

**Teodora DIMITROVA - GREKOW**POLIETCHNIKA BIAŁOSTOCKA,  
ul. Wiejska 45A, 15-351 Białystok**Hybrydowy algorytm samolokalizacji**

Dr inż. Teodora DIMITROVA - GREKOW

Ukończyła studia na Wydziale Elektroniki Politechniki Sofijskiej, Bułgaria w 1991r., obroniła pracę doktorską na Uniwersytecie Technicznym w Wiedniu w 1997r. Jest adiunktem na Wydziale Informatyki przy Politechnice Białostockiej. Jej zainteresowania naukowe to synteza układów programowalnych, robotyka, mechatronika, analiza i przetwarzanie sygnałów.



e-mail: t.grekow@pb.edu.pl

**Streszczenie**

Niniejszy artykuł prezentuje podejście hybrydowe do samolokalizacji w oparciu o zintegrowany system zbierania danych. Obie funkcje topologiczna i metryczna zostały zrealizowane z użyciem dalmierza ultradźwiękowego. Do przetestowania poprawności działania opracowanej metody wykorzystano robot Lego Mindstorms NXT. Zaprezentowane rozwiązanie przyspiesza pracę pojazdu, skracając czas rozpoznawania napotkanych obiektów orientacyjnych. Minimalizowany jest błąd odometryczny. Bardzo istotnym elementem pracy jest identyfikacja obiektów, ich orientacji i budowanie modelu mapy o względnym stopniu zaufania. Przeprowadzone badania wykazały wysoką dokładność zaprezentowanej metody samolokalizacji.

**Słowa kluczowe:** roboty mobilne, nawigacja, lokalizacja, metryczno-topologiczne strategie, roboty edukacyjne, Mindstorms NXT.

**A hybrid algorithm for self location****Abstract**

Application of two independent systems is a classical approach when realizing topological-metric localization algorithms [1, 2, 3]. In this issue a hybrid localization method with an integrated data collecting is proposed. Both functions, topological and metric, are based on a sonar. Multi-reflections are one of the biggest problems by the sonar systems [7, 8]. However, there are many examples of using sonars in the Simultaneous Localization and Mapping (SLAM) [4, 9]. The presented method (Section 2) consists of four phases: 1) data collection and filtering (Figs. 1 and 2), 2) object classification (Fig. 3), 3) building map with a confidence coefficient (Fig. 4), 4) local and global map (Fig. 5) comparison and end decision. Many authors use a grid map for the topological localization [5, 6]. Here a model matching attempt is performed. The concept of the confidence coefficient map is very important in this work. Section 3 describes an experiment whose workspace is shown in Fig. 6. The results (Section 4) are presented in Table 1: 77% of the tests were successful, 14% gave fault results, while in 9% – no solution was found. In spite of the restrictions of the used robot, the project seems very perspective.

**Keywords:** mobile robotics, navigation, location, topological-metric strategies, educational robots, Mindstorms NXT.

**1. Wprowadzenie**

Przy realizacji topologiczno-metrycznych algorytmów samolokalizacji klasycznym podejściem jest użycie dwóch niezależnych systemów orientacyjnych [1, 2]. Wynika to z zasadniczo różnych sposobów rozpatrywania otoczenia: orientacja topologiczna potrzebuje dokładnej identyfikacji znaczników, zaś orientacja metryczna wymaga jedynie precyzji w odległości do tych samych elementów otoczenia. Zazwyczaj pierwsza z nich jest realizowana za pomocą sensorów wizyjnych, a druga – poprzez dalmierze optyczne lub ultradźwiękowe. Autonomia obydwu systemów pozwala na wyspecjalizowaną rejestrację sygnałów i co z tego wynika, niezależne obliczanie komponentów samolokalizacji. Dodatkowo pojawia się możliwość kompensacji błędów jednego z systemów – jeżeli zostanie zastosowana dodatkowa inteligentna

analiza danych albo zewnętrzna kalibracja lub wymiana informacji. Wadą tego rozwiązania jednak zostaje zaangażowany sprzęt oraz wymagana zdolność obliczeniowa, szczególnie przy analizie sygnałów z systemów wizyjnych [3].

Ponieważ metody bazujące na rozpoznawaniu cech nie są łatwe do zastosowania przy algorytmach lokalizacyjnych wykorzystujących wyłącznie czujniki sonaru, wielu autorów proponuje lokalizację topologiczną na podstawie siatki mapy dopasowywania modelu [5, 6].

W niniejszej pracy zaproponowano hybrydową metodę samolokalizacji w oparciu o zintegrowany system zbierania danych. Hybrydowość polega na równoczesnym wykorzystaniu metrycznej oraz topologicznej informacji odczytanej z otoczenia robota. Obie funkcje topologiczna i metryczna zostały zrealizowane w przedstawionym projekcie z użyciem dalmierza ultradźwiękowego. Jego zalety są powszechnie znane: jest łatwo dostępnym, niedrogim sensorem o zadowalającej precyzji. Główną wadą czujników ultradźwiękowych są szumy związane ze stożkowatym obszarem emisji sygnału. Z tej przyczyny powstaje wiele dodatkowych echa komplikujących i zakłócających odbiór. W praktyce boczne refleksje utrudniają na tyle bezpośrednie użycie danych sonaru w celu lokalizacji, że albo praca w warunkach rzeczywistych jest momentami znacznie spowolniona, albo wymagany jest rozbudowany aparat obliczeniowy potrzebny do obróbki informacji. Jednak znanych jest wiele przykładów użycia czujnika sonaru do samolokalizacji oraz do równoczesnej samolokalizacji i mapowania (Simultaneous Localization and Mapping, SLAM) [4, 9].

Dokładność ustalania odległości przy sonarach zależy w różnym stopniu od zastosowanego czujnika, od formy emitowanego sygnału oraz od sposobu obróbki otrzymanej przez odbiornik informacji. W realnych warunkach pojedynczy pomiar jest zupełnie irrelevantny. Wątpliwa, ale jednak nie bez szansy jest dokładność 1 cm, jaką proponują czujniki ultradźwiękowe edukacyjnych zestawów Lego Mindstorms NXT 2.0. Celem opisywanego w tym artykule eksperymentu jest również sprawdzenie czy można używać i na ile skuteczna jest praca pojazdów zbudowanych na bazie właśnie tych zestawów. W tym celu przyjęta została wspomniana wcześniej symplifikacja otoczenia – wszystkie obiekty w środowisku eksperymentalnym są równoległocianami o różnych rozmiarach, pozycjach i orientacjach.

Wszystkie próby rozpoznania obiektów za pomocą sonaru muszą zmagać się z następującymi problemami:

- właściwości fizyczne obiektów: rozmiar, kształt, materiał, z jakiego obiekt jest wykonany, powierzchnia obiektu;
- zależności pomiędzy sensorem, a obiektem, np. odległość, kąt;
- złożoność i ilość obiektów do rozpoznania;
- zmiana położenia, właściwości fizycznych obiektów w czasie;
- czynniki zewnętrzne, np. temperatura i wilgotność powietrza [7, 8].

Z tego powodu podczas badań zostało przyjętych szereg uproszczeń środowiskowych.


Bardzo istotnym elementem pracy to rozpoznawanie obiektów, ich orientacji i budowanie modelu mapy o względnym stopniu zaufania. Dodatkowym wstępnym ułatwieniem warunków pracy jest to, że zbieranie danych o otoczeniu jest wykonywane podczas ruchu postępowego i cofania całego pojazdu. Zwiększa się w ten sposób powierzchnia obserwowanej przestrzeni przy niewielkim koszcie czasu podjechania do przodu i z powrotem.

**2. Istota metody**

Badania składają się z czterech etapów: (1) zbieranie danych o otoczeniu, (2) klasyfikacja obiektów, (3) budowa mapy o względnym stopniu zaufania, (4) porównanie mapy lokalnej z mapą globalną oraz decyzja o aktualnej pozycji i orientacji.

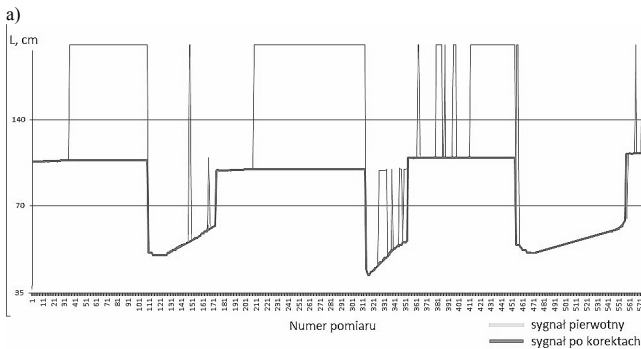
### 2.1. Zbieranie danych o otoczeniu

Surowe pomiary sonaru są zapisywane do pliku. Równocześnie robiona jest wstępna filtracja danych: usuwanie pojedynczych ekstremalnych pomiarów (rys. 1a). Jak widać, wśród pomiarów jest bardzo dużo ‘odbłyśków’. Ich szybkie odfiltrowanie ułatwia dalszą obróbkę otrzymanego sygnału.



Rys. 1. Surowe pomiary czujnika ultradźwiękowego  
Fig. 1. Raw measurements of the sonar

Wtórna korekta, robiona po przeskanowaniu połowy dostępnego otoczenia, koncentruje się na ‘wyjątkach’ i wygładzeniu kształtów (rys. 2). Tzw. ‘wyjątki’ są wynikiem nakładania się echa sygnałów z różnych obiektów, oznaczonych jako  $O_i$ , gdzie  $i$  jest kolejnym numerem obiektu ( $i=1..n$ , zachowana w dalszej części pracy konwencja), oraz sekwencyjnych pomiarów robionych przez robota.



Rys. 2. Odzworowanie środowiska: a) sygnał sonaru po dwóch filtracjach; b) schemat rzeczywistego środowiska  
Fig. 2. Environment mapping: a) sonar signal after double filtering; b) the real environment map


Schemat korekty został empirycznie ustalony podczas eksperymentów i jest elementem nadal udoskonalanym. Kryterium jego wyboru jest skuteczność wyodrębnionych cech przy dalszej klasyfikacji obiektów, a szczególnie w prawidłowej końcowej samoorganizacji pojazdu.

### 2.2. Klasyfikacja obiektów

Jest to najistotniejszy, obok wydobywania cech, etap procesu rozpoznawania obiektów. Kiedy optymalny zbiór cech został wybrany, nadchodzi czas na stworzenie klasyfikatora. Do tego istnieją trzy różne metody:

1. Koncepcja podobieństwa - najprostsze i zarazem najbardziej rozpowszechnione podejście, znane jeszcze jako ‘dopasowywanie szablonu’.
2. Podejście probabilistyczne: zawiera metody bazujące na bayesowskiej regule decyzyjnej, maksymalnym prawdopodobieństwie lub estymatorze gęstości.
3. Budowa granic decyzyjnych poprzez optymalizację pewnego kryterium błędu: liniowa dyskryminanta Fishera, wielowarstwowe perceptrony, drzewo decyzyjne.

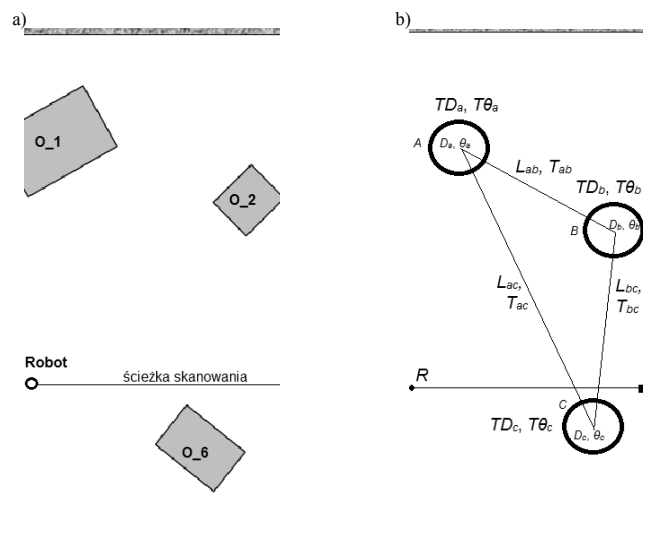
W niniejszej pracy zastosowana została metoda pierwsza. Z uzyskanych po podwójnej filtracji danych wyłaniają się dwa rodzaje elementów: ściany  $S$  i rogi  $R$ . Głównym atrybutem ścian jest kąt  $\theta$ , czyli kąt, pod jakim są one usytuowane w stosunku do trajektorii robota. Można zdefiniować odpowiednio, dla rogów atrybut  $D$  – najkrótsza odległość do tej samej trajektorii (rys. 3). Atrybuty ze swojej strony posiadają własne współczynniki zaufania  $T\theta$  i  $TD$ , co odgrywa bardzo istotną rolę w następnym etapie. Każdy róg naturalnie zakłada identyfikację dwóch ścian z których się on składa. W ten sposób formowane są kompleksowe charakterystyki obiektów: każdy  $i$ -ty obiekt cechuje: pozycja  $D_i$ , orientacja  $\theta_i$ , oraz odpowiednio stopnie zaufania  $TD_i$  i  $T\theta_i$ . Inaczej mówiąc, jego odległość oraz kąt do trajektorii robota charakteryzują się odpowiednio  $(D_i, TD_i)$  i  $(\theta_i, T\theta_i)$ .



Rys. 3. Ekstrakcja cech zidentyfikowanych obiektów  
Fig. 3. Features extraction from the identified objects

### 2.3. Budowa mapy o względnym stopniu zaufania

Rys. 4a pokazuje przykładowy fragment przestrzeni roboczej, odpowiadający za jedno skanowanie.

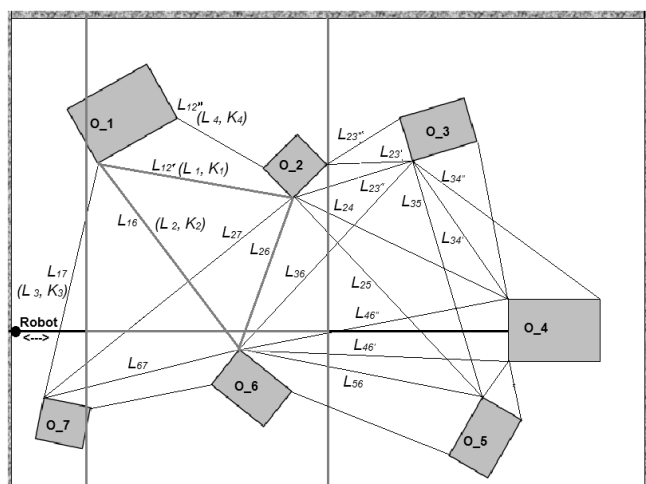


Rys. 4. Budowa grafu hybrydowego: a) przestrzeń rzeczywista; b) zbudowany graf  
Fig. 4. Hybrid graph building: a) the real environment; b) the generated graph

Po zeskanowaniu zidentyfikowano ściany i rogi, odpowiadające  $n$  równoległościom. Rozpoznano również ściany obszaru roboczego, co wpływa jako dodatkowy faktor decydujący o poszczególnych stopniach zaufania. Na podstawie tak zidentyfikowanych i opisanych obiektów można zbudować topologiczno-metryczny graf  $Gt^*$ , który w dalszej części zostanie porównany z mapą globalną, zapisaną również w postaci grafu  $Gg$ . Rys. 4b przedstawia tego typu graf  $Gt^*$ , powstały po analizie przestrzeni z rys. 4a. Jego węzły oznaczone jako A, B i C są opisane poprzez odpowiednie odległości, kąty i ich stopnie zaufania, a ramiona grafu – poprzez ich długość i tak samo odpowiadająca jej stopień zaufania.

Rys. 5 natomiast przypomina graf widoczności, choć nie jest tak przeciążony – ilość rogów nigdy nie przewyższy połowy możliwych linii. I jest nim do pewnego stopnia – na ile widoczność jest warunkiem koniecznym do powstania ramienia.

Zupełność klasycznego podejścia jednak jest w tej metodzie naruszona. Nie są brane pod uwagę 1) wszystkie ramiona z kątów przestrzeni roboczej, 2) wszystkie ramiona związane z rogami ‘widoczne’ przy skanowaniu wzdłuż ściany, 3) wszystkie ramiona mające ocenę prawdopodobieństwa widoczności zero. Ta ocena jest robiona a priori do każdego grafu globalnego  $Gg$  na podstawie geometrycznych zależności, jednoznacznie determinowanych od usytuowania obiektów.



Rys. 5. Graf zredukowanej widoczności  
Fig. 5. Reduced visibility graph

Testy wykazały, iż praktyczna ilość ramion wynikających z warunków tu stawianych jest nawet kilkakrotnie mniejsza od ich pełnej liczby.

Na rys. 5 widać dodatkowy opis ramion –  $L_{ij}$  ( $L_p$ ,  $K_p$ ). Indeksy  $i$  i  $j$  odpowiadają połączonym daną linią obiektom. Indeks  $p$  natomiast prezentuje uniwersalne numery łączy. Współczynnik  $K_p$  jest używany przy dopasowaniu map i zostanie omówiony w następnym podpunkcie. Świadomie nie są podpisane wszystkie istniejące ramiona.

## 2.4. Porównanie mapy lokalnej z mapą globalną oraz decyzja o aktualnej pozycji i orientacji robota

Technika porównania map opiera się na poszukiwaniu rogów. Warunkiem zadowalającego działania algorytmu w ogólnym przypadku jest rozpoznanie minimum trzech rogów. Natomiast skuteczna samolokalizacja, z ca 75% prawdopodobieństwem, jest zagwarantowana kiedy minimum trzy ze znalezionych rogów przynależą do różnych obiektów. Żeby podjąć decyzję system przechodzi przez kilka etapów:

Pierwszym etapem (faza ‘porównania obu grafów/map’) jest dopasowanie do ramion grafu  $Gt$  współczynników indywidualności  $K$ . Współczynnik indywidualności  $i$ -tego ramienia  $K_i$  dla grafu

$Gg$  o  $N$ -ramionach (rys. 5) jest miarą ile razy powtarza się dana długość ramienia w grafie. Im rzadziej się je spotyka, tym większym jest ten współczynnik:

$$K_i = a(1/(\sum P_j), j = 0..N, \quad P_j = \begin{cases} 0, L_i \neq L_j; \\ 1, L_i = L_j. \end{cases}$$

$K_m$   $m$ -tego ramienia grafu  $Gt$  natomiast jest uśrednioną wartością współczynników indywidualności  $Gg$  dla tych ramion, które wchodzi w zbioru  $Lg_m$ , odpowiadającym  $m$ -tego ramia  $Gt$ . Czyli na  $K_m$  mają wpływ wszystkie atrybuty węzłów  $m$ -tego ramienia:

$$K_m = f(L_{ij}, T_{ij}, TD_i, T\theta_i, TD_j, T\theta_j)$$

W tym również granica jego wartości na podstawie przyjętej długości  $L_{ij}$  oraz stopniu zaufania  $T_{ij}$  która również jest funkcją stopni zaufania węzłów ramienia  $TD_i, T\theta_i, TD_j, T\theta_j$ :

Czyli dla każdego ramienia o długość  $L^*$  z  $Gt$  jest wyszukiwana najbliższa wartość  $L$  z  $Gg$  i przepisywany odpowiedni  $K$  ( $T_k$ ).

Drugi etap to porównanie sąsiadujących ramion. Dla ramienia o najwyższym  $K_i$  z  $Gt$  bierzemy po kolej ramienia ze zbioru  $Lg_m$ , zaczynając od tego z największym  $K_i$ :  $Lx$ .

Następnie wybierany jest silniejszy sąsiad  $Lm$ , czyli ramię z większym  $K_m$ :  $L_n$  i z jego zbioru  $Lg_n$  usuwane są wszystkie ramiona niezawierające jednego lub drugiego węzła  $Lx$ .

Dla każdego elementu z tak zredukowanego zbioru sprawdzane jest ramię trzecie – tworzące trójkąt z pierwszymi dwoma rys. 4b.

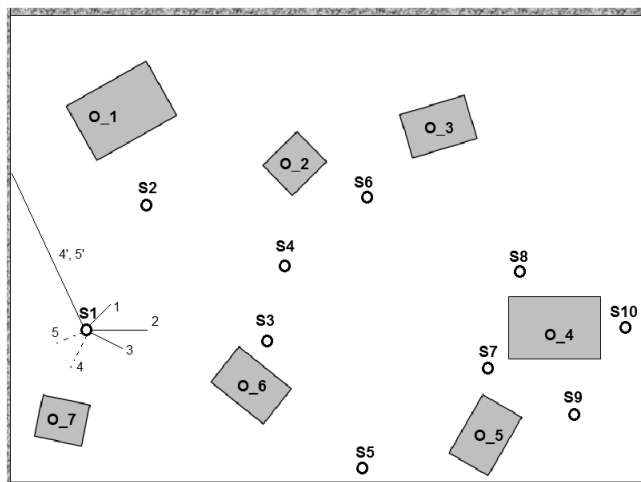
Jeżeli trzecie ramię z  $Gg$  i  $Gt$  się pokryje – generowane jest powiadomienie o zakończeniu samolokalizacji.

Krok się powtarza do momentu skutecznej samolokalizacji lub do wyczerpania możliwości.

Trzeci etap jest oparty na dodatkowych parametrach obiektów – w przypadkach kiedy samolokalizacja jest niepoprawna, pomimo decyzji algorytmu. Jest to etap nadal udoskonalany. Zasadniczo powinno się go stosować do wszystkich przypadków, ale jest na razie zbyt czasochłonny. Podejmowanie decyzji zostałyby oparte o quasi-zupełne przeszukanie grafu, porównanie mapy globalnej i wybór najbliższego rozwiązania.

## 3. Badania

Testy zostały przeprowadzone w ograniczonej ścianami przestrzeń 150x200 cm. Użyto 3 wielkości równoległościom – od 1 do 3 z każdego rodzaju w poszczególnych konfiguracjach testowych. Najmniejszy z obiektów miał wymiary: 12x15x30, a największy: 20x30x50. Trzeci obiekt ma wymiary 15x20x35.



Rys. 6. Przestrzeń robocza z punktami startowymi  
Fig. 6. Experiment workspace with the start points

Celowy wybór rozmiarowo bardzo podobnych do siebie równoległościaków ma na celu skompensowanie wielu uproszczeń przyjętych dla pozostałych parametrów środowiska. Równocześnie takie a priori utrudnienie pozwala interpretować nawet niewielkie sukcesy jako rezultaty obiecujące.

#### Przebieg testów:

Po sprawdzeniu wolnej przestrzeni i ewentualnej korekcji własnej orientacji pierwotnej (w przypadku że robot nie dysponuje przynajmniej 75 cm do poruszania się naprzód) robot podejżdża do bezpiecznej odległości od ewentualnej ściany lub przeszkody lub 75 cm. Podczas jazdy zbiera i zapisuje dane z prawej strony, zgodnie z kierunkiem jazdy. Po pokonaniu zaplanowanej drogi, robot przestawia sonar na drugą stronę po czym jedzie z powrotem (do tyłu) skanując przestrzeń ze strony lewej.

Zebrane w ten sposób dane zostają obrabione i przeanalizowane zgodnie z metodą opisaną w poprzednim rozdziale.

Przeprowadzono szereg badań. Od 5 do 12 serii na przeróżnych konfiguracjach i rodzajach równoległościaków. Każda seria składa 8-14 prób samolokalizacji. Dla każdej serii miejscem startu był różny punkt przestrzeni roboczej, a same próby były powtarzane średnio po trzy razy, stawiając początkowo robota w różnych kierunkach, tak jak widać na rys. 6. Zaprezentowano badania z 10 różnych punktów startowych - ponumerowanych odpowiednio S1 – S10. Dla S1 są przykładowo pokazane wybrane kierunki, przy czym zgodnie z założeniem programu kierunki 4 i 5 zostały zmienione przez robota – brakowało wymaganych 75 cm wolnej przestrzeni. Wybrany kierunek również nie pozwolił na jazdę 75 cm. Jednak robot nie mógł tego zauważyć, ponieważ skanował najpierw z prawej strony. Żeby unikać podobnych kolizji pojazd został zabezpieczony zderzakami.

## 4. Wyniki testów

W tab. 1 są zaprezentowane wyniki z konkretnego eksperymentu, pokazany na rys. 6.

Tab. 1. Trafność samolokalizacji  
Tab. 1. Relevance of the localization

Si	Prawidłowa decyzja, %	Nieprawidłowa decyzja, %	Brak decyzji, %
1.	60	0	40
2.	80	10	10
3.	50	30	10
4.	60	40	0
5.	100	0	0
6.	80	20	0
7.	70	20	10
8.	80	20	0
9.	80	0	20
10.	100	0	0

Pierwsza kolumna zawiera numery poszczególnych punktów startowych. Przedstawione są procentowo poprawne i niepopraw-

ne decyzje oraz udział przypadków, w których robot nie podjął żadnej decyzji.

## 5. Podsumowanie i wnioski

Przeprowadzone doświadczenia pokazują zadowalające wyniki. Można liczyć na ich polepszenie – ciągle przeprowadzane są eksperymenty optymalizujące filtrację danych oraz wykorzystanie specyfiki sygnałów ultradźwiękowych.

Wyniki są bardzo motywujące, szczególnie biorąc pod uwagę duże podobieństwo między użytymi obiektami. Najbardziej trafne są samolokalizacje przy których robot ‘widział’ ścianę. Jest to zupełnie wytłumaczalne, pomimo że w artykule temat nie został umówiony. Szczególnie problematycznym punktem okazał się S1. Co też może być łatwo wyjaśnione wyjątkowo wieloma ‘niewidocznymi sąsiadami’.

Podsumowując, udanych prób samolokalizacji było 77%, w 14% przypadków robot podjął błędną decyzję i tylko w 9% nie znalazł żadnego rozwiązania.

Pomimo ograniczonych możliwościach użytego robota, można uważać projekt za bardzo obiecujący.

## 6. Literatura

- [1] Tomatis N.: Hybrid, Metric- Topological Representation for Localization and Mapping. In: M.E. Jefferies et al. (eds.) Robot & Cogn. Approach. To Spat. Map., STAR 38, pp. 43 – 64. Springer, Berlin Heidelberg, 2008.
- [2] Fogliaroni P., Wallgruen J. O., Clementini E., Tarquini F., Wolter D.: A qualitative Approach to Localization and Navigation Based on Visibility Information. In: K. Stewart Hornsby et al. (eds.) COSIT, LNCS 5756, pp. 312–329. Springer, Berlin Heidelberg, 2009.
- [3] Dimitrova-Grekow T., Zach M.: Asocjyno-metryczny sposób planowania drogi w zamkniętej przestrzeni, PAK nr 07, s. 611-614, 2012.
- [4] Yap T. N., Shelton C. R.: SLAM in large indoor environments with low-cost, noisy, and sparse sonars. In: Proceedings of IEEE international conference on robotics and automation, p. 1395–401, 2009.
- [5] Choi J., Choi M., Nam S. Y., Chung W. K.: Autonomous topological modeling of a home environment and topological localization using a sonar grid map. Autonomous Robots;30(4):351–68, 2011.
- [6] Choi J., Choi M., Chung W. K.: Incremental topological modeling using sonar gridmap in home environment. In: Proceedings of IEEE/RSJ international conference on intelligent robots and systems, p. 3582–7, 2009.
- [7] Poncela A., Urdiales C., Trzegnies C., Sandoval F.: A new sonar-based landmark for localization in indoor environments, Soft Comput 11, pp.281–285, Springer-Verlag 2006.
- [8] Fromberger L.: Representing and Selecting Landmarks in Autonomous Learning of Robot Navigation. In: C. Xiong et al. (eds.) ICIRA Part I, LNAI 5314, pp. 488 – 497. Springer, Berlin Heidelberg, 2008.
- [9] Tardos J. D., Neira J., Newman P. M., Leonard J. J.: Robust mapping and localization in indoor environments using sonar data. International Journal of Robotics Research;21(4):311–30, 2002.

otrzymano / received: 16.08.2013

przyjęto do druku / accepted: 01.10.2013

artykuł recenzowany / revised paper