie i wnioski

Zaproponowana metoda pozwala na wstępne przygotowanie danych do wyszukiwania obiektów w chmurze. Jest jednocześnie metodą hybrydową, która korzysta z metod już istniejących wykorzystując ich potencjał. Posiada również znaczny potencjał rozwojowy, gdyż algorytm można w prosty sposób przygotować do obliczeń równoległych, przetwarzając wiele linii niezależnie, w tym samym czasie. Opracowana metoda docelowo może być wykorzystana, jako narzędzie do automatyzacji procesu inwentaryzacji instalacji na podstawie skanu przestrzennego.

Praca współfinansowana ze środków Europejskiego Funduszu Społecznego.



5. Literatura

- [1] Jarząbek-Rychard M., Borkowski A.: Porównanie algorytmów RANSAC oraz rosnących płaszczyzn w procesie segmentacji danych lotniczego skaningu lotniczego, Archiwum Fotogrametrii, Kartografii i Teledetekcji, Vol. 21, Wrocław, 2010.
- [2] Rabbani T. S.: Automatic Reconstruction of Industrial Installations Using Point Clouds and Images, Publications on Geodesy 62, Delft, May 2006.
- [3] Borrmann D., Elseberg J., Lingemann, K., Nüchter A.: The 3D Hough Transform for Plane Detection in Point Clouds: A Review and a new Accumulator Design, 3D Res. 02, 02003, 2011.
- [4] Żorski W.: Metody segmentacji obrazów oparte na transformacie Hougha, Instytut Automatyki i Robotyki. Wydział Cybernetyki, Wojskowa Akademia Techniczna, 2000.