
Nowy algorytm 6DSLAM wykorzystujący semantyczne rozpoznanie otoczenia

*Janusz Będkowski*¹, Karol Majek¹, Andreas Nüchter²*

Streszczenie

W artykule przedstawiono modyfikację algorytmu 6DSLAM wykorzystującą semantyczne rozpoznawanie otoczenia. Zastosowanie semantycznego podejścia nie tylko poprawia w porównaniu do klasycznej metody dokładność tworzonej mapy metrycznej przez robota mobilnego, ale także umożliwia tworzenie takiej mapy w trudnych warunkach terenowych. Przedstawiono eksperymenty tworzenia mapy metrycznej/semantycznej budynków uwzględniając jazdę poziomą oraz kierunku pionowym po schodach. Porównano wynik z poprzednią implementacją algorytmu 6DSLAM. Nowe podejście poprawia spójność oraz dokładność mapy metrycznej. Zastosowanie semantycznego rozpoznawania otoczenia pozwala na rozszerzenie mapy metrycznej o nowe informacje o charakterze jakościowym, w tym przypadku rozróżniane są ściany, podłoga, sufit oraz punkty charakteryzujące się otoczeniem nieuporządkowanym.

1. WPROWADZENIE ORAZ OBECNY STAN WIEDZY

Nowy algorytm 6DSLAM wykorzystujący semantyczne rozpoznawanie otoczenia został przedstawiony na rysunku 1, za pomocą prostokątnych ramek wskazano modyfikacje w porównaniu do oryginalnego algorytmu[4]. Wszystkie modyfikacje zostały zaimplementowane w technologii obliczeń równoległych NVIDIA CUDA. Wejściem algorytmu jest zbiór par - dane z odometrii/IMU oraz lokalna chmura punktów. Wszystkie obserwacje są pozyskane w schemacie stop-skan w celu uzyskania jak największej dokładności pomiaru (w pracy [5] pokazano przewagę dokładności map metrycznych w strategii skanowania – stop-skan w porównaniu do skanowania w trybie ciągłym). Nowe funkcjonalności w postaci modułu filtracji danych oraz rozrzedzania (ang. data filtering and subsampling) zostały szerzej

* Praca jest współfinansowana przez Narodowe Centrum Badań i Rozwoju w ramach projektu "Badania Mobilnego Systemu Wspomagającego Projektowanie Przestrzenne", LIDER/036/659/L-4/12/NCBR/2013 oraz Narodowe Centrum Nauki w ramach projektu „Metodyka tworzenia modeli semantycznych na podstawie obserwacji robota mobilnego” DEC- 2011/03/D/ST6/03175

¹Institut Maszyn Matematycznych, ul. Krzywickiego 34, 02-078 Warszawa, www.imm.org.pl

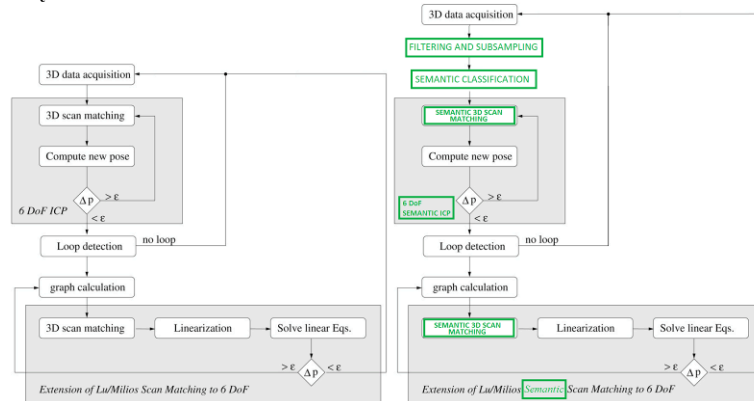
²Julius-Maximilians-University Würzburg Am Hubland D-97074 Würzburg, Germany
<http://www7.informatik.uni-wuerzburg.de>

omówione w pracy [6]. Zadaniem tego modułu jest przygotowanie zbioru danych poprzez redukcję punktów 3D o punkty kwalifikowane jako szum oraz zagwarantowanie jednakowej gęstości. Tak przygotowany zbiór danych jest następnie wykorzystany do stworzenia wstępnego modelu metrycznego za pomocą zmodyfikowanej metody ICP (ang. Iterative Closest Point). Modyfikacja polega na wprowadzeniu informacji semantycznej podobnie jak w pracy [8] (klasyfikacja punktów 3D na cztery klasy: sufit, podłoga, ściana, punkt niesklasyfikowany do poprzednich klas) w procedurze NNS (ang. Nearest Neighbourhood Search), z tą różnicą, że obliczenia są wykonywane na procesorze GPU. W konsekwencji zastąpiono dekompozycję przestrzeni kd-tree na regularną siatkę (Regular Grid Decomposition). Uproszczono w ten sposób las kd-tree poprzez zastosowanie mniej skomplikowanej struktury danych przyspieszając jednocześnie obliczenia na większych zbiorach danych. Autorska implementacja metody NNS wykorzystująca obliczenia równoległe w CUDA (ang. Compute Unified Device Architecture) została szerzej omówiona w [2] i [6]. Wykorzystanie przynależności punktu do określonej klasy jako czynnika dyskryminującego dopasowania w algorytmie ICP jest odmianą koncepcji "closest compatible points" wspomnianej w pracy [10]. Problem dopasowania chmury punktów D do chmury punktów M został zdefiniowany jako minimalizacja funkcji danej wzorem:


$$E(\mathbf{R}, \mathbf{t}) = \sum_{i=1}^{N_m} \sum_{j=1}^{N_d} w_{ij} \|\mathbf{m}_i^c - (\mathbf{R}\mathbf{d}_j^c + \mathbf{t})\|^2$$

Przy czym w_{ij} jest współczynnikiem przyjmującym wartości 0 lub 1. Wartość 1 oznacza parę punktów o tej samej semantycznej etykiecie c spośród czterech omawianych w tym artykule klas. Algorytm ICP wyznacza macierze rotacji \mathbf{R} oraz przesunięcia \mathbf{t} w sposób iteracyjny. Na rysunku 2 przedstawiono ideę semantycznej metody NNS polegającej na poszukiwaniu zbioru par punktów należących do tej samej klasy. W rezultacie punkty należące do różnych klas, mimo bliskiego sąsiedztwa nie będą brały udziału w algorytmie ICP, dzięki czemu algorytm osiąga oczekiwaną zbieżność w krótszym czasie. Uzyskano satysfakcjonujący wynik mapowania metrycznego budynku, poruszając się robotem nawet po schodach, gdzie wyeliminowano problem NNS punktów sufitu jednej chmury punktów oraz punktów podłogi drugiej chmury punktów, będącej obserwacją z wyższej kondygnacji budynku. *Zastosowanie informacji jakościowej w postaci semantycznego rozpoznawania punktów 3D umożliwiło poprawę ilościową w postaci dokładniejszej mapy metrycznej 3D w porównaniu do oryginalnego algorytmu 6DSLAM.* Kolejnym krokiem jest algorytm poszukiwania pętli. Po wykryciu pętli następuje optymalizacja globalna w wyniku której powstaje spójny model metryczny 3D. Poprzez spójność należy rozumieć mapę metryczną 3D będącą zbiorem obserwacji (lokalne chmury 3D) połączone w graf którego węzłami są obserwacje robota a krawędzie korespondują do sąsiednich obserwacji znalezionych metodą odległości Euklidesowej pomiędzy węzłami. W algorytmie przyjęto, że dwa węzły, których odległość jest mniejszej niż dwa metry kwalifikują się wstępnie jako krawędź, dodatkowa metoda sprawdzająca stopień pokrycia

chmur punktów weryfikuje dodanie tej krawędzi do grafu. Przyjęto, że jeżeli dla 70% punktów jednej chmury punktów znaleziono najbliższych sąsiadów z drugiej chmury to krawędź zostaje dodana do grafu. W procedurze optymalizacji metodą LUM[4] także zastosowano semantyczne rozpoznawanie otoczenia. Zastosowano tą samą metodę NNS co w metodzie ICP.



Rys. 1. Porównanie algorytmu 6DSLAM wykorzystującego semantyczne rozpoznawanie otoczenia do algorytmu bazowego [4] dostępnego w bibliotece 3DTK[7]. Nowa funkcjonalność w postaci filtracji danych i rozrzedzania, nowej metody ICP (semanticGPUICP) wykorzystując informację semantyczną oraz nowej metody optymalizacji grafu wykorzystując także informację semantyczną (semanticLUM – Extension of Lu/Milios Semantic Scan Matching to 6 DoF)



Rys. 2. Zobrazowanie idei poszukiwania najbliższych sąsiadów wykorzystując semantyczne rozpoznawanie otoczenia na pary punktów podłoga-podłoga (czarne odcinki), sufit-sufit (niebieskie odcinki), ściana-ściana (zielone odcinki) oraz punkty nie należące do tych klas (pary zaznaczone kolorem czerwonym)

1.1. Semantyczne rozpoznawanie otoczenia

Semantyczne rozpoznawanie obiektów w tym artykule sprowadza się do klasyfikacji chmury punktów na cztery klasy “sufit”, “podłoga”, “ściana”, “punkt o otoczeniu nieregularnym”. To podejście jest inspirowane wynikami przedstawionymi w pracy [9]. W pierwszym etapie każda obserwacja w postaci chmury punktów 3D przekształconej geometrycznie uwzględniając pomiaru IMU (kąty przechylenia robota w osiach “pitch”, “roll”) jest poddawana procedurze filtrowania oraz rozrzedzania. W kolejnym kroku następuje klasyfikacja na punkty

o otoczeniu “płaskim” oraz punkty z otoczeniem „nieregularnym”. Operacja przebiega równolegle dla każdego punktu na procesorze obsługującym technologię CUDA. W tym celu obliczane są wektory normalne dla każdego punktu metodą PCA(Principal Component Analysis)/SVD(Singular Value Decomposition) omówioną w pracy[6]. Wstępna klasyfikacja polega na sprawdzeniu czy otoczenie każdego z punktów może zostać aproksymowane płaszczyzną. W tym celu sprawdzana jest odległość wszystkich punktów z sąsiedztwa od płaszczyzny. W przypadku spełnienia kryterium odległości dany punkt otrzymuje etykietę “kształt płaski” w innym przypadku ten punkt otrzymuje etykietę “punkt o otoczeniu nieregularnym”. W kolejnym kroku sprawdzane jest czy punkt znajduje się nad robotem czy też pod robotem. Jeśli punkt znajduje się nad robotem i wartość Y wektora normalnego (przy czym płaszczyzna XZ to płaszczyzna poziomego ruchu robota, a Y to kierunek pionowy) jest mniejsza niż -0.9 to punkt jest klasyfikowany jako sufit. Jeśli punkt znajduje się pod robotem i wartość Y wektora normalnego jest większa od 0.9 to punkt jest klasyfikowany jako podłoga. Inne punkty o etykietach “płaski” nie należące do klasy “sufit”, “podłoga” klasyfikowane są jako “ściana”. W ten sposób powstaje lokalna mapa semantyczna otoczenia robota.

1.2. Robot mobilny

W celu przeprowadzenia eksperymentów zmodyfikowano robota mobilnego drRobot Jaguar4x4 przedstawionego na rysunku 2. Robot mobilny wyposażony w laserowy system pomiarowy 3D opisany w [3] został przetestowany w zawodach robotycznych Eurathlon 2013[1] gdzie dostarczył dokładną mapę metryczną otoczenia pracując w trudnych warunkach USAR(Urban Search and Rescue). Modyfikacja robota polegała na zastąpieniu prototypu lasera komercyjnym rozwiązaniem głowicy 3D umożliwiającej montaż laserów z rodziny SICK (LMS100, LMS TiM551). Robot jest w stanie dostarczyć dane z IMU (Inertial Measurement Unit), dane odometryczne oraz lokalne chmury punktów 3D. Zbiór tych danych pozyskiwanych w schemacie stop-skan posłużył do walidacji algorytmu 6DSLAM.




Rys. 3. Robot mobilny wykorzystany podczas eksperymentów


2. EKSPERYMENTY

Celem eksperymentu była weryfikacja tezy, że *zastosowanie informacji jakościowej w postaci semantycznego rozpoznawania poprawia efekt ilościowy w postaci dokładniejszej mapy metrycznej 3D w porównaniu do oryginalnego algorytmu*


6DSLAM. W związku z tym przeprowadzono eksperyment w którym zadaniem robota była akwizycja danych podczas poruszania się po budynku uwzględniając ruch po płaszczyźnie oraz ruch po schodach. Zjazd po schodach dla tego konkretnego typu robota jest zagadnieniem trudnym w porównaniu do np.: robotów gąsienicowych, ponieważ pomiary odometrii oraz IMU są narażone na skoki wartości lub też nasycenie sensorów akcelerometrycznych IMU ze względu na liczne lokalne przyspieszenia (udary) bazy mobilnej. Naszym zdaniem jest to wiarygodny eksperyment pokazujący rzeczywisty problem tworzenia mapy semantycznej budynku. Na rysunku 4 przedstawiono wynikową mapę semantyczną fragmentu budynku Wydziału Mechatroniki Politechniki Warszawskiej (klatka schodowa + korytarz o długości około 50m). Kolorem niebieskim oznaczono punkty z klasy “sufit”, kolorem zielonym punkty z klasy “ściana”, kolorem czarnym punkty z klasy “podłoga”, kolor czerwony określa punkty o otoczeniu nieregularnym. Na rysunku 5 przedstawiono wynik porównania algorytmów 6DoF ICP oraz 6DoF semanticICP. Stwierdzono, że po odpowiednio dużej liczbie iteracji ICP nie nastąpił problem tworzenia par punktów sufit-podłoga ale widać problem dokładności w sensie metrycznym. Warto tu zaznaczyć, że dokładność pomiaru kąta obrotu robota jest na poziomie 20 stopni. Dopiero informacja jakościowa pozwoliła na zwiększenie dokładności dopasowania obserwacji przy tej samej liczbie iteracji wynoszącej 150.



Rys. 4. Mapa semantyczna fragmentu budynku Wydziału Mechatroniki Politechniki Warszawskiej (klatka schodowa + korytarz o długości około 50m) uzyskana za pomocą algorytmu 6DoF semantic ICP (główny komponent algorytmu semantic6DSLAM).




Rys. 5. Góra – rzut z boku mapy metrycznej uzyskanej metodą 6DoF GPUICP (kolor czerwony) oraz metodą semanticGPUICP (kolor niebieski). Dół - rzut z góry mapy metrycznej uzyskanej metodą GPUICP (kolor czerwony) oraz metodą semanticGPUICP (kolor niebieski)




Rys. 6. A – zbliżenie rzutu z boku z rysunku 5. B – mapa semantyczna powstała poprzez naniesienie informacji jakościowej (klasy “ściana”-zielony, “podłoga”-czarny, “sufit”-niebieski, “punkty o otoczeniu nieregularnym”-czerwony) na mapę metryczną (rysunek A, kolor niebieski).

Drugi eksperyment pokazuje wynik działania algorytmu semantic6DSLAM (rysunek 7). Na rysunku 8 pokazano przewagę jakościowego podejścia (semanticGPUICP) do klasycznego (6DoF GPUICP) w algorytmie dopasowania obserwacji. Podejście jakościowe eliminuje skutecznie problem tworzenia par punktów sufit-podłoga. Metoda semanticLUM skutecznie tworzy ostateczną spójną mapę metryczną/semantyczną uwzględniając dwie pętle.



Rys. 7. A - mapa semantyczna fragmentu budynku (korytarz, klatka schodowa – pięć kondygnacji, garaż podziemny, wyjazd z garażu, otoczenie przed budynkiem). B – trajektoria ruchu robota (graf połączeń pomiędzy obserwacjami) – pokazane dwie pętle (LOOP1, LOOP2) oraz schody (STAIRS). Mapa semantyczna powstała z zastosowaniem opracowanej modyfikacji algorytmu 6DSLAM.



Rys. 8. A – odpowiednio od góry rzut z góry, rzut z boku, rzut z drugiego boku mapy metrycznej fragmentu budynku z rysunku 7. B – wizualizacja informacji jakościowej (klasy „ściana”-zielony, „podłoga”-czarny, „sufit”-niebieski, „punkty o otoczeniu nieregularnym”-czerwony)

PODSUMOWANIE

W artykule zweryfikowano doświadczalnie tezę, że zastosowanie informacji jakościowej w postaci semantycznego rozpoznawania otoczenia poprawia dokładność mapy metrycznej 3D w porównaniu do oryginalnego algorytmu 6DSLAM. Przedstawiono modyfikację algorytmu 6DSLAM uwzględniającą semantyczne rozpoznawanie otoczenia polegające na klasyfikacji punktów na cztery klasy „sufit”, „podłoga”, „ściana”, „punkt o otoczeniu nieregularnym”. Przeprowadzono eksperymenty uwzględniające pozyskiwanie danych przez robota mobilnego poruszającego się po budynkach w płaszczyźnie poziomej oraz pionowej (zjazd ze schodów). Uzyskano wynik w sensie jakościowym oraz ilościowym – zaobserwowano poprawę dokładności map metrycznych. W przyszłych pracach badawczych planowane jest przeprowadzenie badań złożoności obliczeniowej algorytmu oraz badania ilościowe polegające na weryfikacji dokładności map metrycznych uwzględniając geodezyjne techniki pomiarowe.

LITERATURA

- [1] Karol Majek, Paweł Musialik, Piotr Kaczmarek, Janusz Będkowski, Lesson Learnt from Eurathlon 2013 Land Robot Competition, *Automatyzacja – Nowości i Perspektywy Automation 2014*
- [2] Janusz Marian Bedkowski, Andrzej Maslowski, Geert De Cubber, (2012) "Real time 3D localization and mapping for USAR robotic application", *Industrial Robot: An International Journal*, Vol. 39 Issue: 5, 464-474
- [3] Karol Majek, Michał Pełka, Janusz Będkowski, Maciej Cader, Andrzej Masłowski Projekt autonomicznego robota inspekcyjnego, *Pomiary, Automatyk, Robotyka 278-282*, nr 2/2013
- [4] D. Bormann, J. Elsberg, K. Lingemann, A. Nuechter, and J. Hertzberg, Globally Consistent 3D Mapping with Scan Matching *Journal Robotics and Autonomous Systems*, 65(2):130-142,2008
- [5] Karol Majek, Janusz Będkowski, Comparison of scanning strategies for the Small Mobile Mapping System, *Konferencja Młodzi Naukowcy Wobec Wyzwań Współczesnej Techniki*, 16 – 18 Września 2013 r. w Warszawie
- [6] J. Bedkowski, K. Majek, A. Nuechter, General Purpose Computing on Graphics Processing Units for Robotic Applications, *Journal of Software Engineering for Robotics*, 4(1), May 2013, 23-33 ISSN: 2035-3928
- [7] 3DTK <http://slam6d.sourceforge.net> (serwis dostępny 2014)
- [8] A. Nuechter, O. Wulf, K. Lingemann, J. Hertzberg, B. Wagner, H. Surmann, 3D Mapping with Semantic Knowledge *Proc. RoboCup Int. Symposium 2005*, Osaka, 2005
- [9] A. Nuechter. J. Hertzberg, Towards semantic maps for mobile robots, *Robotics and Autonomous Systems*, 56, 2008.
- [10] S. Rusinkiewicz, M. Levoy, Efficient variants of the ICP algorithm, *Proc. Int. Conf. on 3D Digital Imaging and Modeling*, Quebec, 2001

NEW 6DSLAM ALGORITHM BASED ON SEMANTIC RECOGNITION OF THE ENVIRONMENT

The paper presents new 6DSLAM algorithm based on semantic recognition of the environment. Semantic approach improves the accuracy of the final metric map and guarantees the robustness of the mapping even in difficult indoor terrain conditions. The metric/semantic mapping of indoor environment is shown with an assumption of robot motion on flat surface and stairs. The result is compared with State of the Art algorithm. The new approach guarantees consistency and accuracy of mapping. Semantic approach allows augmenting metric map with qualitative information such as following labels for 3D points: ceiling, floor, walls and points of non-regular surrounding.