

Barbara SIEMIĄTKOWSKA, Jacek SZKLARSKI, Michał GNATOWSKI, Arkadiusz ZYCHEWICZ
 INSTYTUT PODSTAWOWYCH PROBLEMÓW TECHNIKI POLSKIEJ AKADEMII NAUK

Segmentacja danych otrzymanych z lasera 3D

Dr Barbara SIEMIĄTKOWSKA

Barbara Siemiątkowska pracuje w Instytucie Automatyki i Robotyki Politechniki Warszawskiej i w Instytucie Podstawowych Problemów Techniki PAN. Autorka jest absolwentką Wydziału Matematyki Mechaniki i Informatyki Uniwersytetu Warszawskiego. Pracę doktorską z dziedziny zastosowań sztucznej inteligencji w robotyce obroniła w Instytucie Podstawowych Problemów Techniki PAN. Główną dziedziną zainteresowań naukowych autorki jest zastosowanie sieci komórkowych w nawigacji robotów mobilnych.

e-mail: bsiem@ippt.gov.pl



Dr inż. Jacek SZKLARSKI

Jacek SzklarSKI od 2008r. jest pracownikiem Instytutu Podstawowych Problemów Techniki PAN. Jest absolwentem Wydziału Informatyki Politechniki Szczecińskiej oraz Wydziału Matematyczno-Fizycznego Uniwersytetu Szczecińskiego. Doktorat z nauk fizycznych obronił na Uniwersytecie w Poczdamie, pracował też w ośrodku naukowym w Dreźnie.

e-mail: jszklar@ippt.gov.pl



Dr inż. Michał GNATOWSKI

Pracuje w Instytucie Podstawowych Problemów Techniki PAN. Jest absolwentem Wydziału Elektrycznego Politechniki Warszawskiej. Praca doktorska dotyczyła zastosowania metod wieloagentowych we współdziałaniu robotów mobilnych. Zainteresowania naukowe autora obejmują również budowanie map otoczenia robotów mobilnych.

e-mail: mignat@ippt.gov.pl



Mgr Arkadiusz ZYCHEWICZ

Jest doktorantem Instytutu Podstawowych Problemów Techniki PAN. Ukończył Wydział Fizyki Uniwersytetu Warszawskiego. Praca doktorska dotyczy budowania map otoczenia robotów mobilnych na podstawie wskazań dalmierza laserowego 3D.

e-mail: azychew@ippt.gov.pl



Streszczenie

Otoczenie robota – wnętrze budynku jak i obszar znajdujący się na zewnątrz może być podzielony na fragmenty, którym następnie możemy przypisać pewne znaczenie semantyczne. Przed przystąpieniem do dokonywania klasyfikacji należy jednak dokonać filtracji i segmentacji danych pomiarowych. W poniższym artykule przedstawione zostaną wyniki segmentacji chmury punktów, którą otrzymujemy na podstawie wskazań laserowego skanera 3D. Zastosowano nowatorską technikę, w której dane pomiarowe zamieniane są na postać kartezjańską, następnie obliczane są wektory normalne do powierzchni, na której punkty leżą. Składowe wektora są normalizowane i zapisywane w reprezentacji RGB. W wyniku opisanej transformacji powstaje kolorowy obraz. Dzięki temu problem segmentacji danych w przestrzeni 3D jest sprowadzony do zadania analizy kolorowych obrazów. Umożliwia to zastosowanie znanych z wizji algorytmów: usuwania szumów, rozrostu ziarna i segmentacji. Przeprowadzone eksperymenty w pomieszczeniu zamkniętym i na zewnątrz budynku potwierdziły efektywność przyjętej metody.

Słowa kluczowe: segmentacja, mapy 3D.

3D laser data segmentation

Abstract

Map building of unknown environment is a part of a navigation system and is one of the most important topics in modern mobile robotics. Many environment representations have been proposed. One of the most popular is 2D representation which has many limitations, for example the height of obstacles is not taken into account. In the last decade 3D sensors are being more popular which enable 3D map building. In our approach the laser scans a scene and gives 2D data. The rotating support rotates the laser vertically, which allows to make 3D scans. The cloud of points is transformed into a set of normal vectors. The coordinates of a vector are represented as: red, green and blue colors. And 3D information is represented as 2D color image. The segmentation of the RGB image is performed using classical image processing methods. 2D areas are transformed into a 3D representation and classified. Experimental results validated the proposed approach and showed the benefits of using classical method of image processing for 3D data segmentation.

Keywords: 3D mapping, segmentation.

1. Wstęp

Tworzenie trójwymiarowej reprezentacji otoczenia ma istotne znaczenie w wielu dziedzinach: analizie zagrożeń, wizualizacji obiektów historycznych, badaniu miejsc trudno dostępnych. We współczesnej robotyce mobilnej zaczynają powstawać roboty usługowe przeznaczone do kontaktu z człowiekiem i przemieszczające się na zewnątrz pomieszczeń. Bez reprezentacji 3D działanie tych urządzeń nie jest możliwe.

Do pozyskiwania trójwymiarowej informacji o środowisku stosuje wiele różnych sensorów. Do niedawna podstawowym źródłem danych była stereowizja. Dzięki zastosowaniu kamer uzyskujemy ogromną ilość informacji, której przetworzenie nie jest jednak zadaniem prostym. Szczególnie jest to trudne, gdy robot przemieszcza się w nieznanym, skomplikowanym środowisku o zmiennych warunkach oświetleniowych [1, 2]. Aby rozwiązać opisany problem tworzone są układy hybrydowe składające się ze skanera laserowego i kamery klasycznej lub dookólnej [3, 4]. W jeszcze innych rozwiązaniach stosuje się układ wielu skanerów laserowych, które umieszczone są w różnych miejscach pojazdu i nachylone są pod różnymi kątami do powierzchni [5, 6]. Coraz częściej stosuje się również skanery laserowe umieszczone na obrótce, która umożliwia zmianę nachylenia skanera [7, 8].

Urządzenia pomiarowe 3D dostarczają chmurę składającą się z ogromnej liczby punktów. Aby uzyskać istotną informację o otoczeniu dane należy zapamiętać w sposób efektywny, a następnie przeprowadzić segmentację, w wyniku której punkty są dzielone na grupy. Możliwe jest uwzględnienie różnych kryteriów, ale najczęściej do jednej klasy przydzielane są punkty, które należą do tego samego obiektu w przestrzeni 3D. Dopiero po przeprowadzeniu segmentacji możliwa jest dalsza analiza otrzymanych danych.

W literaturze możemy spotkać opis wielu algorytmów podziału chmury punktów na podobszary. W większości metod do jednej klasy przydzielane są punkty leżące na jednej płaszczyźnie. W pracy [9] opisywane jest zastosowanie trójwymiarowej transformacji Hougha, która umożliwia zapisanie chmury punktów w postaci ciągu wieloboków. W [10] opisano metodę, w której dane 2D pochodzące z dalmierza laserowego zapisywane są w postaci ciągu odcinków, a następnie obliczane są równania płaszczyzn.


W [11, 12] przedstawiono metody, w których generowany jest zbiór wektorów normalnych do obserwowanych powierzchni. Do jednej klasy przydzielane są te punkty, które posiadają podobne wektory normalne. Opisująca w tej pracy metoda należy do tej ostatniej grupy, ale może być wykorzystywana do segmentacji obszarów, które nie są płaskie. Algorytm składa się z następujących etapów:

- zbieranie danych pomiarowych,
- utworzenie i zapisanie chmury punktów w prostokątnej tablicy,
- obliczenie normalnych do powierzchni,
- zapisanie danych w postaci kolorowego obrazu,
- segmentacja obrazu.

2. Zbieranie danych


W prowadzonych badaniach eksperymenty były przeprowadzane przy użyciu mobilnego robota „Elektron”, który został wykonany w Instytutach Automatyki i Robotyki oraz Elektroniki i Technik Informacyjnych Politechniki Warszawskiej. Podstawowym sensorem umożliwiającym zbieranie informacji o otoczeniu jest dalmierz laserowy Sick LMS200, zamontowany na obrotnicy.

Skaner laserowy mierzy odległość do przeszkód dla kątów φ od -90° do $+90^\circ$, z rozdzielczością $\Delta\varphi=1.0^\circ$ lub $\Delta\varphi=0.5^\circ$. Zakres odchylenia obrotnicy θ zmienia się od -15° do 90° . Dane są transmitowane ze skanera do jednostki centralnej po szynie RS 422. Istnieje możliwość dokonywania pomiaru w trybie ciągłym (skaner i obrotnica działają niezależnie) jak i skokowym (obrotnica jest zatrzymywana w czasie skanowania). Na rys. 1 przedstawiono zdjęcie robota oraz umieszczony na nim dalmierz laserowy firmy Sick.



Rys. 1. Po lewej: zdjęcia robota „Elektron” z laserem 3D oraz kamerą dookólną na górze. Po prawej: objaśnienie kątów φ i θ

Fig. 1. Left: photo of robot “Elektron” with the 3D laser on the rotating support. Notice the omnicaamera placed on the top. Right: explanation of φ and θ angles



Rys. 2. Chmura punktów pojedynczej sceny. Robot znajduje się w środku układu współrzędnych, w punkcie (0,0,0)

Fig. 2. Point cloud representing a sample scene. The robot is placed in the center of the coordinate system, at (0, 0, 0)

Wyniki pomiarów otrzymane są w układzie „pseudo-polarnym” $\{\varphi_i, \theta_i, r_i\}$, $i=1, \dots, N$, gdzie φ jest poziomym kątem skanowania, θ jest kątem odchylenia obrotnicy, a r jest odległością do


przeszkody. Dane mogą być przekształcane na postać kartezjańską i zapamiętane w postaci chmury punktów. Na rys. 2 przedstawiono przykładowe odczyty ze skanera, zapamiętane w postaci kartezjańskiej.

3. Reprezentacja i segmentacja danych

Po zebraniu danych pomiarowych należy je zapisać w postaci umożliwiającej szybką analizę. Najprostszą metodą jest użycie wartości (φ, θ) jako współrzędnych komórek prostokątnej tablicy i przypisanie wartości odległości r . Jeżeli skaner daje $J=361$ punktów pomiarowych w każdej linii, dla kąta: $\varphi \in [-90^\circ, 90^\circ]$ oraz $K=181$ dla kąta $\theta \in [0^\circ, 90^\circ]$, to zostanie utworzona tablica o wymiarach $J \times K$, przy czym komórka o współrzędnych $(0,0)$ i wartości r reprezentuje dane $(\varphi = -90^\circ, \theta = 0, r)$, a o współrzędnych $(j = J, k = K)$, dane $(\varphi = 90^\circ, \theta = 90^\circ, r)$.

Następnym etapem jest segmentacja danych. W niniejszym artykule zaproponowano nową metodę polegającą na konwersji chmury punktów (tablicy pomiarów) na kolorowy obraz 2D i zastosowaniu szybkich i dobrze znanych algorytmów przetwarzania obrazów. Najprostszą metodą jest zamiana wartości r na stopnie szarości. Przyjmujemy, że dla odległości $r=0$ m barwa jest biała, dla r powyżej wartości maksymalnej barwa jest czarna. Przykładowa scena jest pokazana na rys. 3. Z tego typu reprezentacji nie daje się jednak uzyskać satysfakcjonujących informacji o właściwościach geometrycznych otoczenia.

Kolejny testowany przez nas sposób segmentacji polegał na zastosowaniu, klasycznej, znanej z wizji metody, w której uznajemy, że dwa punkty przestrzeni należą do jednego obiektu, jeśli leżą dostatecznie blisko siebie. Wynik działania algorytmu dla danych z rys. 2 przedstawiono na rys. 4. Algorytm działa prawidłowo jeśli obiekty znajdujące się w otoczeniu robota znajdują się w dużej odległości, ale do jednej klasy przypisane mogą być piksele należące np. do różnych stykających się ze sobą ścian.



Rys. 3. Przykładowy szaroodcieniowy obraz reprezentujący odległość od robota w (φ, θ) przestrzeni. Maksymalna odległość mierzona przez skaner to 8 metrów. Dla przejrzystości odległości większe niż 4 metry są czarne.

Fig. 3. A sample gray-scale image representing distance from the robot in (φ, θ) space. Maximum distance measured by the scanner is 8 meters. Here, for clarity, we show all distances greater than 4 meters as black. Note that on the left side of the image there is a black area due to some error in scanner readings (connected with strong scattering of the laser beam)

W kolejnej testowanej przez nas metodzie dla każdego punktu obliczany jest wektor normalny do powierzchni, która przez dany punkt przechodzi. Następnie trzy współrzędne wektora normalnego zamieniane są na przestrzeń barw RGB.

W pracy [13] zaproponowano metodę, w której każdemu punktowi p przypisujemy parę wartości (n, d) , gdzie $n \in R^3$ jest wektorem normalnym do powierzchni przechodzącej przez dany punkt, a $d \in R$, jest odległością płaszczyzny wyznaczonej przez n od początku układu współrzędnych. Pary wartości (n, d) obliczane są wykorzystując zasadę minimalizacji średnio kwadratowej tzn. dla


danego punktu p_0 oraz punktów sąsiednich $\{p_i\}$, gdzie $i=1,\dots,N$, a N jest liczbą punktów sąsiednich, wektor normalny n jest wyznaczony przez wartość, dla której funkcja określona równaniem:

$$f(n, d) = \sum_{i=0}^N (np_i + d)^2$$

osiąga minimum. Zastosowanie opisanej metody dla chmury punktów jest czasochłonne i nie zawsze daje rozwiązanie, dlatego proponujemy prostszy algorytm. Każdy punkt p oraz N jego sąsiadów wyznacza N trójkątów. Każdy z trójkątów jest fragmentem płaszczyzny o znanej wartości wektora normalnego n_i . Aby zmniejszyć wpływ szumów na wartość wartości n_i , rozpatrywane są jedynie trójkąty dla których odległość między wierzchołkami spełnia warunek:

$$\varepsilon_1 < |p_i - p_j| < \varepsilon_2$$

gdzie p_i, p_j – są wierzchołkami trójkąta, a $\varepsilon_1, \varepsilon_2$ dolnym i górnym progiem. W prowadzonych badaniach $\varepsilon_1=0,5\text{cm}$ i $\varepsilon_2=30\text{cm}$.



Rys. 4. Wynik segmentacji na podstawie kryterium odległości
Fig. 4. Segmentation using distance

Wartość n określa równanie:

$$n = \sum_{i=1}^N n_i$$


Znormalizowane wektory normalne są reprezentowane jako trzy macierze liczb rzeczywistych z zakresu $(-1,\dots,1)$ będących trzema współrzędnymi kolejnych wektorów n . W tym miejscu proponujemy, by potraktować te liczby jako kolory zwykłego obrazu w przestrzeni barw RGB. Oczywiście nie jest to przekształcenie, które wnosi jakieś nowe informacje do dalszej segmentacji czy klasyfikacji, ale dzięki temu będzie można zastosować już istniejące, szybkie algorytmy z dziedziny analizy obrazów.

Obraz RGB jest tworzony poprzez przypisywanie kolejnych współrzędnych n_x, n_y, n_z odpowiednio jako składowe czerwoną, zieloną i niebieską. W klasycznym 8-bitowym obrazie RGB, współrzędnej równej -1 będzie przypisana składowa koloru równa 0, a współrzędnej równej $+1$ składowa równa 255, czyli np. dla czerwonego $R = 255 \frac{n_x + 1}{2}$, przyjmujemy, że R jest liczbą

całkowitą. Naturalnie w przypadku takiej zamiany tracona jest część informacji, gdyż każda składowa reprezentowana jest jedynie przez 8-bitów. W aktualnym etapie badań nie ma to większego wpływu na wyniki, ale rozważane są również obrazy 16-bitowe i 32-bitowe. Przykładowo, w obrazie utworzonym opisaną metodą sufit i podłoga będzie miała czerwoną i zieloną składową równą 128 w 8-bitowym obrazie, podczas gdy składowa niebieska będzie większa niż 128 dla podłogi (będzie bardziej niebieska) a dla sufitu mniejsza niż 128 (będzie bardziej żółta). Z drugiej strony wszystkie płaszczyzny pionowe będą miały składową niebieską równą 128. Ponadto ściany stojące wzdłuż


kierunku patrzenia robota będą różowe (po lewej stronie) lub zielonkawoniebieskie (po prawej stronie). Utworzony w ten sposób obraz jest przedstawiony na rys. 5. Ponadto, w badaniach alternatywnie używana jest konwersja na kolory wartości bezwzględnych składowych wektorów normalnych, np. $R=|n_x| \cdot 255$. Dzięki temu obraz reprezentuje nieco inne cechy otoczenia, np. ściany biegnące wzdłuż osi patrzenia robota, z obu jego stron są wówczas czerwone, a wszystkie powierzchnie prostopadłe (sufit, podłoga, blat biurka) są niebieskie.

Zapisywanie danych z dalmierza w postaci kolorowego obrazu umożliwia wyodrębnienie zbioru pikseli, które należą do jednej płaszczyzny, ale ma również duże znaczenie w przypadku, gdy robot przemieszcza się na zewnątrz budynku.



Rys. 5. Dane zaprezentowane na rys. 3 przetransformowane według obliczonego dla każdego piksela wektora normalnego n . Wartości (x, y, z) wektora n są przedstawione jako czerwony, zielony i niebieski składnik 8-bitowego obrazu RGB (np.: $n_x = -1$ to czerwony=0, $n_z = 1$ to niebieski=255). Zauważalny jest wzrost szumu dla $-\varphi$ w okolicach $\varphi = \pm 90$

Fig. 5. Data for the scene presented in Fig. 3 were transformed in order to obtain normal vectors n for each pixel. Values of (x, y, z) coordinates of n are presented as red, green and blue components of this 8-bit RGB image (e.g., $n_x = -1$ gives red=0, $n_z = 1$ gives blue=255). Note the increasing noise for $-\varphi$ near $\varphi = \pm 90$



Rys. 6. Obraz z rysunku 5 przedstawiony w projekcji stożkowej Albersa, czytelniej przedstawiający obiekty sceny

Fig. 6. Similar like Fig.5, but here Albers equal-area conic projection is applied in order to better represent geometrical properties of the environment


Proste odwzorowywanie kątów φ i θ na pozycję piksela nie prowadzi do utworzenia obrazów optymalnych do późniejszej analizy. Na przykład wszystkie pomiary $\varphi = 0,5\pi$ lub $\varphi = -0,5\pi$ przedstawiają ten sam punkt dla dowolnego kąta θ . Ponadto, fragmenty obrazu dla kątów bliskich $\varphi = \pm 0,5\pi$ są zniekształcone oraz obciążone dużym błędem. Błąd narasta z powodu metody obliczania wektorów normalnych. Duży obszar na rysunku przedstawia niewielki obszar w rzeczywistości i błąd statystyczny

danych z laserów narasta. Wygodnie jest konwertować dane (φ, θ) do sferycznego układu współrzędnych (φ_d, θ_d) , w którym robot znajduje się w środku układu, a kąty φ_d i θ_d reprezentują odpowiednio przechyły podłużne i poprzeczne. Następnie można użyć na przykład projekcji stożkowej Albersa, która przedstawia obrazy w bardziej czytelny sposób (rys. 6). Z powodu ograniczonej ilości pomiarów konieczne jest zastosowanie interpolacji przy przekształcaniu z układu (φ, θ) .

4. Segmentacja kolorowego obrazu

Celem tego kroku jest wykonanie szybkiej segmentacji zebranych danych w obszary, z których każdy reprezentuje płaski wielobok na scenie. W środowisku wewnątrz budynków najbardziej typowymi obszarami są: podłoga, ściana, sufit, drzwi, itp. W celu lepszej klasyfikacji, oprócz listy wieloboków, mogą być także zbierane inne cechy charakteryzujące fizyczne właściwości obiektów. W analizie obrazów istnieją dwie podstawowe metody segmentacji: rozrost obszarów i wykrywanie krawędzi [2]. W proponowanym przez nas algorytmie proces segmentacji został podzielony na 3 etapy, z których pierwsze dwa są oparte o algorytm rozrostu ziarna (obecnie używamy biblioteki OpenCV do przekształceń obrazów w czasie rzeczywistym).

W pierwszym etapie na mapie głębi (rys. 3) wykorzystywany jest algorytm rozrostu ziarna, w ten sposób, że liczona jest odległość pomiędzy kolejnymi komórkami i jeżeli jest ona mniejsza niż zadany próg, to dana komórka jest przypisywana do budowanego obszaru, a przeciwnym przypadku komórka jest początkiem nowego. Jeżeli tak zbudowany obszar jest większy niż zadany próg (np. 30 pikseli) to zostaje mu nadany kolejny numer licząc od 1. Obszarom mniejszym zostaje nadany numer 0 i nie są brane do dalszej analizy.



Rys. 7. Wynik segmentacji danych
Fig. 7. The result of segmentation

Po ukończeniu pierwszego etapu otrzymujemy listę obszarów, które reprezentują stosunkowo dużą powierzchnię. Na przykład krzesło stojące odpowiednio daleko przed większą ścianą, będzie przypisane do innego obszaru niż ściana. Jednakże jeżeli odległość w narożach pomiędzy sufitem, ścianą i podłogą będzie mała, zostaną one zaklasyfikowane jako jeden obszar.

W drugim kroku następuje podział n obszarów na mniejsze podobszary przez zastosowanie algorytmu rozrostu ziarna na obrazie RGB utworzonym z normalnych. Algorytm jest uruchamiany oddzielnie dla każdego z utworzonych podobszarów i , $1 \leq i \leq n$. Próg jest stały i dla 8-bitowego obrazu RGB został dobrany doświadczalnie na 15 (rysunki 5 i 6). W drugim kroku otrzymujemy listę $m \geq n$ obszarów, z których każdy reprezentuje raczej płaską powierzchnię. Na standardowym komputerze klasy PC czas potrzebny do wykonania obliczeń dla standardowego zbioru danych wynosi około 100 ms. Wynik segmentacji przedstawiono na rys. 7. Kolorem białym zaznaczono obszary nie przydzielone do żadnej klasy.

5. Podsumowanie

W artykule przedstawiono metodę zapisywania i segmentacji danych pochodzących ze skanera laserowego 3D. Zastosowano metodę, w której dane zapisywane w postaci kolorowego obrazu. Wykorzystano klasyczne algorytmy przetwarzania obrazów. Metoda umożliwia przeprowadzenie analizy chmury punktów w czasie rzeczywistym. W artykule pt. "Budowa hybrydowej semantyczno-rastrowej reprezentacji otoczenia robota mobilnego na podstawie wskazań dalmierza laserowego 3D" zostanie omówiony algorytm w którym wyniki segmentacji zostaną zastosowane w procesie budowy semantycznej reprezentacji otoczenia robota mobilnego wyposażonego w skaner laserowy 3D.

Prowadzone badania są finansowane przez Ministerstwo Nauki i Szkolnictwa Wyższego i Informatyzacji w ramach grantu nr 4311/B/T02/2007/33.

6. Literatura

- [1] Iocci L., Konolige K., Bajracharya M.: Visually realistic mapping of a planar environment with stereo. *Experimental robotics* 7, pp. 521-532, 2001.
- [2] Gonzales R.C., Woods R.E.: *Digital Image Processing*. Prentice Hall, 2002.
- [3] Siemiątkowska B., Olszewski M., Chojecki R., Marcinkiewicz P., Trojanek P. and Majchrowski M.: Mobile robot localization using laser range scanner and omni-camera. *CISM Courses and Lectures - 16th CISM-IFTOMM Symposium on Robot Design, Dynamics and Control, RoManSy'06*, 487 pp. 229-236.
- [4] Zhang Q. and Pless R.: Extrinsic Calibration of a Camera and Laser Range Finder (improves camera intrinsic calibration), in *Proc. of IEEE Intl. Conference on Intelligent Robots and Systems*, 2004.
- [5] Triebel R., Pfaff P. and Burgard W.: Multi-level surface maps for outdoor terrain mapping and loop closing. *Proc. of IROS*, pp. 1 - 2, 2006.
- [6] Thrun S., Martin C., Liu Y., Hahnel D., Emery-Montermelo R., Charkrabarti D., Burgard W.: A real-time expectation maximization algorithm for acquiring multiplanar maps of indoor environment with mobile robots, *IEEE Trans. on Robotics and Automation*, 20(3), pp. 433-443, 2004.
- [7] Siemiątkowska B., Gnatowski M. and Chojecki R.: Cellular neural networks in 3D laser data segmentation. In *9th WSEAS Int. Conf. on Neural Networks*, pp. 84-88, 2008.
- [8] Weingarten J. and Siegwart R.: EKF-based 3D SLAM for structured environment reconstruction. In *Proc. of IROS 2005*, 2005.
- [9] Vosselman G.: Fusion of laser scanning data, maps, and aerial photographs for building reconstruction, *Geoscience and Remote Sensing Symposium*, vol. 1, 85 - 88, 2002.
- [10] Siemiątkowska B., Gnatowski M., Zychewicz A.: „Fast Method of 3D Map Building Based on Laser Range Data”, *J. of Automation Mobile Robotics & Intelligent Systems*, (1), 2007, nr 2, str. 35 - 39.
- [11] Weingarten J. and Siegwart R.: 3D SLAM using Planar Segments. In *Proc. of IROS, Beijing, October 9-15, (2006)*.
- [12] Haehnel D., Burgard W. and Thrun S.: Learning compact 3d models of indoor and outdoor environments with a mobile robot. *Robotics and Autonomous Systems*, 44(1):15-27, (2003).
- [13] Liu Y., Emery R., Chakrabarti D., Burgard W. and Thrun S.: Using EM to learn 3D models with mobile robots. In *Proc. of the Int. Conf. on Machine Learning (ICML)*, 2001.

otrzymano / received: 27.09.2009
przyjęto do druku / accepted: 03.02.2010

artykuł recenzowany