

REJESTRACJA CHMUR PUNKTÓW 3D W OPARCIU O WYODRĘBNIONE KRAWĘDZIE

REGISTRATION OF OVERLAPPING 3D POINT CLOUDS USING EXTRACTED LINE SEGMENTS

Martyna Poręba¹, François Goulette¹

¹ MINES ParisTech, Centre de Robotique, Mathématiques et Systèmes

SŁOWA KLUCZOWE: chmura punktów, matching, rejestracja, transformacja, odcinek

STRESZCZENIE: Artykuł podejmuje tematykę rejestracji czyli łączenia i orientacji chmur punktów do jednego układu współrzędnych. Z praktycznego punktu widzenia proces ten sprowadza się do estymacji parametrów transformacji - rotacji i translacji, na podstawie wybranych elementów dopasowania jak punkty, linie czy płaszczyzny. Wykorzystano krawędzie powstałe w wyniku przecięć sąsiadujących płaszczyzn modelowanych w chmurze punktów. W rezultacie takie elementy geometryczne mogą być dokładnie wyodrębnione nawet w rzadkiej chmurze punktów. Dane symulowane obarczone addytywnym szumem Gaussa posłużyły do przetestowania kilku istniejących metod estymacji pod kątem ich odporności na szum oraz poprawności oferowanego rozwiązania. Dla potrzeb oceny ilościowej wykonanej transformacji zdefiniowano kryterium dokładności wykorzystujące zmodyfikowaną miarę odległości Hausdorffa. Jako że poprawny, automatyczny matching elementów liniowych jest zadaniem trudnym i rzutującym na poprawność estymowanych parametrów, zaproponowano metodę uwzględniającą wzajemne podobieństwo linii. Przeprowadzone testy wykazały, że algorytm ten zapewnia prawidłowe sparowanie linii, a jego dokładność wynosi co najmniej 99%, przy średnio 8% par pominiętych.

1. WPROWADZENIE

Wzajemna rejestracja chmur punktów w jeden model jest niezbędna do dalszych opracowań projektów pomiarowych. Ograniczenie do minimum ilości martwych pól oraz skanowanie stosunkowo dużych obszarów wymuszają projektowanie wielu stanowisk, a w następstwie ich dalsze wyrównanie względem zestawu elementów kontrolnych. Z drugiej strony, różnorodność dostępnych technik pomiarowych sprawia, że integracja danych pochodzących z różnych źródeł (np. fotogrametrii, skaningu naziemnego i lotniczego, baz danych topograficznych), a dostarczających komplementarnych informacji stanowi bardzo ważny aspekt. Rejestracja może przebiegać w oparciu o skanowane tarcze i sygnały celownicze, elementy geometryczne otoczenia (linie, płaszczyzny, cylindry czy sfery). punkty z nakładających się chmur punktów lub inne dane pomiarowe. Niemniej jednak identyfikacja odpowiadających sobie punktów na różnych skanach może okazać się utrudniona lub niemożliwa ze względu na niejednorodną, heterogeniczną strukturę chmur

punktów. Problem ten uwiadamia się szczególnie podczas opracowywania danych laserowych o niskiej gęstości. Najczęściej stosowane metody rejestracji bazują na algorytmie ICP – Iteracyjny Najbliższy Punkt (Iterative Closest Point) zaproponowanym przez (Besl i McKay, 1992). Algorytm ten poprzez kolejne iteracje dąży do zminimalizowania wzajemnej odległości między dwoma chmurami punktów szacując macierz transformacji dla aktualnego, przybliżonego sparowania punktów. Dwa główne etapy tj. wybór punktów homologicznych oraz estymacja parametrów powtarzane są do momentu, aż błąd wyrównania będzie mniejszy niż przyjęte kryterium dokładności. Mimo licznych zalet wersja bazowa algorytmu ICP posiada pewne ograniczenia, które nadal stanowią przedmiot badań. Wprowadzane ulepszenia dotyczą sposobu wyboru punktów (przetwarzanie całości danych lub próbkowanie), strategii matchingu, wagowania i odrzucania błędnych par czy definicji minimalizowanej funkcji kosztu (Douadi, 2007). Wciąż jednak słabą stroną metody pozostaje duża liczba iteracji niezbędna do osiągnięcia konwergencji, a nawet, w przypadku stosunkowo zaszumionych danych, uzyskiwanie zbieżności dla fałszywego minimum. Rozwiązaniem problemu może być wstępna inicjalizacja algorytmu przez wprowadzenie pierwszego oszacowania transformacji. Niemniej jednak takie podejście wymaga często interwencji operatora (manualne wskazanie w chmurze homologicznych punktów) co czyni metodę ICP pół-automatyczną. Krótki przegląd technik rejestracji chmur punktów ukazuje, że obok algorytmów iteracyjnych istnieją także rozwiązania wymagające uprzedniego wyodrębnienia, a następnie ustalenia wzajemnie odpowiadających sobie elementów dopasowania w obu częściowo pokrywających się chmurach punktów.

1.1. Cel badań

Na proces łączenia składają się dwa główne etapy tj. matching wybranych elementów dopasowania i estymacja parametrów transformacji. Wykorzystano elementy liniowe reprezentujące krawędzie powstałe w wyniku przecięć głównych płaszczyzn, uprzednio modelowanych w chmurze punktów. Takie rozwiązania sprawia, że dokładna rejestracja chmur o niskiej gęstości może być również zrealizowana. Co więcej, sama procedura nie wymaga rozmieszczania żadnych tarcz celowniczych przed skanowaniem. W poszukiwaniu optymalnego sposobu estymacji parametrów transformacji na podstawie aktualnego matchingu linii, zaimplementowano i przetestowano trzy algorytmy spośród omówionych w paragrafie 1.2 tj.: EIGEN, ICL(forma ICP) oraz FMII. Szczególny nacisk położono na poprawność oferowanego rozwiązania i odporność poszczególnych metod na szum pomiarowy. Dla celów kontroli dokładności przeprowadzonej rejestracji wykorzystano metrykę Hausdorffa. Stąd, odległość między dwoma zbiorami elementów liniowych (2.2) służy do oszacowania jakości procesu rejestracji. Biorąc pod uwagę, że poprawne, automatyczne sparowanie odcinków jest zadaniem trudnym, a istniejące algorytmy oferują często przybliżone rozwiązanie, zaproponowano nową metodę matchingu (2.1). Skuteczność algorytmu, a co za tym idzie kompletność i poprawność wykonanego sparowania, zostały zweryfikowane i omówione w eksperymentalnej części (3).

1.2. Przegląd istniejących algorytmów bazujących na liniach

Linie proste, wszechobecne w terenach zurbanizowanych, stanowią bogate źródło informacji na temat geometrii obiektów, znajdując również zastosowanie w procesie wzajemnej rejestracji chmur punktów. Wykorzystanie prymitywów liniowych, w odróżnieniu od

punktów, stanowi z algorytmicznego punktu widzenia większe wyzwanie. Jednak same odcinki są łatwiejsze do wykrycia i opisanie, mniej wrażliwe na szum pomiarowy, a ich liczba niezbędna do estymacji optymalnych parametrów transformacji mniejsza.

Zhang i Faugeras (1991) porównują kilka algorytmów estymacji parametrów transformacji opierających się między innymi na rozszerzonym filtrze Kalmana (*Extended Kalman filter*), minimalizacji poprzez metodę najmniejszych kwadratów MNK, czy rozkładzie według wartości osobliwych SVD (*Singular Value Decomposition*). Metody te zostały przeanalizowane przy założeniu znanego dopasowania między odcinkami i dla różnej parametryzacji estymowanej macierzy obrotu. Ostatecznie, opis rotacji za pomocą reprezentacji oś-kąt (*axis-angle representation*) z jednoczesnym wykorzystaniem filtra Kalmana okazuje się najkorzystniejszy pod względem dokładności oferowanego rozwiązania. Rozważając z kolei czas obliczeń metoda ta ustępuje rozwiązaniu EIGEN, gdzie obrót reprezentowany jest poprzez kwaterniony, a do jego estymacji wykorzystano dekompozycję SVD.

Alshawa (2006) proponuje dwa warianty metody ICL (*Iterative Closest Line*). Pierwszy, ICL(forma ICP), wzorowany bezpośrednio na algorytmie ICP lecz różniący się znacznie sposobem obliczania translacji. Drugi, ICL(forma alternatywna), wykorzystujący model transformacji przez podobieństwo (Habib *et al.*, 2004) właściwy dla odcinków o jednakowej długości. Zakładając, że elementy liniowe wyodrębnione niezależnie z dwóch chmur punktów charakteryzują się przeważnie różną długością, wstępny etap obejmuje ujednoczenie długości homologicznych odcinków. Zupełnie inaczej ten sam problem został rozwiązany przez Renaudin *et al.* (2011). Zmodyfikowano algorytm (Habib *et al.*, 2004) uwzględniając w modelu matematycznym wektor różnic położenia końców odcinków. Następnie, wyeliminowano tą dodatkową niewiadomą z dalszego procesu obliczeń poprzez wprowadzenie nowej definicji macierzy wag dla wektora błędów powiązane z równaniami obserwacyjnymi. W obydwu przypadkach, optymalne parametry transformacji szacowane są iteracyjnie, startując od wartości przybliżonych. Ocena dokładności otrzymanych w ten sposób parametrów transformacji wykonana została przez (Canaz i Habib, 2013) i sprowadza się do analizy porównawczej z dwoma innymi metodami tj. rejestracją wykorzystującą płaszczyzny jako elementy dopasowania (Ghanma, 2006) oraz algorytmem ICPP (*Iterative Closest Projected Point*) (Al –Durgham *et al.*, 2011). Metoda ICPP jest wariantem ICP polegającym na minimalizacji odległości pomiędzy punktem jednej chmury a jego rzutem na płaszczyznę zdefiniowaną przez trzy najbliższe punkty drugiej.

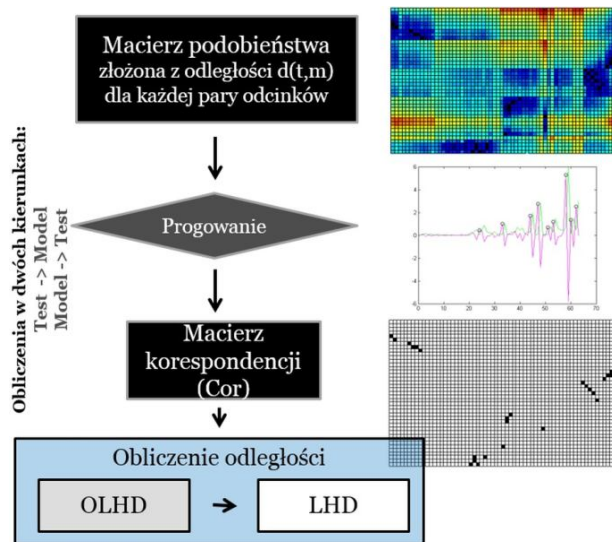
Różne sposoby szacowania parametrów transformacji w oparciu o prymitywy liniowe omówione są także przez Guerra i Pascucci (1999). Ostatecznie, aby zrekompensować brak precyzyjnego matchingu, zasugerowano wykorzystanie trypletu par wybieranych losowo. Takie rozwiązanie polega na przetestowaniu znacznej ilości teoretycznych transformacji, spośród których wybierana jest jedna, zapewniająca najlepsze dopasowanie. Główną wadą takiego podejścia jest złożoność obliczeniowa algorytmu, jak również domyślnie przyjęte założenie według którego środki odcinków tworzą odpowiadające sobie punkty.

Kamgar-Parsi i Kamgar-Parsi (2004) proponują kilka algorytmów dostosowanych dla linii prostych ograniczonych jak i nieograniczonych. W zależności od długości linii wyróżnić można trzy przypadki: 1) FMFI (*Finite Model, Finite Image*), gdzie obydwa

zbiory, na podstawie których wyznaczane są parametry transformacji zawierają odcinki; 2) IMII (*Infinite Model, Infinite Image*) bazujący na liniach ; 3) FMII (*Finite Model, Infinite Image*) stanowiący połączenie obu wcześniejszych przypadków. Niezależnie od wybranego wariantu procedura obliczeniowa jest praktycznie identyczna i polega na utworzeniu funkcji kosztu minimalizującej odległość pomiędzy punktami homologicznymi każdej z N par prymitywów liniowych. Poszukiwanie optymalnej transformacji odbywa się iteracyjnie rozwiązując układ równań nieliniowych zawierający $(6+N)$ niewiadomych. Algorytm inicjalizowany jest poprzez wprowadzenie przybliżonych wartości dla parametru *shift* definiującego położenie odpowiadających sobie punktów. Wykonane przez autorów badania wykazały, że algorytmy są praktycznie zawsze zbieżne do minimum, niezależnie od sposobu inicjalizacji, a czas obliczeń skorelowany jest z liczbą iteracji i oczekiwaną dokładnością końcową. Zaobserwowano również, że metoda FMFI może zawodzić, jeżeli w parze dopasowanych elementów krótszy odcinek nie jest całkowicie zawarty w dłuższym.

2. METODOLOGIA

Głównym celem przeprowadzonych badań była weryfikacja dokładności istniejących metod estymacji parametrów transformacji na podstawie prymitywów liniowych 3D, a także zapewnienie ich poprawnego matchingu. Rysunek 1 przedstawia schemat zaproponowanego algorytmu, na który składają się dwa etapy: dopasowanie odcinków (omówione w paragrafie 2.1) oraz określenie odległości – miary dokładności rejestracji – liczonej między dwoma zbiorami odpowiadających sobie linii (paragraf 2.2).



Rys. 1 Ogólny schemat

2.1. Matching

Kluczowym krokiem algorytmu jest utworzenie macierzy podobieństwa (*similarity matrix*), której każda komórka odpowiadałaby odległości między analizowaną parą odcinków. Wybrano rozwiązanie (Gao i Leung, 2002) dedykowane oryginalnie danym typu 2D, przystosowując je do przestrzeni trójwymiarowej. Przyjmijmy dwa zbiory odcinków Test $T=\{t_1, t_2, \dots, t_i, \dots, t_p\}$ i Model $M=\{m_1, m_2, \dots, m_j, \dots, m_q\}$. Macierz odległości o wymiarze $p \times q$ zgodnym z liczbą elementów tych zbiorów, tworzona jest zgodnie z równaniem (1), uwzględniając jednocześnie odległość kątową $d\theta(t_i, m_j)$, odległość równoległą $dII(t_i, m_j)$ oraz odległość prostopadłą $d^\perp(t_i, m_j)$.

$$d(t_i, m_j) = \sqrt{W \cdot (d\theta(t_i, m_j))^2 + (dII(t_i, m_j))^2 + (d^\perp(t_i, m_j))^2} \quad (1)$$

Wartość parametru W – bezwymiarowej wagi przypisanej odległości kątowej została ustalona empirycznie i wynosi 10.

Kolejny etap to wybór wartości progowej δ , wyznaczanej w funkcji danych. W tym celu zaproponowano, aby w pierwszej kolejności wykonać wstępny matching S wyszukując dla każdej linii ze zbioru T najbliższy i tym samym najbardziej zgodny element w zbiorze M . Zadanie to jest zawsze wykonalne, jako że danemu odcinkowi $t_i \in T$ można przypisać jakikolwiek odpowiednik $m_j \in M$, mimo iż odległość między nimi jest znaczna, a para taka w rzeczywistości nie istnieje. Startując z tak utworzonego dopasowania S , odszukanie optymalnej wartości progowej δ sprowadza się do analizy odległości, posortowanych rosnąco i powiązanych z aktualnymi parami. Obliczane są zatem różnice sąsiednich wyrazów ciągu. Proces wykonywany jest dwukrotnie, przy czym za drugim razem dla nowo utworzonej listy wartości. Pierwszy pik (maksimum lokalne) wykryty przez funkcję analizującą ekstrema lokalne (większe od zadanej „czułości” funkcji) odpowiada poszukiwanej wartości progowej δ .

Ostatecznie binarna macierz korespondencji Cor (*correspondence matrix*) opisująca relacje pomiędzy odcinkami ze zbioru T i M tworzona jest jako:

$$Cor = \{(i, j) \in \mathbb{N}^2 : \forall (t_i \in T, m_j \in M), d(t_i, m_j) \leq \delta\} \quad (2)$$


Innymi słowy, powstaje ona w wyniku progowania macierzy podobieństwa. Szczegółowa dyskusja dotycząca sposobu definiowania odległości między dwoma odcinkami oraz doboru wartości progowej δ zawarta jest w (Poreba i Goulette, 2013). Dokładność i skuteczność metody matchingu została zweryfikowana, a wyniki przedstawione w dalszej części opracowania.

2.2. Metryka Hausdorffa jako miara odległości między dwoma zbiorami linii

Dla potrzeb obliczenia odległości pomiędzy dwoma zbiorami linii wykorzystano metrykę Hausdorffa szeroko stosowaną w cyfrowym przetwarzaniu obrazów. Z definicji odpowiada ona maksimum dwóch funkcji $h(T, M)$ i $h(M, T)$, gdzie:

$$h(T, M) = \max_{t_i \in T} \min_{m_j \in M} d(t_i, m_j) \quad (3)$$

i oznacza największą odległość d zbioru T do najbliższego elementu zbioru M . Odległość $h(T, M)$ nazwana jest także skierowaną miarą odległości Hausdorffa zależy od kierunku liczenia ($h(T, M) \neq h(M, T)$), co jest efektem zróżnicowania położenia lub kształtu porównywanych elementów (Rys. 2). Sama zaś odległość $d(t_i, m_j)$ pomiędzy elementami $t_i \in T$ i $m_j \in M$ może być liczona dowolnie, na przykład za pomocą metryki euklidesowej.



Rys. 2 Idea odległości Hausdorffa dla dwóch linii łamanych

Zastosowano formułę wprowadzoną przez (Gao i Leung, 2002). Odwołuje się ona do zmodyfikowanej metryki Hausdorffa i jest odpowiedniejsza dla celów porównywania dwóch zbiorów odcinków. Zasadnicza różnica polega jednak na uwzględnieniu w obliczeniach wyłącznie odpowiadających sobie linii, usystematyzowanych przez macierz *Cor*. Skierowana odległość Hausdorffa OLHD (*Oriented Line Hausdorff Distance*) jest zatem równa:

$$OLHD(T, M) = \frac{1}{\sum_{m_j \in M} L_{m_j}} \sum_{(i,j) \in Cor} L_{m_j} d(t_i, m_j) \quad (4)$$

gdzie L_{m_j} długość j-tego odcinka ze zbioru M , indeksowanego przez *Cor*, a odległość $d(t_i, m_j)$ obliczana jest zgodnie z równaniem (1). Takie rozwiązanie oparte na średniej ważonej dostarcza wiarygodniejszych wyników, ponieważ dłuższe linie charakteryzujące się wyższą dokładnością, są bardziej uprzywilejowane (większa waga). Ostatecznie, zmodyfikowana odległość Hausdorffa LHD (*Line Hausdorff Distance*) – wskaźnik dokładności rejestracji, wyznaczana jest jako:

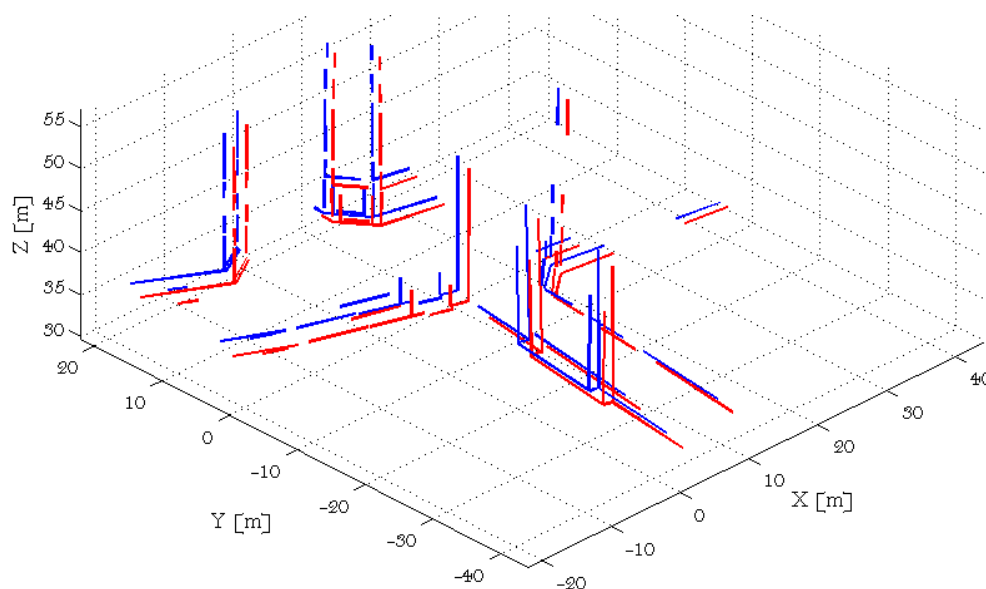
$$LHD(T, M) = \max(OLHD(T, M), OLHD(M, T)) \quad (5)$$

Biorąc pod uwagę, że definicja metryki Hausdorffa wymaga niezależnego określenia dwóch miar skierowanych $OLHD(T, M)$ i $OLHD(M, T)$, również matching linii (macierz korespondencji *Cor*) generowany jest dwukrotnie, zapewniając tym samym kontrolę wyników.

3. WYNIKI I Dyskusja

3.1. Ocena wybranych algorytmów estymacji parametrów transformacji

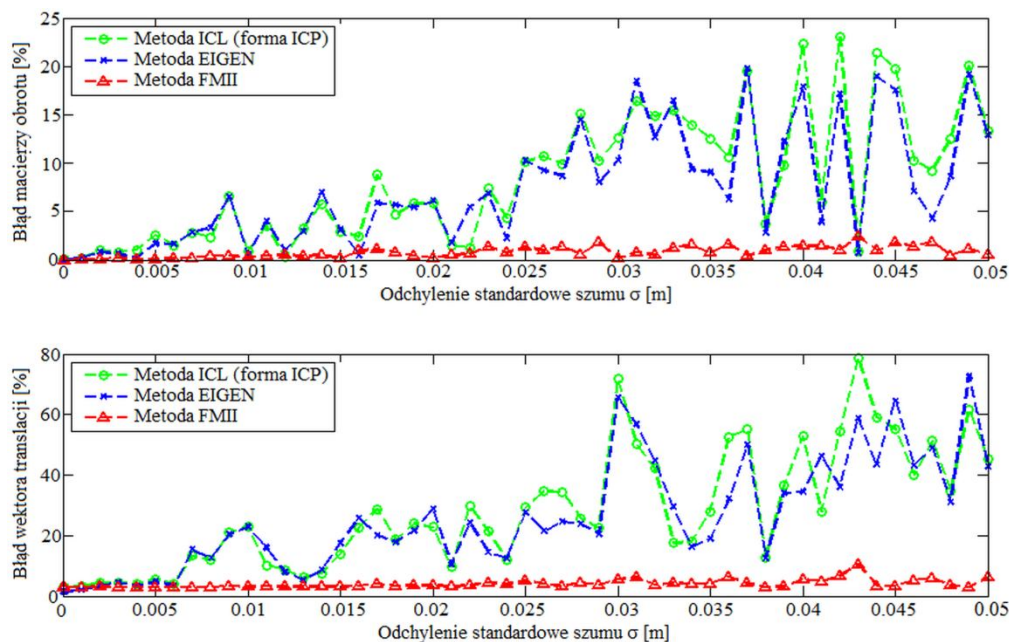
Poszukując optymalnego algorytmu estymacji parametrów transformacji na podstawie sparowanych elementów liniowych, przetestowano trzy algorytmy: EIGEN (Zhang i Faugeras, 1991), ICL (forma ICP) (Alshawa, 2006) oraz FMII (Kamgar – Parsi i Kamgar-Parsi, 2004). Wszystkie algorytmy zaimplementowano w środowisku Matlab[®]. Wybrane metody charakteryzuje różne podejście do problemu, a jedyne podobieństwo można upatrywać w dwuetapowym procesie obliczeń tzn. najpierw estymowana jest macierz rotacji \hat{R} , która następnie niezbędna jest do oszacowania translacji \hat{T} . Badania oparto na danych symulowanych wygenerowanych tak, aby jeden zbiór odcinków stanowił modyfikację drugiego. Przeanalizowano dwa scenariusze: 1) współrzędne końców odcinków obarczono wyłącznie białym szumem gaussowskim o zadanym odchyleniu standardowym σ ; 2) dodatkowo wprowadzono znane parametry rotacji R (macierz małych kątów) i translacji T . Testy wykonano dla różnych wartości σ szumu, zmienianej z interwałem 0.001 m w przedziale od $\sigma = 0.00$ m do $\sigma = 0.05$ m.



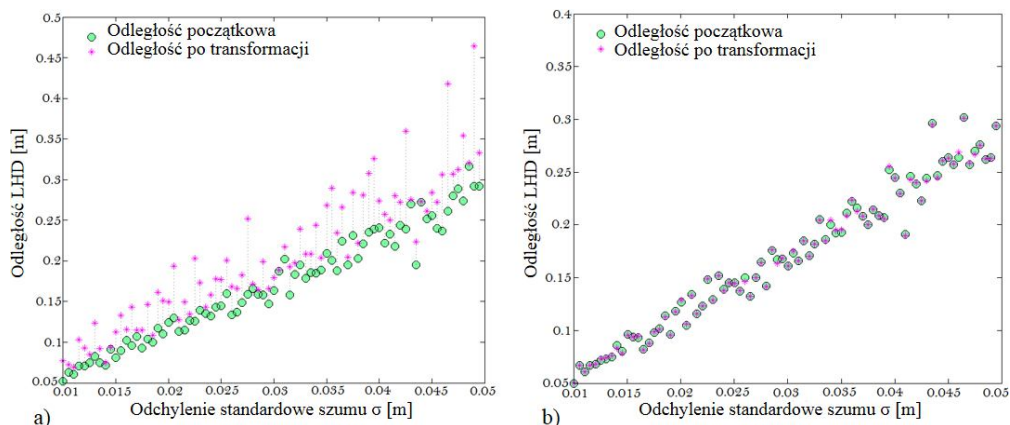
Rys. 3 Przykład danych testowych

Rysunek 4 ilustruje uzyskane błędy odpowiednio dla rotacji i translacji w stosunku do wartości rzeczywistych: wektora translacji $T=[-1\text{ m};0.5\text{ m};1\text{ m}]$, oraz trzech kątów Eulera $(1^\circ,-1^\circ,1^\circ)$ definiujących obrót. Algorytmy ICL(forma ICP) i EIGEN dają zbliżone wyniki, mimo iż wykorzystują różną reprezentację odcinków oraz sposób oszacowania wektora translacji. Obie te metody cechuje niska odporność na szum. Błąd estymacji macierzy obrotów na poziomie 5% osiągany jest dla odchylenia standardowego σ szumu nie

przekraczającego 0.015 m. Zdecydowanie najlepszym i najbardziej stabilnym obliczeniowo algorytmem okazał się FMII, który bez względu na wprowadzony szum oferuje dokładne rozwiązanie. Błąd rotacji e_R jest niższy od 0.5 % dla $\sigma < 0.02$ m, jednocześnie nie przekraczając 2.4 % dla pozostałych wartości σ . Błąd wektora translacji e_T przewyższa e_R i oscyluje w przedziale od 2.9% do 10.4%.



Rys. 4 Porównanie algorytmów: błąd rotacji i translacji



Rys. 5 Porównanie algorytmów- odległość Hausdorffa LHD: a) ICL(forma ICP); b) FMII

Aby zobrazować jak relatywnie niewielkie błędy estymacji parametrów transformacji wpływają na jakość wykonanej rejestracji, obliczono odległość Hausdorffa LHD. Zastosowano dane symulowane obarczone jedynie addytywnym szumem białym

o zadanym odchyleniu standardowym σ . Badaniu podano algorytm ICL(forma ICP) i FMII. Zaobserwowano, że w przypadku metody ICL nawet mały błąd położenia końców odcinków znacząco wpływa na wynik. W rezultacie, położenie odcinków po rejestracji ulega zmianie (co nie powinno mieć miejsca skoro wprowadzone parametry transformacji były zerowe), a ich wzajemna odległość wzrasta w stosunku do wartości początkowej (Rys.5).

3.2. Kontrola poprawności matchingu

Ocenę zaproponowanego algorytmu matchingu wykonano w oparciu o sześć zbiorów testowych. Uzyskane wyniki porównano z rzeczywistym sparowaniem (*ground truth*). Za każdym razem określano liczbę par: 1) poprawnie zidentyfikowanych TP (True Positive); 2) poprawnie odrzuconych TN (True Negative); 3) błędnie dopasowanych FP (False Positive); 4) pominiętych FN (False Negative). Na tej podstawie utworzono tzw. macierze pomyłek (*confusion matrix*) oraz zdefiniowano trzy wskaźniki: 1) *Accuracy*; 2) *Sensitivity*; 3) *Specificity*. Poszczególne wartości zestawiono w Tabeli 1, oddzielnie dla obu kierunków obliczeń.


$$Accuracy = \frac{TP + TN}{(TP + TN + FP + FN)} \quad Sensitivity = \frac{TP}{(TP + FN)} \quad (8)$$

$$Specificity = \frac{TN}{(TN + FP)}$$

Tab. 1 Dokładność algorytmu matchingu

Dane	Accuracy [%]		Sensitivity [%]		Specificity [%]		LHD[m]
	T→M	M→T	T→M	M→T	T→M	M→T	
D1	98.8	99.8	100	91.7	99.9	99.8	0.518
D2	99.5	99.5	93.1	93.1	99.7	99.7	0.302
D3	99.7	99.7	91.7	91.7	99.8	99.8	0.560
D4	99.6	99.6	85.7	95.2	99.7	99.6	0.671
D5	99.3	98.9	90.9	90.9	99.4	99.0	1.257
D6	99.7	99.5	91.7	91.7	99.7	99.6	0.657

Uzyskane wyniki pokazują, że proponowana metoda zapewnia prawidłowy matching linii, a jej dokładność (*Accuracy*) tzn. zdolność poprawnego rozróżnienia, spośród wszystkich możliwych kombinacji par odcinków, rzeczywistego dopasowania wynosi średnio 99 %. Za każdym razem wykryto około 92 % istniejących par (*Sensitivity*). Stąd wniosek, że prawdopodobieństwo FN (niesparowania dwóch homologicznych linii) jest stosunkowo niewielkie. Wartość parametru *Specificity* określającego skuteczność algorytmu matchingu w identyfikacji i odrzucaniu nieistniejących par (TN) wynosi około 99.7%.



Rys. 6 Przykładowe błędy dopasowania: a) FP; b)FN

Ponadto zauważono, że liczba utworzonych FP rośnie wraz ze wzrostem odległości między dwoma zbiorami linii i przy LHD równym 1.257 m może oznaczać nawet o 73 % więcej dopasowanych par. Przyczyn tego rodzaju błędu należy upatrywać w wartości progowej δ , której wielkość wynika bezpośrednio ze wzajemnego oddalenia chmur punktów. Jak pokazuje Rysunek 6a, duże przesunięcie pionowe dP znajduje swoje odzwierciedlenie w doborze δ . W następstwie odcinki 17-18 i 15-16 są dodatkowo łączone odpowiednio z odcinkiem 47-48 i 15-16, jako że odległość $d(t,m)$ między nimi jest mniejsza niż δ . Błędy te można zminimalizować dopasowując odcinki wyłącznie w relacji jeden-do-jednego. Warto jednak zaznaczyć, że na tym etapie należy zmierzyć się z typowym problemem nad-segmentacji (*over-segmentation*) skutkującym tym, że w rzeczywistości odcinki powinny być łączone w stosunku jeden-do-wielu. Kolejny problem to obecność FN czyli par, których nie udało się dopasować mimo odpowiedniej wartości progowej. Rysunek 6b ilustruje przykład takiego błędu, gdzie dwie praktycznie równoległe linie nie zostały sparowane, jako że odległość równoległa $d_{II}(t,m)$ jest większa od przyjętego δ . Remedium może być zgrubna rejestracja, przed matchingiem, pozwalająca zredukować wzajemną odległość chmur punktów.

4. LITERATURA

Al-Durgham M., Datchev I., Habib A., 2011. Analysis of Two Triangle-Based Multi-Surface Registration Algorithms of Irregular Point Clouds, ISPRS Workshop Laser Scanning 2011, vol. XXXVIII-5/W12, 29-31 sierpień, Calagary, Kanada.

Alshawa M., 2006. Consolidation des nuages de points en lasergrammétrie terrestre. Nouvelle approche basée sur les entités linéaires. Praca magisterska INSA Strasbourg.

- Belton D., Mooney B., Snow T., Kwang-Ho B., 2011. Automated Matching of Segmented Point Clouds to As-built Plans. *Proceedings of the Surveying & Spatial Sciences Biennial Conference*, 21-25 listopad, Wellington, Nowa Zelandia.
- Besl P.J., McKay N.D., 1992. A method for registration of 3-D shapes. *IEEE Transactions of Pattern Analysis and Machine Intelligence*, vol. 14, nr 2, s.239-256.
- Canaz S., Habib A., 2013. Planar and linear feature –based registration of terrestrial laser scans with minimum overlap using photogrammetric data. *Proceedings of the 8th International Symposium on Mobile Mapping Technology*, 1-3 maj, Tainan, Tajwan.
- Ghanma M., 2006. Integration of Photogrammetry and LIDAR. Praca doktorska Department of Geomatics Engineering, University of Calagary.
- Douadi L., 2006. Contribution à l'étude du recalage de données 3D/couleur. Praca doktorska Université Montpellier II.
- Gao Y., Leung M.K., 2002, Line segment Hausdorff distance on face matching. *The Journal of the Pattern Recognition Society*, vol. 35, s.361-371.
- Guerra C., Pascucci V., 1999. On matching Sets of 3D Segments. *Proceedings SPIE Vision Geometry VIII*, vol. 3811, s.157-167.
- Habib A.F., Ghanma M.S., Tait M., 2004. Integration of LIDAR and photogrammetry for close range applications. *ISPRS Proceedings of XXth Congress*, 12-23 lipiec, Sтамбул, Turcja.
- Kamgar-Parsi B., Kamgar-Parsi B., 2004. Algorithms for Matching 3D Line Sets. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 26 nr. 5, s.361-371.
- Li W., Li X., Bian Y., Zhao H., 2012, Multiple View Point Cloud Registration Based on 3D Lines. *Proceedings of the 2012 International Conference on Image Processing, Computer Vision & Pattern Recognition*, Las Vegas, USA.
- Poreba M., Goulette F., 2013. Line Segment-based Approach for Accuracy Assessment of MLS point clouds in Urban Areas. *Proceedings of the 8th International Symposium on Mobile Mapping Technology*, 1-3 maj, Tainan, Taiwan.
- Renaudin E., Habib A., Kersting A.P., 2011. Feature-Based Registration of Terrestrial Laser Scans with Minimum Overlap Using Photogrammetric Data. *ETRI Journal*, vol. 33, nr. 4, pp.517-527.
- Yao J., Ruggeri M.R., Taddei P., Sequeira V., 2010. Robust range image registration using 3D lines. *Proceedings of 2010 IEEE 17th International Conference of Image Processing*, 26-29 wrzesień, Hong Kong, Chiny.
- Zhang Z., Faugeras O.D., 1991. Determining Motion from 3D Line Segment Matches: a comparative Study. *Journal Image and Vision Computing*, vol. 9 nr. 1, s.10-19.

REGISTRATION OF OVERLAPPING 3D POINT CLOUDS USING EXTRACTED LINE SEGMENTS

KEY WORDS: point cloud, matching, registration, transformation, line segment

Summary

The registration of 3D point clouds collected from different scanner positions is necessary in order to avoid occlusions, ensure a full coverage of areas, and collect useful data for analyzing and documenting the surrounding environment. This procedure involves three main stages: 1) choosing appropriate features, which can be reliably extracted; 2) matching conjugate primitives; 3) estimating the transformation parameters. Currently, points and spheres are most frequently chosen as the registration features. However, due to limited point cloud resolution, proper identification and precise measurement of a common point within the overlapping laser data is almost impossible. One possible solution to this problem may be a registration process based on the Iterative Closest Point (ICP) algorithm or its variation. Alternatively, planar and linear feature-based registration techniques can also be applied.

In this paper, we propose the use of line segments obtained from intersecting planes modelled within individual scans. Such primitives can be easily extracted even from low-density point clouds. Working with synthetic data, several existing line-based registration methods are evaluated according to their robustness to noise and the precision of the estimated transformation parameters. For the purpose of quantitative assessment, an accuracy criterion based on a modified Hausdorff distance is defined. Since an automated matching of segments is a challenging task that influences the correctness of the transformation parameters, a correspondence-finding algorithm is developed. The tests show that our matching algorithm provides a correct pairing with an accuracy of 99 % at least, and about 8% of omitted line pairs.

Dane autorów:

Dr inż. Martyna Poręba
e-mail: martyna.poreba@mines-paristech.fr
telefon: 12 617 39 93

Prof. dr hab. inż. François Goulette
e-mail: francois.goulette@mines-paristech.fr
telefon: (+33) 14 051 92 35

Przesłano 20.10.2014
Zaakceptowano 20.12.2014