

Politechnika Wrocławska
Wydział Elektroniki, Fotoniki i Mikrosystemów

KIERUNEK: Automatyka i Robotyka (AIR)

**PRACA DYPLOMOWA
MAGISTERSKA**

TYTUŁ PRACY:
Porównanie wybranych metod lokalizacji robota
mobilnego

AUTOR:
Kacper Szczepanowski

PROMOTOR:
dr inż. Wojciech Domski

STRESZCZENIE

Celem pracy było porównanie jakości działania dwóch metod lokalizacji robota mobilnego. Jedna z metod wykorzystuje histogram do reprezentacji mapy środowiska, natomiast druga metoda wykorzystuje rozkład normalny do opisu otoczenia. W ramach pracy stworzono pakiet do oprogramowania ROS umożliwiający realizację zadania lokalizacji obiema metodami. Zostały przeprowadzone badania statystyczne jakości działania dla każdej z metod. Kolejnym etapem było zaimplementowanie metody pozwalającej na korektę estymacji lokalizacji robota mobilnego. Zostały wykonane badania jednostkowe metody korekcyjnej oraz badania statystyczne zmodyfikowanych algorytmów. Na końcu dokonano porównania obu metod i przedstawiono możliwe kontynuacje badań.

SUMMARY

The aim of the thesis was to compare the quality of two methods of mobile robot localization. One method uses a histogram to represent map of the environment and the other method uses a normal distribution to describe the map. As part of the work ROS package was created allowing to perform localization task using both of described methods. Statistical performance quality studies were conducted for each of the methods. The next step was to implement a correction method increasing accuracy of a mobile robot localization. Unit tests of correction methods and tests of standard algorithms were performed. And at the end, the two methods were compared and a potential continuation of the research was shown.

Słowa kluczowe: lokalizacja, robot mobilny, metoda histogramów, metoda rozkładu normalnego, ROS

Keywords: localization, mobile robot, histogram method, normal distribution transform, ROS

Spis treści

1	Wstęp	3
1.1	Teza pracy	5
1.2	Układ pracy	5
2	Środowisko symulacyjne	7
2.1	ROS i Gazebo	7
2.2	Model robota mobilnego	9
2.3	Środowisko robota	10
3	Zagadnienia teoretyczne	11
3.1	Reprezentacja mapy przy pomocy histogramów	11
3.1.1	Estymacja położenia	12
3.1.2	Estymacja orientacji	12
3.2	Reprezentacja mapy przy pomocy rozkładu normalnego	13
3.2.1	Estymacja położenia	13
3.2.2	Estymacja orientacji	14
3.3	Zwiększenie dokładności lokalizacji	14
4	Badania jakości estymacji położenia i orientacji	17
4.1	Badania estymacji lokalizacji i orientacji metodą histogramów	18
4.1.1	Podjęcie podstawowe	18
4.1.2	Korekcja lokalizacji z wykorzystaniem punktów sąsiadujących . . .	22
4.2	Badania estymacji lokalizacji i orientacji metodą rozkładu normalnego . . .	24
4.2.1	Podjęcie podstawowe	25
4.2.2	Korekcja lokalizacji z wykorzystaniem punktów sąsiadujących . . .	27
5	Podsumowanie	31
	Załącznik A	33
	Bibilografia	33

Rozdział 1

Wstęp

Robotyka mobilna jest jedną z najprężniej rozwijających się gałęzi robotyki[4]. Roboty mobilne tworzone są w celu wykonywania wielu typów zadań często skrajnie się od siebie różniących. Obecnie można je spotkać nie tylko w przemyśle, gdzie wykorzystywane są na przykład w transporcie magazynowym w celu znacznej optymalizacji procesów logistycznych. Można je spotkać podczas akcji ratowniczych w ramach poszukiwań górników lub osób zaginionych w górach. Coraz częściej roboty mobilne można spotkać w gospodarstwach domowych, w których autonomiczne odkurzacze cieszą się rosnącą popularnością. Ważną gałęzią robotyki mobilnej stała się branża samochodowa, która zajmuje się rozwijaniem możliwości autonomicznych pojazdów. Duże zainteresowanie różnymi gałęziami robotyki mobilnej owocuje w znaczący ich rozwój i przybliża ludzi do stworzenia w pełni autonomicznych pojazdów.

Rozwój techniki komputerowej owocuje wzrostem mocy obliczeniowej nawet niewielkich jednostek, dzięki czemu możliwe jest wykonywanie postawionych zadań z większą precyzją oraz w krótszym czasie. Jednym z podstawowych problemów robotyki mobilnej[8] jest lokalizacja robota, czyli śledzenie przez niego swojego położenia. Odpowiednio dokładna estymacja położenia może być krytyczna dla optymalizacji zdefiniowanego zadania, np. w dziedzinie czasu. Z drugiej strony błędy w estymacji położenia lub orientacji mogą doprowadzić do wypadków, które skutkowałyby uszkodzeniami robotów lub otoczenia, a w konsekwencji dużymi stratami finansowymi. W skrajnych przypadkach mogłyby doprowadzić do utraty zdrowia lub śmierci człowieka.

Częstym wyborem przy realizacji zadania lokalizacji jest wykorzystanie odometrii robota. Metody przyrostowe bazują na danych wewnętrznych robota, takich jak np. odczyty z enkoderów silników, na podstawie których można obliczyć metodami numerycznymi prędkości poszczególnych kół, a dzięki temu estymować aktualne położenie oraz orientację robota. Metody te są względnie proste w implementacji. Obarczone są natomiast błędami systematycznymi, które mogą być niewielkie w początkowej fazie pomiarów, ale kumulują się w kolejnych krokach, co znacząco wpływa na jakość wyniku rozwiązywanego problemu.

Inną grupą metod przybliżania położenia i orientacji robotów mobilnych są metody lokalizacji globalnej, które wykorzystują dane zewnętrzne (takie jak np. odczyty ze skanera) czy znaczniki rozmieszczone na obszarze, po którym porusza się robot. Metody te w przeciwieństwie do metod przyrostowych cechują się tym, że błędy nie akumulują się wraz z upływem czasu, lecz wartości błędów są stałe od początku do końca wykonywanego zadania. Znaczniki wykorzystywane do określenia położenia robota można podzielić na aktywne i pasywne, a także naturalne i sztuczne. Oznaczenia aktywne wysyłają pewien rodzaj sygnału, który jest interpretowany przez robota i na tej podstawie określa punkt w przestrzeni w jakim się znajduje, natomiast znaczniki pasywne wymagają wykrycia

oraz zinterpretowania przez czujniki robota. Znaczniki sztuczne, często spotykane w postaci np. kodów QR lub napisów, wymagają ingerencji w otoczenie robota, natomiast do typu naturalnych znaczników znajdują się struktury takie jak ściany lub narożniki pomieszczenia. Znaczniki naturalne nie zmieniają otoczenia w jakim porusza się obiekt, jednak ze względu na częste występowanie możliwe jest błędne określenie położenia.

Do określania położenia robota alternatywnie stosowana jest grupa metod lokalizacji probabilistycznej[7]. Metody te określają najbardziej prawdopodobne miejsce lub miejsca znajdowania się robota na podstawie cech otoczenia w jakim się on znajduje. W tym przypadku w pełni znana jest mapa po jakiej porusza się robot oraz obserwacje otrzymywane z czujników. W niektórych przypadkach znany jest również ciąg sterowań robota prowadzący do aktualnego położenia. Na tej podstawie określane jest najbardziej prawdopodobny stan robota. Metody te najlepiej sprawdzają się w przestrzeniach cechujących się brakiem symetrii, natomiast pusty pokój generowałby do czterech równie prawdopodobnych wyników działania algorytmu. W tej grupie metod najczęściej wykorzystuje się dane pozyskiwane ze skanerów laserowych 2D lub czujników typu LiDAR. Z tych danych ekstrahowane są odpowiednie cechy, na podstawie których dokonywany jest proces estymacji położenia.

Problemem w realizacji zadania lokalizacji robota mobilnego jest określenie odpowiedniej interpretacji danych otrzymywanych z czujników, a co za tym idzie odpowiednie zdefiniowanie cech opisujących otoczenie robota i postać w jakiej reprezentowana będzie mapa. Nieprawidłowo określone cechy mogą powodować niepoprawne działanie algorytmu estymacji położenia, a co za tym idzie błędną realizację innych zadań robota, które wymagają określenia jego położenia. Inną trudnością może być fakt, iż wynikiem działania algorytmu może być pewne otoczenie, na obszarze którego jest wysokie prawdopodobieństwo rzeczywistego położenia robota. Jeżeli obszar ten znajduje się w pobliżu sztywnych ograniczeń, takich jak ściany, występuje ryzyko zlokalizowania robota po złej stronie tej przeszkody, np. w innym pomieszczeniu.

W metodach probabilistycznych zbiór cech można przedstawić przy pomocy rozkładu normalnego [2]. W takim wypadku pomiary z czujników przedstawiane są jako pary liczb: wartość oczekiwana danych uzyskanych z pomiaru w określonym stanie oraz odchylenie standardowe dla danych z tego pomiaru. Alternatywnym podejściem do reprezentacji pomiarów otrzymanych ze skanów otoczenia jest wygenerowanie na ich podstawie histogramu[1].

W niniejszej pracy zaproponowano wykorzystanie dwóch metod probabilistycznych w celu estymacji położenia oraz orientacji robota mobilnego na podstawie danych pozyskanych przy pomocy skanera laserowego. Jedna z metod przewiduje estymację położenia na podstawie zbioru cech wygenerowanego przy pomocy histogramu. W przypadku takiej reprezentacji mapy histogram przedstawia odległość odczytanych punktów od robota, a położenie wyznaczane jest poprzez określenie minimalnej różnicy histogramów. Druga metoda wykorzystuje natomiast wspomniane wcześniej określanie cech na podstawie rozkładu normalnego danych z pomiarów. W celu wpływania na jakość estymacji położenia zbiór danych został podzielony na mniejsze podzbiory, dla których obliczana jest osobno wartość oczekiwana oraz odchylenie standardowe. Dzięki temu zwiększono liczbę cech otoczenia. Na bazie tych dwóch metod została estymowana lokalizacja robota na mapie, a w ostatniej fazie została porównana skuteczność zastosowania każdej z metod.

1.1 Teza pracy

Dla w pełni znanego otoczenia możliwa jest estymacja położenia i orientacji robota poprzez wykorzystanie mapy bazującej na histogramach oraz mapy opartej o rozkład normalny.

1.2 Układ pracy

W drugim rozdziale zostało omówione środowisko i narzędzia wykorzystywane do stworzenia projektu, który jest częścią niniejszej pracy. W pierwszej kolejności zostało omówione wykorzystywane oprogramowanie. Następnie przedstawiono strukturę napisanego programu. W dalszej części opisano model wykorzystywanego robota oraz mapę, która stanowi przestrzeń zadaniową problemu.

W trzecim rozdziale poruszono zagadnienia teoretyczne, które zostały wykorzystane w realizacji pracy. Został opisany sposób reprezentacji mapy przy pomocy histogramów oraz przy pomocy rozkładu normalnego. Została również opisana metoda na zwiększenie dokładności lokalizacji platformy mobilnej przy pomocy uwzględnienia punktów sąsiadujących.

Czwarty rozdział został poświęcony badaniom jakości zaimplementowanych algorytmów. Wyniki badań statystycznych zostały przedstawione w formie tabelarycznej oraz na histogramach. Następnie opisano badania dotyczące poprawy jakości wyznaczania lokalizacji robota.

Ostatni rozdział stanowi podsumowanie całości. Zawarto w nim wnioski wyciągnięte podczas prac oraz pomysły na dalsze rozwijanie poruszanego zagadnienia.

Rozdział 2

Środowisko symulacyjne

Jednym z najważniejszych elementów w zagadnieniu lokalizacji robota mobilnego jest testowanie działania algorytmu w odpowiednio dobranym środowisku. Obecnie możliwe jest wykorzystanie środowisk symulacyjnych, które pozwalają na odwzorowanie rzeczywistych warunków w akceptowalny sposób. Wybrane środowisko powinno umożliwiać łatwe kreowanie i zmienianie świata w jakim będzie poruszać się robot. Powinny być dostępne pakiety umożliwiające podgląd danych w czasie rzeczywistym, które posłużyć mogą do weryfikacji działania zaimplementowanego algorytmu. Od używanego pakietu symulacyjnego oczekuje się również możliwości zamodelowania robota wraz ze wszystkimi wymaganymi sensorami oraz opcji sterowania tym robotem. Środowisko symulacyjne powinno umożliwiać uruchomienie zaimplementowanych algorytmów potrzebnych do wykonania zdefiniowanego zadania.

W celu spełnienia określonych wyżej wymagań zdecydowano się na wybór systemu operacyjnego Linux Ubuntu 20.04 Focal Fossa, na którym została zainstalowana platforma programistyczna ROS (*Robot Operating System*)[3] wraz z symulatorem graficznym Gazebo oraz interpreter języka Python. ROS posiada wsparcie dla wybranych języków programowania, w tym dla wspomnianego wcześniej języka Python. W projekcie wykorzystano biblioteki dostępne dla języka Python takie jak: *time*, *numpy*, *pickle*, *json*, *sys*, a także biblioteki udostępnione w celu integracji z ROsem i Gazebo: *rospy*, *sensor_msgs*, *nav_msgs*, *gazebo_msgs*.

2.1 ROS i Gazebo

W ramach projektu został stworzony pakiet (z ang. *package*) do systemu ROS, zawierający zdefiniowany model robota mobilnego klasy (2,0), a także odpowiednie skrypty realizujące wykorzystywane algorytmy.


Celem realizacji zadania lokalizacji postanowiono zastosować pewną dekompozycję problemu i wykorzystać możliwości udostępniane przez architekturę ROSa. Całe zadanie zostało zatem podzielone na kilka etapów: budowanie mapy, lokalizację metodą histogramów, lokalizację metodą rozkładu normalnego. Każdy etap zrealizowano wykorzystując podejście obiektowe, co oznacza, że każda część zadania została zdefiniowana w formie klasy i odpowiednich metod, które wykonują odpowiednie operacje. Tak zaimplementowany kod można wykorzystywać w innych skryptach poprzez zaimportowanie jako biblioteki.

Architektura ROSa wykorzystuje do działania koncepcję węzłów (z ang. *nodes*) oraz tematów (z ang. *topics*). Podczas wykorzystywania poszczególnych klas można wyróżnić następujące węzły:

- Mapping,
- Histogram_Localization,
- Probabilistic_Localization.


Do prawidłowego funkcjonowania każdy z węzłów wymaga działania węzła odpowiedzialnego za symulator Gazebo, natomiast w aktualnie wybranym świecie powinien znajdować się model robota dostępnego w pakiecie (lub inny podany jako parametr podczas inicjalizacji odpowiedniego obiektu w skrypcie). W celu wykorzystania integracji ROSa z Gazebo należy wykorzystać udostępnione pakiety *gazebo_ros_pkgs*.

Węzeł *Mapping* przy pomocy tematu */gazebo/set_model_state* rozmieszcza robota po wybranym obszarze z pewną rozdzielczością budowania mapy. Obszar oraz rozdzielczość podaje użytkownik przez zdefiniowane parametry. Następnie dzięki subskrypcji tematu */laser/scan* węzeł otrzymuje odpowiednie dane z czujników i zapisuje informacje takie jak aktualne położenie oraz skan do pliku w jednym z wybranych formatów: *JSON* lub *Pickle*. Proces skanowania mapy i zapisywanie danych do pliku jest czasochłonny, a pliki potrafią osiągać duże rozmiary (zwłaszcza pliki w formacie *JSON*). Na rys. 2.1 pokazany jest graf zależności podczas działania węzła *Mapping* otrzymany przy pomocy narzędzia *rqt_graph*.




Rysunek 2.1 Graf zależności węzła Mapping

Węzeł *Histogram_Localization* wykorzystuje informacje zapisane we wskazanym przez użytkownika pliku. Wczytane dane są poddawane wstępnej filtracji, a następnie budowana jest w pamięci mapa cech oparta na histogramach służąca do określenia położenia oraz mapa służąca do estymacji orientacji. W kolejnym kroku wykorzystywana jest subskrypcja węzła */laser/scan* w celu pobrania pomiaru ze skanera. Dane otrzymane przez węzeł, wykorzystywane są do porównania ze zbudowaną wcześniej mapą. Na koniec zwracany jest wybrany przez algorytm punkt i orientacja robota. Możliwe jest również wykorzystanie w tym celu danych pomiarowych zapisanych w pliku. Wykres zależności tego węzła wygenerowany przez pakiet *rqt_graph* został pokazany na rys. 2.2.



Rysunek 2.2 Graf zależności węzła Histogram_Localization


Działanie węzła *Probabilistic_Localization* jest analogiczne do węzła wykorzystującego metodę histogramów. Możliwe jest wykorzystanie tych samych sposobów pozyskiwania danych. Analogiczny jest również schemat działania tego węzła. Jediną różnicą jest algorytm, który jest wykorzystywany w celu realizacji zadania estymacji położenia i orientacji. Również dla tego węzła został wygenerowany graf zależności przy pomocy pakietu *rqt_graph*, co przedstawiono na rys. 2.3.



Rysunek 2.3 Graf zależności węzła *Probabilistic_Localization*

2.2 Model robota mobilnego

Postawione zadanie nie stawiało żadnych konkretnych wymagań co do wyboru rodzaju robota w symulacji. Dlatego zdecydowano się na prosty model w postaci robota mobilnego klasy (2,0) o dwóch kołach sterowanych niezależnie oraz wyposażonego w czujnik laserowy o zasięgu 360° i liczbie pomiarów wynoszącej 1000. Opis modelu został stworzony w formacie URDF[10], który umożliwia wykorzystanie modelu zarówno w graficznym symulatorze Gazebo, jak i w narzędziu służącym do wizualizacji – RViz. W celu symulacji działania czujnika laserowego wykorzystano wtyczkę *gazebo_ros_head_hokuyo_controller* do publikowania odczytywanych danych przy pomocy tematu */laser/scan*. Widok modelu robota w symulatorze przedstawiono na rys. 2.4. Rysunek 2.4a przedstawia widok robota bez wizualizacji czujnika laserowego, natomiast rysunek 2.4b przedstawia robota z wizualizacją wiązek skanera.




(a) Robot bez wizualizacji lasera

(b) Robot z wizualizacją lasera


Rysunek 2.4 Widok modelu robota w środowisku symulacyjnym Gazebo

2.3 Środowisko robota

Kolejnym etapem było zdefiniowanie przestrzeni w jakiej realizowane będzie wyznaczone zadanie. Wybór padł na jeden ze światów domyślnie dostępnych w Gazebo, a mianowicie odwzorowanie przestrzeni biurowej firmy Willow Garage, czyli świat o takiej samej nazwie. Mapę tę cechuje dosyć duża powierzchnia podzielona na obszary – pokoje o różnym stopniu symetryczności. Taka specyfika tego świata pozwoliła na zbadanie właściwości zaimplementowanych algorytmów podczas zastosowania dla różnych rodzajów pomieszczeń. Widok modelu świata z lotu ptaka został przedstawiony na rys. 2.5, natomiast rys. 2.6 przedstawia wspomniany świat wraz z modelem robota.



Rysunek 2.5 Świat Willow Garage – widok z góry



Rysunek 2.6 Świat Willow Garage z widocznym modelem robota

Rozdział 3

Zagadnienia teoretyczne

Człowiek podczas przemieszczania się po pewnym obszarze porusza się intuicyjnie. Podświadomie przetwarza informacje pozyskiwane zmysłami i określa w jakim punkcie otoczenia się znajduje. W przypadku robota cały proces przebiega czysto matematycznie. Konieczne jest odebranie, zinterpretowanie i przeliczenie często ogromnej ilości danych w celu obliczenia i uzyskania, często nieprawidłowej, informacji o swoim położeniu. Zadanie lokalizacji robota definiuje się jako wyznaczenie stanu (położenia) robota x_t lub $X = \{x_{1:t}\}$ przy pełnej znajomości środowiska m , ciągu sterowań $\mathcal{U} = \{u_{1:t}\}$ oraz ciągu obserwacji $\mathcal{Z} = \{z_{1:t}\}$.

Założenia dotyczące niniejszej pracy nie obejmują zagadnień sterowania robotem. W tym przypadku przytoczoną wcześniej definicję można przedstawić w następujący sposób: należy wyznaczyć stan (położenie) robota x_t dla w pełni znanego środowiska m oraz obserwacji w danym momencie z_t .

Zbieranie informacji o mapie odbywa się w sposób iteracyjny na zadanym przez użytkownika obszarze otoczenia oraz z wybraną rozdzielczością (wektor przesunięcia robota w kolejnej iteracji procesu). Tak zbierane dane są zapisywane w plikach w postaci listy słowników. Słowniki zawierają pary: współrzędne punktu oraz surowy odczyt danych ze skanera. Przygotowane dane są wczytywane i zapisywane do pamięci programu w odpowiedniej formie.

Ze względu na sposób tworzenia mapy, jaki został opisany, zebrane pomiary tworzą siatkę o boku a . Jeśli rzeczywiste położenie robota wystąpi wewnątrz siatki oraz przy założeniu, że zostanie wyznaczony najbliższy znany punkt, wtedy maksymalny błąd lokalizacji wyniesie połowę przekątnej.

$$e_{max} = \frac{a\sqrt{2}}{2} \quad (3.1)$$

3.1 Reprezentacja mapy przy pomocy histogramów

W celu utworzenia histogramu z danych pobranych z pliku należy podzielić cały zbiór na L koszy (z ang. *bins*), które reprezentują określone przedziały odległości punktów od skanera[9]. Graniczne wartości każdego z przedziałów można określić w następujący sposób

$$(i - 1) \frac{k_{max}}{L} < l_i \leq i \frac{k_{max}}{L}, \quad (3.2)$$

gdzie k_{max} to maksymalny zasięg skanera, a l_i reprezentuje kolejny koszt dla $i = \{1, 2, 3 \dots L\}$. Mapa w pamięci robota przechowywana jest w postaci listy, natomiast każdy element tej listy zawiera informacje o współrzędnych danego punktu, ilości koszy oraz wartościach przypisanych dla każdego z nich.

3.1.1 Estymacja położenia

Dla mapy reprezentowanej przez postać histogramu nie jest istotna początkowa orientacja. Ta reprezentacja danych jest niezależna od orientacji robota. Estymacja położenia jest realizowana poprzez porównanie histogramu utworzonego z pomiaru robota w aktualnym stanie z każdym histogramem punktu mapy znajdującej się w pamięci. Odejmowanie histogramów opisane jest przez (3.3), gdzie M_i to histogram kolejnego punktu na mapie, I to histogram utworzony z aktualnego odczytu, a j to indeks kolejnego kosza obydwu histogramów. Wynikiem odejmowania jest suma różnicy wartości bezwzględnych wszystkich koszy.

$$M_i - I = \sum_{j=0}^L |M_{ij} - I_j| \quad (3.3)$$

Po zrealizowaniu odejmowania histogramów dla całej mapy należy wybrać punkt, który posiada najbardziej podobny histogram. W tym celu należy zwrócić indeks mapy, dla którego różnica jest minimalna (3.4).

$$p = \arg \min_i (M_i - I) \quad (3.4)$$

3.1.2 Estymacja orientacji

Przy założeniu, że skaner zbiera dane na pełnym zakresie 360° można wyznaczyć orientację mapy przy pomocy średniej wartości pomiaru. W tym celu należy podzielić przestrzeń na K sektorów. Przy założeniu, że wiązki lasera są umieszczone równomiernie, w każdym sektorze znajdzie się n wiązek. Wartości histogramu wyznaczone są poprzez obliczenie wartości średniej z pomiarów znajdujących w danym sektorze. Liczba sektorów określa precyzję wartości kąta obrotu dla pojedynczego kosza histogramu (3.5) i jednocześnie dokładność dyskretyzacji zadania estymacji orientacji robota.

$$\gamma = \frac{2\pi}{K} \quad (3.5)$$

Zadanie estymacji orientacji jest uproszczone, ponieważ założone jest, że została już wyznaczona pozycja robota. W tym wypadku tworzony jest histogram orientacji tylko dla punktu wskazanego w procesie estymacji położenia. W celu wyznaczenia orientacji robota należy wykonać w sposób iteracyjny odejmowanie histogramów orientacji. Po każdym wykonaniu operacji odejmowania należy przesunąć pierwszy kosz histogramu stworzonego z aktualnego pomiaru na ostatnią pozycję i powtórzyć odejmowanie. Operacja ta jest wykonywana do momentu aż histogram powróci do pierwotnej postaci.

$$e_o = \sum_{j=0}^K |M_i - I_j| \quad (3.6)$$

Natomiast indeks przesunięcia histogramu n , dla którego błąd histogramu orientacji jest minimalny, otrzymamy poprzez

$$n = \arg \min_{j \in [0, K]} |M_i - I^j|. \quad (3.7)$$

Rotacja histogramu określona jako I^j jest podobna do rotacji bitowej i określona jest jako

$$I^j = (i_j, i_{j+1}, \dots, i_K, i_1, i_2, \dots, i_{j-1}). \quad (3.8)$$

Dzięki otrzymanemu indeksowi (3.7) i rozdzielczości kątowej (3.5) można wyznaczyć orientację robota

$$\Theta = (\varphi + \gamma n) \% 2\pi. \quad (3.9)$$

Gdzie φ oznacza orientację robota podczas tworzenia mapy (domyślnie $\varphi = 0$), a n to wyliczony indeks przesunięcia histogramu.

3.2 Reprezentacja mapy przy pomocy rozkładu normalnego

W celu utworzenia wektora cech z danych zawartych w pliku należy wykorzystać rozkład normalny $\mathcal{N}(\sigma, \mu)$ [6] do reprezentacji rekordów otrzymanych ze skanera. W ten sposób dla danego pomiaru wyłonione zostają cechy otoczenia w postaci wartości oczekiwanej σ oraz odchylenia standardowego μ . W celu zwiększenia liczby cech podzielono zestaw danych na k sektorów i dla każdego z nich wyliczona została wartość średnia oraz odchylenie standardowe. Mapa w pamięci robota przechowywana jest w postaci listy, natomiast każdy element tej listy zawiera informacje o współrzędnych danego punktu oraz macierz par cech postaci $\omega_i = \{\sigma_i, \mu_i\}$. Zatem wykorzystywana reprezentacja cech przedstawiona jest jako

$$\Omega = \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_{k-1} \\ \omega_k \end{bmatrix}. \quad (3.10)$$

3.2.1 Estymacja położenia

W przeciwieństwie do metody histogramów w tym przypadku konieczne jest uwzględnienie początkowej orientacji robota, ponieważ kolejność sektorów jest uzależniona od kąta obrotu monocyklu. Dlatego podczas budowania mapy wektor cech jest modyfikowany z wykorzystaniem lokalnego minimum.

$$l = \arg \min_i S, \quad (3.11)$$

gdzie S to pojedynczy skan, a i to kolejny indeks w danych tego pomiaru. Nowy skan przyjmuje postać

$$S' = (S_l, S_{l+1}, S_{l+2}, \dots, S_z, S_1, S_2, \dots, S_{l-1}), \quad (3.12)$$

gdzie $z = 1000$ to liczba pomiarów w jednym skanie. Dla każdego punktu mapy zapisanego w pliku i z przypisanym skaniem S_i powstaje wektor S'_i , a następnie budowany jest wektor cech zgodnie z (3.10).

Estymacja położenia polega na porównaniu cech z aktualnego położenia z każdym punktem mapy i wybraniu tego najbardziej pasującego. Wykonywane jest odejmowanie wektorów cech

$$\Delta = M_i - \Omega, \quad (3.13)$$

gdzie M_i to wektor cech kolejnego punktu mapy, a Ω to wektor cech obliczony z aktualnego położenia. Różnica wektorów cech jest obliczana poprzez sumowanie różnicy kwadratów dla kolejnych par.

$$\delta = \sum_{j=0}^K \sqrt{(\sigma_j^i - \sigma_j^\Omega)^2 + (\mu_j^i - \mu_j^\Omega)^2}, \quad (3.14)$$

gdzie j to indeks kolejnej pary wektora cech, natomiast i to indeks kolejnego punktu na mapie. W ostatnim etapie wybierany jest najmniejszy wynik odejmowania wektorów cech. Zwrócony indeks odpowiada zlokalizowanemu punktowi na mapie.

$$p = \arg \min_i |M_i - \Omega|, \quad (3.15)$$

3.2.2 Estymacja orientacji

Procedura estymacji orientacji metodą rozkładu normalnego przebiega podobnie do tej wykorzystującej histogramy. Wektor cech używany do określenia orientacji platformy mobilnej metodą rozkładu normalnego tworzy się w sposób analogiczny do wektora cech lokalizacji (3.10). Pominięty zostanie krok wyznaczenia minimum lokalnego (3.11). Jeżeli w danym sektorze wszystkie pomiary otrzymają wartość nieprawidłową obie liczby w parze przyjmują wartość 0. Przy ponownym założeniu, że laser ma zakres 360° oraz wiązki lasera rozchodzą się równomiernie – w każdym sektorze znajdzie się m wiązek, a liczba sektorów – K określi dokładność estymacji orientacji (3.5).

Różnica wektorów cech obliczana jest tak samo jak w przypadku określania położenia (3.14). W tym przypadku dodatkowo wyznaczany jest indeks przesunięcia wektora cech.

$$n = \arg \min_j |M_i - \Omega^j|, \quad (3.16)$$

gdzie Ω^j określa przesunięcie wektora cech określane jako

$$\Omega^j = ((\sigma_j, \mu_j), (\sigma_{j+1}, \mu_{j+1}), \dots, (\sigma_K, \mu_K), (\sigma_1, \mu_1), (\sigma_2, \mu_2), \dots, (\sigma_{j-1}, \mu_{j-1})). \quad (3.17)$$

Otrzymany indeks można wykorzystać do wyliczenia orientacji względem położenia na mapie

$$\Theta = (\varphi + \gamma n) \% 2\pi, \quad (3.18)$$

gdzie φ to orientacja początkowa obiektu, γ to rozdzielczość estymowanej orientacji, a n to indeks przesunięcia wektora cech.

3.3 Zwiększenie dokładności lokalizacji

Zwiększenie rozdzielczości mapy znacząco zwiększa ilość danych, które są zapisywane i przetwarzane w procesie lokalizacji robota. Innym podejściem jest zwiększenie wymiaru macierzy cech, jednak i w tym przypadku zwiększa się złożoność obliczeniowa całego procesu. W celu uniknięcia tego problemu zdecydowano się na zastosowanie podejścia, które zakłada wykorzystanie otoczenia wytypowanego punktu w celu zwiększenia dokładności wyznaczania położenia. Takie podejście sprawiło, że konieczne stało się jedynie ponowne sprawdzenie czterech punktów w otoczeniu wstępnie wyznaczonego punktu.

To podejście wykorzystuje punkt wyznaczony przy pomocy bazowej wersji jednej z metod opisanych wyżej i jest dalej nazywany *punktem odniesienia* p_0 . Dla tak wyznaczonego

położenia wprowadzana jest korekta względem osi X, a następnie względem osi Y. Dla każdego wymiaru wybierane są dwa punkty sąsiadujące z punktem odniesienia

$$p'_i = p_0 \pm a, \quad (3.19)$$

gdzie a to rozdzielczość mapy, natomiast $i \in \{1, 2\}$ to indeks punktów sąsiadujących na rozpatrywanej osi. Z tak określonych punktów sąsiadujących wybierany jest punkt o najmniejszej różnicy wektora cech z punktem rzeczywistym, a co za tym idzie z największym prawdopodobieństwem lokalizacji robota.

$$dir = arg \min_i (e_p^i) \quad (3.20)$$

Gdzie e_p^i to różnica cech punktu sąsiadującego o indeksie i , natomiast dir to otrzymany indeks wybranego punktu sąsiedniego. W ten sposób definiowany jest kierunek korekty estymacji położenia. Kolejnym krokiem jest wyznaczenie wagi przesunięcia w kierunku wybranego punktu ościennego. Obliczany jest on poprzez stosunek różnicy wektorów cech pomiędzy wybranym punktem odniesienia i wybranym punktem sąsiadującym (e_p^{dir}) do różnicy cech pomiędzy punktem rzeczywistym, a wybranym punktem sąsiednim z .

$$\xi = \left(1 - \frac{e_p^{dir}}{z}\right) \alpha, \quad (3.21)$$

Gdzie α to współczynnik tłumiący dobierany w sposób eksperymentalny. Dla $\xi \in (0, \frac{a}{2})$ następuje przesunięcie maksymalnie o wartość połowy rozdzielczości mapy. Ostatecznie skorygowany punkt to przesunięcie o wartość odległości punktu odniesienia z wybranym punktem sąsiadującym przeskalowaną przez współczynnik ξ .

$$p_F = p_0 + (p_0 - p_{dir})\xi \quad (3.22)$$

Ponieważ odległość sąsiadujących punktów na siatce przyjmuje zawsze wartość równą rozdzielczości mapy z dokładnością do znaku, to

$$p_0 - p_{dir} = \pm a. \quad (3.23)$$


Ostatecznie skorygowany punkt końcowy wyznaczony jest jako

$$p_F = p_0 + a \cdot \xi. \quad (3.24)$$

Rozdział 4

Badania jakości estymacji położenia i orientacji

W celu zbadania jakości działania algorytmów opisanych w poprzednim rozdziale został przeprowadzony szereg testów, który pozwolił określić pewne właściwości dla obu wykorzystanych algorytmów oraz dokonanie ich statystycznego porównania. Został zmapowany pewien obszar dla środowiska robotycznego *WillowGarage* (rys. 2.5). Pomiary ze skanera zostały wykonane na obszarze zaznaczonym zielonym kolorem na rys. 4.1.



Rysunek 4.1 Obszar testowania algorytmów

Dane pomiarowe zostały pobrane dla rozdzielczości $x_{res} = y_{res} = 0.1m$ i zapisane w pliku. Każdy pomiar został wykonany dla orientacji robota $\theta = 0^\circ$. Następnie wyznaczono punkty testowe. W tym celu zostało wybranych 1000 losowych, niepowtarzających się punktów na zmapowanym obszarze. Dla każdego z punktów testowych został wykonany pomiar skanera w zadanej pozycji z losowo wybraną orientacją. Zbiór danych testowych również został zapisany do pliku razem z informacją o rzeczywistym położeniu oraz orientacji jako wektor $(x, y, \theta)^T$. Tak przygotowane dane pozwoliły na analizę działania obu algorytmów dla takich samych warunków.

W kolejnym kroku dokonano estymacji położenia oraz orientacji dla każdego z punktów testowych przy pomocy obu algorytmów. W przypadku obu metod postępowanie było identyczne. Dla kolejnego elementu w zbiorze testowym wyznaczany był punkt z pliku zawierającego informacje o środowisku, a następnie wyznaczany zostawał błąd estymacji względem rzeczywistego punktu pomiarowego. Tak otrzymane wyniki zostały poddane analizie rozkładu normalnego. Wyznaczone zostały wartości opisujące jakość algorytmów, takie jak średnia wartość błędu, odchylenie standardowe błędu, błąd minimalny, błąd maksymalny oraz mediana błędu.

Badania wykonano dla różnych wartości parametru k oraz l . W przypadku metody histogramów k oznacza liczbę słupków histogramu, natomiast w przypadku metody rozkładu normalnego parametr k oznacza liczbę sektorów dla wektora cech. Parametr l dla obu metod oznacza liczbę sektorów, na które zostały podzielone dane pomiarowe do wyznaczenia orientacji.

W kolejnym kroku sprawdzono jakość zaimplementowanej metody zwiększenia dokładności estymacji położenia. Wyznaczone zostały punkty na stworzonej mapie, a następnie dokonano badań jakości działania wybranej metody.

4.1 Badania estymacji lokalizacji i orientacji metodą histogramów

W celu zbadania mocnych i słabych stron reprezentacji mapy przy pomocy histogramów dokonano szeregu badań statystycznych. W pierwszym etapie dokonano badań jakości podstawowej wersji algorytmu. W kolejnym kroku dokonano badań jednostkowych na wykorzystanej metodzie korekcji lokalizacji oraz ponownie wykonano badania statystyczne w celu porównania wyników. Został zbadany wpływ liczby koszy na jakość wyznaczenia lokalizacji i liczby sekcji na jakość określenia orientacji. Przetestowano również wpływ liczby koszy i parametru tłumienia na działanie metody korekcji.

4.1.1 Podejście podstawowe

Wyniki badań estymacji lokalizacji metodą histogramów zostały przedstawione w tabeli 4.1. Widoczna jest tendencja spadkowa średniej wartości błędu lokalizacji oraz odchylenia standardowego dla tego błędu wraz ze wzrostem wartości parametru k . Jedynym wyjątkiem od tego zachowania są wyjątkowo dobre wyniki dla $k = 15$. Może to być spowodowane charakterystyką badanego pomieszczenia, a także faktu, że dla tej wartości k błąd maksymalny wyniósł 0.9m, natomiast w innych przypadkach błąd ten wynosił około 7 metrów. Tak duża wartość błędu maksymalnego może być spowodowana symetrią badanego pomieszczenia. Można zauważyć, że dla $k > 20$ nie następuje znacząca poprawa jakości estymacji położenia. W przypadku dużej liczby koszy, dla $k > 150$, dokładność wyznaczania lokalizacji pogorszyła się.

Badania jakości błędu estymacji orientacji zostały przedstawione w tabeli 4.2. Dla każdej wartości parametru l średnia wartość błędu jest mniejsza niż wyznaczona precyzja estymacji (3.5). Wartości średnie błędów, a także odchylenie standardowe maleją wraz ze zwiększeniem liczby sektorów, na które dzieli się dane pomiarowe. Zgodnie z oczekiwaniami wraz ze wzrostem wartości parametru l średni błąd oraz odchylenie standardowe maleją. Estymacja orientacji ma charakter cykliczny, dlatego zdecydowano się na zmianę obliczanego błędu z przedziału $e \in [0, 2\pi]$ na wartość $e_f = |e|$ dla $e \in [-\pi, \pi]$. Dla każdej

k	5	10	15	20	25	30	50	100	200
średnia	0.325	0.191	0.158	0.178	0.167	0.162	0.164	0.161	0.181
odchyl. std.	0.771	0.478	0.113	0.423	0.322	0.245	0.329	0.326	0.397
bł. min.	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
bł. maks.	6.940	7.000	0.900	7.000	7.000	7.100	7.100	7.100	7.100
mediana	0.170	0.150	0.150	0.150	0.140	0.150	0.140	0.140	0.150

Tabela 4.1 Błąd lokalizacji wyrażony w metrach – metoda histogramów


z badanych wartości parametru l średni błąd pomiaru jest mniejszy niż wyznaczona dokładność dyskretyzacji (3.5). Niespodziewanie najmniejszą wartość błędu maksymalnego uzyskano dla $l = 10$. Po zwiększeniu liczby sekcji otrzymany błąd maksymalny wahał się w wartościach od 1.532 do 1.742 radianów, co przekłada się na około $90 - 100^\circ$. Dla $l = 30$ osiągnięto średnią błędów oraz odchylenie standardowe na poziomie $\sigma \approx \mu \approx 0.06rad$, czyli około 3° .

l	5	10	15	20	25	30
średnia	0.331	0.176	0.114	0.082	0.105	0.058
odchyl. std.	0.224	0.159	0.092	0.072	0.088	0.062
bł. min.	0.000	0.000	0.000	0.000	0.000	0.000
bł. maks.	2.720	1.167	1.532	1.742	1.637	1.742
mediana	0.310	0.154	0.108	0.077	0.091	0.056


Tabela 4.2 Błąd orientacji wyrażony w radianach – metoda histogramów

Błędy estymacji lokalizacji otrzymane podczas przeprowadzonych badań zostały przedstawione na rys. 4.2 w postaci histogramów. Dla reprezentacji w postaci histogramu o 5 koszach (rys. 4.2(a)) można zauważyć występowanie słupków o pojedynczych wartościach na całym zakresie wykresu. Na rysunkach 4.2(b)–4.2(f) można zauważyć, że zwiększenie liczby koszy histogramu reprezentującego wektor cech spowodowało znaczne zmniejszenie liczby wystąpień grubych błędów lokalizacji. Wyjątkiem jest pojedynczy błąd o wartości około 7.0m, którego występowanie jest najprawdopodobniej spowodowane przez pewną symetryczność używanego pomieszczenia. Zgodnie z przewidywaniami wraz ze wzrostem wielkości wektora cech wzrastała koncentracja koszy w okolicy wartości 0.


Takie rezultaty są spowodowane kompresją danych z czujnika laserowego dokonywanej w celu budowy wektora cech. W przypadku zróżnicowanego pomiaru wzrost liczby koszy w histogramie sprawia, że odwzorowanie rzeczywistego pomiaru jest coraz lepsze. Dlatego lokalizacja metodą histogramów robota mobilnego sprawdzi się lepiej w zróżnicowanych pomieszczeniach, takich jak pomieszczenie wybrane do testów. Z drugiej strony wykorzystanie jej w pomieszczeniach cechujących się wyraźną symetrią może spowodować częste występowanie grubych błędów, które wpłyną na wyniki jakości estymacji lokalizacji, a w konsekwencji również na jakość estymacji orientacji.




(a) Histogram błędów lokalizacji – 5 koszy




(b) Histogram błędów lokalizacji – 10 koszy




(c) Histogram błędów lokalizacji – 15 koszy



(d) Histogram błędów lokalizacji – 20 koszy



(e) Histogram błędów lokalizacji – 25 koszy




(f) Histogram błędów lokalizacji – 30 koszy

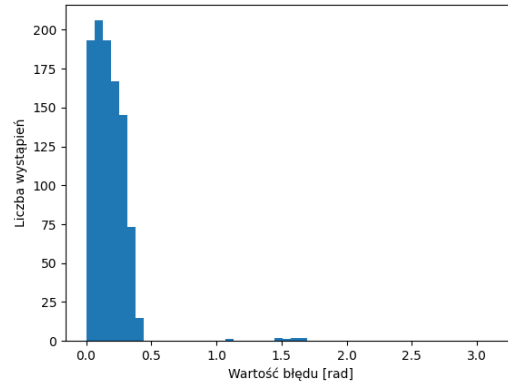
Rysunek 4.2 Histogramy błędów estymacji lokalizacji metodą histogramów dla różnej liczby koszy

Na rysunku 4.3 przedstawiono histogramy błędów otrzymanych podczas przeprowadzonych badań jakości estymacji orientacji metodą histogramów. Na każdym z wykresów (rys. 4.3(a)–4.3(f)) można zauważyć, że błędy wyznaczania orientacji skupiają się w otoczeniu wartości 0 radianów. Wraz ze wzrostem liczby sekcji (zwiększeniem wymiaru wektora cech) zauważalnie rośnie liczba wystąpień błędów w pobliżu wartości zero. Takie zachowanie na pokazanych wykresach potwierdziło wstępną hipotezę wzrostu dokładności estymacji orientacji proporcjonalnie do wzrostu wielkości wektora cech. Jakość wyznacza-


nia orientacji w zróżnicowanym otoczeniu powinna być większa niż w przypadku otoczenia symetrycznego. Powodem tego jest ta sama zależność jak w przypadku wyznaczania lokalizacji robota.




(a) Histogram błędów orientacji dla 5 sekcji




(b) Histogram błędów orientacji dla 10 sekcji



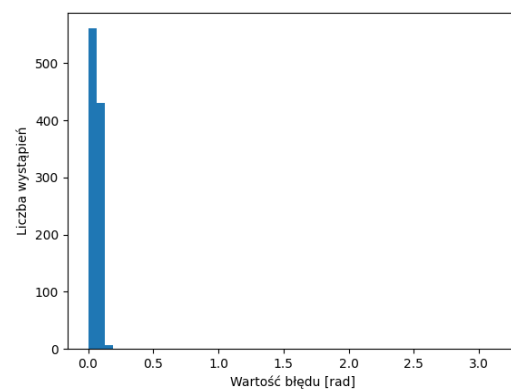
(c) Histogram błędów orientacji dla 15 sekcji



(d) Histogram błędów orientacji dla 20 sekcji



(e) Histogram błędów orientacji dla 25 sekcji



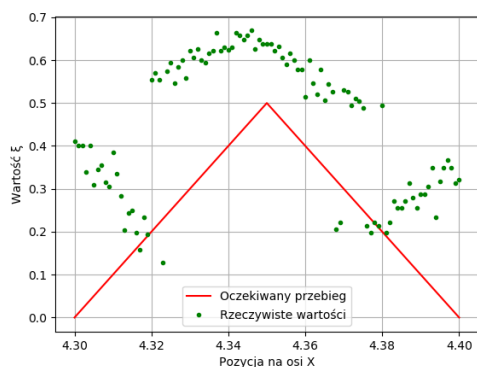


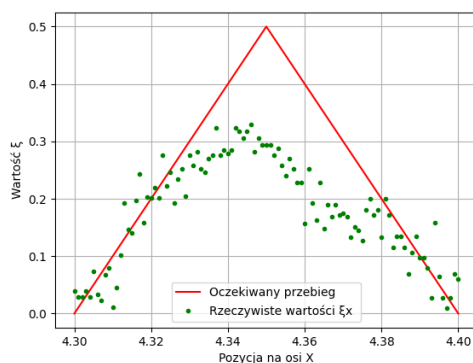
(f) Histogram błędów orientacji dla 30 sekcji

Rysunek 4.3 Histogramy błędów estymacji orientacji metodą histogramów dla różnej liczby sekcji

4.1.2 Korekcja lokalizacji z wykorzystaniem punktów sąsiadujących

W celu przeprowadzenia badań zostały wylosowane punkty na mapie, a następnie zbadano wpływ wartości współczynnika tłumienia α na korekcję przesunięcia robota wzdłuż jednej z osi. Zostało to wykonane poprzez pobranie stu pomiarów z czujnika laserowego na odcinku równym rozdzielczości mapy. Podczas tych pomiarów lokalizacja robota zmieniała się względem jednej osi.


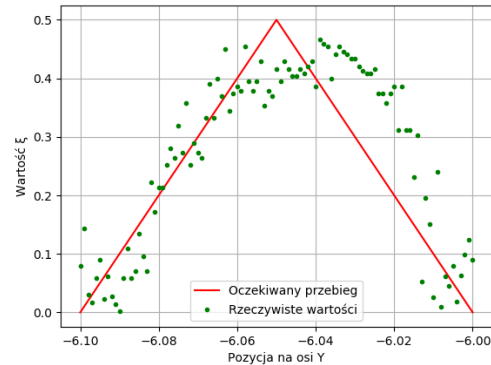

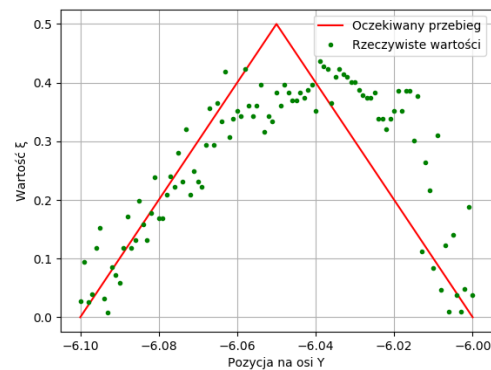
Na rys. 4.4 przedstawiono zmianę wartości współczynnika korekcji ξ od położenia robota w osi X. Robot był przemieszczany na odcinku $x = [4.3, 4.4]$ dla stałej wartości $y = -6.12$. Badania te zostały wykonane dla liczby koszy $k = 30$ i różnej wartości α . Oczekiwana wartość współczynnika ξ została przedstawiona kolorem czerwonym, natomiast kolorem zielonym zostały naniesione rzeczywiste otrzymane wartości. Jak można zauważyć najlepsze wyniki uzyskano dla wartości $\alpha \approx 1$. Przy wartościach α znacząco różnych od 1 uzyskiwane wartości współczynnika korekcji przestają mieć przebieg zbliżony do oczekiwanego. Jak można zauważyć na rys. 4.4(a) oraz 4.4(b) wartości parametru ξ rozdzielają się na 3 skupiska. Liczba skupisk prawdopodobnie jest zależna od zasięgu lasera, liczby koszy użytej w reprezentacji mapy oraz od rozdzielczości mapy.

(a) Współczynnik $\alpha = 1.6$ (b) Współczynnik $\alpha = 1.2$ (c) Współczynnik $\alpha = 1.05$ (d) Współczynnik $\alpha = 0.7$

Rysunek 4.4 Wpływ wartości parametru α na wartość parametru korekcji ξ dla osi X

Na rys. 4.5 przedstawiono zmianę wartości współczynnika korekcji ξ od położenia robota w osi Y. Robot był przemieszczany na odcinku $y \in [6.0, 6.1]$. W tym przypadku

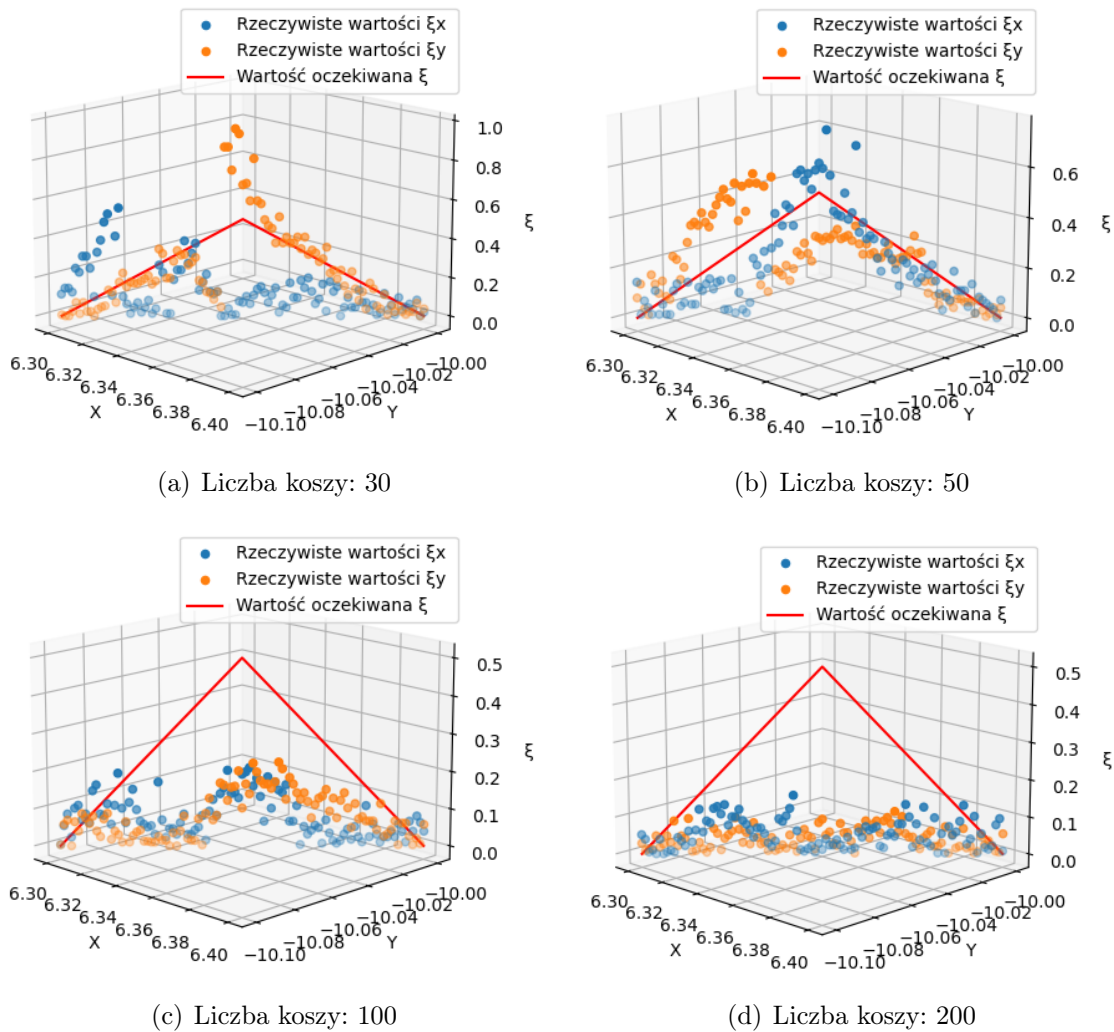
najlepsze wyniki otrzymano ponownie dla wartości $\alpha \approx 1$. Dla $\alpha = 1.2$ ponownie można dostrzec pewne skupiska punktów. Lepsze wyniki otrzymano, gdy wartość parametru zbiegała do wartości 1. Przy wartościach parametru $\alpha < 1.0$ również uzyskano wyniki znacząco odbiegające od zakładanych. Dla $\alpha = 1.2$ ponownie wystąpiło grupowanie wartości ξ podobnie jak w badaniach dla osi X.

(a) Współczynnik $\alpha = 1.2$ (b) Współczynnik $\alpha = 1.11$ (c) Współczynnik $\alpha = 1.08$ (d) Współczynnik $\alpha = 1.05$

Rysunek 4.5 Wpływ wartości parametru α na wartość parametru korekcyjnego ξ dla osi Y

Kolejnym krokiem było zbadanie wpływu wielkości wektora cech na wartość parametru ξ dla obu osi jednocześnie. W tym celu ponownie zostało pobranych 100 pomiarów. W tym przypadku dane zostały pobrane na przekątnej wybranej komórki siatki mapy. Początek pomiaru miał miejsce w punkcie $p_p = [6.3, -10.1]$, natomiast koniec w $p_k = [6.4, -10.0]$. Następnie dokonano estymacji położenia punktu z wykorzystaniem korekty punktów sąsiadujących. Otrzymane wartości parametru korekty zostały przedstawione na rys. 4.6.

Wyniki badań jakości estymacji lokalizacji metodą histogramów z wykorzystaniem korekty pozycji ze względu na punkty sąsiadujące zostały ukazane w tabeli 4.3. Pomimo że uzyskano podczas badań wartości parametru ξ zbliżone do wartości oczekiwanej, estymacja lokalizacji z korektą nie przyniosła zauważalnych popraw. Wyniki te są zbliżone do tych uzyskanych poprzez podejście podstawowe (tabela 4.1). Może być to spowodowane tym, że dla niektórych źle wytypowanych punktów metoda ta błędnie wybiera kierunek korekty. Wyjątkiem jest poprawienie wyników estymacji położenia o około 6% dla $k = 50$. Może to nasuwać wniosek o konieczności odpowiedniego dobrania zasięgu skanera oraz liczby koszy histogramu.

Rysunek 4.6 Wpływ liczby koszy na wartość parametru korekcji ξ

k	5	10	15	20	25	30	50
średnia	0.323	0.190	0.158	0.178	0.166	0.161	0.154
odchyl. std.	0.769	0.476	0.113	0.423	0.323	0.244	0.240
bł. min.	0.000	0.000	0.000	0.000	0.002	0.002	0.000
bł. maks.	6.924	6.980	0.913	7.003	7.009	7.093	7.032
mediana	0.172	0.152	0.146	0.145	0.144	0.147	0.143

Tabela 4.3 Błąd lokalizacji wyrażony w metrach – metoda histogramów z wykorzystaniem punktów sąsiadujących

4.2 Badania estymacji lokalizacji i orientacji metodą rozkładu normalnego

Metoda rozkładu normalnego działa w sposób analogiczny to metody histogramów. Z tego powodu zostały wykonane bliźniacze badania statystyczne, które pozwoliły zbadać jakość sprawdzanej metody. Sprawdzona została podstawowa wersja algorytmu oraz jej zmodyfikowana wersja. Zbadany został wpływ liczby sekcji na jakość określenia lokalizacji

i orientacji. Przetestowano również wpływ liczby sekcji i parametru tłumienia na działanie metody korekcji.

4.2.1 Podejście podstawowe

Wynik badań jakości estymacji lokalizacji metodą rozkładu normalnego zostały przedstawione w tabeli 4.4. Zawarte w niej rezultaty są podobne do tych uzyskanych przy użyciu metody histogramów. Zauważyć można jednak kilka różnic. Dla wartości $k \geq 15$ wartości poszczególnych wierszy utrzymują się na podobnym poziomie, w przeciwieństwie do wyników uzyskanych za pomocą poprzedniej metody. Kolejną obserwacją jest fakt, że dla tych samych wartości parametru k maksymalny błąd położenia jest znacznie mniejszy niż w przypadku metody histogramów. Inne wyniki mają porównywalne wartości jak w przypadku poprzedniej metody.

k	5	10	15	20	25	30	50	100
średnia	0.311	0.178	0.171	0.170	0.171	0.172	0.176	0.202
odchyl. std.	0.776	0.250	0.120	0.123	0.122	0.123	0.128	0.147
bł. min.	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
bł. maks.	7.000	7.090	0.660	0.900	0.900	0.900	0.900	1.000
mediana	0.170	0.150	0.150	0.150	0.150	0.155	0.150	0.17

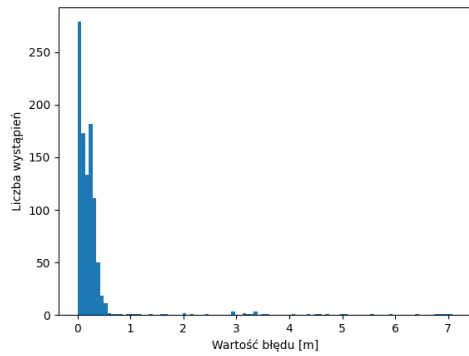
Tabela 4.4 Błąd lokalizacji wyrażony w metrach – metoda rozkładu normalnego

Wyniki badań statystycznych estymacji orientacji metodą rozkładu normalnego zostały przedstawione w tabeli 4.5. Dla poszczególnych wartości parametru k średnie wartości błędów estymacji orientacji są minimalnie gorsze od wyników uzyskanych podczas badań metodą histogramów, ale są to różnice pomijalne. Rezultaty badań jakości estymacji metodą rozkładu normalnego są analogiczne do tych otrzymanych podczas badań metodą histogramów. W tym przypadku również dokładność wzrasta wraz ze wzrostem wartości parametru k , a średnia błędów estymacji spełnia założenie o dokładności dyskretyzacji (3.5).


k	5	10	15	20	25	30
średnia	0.428	0.165	0.114	0.079	0.101	0.056
odchyl. std.	0.545	0.129	0.145	0.048	0.070	0.032
bł. min.	0.000	0.000	0.000	0.000	0.000	0.000
bł. maks.	3.103	2.850	3.096	0.077	0.089	0.143
mediana	0.317	0.155	0.108	0.078	0.296	0.056

Tabela 4.5 Błąd orientacji wyrażony w radianach – metoda rozkładu normalnego


Na rysunku 4.7 zostały przedstawione histogramy błędów estymacji położenia robota mobilnego przy pomocy metody rozkładu normalnego. Analogicznie jak w badaniach poprzednią metodą, w tym przypadku podzielenie danych pomiarowych na 5 sekcji okazało się zbyt niedokładne i skutkowało pojawieniem pojedynczych grubych błędów o różnych wartościach (rys. 4.7(a)). Dla $k = 10$ błędy te zostały wyeliminowane (oprócz pojedynczego błędu o wartości 7.1m na rys. 4.7(b)). Dla $k \geq 15$ maksymalny błąd spadł poniżej 1.0m natomiast histogramy błędów mają podobny kształt.




(a) Histogram błędów lokalizacji – 5 sekcji




(b) Histogram błędów lokalizacji – 10 sekcji




(c) Histogram błędów lokalizacji – 15 sekcji



(d) Histogram błędów lokalizacji – 20 sekcji




(e) Histogram błędów lokalizacji – 25 sekcji




(f) Histogram błędów lokalizacji – 30 sekcji

Rysunek 4.7 Histogramy błędów estymacji lokalizacji metodą rozkładu normalnego dla różnej liczby sekcji


Na rysunku 4.8 przedstawiono histogramy błędów estymacji orientacji metodą rozkładu normalnego. Zgodnie z przewidywaniami, dla wartości parametru $k \geq 5$ wykresy 4.8(b)–4.8(f) mają przebieg i wartości zbliżone do wyników uzyskanych za pomocą poprzedniej metody. Największą różnicę można zaobserwować na histogramie błędów dla 5 sekcji (rys. 4.8(a)) w porównaniu z histogramem błędów estymacji orientacji dla 5 koszy (rys. 4.3(a)). Metoda rozkładu normalnego wygenerowała widocznie więcej błędów w okolicach wartości liczby π . Jednak zwiększenie rozmiaru macierzy cech eliminuje występowanie tych błędów.




(a) Histogram błędów orientacji – 5 sekcji




(b) Histogram błędów orientacji – 10 sekcji




(c) Histogram błędów orientacji – 15 sekcji



(d) Histogram błędów orientacji – 20 sekcji



(e) Histogram błędów orientacji – 25 sekcji



(f) Histogram błędów orientacji – 30 sekcji


Rysunek 4.8 Histogramy błędów estymacji orientacji metodą rozkładu normalnego dla różnej liczby sekcji

4.2.2 Korekcja lokalizacji z wykorzystaniem punktów sąsiadujących


Modyfikacja uwzględniająca punkty sąsiadujące została zaimplementowana również dla metody rozkładu normalnego. Z powodu podobnej charakterystyki obu algorytmów eks-

perymenty zostały przeprowadzone w identyczny sposób.

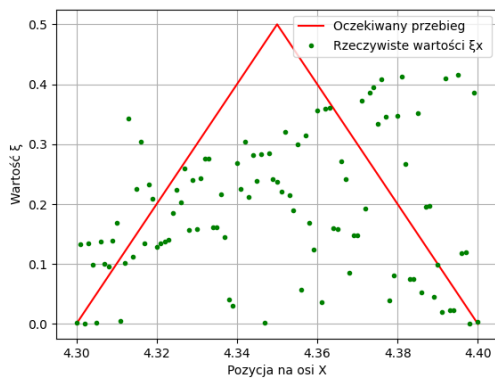
Na rys. 4.9 zostały przedstawione wykresy uzyskane podczas próby znalezienia odpowiedniej wartości parametru tłumienia α w celu uzyskania przebiegu wartości rzeczywistych parametru ξ jak najbardziej zbliżonego do przebiegu oczekiwanego, zaznaczonego kolorem czerwonym. Żadna z badanych wartości α nie pozwoliła na uzyskanie satysfakcjonującego wyniku. Rzeczywiste wartości parametru ξ przyjęły wartości o charakterze losowym w każdym testowanym przypadku. Zmiana wartości parametru tłumienia miała wpływ jedynie na wartość maksymalną.




(a) Parametr $\alpha = 0.7$



(b) Parametr $\alpha = 0.95$



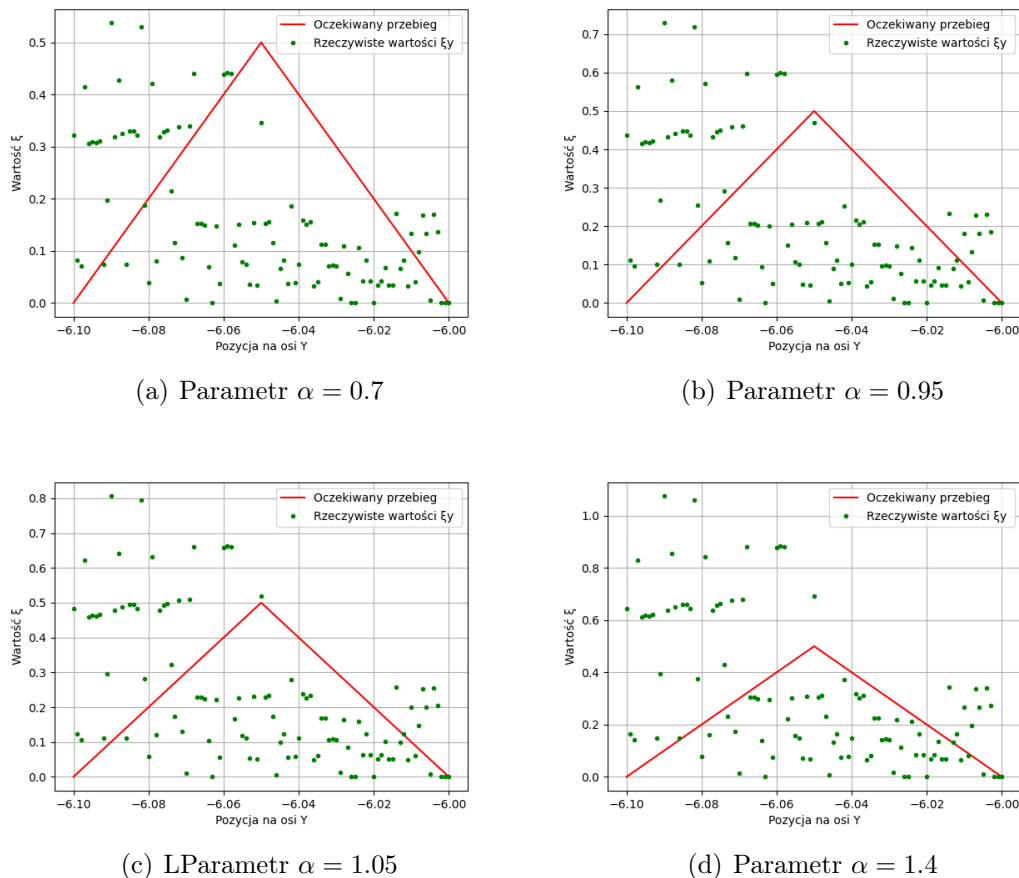
(c) Parametr $\alpha = 1.05$



(d) Parametr $\alpha = 1.4$

Rysunek 4.9 Wpływ wartości parametru α na wartość parametru korekcji ξ dla osi X

Odpowiednio przeprowadzono badania wpływu zmiany parametru α na wartość parametru ξ względem osi Y. Uzyskane wyniki zostały przedstawione na rys. 4.10. Podobnie jak w przypadku badań w kierunku osi X, tak i tutaj wartości rzeczywiste ξ mają charakter losowy, a manipulacja wartością α ma wpływ jedynie na wartość maksymalną współczynnika korekcji.




Rysunek 4.10 Wpływ wartości parametru α na wartość parametru korekcji ξ dla osi Y


Analogicznie do badań przeprowadzonych dla metody histogramów zostały przeprowadzone testy zachowania parametru ξ na przekątnej jednej jednostki siatki mapy. Ponownie początek pomiaru przyjęto w punkcie $p_p = [6.3, -10.1]$, natomiast koniec dla współrzędnych $p_k = [6.4, -10.0]$. Rezultaty tego testu nie różnią się od tych uzyskanych podczas poprzednich badań modyfikacji tej metody. Rzeczywiste wartości współczynnika ξ przyjmują wartości losowe. Wraz ze wzrostem liczby sekcji wzrasta rozrzut wartości parametru korekcji. W żadnym ze zbadanych przypadków (rys.4.11) nie uzyskano wartości zbliżonych do przebiegu oczekiwanego.

W tabeli 4.6 zostały przedstawione statystyczne badania zaimplementowanej metody korekcji. Rezultaty przeprowadzonych testów zgodne są z przypuszczeniami opartymi na wynikach badań cząstkowych. Losowość wartości parametru korekcji w większości przypadków działają niekorzystnie na jakość estymacji położenia układu robotycznego lub nie wprowadzają znaczącej zmiany. Jedynym wyjątkiem są wyniki otrzymane dla $k = 100$. W tym przypadku średnia wartość błędu zmalała o około 4% wartości uzyskanej podejściem podstawowym.


Przyczyną otrzymanych wyników może być sposób wyliczania wektora cech, który nie zmienia się w sposób liniowy podobnie do metody histogramów. Inną przyczyną braku pozytywnych wyników badań tej metody może być sposób w jaki wymuszono zmianę pierwotnych danych pomiarowych poprzez wyliczenie minimum lokalnego (3.12).




(a) Liczba sekcji: 30



(b) Liczba sekcji: 50



(c) Liczba sekcji: 100



(d) Liczba sekcji: 200

Rysunek 4.11 Wpływ liczby sekcji na wartość parametru korekcji ξ

k	5	10	15	20	25	30	50	100
średnia	0.312	0.179	0.178	0.179	0.178	0.179	0.185	0.195
odchyl. std.	0.756	0.252	0.126	0.126	0.129	0.129	0.134	0.145
bł. min.	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
bł. maks.	6.988	7.033	0.631	0.891	0.892	0.899	0.899	1.071
mediana	0.174	0.161	0.161	0.159	0.159	0.155	0.159	0.167

Tabela 4.6 Błąd lokalizacji wyrażony w metrach – metoda rozkładu normalnego z wykorzystaniem punktów sąsiadujących

Rozdział 5

Podsumowanie

W pracy zostały zaimplementowane i porównane dwie metody lokalizacji robota mobilnego w zamkniętych pomieszczeniach z założeniem pełnej znajomości otoczenia robota. Jedno z podejść wykorzystywało reprezentację mapy przy pomocy histogramów, natomiast druga reprezentacja wykorzystywała rozkład normalny do budowy wektora cech. W ramach pracy został stworzony pakiet do oprogramowania ROS zawierający implementację wspomnianych algorytmów w postaci bibliotek, a także model robota w formacie URDF. Model układu robotycznego został wyposażony w skaner laserowy o zasięgu 10m oraz zakresie 360° w celu przeprowadzenia badań jakości zaimplementowanych metod. Zdecydowano się na wykorzystanie czujnika z 1000 próbek na cykl pomiarowy.

W celu określenia jakości działania zaimplementowanych algorytmów została wyznaczona próbka statystyczna składająca się z danych pobranych w wylosowanych punktach. Celem porównania algorytmów testy przeprowadzane były dla tej samej próbki danych.

Przeprowadzone testy lokalizacji przy pomocy metody histogramów pokazały, że ta reprezentacja mapy pozwala na skuteczną estymację położenia platformy mobilnej w zamkniętej przestrzeni. Taka reprezentacja danych, przy zastosowaniu histogramu o liczbie koszy równej 20, pozwala na 50-krotną kompresję wektora cech. Podczas budowania mapy o wysokiej rozdzielczości na dużym obszarze pozwala to na znaczne zmniejszenie złożoności pamięciowej algorytmu lokalizacji. Metoda ta w dużym stopniu zależy od własności wykorzystywanego czujnika laserowego. Liczba próbek z jednego pomiaru oraz maksymalny zasięg sensora są bezpośrednio skorelowane z jakością budowania histogramu. Kolejnym ważnym aspektem, który wpływa na jakość lokalizacji, jest rozdzielczość siatki z jakiej zbudowana jest mapa.

Otrzymane wyniki wskazują na wzrost jakości lokalizacji robota wraz ze zwiększeniem liczby koszy histogramu do liczby koszy wynoszącej około 30. Dla większych wartości nie zanotowano spadku wartości średniej błęd. W przypadku liczby koszy większej niż 150 odnotowano spadek jakości działania algorytmu.

Następnym etapem było przeprowadzenie testów jakości estymacji orientacji robota przy pomocy metody histogramów. Orientacja jest wyznaczana względem punktu wytypowanego podczas lokalizacji robota, dlatego jej dokładność jest mocno zależna od jakości wyznaczonej pozycji. Metoda ta pozwala na wyznaczenie orientacji z dokładnością większą od minimalnej określonej poprzez rozmiar wektora cech. Średnia błędów otrzymanych podczas badań malała wraz ze wzrostem liczby sektorów.

Następnie została zaimplementowana metoda korekcji lokalizacji. Podejście to zakładało wykorzystanie punktów sąsiadujących na mapie w celu korekcji estymacji położenia robota w przypadku, gdy robot znajduje się pomiędzy punktami pomiarowymi na mapie. Przeprowadzone testy jednostkowe dały rezultaty zgodne z założeniami. Jednak podczas

badania statystycznych na losowych punktach okazało się, że otrzymane wyniki nie różnią się od wyników dla podejścia podstawowego lub są one marginalnie lepsze. Wyjątkiem była lokalizacja robota dla reprezentacji histogramu przy pomocy 50 koszy. W tym wypadku uzyskano poprawę wyników względem bazowej wersji wykorzystywanej metody. Może to być spowodowane zależnością tej metody korekcji wyników od liczby koszy oraz zasięgu czujnika.

Testy przeprowadzone w celu określenia jakości działania metody rozkładu normalnego zostały przeprowadzone w analogiczny sposób. Wartości wyników otrzymane podczas testowania tej reprezentacji mapy były podobne do metody poprzedniej. W przypadku tego podejścia wartość średniej błędów przestała maleć dla liczby sekcji $k \geq 15$.

Estymacja orientacji metodą rozkładu normalnego również dała wyniki przybliżone do tych uzyskanych podczas badania metody histogramów. To podejście działa znacznie gorzej dla małych wartości liczby sekcji, porównując z taką samą liczbą koszy histogramu. Wraz ze wzrostem wielkości wektora cech różnice pomiędzy obiema metodami się niwelują.

Implementacja metody korekcji lokalizacji robota w tym przypadku nie powiodła się. Testy jednostkowe nie przyniosły oczekiwanych wyników. Konsekwencją tego było otrzymanie wyników gorszych podczas testów statystycznych. Powodem takich rezultatów może być sposób estymacji lokalizacji metodą rozkładu normalnego, który wymusza ingerencję w zestaw surowych danych z czujnika poprzez wyznaczenie lokalnego minimum. Innym powodem może być sam sposób budowania wektora cech poprzez wyliczanie $\mathcal{N}(\sigma, \mu)$, którego zmiana może nie przebiegać w sposób liniowy.

Jak wcześniej wspomniano wyniki otrzymane podczas testowania obu metod były do siebie zbliżone. Z tego wynika, że obie metody można wykorzystywać zamiennie. Wartości średniej błędów otrzymywane podczas lokalizacji metodą histogramów wynosiły około 95% wartości średniej błędów metody rozkładu normalnego. Ponadto reprezentacja metodą histogramów ma zawsze 2 razy mniejszy wymiar niż reprezentacja metodą rozkładu normalnego przy liczbie koszy równej liczbie sekcji. Metoda histogramów wykorzystuje wektor o wymiarze N =liczbie koszy, natomiast metoda rozkładu normalnego opisuje stan poprzez dwukolumnową macierz o liczbie wierszy K =liczbie sekcji. Dodatkowo lokalizacja metodą histogramów jest kompatybilna z wprowadzeniem korekcji, która nie przynosi poprawy wyników w przypadku metody rozkładu normalnego.

Estymacja orientacji w obu przypadkach jest tak samo efektywna. Jediną różnicą jest wymiarowość pamięciowa opisana wcześniej.

Przeprowadzone badania potwierdziły postawioną tezę pracy.

Badania dla dwóch omówionych wcześniej metod zostały wykonane z pominięciem aspektu przemieszczania się robota i lokalizacji w czasie rzeczywistym. Możliwe jest rozszerzenie omawianych metod poprzez zapamiętanie kolejnych wytypowanych punktów oraz zwiększenie w ten sposób dokładności lokalizacji w aktualnej chwili. Inną możliwością jest zwiększenie dokładności lokalizacji robota poprzez zastosowanie filtrów, na przykład filtrów opartych na roju cząstek, które pomogłyby wyeliminować grube błędy lokalizacji.

Planowane jest wykorzystanie obu metod do realizacji jednocześnie zadania mapowania oraz lokalizacji, które należą do rodziny metod SLAM (z ang. *Simultaneous localization and mapping*)[5]. Możliwe jest zrealizowanie scenariusza, w którym robot przemieszcza się z jednego pomieszczenia – w pełni znanego, do innego pomieszczenia – jeszcze nie eksplorowanego. W takim wypadku znana byłaby lokalizacja początkowa robota w nieznanym otoczeniu oraz wektor otrzymanych sterowań. Na podstawie tych danych oraz danych z czujnika reprezentowanych w odpowiedni sposób (histogramy lub rozkład normalny) dokonywane byłoby jednoczesne mapowanie nowej powierzchni oraz lokalizacja robota w czasie rzeczywistym.

Załącznik A

Do pracy załączono płytę DVD zawierającą w poszczególnych katalogach:

`/Praca_magisterska.pdf` — wersja cyfrowa pracy,

`/Kod_zrodlowy` — kod źródłowy pakietu ROS zawierający:

- klasę `mapping` – umożliwiającą mapowanie obszaru w środowisku Gazebo,
- klasę `Hist_localization` – zawierającą implementację metody histogramów oraz metody do jej obsługi,
- klasę `Probab_localization` – zawierającą implementację metody rozkładu normalnego oraz metody do jej obsługi,
- prosty model platformy mobilnej klasy (2,0) kompatybilnej z dostarczonymi bibliotekami.

Literatura

- [1] L. Banjanovic-Mehmedovic, E. Ivanjko, I. Petrovic. Histogram based mobile robot localization. *International Electrotechnical and Computer Science Conference*, strony 173–176, Portorož, Slovenia, 2005.
- [2] P. Biber, W. Strasser. The normal distributions transform: a new approach to laser scan matching. *IEEE/RSJ International Conference on Intelligent Robots and Systems*, strony 2743–2748, Las Vegas, Stany Zjednoczone, 2003.
- [3] L. Joseph, J. Cacace. *Mastering ROS for Robotics Programming - Second Edition: Design, build, and simulate complex robots using the Robot Operating System*. Packt Publishing, Birmingham, 2018.
- [4] A. Kelly. *Mobile Robotics: mathematic, models and methods*. Cambridge University Press, Cambridge, 2013.
- [5] A. Kudriashov, T. Buratowski, M. Giergiel, P. Małka. *SLAM Techniques Application for Mobile Robot in Rough Terrain*. Springer Cham, 2020.
- [6] M. Magnusson. *The Three-Dimensional Normal-Distributions Transform — an Efficient Representation for Registration, Surface Analysis, and Loop Detection*. Praca doktorska, Örebro University, 2009.
- [7] C. Olson. Probabilistic self-localization for mobile robots. *IEEE Transactions on Robotics and Automation*, strony 55–66, 2000.
- [8] B. Siciliano, O. Khatib. *Springer Handbook of Robotics*. Springer Berlin, Heidelberg, 1993.
- [9] M. Tarhunakov. Mapa histogramów w lokalizacji robota mobilnego. Praca magisterska, Politechnika Wrocławska, 2022.
- [10] D. Tola, P. Corke. Understanding URDF: A Survey Based on User Experience. *ArXiv*, abs/2302.13442, 2023.