



POLITECHNIKA ŚLĄSKA
WYDZIAŁ AUTOMATYKI, ELEKTRONIKI I INFORMATYKI
DYSCYPLINA NAUKOWA
INFORMATYKA TECHNICZNA I TELEKOMUNIKACJA

Rozprawa doktorska

**Metody wspomagające precyzję dokowania
systemów AGV do stanowiska montażowego**

Autor: mgr inż. Piotr Biernacki

Promotor: dr hab. inż. Adam Ziębiński, Prof. PŚ

Gliwice, 2025

*Dla mej opoki
najbliższych memu sercu
za ogrom ciepła*

Streszczenie

Celem pracy było opracowanie metod zwiększających precyzję dokowania systemów AGV do wymaganego punktu dla danego stanowiska montażowego. Praca była realizowana w ramach projektu międzynarodowego o akronimie CoBotAGV, którego celem było zintegrowanie systemów AGV z robotami współpracującymi i umożliwienie ich relokacji między stanowiskami montażowymi przy zapewnieniu dokładnego i powtarzalnego dokowania.

Rozwiązanie opracowane w ramach pracy doktorskiej przeznaczone jest do zastosowań w warunkach przemysłowych, przy wykorzystaniu wyłącznie zasobów pokładowych AGV, przede wszystkim LiDAR-ów 2D oraz odometrii - bez potrzeby rozbudowywania systemu AGV o kolejne podsystemy percepcji. Założeniem zarówno projektu, jak i pracy doktorskiej, było osiągnięcie wysokiej dokładności dokowania przy jednoczesnym zachowaniu elastyczności procesów produkcyjnych, zgodnie z założeniami Przemysłu 4.0.

Dodatkowym wyzwaniem, wynikającym z założeń projektu CoBotAGV był brak możliwości budowy i wykorzystania mapy środowiska.

W odpowiedzi na postawione wyzwania zaproponowano zestaw metod zapewniających poprawę dokładności oraz precyzji poprzez odpowiednio kalibrację i filtrację pomiarów dostarczanych przez podsystemy AGV. Opracowano nowatorski system pozycjonowania względem stanowiska montażowego na bazie refleksyjnego znacznika przestrzennego wykrywanego i identyfikowanego za pomocą LiDAR-u 2D. Wszystkie opracowane metody zostały zintegrowane w spójny system realizujący dokowanie oraz weryfikację pozycji AGV po zadokowaniu na bazie skalibrowanych danych pomiarowych.

W ramach pracy doktorskiej przeanalizowano charakterystyki pomiarowe czujników odległości oraz odometrii, a następnie opracowano i zweryfikowano metody ich poprawy. Autorska metoda adaptacyjnej kalibracji czujników odległości (ACM) zredukowała błędy pomiarowe nawet o 79%, a metoda adaptacyjnej kalibracji z filtracją medianową (MSCwMF) dodatkowo poprawiła precyzję pomiarów odległości poprzez skuteczniejsze tłumienie szumów. Opracowano także metodę kalibracji odometrii w ruchu obrotowym (2DLAT), wykorzystującą dane ze skalibrowanego LiDAR-u 2D w celu ograniczania kumulacji błędów systematycznych odometrii. Oceniono i zastosowano metody filtracji za pomocą średniej ruchomej oraz filtracji medianowej, uzyskując znaczne obniżenie odchylenia standardowego pomiarów odległości z LiDAR-ów 2D. Opracowane zostały również metody kalibracji czujników odległości wykorzystujące techniki uczenia maszynowego (NC oraz RC), które pozwoliły obniżyć błędy pomiarowe poniżej poziomu 1 mm.

Kluczowym dla procedury dokowania, nowatorskim elementem pracy doktorskiej jest znacznik przestrzenny z kodami refleksyjnymi (2DM-RC) oraz metoda jego detekcji i identyfikacji na podstawie danych z LiDAR-u 2D, uwzględniająca zarówno pomiary odległości, jak i intensywność odbitych wiązek laserowych. Dzięki refleksyjnej strukturze na segmentach znacznika, stanowiącej "kod" binarny możliwe jest równoczesne rozpoznanie elementów stanowiska montażowego oraz dokładne wyzna-

czenie jego pozycji i orientacji względem AGV. Pozwala to na bieżącą rekaliibrację trajektorii dokowania i kompensację dryfu odometrii.

Wszystkie opracowane komponenty zintegrowano w systemie dokowania opartym na systemie ROS (Robot Operating System), obejmującym węzły oprogramowania służące do komunikacji z jednostką przetwarzającą systemu AGV, kalibracji i filtracji pomiarów odległości, kalibracji odometrii, detekcji i identyfikacji znacznika 2DM-RC, nawigacji, dokowania oraz automatycznej weryfikacji pozycji po zadokowaniu. System przetestowano eksperymentalnie na prototypowej platformie "Formica 3" firmy AIUT. Badania wykazały, że kalibracja czujników odległości oraz odometrii wyraźnie zwiększa dokładność osiąganego punktu; ciągła rekaliibracja względem znaczników 2DM-RC skutecznie niweluje skumulowany błąd odometrii; procedura weryfikacji po zadokowaniu umożliwia określenie dokładnej pozycji i orientacji AGV względem stanowiska montażowego oraz wyznaczenie wartości korekt niezbędnych dla dalszych operacji robota współpracującego.

Osiągnięte wyniki potwierdzają wszystkie tezy pracy: kalibracja podnosi dokładność pomiarów, filtracja zwiększa ich precyzję, zastosowanie znacznika przestrzennego umożliwia dokładne pozycjonowanie stanowiska montażowego, a redukcja błędów pomiarowych przekłada się na wzrost dokładności dokowania. Oryginalny wkład w dziedzinę informatyki technicznej i telekomunikacji obejmuje: metody kalibracji ACM, MSCwMF, NC, RC dla czujników odległości, metodę kalibracji odometrii w ruchu obrotowym 2DLAT oraz refleksyjny znacznik przestrzenny 2DM-RC wraz z algorytmami detekcji i identyfikacji.

W rezultacie powstał kompletny łańcuch przetwarzania danych, który umożliwia dokładne i powtarzalne dokowanie AGV do stanowiska montażowego w zmiennych warunkach przemysłowych, wzmacniając zarazem implementację koncepcji Przemysłu 4.0.

Abstract

The aim of the dissertation was to develop methods for increasing the precision of AGV docking to a required point of a given assembly station. The work was carried out as part of the international project CoBotAGV, whose objective was to integrate AGV systems with collaborative robots and to enable their relocation between assembly stations while ensuring accurate and repeatable docking.

The solution developed within the doctoral dissertation is intended for industrial applications, using only the onboard resources of the AGV, primarily 2D LiDARs and odometry - without the need to expand the AGV system with additional perception subsystems. The objective of both the project and the doctoral research was to achieve high docking accuracy while maintaining the process flexibility required by the Industry 4.0 concept.

An additional challenge, arising from the CoBotAGV project requirements, was the lack of possibility to build and use an environmental map.

In response to the challenges posed, a set of methods was proposed to improve accuracy and precision through calibration and filtering of measurements provided by the AGV subsystems. An innovative positioning system was developed for determining the AGV's position relative to the assembly station, based on a reflective spatial marker detected and identified by a 2D LiDAR. All developed methods were integrated into a coherent system executing docking and verifying the AGV's position after docking, based on calibrated measurement data.

Within the doctoral work, the measurement characteristics of distance sensors and odometry were analysed, and methods for their improvement were developed and validated. The proprietary Adaptive Calibration Method (ACM) for distance sensors reduced measurement errors by up to 79%, while the Adaptive Calibration with Median Filtering method (MSCwMF) further improved distance measurement precision by more effective noise suppression. A rotational odometry calibration method (2DLAT) was also developed, using data from a calibrated 2D LiDAR to limit the accumulation of systematic odometry errors. Filtering methods based on moving average and median filters were assessed and applied, resulting in a significant reduction of the standard deviation of distance measurements from 2D LiDARs. In addition, calibration methods for distance sensors using machine learning techniques (NC and RC) were developed, reducing measurement errors to below 1 mm.

A key innovative element of the docking procedure developed in this dissertation is the 2D marker with reflective codes (2DM-RC) and its detection and identification method, based on 2D LiDAR data, taking into account both distance measurements and the intensity of reflected laser beams. Thanks to the reflective structure of the marker segments, which forms a binary "code", it is possible to simultaneously recognise elements of the assembly station and accurately determine its position and orientation relative to the AGV. This enables continuous recalibration of the docking trajectory and compensation of odometry drift.

All developed components were integrated into a docking system based on the Robot Operating System (ROS), including software nodes for communication with

the AGV's processing unit, calibration and filtering of distance measurements, odometry calibration, 2DM-RC marker detection and identification, navigation, docking, and automatic verification of the AGV's position after docking. The system was experimentally tested on the "Formica 3" prototype platform by AIUT. The tests showed that calibration of distance sensors and odometry clearly increases the accuracy of the achieved docking point; continuous recalibration relative to 2DM-RC markers effectively eliminates accumulated odometry errors; and the post-docking verification procedure makes it possible to determine the precise position and orientation of the AGV relative to the assembly station and to calculate correction values required for further operations of the collaborative robot.

The achieved results confirm all the theses of the work: calibration increases measurement accuracy, filtering improves measurement precision, the use of a spatial marker enables accurate positioning of the assembly station, and the reduction of measurement errors translates into improved docking accuracy. The original contribution to the field of technical computer science and telecommunications includes: the ACM, MSCwMF, NC, and RC calibration methods for distance sensors, the 2DLAT rotational odometry calibration method, and the reflective spatial marker 2DM-RC with its detection and identification algorithms.

As a result, a complete data processing chain has been created, enabling accurate and repeatable AGV docking to an assembly station in variable industrial conditions and supporting the implementation of the Industry 4.0 concept.

Spis treści

1	Wstęp	1
2	Analiza zagadnienia	5
2.1	Kalibracja czujników odległości	5
2.1.1	Kalibracja ultradźwiękowych czujników odległości	6
2.1.2	Kalibracja czujników odległości typu LiDAR 2D	7
2.2	Filtracja czujników odległości	9
2.3	Kalibracja odometrii	11
2.4	Systemy pozycjonowania w procesie dokowania	13
3	Właściwości czujników odległości	19
3.1	Czujniki odległości	19
3.1.1	Laserowe czujniki odległości – Light Detection and Ranging (LiDAR)	19
3.1.2	Podsumowanie najważniejszych właściwości pomiarowych czujników odległości typu LiDAR	24
3.1.3	Ultradźwiękowe czujniki odległości	24
3.1.4	Podsumowanie najważniejszych właściwości pomiarowych ultradźwiękowych czujników odległości	26
3.2	Badanie charakterystyki czujników odległości	26
3.2.1	Podsumowanie dokładności oraz precyzji zbadanych czujników odległości	36
4	Kalibracja czujników odległości	39
4.1	Metody kalibracji statystycznej	39
4.1.1	Kalibracja jednosekcyjna	40
4.1.2	Adaptacyjna kalibracja	40
4.1.3	Adaptacyjna kalibracja z filtracją	41
4.1.4	Implementacja metod kalibracji	42
4.1.5	Przykłady wykorzystania metody kalibracji jednosekcyjnej	44
4.1.6	Przykłady wykorzystania metody kalibracji adaptacyjnej	56
4.1.7	Przykłady wykorzystania metody kalibracji adaptacyjnej z filtracją	61
4.2	Metody kalibracji z wykorzystaniem uczenia maszynowego	69
4.2.1	Kalibracja naturalna	71
4.2.2	Kalibracja resztowa	72
4.2.3	Przykłady wykorzystania metod kalibracji z użyciem uczenia maszynowego	72

5	Filtracja pomiarów odległości	77
5.1	Filtracja za pomocą średniej ruchomej	77
5.2	Filtracja medianowa	78
5.3	Podsumowanie badań wpływu metod filtracji na pomiary odległości .	78
5.3.1	Filtracja za pomocą średniej ruchomej	78
5.3.2	Filtracja medianowa	79
6	Kalibracja odometrii	85
6.1	Metoda sprawdzająca jakość odometrii w ruchu liniowym	86
6.2	Metoda sprawdzająca jakość odometrii w ruchu obrotowym	87
6.3	Wyniki badań jakości odometrii	89
6.4	Wprowadzenie korekty odometrii	94
7	Refleksyjny znacznik przestrzenny	97
7.1	Metoda detekcji i identyfikacji refleksyjnego znacznika przestrzennego przy użyciu LiDAR-u 2D	98
7.2	Metoda obliczania pozycji i orientacji punktu dokowania	104
7.3	Ocena jakości detekcji refleksyjnego znacznika przestrzennego	105
8	Architektura systemu kontroli oraz akwizycji danych. Integracja z platformą mobilną	107
8.1	Robot Operating System	108
8.1.1	Mapa węzłów w sieci ROS	109
8.2	Akwizycja danych i sposób kontroli	112
8.2.1	Dane odbierane z AGV	113
8.2.2	Dane przesyłane do PLC	115
9	Dokowanie platformy mobilnej	119
9.1	Metoda weryfikacji służąca estymacji względnej pozycji pomiędzy AGV a AS	120
9.2	Eksperymenty badające jakość dokowania AGV	123
9.3	Podsumowanie jakości dokowania AGV	127
9.4	Wnioski z przeprowadzonych badań dokowania	130
10	Podsumowanie	133
	Bibliografia	137
A	Symbole i skróty przyjęte w pracy	155
B	Spis publikacji i patentów	157
C	Wyniki kalibracji pomiarów odległości przy użyciu ML	159

Rozdział 1

Wstęp

Współczesne zakłady produkcyjne stają przed koniecznością szybkiej adaptacji procesów wytwórczych do dynamicznie zmieniających się warunków rynkowych. W dobie globalnej konkurencji, klienci stawiają przed producentami coraz wyższe wymagania w zakresie elastyczności, różnorodności produktów i skracania cykli produkcyjnych. Aby sprostać tym oczekiwaniom, przedsiębiorstwa coraz częściej wdrażają rozwiązania z obszaru automatyzacji i robotyzacji procesów wewnętrznej logistyki. Jednym z kluczowych elementów tych rozwiązań są mobilne platformy transportowe, w tym AGV (Automated Guided Vehicles), przemieszczające się w obrębie zakładów produkcyjnych i logistycznych.

Skuteczna współpraca systemu AGV z innymi elementami środowiska wymaga precyzyjnego i powtarzalnego dokowania do ściśle określonej pozycji względem stanowiska montażowego, punktów załadunku, robotów kolaboracyjnych, punktu ładowania czy stref buforowych. Osiągnięcie wysokiej dokładności dokowania na poziomie centymetrowym stanowi istotne wyzwanie, obejmujące zarówno kwestie konstrukcyjne i pomiarowe, jak i kwestie sterowania oraz integracji czujników stanowiących system percepcji.

Brak dokładności podczas wykonywania czynności logistycznych w zakładach produkcyjnych prowadzi do awarii, uszkodzeń systemów AGV, przestojów oraz zakłóceń płynności procesów produkcyjnych, co stanowi realny koszt dla systemów przemysłowych i istotny problem we wdrażaniu Przemysłu 4.0.

Dokowanie następuje na końcowym etapie przejazdu platformy mobilnej do wskazanego punktu i zazwyczaj wymaga użycia dodatkowych czujników lub znaczników, ponieważ sama nawigacja naturalna wykorzystująca zamontowane na AGV czujniki oraz wcześniej utworzoną mapę środowiska z reguły nie zapewnia wystarczającej dokładności w dynamicznym otoczeniu.

Obecnie najczęściej stosowane metody zapewnienia precyzji dokowania systemów AGV opierają się na wykorzystaniu dodatkowych elementów infrastruktury technicznej takich jak elementy odblaskowe dla skanerów laserowych, wizualne znaczniki odniesienia (kody QR, znaczniki ArUco/AprilTag) dla kamer lub fizyczne elementy przestrzenne montowane na podłożu hali. Rozwiązania te borykają się jednak z istotnymi problemami w postaci warunków oświetlenia (nasłonecznienie, zaciemnienie), które potrafią zakłócać systemy wizyjne. Ponadto cechy stosowanych znaczników muszą być odróżnialne od otoczenia, w przeciwnym razie systemy rozpoznawania zaimplementowane w AGV mogą pomylić znacznik z elementami tła. Metody te są podatne na takie pomyłki, szczególnie w przypadku gdy elementy otoczenia mają podobny kształt lub właściwości odbicia jak znacznik.

Dostępne są również takie rozwiązania jak taśmy magnetyczne, znaczniki RFI-


D/NFC czy aktywne beacons w postaci diod podczerwieni lub ultradźwięków odbieranych przez system AGV. Choć rozwiązania te pozwalają osiągnąć wysoki poziom dokładności, to ich istotnym ograniczeniem jest konieczność ingerencji w przestrzeń produkcyjną oraz ograniczenie elastyczności przebiegu procesów. Każda zmiana lokalizacji punktu dokowania lub rekonfiguracja linii produkcyjnej wymaga kosztownej i czasochłonnej modyfikacji infrastruktury technicznej, co jest niezgodne z założeniami Przemysłu 4.0, w którym elastyczność, skalowalność i możliwość szybkiej adaptacji są fundamentalnymi wymaganiami.

W związku z powyższym pojawił się problem badawczy, polegający na konieczności opracowania metod, które zapewnią wysoką precyzję oraz dokładność lokalizacji i dokowania bez konieczności modyfikowania systemów AGV oraz montażu trudno modyfikowalnych elementów infrastruktury w środowisku hali produkcyjnej. Celem było wykorzystanie wyłącznie tych zasobów, które są już dostępne na pokładzie AGV, w tym przede wszystkim, obecnie najczęściej stosowanych, czujników LiDAR 2D, enkoderów kół jezdnych oraz opracowanie sposobów ich efektywnego wykorzystania do dokładnego i powtarzalnego pozycjonowania w trakcie dokowania.

Tematyka realizowanej pracy doktorskiej dotyczy opracowania metod wspomagających precyzję dokowania systemu AGV do stanowiska montażowego. Termin precyzji w temacie pracy rozumiany jest jako powtarzalność procedur dokowania i dokładności względem określonego punktu referencyjnego. Badania w pracy doktorskiej były wykonywane w ramach międzynarodowego projektu “Automated Guided Vehicles integrated with Collaborative Robots for Smart Industry Perspective” o akronimie CoBotAGV, którego celem było stworzenie zaawansowanego rozwiązania logistyki wewnętrznej, umożliwiającego elastyczne i precyzyjne przemieszczanie robotów kolaboracyjnych pomiędzy stanowiskami montażowymi przy wykorzystaniu autonomicznych systemów AGV. Sam transport robota kolaboracyjnego do kolejnych stanowisk nie jest jednak wystarczający. Konieczne było zapewnienie jego dokładnego dokowania oraz precyzyjnej rekalkulacji na nowym stanowisku, tak by mógł natychmiast rozpocząć pracę z wymaganą dokładnością.

Dlatego też jednym z celów projektu CoBotAGV było zwiększenie precyzji dokowania platformy mobilnej wyposażonej w ramię robota kolaboracyjnego do stanowiska montażowego (rys. 1.1). Problem badawczy wraz z założeniami dotyczącymi procedury dokowania oraz ograniczeniami co do zestawu dostępnych czujników zostały zdefiniowane w ramach pierwszego pakietu badawczego “WP1 - CoBotAGV - pojazd autonomiczny zintegrowany z robotem współpracującym”. W szczególności dotyczy to zadań związanych z integracją pomiędzy AGV a robotem współpracującym oraz opracowaniem metod precyzyjnego dokowania AGV do stanowiska montażowego oraz rekalkulacji systemu odniesienia mobilnego robota kolaboracyjnego względem stanowiska montażowego.

Procedura dokowania jest na tyle dokładna i precyzyjna, na ile pozwalają dane pomiarowe dostarczane przez czujniki, w które wyposażony jest AGV. Kluczowe znaczenie dla dokładności oraz precyzji dokowania mają jakość odometrii obliczanej na podstawie danych z enkoderów oraz jakość pomiarów z czujników odległości, w szczególności typu LiDAR 2D, a także interpretacja tych danych w kontekście zmiennych warunków środowiskowych i dynamicznego charakteru procesów przemysłowych. Ograniczenia nakładane przez projekt CoBotAGV, polegające na braku możliwości utworzenia mapy środowiska i wykorzystania jej w celu pozycjonowania systemu AGV oraz konieczność wykorzystania wyłącznie podsystemów, w które system AGV już jest wyposażony, stanowią dodatkowe wyzwania. Powstała zatem potrzeba opracowania systemu pozycjonowania w postaci znacznika, wykorzystu-



Rysunek 1.1: AGV Formica 3 wraz z ramieniem robota kolaboracyjnego (a). Wizualizacja platformy CoBotAGV dokującej do stanowiska montażowego (b).

jącego jedynie dane pomiarowe LiDAR-u 2D oraz odometrii, w celu wyznaczenia pozycji oraz orientacji stanowiska montażowego względem systemu AGV.

Uwzględniając wszystkie powyższe wymagania oraz ograniczenia, przyjęto w ramach pracy doktorskiej kompleksowe podejście, którego celem było **opracowanie metod wpływających na zwiększenie precyzji dokowania systemów AGV do wymaganego punktu dla danego stanowiska montażowego, poprzez zwiększenie precyzji i dokładności podsystemów pomiarowych oraz zastosowanie metody pozycjonowania na bazie znacznika przestrzennego.**

W ramach pracy doktorskiej zdefiniowano następujące tezy:

1. Zastosowanie metod kalibracji pozwala na zwiększenie dokładności pomiarów z czujników.
2. Zastosowanie metod filtracji pozwala na zwiększenie precyzji pomiarów z czujników.
3. Zastosowanie znacznika przestrzennego pozwala na dokładne pozycjonowanie stanowiska montażowego.
4. Zastosowanie metod zmniejszających błędy pomiarowe zwiększa dokładność dokowania.

Przyjęto następującą strukturę rozprawy doktorskiej. Rozdział 2 zawiera przegląd literatury dotyczącej poruszanych w niniejszej pracy zagadnień. W kolejnych rozdziałach przedstawione zostały wyniki własnych badań oraz opracowane metody.

W ramach realizacji pracy doktorskiej wykonano szereg badań sprawdzających charakterystykę pomiarową czujników odległości (rozdział 3).


Opracowano metody kalibracji pomiarów odległości dla badanych czujników odległości w celu poprawy ich dokładności pomiarowej (rozdział 4).

Przeprowadzono badania metod filtracji odpowiednich dla pomiarów odległości z LiDAR-ów 2D w celu poprawy ich precyzji pomiarowej (rozdział 5).

Przeprowadzono również badania mające na celu sprawdzenie jakości danych odometrycznych dostarczanych przez AGV oraz opracowano metody ich kalibracji (rozdział 6).

Ponadto opracowano nowatorski znacznik przestrzenny z elementami odblaskowymi oraz metodę jego lokalizacji i identyfikacji. W zaproponowanym rozwiązaniu wykorzystano fakt, że nowoczesne LiDAR-y 2D oprócz pomiarów odległości dostarczają również informację o sile odbitej wiązki laserowej, co pozwala odróżnić powierzchnie wyposażone w elementy refleksyjne. Zastosowanie opracowanego znacznika przestrzennego z elementami odblaskowymi oraz metody jego detekcji i rozpoznawania pozwala zarówno na dokładną lokalizację AGV względem stanowiska montażowego (z ang. Assembly Station), jak i identyfikację poszczególnych elementów AS wyposażonych w opracowany znacznik oraz określenie pozycji i orientacji punktu dokowania (rozdział 7).

Zaprojektowano niezależny sprzętowo system akwizycji danych i kontroli platformy mobilnej, w którym zintegrowano wszystkie metody opracowane w ramach pracy doktorskiej. System ten, bazując na danych dostarczanych przez platformę mobilną, przeprowadza ich filtrację, kalibrację oraz analizę otrzymanych danych pomiarowych (rozdział 8). Wynikiem przeprowadzonej analizy jest określenie względnej pozycji i orientacji stanowiska montażowego, wyznaczenie punktu dokowania, wykonanie procedury dokowania oraz automatyczna weryfikacja pozycji AGV po zadokowaniu do AS w celu wyznaczenia ostatecznej dokładności dokowania (rys. 1.2).



Rysunek 1.2: Uproszczony schemat przepływu danych z AGV do opracowanego systemu dokowania do stanowiska montażowego.

Zintegrowany system dokowania wraz opracowanymi metodami został poddany testom eksperymentalnym podczas szeregu procedur dokowania prototypową platformą mobilną typu AGV (Formica 3 firmy AIUT) do stanowiska montażowego poprzez manualną i automatyczną weryfikację osiągnięcia zadanego punktu dokowania (rozdział 9). Przeprowadzone badania pozwoliły na pomiar wpływu poszczególnych metod na ostateczną dokładność oraz precyzję dokowania, jak i opracowanie wyników dokowania opisanych w pracy doktorskiej i wykorzystanych w projekcie CoBotAGV.

Wyniki otrzymane podczas szczegółowej analizy opracowanych metod oraz badań dokowania platformy mobilnej do stanowiska montażowego pozwoliły na zweryfikowanie, czy metody opracowane w ramach pracy doktorskiej potwierdzają postawione tezy oraz spełniają założenia w ramach projektu CoBotAGV (rozdział 10).

Rozdział 2

Analiza zagadnienia

W dobie Przemysłu 4.0 rośnie zapotrzebowanie na elastyczne linie produkcyjne i autonomiczne systemy, zdolne do szybkiego dostosowywania się do zmiennego środowiska produkcyjnego. Coraz częściej w halach produkcyjnych stosuje się autonomiczne platformy mobilne, od klasycznych pojazdów AGV (Automated Guided Vehicles) po bardziej inteligentne roboty AMR (Autonomous Mobile Robots), które potrafią samodzielnie transportować materiały pomiędzy stanowiskami pracy z wysoką precyzją [97]. Zapewnienie wysokiej precyzji działań jest kluczowe m.in. przy zadaniach dokowania do stanowisk montażowych lub stacji przeładunkowych. Dokładność dokowania AGV/AMR ma bezpośredni wpływ na płynność procesu produkcyjnego. Nawet drobne błędy pozycji mogą skutkować problemami w przekazywaniu ładunku, opóźnieniami lub koniecznością interwencji operatora [50]. W konsekwencji precyzyjne pozycjonowanie pojazdów mobilnych stało się jednym z kluczowych wymagań nowoczesnych systemów produkcyjnych.

Dokowanie mobilnej platformy można zdefiniować jako proces jej pozycjonowania z wysoką dokładnością względem wyznaczonego punktu lub obiektu tj. stanowiska montażowego, przenośnika, regału czy stacji ładowania. Pojazd musi osiągnąć zadaną pozycję i orientację z minimalnym błędem, zazwyczaj z dokładnością do pojedynczych centymetrów lub większą, aby możliwe było np. automatyczne przekazanie ładunku lub rozpoczęcie procesu ładowania systemu AGV. Problematyka ta jest intensywnie badana przez naukowców. Zaproponowano liczne podejścia wykorzystujące różnego typu czujniki oraz metody ich kalibracji oraz filtracji, jak i znaczniki umieszczone w środowisku systemu AGV, mające na celu zminimalizowanie błędu pozycji i orientacji przy dojeżdżaniu do celu. Poniżej omówiono najczęściej stosowane metody oraz czujniki wpływające na zwiększenie precyzji dokowania przemysłowych systemów AGV do stanowisk montażowych.

2.1 Kalibracja czujników odległości

Jednym z kluczowych elementów wpływających na precyzję dokowania jest dokładność pomiarów odległości wykonywanych przez czujniki odległości będące jednymi z podsystemów AGV. W praktyce AGV są wyposażane w czujniki odległości różnego typu: LiDAR 2D (skanery laserowe) służące do skanowania otoczenia i lokalizacji względnej, czujniki ultradźwiękowe służące do wykrywania przeszkód lub czujniki wizyjne. Każda z tych technologii obciążona jest pewnymi błędami pomiarowymi, zarówno systematycznymi (np. błąd stały, nieliniowość charakterystyki pomiarowej), jak i losowymi (szum pomiarowy, fluktuacje). Aby uzyskać jak największą dokładność dokowania, niezbędne jest skalibrowanie czujników pomiarowych

tak, by ich pomiary w jak największym stopniu odzwierciedlały rzeczywistość. Kalibracja czujników odległości jest więc krokiem poprzedzającym dokładną lokalizację. Sterowanie systemem AGV przy użyciu nieskalibrowanych czujników tak by osiągnąć żądany punkt z dużą precyzją jest trudne [5]. Poniżej przeanalizowano dwie główne klasy czujników odległości stosowanych w AGV (ultradźwiękowe i laserowe) pod kątem ich kalibracji i metod poprawy dokładności pomiarów opierając się na badaniach opisanych w literaturze.

2.1.1 Kalibracja ultradźwiękowych czujników odległości

Czujniki ultradźwiękowe należą do najdłużej stosowanych w robotyce mobilnej podsystemów do pomiaru odległości. Ich popularność wynika z niskiej ceny, prostoty i niezawodności w typowych zastosowaniach wykrywania przeszkód. Działają one na zasadzie pomiaru czasu przelotu fali akustycznej w powietrzu - emitowana jest krótka fala ultradźwiękowa, która odbija się od przeszkody i powraca do odbiornika. Znając prędkość dźwięku oraz na podstawie zmierzonego czasu Δt obliczana jest odległość d wg zależności $d = c \cdot \Delta t / 2$ w przypadku pomiaru dwukierunkowego. Czujniki ultradźwiękowe cechują się wieloma ograniczeniami: stosunkowo wąskim pasmem przenoszenia (co wpływa na rozdzielczość pomiaru), szerokim kątem wiązki (skutkującym niejednoznacznościami przy pomiarze odległości do małych obiektów), a przede wszystkim nieliniową charakterystyką i zmiennością w warunkach rzeczywistych. W literaturze podkreśla się, że surowe wskazania tanich dalmierzów ultradźwiękowych są obarczone znacznym błędem. Często dopiero zastosowanie odpowiedniej kalibracji i obróbki sygnału pozwala uzyskać użyteczną dokładność [7]. Paunović i in. [75] zauważają, że ze względu na nieliniowość charakterystyki pomiarowej, konieczne jest staranne skalibrowanie każdego czujnika ultradźwiękowego, aby zapewnić wiarygodne odczyty odległości. Czujniki te wymagają indywidualnej kalibracji, gdyż fabryczne parametry mogą nie gwarantować dostatecznej dokładności w całym zakresie pomiarowym.

Do głównych źródeł błędów w pomiarach ultradźwiękowych należą:

- błąd stały i nieliniowość – wiele tanich czujników ma pewne opóźnienie sprzętowe i przetwarzania, skutkujące stałym dodatnim błędem (odczytana minimalna odległość jest większa niż rzeczywista) oraz ewentualną nieliniowość zwiększającą się wraz z odległością,
- zmienność prędkości dźwięku – zależna głównie od temperatury powietrza (oraz w mniejszym stopniu od wilgotności i ciśnienia),
- szумы i fluktuacje odbiornika – sygnał echa może mieć różną amplitudę i kształt w zależności od powierzchni obiektu, co wpływa na moment detekcji,
- pole widzenia i efekty krawędziowe – jeśli obiekt znajduje się na obrzeżu wiązki, odbierany sygnał jest słabszy, co może opóźnić detekcję lub całkowicie ją utrudnić.

Naturalnym podejściem kalibracyjnym jest wykorzystanie pomiarów referencyjnych, gdzie dla danego czujnika poddawanego kalibracji dokonuje się serii pomiarów odległości do płaskiej przeszkody ustawionej w różnych znanych odległościach (np. co 10 cm w zakresie roboczym czujnika) i przy różnych orientacjach względem przeszkody. Na tej podstawie można wyznaczyć charakterystykę pomiarową czujnika i dopasować funkcję korekcyjną. Paunović i in. opisują procedurę kalibracji pięciu

czujników ultradźwiękowych SRM400, polegającą na pomiarach odległości do płaskiego obiektu w 10 różnych dystansach i pod 5 różnymi kątami względem osi czujnika [75]. Wynikiem takiej kalibracji była charakterystyka błędu w funkcji odległości. Badania wykazały znaczną nieliniowość pomiarową pomiędzy poszczególnymi egzemplarzami czujników, jak i systematyczne odchylenie od wartości rzeczywistej. Po kalibracji (uwzględnieniu indywidualnych poprawek dla każdego dalmierza) udało się znacznie poprawić spójność i dokładność odczytów. Wykresy błędu pokazały redukcję błędów systematycznych. Podobne wnioski przedstawili Noykov i Roumenin, którzy opracowali metodę kalibracji popularnego czujnika Polaroid 6500 na potrzeby robotów mobilnych [62].

Kolejnym istotnym aspektem jest kompensacja wpływu temperatury na pomiar. Prędkość dźwięku w powietrzu c zmienia się wraz z temperaturą o $\approx 0,6$ m/s na każdy 1°C zmiany (w zakresie temperatur pokojowych), zgodnie z zależnością $c(T) \approx 331,2 + 0,6T$ (m/s) [7]. Oznacza to, że wzrost temperatury o 5°C powoduje, że w ciągu 1 ms dźwięk pokona dystans o kilka milimetrów większy. Jeżeli system pomiarowy nie uwzględni tej zmiany, pojawi się systematyczny błąd dystansu. Dlatego w zastosowaniach wymagających wysokiej dokładności stosuje się kompensację temperaturową – czujnik temperatury mierzy bieżące warunki, a oprogramowanie odpowiednio koryguje przyjętą prędkość dźwięku. Aliew [7] opisuje układ dalmierza ultradźwiękowego wykorzystujący czujnik temperatury o dokładności $0,5^\circ\text{C}$ oraz 16-bitowy timer do pomiaru ToF, co umożliwiło uzyskanie rozdzielczości poniżej 0,02 mm w pomiarze odległości. Dzięki uwzględnieniu temperatury i zastosowaniu algorytmów filtrujących, udało się osiągnąć dokładność rzędu 0,4 mm przy wykorzystaniu taniego modułu ultradźwiękowego. Tak wysoka dokładność wymagała jednak zaawansowanego przetwarzania sygnału: autor porównał metody aproksymacji charakterystyki czujnika (metoda najmniejszych kwadratów, aproksymacja wielomianowa odcinkami, metoda Vandermonde’a) oraz wprowadził własny algorytm filtracji sygnału echa. Okazało się, że przeciętnie surowe odczyty wahały się w zakresie nawet ± 8 mm, natomiast po obróbce (uśrednianiu wielu próbek i kalibracji) błąd maksymalny zredukowano do poniżej 1 mm. Skutecznym okazało się zastosowanie uśredniania wielu pomiarów – badania wykazały, że rozkład szumu ultradźwiękowego jest zbliżony do normalnego, więc średnia z dostatecznie dużej liczby próbek odpowiada wartości rzeczywistej [7]. Aby uzyskać zadowalającą dokładność, Aliew uśredniał nawet 100 pomiarów. Oczywiście zwiększa to czas pomiaru, dlatego też poszukuje się kompromisu między szybkością a dokładnością.

Prawidłowo skalibrowane i przetworzone pomiary z czujników ultradźwiękowych mogą osiągać znacznie wyższą dokładność (rzędu pojedynczych milimetrów) niż deklarowana nominalnie [91]. Dzięki temu nadają się one do zastosowań wymagających precyzyjnego dokowania, choć w praktyce częściej pełnią rolę uzupełniającą w stosunku do LiDAR-ów czy systemów wizyjnych, ze względu na ograniczony zasięg i pole widzenia.

2.1.2 Kalibracja czujników odległości typu LiDAR 2D

Skanery laserowe 2D (LiDAR-y) stały się w ostatnich dekadach podstawowym czujnikiem nawigacyjnym platform mobilnych, w tym AGV. Typowy LiDAR 2D (skaner wirujący w płaszczyźnie poziomej) dostarcza informację o odległości do najbliższych obiektów w otoczeniu dla danego kąta, tworząc mapę punktów w układzie polarnym, tzw. chmurę punktów (ang. 2D LiDAR pointcloud). Przemysłowe LiDAR-y 2D oprócz pomiarów odległości dostarczają również pomiar siły odbitej

wiązki lasera. Dokładność pomiaru odległości w lidarach komercyjnych jest z reguły wyższa niż w czujnikach ultradźwiękowych. Wysokiej klasy czujniki laserowe mają nominalny błąd rzędu kilku centymetrów lub mniejszy [28] [19]. Niemniej jednak, jeśli celem jest precyzja dokowania rzędu 1 cm lub lepsza, konieczne bywa dodatkowe skalibrowanie i dopracowanie systemu LiDAR. Błędy pomiaru LiDAR-ów wynikają z kilku czynników:

- błędy wewnętrzne czujnika (ang. *intrinsic*) – błędna kalibracja czasu przelotu emitowanej wiązki laserowej (stały błąd czasowy) lub niedoskonałości elektroniki powodujące, że odległości systematycznie odbiegają od rzeczywistych,
- zależność błędu od odległości i refleksyjności – wiele LiDAR-ów wykazuje heteroskedastyczność błędu, tzn. wraz ze wzrostem dystansu wzrasta wariancja i możliwe odchylenie pomiaru od wartości referencyjnej [5], dodatkowo obiekty o niskiej refleksyjności (pochłaniające laser) mogą powodować niedoszacowanie odległości lub brak odczytu,
- szумы i interferencje – szum detektora, zakłócenia pochodzące od innych źródeł światła (np. bezpośrednie światło słoneczne), czy wielokrotne odbicia mogą wprowadzać losowe błędy,
- błędy instalacji (ang. *extrinsic*) – nieprawidłowe wypoziomowanie lub odchylenie czujnika względem płaszczyzny poziomej skutkuje zniekształceniem mapy otoczenia (np. skaner zamontowany pod kątem będzie mierzył odległość nie do punktów na wysokości czujnika, tylko wyżej/niżej).

Standardową metodą oceny dokładności LiDAR-u są pomiary kontrolne względem wzorca poprzez umieszczenie czujnika odległości w znanych pozycjach względem płaskich ścian czy obiektów i porównanie zmierzonych odległości z rzeczywistymi. Jeśli stwierdzony zostanie błąd stały lub nieliniowość pomiarowa, można wprowadzić odpowiednie poprawki do odczytów.

Alternatywą, zaproponowaną przez Alhashimi [5], jest kalibracja bez referencyjnego czujnika pomiarowego, wykorzystująca jedynie informacje ze skanera w kontrolowanym środowisku. W pracy Alhashimi przedstawiono metodę, w której LiDAR 2D jest kalibrowany poprzez obserwację zestawu nieruchomych obiektów w otoczeniu (np. słupków) pod różnymi kątami. Ponieważ obiekty te są stacjonarne, wzajemne odległości między nimi są stałe. Autorzy wykorzystali tę własność do sformułowania kryterium kalibracji - po skalibrowaniu czujnika, odległości i kąty między wykrywaniem punktami stałych obiektów powinny pozostać niezmiennie, niezależnie od pozycji czujnika. Kalibracja sprowadza się zatem do znalezienia takich parametrów modelu pomiarowego LiDAR-u 2D, aby obserwowane cechy otoczenia zachowywały zgodność geometryczną. Model pomiaru założony w pracy obejmował parametr korekty dodawany do prawdziwej odległości oraz parametr skalujący wariancję szumu (heteroskedastyczność). Rozwiązanie polegało na wyznaczeniu tych parametrów metodami statystycznymi, tak aby pomiary spełniały założenie stałości odległości pomiędzy obiektami statycznymi. Zaproponowano analityczne estymatory umożliwiające implementację również w systemach wbudowanych. Efektywność metody potwierdzono zarówno symulacyjnie, jak i eksperymentalnie. W testach osiągnięto aż dziesięciokrotną poprawę dokładności surowych pomiarów po zastosowaniu kalibracji względem niekalibrowanego czujnika.

Inną metodologią kalibracji wewnętrznej jest wykorzystanie fuzji czujników. Jeżeli platforma mobilna posiada więcej niż jeden czujnik odległości (np. dwa LiDAR-y, LiDAR i sonar, LiDAR i źródło odometrii), można przeprowadzić wzajemną kalibrację. Przykładowo, Alhashimi i in. w innej pracy [6] zastosowali strategię opartą na algorytmie EM (ang. Expectation-Maximization) do jednoczesnej estymacji parametrów kalibracyjnych i stanu platformy, integrując dane z LiDAR-u, odometrii oraz sonaru. Podobnie w podejściu Bayesowskim wykorzystano łańcuch Monte Carlo (MCMC) do kalibracji heteroskedastycznych czujników odległości [4].

Współczesne badania pokazują, że dzięki kalibracji można znacząco zwiększyć dokładność pomiarową skanerów laserowych 2D. Metody kalibracji bezwzorcowej, wykorzystujące struktury otoczenia, pozwalają skompensować nieliniowości LiDAR-u nawet bez kosztownego sprzętu dostarczającego pomiary referencyjne [5].

Odpowiednio skalibrowany LiDAR 2D jest w stanie dostarczać pomiary odległości nawet z dokładnością poniżej 1 cm. Jest to kluczowe dla zadań dokowania, gdzie dokładna informacja o odległości od stanowiska dokowania lub znaczników wpływa na błąd końcowy pozycji systemu AGV. Należy pamiętać, że osiągnięcie tak wysokiej dokładności i precyzji to efekt zarówno kalibracji jednorazowej (podczas wdrożenia systemu), jak i ciągłego korygowania pomiarów w czasie pracy, np. poprzez filtrowanie skanów LiDAR-owych.

Zapewnienie, że zarówno ultradźwiękowe, jak i laserowe czujniki odległości dostarczają możliwie dokładnych i precyzyjnych danych, stanowi podstawę osiągnięcia końcowego celu, jakim jest powtarzalne dokowanie z wysoką dokładnością oraz spełnienie wymagań nowoczesnych, elastycznych systemów produkcyjnych.

2.2 Filtracja czujników odległości

Czujniki pomiaru odległości, takie jak czujniki ultradźwiękowe i skanery laserowe 2D (LiDAR-y 2D), odgrywają kluczową rolę w systemach mobilnych, od pojazdów AGV (Automated Guided Vehicles), przez samochody autonomiczne, po bezzałogowe statki powietrzne. Ich zadaniem jest dostarczanie informacji o odległości do przeszkód lub obiektów otoczenia, co umożliwia nawigację, unikanie kolizji i mapowanie przestrzeni. Niestety, pomiary z tych czujników obarczone są szumami i zakłóceniami pochodzącymi z różnych źródeł. Sygnały ultradźwiękowe mogą ulegać zakłóceniom wskutek zmian warunków środowiskowych (temperatury, wilgotności) lub interferencji z innymi czujnikami ultradźwiękowymi. Z kolei czujniki typu LiDAR są wrażliwe na właściwości optyczne obiektów, gdzie intensywne oświetlenie czy powierzchnie o niskiej refleksyjności mogą generować błędne odczyty i szum pomiarowy w skanie [34]. W rezultacie, surowe dane z czujników odległości bywają niestabilne i mogą wprowadzać układ sterowania w błąd.

Niezawodna filtracja szumów jest zatem niezbędna, aby poprawić jakość danych pomiarowych przed ich wykorzystaniem w algorytmach wyższego poziomu (np. lokalizacji, mapowania czy kontroli ruchu). Brak filtracji lub niewystarczające wygładzenie danych może skutkować błędnymi decyzjami systemu sterowania i stwarzać zagrożenie na hali produkcyjnej.

Najprostszą metodą wygładzania szeregów pomiarowych jest filtr ruchomej średniej (MAF, ang. moving average filter). Polega on na zastąpieniu każdego kolejnego pomiaru średnią wartością z ostatnich N próbek (gdzie N to rozmiar okna filtracji). W praktyce realizuje się to poprzez bufor o stałej długości, do którego dodawane

są kolejne próbki, a każda nowa próbka powoduje usunięcie najstarszej i obliczenie nowej średniej. Zalety ruchomej średniej to prostota i niskie koszty obliczeniowe dzięki czemu nadaje się ona do użycia nawet w mikrokontrolerach o ograniczonej mocy obliczeniowej. Z tego względu filtr ten jest często pierwszym wyborem podczas wygładzania pomiarów z czujników w prostych systemach wbudowanych.

Filtracja uśredniająca skutecznie redukuje drobny szum Gaussowski obecny w sygnale, zmniejszając odchylenie standardowe pomiaru. Należy jednak pamiętać, że ceną za to jest opóźnienie reakcji filtra na rzeczywiste zmiany sygnału. Im większe okno N , tym gładziej (bardziej stabilny) sygnał wyjściowy, ale tym dłużej filtr dostosowuje się do nowej wartości po nagłej zmianie (utrata szybkości reakcji). Badania eksperymentalne potwierdzają tę zależność - zwiększanie liczby uśrednianych próbek zmniejsza fluktuacje i obniża przeregulowanie sygnału, ale jednocześnie wydłuża czas narastania i ustalania wartości na wyjściu filtra. Baskoro i in. [10] analizowali wpływ rozmiaru okna MAF na pomiary z czujnika ultradźwiękowego. Wykazali, że choć filtracja średnią ruchomą poprawia stabilność i ogranicza przeregulowanie sygnału, to zbyt duże okno powoduje istotne spowolnienie odpowiedzi na zmiany. Wyniki tych badań sugerują konieczność kompromisu - w danym zastosowaniu należy dobrać rozmiar okna tak, by zbalansować wymagane wygładzenie sygnału z akceptowalnym opóźnieniem.

Filtr medianowy jest popularną metodą filtracji nieliniowej, szczególnie skuteczną w usuwaniu szumu impulsowego (pojedynczych zakłóceń sygnału). Działa on poprzez zastąpienie każdej próbki medianą wartości w oknie sąsiednich próbek. Próbkę w oknie czasowym są sortowane, a wartość środkowa (mediana) jest przyjmowana jako wynik filtra. Takie podejście skutecznie eliminuje skrajne odchylenia - pojedyncze znaczne odchylenie sygnału nie wpływa istotnie na medianę, o ile większość próbek w oknie odzwierciedla rzeczywisty sygnał.

Zaletą filtra medianowego jest zachowanie ostrych zmian sygnału, o ile ich czas trwania jest dłuższy niż połowa okna. W przeciwieństwie do uśredniania, mediana nie rozmywa gwałtownych skoków (np. krawędzi obiektu) dzięki czemu jest stosowana, gdy ważne jest zachowanie charakterystyki struktur w danych (krawędzie w obrazie czy nagłe zmiany odległości w profilu terenu). Jak ujął to Stone [87], filtr medianowy w porównaniu do średniej ruchomej i filtra Savitzky-Golaya jest szczególnie skuteczny w usuwaniu impulsowych zakłóceń (impulse noise) z danych doświadczalnych. Jednocześnie mediana dobrze sprawdza się tam, gdzie istotne jest zachowanie ostrych krawędzi i nieciągłości sygnału, co czyni ją atrakcyjną dla filtracji np. skanów z LiDAR-u 2D z obiektami o wyraźnych granicach.

Dla przykładu, w dokumentacjach przemysłowych czujników ultradźwiękowych spotyka się wbudowane mediany z oknem 3–18 próbek, konfigurowalne przez użytkownika, w celu wygładzenia odczytu i odrzucenia błędów pomiarowych [94].

Filtr medianowy, podobnie jak średnia, wprowadza opóźnienie rzędu połowy okna. Jednak w zastosowaniach platform mobilnych, gdzie sygnały odległości są zwykle próbkowane z wysoką częstotliwością, medianę można z powodzeniem stosować w czasie rzeczywistym. Podsumowując, filtr medianowy jest doskonałym narzędziem do eliminacji zakłóceń impulsowych, zachowując przy tym strukturę sygnału, co czyni go preferowaną opcją do odszumiania pomiarów obarczonych sporadycznymi błędami [87].

W systemach mobilnych, takich jak systemy AGV, pojazdy autonomiczne czy drony, filtrowanie sygnałów z czujników odległości przekłada się bezpośrednio na po-

prawę precyzji działania. Wyniki badań potwierdzają, że odpowiednio dobrane filtry potrafią znacznie zredukować błąd pomiaru, wygładzić trajektorie ruchu i zapobiec niestabilności sterowania. Jednocześnie trzeba brać pod uwagę ograniczenia praktyczne takie jak wymagany czas reakcji oraz moc obliczeniowa systemu balansując pomiędzy tłumieniem szumu a zachowaniem istotnych informacji [10].

2.3 Kalibracja odometrii

Odometria pozwala na szacowanie przemieszczenia na podstawie pomiarów obrotu kół i stanowi podstawowy sposób określania położenia platformy mobilnej w przestrzeni. Niestety odometria obciążona jest narastającym błędem, który bez odpowiednich korekcyj powoduje dryf pozycji (stopniowe rozejście się szacowanej pozycji z pozycją rzeczywistą) [8]. Można wyróżnić trzy główne źródła błędów odometrycznych:

- błędy systematyczne wynikające z niedokładnej znajomości parametrów modelu kinematycznego platformy mobilnej, np. błędy w założonych średnicach kół lub odległości pomiędzy kołami (rozstawie kół),
- błędy niesystematyczne spowodowane czynnikami losowymi podczas jazdy, np. poślizg kół, nierówności podłoża,
- błędy numeryczne związane z przybliżeniami obliczeń i całkowaniem dyskretnym w czasie.

W literaturze podkreśla się, że całkowity błąd lokalizacji narasta w przybliżeniu z kwadratem pokonanego dystansu [38] lub posiada systematyczny błąd [37]. Oznacza to, że nawet niewielkie odchyłki parametrów mogą skutkować dużym błędem po przejechaniu dłuższego dystansu.

Dominujący wpływ na wartość błędu odometrii ma niepewność parametrów kinematycznych platformy mobilnej (tj. promieni kół, rozstawu kół). Dobrze skalibrowana odometria pozwala pokonać znacznie dłuższą drogę zanim błąd narastający wymusi korekcję pozycji za pomocą zewnętrznego systemu odniesienia / pozycjonowania [8].

Kalibracja odometrii rozumiana jako wyznaczenie rzeczywistych wartości parametrów modelu ruchu jest kluczowym zabiegiem zwiększającym dokładność lokalizacji odometrycznej platformy mobilnej.

W przypadku typowej platformy mobilnej z napędem różnicowym, parametrami podlegającymi kalibracji są przede wszystkim efektywne promienie kół napędowych (lewego i prawego) oraz wzajemna odległość między kołami (rozstaw kół) [18], gdyż od nich zależy przeliczanie impulsów z enkoderów na przejechany dystans i zmiany orientacji pojazdu.

Do klasycznych metod kalibracji odometrii zalicza się podejścia, w których platforma mobilna wykonuje z góry zaplanowane trajektorie testowe, a następnie na podstawie obserwowanych odchyłek od oczekiwanego położenia korygowane są parametry modelu. Jedną z pierwszych prac w tej dziedzinie jest metoda UMBmark opracowana przez Borensteina i Fenga [15]. W procedurze UMBmark platforma mobilna z napędem różnicowym wykonuje specjalnie dobraną sekwencję ruchów (np. jazdę po kwadracie zgodnie z lub przeciwnie do ruchu wskazówek zegara), co pozwala wyodrębnić asymetrię średnic kół oraz niepewność rozstawu kół. Na podstawie uzyskanych wartości przesunięć i rotacji po zamknięciu testowej pętli obliczane

są współczynniki korekcyjne dla efektywnego promienia i rozstawu kół. Zastosowanie tej procedury potrafi znacznie zmniejszyć błędy systematyczne. Borenstein i Feng odnotowali poprawę dokładności odometrii o co najmniej jeden rząd wielkości po kalibracji, w porównaniu do stanu przed kalibracją. Co istotne, metoda UMBmark zapewnia powtarzalne wyniki kalibracji. Procedura UMBmark umożliwia wykrycie i skorygowanie nawet bardzo niewielkich odchyłeń (np. różnicy średnic kół rzędu 0.1%), przy użyciu prostych narzędzi pomiarowych (taśmy mierniczej do sprawdzenia rzeczywistego przebytego dystansu). Podobne metody identyfikacji parametrów odometrii przedstawili Jung i Chung [36], którzy wykorzystali analizę odchyłek orientacji platformy mobilnej podczas jazdy po specjalnie zaprojektowanym torze do precyzyjnej kalibracji dwukołowej platformy różnicowej. Zaproponowano tam wykorzystanie tzw. błędów kierunkowych (ang. heading errors) do estymacji poprawki parametrów, co pozwoliło zwiększyć dokładność odometrii platformy mobilnej z napędem różnicowym.

Abbas i in. [1] zaproponowali usprawnioną procedurę pomiaru i kompensacji systematycznych błędów odometrii spowodowanych niedoskonałościami kinematycznymi platformy, a Bostani i in. [16] przedstawili kolejną metodę wyznaczania i korekcji błędów odometrycznych w oparciu o podobne zasady.

Innym podejściem do kalibracji odometrii jest wykorzystanie systemu wizyjnego zamontowanego nad platformami oraz identyfikację parametrów z użyciem metod estymacji. Antonelli, Chiaverini i Fusco opracowali metodę wyznaczania parametrów odometrii wykorzystując metodę najmniejszych kwadratów [8]. Pokrewnym rozwiązaniem kalibracji odometrii jest wykorzystanie zewnętrznego systemu motion-capture (zestaw kamer podczerwieni śledzących refleksyjne znaczniki umieszczone na śledzonym obiekcie) w celu oceny dokładności lokalizacji platformy mobilnej i ewentualnej kalibracji. Dudzik [25] wykorzystał system optyczny OptiTrack do zmierzenia rzeczywistej trajektorii platformy mobilnej i porównania jej z trajektorią odometrii, co posłużyło do analizy błędów lokalizacji oraz walidacji skuteczności algorytmów korekcji. Takie podejścia dostarczają wzorcowego odniesienia (ang. ground truth), które może być użyte do wyznaczenia poprawek kalibracyjnych.

Kolejną metodą zwiększania precyzji nawigacji jest wykorzystanie dodatkowych czujników i fuzji danych do równoczesnej kalibracji odometrii poprzez ciągłą korekcję błędów i estymację pozycji AGV w trakcie ruchu. Jeśli platforma mobilna dysponuje czujnikiem pozwalającym obserwować swoje otoczenie lub przemieszczanie się (np. LiDAR 2D, kamera, moduł IMU), to dane z takiego czujnika mogą posłużyć do oceny rzeczywistych zmian położenia platformy mobilnej i porównania ich z odometrycznymi, co w konsekwencji umożliwia wyznaczenie poprawek kalibracyjnych. Przykładem takiego podejścia jest metoda jednoczesnej kalibracji odometrii i czujnika zaproponowana przez Censi i in. [18]. Censi prezentuje algorytm, który nie wymaga zewnętrznych urządzeń ani specjalnych znaczników. Platforma mobilna porusza się po dowolnej ścieżce (nie musi to być ściśle określona trajektoria kalibracyjna), a na podstawie odczytów enkoderów kół oraz danych z czujnika pokładowego estymowane są jednocześnie wszystkie parametry. Sformułowano to zagadnienie jako problem maksymalizacji wiarygodności (ang. maximum likelihood). Autorzy uzyskali rozwiązanie w postaci zamkniętej (analitycznej), bez potrzeby iteracyjnej optymalizacji. Zaletą takiego ujęcia jest gwarancja zbieżności do optimum oraz możliwość analitycznego wyznaczenia macierzy kowariancji oszacowanych parametrów. Wyniki eksperymentalne potwierdziły wysoką dokładność systemu po zastosowaniu tej metody.

Podobne rozwiązanie kalibracji odometrii platformy mobilnej zaproponowali Galasso i in. [27]. Opracowali automatyczną metodę kalibracji systemu AGV wykorzystując wyłącznie dane pokładowe z enkoderów kół oraz czujnika lokalizacji względnej (np. LiDAR 2D lub kamery). Procedura wymagała przejazdów z ustaloną prędkością po zaplanowanych trajektoriach, a jej wynikiem było szybkie i dokładne obliczenie zarówno parametrów kinematyki, jak i pozycji czujnika lokalizacji względnej względem ramy pojazdu.

Podsumowując, kalibracja odometrii autonomicznych platform mobilnych jest zagadnieniem wieloaspektowym, obejmującym zarówno jednorazowe procedury wyznaczenia parametrów kinematycznych, jak i ciągłe algorytmy korygujące błędy podczas pracy platformy mobilnej. Historycznie skupiano się na kompensacji błędów systematycznych metodami geometrycznymi (jak testy UMBmark [15] czy metoda najmniejszych kwadratów [8]), co znacząco poprawiło bazową dokładność odometrii. Wraz z pojawieniem się wydajnych czujników i jednostek obliczeniowych, coraz większą rolę odgrywają metody fuzji – wykorzystanie skanerów laserowych, kamer, IMU czy żyroskopów pozwala w trakcie ruchu estymować pozycję systemu AGV i jednocześnie kalibrować odometrię [57].

2.4 Systemy pozycjonowania w procesie dokowania

Uzyskanie wysokiej precyzji dokowania wymaga kompleksowego podejścia, które oprócz kalibracji oraz filtracji pomiarów z czujników, uwzględnia również zastosowanie dodatkowych systemów wspomagających pozycjonowanie pojazdu.

Aby zapewnić wymaganą dokładność, zazwyczaj stosuje się zewnętrzne systemy prowadzenia i pozycjonowania systemów AGV, które wymagają pewnych modyfikacji infrastruktury hali produkcyjnej. Najstarsze rozwiązania opierają się na prowadzeniu pojazdu po fizycznie wyznaczonych trasach, np. za pomocą przewodów wbudowanych w posadzkę lub linii namalowanych na podłodze, które są śledzone przez czujniki pojazdu [17]. Nowocześniejsze rozwiązania wykorzystują znaczniki w otoczeniu, np. taśmy magnetyczne naklejane na podłogę i śledzone przez czujniki magnetyczne AGV, reflektory laserowe rozmieszczone w otoczeniu stanowiące punkty odniesienia dla LiDAR-ów 2D, kody QR lub inne znaczniki wizyjne naklejone na podłożu bądź ścianach, a także transpondery RFID/NFC umieszczone w podłodze lub na stanowiskach montażowych. Wszystkie te elementy umożliwiają osiąganie wysokiej precyzji dokowania, lecz wiążą się z ingerencją w środowisko – wymagają instalacji fizycznych znaczników i najczęściej z góry zdefiniowanych, sztywnych ścieżek poruszania się AGV. Takie podejście ogranicza elastyczność i utrudnia szybkie modyfikacje procesu, co stoi w sprzeczności z koncepcją inteligentnej fabryki w Przemśle 4.0, zakładającej dynamiczne zmiany i decentralizację sterowania [58] [29]. Z tego powodu w literaturze podkreśla się potrzebę opracowywania metod dokowania pozwalających na wysoką dokładność bez konieczności kosztownych modyfikacji otoczenia produkcyjnego [98].

Jednym z najdłużej stosowanych sposobów prowadzenia AGV jest korzystanie z fizycznych tras wyznaczonych w środowisku. Historycznie były to przewody emitujące pole magnetyczne, umieszczone pod posadzką, lub linie namalowane na podłodze – pojazd śledził odchylenie od linii za pomocą odpowiednich czujników i odpowiednio korygował swoje położenie. Rozwiązania te cechują się prostotą i niezawodnością, jednak każda zmiana trasy wymaga kosztownej zmiany infrastruktury oraz

zatrzymania dotychczasowej produkcji [17]. Współcześnie częściej wykorzystuje się taśmy magnetyczne naklejane na podłódze.

Su i in. [88] zaproponowali ulepszony system śledzenia magnetycznego oparty na silnych magnesach neodymowych jako znacznikach oraz dwuwymiarowej macierzy czujników magnetorezystywnych na pojeździe. Dzięki modelowaniu pola magnetycznego magnesu jako dipola oraz zastosowaniu algorytmów hybrydowej optymalizacji (połączenie Particle Swarm Optimization i algorytmu Levenberga-Marquardta) do estymacji położenia znacznika, uzyskano znaczącą poprawę dokładności. Średni błąd pozycjonowania zmniejszono do $\pm 1,69$ mm, co stanowi rezultat kilkukrotnie lepszy od tradycyjnych systemów magnetycznych.

Zaletą prowadzenia magnetycznego jest odporność na warunki optyczne (oświetlenie, zapylenie), jednak wadą pozostaje konieczność rozmieszczenia fizycznych znaczników (taśm lub magnesów) w otoczeniu. W dynamicznych środowiskach produkcyjnych, gdzie trasy transportowe mogą ulegać zmianom, nawet względnie proste w instalacji taśmy magnetyczne mogą ograniczać elastyczność procesu.

Laserowe skanery (LiDAR 2D) od lat są stosowane w nawigacji AGV ze względu na zdolność do dokładnego pomiaru odległości i kształtu otoczenia. W tzw. nawigacji z reflektorami laserowymi wykorzystuje się pryzmatyczne znaczniki odbłaskowe rozmieszczone w środowisku hali. LiDAR 2D na platformie mobilnej emituje wiązki promieni lasera i odbiera sygnały odbite. Jeśli w zasięgu znajdują się reflektory (np. odbłaski o wysokiej refleksyjności lub retroreflektory), wiązka laserowa odbita od reflektora jest znacznie silniejsza niż odbita od otoczenia. System jest w stanie wykryć reflektory w chmurze punktów skanera i na tej podstawie określić pozycję pojazdu, korzystając z odległości mierzonych do punktów reprezentujących reflektory.

Rozwiązanie to jest szeroko wykorzystywane w przemyśle, a wiele komercyjnych AGV nawigujących swobodnie korzysta z nawigacji wykorzystującej reflektory laserowe. Zapewnia ono typową precyzję lokalizacji na poziomie kilku centymetrów, przy czym dokładność dokowania może być zwiększana przez zagęszczenie reflektorów w obszarze docelowym. Wadą tego systemu jest konieczność instalacji wielu znaczników odbłaskowych w otoczeniu (np. na słupach, ścianach). Zwykle do obliczenia pozycji wymagane są co najmniej trzy jednocześnie widoczne reflektory, a dla pełnego pokrycia obszaru pracy AGV często montuje się kilkadziesiąt takich odbłasków. Modyfikacja układu hali (np. dostawienie regałów zasłaniających reflektory) może zakłócić działanie systemu, dlatego utrzymanie tej infrastruktury wymaga nadzoru i generuje dodatkowe koszty.

Aby ograniczyć liczbę wymaganych znaczników laserowych, rozwija się metody zwiększające wykorzystanie informacji z samego otoczenia lub specjalnych lokalnych znaczników przy stanowisku. Ciekawym podejściem jest wykorzystanie odbłaskowych znaczników o kontrolowanej intensywności odbicia. Liu [48] zaproponował metodę dokowania, w której na stanowisku docelowym umieszczono fragment materiału odbłaskowego odbijającego promień lasera z określoną charakterystyką intensywności. LiDAR 2D oprócz standardowego pomiaru odległości, dostarcza również wartość intensywności odbicia. Wykrycie znaczącego wzrostu intensywności sygnalizuje wykrycie specjalnego znacznika odbłaskowego o znanej pozycji w układzie odniesienia stanowiska. Metoda ta umożliwiła autonomiczne dokowanie platformy mobilnej do stacji dokującej (np. ładowania baterii) w nieuporządkowanym otoczeniu, bez użycia kamer, osiągając wysoką skuteczność i dokładność. W publikacji Liu podano, że opracowany algorytm umożliwił wykrywanie stacji dokującej i dokładne dojazdy nawet przy zmiennych warunkach otoczenia, dzięki czemu platforma mobilna mogła

automatycznie zadokować do ładowarki. Zaletą wykorzystania intensywności odbitych wiązek LiDAR jest brak skomplikowanych modyfikacji – wystarczy jedynie pasywny znacznik (np. naklejka odblaskowa) umieszczony na stanowisku, co wiąże się z minimalnymi zmianami, a w samym AGV wykorzystywany jest istniejący już czujnik typu LiDAR 2D.

Innym sposobem zwiększenia precyzji lokalizacji laserowej bez gęstej sieci reflektorów jest zastosowanie algorytmów dopasowania skanów (algorytm Iterative Closest Point - ICP) do znanej mapy otoczenia w fazie dokowania. Yilmaz i Te meltas [99] zaproponowali dwuetapowy system nawigacji. Podczas jazdy między obszarami platforma mobilna korzysta z lokalizacji naturalnej, natomiast po dotarciu w pobliże celu przełącza się na precyzyjny tryb lokalizacji poprzez dopasowanie skanu LiDAR do mapy otoczenia. Dzięki takiemu hybrydowemu podejściu uzyskano dokładność końcowego dokowania poniżej 1 cm (oraz poniżej 1° w orientacji) bez potrzeby instalowania fizycznych znaczników na całej trasie przejazdu. To pokazuje, że odpowiednio wykorzystując naturalne cechy otoczenia (ściany, krawędzie) i zaawansowane algorytmy lokalizacji, można ograniczyć zależność od infrastruktury. Niemniej jednak, nawet w takich systemach często stosuje się lokalne znaczniki lub elementy charakterystyczne w samym obszarze dokowania, aby ułatwić końcową fazę ustawiania (np. specjalne narożniki, wzorce na podłodze ułatwiające ICP).

Jedną z najpopularniejszych kategorii rozwiązań dokowania platform mobilnych są metody wykorzystujące skanery laserowe (LiDAR 2D) oraz proste fizyczne znaczniki przestrzenne umieszczone na stacji dokującej. Typowo stosuje się tutaj pasywne reflektory lub specjalnie ukształtowane elementy geometryczne, które wyróżniają się na tle otoczenia w skanie laserowym. Niektóre systemy instalują na stacji dokującej narożniki, słupki lub bloki o charakterystycznym kształcie, tak aby ich kontur był łatwo rozpoznawalny przez skaner 2D. Hercik i in. [33] przeprowadzili badania kilku kształtów znaczników i stwierdzili, że blok w kształcie litery “L” zapewniał najwyższą precyzję dokowania – powtarzalny błąd pozycjonowania wynosił około ± 3 mm. Przykładowo, stacja ładowania platform mobilnych MiR (ang. Mobile Industrial Robots) posiada wgłębienie w kształcie litery V, które musi pozostać odsłonięte w stosunku do innych obiektów, aby laser mógł wykryć jego zarys [35].

Rozwój technik widzenia maszynowego przyniósł szerokie zastosowanie znaczników wizyjnych do lokalizacji platform mobilnych. Są to wzory graficzne łatwe do wykrycia i zidentyfikowania przez kamerę, zwykle o unikalnej strukturze (np. czarno-białe kody dwuwymiarowe). Do popularnych rozwiązań należą kody QR, znaczniki ArUco/AprilTag, czy inne znaczniki wizyjne o wysokim kontraście. Zaletą tych znaczników jest ich niski koszt i łatwość instalacji – wystarczy wydrukowany znacznik i nakleić we właściwym miejscu. Kamera zamontowana na AGV dostarcza obraz, na którym algorytm wizyjny lokalizuje znacznik i oblicza względną pozycję oraz orientację.

Kody QR były wielokrotnie badane jako metoda doprowadzania AGV do punktu z dużą dokładnością. Li i Huang [45] przedstawili koncepcję wykorzystania kodów QR jako punktów orientacyjnych rozmieszczonych w środowisku wewnątrz budynków. Prace Li i Huang wykazały, że dodanie takiego wsparcia wizji do klasycznej lokalizacji poprawia dokładność i niezawodność pozycjonowania platformy mobilnej. Jednym z imponujących osiągnięć jest system dokowania opracowany przez Bolanakisa i in. [14], gdzie zastosowano matrycę wielu małych kodów QR na stacji dokowania oraz kamerę o wysokiej rozdzielczości na pojeździe. Dzięki jednoczesnemu śledzeniu wielu kodów i redundantnemu obliczaniu pozycji osiągnięto bardzo

wysoką dokładność pozycji – średni błąd pozycjonowania wyniósł zaledwie $39\ \mu\text{m}$, a orientacji $0,0088^\circ$. Jest to wynik wręcz laboratoryjny, pokazujący potencjał metody. System działał z częstotliwością odświeżania 60 Hz, a dzięki użyciu wielu znaczników zapewniono odporność na uszkodzenie części z nich. Co ważne, cała infrastruktura dokująca była pasywna (wydrukowane kody), bez elementów aktywnych czy zasilania, co obniża koszty utrzymania.

Innym typem znaczników są AprilTag lub ArUco, będące specjalnie zaprojektowanymi wzorami binarnymi zoptymalizowanymi pod kątem jednoznacznej detekcji i niskiego błędu estymacji pozycji. Richter i in. [79] zwracają uwagę, że dokładność wyznaczenia pozycji z kamery zależy w dużej mierze od precyzji detekcji narożników znacznika. Zaproponowali oni ulepszony algorytm detekcji krawędzi AprilTag, który zwiększa precyzję lokalizacji tych znaczników w obrazie, a tym samym poprawia dokładność dokowania platformy mobilnej przy ich użyciu. Celem było osiągnięcie powtarzalnego ustawienia z dokładnością poniżej 1 cm względem stanowiska, co jest wymagane np. przy automatycznym łączeniu modułów na linii montażowej. System wizyjny z ulepszonym algorytmem detekcji pozwolił na wielokrotne precyzyjne dokowanie – platforma mobilna za każdym razem zatrzymywała się w pozycji mieszczącej się w polu tolerancji poniżej 1 cm od pozycji referencyjnej, przekazując jednocześnie informację o swoim położeniu do stacji (co umożliwia jej ewentualną korektę przez podsystemy stacji).

Jia i in. [35] zaprojektowali hybrydowy system wizyjno-laserowy, gdzie kamera wykrywa znacznik AprilTag na stacji, a LiDAR dba o unikanie kolizji. Deklarowana dokładność dokowania wyniosła $<5\ \text{cm}$.

Mutti i Pedrocchi [58] opisali system, gdzie kamera odczytuje pozycję z pomocą znaczników wizyjnych głównie w celu kalibracji odometrii i poprawy modelu kinematycznego platformy mobilnej poprzez filtr Unscented Kalman Filter (UKF), co przekłada się na bardziej dokładne dojazdy do celu.

Tego typu rozwiązania pokazują, że znaczniki wizyjne mogą skutecznie zastąpić inne systemy w końcowej fazie dokowania, oferując wysoką dokładność przy minimalnej modyfikacji otoczenia - wystarczy wydrukowany znacznik na stanowisku lub innym obiekcie.

Należy jednak zaznaczyć pewne ograniczenia znaczników wizyjnych. Po pierwsze, zasięg detekcji ograniczony jest rozdzielczością kamery i rozmiarem znacznika – wraz ze wzrostem odległości od znacznika maleje jego rozmiar na obrazie i rośnie względny błąd wyznaczenia pozycji. Dlatego w praktyce kody QR/AprilTag sprawdzają się, gdy kamera może podjechać stosunkowo blisko (np. $< 2\text{--}3\ \text{m}$) lub gdy znaczniki są odpowiednio duże [98].

Po drugie, warunki oświetleniowe silnie wpływają na działanie systemu. Ekstremalne warunki (silne odbicia, półmrok) mogą uniemożliwić odczyt znaczników wizyjnych. Metody czysto wizyjne są czułe na warunki oświetleniowe. Jak odnotowano, nawet standardowe oświetlenie hali może powodować refleksy lub cienie utrudniające detekcję znaczników, a zmiana kąta widzenia kamery wpływa na błędy estymacji położenia [20]. Ponadto kamera ma ograniczone pole widzenia – jeśli platforma mobilna nie zbliży się wystarczająco i w odpowiednim zakresie kątowym, znacznik może w ogóle nie zostać dostrzeżony.

Znaczniki wizyjne stanowią bardzo atrakcyjne rozwiązanie ze względu na niski koszt i łatwość wdrożenia (szczególnie gdy AGV jest już wyposażony w kamerę). Oferują wysoką dokładność lokalizacji względnej – rzędu milimetrów, a nawet ułamków milimetra w sprzyjających warunkach [14]. Należy jednak brać pod uwagę ich ograniczenia odnośnie warunków pracy i zasięgu. Dlatego często łączy się je hybry-

dowo z innymi czujnikami, wykorzystując znaczniki wizyjne tylko do finalnej korekty pozycji.

Kolejną grupą rozwiązań są technologie radiowe, które mogą wspomagać pozycjonowanie AGV. Najprostszą formą są znaczniki RFID (ang. Radio-Frequency IDentification) – pasywne tagi z unikalnym kodem, które można umieścić w podłodze lub na obiektach środowiska hali. AGV wyposażony w czytnik RFID (np. pod spodem pojazdu) może odczytać kod znacznika, gdy znajdzie się on w zasięgu pola elektromagnetycznego (zwykle kilkanaście centymetrów). Pojedynczy tag RFID nie daje informacji o ciągłym położeniu, ale pozwala na korekcję. Znając pozycję znacznika w układzie hali, system może skorygować estymowaną pozycję AGV w momencie przejazdu nad tagiem. Zastosowanie wielu tagów rozmieszczonych w formie siatki na podłodze umożliwia dość dokładne śledzenie pozycji. Lu i wsp. [49] opisali system, w którym wbudowane w podłogę znaczniki NFC (13,56 MHz) rozmieszczono w równomiernym wzorze (w formie siatki) na obszarze fabryki. Czytnik zainstalowany w AGV odczytywał tagi pod pojazdem, a znając ich ID (przypisane do współrzędnych) korygowano pozycję z odometrii. Taki system jest w pełni odporny na warunki optyczne i dość prosty w eksploatacji, jednak wymaga zainstalowania bardzo wielu tagów w podłodze, jeśli ma pokrywać duży obszar (co może być kosztowne i pracochłonne).

W pracy Yang i in. [96] zaprezentowano metodę lokalizacji opartą na filtrze Kalmana dla systemu RFID w technologii Hybrid Inertial Microwave Reflectometry (HIMR). Zastosowanie zaawansowanej estymacji pozwoliło śledzić pozycję z dokładnością rzędu centymetrów. Z kolei praca [77] Perper opisuje platformę UHF RFID zdolną do pozycjonowania rozdzielczością poniżej 1 cm. Są to jednak systemy eksperymentalne, wymagające rozbudowanej infrastruktury antenowej i obliczeniowej, stąd ich praktyczne wdrożenia w kontekście dokowania AGV nie są jeszcze powszechne.

W praktyce przemysłowej często łączy się wiele technik celem uzyskania najwyższej niezawodności. Podejście fuzji jest wyraźnym trendem. Przykładowo Nowak i in. [61] w systemie dokowania elektrycznych busów wykorzystali wizję do dokładnego ustawienia pojazdu względem stacji ładowania, wspomaganą dodatkowym czujnikiem typu LiDAR 3D w celu wykrycia i zlokalizowania stacji ładowania. Inni autorzy proponują architektury wieloetapowe, w którym najpierw platforma mobilna korzysta z nawigacji magnetycznej, laserowej lub inercyjnej, a w fazie końcowej aktywuje się system lokalny (np. kamera wykrywająca znaczniki wizyjne) – przełączenie następuje automatycznie na podstawie odległości od celu lub pewności lokalizacji [99] [79]. Takie hybrydowe systemy dokowania zapewniają zarówno elastyczność (brak konieczności gęstej sieci znaczników na całej trasie), jak i dokładność na ostatnim odcinku dokowania, spełniając tym samym wymagania Przemysłu 4.0.

Rozdział 3

Właściwości czujników odległości

Percepcja platformy mobilnej Automated Guided Vehicle (AGV) oraz jakość jej percepcji zależą od jakości danych pozyskiwanych z czujników, w które AGV jest wyposażony. Oferta czujników odległości dostępnych na rynku jest szeroka. Poza ceną różnią się one między sobą wieloma innymi parametrami, takimi jak: zasięg działania, precyzja, dokładność, wymagania dotyczące zasilania, przeznaczenie, zasada działania czy zastosowana technologia. Kluczowym parametrem w percepcji platformy mobilnej jest zgodność wykonywanych pomiarów z rzeczywistością.

3.1 Czujniki odległości

Istnieje wiele typów czujników odległości, a każdy z nich umożliwia odbiór i interpretację otoczenia w inny sposób, wykorzystując różne metody, cechy i właściwości środowiska (odbicie światła, dźwięku). Czujniki odległości mają swoje zalety i wady. Są one związane z ich zasadą działania oraz wykorzystywaną technologią.

3.1.1 Laserowe czujniki odległości – Light Detection and Ranging (LiDAR)

Czujniki typu LiDAR umożliwiają wykonywanie precyzyjnych pomiarów odległości z wysoką częstotliwością (w porównaniu do czujników ultradźwiękowych). Istnieją dwie główne metody pomiaru odległości z wykorzystaniem czujników laserowych – triangulacja oraz metoda pomiaru czasu przelotu (ang. Time of Flight - ToF).

Metoda triangulacji wykorzystuje źródło światła laserowego oraz matrycę detekcyjną ustawioną pod określonym kątem względem źródła. Światło odbija się od przeszkody i trafia na matrycę detekcyjną. Pozycja wykrytego punktu świetlnego na matrycy jest ściśle powiązana z kątem, pod jakim światło dotarło do detektora, a kąt z kolei zależy od odległości, jaką przebyła wiązka [24].

Metoda pomiaru czasu przelotu, umożliwia pomiar odległości na podstawie czasu przelotu światła laserowego o znanej prędkości. Wyróżnia się dwie odmiany tej metody: bezpośrednią i pośrednią.

Bezpośrednia metoda ToF polega na generowaniu krótkich impulsów światła i pomiarze czasu, po którym impuls wraca do czujnika. Pozwala to obliczyć odległość do przeszkody [51].

Pośrednia metoda ToF wykorzystuje ciągłą falę światła o modulowanej częstotliwości. Pomiar przesunięcia fazowego między sygnałem nadanym a odbitym umożliwia określenie odległości do obiektu [9].

DFRobot TF Mini

DFRobot TF Mini [21] to laserowy czujnik, który dokonuje pomiaru odległości za pomocą techniki ToF. Posiada pojedynczą wiązkę lasera o polu widzenia (ang. Field of View - FOV) wynoszącym $2,3^\circ$. TF Mini mierzy odległości od 0,3 m do 12 m z rozdzielczością 1 mm. Błąd pomiarowy zależy od zakresu pracy – maksymalnie 60 mm w zakresie od 0,3 m do 6 m oraz 1% błędu powyżej 6 m aż do maksymalnego zasięgu działania. Zasilany jest napięciem 5 V i pobiera około 120 mA. TF Mini komunikuje się przez UART [39], a maksymalna częstotliwość transmisji danych wynosi 100 Hz.



Rysunek 3.1: Czujnik odległości, DFRobot TF Mini LiDAR [65].

DFRobot TF Mini-S

DFRobot TF Mini-S [22] to laserowy czujnik, który również mierzy odległość z wykorzystaniem techniki ToF. Jego specyfikacja jest bardzo zbliżona do DFRobot TF Mini, jednak największą różnicą względem poprzednika jest zmniejszenie minimalnego zasięgu działania oraz zwiększenie częstotliwości pomiarowej. Czujnik posiada pojedynczą wiązkę lasera o FOV wynoszącym 2° . TF Mini-S mierzy odległości od 0,1 m do 12 m z rozdzielczością 1 mm. Błąd pomiarowy zależy od zakresu pracy – maksymalnie 60 mm błędu w zakresie 0,1 m do 6 m oraz 1% błędu powyżej 6 m aż do maksymalnego zasięgu. Zasilany jest napięciem 5 V i pobiera około 140 mA. Komunikuje się przez UART [39] lub I2C [52], a maksymalna częstotliwość transmisji danych wynosi 1000 Hz.

Leica D510

Leica D510 [41] to laserowy czujnik pomiaru odległości. Posiada pojedynczą wiązkę lasera o polu widzenia $0,0344^\circ$. Leica D510 mierzy odległości w zakresie od 0,05 m do 200 m z rozdzielczością 0,1 mm.

Błąd pomiarowy czujnika D510 zależy od zakresu pracy:

- 1 mm w zakresie od 0,05 m do 10 m,
- 0,1 mm/m w zakresie od 10 m do 30 m,
- 0,2 mm/m w zakresie od 30 m do 100 m,
- 0,3 mm/m powyżej 100 m

Leica D510 posiada certyfikat (ISO 16331-1) potwierdzający dokładność pomiarów do 1 mm. Został również wyposażony we wbudowaną kamerę ułatwiającą skierowanie wiązki lasera w konkretny punkt oraz akcelerometr mierzący kąt pochylenia

z dokładnością do $0,2^\circ$. Pomiar może być wykonywany ręcznie lub zdalnie za pomocą łączności Bluetooth i dedykowanej aplikacji Leica dla urządzeń z Androidem oraz PC.



Rysunek 3.2: Czujnik odległości, Leica D510 LiDAR [68].

Leica X4

Leica DISTO X4 [42] to laserowy czujnik odległości zaprojektowany do pomiarów zarówno na zewnątrz, jak i wewnątrz budynków. Posiada pojedynczą wiązkę lasera o wąskim polu widzenia, wynoszącym około $0,0344^\circ$. Leica X4 dokonuje pomiaru odległości w zakresie od 0,05 m do 150 m z rozdzielczością 0,1 mm.

Leica DISTO X4 spełnia standard ISO 16331-1, jednak błąd pomiarowy zależy również od zakresu oraz warunków pracy:

- 1 mm dokładność w sprzyjających warunkach do 10 m,
- 0,1 mm/m błędu powyżej 10 m

Urządzenie wyposażone jest we wbudowaną kamerę cyfrową z 4-krotnym zoomem i celownikiem (na ekranie czujnika), umożliwiającą precyzyjne skierowanie lasera nawet na odległe obiekty w świetle dziennym. Zintegrowany akcelerometr umożliwia pomiar kąta pochylenia z dokładnością $0,2^\circ$. Pomiary mogą być wyzwalone ręcznie lub przez komunikację Bluetooth Low Energy (BLE). Leica X4 obsługuje połączenie z aplikacjami mobilnymi (Android, iOS) oraz oprogramowaniem Leica dla systemu Windows do zaawansowanego dokumentowania pomiarów i planowania 2D/3D.



Rysunek 3.3: Czujnik odległości, Leica X4 LiDAR [69].

RPLidar A1

RPLiDAR A1 [80] to czujnik typu LiDAR 2D, który mierzy odległość na zasadzie triangulacji. Dzięki obrotowemu ruchowi czujnika laserowego zapewnia pole widzenia o zakresie 360 stopni. Czujnik ten może mierzyć odległości w zakresie od 0,15 m do 12 m, z rozdzielczością około 1% mierzonej odległości. Dokładność pomiaru zależy od zakresu, ale zazwyczaj wynosi $\pm 1\%$ mierzonej odległości w standardowych warunkach wewnętrznych. Częstotliwość obrotu czujnika może być regulowana od 1

Hz do 10 Hz, z częstotliwością próbkowania do 8000 Hz – w zależności od konfiguracji. LiDAR ten jest zasilany napięciem 5 V, pobiera około 400–500 mA. RPLiDAR A1 komunikuje się przez interfejs UART [39], za pośrednictwem adaptera USB [31].



Rysunek 3.4: Czujnik odległości, RPLidar A1 LiDAR 2D [71].

RPLidar A2

RPLiDAR A2 [81] to czujnik typu LiDAR 2D, który mierzy odległość w oparciu o zasadę triangulacji. Dzięki obrotowemu ruchowi czujnika laserowego obejmuje pole widzenia (FOV) równe 360°. Czujnik mierzy odległości od 0,15 m do 12 m z rozdzielczością 0,5 mm dla odległości poniżej 1,5 m oraz z rozdzielczością mniejszą niż 1% mierzonej wartości powyżej 1,5 m. Błąd pomiarowy zależy od zakresu pracy i wynosi 1% mierzonej odległości. Częstotliwość obrotu czujnika laserowego może być regulowana od 5 Hz do 15 Hz, a częstotliwość próbkowania wynosi 8000 Hz. Urządzenie zasilane jest napięciem 5 V i pobiera od 450 do 600 mA. RPLiDAR A2 komunikuje się przez UART [39], za pośrednictwem adaptera USB [31].



Rysunek 3.5: Czujnik odległości, RPLidar A2 LiDAR 2D [72].

Leuze RSL 425 XL

Leuze RLS425 XL [43] to przemysłowy laserowy skaner 2D, który mierzy odległość przy użyciu pośredniej metody ToF (Time of Flight). Dzięki obrotowemu ruchowi sensora laserowego obejmuje pole widzenia o zakresie 270° z rozdzielczością kątową 0,1°. Zasięg FOV może być dostosowany i podzielony na 10 pól. Jest możliwość zdefiniowania pól ochronnych i ostrzegawczych. Obecność obiektu w tych polach aktywuje funkcje bezpieczeństwa i generuje sygnały przerwań do systemu

nadrzędnego. Czujnik mierzy odległości w zakresie od 0,05 m do 50 m z rozdzielczością 1 mm. Błąd pomiarowy zależy od zakresu działania i wynosi około 10–20 mm. Częstotliwość skanowania może być konfigurowana w zakresie od 12,5 Hz do 25 Hz. Zasilany jest napięciem 24 V i pobiera prąd w zakresie 0,7–3 A. Leuze RLS425 XL komunikuje się za pośrednictwem interfejsu Ethernet [86].



Rysunek 3.6: Czujnik odległości, Leuze RSL425 XL LiDAR 2D [70].

Sick microscan3

SICK microScan3 [84] to przemysłowy laserowy skaner 2D, który mierzy odległość za pomocą techniki wielokrotnego pomiaru czasu przelotu (ang. multi-echo ToF). Dzięki obrotowemu ruchowi czujnika laserowego, microscan3 obejmuje pole widzenia o zakresie 275 stopni, z konfigurowalną rozdzielczością kątową w zakresie od 0,1° do 0,4°. Pole widzenia może być elastycznie dzielone na wiele konfigurowalnych stref ochronnych i ostrzegawczych (łącznie do 128 pól), co umożliwia dynamiczne monitorowanie bezpieczeństwa. Wykrycie obiektu w tych strefach wyzwala funkcje bezpieczeństwa oraz sygnały przerwania dla systemu nadrzędnego. Czujnik mierzy odległości w zakresie od 0,1 m do 64 m. Błąd pomiarowy zależy od zakresu działania i oscyluje wokół 10–20 mm. Częstotliwość skanowania może być konfigurowana w zakresie od 20 Hz do 25 Hz. microScan3 pracuje przy zasilaniu 24 V DC, a typowe zużycie prądu wynosi 2–3 A. Komunikuje się przez interfejs Ethernet [86] (UDP/TCP) [13] i jest konfigurowany poprzez oprogramowanie SICK Safety Designer.



Rysunek 3.7: Czujnik odległości, Sick microScan3 LiDAR 2D [73].

3.1.2 Podsumowanie najważniejszych właściwości pomiarowych czujników odległości typu LiDAR

Tabela 3.1 prezentuje porównawcze zestawienie najważniejszych właściwości czujników LiDAR opisanych w poprzednim podrozdziałach.

Tabela 3.1: Podsumowanie właściwości pomiarowych laserowych czujników odległości.


Model czujnika	Zasięg	Rozdzielczość	Błąd pomiarowy	FOV	Rozdzielczość kątowa	Częstotliwość dost. danych
TF Mini	0.3 - 12 m	5mm	max 60mm @ 0.3 - 6m 1% @ >6m	2.3 deg	2.3 deg	100 Hz
TF Mini-S	0.1 - 12 m	5mm	max 60mm @ 0.1 - 6m 1% @ >6m	2 deg	2 deg	1000 Hz
Leica D510	0.05 - 200 m	0.1mm	1mm @ 0.05 - 10m	0.034 deg	0.034 deg	7 Hz
RSL425 XL	0.05 - 50 m	0.001 m	0.01 - 0.02 m	270 deg	0.1 deg	25 Hz
microScan3	0.1 - 64 m		0.025 m	275 deg		
RPLidar A1	0.15 - 12 m	0.005 m <1.5 m;	<1%	360 deg	1 deg	5.5 Hz
RPLidar A2	0.15 - 16 m	1% >1.5 m			0.9 deg	8 Hz
Leica X4	0.05 - 150 m	0.0001 m	0.001 m <10 m	0.034 deg	0.034 deg	7 Hz

3.1.3 Ultradźwiękowe czujniki odległości

Czujniki ultradźwiękowe umożliwiają pomiar odległości. W porównaniu do LiDAR-ów charakteryzują się niższą częstotliwością pomiarową, jednak nie są wrażliwe na obecność silnego światła otoczenia ani na powierzchnie o niskim współczynniku odbicia światła. Emitują falę dźwiękową, która odbija się od przeszkody i wraca do czujnika. Czas przelotu fali w powietrzu jest mnożony przez prędkość dźwięku (przyjętą jako 343 m/s przy temp. 20°C), a następnie dzielony przez 2 – w rezultacie otrzymujemy odległość do przeszkody.

HC-SR04

HC-SR04 [30] to czujnik ultradźwiękowy, który dokonuje pomiaru odległości. Posiada kąt widzenia (FOV) równy 15 stopni. HC-SR04 mierzy odległości w zakresie od 0,02 m do 4 m z rozdzielczością 3 mm. Błąd pomiaru zależy od zakresu pracy i oscyluje wokół 1% mierzonej odległości. Zasilany jest napięciem 5 V i pobiera około 15 mA. Aby wykonać pomiar, czujnik musi otrzymać sygnał od urządzenia nadrzędnego przez co najmniej 10 μ s (sygnał wyzwalający – ang. trigger). Po jego odebraniu czujnik wysyła serię ośmiu impulsów ultradźwiękowych o częstotliwości 40 kHz. Jeżeli czujnik odbierze wysłany sygnał, generuje sygnał o czasie trwania proporcjonalnym do zmierzonej odległości (sygnał echo). Czas trwania sygnału echo z czujnika HC-SR04 w mikrosekundach należy podzielić przez 58, aby uzyskać wynik w centymetrach. Zgodnie z instrukcją obsługi czujnika zaleca jest przerwa pomiędzy kolejnymi wyzwoleniami pomiarów odległości o czasie co najmniej 60 ms.



Rysunek 3.8: Ultradźwiękowy czujnik odległości, HC-SR04 [67].

DFRobot URM37v5

DFRobot URM37v5 [23] to czujnik ultradźwiękowy, który dokonuje pomiaru odległości. Posiada kąt widzenia równy 15 stopni. URM37v5 mierzy odległości od 0,02 m do 8 m z rozdzielczością 10 mm. Błąd pomiarowy zależy od zakresu pracy i oscyluje wokół 1% mierzonej odległości. Czujnik posiada funkcjonalność wygenerowania sygnału, gdy wykryta odległość jest mniejsza niż zaprogramowana wartość progowa. Maksymalny czas trwania pojedynczego pomiaru wynosi 100 ms. Zasilany jest napięciem 3.3–5 V i pobiera około 20 mA.

Pomiar odległości może być odczytywany poprzez:

- interfejs UART – urządzenie nadrzędne wysyła zapytanie do URM37v5 i odbiera informację o zmierzonej odległości,
- odczyt PWM – URM37v5 generuje sygnał PWM [100], w którym każde 50 μ s odpowiada 1 cm. Pomiar odległości aktywowany jest przez wysłanie do czujnika impulsu o niskim poziomie logicznym,
- odczyt ADC – URM37v5 generuje sygnał analogowy, w którym każde 6.8mV odpowiada 1cm [74]. Pomiar również aktywowany jest przez impuls niskiego poziomu.

Można także uruchomić tryb automatycznych pomiarów, w którym moduł mierzy odległość automatycznie co 25 ms (okres pomiarowy może być konfigurowany), a następnie generuje sygnał PWM, gdzie każde 50 μ s odpowiada 1 cm. URM37v5 może być również używany do sterowania serwomechanizmem poprzez jeden z dedykowanych pinów.



Rysunek 3.9: Ultradźwiękowy czujnik odległości, DFRobot URM37v5 [66].

3.1.4 Podsumowanie najważniejszych właściwości pomiarowych ultradźwiękowych czujników odległości

Tabela 3.2 prezentuje zestawienie porównawcze najważniejszych właściwości obu czujników ultradźwiękowych opisanych w poprzednim podrozdziałach.

Tabela 3.2: Podsumowanie właściwości pomiarowych ultradźwiękowych czujników odległości.


Model czujnika	Zasięg	Rozdzielczość	Błąd pomiarowy	FOV	Rozdzielczość kątowna	Częstotliwość dost. danych
HC-SR04	0.02 - 4 m	0.17 mm	1%	15 deg	15 deg	10 Hz
URM37 v5	0.02 - 8 m	10 mm	1%	30 deg	30 deg	10 Hz

3.2 Badanie charakterystyki czujników odległości

Weryfikacja jakości pomiarów odległości została przeprowadzona dla sześciu laserowych czujników odległości: dwóch LiDAR-ów 1D (DFRobot TF Mini, DFRobot TF Mini-S), czterech LiDAR-ów 2D (Leuze RSL425 XL, Sick microscan3, RPLidar A1, RPLidar A2) oraz dwóch czujników ultradźwiękowych: (HC-SR04, URM37v5). Eksperyment został wykonany w zakresie od 0,05 m do 2,25 m (zmiennym w zależności od zakresu operacyjnego poszczególnych czujników). Jako czujniki referencyjne wykorzystano dalmierz Leica D510 (dla LiDAR-ów 1D oraz czujników ultradźwiękowych) oraz Leica X4 (dla LiDAR-ów 2D) ze względu na ich wysoką dokładność pomiarową.

W celu sprawdzenia charakterystyki pomiarów odległości, zbudowano autorskie stanowisko badawcze (rys. 3.10). Składało się ono z dwóch aluminiowych profili kątowych, które pełniły funkcję szyn dla wózka transportowego, na którym pionowo zamocowano biały styropian ($1\text{ m} \times 0.5\text{ m}$). Czujniki zostały zamontowane po jednej stronie szyn, prostopadle do kierunku ruchu wózka. Wózek transportowy pełnił rolę ruchomej przeszkody. Czujniki LiDAR zostały rozstawione względem siebie co 0.5 m, aby uniknąć wzajemnych zakłóceń. Czujniki ultradźwiękowe testowano osobno ze względu na ich szerokie pole widzenia (FOV) oraz możliwość wzajemnego wzbudzania się. Wszystkie czujniki były zwrócone w stronę przeszkody na wózku i zamocowane w sposób zapewniający wyrównanie ich początkowych punktów pomiarowych.

W celu pozyskiwania pomiarów odległości, czujniki (LiDAR-y 1D oraz ultradźwiękowe) zostały podłączone do mikrokontrolera STM32F429ZI [63], który co 10 ms przesyłał za pośrednictwem interfejsu Ethernet wszystkie dane zgromadzone z czujników. STM32 był połączony z komputerem, który zapisywał dane pomiarowe. Czujniki LiDAR 1D oraz URM37v5 połączono z STM32 poprzez interfejs UART, natomiast czujnik HC-SR04 za pomocą dwóch linii sygnałowych (trigger oraz echo). Po zamontowaniu wszystkich elementów i uruchomieniu niezbędnego oprogramowania, ruchoma przeszkoda została ustawiona w pozycji początkowej – w odległości 0,05 m od czujników odległości. Następnie zapis każdej serii pomiarowej był wyzwalany przypisanym klawiszem i rozpoczynał zapis 40 pomiarów dla każdego z czujników w równych odstępach czasu (co 500ms). Po zapisaniu serii pomiarowej przeszkoda była przesuwana na szynach i rozpoczynano kolejną serię zapisów. Cały test przeprowadzono w zakresie 0,05 – 2,25 m, przy czym od 0,05 m do 0,13 m przeszkodę przesuwano co 0,02 m, a w zakresie 0,13–2,25 m co 0,05 m.



Rysunek 3.10: Stanowisko badawcze umożliwiające badanie jakości pomiarowej czujników odległości.

Wszystkie testowane czujniki LiDAR 2D były bezpośrednio połączone z komputerem poprzez interfejs Ethernet. Czujnik RSL425 XL wysyłał dane pomiarowe co 80 ms, korzystając z protokołu UDP. Po zamontowaniu wszystkich elementów i uruchomieniu niezbędnych programów agregujących dane, ruchoma przeszkoda została ustawiona w pozycji początkowej – 0,075 m od czujnika. Następnie zapis serii pomiarów został wyzwolony przypisanym klawiszem, rozpoczynając zapis 40 pomiarów w równych odstępach czasu (co 300 ms). Po zapisaniu pojedynczej serii pomiarów, przeszkoda była przesuwana na szynach, a następnie uruchamiano kolejną serię zapisów. Pełny test wykonano w zakresie 0,075–2,25 m, gdzie od 0,075 m do 0,135 m przeszkodę przesuwano co 0,02 m, a w zakresie od 0,135 m do 2,25 m co 0,05 m. Dla czujników microscan3 i RPLiDAR-ów przeszkodę w punkcie początkowym ustawiono odpowiednio w odległości 0,1 m oraz 0,15 m od nich, a następnie przesuwano ją co 0,05 m.

Kolejne podrozdziały przedstawiają wyniki eksperymentu mającego na celu weryfikację jakości pomiarów czujników odległości. Każdy z nich zawiera charakterystykę pomiarów, wykres reszt oraz obliczenia średniej i odchylenia standardowego dla danego czujnika.


Na początku każdego z kolejnych podrozdziałów znajduje się rysunek oraz tabela prezentujące zestaw informacji dotyczący charakterystyki pomiarowej danego czujnika. Na lewym górnym wykresie każdego rysunku znajdują się pomiary odległości wykonane przez dany czujnik wraz z pomiarami referencyjnymi. Na lewym dolnym wykresie każdego rysunku znajdują się wartości reszt – różnice pomiędzy pomiarami odległości danego czujnika a czujnikiem referencyjnym. Na prawym górnym wykresie każdego rysunku przedstawiono średnie wartości pomiarów danego czujnika dla danej odległości referencyjnej, natomiast na prawym dolnym wykresie każdego rysunku znajdują się odchylenia standardowe pomiarów dla zbadanych odległości referencyjnych.

Tabela prezentuje zestaw obliczonych wartości statystycznych dotyczących charakterystyki pomiarowej danego czujnika. Odchylenie standardowe opisuje precyzję czujnika, natomiast wartości reszt odzwierciedlają jego dokładność pomiarową. Odchylenia standardowe obliczono dla każdej serii pomiarowej, a następnie wyznaczono wartości minimalne, maksymalne i średnie dla całego zakresu pomiarowego danego

czujnika. Różnica między wartością maksymalną a minimalną ilustruje rozrzut wyników w całym zakresie. Analogicznie wyznaczono wartości minimalne, maksymalne oraz średnie dla reszt.

DFRobot TF Mini

Rysunek 3.11 przedstawia porównanie wyników pomiarów odległości z czujnika DFRobot TF Mini z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.



Rysunek 3.11: Wyniki pomiarów odległości z czujnika DFRobot TF Mini z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.

Tabela 3.3 przedstawia wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika TF Mini.

Zgodnie z informacjami w dokumentacji czujnika TF Mini, błąd pomiaru odległości nie powinien przekraczać 0,06 m w zakresie 0,3–6 m, jednak podczas wykonanego badania osiągnął on wartość 0,114 m przy odległości 2,25 m. Z tego powodu czujnik TF Mini nie może zostać uznany za dokładny. Mimo to, spośród wszystkich testowanych czujników uzyskał on najlepszą precyzję – średnie odchylenie standardowe wynosiło 0,0011 m.


Tabela 3.3: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika TF Mini.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
TF Mini	0.0002	0.0011	0.0020	0.0018	-0.0290	0.0383	0.1140	0.0560

DFRobot TF Mini-S

Rysunek 3.12 przedstawia porównanie wyników pomiarów odległości z czujnika DFRobot TF Mini-S z wartościami referencyjnymi, wraz z odpowiadającymi im

resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.



Rysunek 3.12: Wyniki pomiarów odległości z czujnika DFRobot TF Mini-S z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.

Tabela 3.4 zawiera wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika TF Mini-S.

Zgodnie z informacjami w dokumentacji czujnika TF Mini-S, błąd pomiaru odległości nie powinien przekraczać 0,06 m w zakresie 0,3–6 m i zostało to potwierdzone w przeprowadzonych badaniach – błąd pomiarowy wahał się od 0,013 m do -0,019 m względem wartości referencyjnych. Czujnik ten charakteryzuje się stosunkowo wysoką precyzją – średnie odchylenie standardowe wynosi 0,0014 m, co jest wynikiem lepszym w porównaniu do większości testowanych czujników.

Tabela 3.4: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika TF Mini-S.


Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
TF Mini-S	0.0003	0.0014	0.0026	0.0023	-0.0190	-0.0055	0.0130	0.0072

HC-SR04

Rysunek 3.13 przedstawia porównanie wyników pomiarów odległości z czujnika HC-SR04 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.

Tabela 3.5 przedstawia wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika HC-SR04.

Zgodnie z informacjami w dokumentacji czujnika HC-SR04, błąd pomiaru nie powinien przekraczać 1% mierzonej odległości i zostało to potwierdzone badaniami. Maksymalny błąd pomiaru w testowanym zakresie do 2,25 m wyniósł 0,0219 m.



Rysunek 3.13: Wyniki pomiarów odległości z czujnika HC-SR04 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.


Czujnik ten charakteryzuje się stosunkowo niskim błędem pomiarowym oraz odchyleniem standardowym w zakresie do 0,5 m. Poza tym zakresem HC-SR04 wykazuje największy (spośród testowanych czujników) rozrzut między minimalnym a maksymalnym odchyleniem standardowym, który zwiększa się wraz z odległością. Ze względu na występujące błędy pomiarowe oraz brak odpowiedniej precyzji, czujnik HC-SR04 nie może zostać uznany za dokładny ani precyzyjny w zakresie powyżej 0,5 m bez zastosowania odpowiednich metod kalibracji i filtracji.

Tabela 3.5: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika HC-SR04.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
HC-SR04	0.0001	0.0042	0.0099	0.0098	-0.0203	-0.0062	0.0219	0.0100

DFRobot URM37 v5

Rysunek 3.14 przedstawia porównanie wyników pomiarów odległości z czujnika DFRobot URM37 v5 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.



Rysunek 3.14: Wyniki pomiarów odległości z czujnika URM37 v5 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.

Tabela 3.6 zawiera wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika URM37 v5.


Zgodnie z informacjami w dokumentacji, błąd pomiarowy sensora URM37 v5 nie powinien przekraczać 1% mierzonej odległości. Po przeprowadzeniu badań stwierdzono, że niektóre błędy pomiarowe w zakresie do 2,25 m osiągnęły wartość 0,03 m, natomiast większość pomiarów utrzymywała się na poziomie 0,02 m. Sensor charakteryzuje się niskimi wartościami odchylenia standardowego do odległości około 1,7 m, gdzie poza tym zakresem wartości reszt ulegają zmianie z 0,02 m na 0,01 m. Wszystkie reszty przyjmowały ujemne wartości i były do siebie zbliżone.

Tabela 3.6: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika URM37v5.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
URM37 v5	0	0.0004	0.0045	0.0045	-0.0300	-0.0168	-0.0060	0.0177

RPLiDAR A1

Rysunek 3.15 przedstawia porównanie wyników pomiarów odległości z czujnika RPLiDAR A1 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.



Rysunek 3.15: Wyniki pomiarów odległości z czujnika RPLiDAR A1 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.

Tabela 3.7 zawiera wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RPLiDAR A1.


Zgodnie z informacjami w dokumentacji producenta, błąd pomiarowy nie powinien przekroczyć 1% mierzonej odległości w zakresie 0,15–12 m. W praktyce maksymalny błąd osiągnął -0,0204 m przy odległości 2 m, jednak był to pojedynczy punkt dla którego odchylenie standardowe wynosiło 0,005 m. Obliczona wartość RMSE dla reszt wyniosła 0,0079 m, co jest dobrym wynikiem biorąc pod uwagę, że jest to jeden z tańszych czujników.

Tabela 3.7: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RPLiDAR A1.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
RPLiDAR A1	0.0002	0.0022	0.0053	0.0051	-0.0204	-0.0063	0.0083	0.0079

RPLiDAR A2

Rysunek 3.16 przedstawia porównanie wyników pomiarów odległości z czujnika RPLiDAR A2 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.



Rysunek 3.16: Wyniki pomiarów odległości z czujnika RPLiDAR A2 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.


Tabela 3.8 prezentuje wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RPLidar A2. Według dokumentacji producenta, błąd pomiarowy nie powinien przekraczać 1% mierzonej odległości w zakresie 0,15–16 m. Testy wykazały, że sensor spełnia ten warunek. RMSE reszt wyniosło 0,0064 m. Sensor ten charakteryzuje się również wysoką precyzją pomiarową, ponieważ średnia wartość odchylenia standardowego wyniosła jedynie 0,0012 m.

Tabela 3.8: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RPLidar A2.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
RPLidar A2	0	0.0012	0.0020	0.0020	-0.0124	-0.0059	0.0018	0.0064


Leuze RSL 425 XL

Rysunek 3.17 przedstawia porównanie wyników pomiarów odległości z czujnika Leuze RSL425 XL z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.




Rysunek 3.17: Wyniki pomiarów odległości z czujnika Leuze RSL425 XL z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.

Ze względu na duże błędy w początkowym zakresie pomiarowym sensora Leuze RSL425 XL, dane do analizy zostały ograniczone – pominięto pierwsze dwie serie pomiarowe. Rysunek 3.18 pokazuje, że pomiar wykonany dla bliższej odległości zwracał większe wartości niż pomiar dla dalszej odległości. Rysunek 3.19 przedstawia ten sam problem z perspektywy reszt dzielonych na odcinki.



Rysunek 3.18: Leuze RSL425 XL - błędy i nieliniowość pomiarów odległości.



Rysunek 3.19: Leuze RSL425 XL - błędy i nieliniowość pomiarów odległości widoczna na odcinkach reszt.

Tabela 3.9 zawiera wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika Leuze RSL425 XL.


Zgodnie z dokumentacją producenta, błąd pomiarowy sensora Leuze RSL425 XL nie powinien przekraczać 0,02 m w zakresie 0,05–50 m, jednak w praktyce (tab. 3.9) osiągnął maksymalnie -0,052 m przy odległości 2,25 m. Wartość RMSE dla reszt wyniosła 0,0218 m. Ze względu na tę wartość błędu pomiarowego oraz średnie odchylenie standardowe równe 0,0064 m, sensor Leuze RSL425 XL nie może być uznany ani za dokładny, ani za precyzyjny.

Tabela 3.9: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RSL425 XL.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
RSL425 XL	0.0047	0.0064	0.0081	0.0034	-0.0520	-0.0200	0.0087	0.0218

Sick microscan3

Rysunek 3.20 przedstawia porównanie wyników pomiarów odległości z czujnika Sick microscan3 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.



Rysunek 3.20: Wyniki pomiarów odległości z czujnika Sick microscan3 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.

Tabela 3.10 zawiera wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika SICK microScan3.


Według dokumentacji producenta, błąd pomiarowy SICK microScan3 nie powinien przekraczać 0,025 m w zakresie 0,1–64 m. Podczas badań największy błąd osiągnął wartość -0,0285 m przy odległości 2,20 m. Wartość RMSE reszt wyniosła 0.0124 m, co jest lepszym wynikiem niż w przypadku poprzedniego skanera przemysłowego, Leuze RSL425 XL.

Tabela 3.10: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika microScan3.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
microScan3	0.0017	0.0025	0.0038	0.0021	-0.0285	-0.0114	0.0009	0.0124

3.2.1 Podsumowanie dokładności oraz precyzji zbadanych czujników odległości

Rysunek 3.21 przedstawia wyniki pomiarów odległości wykonanych przez badane czujniki 1D, natomiast rys. 3.22 przedstawia wyniki pomiarów odległości wykonanych przez badane czujniki typu LiDAR 2D. Na górnym wykresie każdego z rysunków znajdują się pomiary odległości nieskalibrowanych sensorów oraz sensora referencyjnego. Na dolnym wykresie każdego z rysunków pokazano różnice pomiędzy pomiarami odległości nieskalibrowanych sensorów a pomiarem referencyjnym.



Rysunek 3.21: Zestawienie pomiarów odległości oraz reszt badanych czujników 1D.


Tabele 3.11 oraz 3.12 zawierają dodatkowe informacje dotyczące jakości pomiarów odległości poszczególnych sensorów. Odchylenie standardowe charakteryzuje precyzję sensora, natomiast reszty odzwierciedlają jego dokładność. Dla każdej serii pomiarowej obliczono odchylenie standardowe, następnie dla całego zakresu pomiarowego wyznaczono wartości minimalne, maksymalne i średnie. Różnica między skrajnymi wartościami odchylenia standardowego obrazuje rozrzut pomiarów. Analogiczną analizę przeprowadzono dla reszt.

Najbardziej precyzyjnym czujnikiem 1D, zgodnie z danymi z tabeli 3.11, jest LiDAR TF Mini, który charakteryzuje się najmniejszym średnim odchyleniem standardowym (0,0011 m) oraz najmniejszym rozrzutem pomiarów (0,0018 m). Jednakże TF Mini wykazuje zarazem najwyższą wartość błędu RMSE (0,056 m), co świadczy o najniższej dokładności spośród testowanych czujników.

Najmniejszą precyzję wykazuje czujnik ultradźwiękowy HC-SR04, który charakteryzuje się największym średnim odchyleniem standardowym (0,0042 m) oraz największym rozrzutem pomiarów (0,0098 m). Stosunkowo najlepsze parametry charakterystyki pomiarowej posiada czujnik TF Mini-S, który cechuje się niskim średnim odchyleniem standardowym (0,0014 m), niewielkim rozrzutem (0,0023 m) oraz najniższym błędem RMSE (0,0072 m). Niską precyzję można poprawić za pomocą algorytmów filtracji, a ograniczoną dokładność skorygować poprzez wykorzystanie metod kalibracji.

Tabela 3.11: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujników 1D.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
TF Mini	0.0002	0.0011	0.0020	0.0018	-0.0290	0.0383	0.1140	0.0560
TF Mini-S	0.0003	0.0014	0.0026	0.0023	-0.0190	-0.0055	0.0130	0.0072
HC-SR04	0.0001	0.0042	0.0099	0.0098	-0.0203	-0.0062	0.0219	0.0100
URM37 v5	0	0.0004	0.0045	0.0045	-0.0300	-0.0168	-0.0060	0.0177



Rysunek 3.22: Zestawienie pomiarów odległości oraz reszt badanych czujników 2D.

Według danych zawartych w tab. 3.12, najbardziej precyzyjnym i dokładnym czujnikiem spośród czujników 2D jest RPLidar A2 – jego RMSE wynosi 0,0064 m, a średnie odchylenie standardowe to 0,0012 m. Nieco gorszą precyzję (0,0022 m) i dokładność (0,0079 m) posiada RPLidar A1. Najlepszym z testowanych przemysłowych skanerów laserowych 2D jest SICK microScan3, którego dokładność wynosi 0,0124 m. Jest to o 0,0094 m lepszy wynik niż dokładność sensora Leuze RSL425 XL (0,0218 m). SICK microScan3 charakteryzuje się również większą precyzją (0,0025 m) w porównaniu do Leuze RSL425 XL (0,0063 m).

Tabela 3.12: Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujników 2D.

Model czujnika	STDEV [m]				Reszty [m]			
	Min.	Śred.	Max.	Max. - Min.	Min.	Śred.	Max.	RMSE
RSL425 XL	0.0047	0.0064	0.0081	0.0034	-0.0520	-0.0200	0.0087	0.022
microScan3	0.0017	0.0025	0.0038	0.0021	-0.0285	-0.0114	0.0009	0.0124
RPLidar A1	0.0002	0.0022	0.0053	0.0051	-0.0204	-0.0063	0.0083	0.0079
RPLidar A2	0	0.0012	0.0020	0.0020	-0.0124	-0.0059	0.0018	0.0064

Rozdział 4

Kalibracja czujników odległości

Aby zwiększyć dokładność pomiarów z czujników, konieczne jest przeprowadzenie ich kalibracji. Kalibracja to proces porównania wyników pomiarów oraz ich dostosowania do wartości rzeczywistych. Metody kalibracji czujników różnią się od siebie i są zależne od typu czujnika i dostarczanych przez niego danych. Czujniki odległości do procesu kalibracji wymagają innego czujnika odległości dostarczającego pomiarów referencyjnych lub przestrzeni z serią przeszkód, do których odległość jest znana.

Kalibrację czujników odległości należy rozpocząć od precyzyjnego wyrównania czujników (referencyjnego oraz poddawanego kalibracji) względem siebie oraz względem obiektu, na który będą wskazywały. Następnie należy wykonać serię pomiarów dla różnych odległości. Mając dane z pomiarów odległości, można przejść do kolejnego kroku kalibracji – wyznaczenia linii trendu (dopasowania krzywej do uzyskanych pomiarów odległości).

4.1 Metody kalibracji statystycznej

W ramach pracy doktorskiej przeprowadzono badania metod kalibracji dla wszystkich opisanych w rozdziale 3.2 czujników odległości jednowiązkowych oraz obrotowych typu LiDAR 2D.

Zaproponowane metody kalibracji pozwalają na podział zakresu pomiarowego danego czujnika na odcinki na podstawie wyznaczenia punktów minimalnych i maksymalnych reszt (błędów) czujnika. Dla każdego wyznaczonego odcinka wyszukiwane są następnie najniższe wartości pierwiastka ze średniego błędu kwadratowego (ang. root mean square error - RMSE) dla wielomianu określonego stopnia (badania przeprowadzono w zakresie od 1 do 4 stopnia). Wynikiem kalibracji jest zestaw funkcji kalibracyjnych.

Takie podejście umożliwia uzyskanie możliwie najmniejszego błędu pomiarowego dla danego odcinka pomiarowego ze względu na zdolność metody kalibracji do dopasowywania się do charakterystyki pomiarowej czujnika. W rezultacie możliwe jest uzyskanie jak największej dokładności pomiarowej danego czujnika w zakresie pomiarowym poddanym kalibracji.

Opracowane metody pozwalają na uzyskanie większej dokładności niż w przypadku wyznaczenia wielomianu dla całego zakresu pomiarowego (rozdział 4.1.1) lub jego podziału na 2 lub 3 odcinki wynikające z charakterystyki danego czujnika.

Proponowane rozwiązania umożliwiają kalibrację całej partii czujników lub pojedynczego egzemplarza, jednak czujniki z różnych partii produkcyjnych mogą wykazywać drobne różnice w wynikach pomiarów odległości.

Ze względu na konieczność użycia wielu funkcji wielomianowych w celu obliczenia wartości korekt w skalibrowanym zakresie, wskazane jest tabelaryczne zestawienie wyników kalibracji (poprzez utworzenie tabeli i powiązanie pomiarów odległości z wartościami odpowiadających im korekt). Takie podejście pozwala na szybkie działanie kalibracji, zwłaszcza w systemach nieposiadających dużej mocy obliczeniowej. Dodatkowo umożliwia ono zastosowanie niskokosztowych czujników w rozwiązaniach IoT, AGV wymagających dobrej jakości pomiarów.

Aproksymacja krzywej (ang. curve fitting) [60] [3] [44] to proces dopasowywania funkcji do danych pomiarowych. Wynikiem aproksymacji krzywej jest funkcja wraz z parametrami opisującymi trend w danych. Przed rozpoczęciem procesu dopasowywania należy wybrać model (np. wielomianowy, wykładniczy, potęgowy), który najlepiej odpowiada przebiegowi danych.

Dopasowanie polega zwykle na minimalizacji sumy kwadratów różnic między wartościami przewidywanymi przez model a wartościami rzeczywistymi, zgodnie z metodą najmniejszych kwadratów. Po dopasowaniu funkcji do danych należy sprawdzić jakość dopasowania, w tym celu można obliczyć wartość pierwiastka ze średniego błędu kwadratowego (RMSE).

Aby wykonać dokładną kalibrację czujnika, konieczne są dokładne pomiary, dlatego bardzo istotne jest przeprowadzenie serii pomiarów odległości z dużą starannością, w równych odstępach w całym zakresie poddawanych kalibracji.

4.1.1 Kalibracja jednosekcyjna

Jedną z powszechnie stosowanych metod kalibracji czujników odległości jest podejście, w którym cały zestaw danych z czujnika analizowany jest jednocześnie.

Metoda ta składa się z następujących kroków:

1. Dopasowanie krzywej do pomiarów czujnika referencyjnego.
2. Ocena jakości dopasowania krzywej do pomiarów czujnika referencyjnego.
3. Dopasowanie krzywej do pomiarów czujnika poddawanego kalibracji.
4. Ocena jakości dopasowania krzywej do pomiarów czujnika poddawanego kalibracji.
5. Wyznaczenie różnic pomiędzy referencyjną linią regresji a linią regresji czujnika poddawanego kalibracji - obliczenie reszt (ang. residuals).
6. Dopasowanie krzywej do reszt obliczonych w kroku 5.
7. Ocena jakości końcowego dopasowania krzywej.

Powyższe kroki umożliwiają jednoczesne dopasowanie krzywej do całego zakresu danych pomiarowych, a wynikiem końcowym jest pojedyncza funkcja kalibracyjna. Jednak końcowa dokładność oraz precyzja zależy od jakości danych dostarczanych przez nieskalibrowany czujnik.

4.1.2 Adaptacyjna kalibracja

Dla danych pomiarowych z płynnymi przejściami metoda jednosekcyjna może dawać zadowalające wyniki, ale jeśli dane zawierają gwałtowne, skokowe zmiany w charakterystyce pomiarowej, lepszym rozwiązaniem może być podział danych na

odcinki i zastosowanie metody adaptacyjnej kalibracji (ang. Adaptive Calibration Method - ACM).

Adaptacyjna metoda kalibracji czujnika składa się z następujących kroków:

1. Dopasowanie krzywej do pomiarów czujnika referencyjnego.
2. Ocena jakości dopasowania krzywej do pomiarów czujnika referencyjnego.
3. Uśrednienie wszystkich serii pomiarowych czujnika poddawanego kalibracji.
4. Wyznaczenie różnic pomiędzy referencyjną linią regresji a punktami średnimi czujnika poddawanego kalibracji z kroku 3 - obliczenie reszt (ang. residuals).
5. Wyznaczenie punktów minimalnych i maksymalnych w danych z kroku 4 oraz określenie odcinków malejących i rosnących.
6. Przeprowadzenie jednosekcyjnej kalibracji dla każdego z wyznaczonych w kroku 5 odcinków.

Jeśli wartość RMSE dopasowania krzywej w którymkolwiek etapie oceny jakości nie jest zadowalająca, należy zwiększyć stopień dopasowywanej funkcji regresji lub zmienić jej model, a następnie powtórzyć proces dopasowania.

Celem procesu kalibracji jest powiązanie błędu pomiaru odległości danego czujnika z rejestrowaną odległością. W ten sposób można wyznaczyć funkcję kalibracyjną lub zestaw funkcji kalibracyjnych, które opisują charakterystykę pomiarową sensora i umożliwiają korektę jego pomiarów w skalibrowanych odcinkach pomiarowych.

Po przeprowadzeniu kalibracji, poprawny pomiar odległości może być uzyskany poprzez przekazanie wartości pomiaru do funkcji kalibracyjnej i odjęcie wyniku funkcji od przekazanej wartości (wzór 4.1).

$$m_c = m_r - f_c(m_r) \quad (4.1)$$

gdzie:

- m_c – pomiar skalibrowany,
- m_r – pomiar surowy,
- f_c – funkcja kalibracyjna z parametrami dla danego przedziału.

4.1.3 Adaptacyjna kalibracja z filtracją

Metoda MSCwMF (Multi-Section Calibration with Median Filtration) zawęży rozrzut pomiarów czujnika oraz dopasowuje zestaw funkcji wielomianowych do danych pomiarowych w celu odzwierciedlenia charakterystyki pomiarów i dokładnego powiązania błędu pomiaru z rejestrowaną przez czujnik odległością.

Metoda składa się z następujących kroków:

1. Filtrowanie surowych pomiarów przy użyciu filtracji medianowej (MF) o określonej szerokości okna.
2. Obliczenie średnich wartości z każdej serii pomiarowej sensora referencyjnego i sensora poddawanego kalibracji.

3. Obliczenie reszt – różnic pomiędzy czujnikiem referencyjnym a czujnikiem kalibrowanym.
4. Wyszukiwanie lokalnych minimów i maksimów reszt w celu określenia odcinków rosnących i malejących.
5. Dla każdego wyznaczonego odcinka:
 - (a) Dopasowanie krzywej do pomiarów czujnika referencyjnego.
 - (b) Ocena skuteczności dopasowania do danych czujnika referencyjnego.
 - (c) Dopasowanie krzywej do pomiarów czujnika kalibrowanego.
 - (d) Ocena skuteczności dopasowania do danych czujnika kalibrowanego.
 - (e) Obliczenie reszt – różnic pomiędzy linią regresji referencyjnej a dopasowaną krzywą czujnika kalibrowanego.
 - (f) Dopasowanie krzywej do reszt.
 - (g) Ocena jakości dopasowania krzywej do reszt.

Wynik: Zestaw funkcji kalibracyjnych dla danej szerokości okna MF – po jednej dla każdego wyznaczonego odcinka.

Jeśli wartość RMSE podczas oceny dopasowania nie jest zadowalająca, należy zwiększyć stopień dopasowywanej funkcji regresji lub zmienić model regresji, a następnie powtórzyć etap dopasowania.

Wynikiem powyższego algorytmu jest zestaw funkcji kalibracyjnych, po jednej dla każdego wyznaczonego odcinka. Funkcje te można stosować dla konkretnych zakresów lub utworzyć tabelę korekt dla całego skalibrowanego zakresu czujnika. Wartości korekcyjne są powiązane z szerokością okna medianowego filtru. MF jest wymagany dla tej samej szerokości okna, która była użyta podczas procesu kalibracji, zanim możliwe będzie zastosowanie wartości korekcyjnych. Metoda ta pozwala na poprawę zarówno dokładności, jak i precyzji pomiarów czujnika odległości. Wzór 4.2 przedstawia sposób obliczania pomiaru skalibrowanego dla metody opisanej w niniejszej sekcji.

$$m_c = m_r - f_c(\text{med}(m_r)) \quad (4.2)$$

gdzie:

- m_c – pomiar skalibrowany,
- m_r – pomiar surowy,
- f_c – funkcja kalibracyjna z parametrami dla danego przedziału,
- med – funkcja filtracji medianowej o zadanej szerokości okna.

4.1.4 Implementacja metod kalibracji

Metody kalibracji opisane w niniejszym rozdziale zostały zaimplementowane w języku programowania Python wersja 3.10.12 64-bit. Do realizacji rozwiązania użyto bibliotek `scipy`, `numpy` oraz `matplotlib`. Poniżej opisano szczegółowo poszczególne kroki implementacji, w postaci komentarza do załączonych listingów kodu.

Na początku wczytywane są dane pomiarowe z eksperymentów, a następnie tworzona jest struktura słownikowa, która przechowuje pomiary odległości z danego czujnika (Listing 4.1).

Listing 4.1: Wczytywanie danych i tworzenie struktur zbioru danych.

```
dataLines = getAllLines('Mini_miniS_EchoUltra.csv')
gatheredData = {}
sensorNames = getSensorNames(dataLines[0])
initializeDictionary(sensorNames, gatheredData)
fetchData(dataLines, gatheredData, sensorNames)
```

Dane pomiarowe w pliku .csv zapisane są w formacie pokazanym w Listingu 4.2 – pierwszy wiersz zawiera nazwy czujników, a kolejne wiersze zawierają pomiary (w metrach) wykonane przez poszczególne czujniki. Wszystkie wartości są oddzielone średnikiem.

Listing 4.2: Format danych w pliku CSV.

```
Leica;MiniLidar;MiniLidarS;EchoUltrasound
0.055;0.367;0.082;0.05933
0.055;0.367;0.084;0.05933
```

Po załadowaniu danych możliwe jest wykorzystanie jednej z przygotowanych funkcji metod kalibracyjnych. Pierwsza z nich dopasowuje linię regresji do całego zestawu danych przekazanego do funkcji (Listing 4.3).

Listing 4.3: Deklaracja funkcji i przykład użycia metody kalibracji dla pojedynczego odcinka.

```
def curveFittingAndPlot(sensorName, y_sensorData,
    x_refSensData, y_refSensDat,
    x_refGrouped, y_refGrouped,
    fitDeg_from, fitDeg_to, resDeg_from, resDeg_to, plot = True)

curveFittingAndPlot('TF Mini', gatheredData['MiniLidar'][320:],
    gatheredData['Leica'][320:], gatheredData['Leica'][320:],
    xy_ref_data[8:], xy_ref_data[8:],
    1, 7, 1, 7)
```

Pierwszym argumentem przekazywanym do funkcji `curveFittingAndPlot` jest nazwa czujnika, wykorzystywana przy generowaniu wykresów. Następnie przekazywane są: dane pomiarowe kalibrowanego czujnika, dane referencyjne dla osi X i Y, średnia z danych referencyjnych służąca do generowania punktów dopasowania do pomiarów czujnika. Kolejne cztery argumenty to granice stopni funkcji dopasowywanych do danych pomiarowych oraz do reszt. Ostatni parametr kontroluje, czy wykresy z dopasowanymi funkcjami mają być wyświetlane (domyślnie ustawiony na `True`). Funkcja zwraca obiekt zawierający wszystkie modele funkcji dopasowanych wraz z wartościami RMSE dopasowania, a także wypisuje najlepsze z nich.

Druga funkcja kalibracyjna dzieli dane pomiarowe na odcinki (bazując na minimach i maksimach reszt) i dopasowuje linie regresji do każdego z nich (Listing 4.4).

Listing 4.4: Deklaracja funkcji i przykład użycia metody adaptacyjnej kalibracji.

```
def curveFittingAndPlotRanges(sensorName_plot, sensorName, refSensorName,
    dataBank, numOfElemPerSerie, dataOffset,
    fitDeg_from, fitDeg_to, resDeg_from, resDeg_to,
    range_from = 0, range_to = -1, plot = True):

curveFittingAndPlotRanges('TF Mini', 'MiniLidar', 'Leica',
    gatheredData, 40, 320,
```

```
1, 4, 1, 4,  
0, plot = False)
```

Pierwszym argumentem funkcji `curveFittingAndPlotRanges` jest nazwa czujnika wykorzystywana przy generowaniu wykresów. Następnie przekazywane są: nazwa czujnika kalibrowanego, nazwa czujnika referencyjnego, zbiór danych, z którego będą pobierane dane, liczba pomiarów w pojedynczej serii oraz offset, który należy zastosować do pomiarów. Kolejno przekazywane są granice stopni dopasowania do danych pomiarowych oraz do reszt. Argumenty `range_from` oraz `range_to` odnoszą się do numerów odcinków, które mają być kalibrowane - podanie wartości 0 w `range_from` oznacza, że zdefiniowana funkcja rozpocznie podział na odcinki i kalibrację od początku danych pomiarowych. Ostatni argument określa, czy mają być wyświetlane wykresy dopasowania dla każdego odcinka reszt (domyślnie `True`), czy jedynie końcowe wyniki zawierające wszystkie obliczone funkcje kalibracji (przekazując `False`). Funkcja zwraca wyniki dopasowania funkcji wielomianowych dla każdego odcinka oraz wypisuje najlepsze z nich.

4.1.5 Przykłady wykorzystania metody kalibracji jednosekcyjnej

W niniejszym podrozdziale przedstawiono przykłady zastosowania metody kalibracji jednosekcyjnej wraz z informacjami dotyczącymi poziomu poprawy dokładności pomiarów po kalibracji.


Czujniki odległości typu 1D

Metoda kalibracji jednosekcyjnej opisana w podrozdziale 4.1.1 została zastosowana do pomiarów odległości wykonywanych przez czujnik TF Mini. Wyniki tej metody dla różnych stopni regresji wielomianowej pokazano na rysunkach od 4.1 do 4.7.


Na górnym wykresie każdego z rysunków przedstawiono pomiary odległości z czujnika TF Mini wraz z pomiarami referencyjnymi oraz dopasowaną krzywą regresji. Dodatkowo przedstawiono wynik dopasowania krzywej do pomiarów z czujnika TF Mini - regresję wielomianową o określonym stopniu.

Na dolnym wykresie każdego z rysunków znajdują się różnice pomiędzy krzywą regresji czujnika TF Mini a referencyjną krzywą regresji. Punkty te przedstawiają zależność pomiędzy wartością reszty a pomiarem odległości z czujnika TF Mini. Do tych danych również dopasowano linię regresji wielomianowej o określonym stopniu.


Jak można zaobserwować, dokładność dopasowania wzrasta wraz ze stopniem dopasowywanego wielomianu. Im wyższy stopień wielomianu, tym więcej cech charakterystycznych czujnika można uchwycić.




Rysunek 4.1: Aproksymacja wielomianowa 1-go stopnia w kalibracji jednosekcyjnej - TF Mini.




Rysunek 4.2: Aproksymacja wielomianowa 2-go stopnia w kalibracji jednosekcyjnej - TF Mini.




Rysunek 4.3: Aproksymacja wielomianowa 3-go stopnia w kalibracji jednosekcyjnej - TF Mini.




Rysunek 4.4: Aproksymacja wielomianowa 4-go stopnia w kalibracji jednosekcyjnej - TF Mini.



Rysunek 4.5: Aproksymacja wielomianowa 5-go stopnia w kalibracji jednosekcyjnej - TF Mini.




Rysunek 4.6: Aproksymacja wielomianowa 6-go stopnia w kalibracji jednosekcyjnej - TF Mini.




Rysunek 4.7: Aproksymacja wielomianowa 7-go stopnia w kalibracji jednosekcyjnej - TF Mini.

Rysunek 4.8 przedstawia wartości RMSE dopasowania krzywej do pomiarów odległości (górne części rysunków 4.1 – 4.7) przy różnych stopniach regresji wielomianowej. Najniższą wartość RMSE uzyskano dla wielomianu 7. stopnia i wynosi ona 0,0098 m.




Rysunek 4.8: Wartości RMSE aproksymacji pomiarów odległości w kalibracji jednosekcyjnej - TF Mini

Rysunek 4.9 przedstawia wartości RMSE dopasowania krzywej do reszt (dolne wykresy rysunków 4.1 – 4.7) przy różnych stopniach regresji wielomianowej. Poszczególne kolory reprezentują określony stopień regresji wielomianowej, dopasowanej do pomiarów odległości.



Rysunek 4.9: Wartości RMSE aproksymacji reszt w kalibracji jednosekcyjnej - TF Mini

Końcowa dokładność kalibracji zależy od sumy obu wartości RMSE wyznaczonych po dopasowaniach. Na rysunku 4.10 przedstawiono sumę wartości RMSE – RMSE dopasowania do pomiarów odległości oraz RMSE dopasowania do reszt. Najlepszą dokładność dopasowania, mierzoną wartością RMSE, w kalibracji jednosekcyjnej dla czujnika TF Mini uzyskano przy parze funkcji regresji wielomianowej 7. stopnia.



Rysunek 4.10: Suma wartości RMSE aproksymacji pomiarów odległości oraz reszt w kalibracji jednosekcyjnej - TF Mini

Tabela 4.1 przedstawia parę najlepiej dopasowanych funkcji regresji wielomianowej wraz z parametrami dla tych funkcji. Parametry funkcji dopasowanej do reszt mogą być wykorzystane do wyznaczenia błędu pomiarowego (a tym samym korekty) dla danej odległości oraz do kalibracji pomiarów z czujnika TF Mini.

Tabela 4.2 pokazuje porównanie dokładności pomiarów przed i po zastosowaniu kalibracji jednosekcyjnej dla wszystkich badanych czujników typu 1D. Dokładność pomiaru odległości czujnika TF Mini wzrosła o 81,58%.

Tabela 4.1: Wynik kalibracji jednosekcyjnej - para funkcji wielomianowych wraz z parametrami dla czujnika TF Mini.

	Zakres [m]		Stopień wielomianu	Parametry wielomianu							
	Od	Do		a	b	c	d	e	f	g	h
Odl. ref.	0,3260	2,2500	7	-0.3350	2.7996	-9.3017	15.6313	-14.0607	6.7788	-0.7565	0.2310
Odl. czujnika	0,3632	2,3514	7	-0.1358	1.0890	-3.3118	4.6201	-2.6719	0.2060	0.1818	0.0098

Tabela 4.2: Porównanie błędów RMSE przed i po kalibracji jednosekcyjnej dla wszystkich badanych czujników odległości typu 1D.

Czujnik	Kalibracja jednosekcyjna		
	RMSE [m]		Procent poprawy [%]
	Przed kalibracją	Po kalibracji	
TF Mini	0.0560	0.0103	81.58
TF Mini-S	0.0072	0.0025	65.83
HC-SR04	0.0100	0.0054	46.28
URM37 v5	0.0177	0.0035	80.38

Chociaż dokładność pomiarów może zostać znacząco zwiększona dzięki kalibracji jednosekcyjnej, wciąż istnieje możliwość dalszej poprawy poprzez zastosowanie adaptacyjnej metody kalibracji.


Czujniki odległości typu LiDAR 2D

Metoda kalibracji jednosekcyjnej opisana w podrozdziale 4.1.1 została również wykorzystana w celu kalibracji pomiarów odległości czujnika SICK microScan3. Wyniki tej metody dla różnych stopni regresji wielomianowej zostały przedstawione na rysunkach od 4.11 do 4.17.


Na górnym wykresie każdego z rysunków zaprezentowano pomiary odległości z czujnika SICK microScan3, wraz z pomiarami referencyjnymi oraz dopasowaną krzywą regresji. Dodatkowo przedstawiono wynik dopasowania krzywej do pomiarów z czujnika SICK microScan3 – regresję wielomianową o określonym stopniu.

Na dolnym wykresie każdego z rysunków znajdują się różnice pomiędzy krzywą regresji czujnika SICK microScan3 a referencyjną krzywą regresji. Punkty te przedstawiają zależność pomiędzy wartością reszty a pomiarem odległości z czujnika microScan3. Do tych danych również dopasowano krzywą regresji wielomianowej o określonym stopniu.


Jak można zauważyć, dokładność dopasowania wzrasta wraz ze stopniem regresji wielomianowej. Im wyższy stopień wielomianu dopasowanego do pomiarów, tym więcej cech charakterystyki czujnika można wychwycić.




Rysunek 4.11: Aproksymacja wielomianowa 1-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.




Rysunek 4.12: Aproksymacja wielomianowa 2-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.




Rysunek 4.13: Aproksymacja wielomianowa 3-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.




Rysunek 4.14: Aproksymacja wielomianowa 4-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.



Rysunek 4.15: Aproksymacja wielomianowa 5-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.




Rysunek 4.16: Aproksymacja wielomianowa 6-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.




Rysunek 4.17: Aproksymacja wielomianowa 7-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.

Rysunek 4.18 przedstawia wartości RMSE dopasowania krzywej do pomiarów odległości (górne części rysunków 4.11 – 4.17) przy różnych stopniach regresji wielomianowej. Najniższą wartość RMSE uzyskano dla wielomianu 7. stopnia i wyniosła ona 0,00304 m.




Rysunek 4.18: Wartości RMSE aproksymacji pomiarów odległości w kalibracji jednosekcyjnej - Sick microScan3.

Rysunek 4.19 przedstawia wartości RMSE dopasowania krzywej do reszt (dolne wykresy rysunków 4.11 – 4.17) dla różnych stopni wielomianów regresji. Poszczególne kolory odpowiadają określonej stopniowi regresji wielomianowej, dopasowanej do pomiarów odległości.



Rysunek 4.19: Wartości RMSE aproksymacji reszt w kalibracji jednosekcyjnej - Sick microScan3.

Końcowa dokładność kalibracji zależy od obu wartości RMSE wyliczonych po dopasowaniach. Dlatego na rysunku 4.20 przedstawiono sumę wartości RMSE – RMSE dopasowania do pomiarów odległości oraz RMSE dopasowania do reszt. Najlepszą dokładność dopasowania, mierzoną wartością RMSE, w kalibracji jednosekcyjnej dla czujnika SICK microScan3 osiągnięto przy parze funkcji regresji wielomianowej 7. stopnia.



Rysunek 4.20: Suma wartości RMSE aproksymacji pomiarów odległości oraz reszt w kalibracji jednosekcyjnej - TF Mini

Tabela 4.3 przedstawia parę najlepiej dopasowanych funkcji regresji wielomianowej wraz z parametrami tych funkcji. Parametry funkcji dopasowanej do reszt mogą posłużyć do wyznaczania błędu (a tym samym korekty) dla danej odległości oraz do kalibracji pomiarów z czujnika SICK microScan3.

Tabela 4.4 przedstawia porównanie dokładności pomiarów przed i po kalibracji jednosekcyjnej dla wszystkich badanych czujników typu 2D. Dokładność pomiarów czujnika SICK microScan3 po kalibracji jednosekcyjnej wzrosła o 75,11%.

Tabela 4.3: Wynik kalibracji jednosekcyjnej - para funkcji wielomianowych wraz z parametrami dla czujnika Sick microScan3.

	Zakres [m]		Stopień wielomianu	Parametry wielomianu							
	Od	Do		a	b	c	d	e	f	g	h
Ref. odl.	0.1107	2.2382	7	0.0469	-0.3852	1.2664	-2.1387	1.9784	-0.9855	1.2373	-0.0292
Odl. czujnika	0.0980	2.2148	7	0.0484	-0.3927	1.2726	-2.1144	1.9182	-0.9330	0.2178	-0.0268

Tabela 4.4: Porównanie błędów RMSE przed i po kalibracji jednosekcyjnej dla wszystkich badanych czujników odległości typu 2D.

Czujnik	Kalibracja jednosekcyjna		
	RMSE [m]		Procent poprawy [%]
	Przed kalibracją	Po kalibracji	
microScan3	0.0124	0.0031	75.11
RSL425 XL	0.0220	0.0066	70.20
RPLidar A1	0.0079	0.0028	64.26
RPLidar A2	0.0064	0.0018	72.57


Pomimo, że dokładność pomiarów może zostać znacznie zwiększona dzięki kalibracji jednosekcyjnej, wciąż istnieje możliwość dalszej poprawy poprzez zastosowanie metody kalibracji adaptacyjnej.

4.1.6 Przykłady wykorzystania metody kalibracji adaptacyjnej

W niniejszym podrozdziale przedstawiono przykłady zastosowania metody kalibracji adaptacyjnej wraz z informacją o stopniu poprawy dokładności pomiarów po jej zastosowaniu.


Czujniki odległości typu 1D

Rysunek 4.21 przedstawia reszty podzielone na odcinki na podstawie lokalnych minimów i maksimów. Reszty zostały podzielone w taki sposób, aby wyodrębnić zakresy pomiarowe wykazujące trend wzrostowy lub trend spadkowy w danych. Po podziale reszt czujnika zastosowano kolejne kroki opisane w podrozdziale 4.1.2 dotyczącym adaptacyjnej metody kalibracji.



Rysunek 4.21: Reszty podzielone na odcinki, na podstawie lokalnych minimów i maksimów - TF Mini

Rysunek 4.22 prezentuje wyniki działania adaptacyjnej metody kalibracji. Na górnym wykresie rysunku przedstawiono odcinki reszt, wygenerowane przy użyciu funkcji wielomianowych dopasowanych do poszczególnych odcinków (przedstawionych na rysunku 4.21). Na dolnym wykresie rysunku przedstawiono wartości RMSE najlepszego dopasowania do określonego odcinka.



Rysunek 4.22: Wynik kalibracji adaptacyjnej. Wykryte odcinki wraz z wartościami RMSE dopasowania - TF Mini

Tabela 4.5 prezentuje pary najlepiej dopasowanych funkcji regresji wielomianowych dla każdego odcinka wraz z parametrami tych funkcji. Parametry funkcji dopasowanej do każdego z odcinków reszt mogą posłużyć do wyznaczenia błędu (a

tym samym korekty) dla danej odległości oraz do kalibracji pomiarów z czujnika TF Mini.

Tabela 4.5: Wynik kalibracji adaptacyjnej - zestaw funkcji wielomianowych wraz z parametrami dla czujnika TF Mini.

		Zakres [m]		Stopień wielomianu	Parametry wielomianu				
		Od	Do		a	b	c	d	e
1	Ref. odl.	0.3260	0.5770	4	-3.9640	12.4334	-11.8030	5.2969	-0.4941
	Odl. czujnika	0.3643	0.5817	4	-15.9769	39.6755	-34.4515	12.4584	-1.5649
2	Ref. odl.	0.5770	0.6270	1	1.0185	-0.0060			
	Odl. czujnika	0.5816	0.6326	1	0.0182	-0.0059			
3	Ref. odl.	0.6270	0.9220	4	10.8086	-34.4677	40.8299	-20.3867	4.1894
	Odl. czujnika	0.6328	0.8974	4	17.6622	-55.6139	65.1440	-33.7471	6.5352
4	Ref. odl.	0.9220	0.9700	4	0.2618	2.9422	-2.7627	-2.5033	3.0592
	Odl. czujnika	0.8978	0.9485	1	0.0542	-0.0729			
5	Ref. odl.	0.9700	1.0200	4	-2.0419	3.6221	-2.0550	2.3048	-0.8518
	Odl. czujnika	0.9485	0.9948	1	-0.0811	0.0554			
6	Ref. odl.	1.0200	1.0700	3	-1.6186	2.2571	1.5903	-1.2579	
	Odl. czujnika	0.9948	1.0450	1	0.0040	-0.0292			
7	Ref. odl.	1.0700	1.1200	4	-1.6362	1.3412	1.6640	1.1057	-1.5415
	Odl. czujnika	1.0450	1.0938	1	-0.0230	-0.0010			
8	Ref. odl.	1.1200	1.2200	2	-12.3129	30.4822	-17.6009		
	Odl. czujnika	1.0939	1.2608	2	-3.0080	7.4841	-4.6135		
9	Ref. odl.	1.2200	1.2700	1	0.9505	0.1012			
	Odl. czujnika	1.2609	1.3084	1	-0.0521	0.1065			
10	Ref. odl.	1.2700	2.1200	4	-0.3527	2.3899	-5.9809	7.6179	-2.6987
	Odl. czujnika	1.3073	2.2174	4	-0.2506	1.7639	-4.5818	5.2667	-2.2263
11	Ref. odl.	2.1200	2.1690	1	0.9403	0.2234			
	Odl. czujnika	2.2168	2.2629	1	-0.0635	0.2375			
12	Ref. odl.	2.1690	2.2500	4	0.2238	-1.2043	2.4012	-1.4320	1.4073
	Odl. czujnika	2.2629	2.3601	2	0.5599	-2.4220	2.7074		

Tabela 4.6 przedstawia pełne porównanie obu zastosowanych metod kalibracji dla wszystkich badanych czujników odległości typu 1D. Dokładność pomiaru czujnika TF Mini po zastosowaniu metody kalibracji adaptacyjnej wzrosła do 0,0014 m, co stanowi 97,48% poprawy względem dokładności przed kalibracją (0,056 m).


W porównaniu do kalibracji jednosekcyjnej, metoda adaptacyjna poprawiła dokładność o 0,0089 m, co daje 15,9% poprawy w odniesieniu do dokładności czujnika TF Mini przed kalibracją.

Tabela 4.6: Porównanie błędów RMSE przed i po kalibracji jednosekcyjnej oraz adaptacyjnej dla wszystkich badanych czujników odległości typu 1D.

Czujnik	Kalibracja jednosekcyjna			Kalibracja adaptacyjna		Δ metod [m]	Δ metod [%]
	RMSE [m]		Procent poprawy [%]	RMSE [m]	Procent poprawy [%]		
	Przed kalibracją	Po kalibracji		Po kalibracji			
TF Mini	0.0560	0.0103	81.58	0.0014	97.48	-0.0089	15.90
TF Mini-S	0.0072	0.0025	65.83	0.0016	78.31	-0.0009	12.48
HC-SR04	0.0100	0.0054	46.28	0.0050	49.69	-0.0004	3.41
URM37 v5	0.0177	0.0035	80.38	0.0014	92.30	-0.0021	11.92

Czujniki odległości typu LiDAR 2D

Rysunek 4.23 przedstawia reszty podzielone na odcinki na podstawie lokalnych minimów i maksimów. Reszty zostały podzielone w taki sposób, aby wyodrębnić zakresy pomiarowe wykazujące trend wzrostowy lub spadkowy. Po podziale reszt zastosowano kolejne kroki adaptacyjnej metody kalibracji, opisanej w podrozdziale 4.1.2.



Rysunek 4.23: Reszty podzielone na odcinki, na podstawie lokalnych minimów i maksimów - Sick microScan3.

Rysunek 4.24 przedstawia wyniki działania adaptacyjnej metody kalibracji. Na górnym wykresie rysunku znajdują się odcinki reszt wygenerowane przy użyciu funkcji wielomianowych dopasowanych do poszczególnych odcinków (przedstawionych na rysunku 4.23). Na dolnym wykresie rysunku przedstawione są wartości RMSE najlepszego dopasowania do określonego odcinka.

Tabela 4.7 prezentuje pary najlepiej dopasowanych funkcji regresji wielomianowych dla każdego odcinka, a także parametry każdej z tych funkcji. Parametry funkcji dopasowanej do każdego odcinka reszt mogą zostać wykorzystane do wyznaczenia błędu (a tym samym korekty) dla danej odległości oraz kalibracji pomiarów z czujnika SICK microScan3.

Tabela 4.7: Wynik kalibracji adaptacyjnej - zestaw funkcji wielomianowych wraz z parametrami dla czujnika Sick.

		Zakres [m]		Stopień wielomianu	Parametry wielomianu				
		Od	Do		a	b	c	d	e
1	Ref. odl.	0.1107	0.1505	1	0.9956	-0.0106			
	Odl. czujnika	0.0996	0.1393	1	-0.0044	-0.0106			
2	Ref. odl.	0.1505	0.2501	2	0.8480	0.7072	0.0136		
	Odl. czujnika	0.1393	0.2436	2	0.7405	-0.2386	0.0076		
3	Ref. odl.	0.2501	0.3006	1	0.9342	0.0099			
	Odl. czujnika	0.2436	0.2907	1	-0.0705	0.0106			
4	Ref. odl.	0.3006	0.3502	2	1.1320	0.3862	0.0723		

	Odl. czujnika	0.2907	0.3464	1	0.1095	-0.0417			
5	Ref. odl.	0.3502	0.4003	1	0.8992	0.0315			
	Odl. czujnika	0.3464	0.3915	1	-0.1121	0.0351			
6	Ref. odl.	0.4003	0.4505	1	1.0110	-0.0132			
	Odl. czujnika	0.3915	0.4422	1	0.0108	-0.0131			
7	Ref. odl.	0.4505	0.5006	2	-2.8213	3.6240	-0.6178		
	Odl. czujnika	0.4422	0.4893	1	-0.0631	0.0196			
8	Ref. odl.	0.5006	0.5506	2	2.6612	-1.7785	0.7128		
	Odl. czujnika	0.4894	0.5403	1	0.0186	-0.0204			
9	Ref. odl.	0.5506	0.6002	3	2.0556	2.0666	-3.4232	1.4555	
	Odl. czujnika	0.5403	0.5898	1	-0.0020	-0.0092			
10	Ref. odl.	0.6002	0.6502	3	0.3753	4.1800	-4.6066	1.7677	
	Odl. czujnika	0.5898	0.6428	1	0.0570	-0.0440			
11	Ref. odl.	0.6502	0.7005	1	0.9384	0.0327			
	Odl. czujnika	0.6428	0.6900	1	-0.0657	0.0348			
12	Ref. odl.	0.7005	0.7504	1	1.0165	-0.0221			
	Odl. czujnika	0.6900	0.7408	1	0.0163	-0.0217			
13	Ref. odl.	0.7504	0.8004	2	-2.9367	5.5123	-1.7420		
	Odl. czujnika	0.7408	0.7887	1	-0.0438	0.0228			
14	Ref. odl.	0.8004	0.8502	3	1.1763	0.5360	-2.2253	1.6232	
	Odl. czujnika	0.7886	0.8416	1	0.0599	-0.0590			
15	Ref. odl.	0.8502	0.9003	1	0.9840	0.0050			
	Odl. czujnika	0.8416	0.8909	1	-0.0162	0.0051			
16	Ref. odl.	0.9003	0.9504	4	4.4140	-2.8599	-3.2164	0.3343	2.3840
	Odl. czujnika	0.8909	0.9427	1	0.0324	-0.0382			
17	Ref. odl.	0.9504	1.0504	2	0.3850	0.2029	0.4021		
	Odl. czujnika	0.9427	1.0400	2	0.4178	-0.8558	0.4278		
18	Ref. odl.	1.0504	1.1003	3	0.3823	-1.3510	2.6260	-0.6709	
	Odl. czujnika	1.0400	1.0923	1	0.0450	-0.0572			
19	Ref. odl.	1.1003	1.1503	3	-0.4185	2.4895	-3.0908	2.0366	
	Odl. czujnika	1.0923	1.1384	1	-0.0846	0.0844			
20	Ref. odl.	1.1503	1.2005	1	1.0050	-0.0177			
	Odl. czujnika	1.1384	1.1888	1	0.0050	-0.0176			
21	Ref. odl.	1.2005	1.2504	1	0.9193	0.0852			
	Odl. czujnika	1.1888	1.2347	1	-0.0877	0.0926			
22	Ref. odl.	1.2504	1.3005	1	1.1322	-0.1810			
	Odl. czujnika	1.2347	1.2914	1	0.1168	-0.1599			
23	Ref. odl.	1.3005	1.3508	4	1.0073	-1.8531	-0.8249	3.5443	-0.7283
	Odl. czujnika	1.2914	1.3406	1	-0.0239	0.0218			
24	Ref. odl.	1.3508	1.4004	1	1.0474	-0.0742			
	Odl. czujnika	1.3406	1.3925	1	0.0452	-0.0709			
25	Ref. odl.	1.4004	1.5501	3	-3.9121	17.4042	-24.8213	12.7644	
	Odl. czujnika	1.3925	1.5370	3	-4.4538	19.6709	-28.9713	14.2176	
26	Ref. odl.	1.5501	1.6004	3	0.5213	1.3828	-7.1950	7.4259	
	Odl. czujnika	1.5371	1.5895	1	0.0405	-0.0754			
27	Ref. odl.	1.6004	1.7001	4	-0.9095	2.9988	-0.1142	-6.7747	6.3980
	Odl. czujnika	1.5895	1.6884	2	-0.1345	0.4327	-0.3589		
28	Ref. odl.	1.7001	1.7508	2	-0.4427	2.5874	-1.4309		
	Odl. czujnika	1.6884	1.7421	1	0.0563	-0.1068			
29	Ref. odl.	1.7508	1.8003	1	0.9687	0.0461			
	Odl. czujnika	1.7421	1.7901	1	-0.0323	0.0476			
30	Ref. odl.	1.8003	1.9004	4	-0.1010	0.5895	-1.0531	1.4113	0.2835
	Odl. czujnika	1.7900	1.8911	2	0.1404	-0.5071	0.4477		
31	Ref. odl.	1.9004	2.1005	4	88.8780	-713.4366	2146.5731	-2868.1826	1437.5042
	Odl. czujnika	1.8911	2.0796	4	115.0959	-916.6983	2736.7930	-3629.9320	1804.7293
32	Ref. odl.	2.1005	2.1501	1	1.0106	-0.0431			
	Odl. czujnika	2.0796	2.1298	1	0.0105	-0.0427			
33	Ref. odl.	2.1501	2.2005	1	0.9296	0.1311			
	Odl. czujnika	2.1298	2.1766	1	-0.0758	0.1410			

34	Ref. odl.	2.2005	2.2382	3	1.2767	-5.1006	4.8096	2.6877	
	Odl. czujnika	2.1766	2.2156	1	0.0340	-0.0978			

Tabela 4.8 przedstawia pełne porównanie obu zastosowanych metod kalibracji dla wszystkich badanych czujników odległości typu 2D. Dokładność pomiaru czujnika SICK microScan3 po zastosowaniu adaptacyjnej metody kalibracji wzrosła do 0,0025 m, co stanowi 79,52% poprawy w stosunku do dokładności przed kalibracją (0,0124 m). W porównaniu do kalibracji jednosekcyjnej, metoda adaptacyjna zwiększyła dokładność o 0,0006 m, czyli o 4,84% względem dokładności czujnika SICK microScan3 przed kalibracją.


Tabela 4.8: Porównanie błędów RMSE przed i po kalibracji jednosekcyjnej oraz adaptacyjnej dla wszystkich badanych czujników odległości typu 2D.

Czujnik	Kalibracja jednosekcyjna			Kalibracja adaptacyjna		Δ metod [m]	Δ metod [%]
	RMSE [m]		Procent poprawy [%]	RMSE [m]	Procent		
	Przed kalibracją	Po kalibracji		Po kalibracji	poprawy [%]		
microScan3	0.0124	0.0031	75.11	0.0025	79.52	-0.0006	4.84
RSL425 XL	0.0220	0.0066	70.20	0.0065	70.35	-0.0001	0.45
RPLidar A1	0.0079	0.0028	64.26	0.0024	69.12	-0.0004	0.50
RPLidar A2	0.0064	0.0018	72.57	0.0013	79.14	-0.0005	7.81


4.1.7 Przykłady wykorzystania metody kalibracji adaptacyjnej z filtracją

Czujniki typu LiDAR 2D

W pierwszej kolejności wykonano filtrację pomiarów odległości czujnika Leuze RSL425XL. Rysunek 4.25 przedstawia wynik przed i po filtracji pomiarów odległości filtrem medianowym z oknem o szerokości 9. Wykorzystana metoda filtracji została opisana w podrozdziale 5.2.




Rysunek 4.24: Wynik kalibracji adaptacyjnej. Wykryte odcinki wraz z wartościami RMSE dopasowania - Sick microScan3



Rysunek 4.25: Błędy pomiarowe oraz odchylenia standardowe czujnika Leuze RSL425 XL, przed ((a) i (b)) i po ((c) i (d)) filtracji medianowej z oknem o szerokości 9.

Rysunek 4.26 przedstawia reszty podzielone na odcinki na podstawie lokalnych

minimów i maksimów. Reszty zostały podzielone w taki sposób, aby wyodrębnić zakresy pomiarowe wykazujące trend wzrostowy lub spadkowy. Po podziale reszt zastosowano kolejne kroki metody kalibracji opisanej w podrozdziale 4.1.3.




Rysunek 4.26: Reszty podzielone na odcinki, na podstawie lokalnych minimów i maksimów - Leuze RSL425 XL.

Rysunek 4.27 pokazuje wyniki kalibracji jednego z odcinków (trzynastego) czujnika RSL425XL. Na górnym wykresie rysunku przedstawiono pomiary odległości z czujnika RSL425 XL wraz z pomiarami referencyjnymi i krzywą regresji. Na wykresie przedstawiono również wynik dopasowania – wielomianową linię regresji czujnika RSL425 XL o określonym stopniu.

Na dolnym wykresie rysunku pokazano różnice między krzywą regresji czujnika a krzywą referencyjną. Punkty te reprezentują reszty, czyli wartość błędu dla określonego pomiaru odległości czujnika. Dodatkowo w dolnej części przedstawiono funkcje regresji wielomianowej o różnych stopniach.

Jak można zauważyć, dokładność dopasowania wzrasta wraz ze stopniem dopasowanej funkcji regresji. Im wyższy stopień dopasowanej funkcji, tym więcej cech charakterystycznych czujnika można uchwycić.




Rysunek 4.27: Aproksymacja wielomianowa 4-go stopnia, 13-go odcinka w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL.


Rysunek 4.28 przedstawia wartość RMSE dopasowania krzywej do pomiarów odległości przy różnych stopniach regresji wielomianowej. Najmniejszą wartość RMSE uzyskano przy wielomianie czwartego stopnia i wyniosła ona 0,002576 m.

Rysunek 4.29 przedstawia wartości RMSE dopasowania krzywej do reszt przy różnych stopniach regresji wielomianowej. Każda krzywa reprezentuje określony stopień regresji wielomianowej, dopasowanej do pomiarów odległości.


Ostateczna dokładność kalibracji zależy od obu wartości RMSE wyznaczonych po dopasowaniach. Dlatego na Rysunku 4.30 przedstawiono sumę wartości RMSE (wartość RMSE dopasowania do pomiarów odległości i wartość RMSE dopasowania do reszt). Najlepszą dokładność dopasowania, mierzoną wartością RMSE, dla czujnika RSL425 XL uzyskano dla pary dopasowanych wielomianów: czwartego stopnia dla pomiarów odległości i trzeciego stopnia dla reszt.



Rysunek 4.28: Wartości RMSE aproksymacji pomiarów odległości w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL.



Rysunek 4.29: Wartości RMSE aproksymacji reszt w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL.



Rysunek 4.30: Suma wartości RMSE aproksymacji pomiarów odległości oraz reszt w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL


Tabela 4.9 przedstawia parę najlepiej dopasowanych funkcji regresji wielomianowej (do pomiarów odległości i do reszt) wraz z parametrami tych funkcji. Parametry funkcji dopasowanej do reszt mogą być wykorzystane do wyznaczenia błędu (a tym samym korekty) dla danej odległości oraz do kalibracji pomiarów czujnika.

Tabela 4.9: Wynik kalibracji adaptacyjnej z filtracją medianową 13-tego odcinka reszt czujnika RSL425 XL - zestaw funkcji wielomianowych wraz z parametrami.

	Zakres [m]		Stopień wielomianu	Parametry wielomianu				
	Od	Do		a	b	c	d	e
Ref. odl.	1.4543	1.6054	4	0.3834	-1.1095	-0.5180	4.8484	-2.8263
Odl. czujnika	1.4318	1.5787	3	1.2748	-6.0009	9.3645	-4.8704	

Taka kalibracja została wykonana dla wszystkich wykrytych odcinków, na podstawie lokalnych minimów i maksimów reszt. Reszty zostały podzielone w celu wyodrębnienia zakresów pomiarowych o określonym trendzie.

Rysunek 4.31 przedstawia wyniki kalibracji adaptacyjnej z filtracją czujnika Leuze RSL425 XL. Na górnym wykresie rysunku znajdują się odcinki reszt, wygenerowane na podstawie funkcji wielomianowych dopasowanych do poszczególnych odcinków. Na dolnym wykresie rysunku, przedstawiono wartości RMSE najlepszego dopasowania do określonego odcinka.



Rysunek 4.31: Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 9. Wykryte odcinki wraz z wartościami RMSE dopasowania - Leuze RSL425 XL

Metoda kalibracji opisana w podrozdziale 4.1.3 została także zastosowana dla czujników microScan3, RPLidar A2 oraz RPLidar A1. Charakterystyki pozostałych czujników LiDAR 2D przy optymalnej szerokości okna filtracji medianowej (podrozdział 5.2) zaprezentowano na rysunkach od 4.32 do 4.34, natomiast liczba sekcji i zakresy wartości RMSE przedstawiono w tabeli 4.10.

Wartość RMSE najlepszego dopasowania została wyznaczona dla każdej sekcji. Końcowa wartość RMSE dla MSC została wyliczona jako średnia ze wszystkich sekcji. Zakres pomiarowy czujnika RSL425 XL został podzielony na 23 sekcje, a dokładność mieściła się w przedziale od 0,00251 m do 0,00450 m.

Czujnik microScan3 posiadał najlepiej zdefiniowane indywidualne segmenty, a jego dokładność wahała się od 0,00094 m do 0,00180 m. 32 sekcje przyczyniły się do stabilnej poprawy dokładności w całym zakresie testowanych pomiarów odległości. Ponadto w tym przypadku zaobserwowano najmniejszą różnicę między minimalną a maksymalną wartością RMSE.


Podobnie, zakres pomiarowy dla RPLidar A1 został podzielony na 19 sekcji, z dokładnością mieszczącą się w zakresie pomiędzy 0,00057 m do 0,00253 m.

Zakres pomiarowy dla RPLidar A2 został podzielony na 18 sekcji, z dokładnością mieszczącą się w zakresie od 0,00011 m do 0,00129 m.

Podział całego zakresu pomiarowego na jak najmniejsze i monotoniczne sekcje wprowadza dużą wrażliwość na odchylenia pomiarowe. Dla każdej sekcji przypada inna funkcja, a strome funkcje pokrywające wąski zakres pomiarowy z dużą amplitudą reszt stanowią słabe punkty adaptacyjnej metody kalibracji.

Tabela 4.10: Liczba wykrytych odcinków oraz zakres wartości RMSE przy optymalnej szerokości okna dla każdego z czujników 2D.

Czujnik	Liczba odcinków	RMSE [m]		
		Min.	Maks.	Maks. - Min.
RSL425	23	0.00251	0.00450	0.00198
microScan3	32	0.00094	0.00180	0.00087
RPLidar A2	18	0.00011	0.00129	0.00118
RPLidar A1	19	0.00057	0.00253	0.00196




Rysunek 4.32: Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 11. Wykryte odcinki wraz z wartościami RMSE dopasowania - Sick microScan3

Opisana wcześniej metoda adaptacyjnej kalibracji z filtracją (podrozdział 4.1.3) została zastosowana w analizie pomiarów wybranych czujników LiDAR 2D dla szerokości okna filtracji od 0 do wartości optymalnej (patrz podrozdział 5.2). Wyniki zastosowania tej metody kalibracji dla wybranych czujników LiDAR 2D przedstawiono w tabeli 4.11. W każdym wierszu dla szerokości okna równej 0 (bez filtracji) przedstawiono początkowe wartości RMSE oraz odchylenia standardowego (STDEV) dla surowych danych każdego z czujników LiDAR 2D – przed filtracją i kalibracją.

Przyrostowe ulepszenia wynikające z zastosowania metody MSCwMF, osiągane poprzez zwiększanie szerokości okna filtracji medianowej (MF) oraz dalsze przetwarzanie z użyciem metody MSC, zostały porównane z wartościami RMSE i STDEV uzyskanymi przy szerokości okna równej 0 (bez filtracji). Wyniki tego porównania dla wybranych czujników LiDAR 2D przedstawiono w Tabeli 4.11, w kolumnach “MSCwMF” oraz “ Δ MSCwMF”.

Dla czujnika RSL425 XL optymalna szerokość okna wynosiła 9, co umożliwiło poprawę precyzji o 48,99% i zmniejszenie STDEV z 0,00645 do 0,00329 m. W tym przypadku najlepszy wynik w zakresie poprawy dokładności wyniósł 47,55%, redukując wartości RMSE z 0,00652 do 0,00342 m.

Dla microScan3, najlepsze rezultaty uzyskano przy szerokości okna 11, co pozwoliło na poprawę precyzji o 48,19% (STDEV zmniejszono z 0,00249 do 0,00129



Rysunek 4.33: Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 9. Wykryte odcinki wraz z wartościami RMSE dopasowania - RPLidar A1

m) oraz poprawę dokładności o 47,24% (wartość RMSE zredukowano z 0,00254 do 0,00134 m).

Dla RPLidar A1, przy optymalnej szerokości okna wynoszącej 9, odnotowano poprawę precyzji o 47,49% (STDEV zmniejszono z 0,00218 do 0,00114 m) oraz poprawę dokładności o 46,69% (wartość RMSE zmalała z 0,00244 m do 0,00130 m).

W przypadku RPLidar A2, optymalna szerokość okna wyniosła 13, co dało poprawę precyzji o około 43,90% (STDEV zmniejszono z 0,00123 do 0,00069 m) oraz poprawę dokładności o 39,10% (wartość RMSE spadła z 0,00133 do 0,00081 m).


Jak można zauważyć, we wszystkich przypadkach zastosowania metody MSCwMF, wartość STDEV malała wraz ze wzrostem szerokości okna do wartości optymalnej, co powodowało również zmniejszenie wartości RMSE.

W Tabeli 4.11 kolumna “ Δ Surowe” przedstawia porównanie ogólnej poprawy precyzji i dokładności pomiarów czujników LiDAR 2D, uzyskanej przy różnych szerokościach okna z zastosowaniem metody MSCwMF, względem pomiarów niefiltrowanych i niekalibrowanych (surowych).

W przypadku RSL425 XL, brak filtracji (szerokość okna równa 0 przed kalibracją) skutkował znaczną poprawą dokładności pomiarowej – zastosowanie MSCwMF dało poprawę ogólną na poziomie ponad 70%. Zastosowanie optymalnej szerokości okna równej 9 pozwoliło poprawić precyzję o ponad 48%, a dokładność o ponad 84%. Tym samym wartość RMSE zmalała z 0,022 do 0,00342 m, a STDEV z 0,00638 do 0,00329 m.

Dla czujnika microScan3, metoda MSCwMF zapewniła poprawę o ponad 79% przy szerokości okna równej 0. Dla szerokości okna 11 poprawa precyzji przekroczyła 47%, a dokładności – 89%, z czego sam wzrost dokładności wyniósł prawie 10%. Wartość RMSE spadła z 0,0124 do 0,00134 m, a STDEV z 0,00246 do 0,00129 m.

W przypadku czujnika RPLidar A1, zastosowanie MSCwMF przyniosło poprawę dokładności na poziomie ponad 69%. Dla optymalnej szerokości okna równej 9, poprawa precyzji przekroczyła 47%, a poprawa dokładności – 83%, przy wzroście dokładności o ponad 14%. Wartość RMSE zmniejszyła się z 0,00789 do 0,0013 m,



Rysunek 4.34: Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 13. Wykryte odcinki wraz z wartościami RMSE dopasowania - RPLidar A2

a STDEV z 0,00219 do 0,00114 m.

Również czujnik RPLidar A2 znacząco zyskał dzięki metodzie MSCwMF, co dało poprawę dokładności na poziomie ponad 79% przy szerokości okna równej 0. Przy optymalnej szerokości okna równej 13, poprawa precyzji wyniosła ponad 43%, a dokładności ponad 87%. Wzrost dokładności przekroczył 8%, wartość RMSE zmniejszyła się z 0,00639 do 0,00081 m, a STDEV z 0,00123 do 0,00069 m.

Uzyskane wyniki były spójne dla wszystkich testowanych szerokości okna, co potwierdza skuteczność opracowanej metodologii dla wszystkich wybranych czujników LiDAR 2D.

Metoda MSCwMF przy zastosowaniu optymalnej szerokości okna zapewniała bardzo wysoki poziom dokładności, przekraczający nawet 89%, a metoda MF poprawiała precyzję do poziomu powyżej 48%. Porównanie wyników MSCwMF z optymalną szerokością okna do braku filtracji wykazało poprawę przekraczającą 14% (RSL 425 XL), co potwierdza znaczenie stosowania filtracji MF.

Porównanie wyników po samej filtracji oraz po filtracji połączonej z MSC dla tej samej szerokości okna wykazało, że wartość STDEV w większości przypadków ulegała jedynie niewielkiej zmianie, natomiast wartość RMSE ulegała zauważalnemu zmniejszeniu. Można zatem stwierdzić, że zastosowanie MSC ma niewielki wpływ na redukcję precyzji, ale znacząco zwiększa dokładność.

4.2 Metody kalibracji z wykorzystaniem uczenia maszynowego

W niniejszej podrozdziale zaprezentowane zostaną metody kalibracji oparte na uczeniu maszynowym (ang. machine learning).

Ze względu na charakter kalibracji czujników w czasie rzeczywistym, zastosowano tradycyjne algorytmy uczenia maszynowego zamiast metod głębokiego uczenia, aby osiągnąć predykcję i kalibrację w czasie rzeczywistym. Powodem jest również to,

Tabela 4.11: Wynik kalibracji adaptacyjnej z filtracją czujników 2D.

RSL425 XL	MF				MSCwMF		Δ MSCwMF		Δ Surowe	
Szerokość okna	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	Δ STDEV	Δ RMSE
0	0.00638	0.02200	0.00%	0.00%	0.00645	0.00652	0.00%	0.00%	-1.08%	70.36%
3	0.00441	0.02162	30.95%	1.74%	0.00448	0.00459	30.54%	29.60%	29.79%	79.13%
5	0.00369	0.02158	42.22%	1.90%	0.00373	0.00386	42.17%	40.80%	41.55%	82.45%
7	0.00333	0.02150	47.83%	2.25%	0.00337	0.00351	47.75%	46.17%	47.19%	84.04%
9	0.00324	0.02156	49.19%	1.99%	0.00329	0.00342	48.99%	47.55%	48.44%	84.45%
microScan3	MF				MSCwMF		Δ MSCwMF		Δ Surowe	
Szerokość okna	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	Δ STDEV	Δ RMSE
0	0.00246	0.01240	0.00%	0.00%	0.00249	0.00254	0.00%	0.00%	-1.10%	79.51%
3	0.00171	0.01230	30.78%	0.77%	0.00173	0.00177	30.52%	30.31%	29.76%	85.72%
5	0.00142	0.01225	42.27%	1.23%	0.00144	0.00149	42.17%	41.34%	41.53%	87.98%
7	0.00132	0.01222	46.41%	1.47%	0.00134	0.00138	46.18%	45.67%	45.59%	88.87%
9	0.00129	0.01222	47.79%	1.48%	0.00130	0.00135	47.79%	46.85%	47.22%	89.11%
11	0.00128	0.01222	48.07%	1.45%	0.00129	0.00134	48.19%	47.24%	47.62%	89.19%
RPLidar A1	MF				MSCwMF		Δ MSCwMF		Δ Surowe	
Szerokość okna	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	Δ STDEV	Δ RMSE
0	0.00219	0.00789	0.00%	0.00%	0.00218	0.00244	0.00%	0.00%	0.49%	69.13%
3	0.00146	0.00763	33.46%	3.32%	0.00145	0.00163	33.43%	33.31%	33.75%	79.41%
5	0.00122	0.00756	44.09%	4.23%	0.00122	0.00138	44.07%	43.55%	44.34%	82.57%
7	0.00117	0.00758	46.30%	4.03%	0.00117	0.00133	46.24%	45.28%	46.50%	83.11%
9	0.00115	0.00757	47.52%	4.12%	0.00114	0.00130	47.49%	46.69%	47.74%	83.54%
RPLidar A2	MF				MSCwMF		Δ MSCwMF		Δ Surowe	
Szerokość okna	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	STDEV [m]	RMSE [m]	Δ STDEV	Δ RMSE	Δ STDEV	Δ RMSE
0	0.00123	0.00639	0.00%	0.00%	0.00123	0.00133	0.00%	0.00%	-0.08%	79.19%
3	0.00097	0.00630	21.32%	1.39%	0.00097	0.00107	21.14%	19.55%	21.07%	83.26%
5	0.00087	0.00626	29.37%	2.05%	0.00087	0.00098	29.27%	26.32%	29.21%	84.66%
7	0.00081	0.00624	33.77%	2.36%	0.00081	0.00092	34.15%	30.83%	34.09%	85.60%
9	0.00074	0.00622	40.11%	2.64%	0.00073	0.00086	40.65%	35.34%	40.60%	86.54%
11	0.00073	0.00622	40.28%	2.61%	0.00073	0.00085	40.65%	36.09%	40.60%	86.70%
13	0.00070	0.00620	43.45%	3.02%	0.00069	0.00081	43.90%	39.10%	43.86%	87.32%

że w większości przypadków modele oparte na uczeniu maszynowym są w stanie uzyskać akceptowalne wyniki w krótkim czasie.

Problem badawczy został zdefiniowany jako kalibracja zmierzonej odległości (x) względem odległości referencyjnej (y) i został rozwiązany z wykorzystaniem algorytmów regresyjnych.

W celu sprawdzenia znanych algorytmów regresji i wyboru najlepiej działających modeli ML użyto pakietu języka Pythona o nazwie lazypredict [40]. Funkcja LazyRegressor (z pakietu lazypredict) zapewnia prosty interfejs API (ang. Application Programming Interface), który umożliwia wykonanie regresji za pomocą wybranych algorytmów.

W przeprowadzonej analizie uwzględniono 43 algorytmy regresji (dostarczane przez pakiety języka Python o nazwie sklearn [85]).

Dodatkowo uwzględniono w badaniach dwa algorytmy regresji (LGBMRegressor oraz XGBRegressor) kompatybilne z interfejsem lazypredict. Tabela 4.12 przedstawia pełen zestaw analizowanych algorytmów.

Podczas wstępnych testów algorytmy GammaRegressor, PoissonRegressor i IsotonicRegression generowały błędy na testowanym zbiorze danych, natomiast QuantileRegressor potrzebował ponad godzinę na wykonanie predykcji (podczas gdy

Tabela 4.12: Zestaw analizowanych algorytmów regresji

Pakiet	Algorytmy regresji			
sklearn	AdaBoostRegressor	GaussianProcessRegressor	LassoLars	RadiusNeighborsRegressor
	ARDRegression	GradientBoostingRegressor	LassoLarsCV	RandomForestRegressor
	BaggingRegressor	HistGradientBoostingRegressor	LassoLarsIC	RANSACRegressor
	BayesianRidge	HuberRegressor	LinearRegression	Ridge
	DecisionTreeRegressor	IsotonicRegression*	LinearSVR	RidgeCV
	DummyRegressor	KernelRidge	MLPRegressor	SGDRegressor
	ElasticNet	KNeighborsRegressor	NuSVR	SVR
	ElasticNetCV	Lars	OrthogonalMatchingPursuit	TheilSenRegressor
	ExtraTreeRegressor	LarsCV	PassiveAggressiveRegressor	TransformedTargetRegressor
	ExtraTreesRegressor	Lasso	PoissonRegressor*	TweedieRegressor
	GammaRegressor*	LassoCV	QuantileRegressor*	
lightgbm	LGBMRegressor			
xgboost	XGBRegressor			

innym algorytmom zajmowało to mniej niż sekundę). W związku z tym usunięto te trzy algorytmy z dalszych analiz. Algorytmy usunięte z analizy zostały w Tab. 4.12 oznaczone gwiazdką (*).

Ostatecznie w badaniu opisanym w niniejszym podrozdziale uwzględniono więc 41 algorytmów regresji.


Opracowano dwa podejścia do kalibracji z wykorzystaniem uczenia maszynowego, oparte na wybranych algorytmach regresji: kalibrację naturalną oraz kalibrację resztową. W trakcie badań przyjęto również dwa scenariusze weryfikacji modeli regresyjnych ML.

W pierwszym scenariuszu zbiory treningowy i testowy są tożsame, co pozwala ocenić zdolność modeli do dopasowywania się do pomiarów odległości. Podejście to określono jako scenariusz dopasowania.

W drugim scenariuszu dane pomiarowe dzielone są na zbiór treningowy i testowy: co czwarty pomiar (25%) trafia do zbioru testowego, a pozostałe (75%) do zbioru treningowego. Scenariusz ten jest bardziej zbliżony do warunków rzeczywistych i umożliwia ocenę zdolności kalibracyjnych wybranych algorytmów. Podejście to określono jako scenariusz realistyczny.

4.2.1 Kalibracja naturalna


W proponowanej metodzie kalibracji naturalnej (ang. naive calibration - NC) wszystkie algorytmy regresji wykorzystują zmierzoną odległość x jako jednowymiarową cechę wejściową w celu predykcji rzeczywistej wartości y . Zatem skalibrowana odległość opisana jest jako $NC(x)$, gdzie NC to funkcja kalibracyjna oparta na danym algorytmie regresji. Wytrenowany model ML przyjmuje na wejście surowy pomiar odległości, a na wyjściu zwraca skalibrowaną wartość pomiaru odległości, co zostało schematycznie przedstawione na Rysunku 4.35.



Rysunek 4.35: Schemat kalibracji naturalnej wykorzystującej wytrenowany model ML w celu określenia skalibrowanego pomiaru odległości.

4.2.2 Kalibracja resztowa

W proponowanej metodzie kalibracji resztowej (ang. residual calibration - RC) wykorzystuje się zmierzoną odległość x jako jednowymiarową cechę wejściową w celu predykcji wartości resztowej $y - x$. Skalibrowana odległość w kalibracji resztowej opisana jest jako $x + RC(x)$, gdzie RC to funkcja regresji przewidująca błąd pomiaru. Wytrenowany model ML przyjmuje na wejście surowy pomiar odległości, a na wyjściu zwraca wartość korekty, którą należy zsumować z surową wartością pomiaru odległości aby uzyskać skalibrowany pomiar, co zostało schematycznie przedstawione na Rysunku 4.36.



Rysunek 4.36: Schemat kalibracji resztowej wykorzystującej wytrenowany model ML w celu określenia wartości korekty dla pomiaru odległości.

4.2.3 Przykłady wykorzystania metod kalibracji z użyciem uczenia maszynowego

W celu porównania metod kalibracji ML wraz ze scenariuszami ich weryfikacji, zastosowano parametry pomiarów wyjściowych dla danych sensorów oraz opracowanych klasycznych metod kalibracji oznaczonych odpowiednio jako: Surowe, ACM, MSCwMF.

Wartości wyjściowe reprezentują błąd pomiędzy wartościami x i y bez zastosowania jakiegokolwiek kalibracji i stanowią punkt odniesienia dla oceny metod kalibracyjnych.

Metody ACM oraz MSCwMF zostały omówione odpowiednio w podrozdziałach 4.1.2 i 4.1.3.

W celu uproszczenia prezentacji wyników w tabeli, usunięto przyrostki “Regressor” oraz “Regression” z nazw algorytmów regresji, nazwę algorytmu HistGradientBoosting skrócono do HistGB, a GradientBoost na “GB”.

Porównanie tych metod wraz z wynikami prezentującymi wartości RMSE oraz STDEV skalibrowanych pomiarów przedstawiono w tabelach od 4.13 do 4.16.

Kolumny tabeli przedstawiają błędy dla czterech czujników: RSL425 XL, microScan3, RPLidar A1 oraz RPLidar A2. Kolumny oznaczone jako „Średnia” zawierają średnie wartości parametrów danego modelu ML, obliczone dla wszystkich czujników. Wyniki prezentowane w tabelach zostały posortowane według wartości średniego błędu RMSE danego modelu. Każda tabela przedstawia 10 modeli z najmniejszymi średnimi wartościami RMSE. Wartości w kolumnie „Średnia” zostały przedstawione czcionką pogrubioną, jeśli były mniejsze niż wartość uzyskana przy użyciu metody MSCwMF.

Ocena kalibracji

Tabele 4.13 oraz 4.14 prezentują wyniki dwóch metod kalibracji (odpowiednio naturalnej oraz resztowej) z wykorzystaniem uczenia maszynowego (ML) w scenariuszu dopasowania. W tabeli 4.13 można zaobserwować, że 8 modeli ML (ExtraTree,

DecisionTree, ExtraTrees, RandomForest, GB, Bagging, XGB, KNeighbors) osiągało niższe wartości RMSE oraz STDEV niż klasyczne metody kalibracji (MSCwMF, ACM). Trzy pierwsze modele ML osiągnęły jednakowe wartości średnie RMSE równe 0.00024 m, co stanowi poprawę dokładności pomiarów o 86,2% względem metody MSCwMF. Wartości RMSE dla czujników microScan3, RPLidar A1, RPLidar A2 osiągnęły wartości dopasowania bliskie zeru. Czujnik RSL425 XL osiągnął przy wykorzystaniu trzech pierwszych modeli, wartość RMSE równą 0.00095 m, co stanowi poprawę względem wyjściowej wartości RMSE o 95,68%. Pierwsze trzy modele ML osiągnęły poprawę STDEV względem metody MSCwMF równą 96,25%.

Pierwsze trzy modele ML (ExtraTree, DecisionTree, ExtraTrees) w tabeli 4.14 prezentują wyniki bardzo podobne do tych przedstawionych w tabeli 4.13. Również osiągnęły najniższe średnie wartości RMSE równe 0.00024 m. Wzrost wartości RMSE nastąpił dla modeli RandomForest, Bagging, KNeighbors, XGB, jednak nadal modele te osiągnęły niższe wartości RMSE niż metoda MSCwMF. Największy wzrost RMSE (o 0,00211 m) prezentuje model GB, tym samym osiągając wynik gorszy niż metoda MSCwMF.

Porównując obie metody kalibracji ML w scenariuszu dopasowania (opierając się na wynikach przedstawionych w tabelach 4.13 i 4.14), można stwierdzić, że poprawa dokładności oraz precyzji osiągnięta przez metodę kalibracji naturalnej jest większa niż przez kalibrację resztową, choć różnica jest niewielka i trudno mierzalna z powodu braku odpowiedniego sprzętu do pomiaru tak małych różnic.

Tabele 4.15 oraz 4.16 prezentują wyniki dwóch metod kalibracji (odpowiednio naturalnej oraz resztowej) z wykorzystaniem uczenia maszynowego (ML) w scenariuszu realistycznym.

W tabeli 4.15 można zaobserwować, że 8 modeli ML (GB, DecisionTree, RandomForest, Bagging, XGB, KNeighbors, ExtraTrees, ExtraTree) osiągało niższe wartości RMSE oraz STDEV niż klasyczne metody kalibracji. Jedynym wyjątkiem jest ExtraTree, który dla czujnika RSL425 XL osiągnął gorszy wynik RMSE niż metoda MSCwMF. Najlepszym modelem kalibracji naturalnej okazał się GB, osiągając wartość RMSE równą 0,00036 m, co przekłada się na poprawę dokładności o 79.06% względem metody MSCwMF. Średnia wartość STDEV również została zredukowana przez model GB do poziomu 0.00008 m co stanowi poprawę o 95%. Czujnik RSL425 XL osiągnął przy wykorzystaniu modelu GB, wartość RMSE równą 0.00138 m, co stanowi poprawę względem wyjściowej wartości RMSE o 93,72%. Wartości RMSE osiągane przez najlepsze modele ML dla czujników microScan3, RPLidar A1, RPLidar A2 ponownie były bliskie zeru.

Różnica pomiędzy kalibracją resztową a naturalną jest większa w scenariuszu realistycznym, niż w scenariuszu dopasowania choć kierunek zmian pozostał taki sam - tabela 4.16 zawiera wyższe wartości RMSE oraz STDEV niż tabela 4.15.

Wzrost wartości RMSE nastąpił dla modeli DecisionTree, RandomForest, Bagging, ExtraTree, ExtraTrees, KNeighbors, XGB, jednak nadal modele te osiągnęły niższe wartości RMSE niż metoda MSCwMF. Najlepszym modelem kalibracji resztowej wg. tabeli 4.16 okazał się DecisionTree, który osiągnął wartość RMSE równą 0,0082 m, co przekłada się na poprawę dokładności względem metody MSCwMF o 52.32%. Największy wzrost wartości RMSE (o 0,00224 m) prezentuje model GB, tym samym osiągając wynik gorszy niż metoda MSCwMF.

Porównując obie metody kalibracji ML w scenariuszu realistycznym (opierając się na wynikach przedstawionych w tabelach 4.15 i 4.16), można stwierdzić, że poprawa dokładności oraz precyzji osiągnięta przez metodę kalibracji naturalnej jest zauważalnie większa niż przez kalibrację resztową, a średnie wyniki błędu RMSE

dla lepszych modeli ML są coraz bardziej bliskie wartościom prezentowanym przez metodę MSCwMF.

Tabele od 4.13 do 4.16 zawierają wyniki dla 10 modeli regresji z najniższymi wartościami RMSE. Tabele zawierające wyniki dla wszystkich badanych modeli regresji znajdują się w dodatku C. Według danych zawartych w tabelach od 4.13 do 4.16, modelami najbardziej odpornymi na zmiany metodologii oraz warunków definiowanych przez scenariusze są kolejno: DecisionTree, RandomForest, ExtraTree, ExtraTrees oraz Bagging. Natomiast najbardziej wrażliwym na zmiany metodologii okazał się model GB.

Tabela 4.13: Scenariusz dopasowania - kalibracja naturalna.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
ExtraTree	0.00095	5.70E-16	7.15E-16	4.96E-16	0.00024	0.00024	9.28E-17	6.75E-17	7.24E-17	0.00006
DecisionTree	0.00095	5.75E-16	6.93E-16	5.22E-16	0.00024	0.00024	3.57E-17	4.60E-17	7.42E-17	0.00006
ExtraTrees	0.00095	1.76E-15	1.93E-15	1.93E-15	0.00024	0.00024	4.25E-18	5.04E-18	1.23E-17	0.00006
RandomForest	0.00106	1.74E-15	1.93E-15	1.87E-15	0.00027	0.00038	1.29E-17	0	0	0.00010
GB	0.00106	0.00003	0.00002	0.00002	0.00028	0.00025	0	0	0	0.00006
Bagging	0.00113	2.16E-16	2.99E-16	2.98E-16	0.00028	0.00038	1.71E-17	1.49E-17	1.94E-17	0.00010
XGB	0.00099	0.00008	0.00009	0.00010	0.00032	0.00024	0	0	0	0.00006
KNeighbors	0.00158	4.11E-17	5.10E-17	5.36E-17	0.00040	0.00073	0	0	0	0.00018
GaussianProcess	0.00655	0.00294	0.00259	0.00149	0.00340	0.00647	0.00251	0.00221	0.00125	0.00311
NuSVR	0.00663	0.00308	0.00277	0.00163	0.00353	0.00646	0.00249	0.00220	0.00124	0.00310

Tabela 4.14: Scenariusz dopasowania - kalibracja resztowa.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
ExtraTree	0.00095	0	4.81E-19	0	0.00024	0.00024	0	0	0	0.00006
DecisionTree	0.00095	0	4.81E-19	0	0.00024	0.00024	0	0	0	0.00006
ExtraTrees	0.00095	8.14E-18	1.02E-17	3.07E-18	0.00024	0.00024	2.41E-18	6.93E-19	0	0.00006
RandomForest	0.00114	0.00016	0.00016	0.00005	0.00038	0.00070	0.00015	0.00013	0.00003	0.00025
Bagging	0.00123	0.00020	0.00018	0.00006	0.00042	0.00078	0.00017	0.00015	0.00003	0.00028
KNeighbors	0.00199	0.00048	0.00047	0.00017	0.00078	0.00165	0.00045	0.00039	0.00011	0.00065
XGB	0.00173	0.00111	0.00091	0.00060	0.00109	0.00158	0.00104	0.00085	0.00055	0.00100
LGBM	0.00474	0.00177	0.00149	0.00057	0.00215	0.00466	0.00174	0.00135	0.00052	0.00207
HistGB	0.00471	0.00198	0.00166	0.00051	0.00221	0.00462	0.00192	0.00144	0.00047	0.00212
GB	0.00509	0.00197	0.00160	0.00091	0.00239	0.00500	0.00184	0.00147	0.00083	0.00228

Analiza wrażliwości

Interfejs lazypredict uruchamia algorytmy regresji z domyślnymi parametrami, co nie ogranicza złożoności tych algorytmów. Aby umożliwić kalibrację w czasie rzeczywistym, dla najlepiej działających algorytmów wprowadzono ograniczenia złożoności oraz przeprowadzono analizę wrażliwości względem tej złożoności.

Do analizy wrażliwości wybrano 5 algorytmów opartych na drzewach decyzyjnych, w tym GradientBoosting, DecisionTree, RandomForest, Bagging oraz XGB. Dodatkowo, maksymalna głębokość drzew decyzyjnych została ograniczona, aby przeanalizować wpływ tego parametru na dokładność kalibracji.

Analiza wrażliwości opracowanych metod kalibracji dla czujnika RSL425 XL została przedstawiona na rysunku 4.37.

Tabela 4.15: Scenariusz realistyczny - kalibracja naturalna.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
GB	0.00138	0.00003	0.00002	0.00002	0.00036	0.00030	0	0	0	0.00008
DecisionTree	0.00176	4.51E-16	4.74E-16	4.36E-16	0.00044	0.00043	1.53E-17	2.23E-17	4.64E-17	0.00011
RandomForest	0.00176	1.74E-15	1.91E-15	1.89E-15	0.00044	0.00058	8.82E-18	0	2.71E-18	0.00014
Bagging	0.00183	2.19E-16	2.39E-16	2.43E-16	0.00046	0.00053	2.39E-17	2.47E-17	5.11E-18	0.00013
XGB	0.00151	0.00012	0.00011	0.00011	0.00046	0.00034	0	0	0	0.00009
KNeighbors	0.00190	4.11E-17	5.10E-17	5.36E-17	0.00047	0.00057	0	0	0	0.00014
ExtraTrees	0.00284	0.00040	0.00048	0.00026	0.00099	0.00147	0.00018	0.00024	0.00009	0.00049
ExtraTree	0.00433	0.00000	0.00000	0.00000	0.00108	0.00134	5.98E-17	5.80E-17	5.72E-17	0.00033
GaussianProcess	0.00682	0.00305	0.00276	0.00155	0.00354	0.00641	0.00231	0.00232	0.00124	0.00307
NuSVR	0.00689	0.00315	0.00290	0.00174	0.00367	0.00641	0.00229	0.00231	0.00124	0.00306


Tabela 4.16: Scenariusz realistyczny - kalibracja resztowa.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
DecisionTree	0.00213	0.00041	0.00048	0.00027	0.00082	0.00135	0.00023	0.00030	0.00010	0.00049
RandomForest	0.00223	0.00047	0.00055	0.00028	0.00089	0.00145	0.00034	0.00037	0.00012	0.00057
Bagging	0.00228	0.00048	0.00054	0.00028	0.00090	0.00143	0.00034	0.00037	0.00013	0.00057
ExtraTrees	0.00273	0.00043	0.00045	0.00028	0.00097	0.00145	0.00021	0.00024	0.00009	0.00050
KNeighbors	0.00281	0.00069	0.00096	0.00039	0.00121	0.00206	0.00058	0.00065	0.00022	0.00088
XGB	0.00265	0.00110	0.00117	0.00076	0.00142	0.00212	0.00089	0.00102	0.00065	0.00117
ExtraTree	0.00481	0.00042	0.00089	0.00027	0.00160	0.00253	0.00024	0.00043	0.00010	0.00082
LGBM	0.00535	0.00197	0.00186	0.00078	0.00249	0.00481	0.00167	0.00149	0.00062	0.00215
GB	0.00551	0.00206	0.00185	0.00098	0.00260	0.00506	0.00168	0.00157	0.00083	0.00229
HistGB	0.00551	0.00222	0.00209	0.00072	0.00264	0.00502	0.00183	0.00167	0.00058	0.00227


Na rysunkach 4.37 (a) oraz 4.37 (b), oś Y reprezentuje błąd RMSE pomiędzy referencyjną wartością pomiaru odległości, a skalibrowaną wartością odległości otrzymaną z modelu ML, w zależności od maksymalnej głębokości modelu (oś X w zakresie od 1 do 10). Poziome proste, czarna oraz czerwona, reprezentują wartości RMSE otrzymane odpowiednio przez metodę MSCwMF oraz ACM.

Dla maksymalnej głębokości równej 1, wszystkie algorytmy uczenia maszynowego uzyskały gorsze wyniki niż metody MSCwMF oraz ACM. Wraz ze wzrostem głębokości wartość RMSE maleje i stabilizuje się. Dla głębokości równej 2 model GradientBoosting, a dla głębokości równej 3 również XGB osiągają wyniki lepsze niż metody MSCwMF oraz ACM. Wszystkie przedstawione na rysunku 4.37 (a) modele osiągają lepsze wyniki niż metody MSCwMF oraz ACM przy głębokości równej 6, co można zaobserwować wyraźniej na rysunku 4.37 (b). Najwolniej na zmianę głębokości reaguje model DecisionTree. Na podstawie wyników analizy wrażliwości można stwierdzić, że GradientBoosting oraz XGB dostosowują się szybciej i przewyższają klasyczne metody kalibracji przy głębokości większej niż 3 (dwukrotnie mniejszej niż reszta analizowanych modeli).


Rysunek 4.37 (c) przedstawia wpływ zmiany maksymalnej głębokości na odchylenie standardowe pomiarów skalibrowanych przez analizowane modele ML. Wszystkie modele dla każdej analizowanej maksymalnej głębokości osiągały wartości STDEV poniżej 1 mm, a wartość STDEV dla większości modeli wzrastała wraz ze wzrostem maksymalnej głębokości.



(a)



(b)



(c)

Rysunek 4.37: Wyniki wpływu maksymalnej głębokości modeli ML, na wartości RMSE (a) i (b), oraz wartości STDEV (c).

Rozdział 5

Filtracja pomiarów odległości

Wykorzystanie pomiarów z czujników typu LiDAR (Light Detection and Ranging) nie zawsze zapewnia wystarczającą precyzję do dokładnego określenia zakresu ruchu lub ponownej kalibracji pozycji AGV (ang. Autonomous Guided Vehicles). W związku z tym konieczne jest stosowanie metod filtracji i kalibracji w celu zwiększenia precyzji i dokładności pomiarów uzyskiwanych z LiDAR-ów 2D.

Jak wykazano w podrozdziale 3.2, każdy czujnik posiada swoją własną charakterystykę pomiarową. Wspólną cechą czujników jest brak wystarczającej dokładności i precyzji. Możliwe jest ich skalibrowanie przy użyciu metod kalibracji, jednak poprawia to jedynie dokładność danego czujnika. Precyzja pomiarów również wpływa na końcową jakość systemu pozycjonowania, dlatego też w tym rozdziale omówione zostaną wybrane metody filtracji oraz wyniki badań przeprowadzonych przy wykorzystaniu tych metod.

Aby wybrać najbardziej odpowiednią metodę filtracji dla pomiarów odległości z czujników typu LiDAR 2D, wykonano badanie porównujące filtrację za pomocą średniej ruchomej z filtracją medianową. Przeprowadzono testy mające na celu określenie optymalnej szerokości okna filtracyjnego poprzez uzyskanie możliwie najwyższej precyzji w pomiarze odległości. Testowano szerokość okna filtracyjnego w zakresie od 3 do 15 elementów.

5.1 Filtracja za pomocą średniej ruchomej

Jedną z najprostszych i najczęściej stosowanych metod filtracji danych pomiarowych jest filtracja za pomocą średniej ruchomej (ang. Moving Average Filter lub Simple Moving Average). Jest to filtr wygładzający, który redukuje wpływ losowych zakłóceń i szumów w danych, obliczając średnią wartość sygnału z określonej liczby sąsiednich próbek.

Filtracja średnią ruchomą o szerokości okna N (gdzie $N \in \mathbb{N}$), dla sygnału dyskretnego $x[n]$ definiowana jest jako:

$$y[n] = \frac{1}{N} \sum_{k=0}^{N-1} x[n-k] \quad (5.1)$$

gdzie:

- $y[n]$ - przefiltrowany sygnał w chwili n ,
- $x[n]$ - surowy sygnał pomiarowy,
- N - liczba próbek w oknie filtrującym

W kontekście filtracji danych z pomiarów odległości, np. z czujników typu LiDAR czy ultradźwiękowych filtr ten sprawdza się dobrze w redukcji pojedynczych odchył (ang. outliers) oraz szumów o charakterze losowym. Zaletą tej metody filtracji jest prostota implementacji i niska złożoność obliczeniowa, co czyni ją atrakcyjną w systemach czasu rzeczywistego.

W artykule [10] autorzy analizują, jak zmiana liczby próbek N w filtrze MAF wpływa na stabilność i dokładność sygnału z czujników ultradźwiękowych. Wyniki eksperymentów pokazują, że większe N zwiększa precyzję i stabilność odczytów, kosztem czasu odpowiedzi. Użycie filtracji za pomocą średniej ruchomej poprawiło jednak precyzję danych pomiarowych, co jest kluczowe dla niezawodności systemów bezpieczeństwa i automatyki.

5.2 Filtracja medianowa

Filtracja medianowa jest nieliniową metodą filtracji sygnałów i danych pomiarowych, często stosowaną do redukcji szumów impulsowych, bez znacznego rozmycia krawędzi sygnału. Znajduje szerokie zastosowanie w przetwarzaniu obrazów, analizie sygnałów oraz w systemach pomiarowych, gdzie dane są podatne na pojedyncze zakłócenia lub błędy odczytu.

Dla każdego elementu pomiaru, filtr medianowy bierze pod uwagę otoczenie o zadanej szerokości okna filtrującego, sortuje wartości w oknie, a następnie zastępuje wartość medianą zbioru.

Zakładając, że posiadamy sygnał jednowymiarowy $x = \{x_1, x_2, \dots, x_n\}$, o szerokość okna filtracyjnego w (zwykle liczba nieparzysta, np. 3, 5, 7...) to dla każdej próbki x_i , przefiltrowana wartość y_i jest obliczana jako:

$$y_i = \text{mediana}(x_{i-k}, x_{i-k+1}, \dots, x_i, x_{i+k}) \quad (5.2)$$

gdzie:

- $k = \frac{w-1}{2}$,
- $\text{mediana}(\dots)$ - oznacza medianę zbioru liczb

Filtracja medianowa wyklucza skrajne anomalie z danych pomiarowych, które często stanowią szum impulsowy [32].

5.3 Podsumowanie badań wpływu metod filtracji na pomiary odległości

Badania wpływu opisanych w podrozdziałach 5.1 oraz 5.2 metod filtracji na pomiary odległości z czujników typu LiDAR 2D zostały przedstawione w podrozdziałach 5.3.1 oraz 5.3.2. Wykresy przedstawiające reszty oraz odchylenia standardowe surowych danych pomiarowych badanych czujników odległości zostały przedstawione w podrozdziale 3.2.

5.3.1 Filtracja za pomocą średniej ruchomej

Przeprowadzono eksperymenty filtracji za pomocą średniej ruchomej dla LiDAR-ów 2D z wartościami szerokości okna od 3 do 15. W porównaniu do wyjściowej charakterystyki pomiarowej czujników laserowych 2D, poprawie uległ jedynie jeden z

czujników - Leuze RSL425XL. Poprawa precyzji pomiarowej dla RSL425XL wynosiła od 4% do ponad 20%. W przypadku wszystkich pozostałych czujników precyzja oraz dokładność pomiarów pogorszyła się drastycznie, błąd pomiarowy oraz odchylenie standardowe zwiększały się wraz ze wzrostem szerokości okna. Dla szerokości okna równej 3, pogorszenie precyzji pomiarów wynosiło ponad 56% dla Sick microscan3, 205% dla RPLidar A2 oraz ponad 78% dla RPLiadr A1. Rysunek 5.1 przedstawia charakterystykę błędu pomiarowego oraz odchylenia standardowego czujników poddanych filtracji filtrem średnią ruchomą. Można zaobserwować, że filtr ten utworzył wyraźne warstwy w błędach pomiarowych odsuwając pomiary od wyjściowej charakterystyki pomiarowej czujników. Fakt, że jedynie jeden z czujników zwiększył swoją precyzję pokazuje, że wynik filtracji zależy również od sposobu pomiaru odległości przez czujnik i charakterystyki napływania kolejnych pomiarów. Można więc wnioskować że to charakterystyka “szumu” danych odgrywa główne znaczenie, a sama metoda filtracji powinna być dobrana do charakterystyki napływających danych.

Rysunek 5.2 prezentuje wpływ szerokości okna (od 3 do 15 elementów) podczas filtracji ruchomą średnią na precyzję oraz dokładność pomiarową LiDAR-ów 2D. Najkorzystniejsza szerokość okna dla Leuze RSL425XL wynosi 3. Dla tej szerokości okna precyzja zwiększyła się o 20,42% - do poziomu 0,00508 m, a dokładność pomiarów zwiększyła się o 1,54%.

5.3.2 Filtracja medianowa

Na początku przeprowadzono eksperymenty filtracji medianowej dla LiDAR-ów 2D z szerokością okna równą 3. Dla każdego z nich zaobserwowano, że wartości odchylenia standardowego (STDEV) uległy zmniejszeniu dzięki filtracji medianowej (MF), a błędy pomiarowe w każdej serii dla danej rzeczywistej odległości zostały zredukowane (rysunek 5.3). Filtracja medianowa z szerokością okna równą 3 poprawiała precyzję pomiarów czujników laserowych 2D od 21% w przypadku RPLidarA2, do ponad 30% w przypadku RSL425XL, microScan3 oraz RPLidarA1.

Kolejne eksperymenty miały na celu ocenę wpływu zmiennej szerokości okna na precyzję i dokładność pomiarów odległości przy użyciu czujników laserowych 2D. Badanie umożliwiło identyfikację optymalnej szerokości okna dla każdego z analizowanych urządzeń. Rysunek 5.4 przedstawia wpływ MF z szerokościami okna od 0 do 15 na pomiary wybranych czujników laserowych 2D.

Optymalna szerokość okna dla RSL425 XL wynosiła 9, co pozwoliło na poprawę precyzji o 49,19%. W rezultacie STDEV zmniejszyło się z 0,00638 m do 0,00324 m. Jednak największą poprawę dokładności, wynoszącą 2,25%, uzyskano przy szerokości okna równej 7.

Dla microScan3 optymalna szerokość okna wynosiła 11, co pozwoliło na poprawę precyzji o 48,06%. STDEV zostało wówczas zredukowane z 0,00246 m do 0,00128 m. Z kolei największą poprawę dokładności, wynoszącą 1,49%, uzyskano przy szerokości okna równej 9.

W przypadku RPLidarA1 najlepsze rezultaty uzyskano przy szerokości okna równej 9, z poprawą precyzji o 47,52%. STDEV spadło z 0,00219 m do 0,00115 m. Jednak największy wzrost dokładności, wynoszący 4,23%, osiągnięto przy szerokości okna równej 5.


Dla RPLidarA2 optymalna szerokość okna wynosiła 13, co przełożyło się na poprawę precyzji o 43,48%. Wartość STDEV została zredukowana z 0,00123 m do 0,00069 m. W tym przypadku największy wzrost dokładności, wynoszący 3,01%, osiągnięto przy tej samej szerokości okna równej 13.

Jak można zaobserwować, zastosowanie MF, nawet przy najmniejszej szerokości okna, ma znaczący wpływ na poprawę precyzji pomiarów z LiDAR-ów 2D. Jednak wpływ na dokładność pomiarów jest stosunkowo niewielki. Co więcej, wybór optymalnej szerokości okna pod względem precyzji niekoniecznie gwarantuje najwyższą dokładność, dlatego też należy dobierać indywidualnie konfigurację filtra, w zależności od planowanych działań.


Tabela 5.1 przedstawia zagregowane wyniki filtracji filtrem medianowym oraz filtrem średnią ruchomą przy wykorzystaniu różnej szerokości okna filtrującego. Wyniki dla szerokości okna równej 0 przedstawiają wyjściowe wartości parametrów dla danego czujnika. Wyniki prezentowane są aż do najkorzystniejszej szerokości okna uzyskanej przy zastosowaniu filtra medianowego. Porównując oba filtry, to filtr medianowy pozwolił uzyskać największą oraz najstabilniejszą poprawę precyzji sięgającą blisko 50% dla każdego z testowanych czujników.

Tabela 5.1: Wyniki filtracji metodą medianową oraz średnią ruchomą.


RSL425XL		Filtracja medianowa				Filtracja średnią ruchomą			
Szerokość okna	STDEV [m]	RMSE [m]	STDEV imp	RMSE imp	STDEV [m]	RMSE [m]	STDEV imp	RMSE imp	
0	0.00638	0.02200	0.00%	0.00%	0.00638	0.02200	0.00%	0.00%	
3	0.00441	0.02162	30.96%	1.74%	0.00508	0.02166	20.42%	1.54%	
5	0.00369	0.02158	42.23%	1.90%	0.00553	0.02178	13.35%	1.00%	
7	0.00333	0.02150	47.83%	2.25%	0.00611	0.02194	4.22%	0.24%	
9	0.00324	0.02156	49.19%	1.99%	0.00678	0.02215	-6.27%	-0.70%	
microScan3		Filtracja medianowa				Filtracja średnią ruchomą			
0	0.00246	0.01240	0.00%	0.00%	0.00246	0.01240	0.00%	0.00%	
3	0.00171	0.01230	30.75%	0.78%	0.00386	0.01275	-56.91%	-2.84%	
5	0.00142	0.01225	42.26%	1.24%	0.00495	0.01313	-101.15%	-5.90%	
7	0.00132	0.01222	46.42%	1.47%	0.00585	0.01350	-137.38%	-8.88%	
9	0.00129	0.01222	47.78%	1.49%	0.00662	0.01386	-168.80%	-11.79%	
11	0.00128	0.01222	48.06%	1.46%	0.00732	0.01422	-197.31%	-14.66%	
RPLidar A1		Filtracja medianowa				Filtracja średnią ruchomą			
0	0.00219	0.00789	0.00%	0.00%	0.00219	0.00789	0.00%	0.00%	
3	0.00146	0.00763	33.46%	3.32%	0.00391	0.00845	-78.70%	-7.08%	
5	0.00122	0.00756	44.09%	4.23%	0.00505	0.00902	-130.77%	-14.33%	
7	0.00117	0.00758	46.30%	4.03%	0.00598	0.00957	-173.37%	-21.24%	
9	0.00115	0.00757	47.52%	4.12%	0.00678	0.01008	-209.75%	-27.71%	
RPLidar A2		Filtracja medianowa				Filtracja średnią ruchomą			
0	0.00123	0.00639	0.00%	0.00%	0.00123	0.00639	0.00%	0.00%	
3	0.00097	0.00630	21.32%	1.39%	0.00375	0.00729	-205.04%	-14.14%	
5	0.00087	0.00626	29.42%	2.04%	0.00495	0.00798	-303.06%	-24.94%	
7	0.00081	0.00624	33.78%	2.35%	0.00589	0.00860	-379.29%	-34.61%	
9	0.00074	0.00622	40.13%	2.64%	0.00670	0.00918	-445.23%	-43.67%	
11	0.00073	0.00622	40.27%	2.60%	0.00742	0.00972	-503.83%	-52.19%	
13	0.00069	0.00620	43.48%	3.01%	0.00808	0.01024	-557.28%	-60.28%	




(a)




(b)




(c)




(d)




(e)



(f)




(g)




(h)


Rysunek 5.1: Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji średnią ruchomą (AF) z szerokością okna równą 3.




(a)



(b)




(c)




(d)


Rysunek 5.2: Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji średnią ruchomą (AF) z różnymi szerokościami okna.




(a)




(b)




(c)




(d)




(e)



(f)




(g)



(h)

Rysunek 5.3: Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji medianowej (MF) z szerokością okna równą 3.



Rysunek 5.4: Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji medianowej (MF) z różnymi szerokościami okna.

Rozdział 6

Kalibracja odometrii

Odometria jest jedną z kluczowych informacji służących do śledzenia ruchów AGV. Dane na temat odometrii pozwalają na obliczenie prędkości oraz pozycji AGV. Z tego względu dokładność odometrii ma istotny wpływ na dokładność wykonywanych przez AGV działań, a tym samym na proces dokowania. Dlatego też ocena jakości danych odometrycznych oraz ich kalibracja jest istotnym elementem poprawy dokładności dokowania systemów AGV do stacji montażowych.

Mobilne platformy klasy AGV posiadają zazwyczaj dwa napędy zamontowane w środkowej osi pojazdu (po jednym z obu stron AGV) oraz ewentualnie koła podporowe (np. koła wielokierunkowe) z przodu i z tyłu platformy. Platformy tego typu wykorzystują różnicowy model ruchu (ang. differential drive kinematics), co pozwala im oprócz jazdy w przód, w tył oraz po łuku, obracać się także w miejscu. Dane odometryczne pochodzą z enkoderów zamontowanych na napędach platformy mobilnej. W trakcie obracania się kół enkodery zliczają impulsy, które następnie przeliczane są na odległość pokonaną przez dane koło platformy mobilnej.

Na dane odometryczne dostarczane przez system AGV składają się prędkość lewego oraz prawego koła, które umożliwiają obliczenie pozycji oraz orientacji platformy mobilnej typu AGV względem punktu startowego. Nawigacja zliczeniowa (ang. dead reckoning) w przypadku platform o różnicowym modelu ruchu wykorzystuje prędkość platformy, różnice w prędkościach pomiędzy prawym, a lewym kołem oraz odległość pomiędzy kołami w celu obliczenia prędkości liniowej (6.1) oraz kątownej (6.2), które posłużą do obliczenia pozycji oraz orientacji systemu AGV (6.5). Prędkość liniową i kątową wyraża się następującymi wzorami:

$$V = \frac{\omega_L r + \omega_R r}{2} \quad (6.1)$$

$$\omega = \frac{\omega_R r - \omega_L r}{D} \quad (6.2)$$

gdzie:

- ω_R to prędkość kątowna prawego koła [rad/s]
- ω_L to prędkość kątowna lewego koła [rad/s]
- r to promień koła [m]
- V to prędkość liniowa AGV [m/s]
- ω to prędkość kątowna AGV (wokół osi Z) [rad/s]

- D to odległość pomiędzy kołami $[m]$

Znając przebytą drogę S oraz obrót platformy o kąt $\Delta\omega$ możliwe jest obliczenie pozycji x, y oraz orientacji θ systemu AGV w chwili k po czasie Δt przy wykorzystaniu poniższych równań:

$$S = V\Delta t \quad (6.3)$$

$$\Delta\omega = \omega\Delta t \quad (6.4)$$

$$\begin{cases} x_{k+1} = x_k + S \cos(\theta_k + \frac{\Delta\omega}{2}) \\ y_{k+1} = y_k + S \sin(\theta_k + \frac{\Delta\omega}{2}) \\ \theta_{k+1} = \theta_k + \Delta\omega \end{cases} \quad (6.5)$$

Aby możliwe było sprawdzenie jakości danych odometrycznych dostarczanych przez AGV, konieczne jest przygotowanie odpowiedniego środowiska eksperymentalnego, oprogramowania do sterowania i akwizycji danych oraz odpowiedniej metodyki.

Środowisko testowe powinno być na tyle duże, aby umożliwić przemieszczenia AGV na odległość co najmniej kilkukrotnie większą od długości samego AGV. Na podłożu należy wyznaczyć specjalny punkt lub linię startową, która umożliwi ręczny pomiar rzeczywistej odległości przebytej przez AGV.

Oprogramowanie sterujące i gromadzące dane odometryczne powinno zostać zaprojektowane i opracowane tak, aby umożliwić wykonywanie zadanych ruchów w powtarzalny sposób. Powinno ono śledzić w czasie rzeczywistym pozycję i orientację AGV, pozwalając na zapisanie pozycji i orientacji początkowej, końcowej, jak również w momencie odebrania przez AGV polecenia zatrzymania ruchu.

Istnieje wiele potencjalnych przyczyn błędów w pozycjonowaniu platformy mobilnej, które mogą wynikać z niewłaściwej konfiguracji systemu odometrii AGV, np.:

- nieprawidłowa liczba impulsów enkodera przypisana do pełnego obrotu napędu,
- błędna średnica koła,
- błędna wartość rozstawu kół,
- błąd w obliczaniu liczby impulsów na daną odległość,
- błąd w obliczaniu prędkości zadanej na napędy kół - co często wynika z wcześniej wspomnianego błędu w obliczaniu liczby impulsów na daną odległość,
- zbyt napięty lub zbyt luźny łańcuch napędowy,
- błąd w obliczaniu prędkości koła, raportowanej przez AGV.

6.1 Metoda sprawdzająca jakość odometrii w ruchu liniowym

Aby ocenić jakość ruchu liniowego AGV, należy przeprowadzić serię prostoliniowych przejazdów, w których polecenie sterujące zawiera jedynie wartość prędkości

liniowej. Ruchy powinny zostać wykonane dla kilku różnych docelowych odległości. Każda z tych odległości powinna być testowana przy różnych wartościach docelowej prędkości liniowej. Każda kombinacja odległości i prędkości powinna zostać powtórzona kilkukrotnie aby zwiększyć reprezentatywność wyników. Oprogramowanie sterujące wysyła polecenie zatrzymania się w momencie osiągnięcia przez AGV zadanej odległości.

Takie podejście pozwala zgromadzić odpowiednio dużą liczbę danych, aby przeprowadzić walidację systemu odometrii i określić ewentualne błędy.

Błędy te mogą przyjmować jedną z następujących postaci:


- różnica między odległością przebytą według systemu odometrii a rzeczywistą odległością zmierzoną ręcznie (jako wartość referencyjna),
- systematyczny błąd odometrii, możliwy do zauważenia przy różnych docelowych odległościach,
- systematyczny błąd odometrii, możliwy do zauważenia przy różnych docelowych prędkościach liniowych,
- inne ruchy/zachowania, specyficzne dla danej platformy AGV.

6.2 Metoda sprawdzająca jakość odometrii w ruchu obrotowym

W celu sprawdzenia jakości ruchów obrotowych AGV, należy przeprowadzić serię obrotów (zgodnie z ruchem wskazówek zegara lub przeciwnie), w których polecenie sterujące określa wyłącznie prędkość kątową. Seria ruchów obrotowych powinna zostać wykonana dla kilku różnych docelowych kątów obrotu. Każdy z tych kątów powinien zostać przetestowany przy różnych wartościach docelowej prędkości kątowej. Każda kombinacja docelowego kąta obrotu i prędkości powinna zostać powtórzona kilkukrotnie. Oprogramowanie sterujące wysyła polecenie zatrzymania się w momencie osiągnięcia docelowego kąta obrotu.

Aby możliwa była walidacja obrotów AGV, potrzebne jest dodatkowe źródło informacji. Naturalnym wyborem jest IMU z żyroskopem, który umożliwia śledzenie prędkości kątowej platformy mobilnej, jednak może on wprowadzać własne błędy pomiarowe, a dodatkowo testowany AGV nie był wyposażony w czujnik żyroskopowy. W zastępstwie IMU wykorzystano skalibrowany LiDAR 2D zamontowany na platformie AGV.

Rzeczywisty kąt obrotu został obliczony przy użyciu skalibrowanego (przy użyciu metody ACM) LiDAR-u 2D zamontowanego na AGV. W tym celu opracowano autorski algorytm nazwany 2D LiDAR Alignment Test (2DLAT), który przetwarza odczyty odległości względem zadanego kąta biegunowego AGV. Algorytm gromadził pomiary z LiDAR-u 2D w określonych odchyleniach w lewo (przeciwnie do ruchu wskazówek zegara) oraz w prawo (zgodnie z ruchem wskazówek zegara) względem wybranego kąta biegunowego AGV (rysunek 6.1). Dla każdego z odchyłeń zgromadzono 80 pomiarów odległości, które następnie uśredniano, a średnie wartości wykorzystano do oszacowania kąta odchylenia platformy AGV względem ściany.



Rysunek 6.1: Uproszczony schemat wyznaczenia kąta odchylenia systemu AGV od powierzchni względem której wykonywana jest metoda 2DLAT.

Jeśli nie występuje różnica między średnimi odległościami, oznacza to, że wybrany kąt biegunowy AGV jest dokładnie prostopadły do ściany. Wystąpienie różnicy wskazuje na rozbieżność w prostopadłości pomiędzy wybranym kątem polarnym AGV a ścianą (rysunek 6.2). Rozbieżność ta może zostać obliczona za pomocą twierdzenia cosinusów.

$$c = \sqrt{a^2 + b^2 - 2ab \cos 2\alpha} \quad (6.6)$$


$$\delta = \arccos\left(\frac{c^2 + b^2 - a^2}{2cb}\right) \quad (6.7)$$

$$\delta = \beta + \gamma \quad (6.8)$$

$$\beta + 90^\circ + \alpha = 180^\circ \quad (6.9)$$

$$\gamma = \delta - \beta \quad (6.10)$$

W pierwszej kolejności obliczana jest długość boku c (odcinek między punktami kolizji promieni laserowych na ścianie), następnie obliczany jest kąt δ pomiędzy prawym bokiem b a bokiem c . Wiedząc, że suma kątów wewnętrznych trójkąta wynosi 180° , można obliczyć kąt β . Kąt δ , zawiera kąty γ i β . Odejmując β od δ , otrzymujemy kąt γ odchylenia AGV względem ściany.



Rysunek 6.2: Schemat wyznaczania kąta odchylenia systemu AGV od powierzchni względem której wykonywana jest metoda 2DLAT.

Pojedyncze sprawdzenie jakości ruchu kąтового rozpoczyna się od manualnego ustawienia czoła AGV równoległe (lub blisko równoległości) do ściany. Następnie wykonywany jest test 2D LiDAR Alignment Test (2DLAT) dla kąta 0° AGV (wykonanie serii pomiarów przy wykorzystaniu LiDAR-u 2D, obliczenie i zapisanie kąta odchylenia). Kolejno AGV wykonuje obrót zgodnie z ruchem wskazówek zegara o zadany kąt ρ . Po zakończeniu obrotu ponownie wykonywany jest test 2DLAT dla kąta ρ AGV.

Końcowe przemieszczenie może zostać obliczone jako:

$$rotation_error = 2DLAT(\rho) + \rho - 2DLAT(0^\circ) \quad (6.11)$$

Zastosowanie metody 2DLAT i wykonanie serii takich testów pozwala na zgromadzenie wystarczającej liczby danych w celu walidacji systemu odometrii oraz pomiaru ewentualnych błędów. Błędy te mogą objawiać się jako:

- różnica pomiędzy kątem obrotu raportowanym przez system odometrii a rzeczywistym obrotem zmierzonym przy użyciu skalibrowanego LiDAR-u 2D jako odniesienia,
- systematyczny błąd odometrii możliwy do zauważenia dzięki zastosowaniu różnych docelowych kątów obrotu,
- systematyczny błąd odometrii możliwy do zauważenia dzięki zastosowaniu różnych docelowych prędkości kątowych,
- inne ruchy/zachowania, specyficzne dla danej platformy AGV.

Pomiary wykonywane przez skalibrowany przy użyciu metody ACM LiDAR 2D posiadają dokładność oraz precyzję zapewnianą przez metodę ACM dla wybranego LiDAR-u 2D (podrozdział 4.1.6). Uśredniając 80 pomiarów odległości skalibrowanego czujnika zbliżamy się do wartości referencyjnej odległości.

6.3 Wyniki badań jakości odometrii

Test jakości odometrii został przeprowadzony dla AGV Formica 1, platformy mobilnej produkcji firmy AIUT. Oprogramowanie umożliwiające sterowanie i akwizycję

danych zostało stworzone z wykorzystaniem platformy ROS. Moduł ROS wysyłał polecenia prędkości do PLC (głównej jednostki sterującej AGV) oraz odbierał dane odometryczne. W momencie, gdy AGV pokonał zadaną odległość lub kąt (obliczany na podstawie danych odometrycznych AGV), moduł ROS wysyłał polecenie zatrzymania (zerowe prędkości).

Pierwszy test odometrii polegał na serii przejazdów AGV do przodu. Każda seria miała inną zadaną odległość oraz inną zadaną prędkość liniową i była powtarzana trzykrotnie. AGV zawsze startował z tego samego miejsca, a po każdym przejeździe rzeczywista przebyta odległość była mierzona taśmą mierniczą.

Tabela 6.1 przedstawia przebyte odległości zmierzone przez enkodery AGV oraz przez taśmę mierniczą dla różnych zadanych odległości i prędkości liniowych. Z danych w tabeli wynika, że im większa prędkość liniowa, tym większa rzeczywista odległość przebyta dla tej samej zadanej odległości. Odległość odometryczna jest zawsze mniejsza niż rzeczywista odległość. Różnica między rzeczywistą odległością, a odległością z danych odometrycznych nie zależy od zadanej prędkości liniowej, lecz od zadanej odległości. Z tego powodu obliczono błąd odometrii, który przypada na każdy 1m przebytej odległości. Wyniki pokazują, że wartość błędu odometrii jest zbliżona we wszystkich kombinacjach odległości i prędkości, a średni błąd wynosi -0,0105 m. Źródłem błędu może być nieprawidłowa konfiguracja systemu sterowania napędem AGV (błąd systematyczny) lub niewłaściwa konfiguracja enkoderów.

Tabela 6.1: Błąd liniowy odometrii AGV w ruchu liniowym - Formica 1.

Błąd odometrii w ruchu liniowym					
zadana odległość [m]	zadana prędkość liniowa [cm/s]	odległość zmierzona przez odometrię [m]	odległość zmierzona taśmą mierniczą [m]	błąd odometrii [m]	błąd odometrii na każdy przebyty 1 m [m]
1	5	1.0288	1.0407	-0.0119	-0.0114
1	10	1.0551	1.0657	-0.0106	-0.0099
1	30	1.2333	1.2470	-0.0137	-0.0110
2	5	2.0281	2.0487	-0.0206	-0.0100
2	10	2.0567	2.0790	-0.0223	-0.0107
2	30	2.2241	2.2490	-0.0249	-0.0111
3	5	3.0272	3.0543	-0.0271	-0.0089
3	10	3.0566	3.0917	-0.0350	-0.0113
3	30	3.2218	3.2550	-0.0332	-0.0102

Tabela 6.2 przedstawia odległości zmierzone do momentu wysłania sygnału zatrzymania oraz całkowite przebyte odległości dla różnych zadanych odległości i prędkości liniowych. Obie wartości zostały zmierzone przez enkodery AGV. Z danych wynika, że droga hamowania zależy od zadanej wartości prędkości liniowej – im większa prędkość, tym dłuższa droga hamowania. Dla prędkości 5 cm/s i 10 cm/s droga hamowania stanowi około 45–50% wartości zadanej prędkości. Jednak dla największej prędkości (30 cm/s) droga hamowania wynosi około 70% zadanej prędkości. Może to wynikać z wcześniej zdefiniowanej rampy hamowania w systemie bezpieczeństwa AGV. Takie zachowanie AGV można zaklasyfikować do cech charakterystycznych dla danej platformy mobilnej.

Tabela 6.3 przedstawia różnicę w orientacji pomiędzy początkiem a końcem ruchu w testach jazdy na wprost. Polecenie wysyłane do PLC zawierało jedynie wartość

Tabela 6.2: Odległość hamowania AGV w ruchu liniowym - Formica 1.

Odległość hamowania w ruchu liniowym					
zadana odległość [m]	zadana prędkość liniowa [cm/s]	odległość zmierzona przez odometrię - do sygnału stop [m]	odległość zmierzona przez odometrię - do momentu zatrzymania [m]	odległość hamowania [m]	procent prędkości liniowej [%]
1	5	1.0056	1.0288	0.0232	46.3067
1	10	1.0063	1.0551	0.0488	48.8233
1	30	1.0178	1.2333	0.2155	71.8322
2	5	2.0033	2.0281	0.0248	49.5400
2	10	2.0111	2.0567	0.0456	45.6267
2	30	2.0206	2.2241	0.2035	67.8311
3	5	3.0047	3.0272	0.0225	45.0733
3	10	3.0110	3.0566	0.0456	45.5767
3	30	3.0209	3.2218	0.2008	66.9422

prędkości liniowej, bez prędkości kątowej. Tabela pokazuje błąd orientacji AGV powstały podczas jazdy na wprost. Różnice w orientacji zależą od zadanej prędkości liniowej – im większa prędkość, tym mniejsza różnica w orientacji pomiędzy startem a końcem przejazdu. Jednak błąd prędkości kątowej odometrii pozostaje niemal stały i wynosi średnio około $-0,2193^\circ/\text{s}$. We wszystkich testach jazdy na wprost, AGV stale zbacał w prawo. Lewe koło poruszało się szybciej niż prawe, a różnica w prędkościach kół wynosi około $2,5644 \text{ mm/s}$ (zakładając, że odległość między kołami wynosi $0,67 \text{ m}$). Podczas wykonywanych eksperymentów AGV zbacał coraz mniej wraz ze wzrostem prędkości jednak było to spowodowane tym, że przy większych wartościach prędkości liniowej, AGV miał mniej czasu na skumulowanie się błędu odometrii.

Tabela 6.3: Błąd kątowy odometrii AGV w ruchu liniowym - Formica 1.

Błąd kątowy odometrii w ruchu liniowym			
zadana odległość [m]	zadana prędkość liniowa [cm/s]	różnica pomiędzy orientacją początkową a końcową $[\circ]$	błąd prędkości kątowej $[\circ/\text{s}]$
1	5	-4.2758	-0.2054
1	10	-2.4800	-0.2327
1	30	-1.1972	-0.2880
2	5	-8.2381	-0.2011
2	10	-4.7319	-0.2276
2	30	-1.6248	-0.2167
3	5	-12.1148	-0.1983
3	10	-7.0693	-0.2287
3	30	-1.9099	-0.1760

Tabela 6.4 przedstawia różnice w orientacji AGV podczas hamowania, tzn. między orientacją w momencie wysłania sygnału zatrzymania a końcową orientacją.

Podczas hamowania wszystkie różnice w orientacji były mniejsze niż 1 stopień. Największe różnice występowały przy najwyższej prędkości liniowej (30 cm/s), co jest naturalne, ponieważ AGV potrzebował więcej czasu na zatrzymanie. Ze względu na niedoskonałości/błędy enkoderów lub systemu napędowego AGV, niemal każde zatrzymanie kończyło się lekkim skrętem w prawo.

Tabela 6.4: Różnice w orientacji AGV podczas hamowania w ruchu liniowym - Formica 1.

Różnice w orientacji AGV podczas hamowania w ruchu liniowym				
zadana odległość [m]	zadana prędkość liniowa [cm/s]	różnica pomiędzy orientacją początkową a orient. w sygnale stop [°]	różnica pomiędzy orientacją początkową a końcową [°]	różnica pomiędzy orientacją w sygnale stop a końcową [°]
1	5	-4.0763	-4.2758	-0.1995
1	10	-2.3374	-2.4800	-0.1425
1	30	-0.8837	-1.1972	-0.3136
2	5	-8.1525	-8.2381	-0.0855
2	10	-4.7889	-4.7319	0.0570
2	30	-0.9122	-1.6248	-0.7126
3	5	-11.9437	-12.1148	-0.1710
3	10	-7.0123	-7.0693	-0.0570
3	30	-1.6533	-1.9099	-0.2565

Drugi test odometrii polegał na serii obrotów platformy AGV zgodnie z ruchem wskazówek zegara. Każda seria obrotów miała inny docelowy kąt obrotu oraz inną zadaną prędkość kątową AGV i była powtarzana trzykrotnie. AGV zawsze rozpoczynał z tego samego miejsca – czołem do ściany. Rzeczywisty kąt obrotu był obliczany za pomocą skalibrowanego LiDAR-u 2D zamontowanego na platformie AGV oraz dedykowanego algorytmu (2DLAT) uruchamianego przed i po każdym teście.

Tabela 6.5 przedstawia przebyte kąty obrotów, które zostały zmierzone przez enkodery AGV oraz LiDAR 2D dla różnych docelowych kątów oraz zadanych prędkości kątowych.

Z danych w tabeli 6.5 wynika, że im większa prędkość kątowa, tym większy rzeczywisty kąt obrotu dla tej samej zadanej wartości. Kąt obrotu obliczony z odometrii jest zawsze mniejszy niż rzeczywisty kąt. Różnica między kątem obrotu obliczonym na podstawie danych z LiDAR-u 2D a kątem raportowanym przez odometrię nie zależy od zadanej prędkości kątowej, lecz od zadanego kąta. Dlatego też błędy odometrii są zbliżone do siebie dla tej samej wartości zadanego kąta. Jednak błąd dla każdego przebytego stopnia różni się pomiędzy seriami z różnymi docelowymi kątami obrotu.

Błąd kąta obrotu dla każdego przebytego stopnia wynosi średnio:

- dla kąta -15° : 0.0513°,
- dla kąta -55° : 0.0724°,
- dla kąta -90° : 0.0428°.

Wyniki prezentowane w tabeli 6.5 nie wskazują jednoznacznej wartości systematycznego błędu kątowego. Widoczny jest jednak stały błąd kątowy dla zadanych kątów -55 oraz -90 . Powodem tego może być nieprawidłowe działanie kontrolerów napędów, które przy dużych tarciach kół o podłoże starają się zrekompensować niewykonane cykle obrotu kół, wynikiem czego są gwałtowne szarpnięcia po wykonaniu

danego ruchu, nieodzwierciedlone w danych odometrycznych. Problem ten wskazuje na potrzebę zastosowania dodatkowego źródła informacji podczas obrotów, np. IMU i pomiar prędkości kątowej w osi Z (YAW) przy użyciu żyroskopu, aby lepiej estymować orientację AGV.

Tabela 6.5: Błąd kątowy odometrii AGV w ruchu kątowym - Formica 1.

Błąd odometrii w ruchu kątowym					
zadany kąt [°]	zadana prędkość kątowa [°/s]	kąt zmierzony przez odometrię [°]	kąt zmierzony przez 2DLAT [°]	błąd kątowy [°]	błąd kątowy na każdy przebyty 1°
-15	5.7296	-17.7588	-18.6434	0.8845	0.0474
-15	11.4592	-20.3528	-21.5374	1.1845	0.0550
-15	17.1887	-23.6024	-24.8838	1.2813	0.0515
-55	5.7296	-57.8089	-62.5865	4.7776	0.0763
-55	11.4592	-61.3720	-66.2295	4.8575	0.0733
-55	17.1887	-65.1062	-69.8217	4.7155	0.0675
-90	5.7296	-92.9845	-96.8730	3.8885	0.0401
-90	11.4592	-96.0060	-100.5767	4.5706	0.0454
-90	17.1887	-99.3982	-103.8430	4.4449	0.0428

Tabela 6.6 przedstawia kąty obrotów w momencie wysłania sygnału zatrzymania oraz całkowite przebyte kąty obrotów dla różnych docelowych kątów oraz prędkości kątowych. Obie wartości zostały zmierzone przez enkodery AGV. Z danych wynika, że droga hamowania zależy od zadanej prędkości kątowej – im większa prędkość, tym większy kąt hamowania. Dla wszystkich zadanych prędkości, kąt hamowania wynosi od około 39% do 54% wartości prędkości kątowej.

Tabela 6.6: Kąt hamowania w ruchu kątowym - Formica 1.

Kąt hamowania w ruchu kątowym					
zadany kąt [°]	zadana prędkość kątowa [°/s]	kąt zmierzony przez odometrię - do sygnału stop [°]	kąt zmierzony przez odometrię [°]	kąt hamowania [°]	procent prędkości kątowej [%]
-15	5.7296	-15.3074	-17.7588	-2.4515	42.7860
-15	11.4592	-15.2219	-20.3528	-5.1310	44.7760
-15	17.1887	-16.4191	-23.6024	-7.1834	41.7911
-55	5.7296	-55.5569	-57.8089	-2.2519	39.3033
-55	11.4592	-55.8705	-61.3720	-5.5015	48.0098
-55	17.1887	-55.6710	-65.1062	-9.4353	54.8922
-90	5.7296	-90.3905	-92.9845	-2.5940	45.2737
-90	11.4592	-90.8751	-96.0060	-5.1310	44.7760
-90	17.1887	-90.9036	-99.3982	-8.4946	49.4196

Tabela 6.7 przedstawia różnice w położeniu AGV pomiędzy punktem początkowym a końcowym podczas testów obrotu. Prędkość wysyłana do PLC zawierała

wyłącznie zadaną prędkość kątową, a prędkość liniowa była równa zeru. Tabela 6.7 prezentuje przesunięcie pomiędzy pozycją początkową AGV a pozycją końcową po wykonaniu obrotu. Różnice te są wynikiem nierównomiernych sił działających na koła AGV, które obracają się w przeciwnych kierunkach oraz tarcia kół o podłoże. Wartości poszczególnych przesunięć są skorelowane z zadaną prędkością kątową i mają związek z wyznaczonym błędem kątowym (różnicą w prędkościach prawego oraz lewego koła) podczas badania jakości odometrii w ruchu liniowym.

Tabela 6.7: Odległość pomiędzy pozycją początkową AGV a pozycją końcową w ruchu kątowym - Formica 1.

Odległość pomiędzy pozycją początkową a końcową w ruchu kątowym		
zadany kąt [°]	zadana prędkość kątowa [°/s]	odległość pomiędzy pozycją startową a końcową [m]
-15	5,7296	0,0038
-15	11,4592	0,0020
-15	17,1887	0,0013
-55	5,7296	0,0121
-55	11,4592	0,0071
-55	17,1887	0,0046
-90	5,7296	0,0151
-90	11,4592	0,0099
-90	17,1887	0,0065

6.4 Wprowadzenie korekty odometrii

Jeśli występuje różnica między wartością dostarczaną przez system AGV w danych odometrycznych a wartością referencyjną (np. zmierzona manualnie), należy przeprowadzić kalibrację tych danych. Dane odometryczne generowane przez system AGV powinny odpowiadać rzeczywistym pomiarom, aby system nawigacji sterujący platformą dysponował wiarygodnymi informacjami o prędkości poszczególnych napędów AGV.

Jeżeli natomiast różnica występuje między wartością zadaną a otrzymaną z systemu AGV, lecz dane odometryczne są zgodne z rzeczywistością, system nawigacji nadal będzie w stanie prawidłowo sterować platformą. W sytuacji, gdy taka rozbieżność wynika z błędu systematycznego charakterystycznego dla sposobu poruszania się platformy, konieczne jest wprowadzenie korekty do rozkazów prędkości wysyłanych do układu sterowania AGV.

Badania jakości odometrii systemu AGV Formica 1, wykazały błąd systematyczny w ruchu liniowym B_{odom_lin} wynoszący -1,05 cm na każdy przebyt 1 m. Błąd ten można skorygować poprzez modyfikację promieni obu kół r_{kola} lub korektę otrzymywanych danych odometrycznych S_{odom} . Błąd systematyczny B_{odom_lin} oraz współczynnik korekcji w ruchu liniowym K_S obliczany jest następująco:

$$B_{odom_lin} = \frac{S_{odom} - S_{rzeczywiste}}{S_{rzeczywiste}} \quad (6.12)$$

$$K_S = \frac{S_{rzeczywista}}{1 + B_{odom_lin}} \quad (6.13)$$

a następnie w celu korekcji K_S jest przemnażany przez wartości promieni obu kół:

$$r_{skalibrowane} = r_{kola} K_S \quad (6.14)$$

lub otrzymanej wartości przebytej odległości przez dane koło:

$$S_{skalibrowane} = S_{odom} K_S \quad (6.15)$$

W przypadku błędu w ruchu liniowym, wartość K_S dla AGV Formica 1 wynosi:

$$K_S = \frac{1}{1 - 0.0105} = 1.01061 \quad (6.16)$$

Badania jakości odometrii AGV Formica 1 wykazały również różnicę prędkości kół podczas ruchu liniowego. Platforma AGV stale zbaczała w prawo podczas gdy wartość zadanej prędkości kątowej w rozkazie była zerowa. Systematyczny błąd kątowy B_{kat_odom} był skorelowany z wartością prędkości liniowej i został obliczony na podstawie otrzymanych danych odometrycznych - różnicy pomiędzy orientacją początkową a końcową AGV.

$$B_{kat_odom_lin} = \frac{\theta_{koniec} - \theta_{start}}{t_{przejazdu}} \quad (6.17)$$

Średnia wartość systematycznego błędu kątowego w ruchu liniowym dla AGV Formica 1 wynosiła $-0,2193^\circ/s$ ($-0,00383$ rad/s) co wykorzystując wzór 6.2 można przeliczyć na różnicę prędkości pomiędzy lewym, a prawym kołem AGV. Zakładając, że wartość odległości pomiędzy kołami wynosi $0,67$ m, różnica prędkości ΔV_{R_L} wynosi:

$$\Delta V_{R_L} = B_{kat_odom_lin} D \quad (6.18)$$

Podstawiając dane do wzoru 6.18:

$$\Delta V_{R_L} = -0.0038275 rad/s * 0.67m = -0.0025644m/s = -2.5644mm/s \quad (6.19)$$

można obliczyć wartość różnicy prędkości pomiędzy kołami wynoszącą -2.5644 mm/s. Różnicę prędkości potwierdzają obserwacje zbaczania platformy w prawo co jest spowodowane większą prędkością lewego koła.

Błąd ten można skorygować poprzez modyfikację prędkości kątowej ω lub modyfikację prędkości kół w przesyłanych rozkazach prędkości:

$$\omega_{skalibrowane} = \omega + B_{kat_odom_lin} \quad (6.20)$$

lub

$$V_{L_skalibrowane} = V_L + \frac{\Delta V_{R_L}}{2} \quad (6.21)$$

$$V_{R_skalibrowane} = V_R - \frac{\Delta V_{R_L}}{2} \quad (6.22)$$

Podczas wykonywania eksperymentów zastosowanie korekty dla zadawanej prędkości kątowej ω pozwoliło na wyeliminowanie zbaczania platformy AGV w prawo.

Możliwe jest również, jak pokazały wyniki badań dokowania (opisane w podrozdziale 9.3) przeprowadzone na platformie AGV Formica 3, że podczas wykonywania ruchu liniowego platforma w rzeczywistości nie zbacza, jednak dane odometryczne przesyłane przez platformę informują o ciągłym zbaczaniu w prawo. Średnia wartość błędu prędkości kątowej AGV wynosiła -0.0056 rad/s. Błąd tego typu należy skorygować poprzez korektę prędkości kół w otrzymywanych danych odometrycznych. W pierwszej kolejności należy obliczyć różnicę prędkości pomiędzy kołami (wykorzystując wzór 6.2) biorąc pod uwagę rozstaw kół platformy Formica 3 (0.471 m). Następnie należy skorygować wartości otrzymywanych prędkości w danych odometrycznych z wykorzystaniem wzorów 6.21 oraz 6.22.

Przeprowadzono również badania jakości odometrii w ruchu kątowym (obrót wokół osi AGV) wykorzystując autorską metodę 2DLAT. Badania wykazały błąd systematyczny (skorelowany z zadawaną prędkością kątową) w postaci przesunięcia pomiędzy pozycją początkową, a końcową co jest związane z różnicą prędkości kół przy tej samej prędkości zadanej na każde koło.

Badania pozwoliły również wyznaczyć stały błąd wynikający z charakterystycznego szarpnięcia (gwałtowny obrót w prawo po wykonaniu zadanego obrotu). Błąd ten jest widoczny w eksperymentach, w których zadany kąt był równy -55° oraz -90° . Średnia wartość tego błędu to $4,5424^\circ$. Jest to błąd wykryty dzięki opracowanej metodzie 2DLAT, który jest trudny do zniwelowania ponieważ nie jest to błąd systematyczny i nie jest raportowany w danych odometrycznych. Wyeliminowanie tego błędu wymagałoby ingerencji w konfigurację lub też implementację kontrolerów napędów AGV. Środkiem zaradczym na tego typu błędy byłoby wykorzystanie żyroskopu znajdującego się w IMU, który pozwoliłby lepiej wyznaczyć orientację AGV.

Badania jakości odometrii w ruchu kątowym nie wykazały jednak błędu systematycznego $B_{kat_odom_kat}$, który wpływałby na wartość obliczanej orientacji AGV, dzięki czemu dane odometryczne AGV dotyczące ruchu kątowego uznaje się za wiarygodne.

Występowanie błędu $B_{kat_odom_kat}$ świadczyłoby o zawyżonym lub zaniżonym rozstawie kół D . Systematyczny błąd kątowy w ruchu kątowym $B_{kat_odom_kat}$ wyznacza się w następujący sposób - znając wartość kąta obliczonego przez odometrię θ_{odom} oraz rzeczywisty kąt obrotu $\theta_{rzeczywisty}$ (dostarczony przez metodę 2DLAT):

$$B_{kat_odom_kat} = \frac{\theta_{odom} - \theta_{rzeczywisty}}{\theta_{rzeczywisty}} \quad (6.23)$$

Po wyznaczeniu wartości błędu $B_{kat_odom_kat}$ należy obliczyć współczynnik K_D korygujący wartość rozstawu kół:

$$K_D = \frac{\theta_{rzeczywisty}}{1 + B_{kat_odom_kat}} \quad (6.24)$$

oraz zastosować go do obliczenia nowej skalibrowanej wartości rozstawu kół:

$$D_{skalibrowany} = DK_D \quad (6.25)$$

Rozdział 7


Refleksyjny znacznik przestrzenny

Dokładne określenie pozycji AGV zwiększa dokładność planowania jego ruchu, wpływając na prawidłowe wykonanie funkcji dokowania. Dlatego tak istotne jest, aby AGV potrafił dokładnie określić swoją pozycję poprzez prawidłowe wykrycie otaczających obiektów. W związku z tym nadal istotne są wyzwania związane z pojazdami AGV, które wymagają dalszych ulepszeń w zakresie percepcji otoczenia w zadaniach przemysłowych. Niniejszy rozdział przedstawia nowatorską metodę wykrywania i identyfikacji znaczników opartą na refleksyjności (ang. reflectivity) i wykorzystującą wyłącznie technologię dwuwymiarowego skanowania laserowego (2D LiDAR).

Opracowana metoda oraz struktura znacznika przestrzennego umożliwiają dokładny pomiar odległości i orientacji znacznika, a także identyfikację oraz określenie punktu dokowania przez AGV. Skuteczność zaproponowanej metody została zweryfikowana w ramach eksperymentów dokowania, przeprowadzonych z wykorzystaniem ciężkiego, przemysłowego systemu AGV - wyniki tych eksperymentów przedstawiono w podrozdziale 9.3.

Aby wykrywać obiekty, określać ich położenie [92] oraz identyfikować je [82], konieczne jest zdefiniowanie modelu obiektu zawierającego zestaw cech takich jak rozmiar, kształt, struktura czy kolor. Obecne systemy lokalizacji i identyfikacji znaczników w dużej mierze bazują na metodach wykorzystujących kamery [46]. Doskonałe wyniki osiągane są dzięki zastosowaniu kamer stereoskopowych z pomiarem głębi, które umożliwiają rozpoznawanie obiektów w trzech wymiarach [64]. Jakość tych pomiarów jednak znacznie spada, gdy intensywność oświetlenia rozpoznawanego obiektu jest niska.

W celu realizacji funkcji określania pozycji, niezbędna jest możliwość pomiaru odległości i kąta względem wykrytego obiektu [101]. Nowoczesne pojazdy AGV wykorzystują do tego celu technologię LiDAR. Dwuwymiarowe systemy Light Detection and Ranging (2D LiDAR) umożliwiają pomiar odległości, kąta oraz intensywności odbicia dla każdego punktu pomiarowego, który został oświetlony przez impuls światła lasera. Właściwości te mogą być również wykorzystywane do identyfikacji i lokalizacji obiektów. Wadą rozwiązań opartych na LiDAR-ach 2D jest to, że obiekty oraz ich cechy mogą być wykrywane i analizowane jedynie w dwóch wymiarach układu kartezjańskiego, co umożliwia np. określenie długości i głębokości obiektu. Zaletą tych systemów jest natomiast możliwość wykonywania pomiarów w warunkach słabego oświetlenia oraz wyższa dokładność pomiaru w porównaniu do rozwiązań wizyjnych. Dzięki temu system LiDAR 2D może być wykorzystany do lokalizacji oraz identyfikacji obiektów w środowisku przemysłowym i służyć do precyzyjnego dokowania AGV do stanowiska montażowego (AS).



Rysunek 7.1: Przykład skanu z LiDAR-u 2D z informacją o sile odbitych wiązek laserowych.

Celem niniejszego rozdziału jest zaprezentowanie potencjału zastosowania LiDAR-u 2D do identyfikacji i lokalizacji obiektów w środowiskach przemysłowych. Głównym wyzwaniem było opracowanie metody wykrywania oraz identyfikacji znaczników opartych na refleksyjności z wykorzystaniem technologii LiDAR 2D. Opracowany znacznik przestrzenny oraz metoda jego detekcji i identyfikacji umożliwiają określenie względnego położenia i orientacji AGV względem wykrytego znacznika. Opracowany znacznik przestrzenny pozwala również na osadzenie informacji dzięki różnicom w refleksyjności jego powierzchni, co umożliwia jego identyfikację. Nawet pojedynczy znacznik może być użyty do określenia jego pozycji i orientacji względem AGV.

Skuteczność zaproponowanej metody została potwierdzona poprzez eksperymenty dokowania przeprowadzone z użyciem przemysłowego systemu AGV. Po zakończeniu dokowania, opracowany znacznik przestrzenny oraz metoda zostały użyte do dokładnej weryfikacji pozycji AGV po zakończeniu dokowania.


Nowością oraz zaletą opracowanego rozwiązania jest zastosowanie wyłącznie LiDAR-u 2D do identyfikacji i lokalizacji obiektów w środowisku przemysłowym. Przedstawiona metoda ułatwia dokładną weryfikację wyznaczonej trasy i dokładne dokowanie AGV do stanowiska montażowego (AS), a tym samym prawidłową realizację zadań logistycznych. Niezwykle istotne jest, aby w trakcie procesu dokowania następowała aktualizacja punktu dokowania względem odpowiednio rozmieszczonych znaczników oraz weryfikacja pozycji AGV z wysoką dokładnością. Stanowi to kluczowy krok w zapewnieniu poprawnego i powtarzalnego działania pozostałych podsystemów automatyki, robotyki oraz robotów kolaboracyjnych [103].

Autonomiczne rozwiązania logistyczne w środowiskach przemysłowych wykorzystują głównie technologię LiDAR 2D w pojazdach AGV. Umożliwia ona dokładny pomiar odległości i kąta względem obserwowanego obiektu, co jest kluczowe dla dokładnego oszacowania pozycji w systemach nawigacyjnych. Dodatkowo, niektóre typy LiDAR-ów umożliwiają pomiar siły odbitego światła laserowego dla danego punktu pomiarowego (rys. 7.1). Ta właściwość może być wykorzystywana w różnych zastosowaniach, na przykład do automatycznego wykrywania oznaczeń drogowych w chmurach punktów pozyskanych z mobilnego LiDAR-u [95].


7.1 Metoda detekcji i identyfikacji refleksyjnego znacznika przestrzennego przy użyciu LiDAR-u 2D

W tym podrozdziale opisano metodę detekcji i identyfikacji opracowanego znacznika w oparciu o jego rozmiary i siłę odbitych od niego wiązek z LiDAR-u 2D, które są wykorzystywane do identyfikacji znacznika zamocowanego na stanowisku monta-

żowym (AS).



Rysunek 7.2: Przykład znacznika przestrzennego z kodami refleksyjnymi (a) oraz skanu laserowego uzyskanego przez LiDAR 2D (b). Każdy z segmentów składa się z podsegmentów refleksyjnych i nierefleksyjnych.




Rysunek 7.3: Przykład znaczników przestrzennych z kodami refleksyjnymi zamontowanych na nogach stanowiska montażowego.

Opracowane znaczniki przestrzenne z kodami refleksyjnymi (2DM-RC) mogą być wykorzystywane w różnych celach, jednak zaprojektowano je przede wszystkim z myślą o dokowaniu AGV do AS z dużą dokładnością. Znacznik 2DM-RC (rys. 7.2(a)) może składać się z dwóch prostych segmentów umieszczonych pod określonym kątem – w prezentowanym rozwiązaniu były one względem siebie prostopadłe. Każdy z segmentów może mieć inną długość. Długość segmentu zależy od zakładanego maksymalnego zasięgu, z którego 2DM-RC może być wykryty, oraz od rozdzielczości kątowej zastosowanego LiDAR-u 2D. Te dwa parametry określają, ile wiązek lasera zostanie odbitych od segmentów 2DM-RC.

Prostopadłość segmentów znacznika 2DM-RC, zaprojektowanego z myślą o dokowaniu, pozwala określić względną orientację AGV względem AS. Dzięki możliwości odczytu siły odbicia wiązki lasera, możliwe jest rozróżnienie powierzchni o różnej refleksyjności, co umożliwia zakodowanie informacji w każdym z segmentów. Oba segmenty 2DM-RC są częściowo lub w całości pokryte taśmą odblaskową, co pozwala na osadzenie informacji na ich powierzchni. Proste segmenty znacznika 2DM-RC mogą być podzielone na podsegmenty, z których tylko część jest pokryta

taśmą odbłaskową, tworząc tym samym kod binarny, który może być traktowany jako identyfikator n-bitowy. Znaczniki 2DM-RC były zamontowane na nogach stanowiska montażowego (AS). W pełni refleksyjny segment znacznika traktowany był jako front AS, natomiast drugi segment zawierał informację o tym, czy znacznik znajduje się na lewej, czy na prawej nodze AS (rys. 7.3).

Informacje z LiDAR-u 2D o odległości i sile odbicia każdej wiązki są zapisane w skanie laserowym otoczenia. Obraz po prawej stronie (rys. 7.2(b)) przedstawia skan znacznika 2DM-RC wykonany przez czujnik LiDAR 2D. Kolor różowy wskazuje powierzchnię o wysokiej refleksyjności, a kolor niebieski – powierzchnię ciemną o niskiej refleksyjności. Wykorzystując dane pomiarowe dostarczane przez LiDAR 2D, opracowano kolejne kroki analizy w celu wykrycia i identyfikacji znaczników 2DM-RC.



Rysunek 7.4: Diagram procesu detekcji i identyfikacji znacznika 2DM-RC.

Metoda detekcji i identyfikacji znacznika oparta na refleksji z wykorzystaniem czujnika LiDAR 2D składa się z kilku etapów – detekcji segmentów, identyfikacji segmentów, detekcji znacznika 2DM-RC oraz identyfikacji znacznika 2DM-RC (rys. 7.4). Punktem początkowym jest uzyskanie pomiarów odległości i informacji o refleksyjności z LiDAR-u 2D, które są dalej analizowane.

Pierwszym etapem jest detekcja segmentów z wykorzystaniem algorytmu Iterative End Point Fit (IEPF) [59, 47]. Metoda detekcji segmentów została opracowana i szczegółowo opisana w [78]. Na początku skany laserowe są przekształcane z układu biegunowego do kartezjańskiego, następnie grupowane i segmentowane przy użyciu algorytmu IEPF. Wyjściem z tego etapu jest zestaw segmentów – prostych linii składających się z grup punktów wraz z punktami początkowymi i końcowymi.

Istniejące rozwiązanie detekcji segmentów zostało rozwinięte w ramach pracy doktorskiej tak, aby wzbogacić segmenty o współrzędne wszystkich punktów z których się składają, informację o refleksyjności każdego punktu w grupie, pozycję środka segmentu oraz orientację danego segmentu w analizowanym układzie współrzędnych. W wyniku tej modyfikacji uzyskano wystarczającą ilość informacji o prostych segmentach w otoczeniu, aby móc opracować kolejne etapy metody detekcji i identyfikacji znacznika 2DM-RC.

Drugim etapem jest identyfikacja segmentów, która może być przeprowadzona na podstawie ich długości, refleksyjności lub obu tych cech.

W ramach pracy doktorskiej skupiono się na identyfikacji opartej na refleksyjności. Segmenty, których długość jest krótsza lub dłuższa niż założona, są eliminowane. Następnie pozostałe segmenty są identyfikowane na podstawie informacji o refleksyjności, która jest wykorzystywana do ich binaryzacji. Etap identyfikacji opiera się na informacji o liczbie bitów osadzonych w segmencie. Na potrzeby dokowania w projekcie CoBotAGV zastosowano system 3-bitowy. Segment, który ma być

identyfikowany oraz punkty z informacją o refleksyjności są dzielone na trzy podsegmenty. Dla każdego z podsegmentów obliczana jest średnia z trzech najczęściej występujących wartości refleksyjności. Jeżeli średnia przekracza określony próg, binarna reprezentacja dla danego podsegmentu to 1, w przeciwnym razie 0. Zebrane bity są następnie przesuwane w lewo (ang. bit shifts) w celu utworzenia 3-bitowego identyfikatora całego segmentu (np. ID=7 – 111, ID=5 – 101) (rys. 7.3 – segment frontowy i lewy). Segmenty o ID niewystępujących w systemie są eliminowane.

Pozostałe segmenty przechodzą do etapu detekcji 2DM-RC, gdzie określana jest wzajemna odległość i orientacja segmentów. Jeżeli dwa segmenty są względem siebie w pożądanej orientacji i odległości, klasyfikowane są jako 2DM-RC. Następnie obliczana jest dokładna pozycja nogi stanowiska montażowego (AS) na podstawie wykrytego znacznika 2DM-RC, zamontowanego na danej nodze. Znając punkty początkowe i końcowe segmentów, obliczany jest wektor. Wektor ten jest następnie obracany zgodnie z ruchem wskazówek zegara o 90° , normalizowany i mnożony przez odległość od segmentu do środka nogi AS, na której zamontowano 2DM-RC. Ten wektor jest następnie dodawany do pozycji środka segmentu, co wyznacza środek nogi AS.

Ostatnim etapem jest identyfikacja 2DM-RC, w którym połączenie informacji osadzonych w segmentach określa ID całego znacznika. Wykryty znacznik 2DM-RC analizowany jest pod kątem identyfikatorów segmentów, z których się składa. Przyjęto założenie, że noga AS musi składać się z dwóch segmentów, z których jeden jest w pełni refleksyjny (ID=7 – 111, oznacza przednią stronę AS), a drugi zawiera informację o stronie (lewa lub prawa noga, ID=5 lub ID=2). Informacja ta jest kluczowa dla prawidłowego wyznaczenia punktu dokowania.

Podsumowując, analiza skanu z czujnika typu LiDAR 2D oraz metoda detekcji i identyfikacji znacznika 2DM-RC składa się z następujących kroków:

1. Pobranie skanu laserowego
 - (a) gromadzone są pomiary odległości oraz siły odbitego promienia lasera z czujnika typu LiDAR 2D.
2. Konwersja skanu laserowego do chmury punktów (PCL)
 - (a) dla każdego punktu pomiarowego przypisywane są współrzędne X, Y,
 - (b) konwersja układu współrzędnych z biegunowego do kartezjańskiego.
3. Detekcja segmentów
 - (a) wykrywanie segmentów składających się z punktów PCL.
4. Filtrowanie segmentów ze względu na długość
 - (a) każdy wykryty segment o długości krótszej lub dłuższej niż zadana jest eliminowany i nie jest dalej przetwarzany.
5. Identyfikacja segmentów
 - (a) każdy segment dzielony jest na podsegmenty, które są binaryzowane (0/1) na podstawie wartości intensywności dominujących wiązek oraz ustalonego progu intensywności odbitej wiązki,
 - (b) zdekodowane ID jest przypisywane do danego segmentu.

6. Filtrowanie segmentów ze względu na ID

- (a) każdy segment z ID innym niż dozwolone jest eliminowany i nie jest dalej przetwarzany.

7. Detekcja znacznika 2DM-RC

- (a) wszystkie pozostałe segmenty są analizowane pod względem wzajemnej odległości i orientacji,
- (b) segmenty o pożądanej wzajemnej odległości i orientacji zostają uznane za znaczniki 2DM-RC,
- (c) dla każdego wykrytego znacznika 2DM-RC obliczane są pozycja i orientacja.

8. Identyfikacja znacznika 2DM-RC

- (a) połączenie informacji zakodowanych w segmentach określa ID całego 2DM-RC, a tym samym jego przeznaczenie lub znaczenie w procesie dokowania.

Procedura dokowania dla AGV jest możliwa dzięki opracowaniu znaczników 2DM-RC, które są montowane na elementach stanowiska montażowego (AS) oraz metodom ich lokalizacji i identyfikacji.

W przypadku rozważanym w niniejszej pracy AGV musiał wykonać procedurę dokowania od strony bocznej AS. Oznacza to, że przed AGV nie znajdował się żaden fizyczny element, do którego możliwy byłby pomiar odległości i dalsza analiza. Dlatego konieczne było stworzenie specjalnego znacznika, widocznego dla LiDAR-u 2D (gdzie pojedynczy LiDAR 2D posiada najczęściej pole widzenia równe 270°), który umożliwia analizę całego otoczenia wokół AGV.


Na podstawie założeń dokowania, każdy z prostopadłych segmentów zaprojektowanego znacznika 2DM-RC musiał posiadać co najmniej 21 cm długości. Pozwala to na odbicie wystarczającej liczby wiązek lasera (około 40 wiązek przy rozdzielczości kątowej LiDAR-u 2D równej $0,1^\circ$) od segmentów 2DM-RC, nawet jeśli są one ustawione pod kątem 45° względem LiDAR-u 2D.

Dodatkowo, w celu rozróżnienia segmentów i umożliwienia identyfikacji znaczników 2DM-RC, jeden z segmentów musiał składać się z trzech (równej długości) podsegmentów o różnej refleksyjności. Umożliwia to zakodowanie numeru identyfikacyjnego (ID) w 3-bitowym systemie binarnym, w którym bardziej refleksyjna powierzchnia kodowana jest jako 1, a mniej refleksyjna jako 0. Informacja o zakodowanym ID jest powiązana z wykrytą nogą AS. Siła odbitego promienia lasera jest wykorzystywana do identyfikacji i przypisania konkretnych ID do odpowiednich segmentów.


Po wykryciu wymaganego kształtu (2DM-RC), uzyskuje się dostęp do punktów X, Y oraz informacji o orientacji elementów AS. Na podstawie tych informacji można obliczyć pozycję oraz orientację AGV względem AS.

Rysunek 7.5 przedstawia zbudowane stanowisko badawcze ze znacznikiem 2DM-RC, składające się z dwóch białych arkuszy papieru (opcjonalnie z naklejoną taśmą odbłaskową) oraz ciemnym paskiem papieru przyklejonym pośrodku jednego z arkuszy. Cały znacznik 2DM-RC został zamontowany na aluminiowej konstrukcji.

Rysunek 7.6 pokazuje, jak przemysłowy LiDAR 2D Sick microscan3 postrzega testowy znacznik 2DM-RC za pomocą wiązek lasera. Różowy kolor oznacza powierzchnię bardziej refleksyjną, a niebieski – mniej refleksyjną.



Rysunek 7.5: Stanowisko testowe dla pojedynczej nogi AS (lewej) wyposażonej w znacznik 2DM-RC.



Rysunek 7.6: Skan laserowy znacznika 2DM-RC uzyskany przez przemysłowy LiDAR 2D Sick microscan3.

Listing 7.1 przedstawia przykładową wiadomość ROS, która została wypisana na terminal po wykryciu i identyfikacji lewej nogi AS (znacznik 2DM-RC z binarnym kodem 101 = ID 5). Wiadomość zawiera informacje o pozycji i orientacji nogi AS (typu ROS geometry_msgs/Pose).

Listing 7.1: Przykładowa wiadomość o wykrytej nodze AS (pozycja i orientacja) przesłana w temacie ROS o nazwie /assembly_station_legs.


```
header:
  seq: 94
  stamp:
    secs: 0
    nsecs: 0
  frame_id: 'cobotagv/odom'
poses:
  position:
    x: -1.25776983493257
    y: -1.4427265976783485
    z: 0.0
  orientation:
    x: 0.0
```

y: 0.0
 z: -0.6843350257680323
 w: 0.7291677259088383

7.2 Metoda obliczania pozycji i orientacji punktu dokowania

Pozycja oraz orientacja punktu dokowania jest obliczana na podstawie informacji o pozycji wykrytych nóg AS oraz orientacji segmentów 2DM-RC oznaczonych jako frontowe (ID=7) (Rys. 7.7).

W pierwszym kroku obliczane są wektory, bazując na punktach początkowych i końcowych segmentów frontowych. Następnie wektor lewej nogi AS zostaje obrócony o 180 stopni. Oba wektory są normalizowane i mnożone przez odległość od każdej z nóg do punktu odpowiadającego punktowi dokowania (w osi X). Wektory te są dodawane do pozycji nóg AS, które zostały obliczone jako środek pomiędzy nogami AS. Następnie wektory są ponownie normalizowane i obracane o 90 stopni - wektor lewej nogi zgodnie z ruchem wskazówek zegara, a prawej przeciwnie do ruchu wskazówek zegara. Obrócone wektory są mnożone przez żądaną odległość od nóg AS do punktu dokowania (w osi Y) i dodawane do wcześniej obliczonych punktów pomiędzy nogami AS. Wynikiem tych operacji są dwie pozycje, których średnia daje pozycję punktu dokowania. Orientacja punktu dokowania to średnia orientacja przednich segmentów znaczników 2DM-RC obróconych o 180 stopni. Pozycja i orientacja punktu dokowania jest obliczana za każdym razem, gdy wykryta zostaje noga AS, ale punkt dokowania wykorzystywany w fazie dokowania i weryfikacji jest wyliczany jako średnia ruchoma z ostatnich pięciu wykryć.




Rysunek 7.7: Wizualizacja metody obliczania pozycji punktu dokowania dla AS wyposażonej w znaczniki 2DM-RC zamontowane na nogach.

Obliczona pozycja punktu dokowania jest przesyłana do środowiska ROS i odbierana przez klienta akcji, który wysyła cel (pozycję i orientację) do stosu nawigacji ROS, przejmującego kontrolę nad AGV i prowadzącego go do obliczonego punktu dokowania.

7.3 Ocena jakości detekcji refleksyjnego znacznika przestrzennego

Przed rozpoczęciem procesu dokowania oraz w trakcie procesu weryfikacji pozycji po zadokowaniu, AGV przeszukuje skany laserowe w poszukiwaniu 2DM-RC. Podczas eksperymentów związanych z dokowaniem i weryfikacją pozycji gromadzone i przetwarzane były dane na temat pozycji i orientacji 2DM-RC (zamontowanych na nogach AS). Na podstawie wyników przeprowadzonych eksperymentów dokowania dokonano oceny jakości wykrywania znaczników 2DM-RC. Rysunek 7.9 pokazuje AGV (zielony prostokąt) w pobliżu punktu dokowania (pozioma czerwona strzałka) pomiędzy dwiema nogami AS wyposażonymi w 2DM-RC. Czerwona linia przedstawia zaplanowaną trasę do punktu dokowania, obliczoną przez stos nawigacji ROS po wykryciu i identyfikacji znaczników 2DM-RC.


Na rysunku 7.8 przedstawiono wykryty prawy znacznik 2DM-RC. Można zauważyć, że znacznik składa się z wielu punktów laserowych. Pionowe segmenty 2DM-RC identyfikują nogę (lewą lub prawą), a pozioma część zawiera wspólny identyfikator segmentu dla obu 2DM-RC i pomaga w określeniu orientacji nóg. Segment pionowy składa się z podsegmentów (bardziej i mniej refleksyjnych), tworzących strukturę 3-bitową umożliwiającą identyfikację nóg. Czerwona strzałka skierowana w górę (w środku prawego 2DM-RC) wskazuje środek pozycji prawej nogi oraz jej orientację odpowiadającą osi Y układu współrzędnych AS, prostopadłą do przedniej części (poziomego segmentu) nogi i do orientacji żądanego punktu dokowania.



Rysunek 7.8: Widok wykrytego znacznika 2DM-RC zamontowanego na prawej nodze AS.

Tabela 7.1 przedstawia analizę pozycjonowania nóg AS (lewej i prawej) w osiach X, Y oraz ich orientacji. Podczas procesu weryfikacji obie nogi były widziane przez AGV, który był wyposażony w dwa LiDAR-y 2D (przedni i tylny). Średnia wartość odchylenia standardowego (STDEV) dla dwóch znaczników 2DM-RC (lewego i prawego) różniła się o 0,8 mm dla odległości euklidesowej - przedni LiDAR 2D posiadał wyższe STDEV równe 0,0034 m. Różnica ta jest równa wartości STDEV pozycji prawej nogi AS. Z drugiej strony, przedni 2D LiDAR miał mniejsze STDEV orientacji YAW prawej nogi AS o 0,0357°, w porównaniu do tylnego LiDAR-u, ale różnica ta była mniejsza niż STDEV wartości orientacji.

Różnice w wartościach STDEV pomiędzy LiDAR-ami 2D mogły wynikać z ich indywidualnych właściwości pomiarowych. Odchylenia standardowe obu LiDAR-ów 2D były zgodne z charakterystykami pomiarowymi przemysłowego LiDAR-u 2D Sick microscan3 [102] - jego średnie STDEV wynosiło 2,5 mm. Warto zatem zaznaczyć, że precyzja pozycjonowania odpowiadała precyzji samego LiDAR-u 2D.



Rysunek 7.9: Widok dwóch znaczników 2DM-RC zamontowanych na nogach AS oraz obliczonego punktu dokowania z perspektywy przedniego i tylnego czujnika LiDAR 2D zamontowanego na AGV.


Tabela 7.1: Weryfikacja precyzji pozycjonowania nóg AS z zamontowanymi znacznikami 2DM-RC.

Nr	STDEV pozycji i orientacji nóg AS					
	Lewa noga – tylny LiDAR 2D			Prawa noga – przedni LiDAR 2D		
	X [m]	Y [m]	Yaw [°]	X [m]	Y [m]	Yaw [°]
1.	0.0011	0.0026	0.1844	0.0014	0.0026	0.2484
2.	0.0011	0.0013	0.3098	0.0012	0.0017	0.2365
3.	0.0025	0.0023	0.3651	0.0035	0.0037	0.1237
4.	0.0010	0.0017	0.2128	0.0016	0.0030	0.2941
5.	0.0009	0.0017	0.1348	0.0016	0.0039	0.3032
6.	0.0020	0.0014	0.8248	0.0012	0.0021	0.3499
7.	0.0015	0.0023	0.2590	0.0016	0.0029	0.2178
8.	0.0008	0.0028	0.2026	0.0024	0.0033	0.2395
9.	0.0029	0.0025	0.2824	0.0013	0.0022	0.2518
10.	0.0013	0.0026	0.5100	0.0019	0.0027	0.3517
11.	0.0012	0.0020	0.1962	0.0011	0.0043	0.3617
12.	0.0014	0.0022	0.2402	0.0011	0.0034	0.3156
Średnia	0.0015	0.0021	0.3102	0.0017	0.0030	0.2745
STDEV	0.0007	0.0005	0.1899	0.0007	0.0008	0.0687
Średnia odległość Euklidesowa	0.0026		-	0.0034		-

Rozdział 8

Architektura systemu kontroli oraz akwizycji danych. Integracja z platformą mobilną

Metody opracowane w celu poprawy dokładności oraz precyzji dokowania do stacji montażowej powinny zostać poddane testom na rzeczywistym sprzęcie, aby sprawdzić ich skuteczność i wpływ na ostateczną dokładność dokowania. W tym celu należało zaimplementować opracowane metody poprawy dokładności, opracować interfejs komunikacji oraz zintegrować całość z poszczególnymi platformami mobilnymi. W przeciągu trwania projektu CoBotAGV prace badawcze były wykonywane na wielu platformach mobilnych, od rozwiązań hobbistycznych/badawczych tj. Turtlebot, przez większe platformy badawcze tj. ForbotAGV, po profesjonalne rozwiązania przemysłowe tj. Formica 1 czy Formica 3.



Rysunek 8.1: Diagram warstw oprogramowania w kontekście oprogramowania zależnego i niezależnego od sprzętu wraz z elementami stosu systemowego.

Każda z platform posiadała inne wymiary, inną budowę, inny zestaw czujników, inną charakterystykę pracy, poruszania się oraz inne protokoły komunikacji. Aby zaprojektować rozwiązanie obsługujące wszystkie przypadki należało podzielić architekturę systemu na odpowiednie warstwy - zależne oraz niezależne od sprzętu (rys. 8.1). Oprogramowanie zależne od sprzętu posiadało zaimplementowany interfejs komunikacji z podzespołami platformy mobilnej udostępniającymi dane oraz

odbierającymi rozkazy, natomiast oprogramowanie niezależne od sprzętu zajmowało się obróbką pozyskanych danych oraz przygotowaniem rozkazów przesyłanych do platformy mobilnej.


Opracowane rozwiązanie korzysta z platformy Robot Operating System (ROS), która zapewnia zarówno warstwę komunikacyjną pomiędzy modułami oprogramowania, jak i funkcjonalności takie jak nawigacja zliczeniowa na bazie odometrii, Simultaneous localization and mapping (SLAM) [83] czy stos nawigacji [93]. Wszystkie moduły opracowane w ramach pracy doktorskiej zostały zaimplementowane w języku C++, aby zapewnić możliwie największą wydajność wykonywanych operacji.

8.1 Robot Operating System

Robot Operating System (ROS) to otwartoźródłowe środowisko pośredniczące (ang. middleware), oferujące kompleksowy zestaw bibliotek programistycznych i narzędzi zaprojektowanych specjalnie w celu usprawnienia tworzenia złożonych aplikacji robotycznych. Jego celem jest zapewnienie elastycznej i ustandaryzowanej platformy, która upraszcza tworzenie niezawodnych zachowań robotów na różnych platformach robotycznych.

Komunikacja w systemie ROS opiera się na modelu wydawca – subskrybent (ang. publisher - subscriber). Komunikacja ta odbywa się pomiędzy węzłami (ang. nodes) ROS. Pojedynczy węzeł (reprezentowany przez proces w systemie operacyjnym) to instancja oprogramowania pakietu ROS wykonująca określone zadanie w systemie. Węzły ROS wymieniają informacje między sobą za pomocą wiadomości przesyłanych w ramach określonego tematu (ang. topic). Każdy z węzłów przesyła informacje do przestrzeni ROS, publikując wiadomość w ramach określonego tematu, lub odbiera informacje/wiadomości z przestrzeni ROS poprzez subskrybowanie określonego tematu. Zanim rozpocznie się komunikacja między węzłami, konieczne jest uruchomienie pojedynczej instancji ROS Master – głównego węzła ROS, który umożliwia komunikację z innymi węzłami w sieci. Proces ten przedstawiono na rysunku 8.2.


Platforma ROS ze względu na swoją modułowość (węzły w sieci ROS) oraz model komunikacji pomiędzy węzłami sieci (wydawca-subskrybent, ang. publisher-subscriber) pozwala na bardzo dużą swobodę w organizacji przepływu informacji pomiędzy węzłami oraz na odpowiednie podzielenie odpowiedzialności i ponowne wykorzystanie oprogramowania.



Rysunek 8.2: Model komunikacji wydawca – subskrybent w ROS.

8.1.1 Mapa węzłów w sieci ROS

W ramach pracy doktorskiej opracowano system autonomicznego dokowania platformy AGV do stanowiska montażowego. Podstawą komunikacji pomiędzy węzłami oprogramowania stanowi ROS. Rysunek 8.3 przedstawia mapę węzłów w sieci ROS, które realizują procedurę dokowania platformy AGV do stanowiska montażowego. Połączenia pomiędzy węzłami wskazują kierunek przepływu informacji. Temat oraz typ publikowanej informacji jest zgodny ze standardami w sieci ROS. Nazwy niektórych z węzłów odbiegają od rzeczywistych nazw użytych podczas implementacji - ma to na celu zwiększenie czytelności mapy węzłów i ułatwienie analizy przebiegu informacji.



Rysunek 8.3: Mapa węzłów w sieci ROS

Rysunek 8.3 jest podzielony na 3 sekcje. Dolna sekcja zawiera czujniki, które są źródłami danych oraz urządzenia pełniące rolę elementów wykonawczych, takie jak kontroler napędów platformy AGV. Pośrodku znajduje się sekcja oprogramowania zależnego od sprzętu, dekodująca i tłumacząca dane przesyłane przez niższą warstwę w sposób zrozumiały dla warstwy wyższej. Górna sekcja zawiera oprogramowanie niezależne sprzętowo, które analizuje dane przesłane przez warstwę niższą i realizuje założony cel - w tym przypadku dokowanie do stacji montażowej.

Dane pomiarowe z LiDAR-ów 2D zamontowanych na platformie mobilnej, cyklicznie wysyłają pakiety UDP do jednostki przetwarzającej. W pierwszej kolejności pakiety przesyłane przez LiDAR-y 2D są duplikowane przez węzły "traffic mirroring", a następnie przesyłane do węzła dekodującego na potrzeby dokowania oraz do oprogramowania Navitrol. Jest to konieczne, aby platforma mobilna i natywny system nawigacji platformy mobilnej funkcjonował poprawnie. Węzły "SICK decoder" po zdekodowaniu pakietów UDP przesłanych przez LiDAR-y 2D publikują w sieci ROS surowe skany LiDAR-owe otoczenia, które są odbierane przez węzły ("laser corrector") korygujące te pomiary. Korekty te zostały wyznaczone przy wykorzystaniu autorskiej, adaptacyjnej metody kalibracji (ACM). Skalibrowane skany LiDAR-owe są publikowane, a następnie odbierane przez węzeł ("laser scan merger") odpowiedzialny za połączenie ich w jeden skalibrowany skan otoczenia ze wspólnym punktem odniesienia.

Po połączeniu skanów publikowane są dwie wiadomości, połączony skan laserowy oraz chmura punktów, w której każdy z punktów skanu posiada przypisaną pozycję X, Y oraz wartość odpowiadającą sile odbitej wiązki laserowej. Chmura punktów zawierająca laserowy skan otoczenia jest odbierana przez węzeł ("obstacle detector") sieci ROS odpowiedzialny za segmentację skanu na proste odcinki. Segmenty te odbierane są następnie przez węzeł ("shape extractor") odpowiedzialny za wykrycie i identyfikację opracowanego znacznika 2DM-RC. Dodatkowo węzeł ten oblicza i publikuje pozycję docelową dla punktu dokowania względem wykrytego znacznika/ów. Docelowa pozycja punktu dokowania jest następnie odbierana przez dwa węzły, z których jeden odpowiedzialny jest za weryfikację dokładności dokowania, obliczenie korekty pozycji i orientacji po zadokowaniu ("pose verification"), a drugi odpowiedzialny jest za przesłanie odebranej pozycji punktu docelowego do stosu nawigacji ROS ("target pose action client").

Węzeł "target pose action client" przesyła do stosu nawigacji wiadomość typu akcja (ang. action). Wiadomość taka pozwala na obserwowanie statusu, a po zakończeniu akcji (niezależnie od tego, czy zakończyła się sukcesem, czy niepowodzeniem), zostaje wywołana odpowiednia funkcja przypisana danemu stanowi akcji podczas jej wysyłania. Stos nawigacji po otrzymaniu pozycji docelowej, skalibrowanego skanu laserowego oraz pozycji AGV otrzymanej z odometrii oblicza trajektorię ruchu i rozpoczyna publikowanie wiadomości w temacie prędkości liniowej oraz kątowej (temat "velocity command"). Wiadomości z prędkościami są odbierane przez węzeł "differential drive" odpowiedzialny za przeliczenie zadanej prędkości liniowej oraz kątowej na odpowiednie prędkości dla lewego i prawego napędu platformy mobilnej z uwzględnieniem promienia i rozstawu kół. Prędkości te są następnie kodowane do odpowiedniego formatu przez węzeł "AGV HW controller" i przesyłane do jednostki przetwarzającej AGV.

Oprócz LiDAR-ów 2D kolejnym źródłem danych są enkodery, które znajdują się w dolnej sekcji. Generowane przez nie dane odbierane są w środkowej sekcji przez węzeł "AGV HW controller", który jest również odpowiedzialny za dekodowanie pakietów przesyłanych przez jednostkę przetwarzającą platformy AGV. Dane w te-

macie liczby impulsów generowanych przez enkodery oraz skumulowanego dystansu pokonanego przez oba koła AGV, są najpierw przeliczane przez węzeł “AGV HW controller” na radianowe pozycje kół, a następnie przez węzeł “differential drive”, na pozycję, orientację i prędkość liniową oraz kątową wraz z napływaniem kolejnych danych odometrycznych. Dane te są następnie publikowane przez węzeł “differential drive” i odbierane przez stos nawigacji oraz węzeł “pose verification” odpowiedzialny za weryfikację dokładności dokowania i obliczenie korekty pozycji i orientacji AGV po zakończeniu dokowania.


8.2 Akwizycja danych i sposób kontroli

Każda z platform mobilnych oprócz zestawu czujników (tj. LiDAR-y, enkodery, zderzaki, IMU, wagi) i elementów wykonawczych (tj. napędy, hamulce, serwomechanizmy), posiada jednostkę przetwarzającą (tj. IPC, PLC, SBC). Niniejszy podrozdział opisuje akwizycję danych oraz sposób kontroli przemysłowej platformy mobilnej tj. Formica1 lub Formica3, które jako główną jednostkę przetwarzającą posiadały PLC oraz dodatkowo IPC odpowiedzialny za natywną nawigację platformą (Navitrol firmy Navitec). Oprogramowanie opracowane w ramach pracy doktorskiej zostało uruchomione na SBC, który był połączony do wspólnej sieci bezprzewodowej z AGV. W ramach przeprowadzonej integracji opracowanego systemu z platformami AGV, a następnie wykonanych badań, wymiana danych odbywała się pomiędzy SBC, a sterownikiem PLC.


Aby możliwy był odbiór danych z podsystemów AGV (Automated Guided Vehicle) i sterowanie jego ruchami poprzez wysyłanie poleceń do sterownika PLC (Programmable Logic Controller), konieczne było stworzenie modułów oprogramowania wykorzystujących platformę ROS (Robot Operating System). Węzły oprogramowania ROS zostały zaimplementowane w języku C++. Do komunikacji ze sterownikiem PLC za pomocą protokołu TCP/IP wykorzystano bibliotekę sieciową Boost.ASIO.

Po nawiązaniu połączenia ze sterownikiem PLC, sterownik ten okresowo wysyła dane do SBC (Single Board Computer) za pośrednictwem protokołu TCP. Po odebraniu danych przez SBC są one dekodowane, przetwarzane i publikowane w przestrzeni ROS. Rysunek 8.4 przedstawia przepływ danych dostarczanych przez AGV.

Aby możliwe było sterowanie AGV, system ROS uruchomiony na SBC wysyła komendy prędkości do sterownika PLC. Komendy te są przetwarzane przez węzeł napędu różnicowego ROS, który przelicza zadaną prędkość liniową i kątową na osobne prędkości dla lewego i prawego koła, uwzględniając promień i rozstaw kół platformy AGV. Następnie wyliczone wartości są kodowane w ramkę zgodną z protokołem komunikacji oczekiwanym przez PLC i przesyłane w celu ich wykonania. PLC wykonuje otrzymane komendy, sterując napędami pojazdu poprzez kontroler napędów. Rysunek 8.5 przedstawia ten proces.



Rysunek 8.4: Przepływ danych z PLC i LiDAR'ów do SBC.



Rysunek 8.5: Przepływ danych z komendą prędkości z SBC do PLC.

8.2.1 Dane odbierane z AGV

PLC okresowo przesyła informacje odebrane z podłączonych do niego czujników (takich jak enkodery, inklinometry) oraz informacje o stanie AGV, takie jak bieżący tryb pracy AGV. Dane te są kodowane w określonej strukturze ramki przedstawionej w Tabeli 8.1.

Dane z przemysłowych LiDAR-ów 2D są przesyłane bezpośrednio z LiDAR-ów 2D do SBC za pomocą protokołu UDP/IP.

Tabela 8.1: Główna ramka protokołu w komunikacji z PLC.

Pole	ROZPOCZĘCIE			ID	STATUS		TIMESTAMP						NUMER				VER	DŁUGOŚĆ		DANE			ZAKOŃCZENIE				
Rozmiar (bajty)	3			2	2		12						4				2	2		k			3				
Numer bajtu	0	1	2	3	4	5	6	7	8	9-16	17	18	19	20	21	22	23	24	25	26	27	28	...	27+k	28+k	29+k	
Typ danych	ASCII	ASCII	ASCII	INT	WORD		DTL						UINT				INT	INT		various			ASCII	ASCII	ASCII		
Przykład	<	F			WORD																					F	>

Ramka z danymi odometrycznymi

Ramka z Tabeli 8.2 zawiera dane o odometrii AGV. Ramka informuje o chwilowej częstotliwości impulsów z lewego i prawego enkodera oraz o skumulowanej odległości (w mm) przebytej przez lewe i prawe koło AGV.

Ramka po odebraniu i zdekodowaniu jest poddawana przetworzeniu do formy przyjmowanej przez węzły platformy ROS. Skumulowany dystans każdego z kół jest przeliczany na radianową pozycję, uwzględniając obwód koła. Taka informacja jest przekazywana do węzła napędu różnicowego ROS, który implementuje moduł

nawigacji zliczeniowej i w czasie rzeczywistym oblicza pozycję (X,Y), orientację oraz prędkość liniową i kątową platformy mobilnej.

Tabela 8.2: Struktura ramki przechowującej dane odometryczne AGV.

Dane odometryczne			
Nr bajtu	Nazwa	Typ danych	Komentarz
70	Chwilowa częstotliwość impulsów lewego enkodera	UInt	[impulsy/s]
71			
72	Chwilowa częstotliwość impulsów prawego enkodera	UInt	[impulsy/s]
73			
74	Skumulowany dystans przebyty przez lewe koło	UInt	[mm]
75			
76			
77			
78	Skumulowany dystans przebyty przez prawe koło	UInt	[mm]
79			
80			
81			

Ramka z informacjami z inklinometru

Ramka z Tabeli 8.3 zawiera dane o orientacji AGV w zakresie przechyłu (pitch) i przechylenia bocznego (roll). Ramka informuje o kącie nachylenia w osi X i Y. Informacje o kącie (w stopniach) w obu osiach są podawane w formacie float.

Ramka po odebraniu i zdekodowaniu jest publikowana w sieci ROS jako tablica Float32MultiArray z wartościami orientacji pitch oraz roll.

Tabela 8.3: Struktura ramki przechowującej dane z inklinometru AGV.

Sygnały z inklinometru			
Nr bajtu	Nazwa	Typ danych	Komentarz
98	Inklinacja w osi X	Float	Rozdzielczość 0.01°
99			
100			
101			
102	Inklinacja w osi Y	Float	Rozdzielczość 0.01°
103			
104			
105			

Ramki z LiDAR-ów 2D

Dane z LiDAR-ów 2D, przedstawiające laserowy skan otoczenia, otrzymywane są cyklicznie co 40-80 ms, zależnie od konfiguracji LiDAR-u 2D. Zawierają wektor odległości oraz wektor wartości odzwierciedlających siłę odbitej wiązki laserowej. Każdy z LiDAR-ów 2D posiada własny protokół (strukturę przesyłanych danych).

Firma Leuze udostępnia bibliotekę w języku C, pozwalającą na zdekodowanie przesyłanych pakietów UDP. Wymagana jest jedynie implementacja węzła ROS nasłuchującego na określonym porcie, odbierającego i dekodującego pakiety UDP.

Firma Sick udostępnia gotowy węzeł ROS obsługujący ich LiDAR-y. Wymagane jest jedynie dostosowanie parametrów w plikach konfiguracyjnych węzła obsługującego LiDAR-y Sick.

Po zdekodowaniu pakietów UDP, tworzona jest wiadomość typu `sensor_msgs/LaserScan`, która następnie jest publikowana w ramach odpowiedniego tematu w sieci ROS.

8.2.2 Dane przesyłane do PLC

Za każdym razem, gdy SBC chce wysłać polecenie do PLC, musi je najpierw zakodować w ramce przedstawionej w Tabeli 8.1.

Ramka kontroli napędów

Tabela 8.4 przedstawia strukturę ramki służącej do przesyłania komend jazdy z systemu ROS do PLC. Składa się ona z bitów aktywacji poszczególnych trybów oraz prędkości dla napędu lewego i prawego koła. Dzięki informacjom zawartym w ramce oraz napędowi różnicowemu, AGV może skręcać w miejscu lub po łuku o zmiennym promieniu.

Tabela 8.4: Struktura ramki przechowującej komendę jazdy z systemu ROS dla PLC.

Kontrola napędami AGV			
Nr bajtu	Nazwa	Typ danych	Komentarz
66	Aktywacja kontroli napędami	Bit	Ciągły sygnał 1 = aktywny
	Aktywacja kontroli lewego napędu	Bit	Ciągły sygnał 1 = aktywny
	Aktywacja kontroli prawego napędu	Bit	Ciągły sygnał 1 = aktywny
	Wyłączenie nawigacji naturalnej (Navitrol)	Bit	Ciągły sygnał 1 = aktywny
	zarezerwowane	Bit	-
		Bit	-
		Bit	-
		Bit	-
67	zarezerwowane	Bit	-
		Bit	-
		Bit	-
		Bit	-
		Bit	-
		Bit	-
		Bit	-
		Bit	-
68	Prędkość lewego napędu	Float	[m/s]
69			
70			
71			
72	Prędkość prawego napędu	Float	[m/s]
73			
74			
75			

Ramka konfiguracji trybu PLC

Tabela 8.5 zawiera dane konfiguracyjne dla PLC. Ustawienie określonego bitu umożliwia wybór trybu jazdy, a więc źródła komend jazdy.

Tabela 8.5: Struktura ramki przechowującej konfigurację zadanego trybu operacyjnego PLC.

Konfiguracja trybu PLC			
Nr bajtu	Nazwa	Typ danych	Komentarz
12	Aktywacja trybu manualnego	Bit	Ciągły sygnał 1 = aktywny
	Aktywacja nawigacji naturalnej	Bit	Ciągły sygnał 1 = aktywny
	Aktywacja trybu dokowania	Bit	Ciągły sygnał 1 = aktywny
	zarezerwowane	Bit	-
		Bit	-
		Bit	-
		Bit	-
13	zarezerwowane	Bit	-
		Bit	-
		Bit	-
		Bit	-
		Bit	-
		Bit	-
		Bit	-

Ramka wykluczeń sygnałowych

Tabela 8.6 zawiera dane konfiguracyjne składające się z flag wykluczeń. Każda z flag umożliwia zignorowanie lub wyłączenie określonego sygnału odbieranego lub kontrolowanego przez PLC.

Tabela 8.6: Struktura ramki przechowującej konfigurację wykluczeń sygnałów PLC.

Kontrola wykluczeniami			
Nr bajtu	Nazwa	Typ danych	Komentarz
24	Wykluczenie skanerów bezpiecz.	Bit	Ciągły sygnał 1 = aktywny
	Wyłączenie LED	Bit	Ciągły sygnał 1 = aktywny
	Wyłączenie projektora przedniego	Bit	Ciągły sygnał 1 = aktywny
	Wyłączenie projektora tylnego	Bit	Ciągły sygnał 1 = aktywny
	zarezerwowane	Bit	-
		Bit	-
		Bit	-
		Bit	-
25	Wyłączenie wózka	Bit	Ciągły sygnał 1 = aktywny
	Wyłączenie kontroli z zew. sys.	Bit	Ciągły sygnał 1 = aktywny
	Wyłączenie wagi	Bit	Ciągły sygnał 1 = aktywny
	Wyłączenie dźwięków	Bit	Ciągły sygnał 1 = aktywny
	zarezerwowane	Bit	-
		Bit	-
		Bit	-
		Bit	-

Rozdział 9

Dokowanie platformy mobilnej

Precyzyjne dokowanie AGV do stanowiska montażowego (AS) umożliwia prawidłowe przeprowadzenie i zakończenie procesu produkcyjnego. Dlatego też procedura dokowania AGV do linii montażowej odgrywa istotną rolę, szczególnie w rozwiązaniach stosowanych w Przemśle 4.0. Metodologia algorytmów dokowania oraz weryfikacji pozycji i orientacji AGV względem AS po zakończeniu dokowania wykorzystuje metodę wykrywania i identyfikacji znaczników 2DM-RC, z użyciem LiDAR-u 2D. Podejście to umożliwia weryfikację jakości algorytmu dokowania i zapewnia dokładne ustalenie pozycji AGV względem AS, nawet jeśli podczas dokowania wystąpiły błędy.

Opracowana w ramach pracy doktorskiej metoda dokowania, umożliwia precyzyjne dokowanie AGV do AS. Zastosowanie tej metody przedstawiono na przykładzie eksperymentów dokowania przemysłowego AGV o nazwie “Formica 3” [103]. Aby przeprowadzić dokowanie z dużą dokładnością, system AGV musi zlokalizować i zidentyfikować określone elementy AS w otoczeniu i dojechać do wyznaczonego punktu przed AS. Znaczniki 2DM-RC są identyfikowane przy użyciu laserowych skanerów 2D (Sick microscan3), które są zamontowane na platformie AGV.

Aby możliwe było precyzyjne dokowanie, sformułowano kilka założeń dla procedury dokowania:

1. Na górze platformy AGV zostanie zamontowany robot kolaboracyjny, dlatego błąd dokładności powinien być mniejszy niż 2 cm ze względu na ograniczony obszar ruchu ramienia robota.
2. Punkt początkowy dokowania powinien znajdować się nie dalej niż 2 m od najbliższego 2DM-RC zamontowanego na AS. Powodem tego założenia jest ograniczona rozdzielczość kątowna LiDAR-u 2D. Aby zidentyfikować i zlokalizować AS, konieczna jest wystarczająca liczba punktów pomiarowych na jego powierzchni.
3. Podczas manewrów dokowania prędkość jest ograniczona, aby zapewnić możliwość obserwacji najbliższego otoczenia AS w czasie rzeczywistym.
4. Na AS mogą być stosowane zewnętrzne znaczniki.
5. Dostępne metody powinny obejmować analizę danych z LiDAR-u 2D.
6. Metoda dokowania powinna zawierać fazę weryfikacji po osiągnięciu punktu dokowania.

7. Aby przeprowadzić fazę weryfikacji, AGV musi być w stanie zobaczyć co najmniej jeden znacznik 2DM-RC po osiągnięciu punktu dokowania.

Przed rozpoczęciem procedury dokowania, nawigacja naturalna (zewnątrzny system nawigacyjny “Navitrol”, firmy Navitec) prowadzi AGV do pozycji początkowej fazy dokowania. Następnie aktywowany zostaje opracowany w ramach pracy doktorskiej autorski algorytm dokowania oparty na Robot Operating System (ROS) [2].


Procedura dokowania składa się z trzech kroków:

1. Pozycja początkowa (ten krok zilustrowano na rysunku 9.1):
 - (a) AGV rozpoczyna wyszukiwanie znanych wzorców znaczników 2DM-RC, które umożliwiają zlokalizowanie i identyfikację konkretnych elementów AS,
 - (b) gdy tylko zostanie zidentyfikowany przynajmniej jeden znacznik 2DM-RC, obliczany jest punkt dokowania i rozpoczyna się faza dokowania.
2. Faza dokowania (ten krok zilustrowano na rysunkach 9.1 oraz 9.2). Punkt dokowania to cel fazy dokowania. Znajduje się on w określonej odległości od AS:
 - (a) AGV jest sterowany przez stos nawigacji ROS do punktu dokowania,
 - (b) gdy punkt dokowania zostanie osiągnięty, kończy się faza dokowania i rozpoczyna faza weryfikacji.
3. Faza weryfikacji (ten krok zilustrowano na rysunku 9.2). Faza weryfikacji to etap, w którym AGV wykonuje dodatkowy test w celu uzyskania końcowej informacji o dokładności przeprowadzonego dokowania:
 - (a) AGV rozpoczyna wyszukiwanie znanych wzorców znaczników 2DM-RC, które umożliwiają zlokalizowanie i identyfikację konkretnych elementów AS,
 - (b) gdy tylko zostanie zidentyfikowany przynajmniej jeden znacznik 2DM-RC, obliczana jest wartość korekty po zakończeniu fazy dokowania, ponieważ pozycja X,Y oraz orientacja AGV mogą być niedokładne względem AS.


9.1 Metoda weryfikacji służąca estymacji względnej pozycji pomiędzy AGV a AS

Na podstawie badań dotyczących metody wykrywania i identyfikacji znaczników 2DM-RC, algorytmu dokowania oraz funkcjonalności platformy ROS, opracowano sposób przeprowadzenia fazy weryfikacji w celu obliczenia wartości korekty po zakończeniu dokowania AGV w żądanym punkcie dokowania. Faza weryfikacji umożliwia sprawdzenie błędów pozycji i orientacji AGV po zakończonej fazie dokowania. Dokładny pomiar tych błędów oraz znajomość ich wartości pozwala na podjęcie działań w celu ich eliminacji przez inne podsystemy (np. ramię robota kolaboracyjnego).

Platformy AGV posiadają w środowisku ROS specyficzny opis zwany Unified Robot Description Format (URDF). Zdefiniowane połączenia (ang. linki) w URDF



Rysunek 9.1: Procedura dokowania AGV do AS wyposażonego w 2DM-RC zamontowane na nogach – faza dokowania.



Rysunek 9.2: Procedura dokowania AGV do AS wyposażonego w 2DM-RC zamontowane na nogach – faza weryfikacji.

platformy AGV to zestaw wpisów XML, które opisują wymiary robota oraz położenie (X,Y,Z) i orientację jego kół, LiDAR-ów 2D i innych podsystemów, względem środkowego punktu platformy AGV, określanego jako ramka „base_link”. W przestrzeni robota może być zlokalizowanych wiele ramek, np. „base_footprint” - ramka identyczna z „base_link”, ale bez informacji w osi Z, będąca rzutem „base_link” na podłoże.

Takie podejście umożliwia obliczenie względnej odległości i orientacji określonego punktu w otoczeniu AGV względem jednego z elementów platformy AGV. Aby obliczyć translacje między dwoma punktami w otoczeniu AGV z poziomu platformy ROS, stosuje się pakiet tf2 [26], który służy do przekształceń (transformacji). Funkcje tego pakietu jako wejście przyjmują ramki źródłową i docelową, aby obliczyć translację między tymi dwoma układami współrzędnych. Następnie obliczona translacja może być wykorzystana do określenia, gdzie dany punkt ze źródłowego układu współrzędnych (ang. source frame) znajduje się w docelowym układzie współrzędnych (ang. target frame). Dokładne informacje o przekształcaniu

(pozycji i orientacji) między dwiema ramkami można obliczyć przy użyciu funkcji `tf2_ros::Buffer::lookupTransform()` w kodzie C++.

Jeśli jest znana zarówno pozycja i orientacja docelowego punktu dokowania w układzie współrzędnych otoczenia AGV, jak i pozycja i orientacja samego AGV oraz AS, to możliwe jest obliczenie wartości korekty (błędu dokowania) w fazie weryfikacji (rys. 9.2) przy użyciu metod dostępnych w pakiecie `tf2` ROS (Algorytm 1).

Listing 9.1 przedstawia obliczoną pozycję i orientację punktu dokowania. Listing 9.2 przedstawia pozycję i orientację, którą osiągnął AGV. A Listing 9.3, wyniki obliczeń na podstawie Algorytmu 1 obliczający różnicę pomiędzy tymi dwoma pozycjami i orientacjami - czyli korektę w osiach X i Y oraz najkrótszy kąt korekty obrotu (YAW), który należy wykonać, aby osiągnąć dokładną pozycję i orientację w punkcie dokowania.

Listing 9.1: Przykładowe dane wejściowe dla pozycji docelowego punktu dokowania dla algorytmu obliczającego korektę.

```
frame_id: 'cobotagv/odom'
pose:
  position:
    x: -2.4049868061821096
    y: -0.6493939707558077
    z: 0.0
  orientation:
    x: 0.0
    y: 0.0
    z: -0.9993905529296481
    w: 0.03490734471386127
```

Listing 9.2: Przykładowe dane wejściowe pozycji AGV Formica 3 dla algorytmu obliczającego korektę.

```
frame_id: 'cobotagv/odom'
child_frame_id: 'cobotagv/base_footprint'
pose:
  pose:
    position:
      x: -2.3983478260527704
      y: -0.6831364987148251
      z: 0.0
    orientation:
      x: -0.0
      y: 0.0
      z: 0.999867776875473
      w: -0.016261265820944407
```

Listing 9.3: Przykładowe dane wyjściowe z algorytmu do obliczania wartości korekty podczas fazy weryfikacji (korekta odpowiednio w pozycjach X i Y, najkrótszy kąt orientacji YAW oraz orientacja w formacie kwaternionowym).

```
[ INFO] [1691238225.242638044]: Correction x = 0.00668387 y = -0.0255648
                                yaw_shortest = 2.03647 x = 0 y = 0 z = 0.0177706 w = 0.999842
[ INFO] [1691238226.443283117]: Correction x = 0.00624722 y = -0.0244288
                                yaw_shortest = 2.00544 x = 0 y = 0 z = 0.0174998 w = 0.99984
```


Faza weryfikacji, odpowiedzialna za obliczenie wartości korekty po zakończeniu dokowania AGV, może zostać podsumowana jako pętla zawierająca następujące kroki:

1. Zlokalizować elementy AS przy użyciu opracowanej metody wykrywania i identyfikacji 2DM-RC.
2. Obliczyć punkt dokowania – znajomość pozycji i orientacji elementów AS umożliwia obliczenie pozycji i orientacji punktu dokowania po określeniu żądanych odległości punktu dokowania od elementów AS – rys. 9.2.
3. Obliczyć różnicę między pozycją AGV a obliczoną pozycją punktu dokowania z kroku 2-go.
4. Przekształcić (obrócić) obliczoną różnicę z kroku 3-go o odwrotność orientacji docelowego punktu dokowania z kroku 2-go.
5. Obliczyć najkrótszą różnicę pomiędzy orientacją docelowego punktu dokowania a orientacją AGV.

Ostateczna wartość korekty składa się z wyników obliczonych w punktach 4 i 5, czyli odpowiednio korekt liniowych (X,Y) i kątowej (YAW). Układ współrzędnych stanowiska montażowego definiowany jest następująco: oś X jest równoległa do linii łączącej lewą i prawą nogę AS, a jej zwrot przebiega od lewej do prawej nogi, natomiast oś Y jest prostopadła do tej linii i skierowana do środka AS.

9.2 Eksperymenty badające jakość dokowania AGV

Eksperymenty związane z dokowaniem i weryfikacją zostały przeprowadzone zgodnie z opisem zawartym w poprzednim podrozdziale, z wykorzystaniem prototypowej platformy Formica 3 w ramach projektu CoBotAGV. Obie fazy opierały się na opracowanej metodzie wykrywania i identyfikacji znaczników 2DM-RC. Formica 3 to ciężka przemysłowa platforma AGV o wymiarach $0,85 \times 0,58$ m, zaprojektowana w celu podnoszenia i transportu ładunków w magazynie. Formica 3 jest wyposażona w dwa napędy (po jednym z obu stron AGV) i wykorzystuje różnicowy model sterowania.

W opisie eksperymentów termin „dokowanie/weryfikacja do lewej/prawej nogi” oznacza, że pozycja i orientacja punktu dokowania były obliczane na podstawie znacznika 2DM-RC zamontowanego na lewej lub prawej nodze stanowiska AS. Stanowisko badawcze zbudowane w celu przeprowadzenia badań dokowania (rys. 9.3) składało się z aluminiowych profili, na których zamontowano dwa znaczniki 2DM-RC (dla lewej i prawej nogi). AGV rozpoczynał fazę dokowania od lewej strony stanowiska badawczego AS, w odległości około 2 m. Po identyfikacji lewego znacznika 2DM-RC i obliczeniu pozycji oraz orientacji punktu dokowania, AGV rozpoczynał przejazd. Następnie dokował do lewej nogi AS i przeprowadzał weryfikację swojej pozycji i orientacji względem jednej z nóg lub obu. Proces weryfikacji umożliwia ocenę końcowej pozycji dokowania AGV.

Eksperyment przeprowadzono z użyciem dwóch LiDAR-ów 2D Sick microscan3, zamontowanych z przodu i z tyłu AGV. Do kalibracji pomiarów odległości z LiDAR-ów 2D zastosowano adaptacyjną metodę kalibracji [11], co zapewniło dokładność pomiarów.

Algorithm 1 Obliczanie korekty pozycji i orientacji punktu dokowania podczas fazy weryfikacji.

```

1: function CALCULATE_CORRECTION(target_point)  ▷ Retrieve latest transform from odom
   to base_footprint frame
2:   odom_base_transform ← lookupTransform("cobotagv/odom", "cobota-
   gv/base_footprint")
3:   if lookupTransform fails then
4:     return
5:   end if

   ▷ Compute translation difference
6:   correction_transform.translation.x ← target_point.position.x -
   odom_base_transform.translation.x
7:   correction_transform.translation.y ← target_point.position.y -
   odom_base_transform.translation.y

   ▷ Convert target orientation to a quaternion and compute inverse
8:   rotation_quat ← convertToQuaternion(target_point.orientation)
9:   transform_rotation.rotation ← inverseQuaternion(rotation_quat)

   ▷ Transform correction vector to target coordinate system
10:  correction_transform ← applyTransformation(correction_transform, transform_rotation)

   ▷ Extract YAW angles from base and docking point
11:  odom_base_quaternion ← convertToQuaternion(odom_base_transform.rotation)
12:  docking_p_quaternion ← convertToQuaternion(target_point.orientation)
13:  yaw_base ← extractYawFromQuaternion(odom_base_quaternion)
14:  yaw_dock ← extractYawFromQuaternion(docking_p_quaternion)

   ▷ Compute the shortest yaw difference
15:  yaw_angle_diff ← yaw_dock - yaw_base
16:  angle_options ← {yaw_angle_diff, yaw_angle_diff + 2 $\pi$ , yaw_angle_diff - 2 $\pi$ }
17:  angle_shortest ← findMinimumAbsoluteValue(angle_options)

   ▷ Create quaternion for the correction rotation
18:  correction_rotation ← createQuaternionFromEuler(0, 0, angle_shortest)
19:  correction_transform.rotation ← convertToMessage(correction_rotation)

   ▷ Print correction values
20:  print("Correction x =", correction_transform.translation.x)
21:  print("Correction y =", correction_transform.translation.y)
22:  print("yaw_shortest =", convertRadiansToDegrees(angle_shortest))
23:  print("Rotation Quaternion:", correction_transform.rotation)
24: end function

```

Eksperymenty z dokowaniem zostały przeprowadzone w sześciu wariantach. Pierwsze trzy warianty (od 1-go do 3-go) badają wpływ kalibracji pomiarów z LiDAR-ów 2D oraz rekalkulacji AGV względem znaczników na dokładność dokowania. Ostatnie 3 warianty (od 4-go do 6-go) badają wpływ korekty odometrii na dokładność dokowania oraz metodę weryfikacji jakości dokowania. Metoda rekalkulacji AGV do wykrytego znacznika polega na ponownym obliczeniu docelowej pozycji oraz orientacji punktu dokowania względem aktualnie wykrytego znacznika, za każdym razem, gdy AGV wykrywa znacznik podczas dokowania.

Pierwsze trzy warianty dokowania nie posiadały procesu weryfikacji, a dokowanie odbywało się jedynie do lewej nogi oznaczonej znacznikiem 2DM-RC. Podczas wstępnych testów dokowania zaobserwowano, że AGV ma tendencję do kończenia dokowania z obrotem w lewo. W związku z tym, w celu skorygowania końcowej orientacji dokowania, przedni LiDAR 2D został wirtualnie obrócony wokół osi Z (YAW) o $-7,399^\circ$ (korekta obliczona na podstawie przeprowadzonych analiz).

Po wykonaniu serii przejazdów dla trzech pierwszych wariantów i przeanalizowaniu danych, okazało się, że AGV przekazuje błędną odometrię. Sam pojazd porusza się poprawnie, a błąd odometrii w rzeczywistym świecie jest niewielki, ale niestety AGV przesyła błędne dane do systemu nawigacji, informując, że stale skręca w prawo:

- prędkość kątowna około $-0,0023$ rad/s przy prędkości liniowej $0,05$ m/s,
- prędkość kątowna około $-0,0056$ rad/s przy prędkości liniowej $0,1$ m/s,
- prędkość kątowna około $-0,012$ rad/s przy prędkości liniowej $0,2$ m/s,

co tworzy fałszywy obraz stanu odometrii i pozycji AGV w systemie nawigacji ROS. Na podstawie pomiarów zebranych podczas testu odometrii obliczono wartość błędu, który wynosi średnio $0,054$ rad/m. Wartość ta nadal nie jest idealna (co wykazał 5-ty wariant dokowania z próbą korekcji odometrii) i wymaga dalszych badań nad odometrią AGV Formica 3. Błąd odometrii, przekazywany do warstw systemu nawigacyjnego, powoduje, że AGV skręca w lewo, gdy system próbuje poruszać się na wprost, opierając się na błędnych danych odometrycznych.

Po wykryciu błędu odometrii okazało się, że wirtualna korekta orientacji LiDAR-u 2D nie była potrzebna, a sama korekta wprowadziła nowy błąd do procesu dokowania – pozycja dokowania obliczona na podstawie pomiarów z LiDAR-u została odsunięta od AS.

Dlatego też warianty dokowania od 4-go do 6-go nie posiadają wirtualnej korekty orientacji LiDAR-u, a w wariancie 5-tym oraz 6-tym przeprowadzono próbę korekty błędu odometrii.

Podsumowując, każdy wariant charakteryzował się własnymi warunkami, opisanymi poniżej:

1. Dokowanie do lewej nogi AS
 - (a) bez kalibracji pomiarów z LiDAR-ów,
 - (b) z rekalkulacją względem wykrytych znaczników i ponownym obliczaniem pozycji i orientacji punktu dokowania,
 - (c) z wirtualnym obrotem przedniego LiDAR-u w osi Z (YAW) o $-7,399^\circ$.
2. Dokowanie do lewej nogi AS
 - (a) z kalibracją pomiarów z LiDAR-ów,

- (b) z rekaliczacją względem wykrytych znaczników i ponownym obliczaniem pozycji i orientacji punktu dokowania,
 - (c) z wirtualnym obrotem przedniego LiDAR-u w osi Z (YAW) o $-7,399^\circ$.
3. Dokowanie do lewej nogi AS
- (a) z kalibracją pomiarów z LiDAR-ów,
 - (b) bez rekaliczacji względem wykrytych znaczników i ponownego obliczania pozycji i orientacji punktu dokowania,
 - (c) bez wirtualnego obrotu przedniego LiDAR-u w osi Z (YAW) o $-7,399^\circ$.
4. Dokowanie do lewej nogi AS i weryfikacja względem prawej nogi
- (a) z kalibracją pomiarów z LiDAR-ów,
 - (b) brak korekcji błędu odometrii.
5. Dokowanie do lewej nogi AS i weryfikacja względem obu nóg
- (a) z kalibracją pomiarów z LiDAR-ów,
 - (b) z próbą korekcji błędu odometrii (błąd kątowy $-0,054$ rad/m).
6. Dokowanie do lewej nogi AS i weryfikacja względem obu nóg
- (a) z kalibracją pomiarów z LiDAR-ów,
 - (b) z próbą korekcji błędu odometrii (błąd kątowy $-0,054$ rad/m),
 - (c) z korektą błędu dokowania na osi Y (na podstawie średniego błędu z wariantu 5-go).



Rysunek 9.3: Stanowisko testowe do eksperymentów z dokowaniem platformy AGV Formica 3 do znaczników 2DM-RC zamontowanych na lewej i prawej nodze AS.

9.3 Podsumowanie jakości dokowania AGV

Tabela 9.1 przedstawia warianty dokowania oraz ich warunki. W każdym z wariantów zaprezentowanych w tabelach 9.1 oraz 9.2, wyniki dokowania były powtarzalne, a rezultaty procesu weryfikacji porównywalne. Tabela 9.2 przedstawia średnie błędy (ME) oraz odchylenia standardowe (STDEV) dla prób dokowania AGV, gdzie błędy te oznaczają różnice względem zmierzonego i obliczonego docelowego punktu dokowania. Błędy te można podzielić na trzy główne kategorie: błędy dokowania zmierzone przy pomocy taśmy mierniczej, błędy dokowania zmierzone podczas procesu weryfikacji oraz różnice pomiędzy tymi błędami. Wyniki zawarte w tabeli 9.2 umożliwiają ocenę dokładności i precyzji dokowania względem zmierzonego i obliczonego punktu dokowania dla znaczników 2DM-RC zamontowanych na lewej i prawej nodze AS.

Tabela 9.1: Warianty dokowania AGV do AS.

No.	Dokowanie do ... nogi	Weryfikacja do ... nogi/nóg	Kalibracja 2D LiDAR-u	Rekalibracja względem znaczników	Korekta odometrii	Korekta błędu ME dla osi Y	Wirtualny obrót LiDAR-u
1.	lewej	-	-	+	-	-	+
2.	lewej	-	+	+	-	-	+
3.	lewej	-	+	-	-	-	+
4.	lewej	prawej	+	-	-	-	-
5.	lewej	obu	+	-	+	-	-
6.	lewej	obu	+	-	+	+	-

Tabela 9.2: Wyniki dokładności i precyzji dokowania AGV do zmierzonego i obliczonego punktu dokowania względem znaczników 2DM-RC zamontowanych na lewej i prawej nodze AS.

Wariant nr	Metryki	Ręcznie zmierzone odległości przy użyciu taśmy mierniczej			Automatycznie zmierzone odległości za pomocą LiDAR-u 2D podczas procesu weryfikacji			Różnice między ręcznie a automatycznie zmierzonymi odległościami		
		X [m]	Y [m]	YAW [deg.]	X [m]	Y [m]	YAW [deg.]	X [m]	Y [m]	YAW [deg.]
1.	ME	-0.0133	0.0826	0.6974	-	-	-	-	-	-
	STDEV	0.0065	0.0060	1.7232	-	-	-	-	-	-
2.	ME	-0.0048	0.0831	0.3170	-	-	-	-	-	-
	STDEV	0.0060	0.0071	1.3882	-	-	-	-	-	-
3.	ME	-0.0160	0.0947	1.0703	-	-	-	-	-	-
	STDEV	0.0103	0.0118	1.1023	-	-	-	-	-	-
4.	ME	0.0015	-0.1794	-7.3203	0.0171	-0.2007	-6.0278	-0.0156	0.0213	-1.2926
	STDEV	0.0087	0.0194	2.0770	0.0058	0.0289	1.8347	0.0029	-0.0095	0.2423
5.	ME	0.0053	-0.0446	-0.0759	0.0063	-0.0398	0.5099	-0.0010	-0.0048	-0.5858
	STDEV	0.0058	0.0117	1.7348	0.0068	0.0105	1.8563	-0.0011	0.0012	-0.1215
6.	ME	0.0080	-0.0055	-0.0473	0.0022	-0.0048	0.1699	0.0058	-0.0007	-0.2172
	STDEV	0.0120	0.0191	1.6740	0.0102	0.0153	1.6192	0.0018	0.0038	0.0548

Jak pokazują wyniki dla 1-go wariantu dokowania, AGV dokował zbyt daleko od AS. Średni błąd odległości na osi X wynosił 0,0133 m, na osi Y 0,0826 m, a średni błąd orientacji YAW wynosił 0,69°. Odchylenie standardowe dla osi X oraz Y wyniosło odpowiednio 0,0065 m oraz 0,006 m.

Wyniki dla 2-go wariantu przedstawiają ocenę jakości dokowania po zastosowaniu kalibracji pomiarów z LiDAR-u. Błąd na osi X zmniejszył się do 0,0048 m, natomiast błąd na osi Y wzrósł do 0,00831 m. Błąd orientacji zmniejszył się do 0,31°, a odchylenie standardowe końcowej orientacji AGV wyniosło 1,388°.

Wyniki dla 3-go wariantu przedstawiają ocenę jakości dokowania bez możliwości rekalkibracji względem wykrytego znacznika. Wszystkie mierzone parametry wykazały wzrost błędów, a precyzja procesu dokowania spadła. Średni błąd na osi X wyniósł 0,016 m, na osi Y 0,0947 m, a błąd orientacji YAW wyniósł 1,07°. Wartości odchylenia standardowego dla osi X oraz Y również zwiększyły się i wynosiły 0,0103 m na osi X, 0,0118 m na osi Y.

Błąd odległości na osi Y w wariantach od 1-go do 3-go jest wypadkową dwóch błędów – przesunięcia punktu dokowania w prawo (wirtualna korekta orientacji LiDAR-u) i stałego skręcania w lewo przez system nawigacji (błędna odometria AGV).

Niemniej jednak, różnice pomiędzy wariantami dokowania wynikają z zastosowania określonych metod.

Zmiany błędów pomiędzy wariantem 1-szym a 2-gim wydają się niewielkie, ale warto zauważyć, że skaner Sick microscan3 oferuje przyzwoite możliwości pomiarowe, a różnica między wersją skalibrowaną a nieskalibrowaną wynosi 9 mm, a odchylenie standardowe skanera jest równe 2,5 mm. Ważny jest także fakt, że proces kalibracji nie był przeprowadzany na konkretnym egzemplarzu skanera laserowego 2D zamontowanym na AGV. Pierwszy wariant został przeprowadzony bez kalibracji pomiarów odległości z LiDAR-u 2D. W porównaniu do 2-go wariantu (gdzie kalibracja została zastosowana), dokładność dokowania poprawiła się - na osi X o 0,0085m, w orientacji YAW o 0,3805°, natomiast błąd na osi Y zwiększył się o 0,5 mm.

Rekalibracja do ponownie wykrytego znacznika pozwoliła w wariantcie 1-szym na zmniejszenie średnich błędów dokowania na osiach X, Y oraz orientacji YAW w porównaniu do 3-go wariantu dokowania. Rekalkibracja do ponownie wykrytego znacznika 2D w trakcie procesu dokowania była metodą wyeliminowania już nagromadzonego błędu odometrii poprzez aktualizację pozycji znacznika względem AGV i przeliczenia docelowej pozycji dokowania. W 3-cim wariantcie (bez rekalkibracji do wykrytego znacznika 2D) dokładność pozycji X, Y oraz orientacji YAW pogorszyła się w porównaniu do obu wcześniejszych wariantów, osiągając wartości odpowiednio: -0,0160 m, 0,0947 m oraz 1,0703°.

Jak pokazują wyniki dla 4-go wariantu dokowania, AGV dokował zbyt blisko AS, a jego orientacja była skierowana w lewo. Średni błąd odległości na osi X wyniósł 0,0015 m, na osi Y -0,1794 m, a średni błąd orientacji YAW wyniósł -7,32°. Wartości korekty / błędy obliczone podczas procesu weryfikacji różniły się od błędów zmierzonych ręcznie średnio o 0,015 m na osi X, 0,02 m na osi Y i o 1,29° w orientacji YAW.

Wyniki dla 5-go wariantu przedstawiają ocenę dokowania AGV, w której wprowadzono próbę korekty błędu odometrii (średni błąd -0,054 rad/m). Jak pokazują wyniki, po korekcie odometrii, średni błąd odległości na osi X wyniósł 0,0053 m, średni błąd na osi Y zmniejszył się do -0,0446 m, a średni błąd orientacji YAW zmniejszył się do 0,076°. Podczas dokowania w 5-tym wariantcie do weryfikacji użyto dwóch znaczników 2DM-RC. Wartości korekty / błędy obliczone w trakcie procesu weryfikacji różniły się od zmierzonych ręcznie średnio o 0,001 m na osi X, 0,0048 m na osi Y i 0,58° w orientacji YAW.

Wyniki dla wariantu 6-go przedstawiają ocenę dokowania AGV z korektą (4,46 cm) na osi Y. Wyniki pokazują, że średni błąd odległości na osi Y zmniejszył się do 0,0055 m, natomiast na osi X wzrósł do 0,008 m. Proces weryfikacji dokładnie

obliczył również błąd pozycji i orientacji AGV w końcowym punkcie dokowania. Średnie różnice między błędami zmierzonymi ręcznie a tymi obliczonymi podczas weryfikacji wyniosły: 0,0058 m na osi X, 0,0007 m na osi Y i 0,21° w orientacji YAW. Wyniki te dowodzą, że korekta błędu miała wpływ na końcową dokładność dokowania.

Wariant 5-ty (z korektą odometrii) w porównaniu z wariantem 4-tym spowodował spadek dokładności na osi X o 3,8 mm (z 0,0015 m do 0,0053 m), ale poprawił dokładność na osi Y (z -0,1794 m do -0,0446 m) oraz w orientacji YAW (z -7,3203° do -0,0759°). Końcowy eksperyment, przeprowadzony z korektą na osi Y, w porównaniu do wariantu 5-tego, poprawił dokładność z -0,0446 m do -0,0055 m na osi Y oraz z -0,0759° do -0,0473° w orientacji YAW.

Warto również zaznaczyć, że proces weryfikacji był dokładny i pozwolił wykryć oraz obliczyć błędy procesu dokowania. Na przykład, w wariantcie 5-tym, błędy zmierzone dla osi X, Y i orientacji YAW wynosiły odpowiednio 0,0053 m, -0,0446 m i -0,0759°, natomiast błędy obliczone podczas weryfikacji wynosiły odpowiednio 0,0063 m, -0,0398 m i 0,5099°. Posiadając informacje z procesu weryfikacji o błędach dokowania, możliwe jest zminimalizowanie końcowego błędu dokowania do poziomu różnicy między pomiarami ręcznymi a obliczeniami weryfikacyjnymi, co średnio daje 1 mm na osi X, 4,8 mm na osi Y i 0,585° w orientacji YAW.

Tabela 9.3: Maksymalne odchylenia od oczekiwanych pozycji punktów dokowania po procesie dokowania.

Wariant nr	Maks. błąd	Ręcznie zmierzone odległości przy użyciu taśmy mierniczej			Automatycznie zmierzone odległości za pomocą LiDAR-u 2D podczas procesu weryfikacji			Różnice między ręcznie a automatycznie zmierzonymi odległościami		
		X [m]	Y [m]	Yaw [deg.]	X [m]	X [m]	Yaw [deg.]	X [m]	Y [m]	Yaw [deg.]
4.	Avg. + STDEV	0.0102	0.1988	9.3973	0.0229	0.2295	7.8625	0.0185	0.0307	1.5349
	Euclidean distance	0.1991		-	0.2307		-	0.0359		-
5.	Avg. + STDEV	0.0111	0.0563	1.8107	0.0132	0.0503	2.3662	0.0021	0.0060	0.7073
	Euclidean distance	0.0573		-	0.0520		-	0.0064		-
6.	Avg. + STDEV	0.0200	0.0246	1.7213	0.0124	0.0201	1.7891	0.0076	0.0045	0.2720
	Euclidean distance	0.0317		-	0.0236		-	0.0088		-

Tabela 9.3 przedstawia ocenę jakości dokowania dla 3 ostatnich (od 4-go do 6-go) testowanych wariantów, gdzie błędy na osiach X i Y są sumą wartości bezwzględnej średniego błędu (ME) i odchylenia standardowego (STDEV) dla danej osi. W związku z tym tabela 9.3 przedstawia maksymalne błędy dla obu osi oraz orientacji jako przesunięcia względem oczekiwanych pozycji punktów dokowania. Dla każdego wariantu (od 4-go do 6-go) i odpowiadających im błędów obliczono także błąd euklidesowy. Na podstawie tabeli 9.3, najbardziej dokładnym i precyzyjnym wariantem dokowania (bez korekcji błędu na osi Y) był 5-ty wariant, który cechował się najmniejszą odległością euklidesową oraz najmniejszym błędem podczas procesu weryfikacji. W tym przypadku najmniejsze różnice uzyskano pomiędzy błędami od-

ległości mierzonymi taśmą mierniczą, a tymi zmierzonymi za pomocą LiDAR-u 2D: 0,001 m na osi X, 0,0048 m na osi Y oraz 0,5858° w orientacji YAW. Jednak 6-ty wariant, dzięki korekcie na osi Y, osiągnął najmniejszy błąd euklidesowy zarówno dla błędów mierzonych ręcznie, jak i automatycznie w fazie weryfikacji.

Podsumowując, LiDAR 2D może być wykorzystywany do weryfikacji pozycji AGV po dokowaniu do znaczników 2DM-RC zamontowanych na AS z maksymalnym błędem pomiarowym wynoszącym 0,0021 m na osi X, 0,0060 m na osi Y oraz 0,7073° w orientacji YAW, oraz maksymalną odległością euklidesową 0,0064 m. Podobne wyniki potwierdzono w 6-tym wariancie, gdzie różnica pomiędzy błędem zmierzonym ręcznie a tym uzyskanym podczas weryfikacji wyniosła: 0,0076 m na osi X, 0,0045 m na osi Y i 0,272° w orientacji YAW. Ostatecznie, opracowane w ramach pracy doktorskiej metody dokowania z wykorzystaniem autorskich znaczników 2DM-RC pozwoliły osiągnąć przez AGV Formica 3 dokładność dokowania poniżej zakładanych w projekcie CoBotAGV 2 cm.

9.4 Wnioski z przeprowadzonych badań dokowania

Niektóre LiDAR-y 2D są w stanie odczytywać zróżnicowane poziomy odbicia promienia lasera. Dzięki temu możliwe było zaprojektowanie znacznika, który może przechowywać wartości binarne poprzez zróżnicowanie poziomu odbicia w danym obszarze powierzchni. Testy eksperymentalne opracowanej metody wykazały, że właściwości te mogą być z powodzeniem wykorzystywane do wykrywania i identyfikacji znaczników opartych na odbiciu na podstawie pomiarów z LiDAR-u 2D zdolnego do pomiaru siły odbitego promienia lasera. W pierwszej kolejności, obiekt był identyfikowany poprzez odnalezienie wymaganego kształtu znacznika. Informacje uzyskane dodatkowo w tym procesie, dotyczące jego położenia (punkty X, Y) i orientacji, umożliwiły jego lokalizację. Następnie, dzięki opracowanej strukturze 3-bitowej dla znacznika 2DM-RC, możliwa była poprawna identyfikacja obiektu poprzez zdekodowanie wartości binarnych. Jednakże przedstawiona metoda może być również wykorzystywana do identyfikacji wielobitowych znaczników 2DM-RC, zawierających różną liczbę bitów.

Opracowany znacznik 2DM-RC oraz metoda jego wykrywania i identyfikacji zostały z powodzeniem zastosowane w scenariuszu dokowania AGV, a następnie wykorzystane w procesie opracowywania metody dla fazy weryfikacji, która okazała się kluczowa dla oceny jakości dokowania AGV. Proces weryfikacji umożliwił pomiar błędu dokowania, a co najważniejsze – na podstawie uzyskanych wyników, oszacowany błąd był zbliżony do pomiarów manualnych. Warto podkreślić, że opracowany znacznik 2DM-RC oraz metoda jego wykrywania i identyfikacji mogą być stosowane w dowolnej autonomicznej platformie wykorzystującej technologię LiDAR-u 2D.

Dzięki opracowanym metodom dokowania, opartym na znacznikach 2DM-RC oraz precyzyjnym pomiarom odległości dostarczającym przez skalibrowane LiDAR-y 2D, udało się osiągnąć dokładność do 5 mm oraz mniej niż 0,05° w orientacji YAW. Warto również wspomnieć, że odchylenie standardowe (STDEV) w większości przypadków było większe niż średni błąd dokładności. Niemniej jednak średnia dokładność dokowania oraz procesów weryfikacji była wysoka, biorąc pod uwagę, że platforma użyta w eksperymentach była prototypem ciężkiego przemysłowego AGV, którego rozmiary wielokrotnie przewyższają wartość błędu dokładności.

Co jeszcze ważniejsze od samej dokładności i precyzji dokowania, to możliwość dokładnego i precyzyjnego określenia błędów dzięki procesowi weryfikacji opartemu na znacznikach 2DM-RC. Znajomość błędu dokładności umożliwia użytkownikowi

zastosowanie korekty. W przeciwnym razie (bez procesu weryfikacji) nie byłoby to możliwe. Udowodniono, że po kalibracji, LiDAR 2D Sick microscan3 zweryfikował pozycję z najmniejszym średnim błędem (ME) wynoszącym 0,001 m dla osi X, 0,0048 m dla osi Y oraz 0,5858° dla orientacji YAW, co zostało obliczone na podstawie różnic pomiędzy błędami zmierzonymi taśmą mierniczą a tymi uzyskanymi z LiDAR-u 2D podczas procesu weryfikacji.

System dokowania platformy mobilnej zgodnie z wymaganiami zdefiniowanymi w ramach projektu CoBotAGV powinien umożliwić dokowanie platformy AGV do AS bez potrzeby wcześniejszego tworzenia mapy środowiska. Znacznik pozwalał na lokalizację oraz identyfikację stacji montażowej oraz wyznaczenie pozycji punktu dokowania i pozycji AGV względem punktu dokowania bez wcześniejszego tworzenia mapy środowiska. Nawet gdyby taka mapa była utworzona, to znacznik 2DM-RC pozwoliłby zlokalizować AGV względem stacji montażowej i jednocześnie wyeliminować błędy wynikające z procesu wyznaczenia pozycji AGV względem zapamiętanej mapy czy akumulujących się błędów odometrii.

Rozdział 10

Podsumowanie

Celem niniejszej pracy było opracowanie metod wpływających na zwiększenie precyzji dokowania systemów AGV do wymaganego punktu dla danego stanowiska montażowego, poprzez zwiększenie precyzji i dokładności podsystemów pomiarowych oraz zastosowanie metody pozycjonowania na bazie znacznika przestrzennego.

W ramach pracy doktorskiej wykazano, że spełnione zostały postawione tezy:

1. Zastosowanie metod kalibracji pozwala na zwiększenie dokładności pomiarów z czujników.
2. Zastosowanie metod filtracji pozwala na zwiększenie precyzji pomiarów z czujników.
3. Zastosowanie znacznika przestrzennego pozwala na dokładne pozycjonowanie stanowiska montażowego.
4. Zastosowanie metod zmniejszających błędy pomiarowe zwiększa dokładność dokowania.

Cel pracy został osiągnięty. W pracy przedstawiono szereg metod umożliwiających poprawę zarówno precyzji poprzez metody filtracji, jak i dokładności poprzez metody kalibracji podsystemów pomiarowych. Ponadto opracowano również metodę pozycjonowania oraz dokowania AGV do stanowiska montażowego opartą na znaczniku 2DM-RC.

W ramach pracy doktorskiej opracowane zostały autorskie metody kalibracji czujników odległości. Metoda kalibracji adaptacyjnej (ACM, opisana w podrozdziale 4.1.2) pozwoliła na zmniejszenie błędów pomiarowych czujników odległości nawet o 79% dzięki algorytmowi umożliwiającemu dostosowywanie się do charakterystyki błędów pomiarowych (reszt) kalibrowanego czujnika. Metoda kalibracji adaptacyjnej z filtracją medianową (MSCwMF, opisana w podrozdziale 4.1.3) pozwoliła na zmniejszenie błędów pomiarowych czujników odległości w jeszcze większym stopniu, dzięki zastosowaniu filtracji medianowej, która umożliwiła dokładniejszą aproksymację charakterystyki pomiarowej czujnika odległości, a przez to dokładniejszą kalibrację. Opracowane zostały również metody oceny jakości odometrii (opisane w podrozdziałach 6.1 oraz 6.2) oraz metody jej kalibracji, które pozwalają na zmniejszenie kumulujących się błędów systematycznych odometrii. Metody kalibracji naturalnej oraz resztowej wykorzystujące techniki uczenia maszynowego (opisane w podrozdziale 4.2) pozwoliły na zmniejszenie błędów pomiarowych czujników odległości nawet do poziomu poniżej 1 mm. Wyniki otrzymane podczas badań opracowanych metod kalibracji czujników odległości oraz odometrii potwierdzają, że

zastosowanie ich pozwala zwiększyć dokładności pomiarów z badanych czujników, co potwierdza pierwszą tezę.

W ramach pracy doktorskiej przebadane zostały również metody filtracji pomiarów z czujników odległości. Badane metody filtracji średnią ruchomą oraz filtracji medianowej zostały zastosowane na szeregu czujników odległości typu LiDAR 2D. Metoda filtracji medianowej pozwoliła na zmniejszenie wartości odchylenia standardowego badanych czujników do poziomu bliskiego 50%. Wyniki opisane w podrozdziale 5.3.2 potwierdzają, że zastosowanie metod filtracji pozwala na zwiększenie precyzji pomiarów z czujników, co potwierdza drugą tezę.

W ramach pracy doktorskiej opracowany został autorski system pozycjonowania w postaci znacznika 2D z kodami refleksyjnymi (2DM-RC) wraz z metodą jego detekcji oraz identyfikacji (rozdział 7) korzystającą jedynie z danych pomiarowych dostarczanych przez LiDAR 2D. Znacznik 2DM-RC jest znacznikiem przestrzennym, możliwym do wykrycia poprzez analizę danych pomiarowych z LiDAR-u 2D w poszukiwaniu charakterystycznych cech fizycznych znacznika. Dzięki elementom odbłaskowym na powierzchni znacznika możliwe jest “zaszycie” informacji w formie kodu binarnego na poszczególnych segmentach, z których składa się znacznik, jak i zidentyfikowanie znacznika. Wyposażenie elementów stanowiska montażowego w opracowany znacznik 2DM-RC pozwala na ich dokładne pozycjonowanie oraz identyfikację. Wyniki dotyczące procesu weryfikacji pozycji AGV po zadokowaniu do AS (przedstawione w podrozdziale 9.3) potwierdzają, że opracowany znacznik 2DM-RC pozwala na dokładne pozycjonowanie stanowiska montażowego, co potwierdza trzecią tezę.

W ramach pracy doktorskiej opracowany oraz zaimplementowany został system dokowania wykorzystujący platformę ROS (rozdział 8). Zawiera on szereg węzłów odpowiedzialnych m.in. za kalibrację pomiarów odległości z LiDAR-ów 2D, komunikację z systemem AGV, detekcję oraz identyfikację znaczników 2DM-RC, realizację procedury dokowania oraz weryfikacji pozycji po zadokowaniu oraz nawigację. Oprogramowanie to pozwoliło wykonać szereg eksperymentów sprawdzających opracowane metody poprawy dokładności dokowania systemu AGV do stanowiska montażowego.

W ramach pracy doktorskiej przeprowadzone zostały badania wpływu wybranych autorskich metod kalibracji oraz systemu pozycjonowania na dokładność dokowania prototypowego systemu AGV (Formica 3 firmy AIUT) do stanowiska montażowego.

Wyniki badań potwierdzają, że:

- zastosowanie metod kalibracji zmniejszających błędy pomiarowe czujników odległości w 2-gim wariancie dokowania zwiększa dokładność dokowania względem wariantu 1-go,
- zastosowanie metod kalibracji zmniejszających błędy pomiarowe odometrii (wariant 5-ty) zwiększa dokładność dokowania względem wariantu 4-go,
- zastosowanie ciągłej rekalkulacji względem wykrytych znaczników 2DM-RC w wariancie 1-szym pozwoliło na niwelowanie skumulowanego błędu odometrii, a przez to zwiększenie dokładności dokowania względem wariantu 3-go poprzez ponowne obliczanie pozycji i orientacji AS względem AGV i korygowanie docelowej pozycji i orientacji punktu dokowania,
- zastosowanie korekty dla osi Y w wariancie 6-tym o wartości równej średniemu

błędowni dokowania w wariancie 5-tym pozwoliło zwiększyć dokładność dokowania,

- zastosowanie procesu weryfikacji po zadokowaniu pozwala obliczyć dokładną pozycję i orientację AGV względem stanowiska montażowego oraz obliczyć wartość korekty pozycji oraz orientacji, która może zostać wykorzystana w celu wykonania dalszych czynności produkcyjnych przez ramię robota kolaboracyjnego,

co potwierdza czwartą tezę.

Oryginalny wkład w dyscyplinę Informatyka Techniczna i Telekomunikacja stanowią:

- metoda kalibracji adaptacyjnej wpływająca na poprawę dokładności danych pomiarowych z czujników odległości (ACM, podrozdział 4.1.2),
- metoda kalibracji adaptacyjnej z filtracją wpływająca na poprawę dokładności oraz precyzji danych pomiarowych z czujników odległości (MSCwMF, podrozdział 4.1.3),
- metoda kalibracji odometrii w ruchu obrotowym wykorzystująca dane pomiarowe ze skalibrowanego LiDAR-u 2D (2DLAT, podrozdział 6.2),
- refleksyjny znacznik przestrzenny 2DM-RC wraz z metodą jego detekcji oraz identyfikacji umożliwiającą wyznaczenie pozycji oraz orientacji znacznika 2DM-RC wykorzystując jedynie dane pomiarowe z LiDAR-u 2D (rozdział 7.1).

Wyzwania związane z wykorzystaniem platform AGV w inteligentnej produkcji zgodnie z założeniami Przemysłu 4.0, w tym zagadnienie precyzyjnego dokowania, zostały opisane w artykule pt. *“Challenges Associated with Sensors and Data Fusion for AGV-Driven Smart Manufacturing”* [103] opublikowanym w materiałach konferencji ICCS w roku 2021.

Metody oraz wyniki badań zawarte w pracy doktorskiej były również publikowane w artykułach konferencyjnych jak i w czasopismach naukowych oraz prezentowane w ramach konferencji międzynarodowych oraz seminariów związanych z projektem CoBotAGV.

Metoda kalibracji adaptacyjnej została opublikowana w artykule pt. *“The adaptive calibration method for single-beam distance sensors”* [11] oraz zaprezentowana na konferencji ICCCI 2021 w Grecji oraz podczas seminarium w Norwegii na uczelni HVL w roku 2021. Wyniki badań kalibracji adaptacyjnej czujników odległości typu LiDAR 2D zostały zaprezentowane podczas seminarium w Norwegii na uczelni HVL w roku 2022.

Metoda kalibracji naturalnej wykorzystująca metody uczenia maszynowego została opublikowana w artykule pt. *“The calibration of single beam distance sensors based on machine learning methods”* [12] oraz zaprezentowana na konferencji IEEE BigData 2023 we Włoszech.

Metoda kalibracji resztowej wykorzystująca metody uczenia maszynowego została opublikowana w artykule pt. *“Machine learning-based calibration approaches for single-beam and multiple-beam distance sensors”* [89] w czasopiśmie IEEE Sensors w roku 2024.

Metoda kalibracji adaptacyjnej z filtrem medianowym została opublikowana w artykule pt. *“How accurate can 2D LiDAR be? A comparison of the characteristics of calibrated 2D LiDAR systems”* [102] w czasopiśmie *Sensors* w roku 2025.

Opracowany znacznik 2DM-RC wraz z metodą jego detekcji i identyfikacji został zaprezentowany podczas seminarium w Norwegii na uczelni NTNU w roku 2023. Natomiast metoda pozycjonowania wykorzystująca znacznik 2DM-RC oraz wyniki z badań dokowania systemu AGV do stanowiska montażowego zostały opisane w artykule pt. *“The method of reflection-based marker detection and identification to ensure accurate AGV docking”* i przesłane do czasopisma *Scientific Reports*. Przesłany artykuł znajduje się w fazie recenzji.

Plan przyszłych prac obejmuje zarówno rozwinięcie, jak i poszerzenie zakresu dotychczas wykonanych badań:

- wykorzystanie algorytmu SLAM oraz skalibrowanych danych pomiarowych z LiDAR-ów 2D w celu estymacji pozycji systemu AGV,
- fuzja danych odometrycznych z danymi z czujnika IMU oraz algorytmu SLAM poprzez wykorzystanie Extended Kalman Filter w celu dalszego zwiększenia precyzji oraz dokładności estymacji pozycji systemu AGV,
- rozwinięcie i automatyzacja metody kalibracji odometrii w ruchu liniowym oraz kątowym.

Bibliografia

- [1] Tanveer Abbas, Muhammad Arif i Waqas Ahmed. „Measurement and correction of systematic odometry errors caused by kinematics imperfections in mobile robots”. W: *2006 SICE-ICASE International Joint Conference*. IEEE. 2006, s. 2073–2078. DOI: [10.1109/sice.2006.315554](https://doi.org/10.1109/sice.2006.315554). URL: <http://dx.doi.org/10.1109/SICE.2006.315554>.
- [2] Michel Albonico, Milica Đorđević, Engel Hamer i Ivano Malavolta. „Software engineering research on the Robot Operating System: A systematic mapping study”. W: *Journal of Systems and Software* 197 (mar. 2023), s. 111574. ISSN: 0164-1212. DOI: [10.1016/j.jss.2022.111574](https://doi.org/10.1016/j.jss.2022.111574). URL: <http://dx.doi.org/10.1016/j.jss.2022.111574>.
- [3] Anas Alhashimi. „Statistical sensor calibration algorithms”. Prac. dokt. Luleå University of Technology, 2018.
- [4] Anas Alhashimi, Simone Del Favero, Damiano Varagnolo, Thomas Gustafsson i Gianluigi Pillonetto. „Bayesian strategies for calibrating heteroskedastic static sensors with unknown model structures”. W: *2018 European Control Conference (ECC)*. IEEE. 2018, s. 2447–2453. DOI: [10.23919/ecc.2018.8550201](https://doi.org/10.23919/ecc.2018.8550201). URL: <http://dx.doi.org/10.23919/ECC.2018.8550201>.
- [5] Anas Alhashimi, Martin Magnusson, Steffi Knorn i Damiano Varagnolo. „Calibrating Range Measurements of Lidars Using Fixed Landmarks in Unknown Positions”. W: *Sensors* 21.1 (grud. 2020), s. 155. ISSN: 1424-8220. DOI: [10.3390/s21010155](https://doi.org/10.3390/s21010155). URL: <http://dx.doi.org/10.3390/s21010155>.
- [6] Anas Alhashimi, Damiano Varagnolo i Thomas Gustafsson. „Calibrating distance sensors for terrestrial applications without groundtruth information”. W: *IEEE Sensors Journal* 17.12 (2017), s. 3698–3709. DOI: [10.1109/jsen.2017.2697850](https://doi.org/10.1109/jsen.2017.2697850). URL: <http://dx.doi.org/10.1109/JSEN.2017.2697850>.
- [7] Fuad Aliew. „An Approach for Precise Distance Measuring Using Ultrasonic Sensors”. W: *The 1st International Electronic Conference on Machines and Applications*. IECMA 2022. MDPI, wrz. 2022, s. 8. DOI: [10.3390/iecma2022-12901](https://doi.org/10.3390/iecma2022-12901). URL: <http://dx.doi.org/10.3390/IECMA2022-12901>.
- [8] Gianluca Antonelli, Stefano Chiaverini i Giuseppe Fusco. „A calibration method for odometry of mobile robots based on the least-squares technique: theory and experimental validation”. W: *IEEE Transactions on Robotics* 21.5 (2005), s. 994–1004. DOI: [10.1109/tro.2005.851382](https://doi.org/10.1109/tro.2005.851382). URL: <http://dx.doi.org/10.1109/TR0.2005.851382>.
- [9] Cyrus Bamji, John Godbaz, Minseok Oh, Swati Mehta, Andrew Payne, Sergio Ortiz, Satyadev Nagaraja, Travis Perry i Barry Thompson. „A Review of Indirect Time-of-Flight Technologies”. W: *IEEE Transactions on Electron Devices* 69.6 (czer. 2022), s. 2779–2793. ISSN: 1557-9646. DOI: [10.1109/ted.2022.3145762](https://doi.org/10.1109/ted.2022.3145762). URL: <http://dx.doi.org/10.1109/TED.2022.3145762>.

- [10] Farid Baskoro, I Gusti Putu Asto Buditjahjanto, Miftahur Rohman, Dimas Arya Soeadyfa F i Aristyawan Putra Nurdiansyah. „Impact of Sample Size Variation on Moving Average Filter Performance for Stability and Accuracy in Ultrasonic Sensor Measurements”. W: *TEM Journal* (maj 2025), s. 1681–1688. ISSN: 2217-8309. DOI: [10.18421/tem142-65](https://doi.org/10.18421/tem142-65). URL: <http://dx.doi.org/10.18421/TEM142-65>.
- [11] Piotr Biernacki, Adam Ziębiński i Damian Grzechca. „The Adaptive Calibration Method for Single-Beam Distance Sensors”. W: *Computational Collective Intelligence*. Springer International Publishing, 2021, s. 721–732. ISBN: 9783030880811. DOI: [10.1007/978-3-030-88081-1_54](https://doi.org/10.1007/978-3-030-88081-1_54). URL: http://dx.doi.org/10.1007/978-3-030-88081-1_54.
- [12] Piotr Biernacki, Adam Ziębiński, Jia-Hao Syu i Jerry Chun-Wei Lin. „The Calibration of Single Beam Distance Sensors based on Machine Learning Methods”. W: *2023 IEEE International Conference on Big Data (BigData)*. IEEE, grud. 2023, s. 5031–5037. DOI: [10.1109/bigdata59044.2023.10386524](https://doi.org/10.1109/bigdata59044.2023.10386524). URL: <http://dx.doi.org/10.1109/BigData59044.2023.10386524>.
- [13] Steve Bishop, Matthew Fairbairn, Michael Norrish, Peter Sewell, Michael Smith i Keith Wansbrough. *TCP, UDP, and Sockets: rigorous and experimentally-validated behavioural specification Volume 1: Overview*. Spraw. tech. Computer Laboratory, University of Cambridge, 2005. DOI: [10.48456/TR-624](https://doi.org/10.48456/TR-624). URL: <https://www.cl.cam.ac.uk/techreports/UCAM-CL-TR-624.html>.
- [14] Georgios Bolanakis, Kostas Nanos i Evangelos Papadopoulos. „A QR Code-based high-precision docking system for mobile robots exhibiting submillimeter accuracy”. W: *2021 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)*. IEEE. 2021, s. 830–835. DOI: [10.1109/aim46487.2021.9517507](https://doi.org/10.1109/aim46487.2021.9517507). URL: <http://dx.doi.org/10.1109/AIM46487.2021.9517507>.
- [15] Johann Borenstein i Liqiang Feng. „Measurement and correction of systematic odometry errors in mobile robots”. W: *IEEE Transactions on robotics and automation* 12.6 (1996), s. 869–880. DOI: [10.1109/70.544770](https://doi.org/10.1109/70.544770). URL: <http://dx.doi.org/10.1109/70.544770>.
- [16] Ali Bostani, Ahmad Vakili i Tayb A Denidni. „A novel method to measure and correct the odometry errors in mobile robots”. W: *2008 Canadian Conference on Electrical and Computer Engineering*. IEEE. 2008, s. 000897–000900. DOI: [10.1109/ccece.2008.4564665](https://doi.org/10.1109/ccece.2008.4564665). URL: <http://dx.doi.org/10.1109/CCECE.2008.4564665>.
- [17] Roger Bostelman, Roger Bostelman i Tsai Hong. *Review of research for docking automatic guided vehicles and mobile robots*. US Department of Commerce, National Institute of Standards i Technology, 2016. DOI: [10.6028/nist.ir.8140](https://doi.org/10.6028/nist.ir.8140). URL: <http://dx.doi.org/10.6028/NIST.IR.8140>.
- [18] Andrea Censi, Antonio Franchi, Luca Marchionni i Giuseppe Oriolo. „Simultaneous calibration of odometry and sensor parameters for mobile robots”. W: *IEEE Transactions on Robotics* 29.2 (2013), s. 475–492. DOI: [10.1109/tro.2012.2226380](https://doi.org/10.1109/tro.2012.2226380). URL: <http://dx.doi.org/10.1109/TRO.2012.2226380>.
- [19] Matthew A. Cooper, John F. Raquet i Rick Patton. „Range Information Characterization of the Hokuyo UST-20LX LIDAR Sensor”. W: *Photonics* 5.2 (maj 2018), s. 12. ISSN: 2304-6732. DOI: [10.3390/photonics5020012](https://doi.org/10.3390/photonics5020012). URL: <http://dx.doi.org/10.3390/photonics5020012>.

- [20] Yanyan Dai i Kidong Lee. „Multi-Sensor Fusion for Autonomous Mobile Robot Docking: Integrating LiDAR, YOLO-Based AprilTag Detection, and Depth-Aided Localization”. W: *Electronics* 14.14 (2025), s. 2769. DOI: [10.3390/electronics14142769](https://doi.org/10.3390/electronics14142769). URL: <http://dx.doi.org/10.3390/electronics14142769>.
- [21] *DFRobot TF-Mini Datasheet*. Accessed: 2025-08-10. URL: https://download.kamami.pl/p570405-SJ-GU-TFmini-T-01%20A02%20Datasheet_EN.pdf (term. wiz. 10.08.2025).
- [22] *DFRobot TF-Mini-S Datasheet*. Accessed: 2025-08-10. URL: https://www.mouser.com/datasheet/2/1099/Benewake_10152020_TFmini_S-1954051.pdf (term. wiz. 10.08.2025).
- [23] *DFRobot URM3v5 Datasheet*. Accessed: 2025-08-10. URL: <https://docs.rs-online.com/f172/A700000007238458.pdf> (term. wiz. 10.08.2025).
- [24] Dawei Ding, Wenfeng Ding, Rui Huang, Yucan Fu i Fengyu Xu. „Research progress of laser triangulation on-machine measurement technology for complex surface: A review”. W: *Measurement* 216 (lip. 2023), s. 113001. ISSN: 0263-2241. DOI: [10.1016/j.measurement.2023.113001](https://doi.org/10.1016/j.measurement.2023.113001). URL: <http://dx.doi.org/10.1016/j.measurement.2023.113001>.
- [25] Sebastian Dudzik. „Application of the motion capture system to estimate the accuracy of a wheeled mobile robot localization”. W: *Energies* 13.23 (2020), s. 6437. DOI: [10.3390/en13236437](https://doi.org/10.3390/en13236437). URL: <http://dx.doi.org/10.3390/en13236437>.
- [26] Tully Foote. „tf: The transform library”. W: *2013 IEEE Conference on Technologies for Practical Robot Applications (TePRA)*. IEEE, kw. 2013. DOI: [10.1109/tepra.2013.6556373](https://doi.org/10.1109/tepra.2013.6556373). URL: <http://dx.doi.org/10.1109/TePRA.2013.6556373>.
- [27] Francesco Galasso, Dario Lodi Rizzini, Fabio Oleari i Stefano Caselli. „Efficient calibration of four wheel industrial AGVs”. W: *Robotics and Computer-Integrated Manufacturing* 57 (2019), s. 116–128. DOI: [10.1016/j.rcim.2018.11.005](https://doi.org/10.1016/j.rcim.2018.11.005). URL: <http://dx.doi.org/10.1016/j.rcim.2018.11.005>.
- [28] Craig Glennie i Derek D. Lichti. „Static Calibration and Analysis of the Velodyne HDL-64E S2 for High Accuracy Mobile Scanning”. W: *Remote Sensing* 2.6 (czer. 2010), s. 1610–1624. ISSN: 2072-4292. DOI: [10.3390/rs2061610](https://doi.org/10.3390/rs2061610). URL: <http://dx.doi.org/10.3390/rs2061610>.
- [29] Weipeng Guan, Linyi Huang, Babar Hussain i C Patrick Yue. „Robust robotic localization using visible light positioning and inertial fusion”. W: *IEEE Sensors Journal* 22.6 (2021), s. 4882–4892. DOI: [10.1109/jsen.2021.3053342](https://doi.org/10.1109/jsen.2021.3053342). URL: <http://dx.doi.org/10.1109/JSEN.2021.3053342>.
- [30] *HCSR04 Datasheet*. Accessed: 2025-08-10. URL: <https://cdn.sparkfun.com/datasheets/Sensors/Proximity/HCSR04.pdf> (term. wiz. 10.08.2025).
- [31] Fan He. „USB Port and power delivery: An overview of USB port interoperability”. W: *2015 IEEE Symposium on Product Compliance Engineering (ISPC)*. IEEE. 2015, s. 1–5.
- [32] Yiming He, Yanhua Dong i Hongyu Sun. „Research and application of the median filtering method in enhancing the imperceptibility of perturbations in adversarial examples”. W: *Electronics (Basel)* 13.13 (czer. 2024), s. 2458.

- [33] Radim Hercik, Radek Byrtus, Rene Jaros i Jiri Koziorek. „Implementation of autonomous mobile robot in smartfactory”. W: *Applied Sciences* 12.17 (2022), s. 8912. DOI: [10.3390/app12178912](https://doi.org/10.3390/app12178912). URL: <http://dx.doi.org/10.3390/app12178912>.
- [34] Weiwei Hu, Keke Zhang, Lihuan Shao, Qinglei Lin, Yongzhu Hua i Jin Qin. „Clustering denoising of 2d lidar scanning in indoor environment based on keyframe extraction”. W: *Sensors* 23.1 (2022), s. 18. DOI: [10.3390/s23010018](https://doi.org/10.3390/s23010018). URL: <http://dx.doi.org/10.3390/s23010018>.
- [35] Feiyu Jia, Misha Afaq, Ben Ripka, Quamrul Huda i Rafiq Ahmad. „Vision- and lidar-based autonomous docking and recharging of a mobile robot for machine tending in autonomous manufacturing environments”. W: *Applied Sciences* 13.19 (2023), s. 10675. DOI: [10.3390/app131910675](https://doi.org/10.3390/app131910675). URL: <http://dx.doi.org/10.3390/app131910675>.
- [36] Changbae Jung i Woojin Chung. „Accurate calibration of two wheel differential mobile robots by using experimental heading errors”. W: *2012 IEEE International Conference on Robotics and Automation*. IEEE. 2012, s. 4533–4538. DOI: [10.1109/icra.2012.6224660](https://doi.org/10.1109/icra.2012.6224660). URL: <http://dx.doi.org/10.1109/ICRA.2012.6224660>.
- [37] Alonzo Kelly. „General solution for linearized stochastic error propagation in vehicle odometry”. W: *IFAC Proceedings Volumes* 35.1 (2002), s. 25–30. DOI: [10.3182/20020721-6-es-1901.00816](https://doi.org/10.3182/20020721-6-es-1901.00816). URL: <http://dx.doi.org/10.3182/20020721-6-ES-1901.00816>.
- [38] Alonzo Kelly. „General solution for linearized systematic error propagation in vehicle odometry”. W: *Proceedings 2001 IEEE/RSJ International Conference on Intelligent Robots and Systems. Expanding the Societal Role of Robotics in the the Next Millennium (Cat. No. 01CH37180)*. T. 4. IEEE. 2001, s. 1938–1945. DOI: [10.1109/irosl.2001.976357](https://doi.org/10.1109/irosl.2001.976357). URL: <http://dx.doi.org/10.1109/IROSL.2001.976357>.
- [39] Neha R Laddha i AP Thakare. „A review on serial communication by UART”. W: *International journal of advanced research in computer science and software engineering* 3.1 (2013).
- [40] *lazypredict - pakiet języka Python*. Accessed: 2025-08-10. URL: <https://lazypredict.readthedocs.io> (term. wiz. 10.08.2025).
- [41] *Leica D510 Datasheet*. Accessed: 2025-08-10. URL: https://shop.leica-geosystems.com/sites/default/files/2022-04/Leica%20DISTO%20D510%20data-sheet_2201_V1.0_EN.pdf (term. wiz. 10.08.2025).
- [42] *Leica X4 Datasheet*. Accessed: 2025-08-10. URL: https://shop.leica-geosystems.com/sites/default/files/2022-01/Leica%20DISTO%20X4%20data-sheet_2201_V1.0_EN.pdf (term. wiz. 10.08.2025).
- [43] *Leuze RSL425 XL Datasheet*. Accessed: 2025-08-10. URL: [https://files.leuze.com/Volumes/Volume0/opasdata/d100001/medias/docus/212/\\$v35/DS_RSL425-XL-CU416-25_eng_53800278.pdf](https://files.leuze.com/Volumes/Volume0/opasdata/d100001/medias/docus/212/$v35/DS_RSL425-XL-CU416-25_eng_53800278.pdf) (term. wiz. 10.08.2025).
- [44] Robert de Levie. „Curve fitting with least squares”. W: *Critical Reviews in Analytical Chemistry* 30.1 (2000), s. 59–74.

- [45] Zheqi Li i Jidong Huang. „Study on the use of QR codes as landmarks for indoor positioning: Preliminary results”. W: *2018 IEEE/ION position, location and navigation symposium (PLANS)*. IEEE. 2018, s. 1270–1276. DOI: [10.1109/plans.2018.8373516](https://doi.org/10.1109/plans.2018.8373516). URL: <http://dx.doi.org/10.1109/PLANS.2018.8373516>.
- [46] Peter Lightbody, Tomáš Krajník i Marc Hanheide. „An efficient visual fiducial localisation system”. W: *ACM SIGAPP Applied Computing Review* 17.3 (list. 2017), s. 28–37. ISSN: 1931-0161. DOI: [10.1145/3161534.3161537](https://doi.org/10.1145/3161534.3161537). URL: <http://dx.doi.org/10.1145/3161534.3161537>.
- [47] Hongwei Lin, Takashi Maekawa i Chongyang Deng. „Survey on geometric iterative methods and their applications”. W: *Computer-Aided Design* 95 (lut. 2018), s. 40–51. ISSN: 0010-4485. DOI: [10.1016/j.cad.2017.10.002](https://doi.org/10.1016/j.cad.2017.10.002). URL: <http://dx.doi.org/10.1016/j.cad.2017.10.002>.
- [48] Yugang Liu. „A laser intensity based autonomous docking approach for mobile robot recharging in unstructured environments”. W: *IEEE Access* 10 (2022), s. 71165–71176. DOI: [10.1109/access.2022.3188099](https://doi.org/10.1109/access.2022.3188099). URL: <http://dx.doi.org/10.1109/ACCESS.2022.3188099>.
- [49] Shaoping Lu, Chen Xu, Ray Y Zhong i Lihui Wang. „A RFID-enabled positioning system in automated guided vehicle for smart factories”. W: *Journal of Manufacturing Systems* 44 (2017), s. 179–190. DOI: [10.1016/j.jmsy.2017.03.009](https://doi.org/10.1016/j.jmsy.2017.03.009). URL: <http://dx.doi.org/10.1016/j.jmsy.2017.03.009>.
- [50] Shaoping Lu, Chen Xu, Ray Y. Zhong i Lihui Wang. „A RFID-enabled positioning system in automated guided vehicle for smart factories”. W: *Journal of Manufacturing Systems* 44 (lip. 2017), s. 179–190. ISSN: 0278-6125. DOI: [10.1016/j.jmsy.2017.03.009](https://doi.org/10.1016/j.jmsy.2017.03.009). URL: <http://dx.doi.org/10.1016/j.jmsy.2017.03.009>.
- [51] Jie Ma, Shenglong Zhuo, Lei Qiu, Yuzhu Gao, Yifan Wu, Ming Zhong, Rui Bai, Miao Sun i Patrick Yin Chiang. „A review of ToF-based LiDAR”. W: *Journal of Semiconductors* 45.10 (2024), s. 101201.
- [52] Jayant Mankar, Chaitali Darode, Komal Trivedi, Madhura Kanoje i Prachi Shahare. „Review of I2C protocol”. W: *International Journal of Research in Advent Technology* 2.1 (2014).
- [53] Dariusz Marek, Piotr Biernacki, Jakub Szyguła i Adam Domański. „General Concepts of a Simulation Method for Automated Guided Vehicle in Industry 4.0”. W: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, grud. 2022, s. 6306–6314. DOI: [10.1109/bigdata55660.2022.10020846](https://doi.org/10.1109/bigdata55660.2022.10020846). URL: <http://dx.doi.org/10.1109/BigData55660.2022.10020846>.
- [54] Dariusz Marek, Piotr Biernacki, Jakub Szyguła, Adam Domański, Marcin Paszkuta, Marta Szczygieł, Marcel Król i Konrad Wojciechowski. „Collision Avoidance Mechanism for Swarms of Drones”. W: *Sensors* 25.4 (lut. 2025), s. 1141. ISSN: 1424-8220. DOI: [10.3390/s25041141](https://doi.org/10.3390/s25041141). URL: <http://dx.doi.org/10.3390/s25041141>.

- [55] Dariusz Marek, Marcin Paszkuta, Jakub Szyguła, Piotr Biernacki, Adam Domański, Marta Szczygieł, Marcel Król i Konrad Wojciechowski. „General Concepts in Swarm of Drones Control: Analysis and Implementation”. W: *2023 IEEE International Conference on Big Data (BigData)*. IEEE, grud. 2023, s. 5070–5077. DOI: [10.1109/bigdata59044.2023.10386672](https://doi.org/10.1109/bigdata59044.2023.10386672). URL: <http://dx.doi.org/10.1109/BigData59044.2023.10386672>.
- [56] Dariusz Marek, Marcin Paszkuta, Jakub Szyguła, Piotr Biernacki, Adam Domański, Marta Szczygieł, Marcel Król i Konrad Wojciechowski. „Swarm of Drones in a Simulation Environment—Efficiency and Adaptation”. W: *Applied Sciences* 14.9 (kw. 2024), s. 3703. ISSN: 2076-3417. DOI: [10.3390/app14093703](https://doi.org/10.3390/app14093703). URL: <http://dx.doi.org/10.3390/app14093703>.
- [57] Agostino Martinelli, Nicola Tomatis, Adriana Tapus i Roland Siegwart. „Simultaneous localization and odometry calibration for mobile robot”. W: *Proceedings 2003 IEEE/RSJ international conference on intelligent robots and systems (IROS 2003)(Cat. No. 03CH37453)*. T. 2. IEEE. 2003, s. 1499–1504. DOI: [10.1109/iros.2003.1248856](https://doi.org/10.1109/iros.2003.1248856). URL: <http://dx.doi.org/10.1109/IROS.2003.1248856>.
- [58] Stefano Mutti i Nicola Pedrocchi. „Improved tracking and docking of industrial mobile robots through UKF vision-based kinematics calibration”. W: *IEEE Access* 9 (2021), s. 127664–127671. DOI: [10.1109/access.2021.3111004](https://doi.org/10.1109/access.2021.3111004). URL: <http://dx.doi.org/10.1109/ACCESS.2021.3111004>.
- [59] V. Nguyen, A. Martinelli, N. Tomatis i R. Siegwart. „A comparison of line extraction algorithms using 2D laser rangefinder for indoor mobile robotics”. W: *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, 2005, s. 1929–1934. DOI: [10.1109/iros.2005.1545234](https://doi.org/10.1109/iros.2005.1545234). URL: <http://dx.doi.org/10.1109/IROS.2005.1545234>.
- [60] B Nikolova, G Nikolov i M Todorov. „Curve fitting of sensors’ characteristics”. W: *Annual Journal of Electronics, ISSN* (2009), s. 1313–1842.
- [61] Tomasz Nowak, Michał R Nowicki i Piotr Skrzypczyński. „Vision-based positioning of electric buses for assisted docking to charging stations”. W: *International Journal of Applied Mathematics and Computer Science* 32.4 (2022), s. 583–599. DOI: [10.34768/amcs-2022-0041](https://doi.org/10.34768/amcs-2022-0041). URL: <http://dx.doi.org/10.34768/amcs-2022-0041>.
- [62] Sv. Noykov i Ch. Roumenin. „Calibration and interface of a polaroid ultrasonic sensor for mobile robots”. W: *Sensors and Actuators A: Physical* 135.1 (mar. 2007), s. 169–178. ISSN: 0924-4247. DOI: [10.1016/j.sna.2006.07.006](https://doi.org/10.1016/j.sna.2006.07.006). URL: <http://dx.doi.org/10.1016/j.sna.2006.07.006>.
- [63] *NUCLEO STM32F429ZI Datasheet*. Accessed: 2025-08-10. URL: https://www.st.com/resource/en/data_brief/nucleo-f429zi.pdf (term. wiz. 10.08.2025).
- [64] Katja Nummiaro, Esther Koller-Meier, Tomš Svoboda, Daniel Roth i Luc Van Gool. „Color-Based Object Tracking in Multi-camera Environments”. W: *Pattern Recognition*. Springer Berlin Heidelberg, 2003, s. 591–599. ISBN: 9783540452430. DOI: [10.1007/978-3-540-45243-0_75](https://doi.org/10.1007/978-3-540-45243-0_75). URL: http://dx.doi.org/10.1007/978-3-540-45243-0_75.

- [65] Obraz czujnika DFRobot TF-Mini. Accessed: 2025-08-10. URL: https://kamami.pl/109965-large_default/dfrobot-tf-mini-lidar-tof-laser-sensor.jpg (term. wiz. 10.08.2025).
- [66] Obraz czujnika DFRobot URM37 v5. Accessed: 2025-08-10. URL: <https://static-data2.manualslib.com/product-images/194/19331/1933046/raw.jpg> (term. wiz. 10.08.2025).
- [67] Obraz czujnika HC-SR04. Accessed: 2025-08-10. URL: <https://www.kollino.de/wp-content/uploads/2018/06/HC-SR04.jpg> (term. wiz. 10.08.2025).
- [68] Obraz czujnika Leica D510. Accessed: 2025-08-10. URL: <https://www.onepointsurvey.com/products/leica-disto-d510-laser-distance-meter> (term. wiz. 10.08.2025).
- [69] Obraz czujnika Leica X4. Accessed: 2025-08-10. URL: <https://www.tequipment.net/Leica/X4-1-P2P-Package/Laser-Distance-Meter/> (term. wiz. 10.08.2025).
- [70] Obraz czujnika Leuze RSL425 XL. Accessed: 2025-08-10. URL: <https://www.leuze.com/pl-pl/rs1425-xl-cu416-25/53800278> (term. wiz. 10.08.2025).
- [71] Obraz czujnika RPLiDAR A1. Accessed: 2025-08-10. URL: <https://www.waveshare.com/rplidar-a1.htm> (term. wiz. 10.08.2025).
- [72] Obraz czujnika RPLiDAR A2. Accessed: 2025-08-10. URL: <https://botland.store/withdrawn-products/7036-laser-scanner-360-degree-rplidar-a2m8-5904422361433.html> (term. wiz. 10.08.2025).
- [73] Obraz czujnika Sick microscan3. Accessed: 2025-08-10. URL: <https://www.sick.com/media/895/4/64/264/IM0061264.png> (term. wiz. 10.08.2025).
- [74] Samuel Palermo, Sebastian Hoyos, Shengchang Cai, Shiva Kiran i Yuanming Zhu. „Analog-to-digital converter-based serial links: An overview”. W: *IEEE Solid-State Circuits Magazine* 10.3 (2018), s. 35–47.
- [75] Ivan Paunovic, Darko Todorovic, Miroslav Bozic i Goran Djordjevic. „Calibration of ultrasonic sensors of a mobile robot”. W: *Serbian Journal of Electrical Engineering* 6.3 (2009), s. 427–437. ISSN: 2217-7183. DOI: [10.2298/SJEE0903427p](https://doi.org/10.2298/SJEE0903427p). URL: <http://dx.doi.org/10.2298/SJEE0903427P>.
- [76] Olena Pavliuk, Tomasz Steclik i Piotr Biernacki. „The forecast of the AGV battery discharging via the machine learning methods”. W: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, grud. 2022, s. 6315–6324. DOI: [10.1109/bigdata55660.2022.10020968](https://doi.org/10.1109/bigdata55660.2022.10020968). URL: <http://dx.doi.org/10.1109/BigData55660.2022.10020968>.
- [77] Isaac Perper. „A Low-Cost, Scalable Platform for Sub-Centimeter UHF RFID Positioning”. Prac. dokt. Massachusetts Institute of Technology, 2021.
- [78] Mateusz Przybyla. „Detection and tracking of 2D geometric obstacles from LRF data”. W: *2017 11th International Workshop on Robot Motion and Control (RoMoCo)*. IEEE, lip. 2017, s. 135–141. DOI: [10.1109/romoco.2017.8003904](https://doi.org/10.1109/romoco.2017.8003904). URL: <http://dx.doi.org/10.1109/RoMoCo.2017.8003904>.
- [79] Jan Richter, David Bohlig, Andreas Nüchter i Klaus Schilling. „Advanced edge detection of apriltags for precise docking maneuvers of mobile robots”. W: *IFAC-PapersOnLine* 55.8 (2022), s. 117–123. DOI: [10.1016/j.ifacol.2022.08.020](https://doi.org/10.1016/j.ifacol.2022.08.020). URL: <http://dx.doi.org/10.1016/j.ifacol.2022.08.020>.

- [80] *RPLiDAR A1 Datasheet*. Accessed: 2025-08-10. URL: https://bucket-download.slamtec.com/d1e428e7efbdc65a8ea111061794fb8d4ccd3a0/LD108_SLAMTEC_rplidar_datasheet_A1M8_v3.0_en.pdf (term. wiz. 10.08.2025).
- [81] *RPLiDAR A2 Datasheet*. Accessed: 2025-08-10. URL: https://bucket-download.slamtec.com/20b2e974dd7c381e46c78db374772e31ea74370d/LD208_SLAMTEC_rplidar_datasheet_A2M8_v2.6_en.pdf (term. wiz. 10.08.2025).
- [82] Aria Salari, Abtin Djavadifar, Xiangrui Liu i Homayoun Najjaran. „Object recognition datasets and challenges: A review”. W: *Neurocomputing* 495 (lip. 2022), s. 129–152. ISSN: 0925-2312. DOI: [10.1016/j.neucom.2022.01.022](https://doi.org/10.1016/j.neucom.2022.01.022). URL: <http://dx.doi.org/10.1016/j.neucom.2022.01.022>.
- [83] Joao Machado Santos, David Portugal i Rui P. Rocha. „An evaluation of 2D SLAM techniques available in Robot Operating System”. W: *2013 IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR)*. IEEE, paź. 2013, s. 1–6. DOI: [10.1109/ssrr.2013.6719348](https://doi.org/10.1109/ssrr.2013.6719348). URL: <http://dx.doi.org/10.1109/SSRR.2013.6719348>.
- [84] *Sick microscan3 Datasheet*. Accessed: 2025-08-10. URL: https://www.sick.com/media/pdf/7/47/147/dataSheet_MICS3-CBAZ90IZ1P01_1094461_en.pdf (term. wiz. 10.08.2025).
- [85] *sklearn - pakiety języka Python*. Accessed: 2025-08-10. URL: <https://scikit-learn.org> (term. wiz. 10.08.2025).
- [86] Jorg Sommer, Sebastian Gunreben, Frank Feller, Martin Kohn, Ahlem Mifdaoui, Detlef Saß i Joachim Scharf. „Ethernet—a survey on its fields of application”. W: *IEEE Communications Surveys & Tutorials* 12.2 (2010), s. 263–284.
- [87] David C Stone. „Application of median filtering to noisy data”. W: *Canadian Journal of chemistry* 73.10 (1995), s. 1573–1581. DOI: [10.1139/v95-195](https://doi.org/10.1139/v95-195). URL: <http://dx.doi.org/10.1139/v95-195>.
- [88] Shijian Su, Xianping Zeng, Shuang Song, Mingqiang Lin, Houde Dai, Wanan Yang i Chao Hu. „Positioning accuracy improvement of automated guided vehicles based on a novel magnetic tracking approach”. W: *IEEE Intelligent Transportation Systems Magazine* 12.4 (2018), s. 138–148. DOI: [10.1109/mits.2018.2880269](https://doi.org/10.1109/mits.2018.2880269). URL: <http://dx.doi.org/10.1109/MITS.2018.2880269>.
- [89] Jia-Hao Syu, Jerry Chun-Wei Lin, Piotr Biernacki i Adam Ziębiński. „Machine Learning-Based Calibration Approaches for Single-Beam and Multiple-Beam Distance Sensors”. W: *IEEE Sensors Journal* 24.1 (sty. 2024), s. 975–983. ISSN: 1530-437X. DOI: [10.1109/jsen.2023.3328650](https://doi.org/10.1109/jsen.2023.3328650). URL: <http://dx.doi.org/10.1109/JSEN.2023.3328650>.
- [90] Jakub Szyguła, Piotr Biernacki, Dariusz Marek, Adam Domański, Łukasz Sobczak, Jarosław Flak, Dariusz Caban i Piotr Pawlas. „Analysis of web-based geo-visualization methods applied for Automated Guided Vehicle using Satellite Navigation Systems”. W: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, grud. 2022, s. 6371–6377. DOI: [10.1109/bigdata55660.2022.10020593](https://doi.org/10.1109/bigdata55660.2022.10020593). URL: <http://dx.doi.org/10.1109/BigData55660.2022.10020593>.

- [91] F. Tong, S.K. Tso i T.Z. Xu. „A high precision ultrasonic docking system used for automatic guided vehicle”. W: *Sensors and Actuators A: Physical* 118.2 (lut. 2005), s. 183–189. ISSN: 0924-4247. DOI: [10.1016/j.sna.2004.06.026](https://doi.org/10.1016/j.sna.2004.06.026). URL: <http://dx.doi.org/10.1016/j.sna.2004.06.026>.
- [92] Paula Verde, Javier Díez-González, Rubén Álvarez i Hilde Perez. „Characterization of AGV Localization System in Industrial Scenarios Using UWB Technology”. W: *IEEE Transactions on Instrumentation and Measurement* 72 (2023), s. 1–13. ISSN: 1557-9662. DOI: [10.1109/tim.2023.3296817](https://doi.org/10.1109/tim.2023.3296817). URL: <http://dx.doi.org/10.1109/TIM.2023.3296817>.
- [93] Zhe Wei, Sen Wang, Kangyelin Chen i Fang Wang. „ROS-Based Navigation and Obstacle Avoidance: A Study of Architectures, Methods, and Trends”. W: *Sensors* 25.14 (lip. 2025), s. 4306. ISSN: 1424-8220. DOI: [10.3390/s25144306](https://doi.org/10.3390/s25144306). URL: <http://dx.doi.org/10.3390/s25144306>.
- [94] *wenglor product page*. Accessed: 2025-08-10. URL: https://www.wenglor.com/medias/__secure__?mediaPK=9091962634270 (term. wiz. 10. 08. 2025).
- [95] Bisheng Yang, Lina Fang, Qingquan Li i Jonathan Li. „Automated Extraction of Road Markings from Mobile Lidar Point Clouds”. W: *Photogrammetric Engineering & Remote Sensing* 78.4 (kw. 2012), s. 331–338. ISSN: 0099-1112. DOI: [10.14358/pers.78.4.331](https://doi.org/10.14358/pers.78.4.331). URL: <http://dx.doi.org/10.14358/PERS.78.4.331>.
- [96] Qian Yang, David G Taylor i Gregory D Durgin. „Kalman filter based localization and tracking estimation for HIMR RFID systems”. W: *2018 IEEE International Conference on RFID (RFID)*. IEEE. 2018, s. 1–5. DOI: [10.1109/rfid.2018.8376199](https://doi.org/10.1109/rfid.2018.8376199). URL: <http://dx.doi.org/10.1109/RFID.2018.8376199>.
- [97] Abdurrahman Yilmaz i Hakan Temeltas. „A multi-stage localization framework for accurate and precise docking of autonomous mobile robots (AMRs)”. W: *Robotica* 42.6 (maj 2024), s. 1885–1908. ISSN: 1469-8668. DOI: [10.1017/S0263574724000602](https://doi.org/10.1017/S0263574724000602). URL: <http://dx.doi.org/10.1017/S0263574724000602>.
- [98] Abdurrahman Yilmaz i Hakan Temeltas. „A multi-stage localization framework for accurate and precise docking of autonomous mobile robots (AMRs)”. W: *Robotica* 42.6 (2024), s. 1885–1908. DOI: [10.1017/S0263574724000602](https://doi.org/10.1017/S0263574724000602). URL: <http://dx.doi.org/10.1017/S0263574724000602>.
- [99] Abdurrahman Yilmaz i Hakan Temeltas. „Integration of affine ICP into the precise localization problem of smart-AGVs: Procedures, enhancements and challenges”. W: *Transactions of the Institute of Measurement and Control* 43.8 (2021), s. 1695–1709. DOI: [10.1177/0142331220933430](https://doi.org/10.1177/0142331220933430). URL: <http://dx.doi.org/10.1177/0142331220933430>.
- [100] Zhenyu Yu, Arefeen Mohammed i Issa Panahi. „A review of three PWM techniques”. W: *Proceedings of the 1997 American Control Conference (Cat. No. 97CH36041)*. T. 1. IEEE. 1997, s. 257–261.
- [101] Feihu Zhang i Alois Knoll. „Vehicle Detection Based on Probability Hypothesis Density Filter”. W: *Sensors* 16.4 (kw. 2016), s. 510. ISSN: 1424-8220. DOI: [10.3390/s16040510](https://doi.org/10.3390/s16040510). URL: <http://dx.doi.org/10.3390/s16040510>.

- [102] Adam Ziębiński i Piotr Biernacki. „How Accurate Can 2D LiDAR Be? A Comparison of the Characteristics of Calibrated 2D LiDAR Systems”. W: *Sensors* 25.4 (lut. 2025), s. 1211. ISSN: 1424-8220. DOI: [10.3390/s25041211](https://doi.org/10.3390/s25041211). URL: <http://dx.doi.org/10.3390/s25041211>.
- [103] Adam Ziębiński, Dariusz Mrozek, Rafał Cupek, Damian Grzechca, Marcin Fojcik, Marek Drewniak, Erik Kyrkjebø, Jerry Chun-Wei Lin, Knut Øvsthus i Piotr Biernacki. „Challenges Associated with Sensors and Data Fusion for AGV-Driven Smart Manufacturing”. W: *Computational Science – ICCS 2021*. Springer International Publishing, 2021, s. 595–608. ISBN: 9783030779702. DOI: [10.1007/978-3-030-77970-2_45](https://doi.org/10.1007/978-3-030-77970-2_45). URL: http://dx.doi.org/10.1007/978-3-030-77970-2_45.

Spis rysunków

1.1	AGV Formica 3 wraz z ramieniem robota kolaboracyjnego (a). Wizualizacja platformy CoBotAGV dokującej do stanowiska montażowego (b).	3
1.2	Uproszczony schemat przepływu danych z AGV do opracowanego systemu dokowania do stanowiska montażowego.	4
3.1	Czujnik odległości, DFRobot TF Mini LiDAR [65].	20
3.2	Czujnik odległości, Leica D510 LiDAR [68].	21
3.3	Czujnik odległości, Leica X4 LiDAR [69].	21
3.4	Czujnik odległości, RPLidar A1 LiDAR 2D [71].	22
3.5	Czujnik odległości, RPLidar A2 LiDAR 2D [72].	22
3.6	Czujnik odległości, Leuze RSL425 XL LiDAR 2D [70].	23
3.7	Czujnik odległości, Sick microScan3 LiDAR 2D [73].	23
3.8	Ultradźwiękowy czujnik odległości, HC-SR04 [67].	25
3.9	Ultradźwiękowy czujnik odległości, DFRobot URM37v5 [66].	25
3.10	Stanowisko badawcze umożliwiające badanie jakości pomiarowej czujników odległości.	27
3.11	Wyniki pomiarów odległości z czujnika DFRobot TF Mini z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	28
3.12	Wyniki pomiarów odległości z czujnika DFRobot TF Mini-S z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	29
3.13	Wyniki pomiarów odległości z czujnika HC-SR04 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	30
3.14	Wyniki pomiarów odległości z czujnika URM37 v5 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	31
3.15	Wyniki pomiarów odległości z czujnika RPLiDAR A1 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	32
3.16	Wyniki pomiarów odległości z czujnika RPLiDAR A2 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	33
3.17	Wyniki pomiarów odległości z czujnika Leuze RSL425 XL z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	34
3.18	Leuze RSL425 XL - błędy i nieliniowość pomiarów odległości.	34

3.19	Leuze RSL425 XL - błędy i nieliniowość pomiarów odległości widoczna na odcinkach reszt.	35
3.20	Wyniki pomiarów odległości z czujnika Sick microscan3 z wartościami referencyjnymi, wraz z odpowiadającymi im resztami oraz obliczonymi wartościami średnimi i odchyleniami standardowymi.	36
3.21	Zestawienie pomiarów odległości oraz reszt badanych czujników 1D.	37
3.22	Zestawienie pomiarów odległości oraz reszt badanych czujników 2D.	38
4.1	Aproksymacja wielomianowa 1-go stopnia w kalibracji jednosekcyjnej - TF Mini.	45
4.2	Aproksymacja wielomianowa 2-go stopnia w kalibracji jednosekcyjnej - TF Mini.	45
4.3	Aproksymacja wielomianowa 3-go stopnia w kalibracji jednosekcyjnej - TF Mini.	46
4.4	Aproksymacja wielomianowa 4-go stopnia w kalibracji jednosekcyjnej - TF Mini.	46
4.5	Aproksymacja wielomianowa 5-go stopnia w kalibracji jednosekcyjnej - TF Mini.	47
4.6	Aproksymacja wielomianowa 6-go stopnia w kalibracji jednosekcyjnej - TF Mini.	47
4.7	Aproksymacja wielomianowa 7-go stopnia w kalibracji jednosekcyjnej - TF Mini.	48
4.8	Wartości RMSE aproksymacji pomiarów odległości w kalibracji jednosekcyjnej - TF Mini	48
4.9	Wartości RMSE aproksymacji reszt w kalibracji jednosekcyjnej - TF Mini	49
4.10	Suma wartości RMSE aproksymacji pomiarów odległości oraz reszt w kalibracji jednosekcyjnej - TF Mini	49
4.11	Aproksymacja wielomianowa 1-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.	51
4.12	Aproksymacja wielomianowa 2-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.	51
4.13	Aproksymacja wielomianowa 3-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.	52
4.14	Aproksymacja wielomianowa 4-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.	52
4.15	Aproksymacja wielomianowa 5-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.	53
4.16	Aproksymacja wielomianowa 6-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.	53
4.17	Aproksymacja wielomianowa 7-go stopnia w kalibracji jednosekcyjnej - Sick microScan3.	54
4.18	Wartości RMSE aproksymacji pomiarów odległości w kalibracji jednosekcyjnej - Sick microScan3.	54
4.19	Wartości RMSE aproksymacji reszt w kalibracji jednosekcyjnej - Sick microScan3.	55
4.20	Suma wartości RMSE aproksymacji pomiarów odległości oraz reszt w kalibracji jednosekcyjnej - TF Mini	55
4.21	Reszty podzielone na odcinki, na podstawie lokalnych minimów i maksimów - TF Mini	57

4.22	Wynik kalibracji adaptacyjnej. Wykryte odcinki wraz z wartościami RMSE dopasowania - TF Mini	57
4.23	Reszty podzielone na odcinki, na podstawie lokalnych minimów i maksimów - Sick microScan3.	59
4.24	Wynik kalibracji adaptacyjnej. Wykryte odcinki wraz z wartościami RMSE dopasowania - Sick microScan3	62
4.25	Błędy pomiarowe oraz odchylenia standardowe czujnika Leuze RSL425 XL, przed ((a) i (b)) i po ((c) i (d)) filtracji medianowej z oknem o szerokości 9.	62
4.26	Reszty podzielone na odcinki, na podstawie lokalnych minimów i maksimów - Leuze RSL425 XL.	63
4.27	Aproksymacja wielomianowa 4-go stopnia, 13-go odcinka w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL.	64
4.28	Wartości RMSE aproksymacji pomiarów odległości w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL.	64
4.29	Wartości RMSE aproksymacji reszt w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL.	65
4.30	Suma wartości RMSE aproksymacji pomiarów odległości oraz reszt w kalibracji adaptacyjnej z filtracją - Leuze RSL425 XL	65
4.31	Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 9. Wykryte odcinki wraz z wartościami RMSE dopasowania - Leuze RSL425 XL	66
4.32	Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 11. Wykryte odcinki wraz z wartościami RMSE dopasowania - Sick microScan3	67
4.33	Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 9. Wykryte odcinki wraz z wartościami RMSE dopasowania - RPLidar A1	68
4.34	Wynik kalibracji adaptacyjnej z filtracją o szerokości okna równej 13. Wykryte odcinki wraz z wartościami RMSE dopasowania - RPLidar A2	69
4.35	Schemat kalibracji naturalnej wykorzystującej wytrenowany model ML w celu określenia skalibrowanego pomiaru odległości.	71
4.36	Schemat kalibracji resztowej wykorzystującej wytrenowany model ML w celu określenia wartości korekty dla pomiaru odległości.	72
4.37	Wyniki wpływu maksymalnej głębokości modeli ML, na wartości RMSE (a) i (b), oraz wartości STDEV (c).	76
5.1	Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji średnią ruchomą (AF) z szerokością okna równą 3.	81
5.2	Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji średnią ruchomą (AF) z różnymi szerokościami okna.	82
5.3	Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji medianowej (MF) z szerokością okna równą 3.	83
5.4	Wyniki pomiarów LiDAR-ów 2D po zastosowaniu filtracji medianowej (MF) z różnymi szerokościami okna.	84
6.1	Uproszczony schemat wyznaczania kąta odchylenia systemu AGV od powierzchni względem której wykonywana jest metoda 2DLAT.	88
6.2	Schemat wyznaczania kąta odchylenia systemu AGV od powierzchni względem której wykonywana jest metoda 2DLAT.	89

7.1	Przykład skanu z LiDAR-u 2D z informacją o sile odbitych wiązek laserowych.	98
7.2	Przykład znacznika przestrzennego z kodami refleksyjnymi (a) oraz skanu laserowego uzyskanego przez LiDAR 2D (b). Każdy z segmentów składa się z podsegmentów refleksyjnych i nierefleksyjnych.	99
7.3	Przykład znaczników przestrzennych z kodami refleksyjnymi zamontowanych na nogach stanowiska montażowego.	99
7.4	Diagram procesu detekcji i identyfikacji znacznika 2DM-RC.	100
7.5	Stanowisko testowe dla pojedynczej nogi AS (lewej) wyposażonej w znacznik 2DM-RC.	103
7.6	Skan laserowy znacznika 2DM-RC uzyskany przez przemysłowy LiDAR 2D Sick microscan3.	103
7.7	Wizualizacja metody obliczania pozycji punktu dokowania dla AS wyposażonej w znaczniki 2DM-RC zamontowane na nogach.	104
7.8	Widok wykrytego znacznika 2DM-RC zamontowanego na prawej nodze AS.	105
7.9	Widok dwóch znaczników 2DM-RC zamontowanych na nogach AS oraz obliczonego punktu dokowania z perspektywy przedniego i tylnego czujnika LiDAR 2D zamontowanego na AGV.	106
8.1	Diagram warstw oprogramowania w kontekście oprogramowania zależnego i niezależnego od sprzętu wraz z elementami stosu systemowego.	107
8.2	Model komunikacji wydawca – subskrybent w ROS.	109
8.3	Mapa węzłów w sieci ROS	110
8.4	Przepływ danych z PLC i LiDAR’ów do SBC.	113
8.5	Przepływ danych z komendą prędkości z SBC do PLC.	113
9.1	Procedura dokowania AGV do AS wyposażonego w 2DM-RC zamontowane na nogach – faza dokowania.	121
9.2	Procedura dokowania AGV do AS wyposażonego w 2DM-RC zamontowane na nogach – faza weryfikacji.	121
9.3	Stanowisko testowe do eksperymentów z dokowaniem platformy AGV Formica 3 do znaczników 2DM-RC zamontowanych na lewej i prawej nodze AS.	126

Spis tablic

3.1	Podsumowanie właściwości pomiarowych laserowych czujników odległości.	24
3.2	Podsumowanie właściwości pomiarowych ultradźwiękowych czujników odległości.	26
3.3	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika TF Mini.	28
3.4	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika TF Mini-S.	29
3.5	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika HC-SR04.	30
3.6	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika URM37v5.	31
3.7	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RPLidar A1.	32
3.8	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RPLidar A2.	33
3.9	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika RSL425 XL.	35
3.10	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujnika microScan3.	36
3.11	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujników 1D.	37
3.12	Wybrane miary statystyczne dotyczące charakterystyki pomiarowej czujników 2D.	38
4.1	Wynik kalibracji jednosekcyjnej - para funkcji wielomianowych wraz z parametrami dla czujnika TF Mini.	50
4.2	Porównanie błędów RMSE przed i po kalibracji jednosekcyjnej dla wszystkich badanych czujników odległości typu 1D.	50
4.3	Wynik kalibracji jednosekcyjnej - para funkcji wielomianowych wraz z parametrami dla czujnika Sick microScan3.	56
4.4	Porównanie błędów RMSE przed i po kalibracji jednosekcyjnej dla wszystkich badanych czujników odległości typu 2D.	56
4.5	Wynik kalibracji adaptacyjnej - zestaw funkcji wielomianowych wraz z parametrami dla czujnika TF Mini.	58
4.6	Porównanie błędów RMSE przed i po kalibracji jednosekcyjnej oraz adaptacyjnej dla wszystkich badanych czujników odległości typu 1D.	58
4.7	Wynik kalibracji adaptacyjnej - zestaw funkcji wielomianowych wraz z parametrami dla czujnika Sick.	59

4.8	Porównanie błędów RMSE przed i po kalibracji jednoosekowej oraz adaptacyjnej dla wszystkich badanych czujników odległości typu 2D.	61
4.9	Wynik kalibracji adaptacyjnej z filtracją medianową 13-tego odcinka reszt czujnika RSL425 XL - zestaw funkcji wielomianowych wraz z parametrami.	65
4.10	Liczba wykrytych odcinków oraz zakres wartości RMSE przy optymalnej szerokości okna dla każdego z czujników 2D.	67
4.11	Wynik kalibracji adaptacyjnej z filtracją czujników 2D.	70
4.12	Zestaw analizowanych algorytmów regresji	71
4.13	Scenariusz dopasowania - kalibracja naturalna.	74
4.14	Scenariusz dopasowania - kalibracja resztowa.	74
4.15	Scenariusz realistyczny - kalibracja naturalna.	75
4.16	Scenariusz realistyczny - kalibracja resztowa.	75
5.1	Wyniki filtracji metodą medianową oraz średnią ruchomą.	80
6.1	Błąd liniowy odometrii AGV w ruchu liniowym - Formica 1.	90
6.2	Odległość hamowania AGV w ruchu liniowym - Formica 1.	91
6.3	Błąd kątowy odometrii AGV w ruchu liniowym - Formica 1.	91
6.4	Różnice w orientacji AGV podczas hamowania w ruchu liniowym - Formica 1.	92
6.5	Błąd kątowy odometrii AGV w ruchu kątowym - Formica 1.	93
6.6	Kąt hamowania w ruchu kątowym - Formica 1.	93
6.7	Odległość pomiędzy pozycją początkową AGV a pozycją końcową w ruchu kątowym - Formica 1.	94
7.1	Weryfikacja precyzji pozycjonowania nóg AS z zamontowanymi znacznikami 2DM-RC.	106
8.1	Główna ramka protokołu w komunikacji z PLC.	113
8.2	Struktura ramki przechowującej dane odometryczne AGV.	114
8.3	Struktura ramki przechowującej dane z inklinometru AGV.	114
8.4	Struktura ramki przechowującej komendę jazdy z systemu ROS dla PLC.	115
8.5	Struktura ramki przechowującej konfigurację zadanego trybu operacyjnego PLC.	116
8.6	Struktura ramki przechowującej konfigurację wykluczeń sygnałów PLC.	117
9.1	Warianty dokowania AGV do AS.	127
9.2	Wyniki dokładności i precyzji dokowania AGV do zmierzonego i obliczonego punktu dokowania względem znaczników 2DM-RC zamontowanych na lewej i prawej nodze AS.	127
9.3	Maksymalne odchylenia od oczekiwanych pozycji punktów dokowania po procesie dokowania.	129
C.1	Scenariusz dopasowania - kalibracja naturalna.	159
C.2	Scenariusz dopasowania - kalibracja resztowa.	160
C.3	Scenariusz realistyczny - kalibracja naturalna.	161
C.4	Scenariusz realistyczny - kalibracja resztowa.	162

Spis listingów

4.1	Wczytywanie danych i tworzenie struktur zbioru danych.	43
4.2	Format danych w pliku CSV.	43
4.3	Deklaracja funkcji i przykład użycia metody kalibracji dla pojedyn- czego odcinka.	43
4.4	Deklaracja funkcji i przykład użycia metody adaptacyjnej kalibracji. .	43
7.1	Przykładowa wiadomość o wykrytej nodze AS (pozycja i orientacja) przesłana w temacie ROS o nazwie /assembly_station_legs.	103
9.1	Przykładowe dane wejściowe dla pozycji docelowego punktu dokowa- nia dla algorytmu obliczającego korektę.	122
9.2	Przykładowe dane wejściowe pozycji AGV Formica 3 dla algorytmu obliczającego korektę.	122
9.3	Przykładowe dane wyjściowe z algorytmu do obliczania wartości ko- rekty podczas fazy weryfikacji (korekta odpowiednio w pozycjach X i Y, najkrótszy kąt orientacji YAW oraz orientacja w formacie kwater- nionowym).	122

Dodatek A

Symbole i skróty przyjęte w pracy

Jeśli w tekście nie wykazano inaczej, stosowane symbole i skróty należy rozumieć jako:

2D - two dimensional - dwuwymiarowy

2DLAT - 2D LiDAR Alignment Test - test rozbieżności kątowej

2DM-RC - 2D marker with reflective codes - znacznik przestrzenny z kodami refleksyjnymi

ACM - Adaptive Calibration Method - metoda kalibracji adaptacyjnej

AGV - Automated Guided Vehicle - zautomatyzowana platforma mobilna

AMR - Autonomous Mobile Robots - autonomiczne roboty mobilne

API - Application Programming Interface - interfejs programistyczny aplikacji

AS - Assembly Station - stanowisko montażowe

CoBotAGV - Collaborative Robot with Automated Guided Vehicle - robot kolaboracyjny z zautomatyzowaną platformą mobilną

FOV - Field of View - pole widzenia

HIMR - Hybrid Inertial Microwave Reflectometry - hybrydowy system lokalizacji i śledzenia oparty o RFID

I2C - Inter-Integrated Circuit - szeregową, dwukierunkową magistralę przesyłania danych

ICP - Iterative Closest Point - iteracyjny algorytm minimalizowania różnic pomiędzy dwoma chmurami punktów

IEPF - Iterative End Point Fit - iteracyjny algorytm wyznaczania segmentów

IMU - Inertial Measurement Unit - czujnik inercji

IPC - Industrial PC - komputer przemysłowy

ISO - International Organization for Standardization - Międzynarodowa Organizacja Normalizacyjna

LiDAR - Light Detection and Ranging - czujnik mierzący siłę odbitego światła i odległość

MAF - Moving Average Filter - filtr średniej ruchomej

MF - Median Filter - filtr medianowy

MiR - Mobile Industrial Robots - firma produkująca platformy mobilne MiR

ML - Machine Learning - uczenie maszynowe

MSCwMF - Multi Section Calibration with Median Filtration - metoda kalibracji adaptacyjnej z filtrem medianowym

NC - Naive Calibration - kalibracja naturalna

NFC - Near Field Communication - komunikacja bliskiego zasięgu

PCL - Point Cloud - chmura punktów

PLC - Programmable Logic Controller - programowalny sterownik logiczny

RC - Residual Calibration - kalibracja resztowa

RFID - Radio Frequency Identification - identyfikacja radiowa

RMSE - Root Mean Square Error - pierwiastek średniego błędu kwadratowego

SBC - Single Board Computer - komputer jednopłytkowy

SLAM - Simultaneous Localization and Mapping - algorytm jednoczesnej lokalizacji i mapowania

STDEV - Standard Deviation - odchylenie standardowe

TCP - Transmission Control Protocol - protokół sterowania transmisją

ToF - Time of Flight - czas przelotu

UART - Universal Asynchronous Receiver-Transmitter - uniwersalny układ nadający i odbierający asynchronicznie

UDP - User Datagram Protocol - protokół pakietów użytkownika

UHF - Ultra-High Frequency - ultra wysoka częstotliwość

XML - Extensible Markup Language - uniwersalny format reprezentacji danych w ustrukturyzowany sposób

YAW - kąt Eulera, obrót wokół osi pionowej obiektu

Dodatek B

Spis publikacji i patentów

Publikacje (przy każdej pozycji podano punktację MNiSW wg aktualnego wykazu):

1. Dariusz Marek, Piotr Biernacki, Jakub Szyguła, Adam Domański, Marcin Paszkuta, Marta Szczygieł, Marcel Król i Konrad Wojciechowski. „Collision Avoidance Mechanism for Swarms of Drones”. W: *Sensors* 25.4 (lut. 2025), s. 1141. ISSN: 1424-8220. DOI: [10.3390/s25041141](https://doi.org/10.3390/s25041141). URL: <http://dx.doi.org/10.3390/s25041141> (100 pkt.)
2. Adam Ziębiński i Piotr Biernacki. „How Accurate Can 2D LiDAR Be? A Comparison of the Characteristics of Calibrated 2D LiDAR Systems”. W: *Sensors* 25.4 (lut. 2025), s. 1211. ISSN: 1424-8220. DOI: [10.3390/s25041211](https://doi.org/10.3390/s25041211). URL: <http://dx.doi.org/10.3390/s25041211> (100 pkt.)
3. Dariusz Marek, Marcin Paszkuta, Jakub Szyguła, Piotr Biernacki, Adam Domański, Marta Szczygieł, Marcel Król i Konrad Wojciechowski. „Swarm of Drones in a Simulation Environment—Efficiency and Adaptation”. W: *Applied Sciences* 14.9 (kw. 2024), s. 3703. ISSN: 2076-3417. DOI: [10.3390/app14093703](https://doi.org/10.3390/app14093703). URL: <http://dx.doi.org/10.3390/app14093703> (100 pkt.)
4. Jia-Hao Syu, Jerry Chun-Wei Lin, Piotr Biernacki i Adam Ziębiński. „Machine Learning-Based Calibration Approaches for Single-Beam and Multiple-Beam Distance Sensors”. W: *IEEE Sensors Journal* 24.1 (sty. 2024), s. 975–983. ISSN: 1530-437X. DOI: [10.1109/jsen.2023.3328650](https://doi.org/10.1109/jsen.2023.3328650). URL: <http://dx.doi.org/10.1109/JSEN.2023.3328650> (100 pkt.)
5. Piotr Biernacki, Adam Ziębiński, Jia-Hao Syu i Jerry Chun-Wei Lin. „The Calibration of Single Beam Distance Sensors based on Machine Learning Methods”. W: *2023 IEEE International Conference on Big Data (BigData)*. IEEE, grud. 2023, s. 5031–5037. DOI: [10.1109/bigdata59044.2023.10386524](https://doi.org/10.1109/bigdata59044.2023.10386524). URL: <http://dx.doi.org/10.1109/BigData59044.2023.10386524> (70 pkt.)
6. Dariusz Marek, Marcin Paszkuta, Jakub Szyguła, Piotr Biernacki, Adam Domański, Marta Szczygieł, Marcel Król i Konrad Wojciechowski. „General Concepts in Swarm of Drones Control: Analysis and Implementation”. W: *2023 IEEE International Conference on Big Data (BigData)*. IEEE, grud. 2023, s. 5070–5077. DOI: [10.1109/bigdata59044.2023.10386672](https://doi.org/10.1109/bigdata59044.2023.10386672). URL: <http://dx.doi.org/10.1109/BigData59044.2023.10386672> (70 pkt.)

7. Dariusz Marek, Piotr Biernacki, Jakub Szyguła i Adam Domański. „General Concepts of a Simulation Method for Automated Guided Vehicle in Industry 4.0”. W: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, grud. 2022, s. 6306–6314. DOI: [10.1109/bigdata55660.2022.10020846](https://doi.org/10.1109/bigdata55660.2022.10020846). URL: <http://dx.doi.org/10.1109/BigData55660.2022.10020846> (70 pkt.)
8. Olena Pavliuk, Tomasz Steclik i Piotr Biernacki. „The forecast of the AGV battery discharging via the machine learning methods”. W: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, grud. 2022, s. 6315–6324. DOI: [10.1109/bigdata55660.2022.10020968](https://doi.org/10.1109/bigdata55660.2022.10020968). URL: <http://dx.doi.org/10.1109/BigData55660.2022.10020968> (70 pkt.)
9. Jakub Szyguła, Piotr Biernacki, Dariusz Marek, Adam Domański, Łukasz Sobczak, Jarosław Flak, Dariusz Caban i Piotr Pawlas. „Analysis of web-based geo-visualization methods applied for Automated Guided Vehicle using Satellite Navigation Systems”. W: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, grud. 2022, s. 6371–6377. DOI: [10.1109/bigdata55660.2022.10020593](https://doi.org/10.1109/bigdata55660.2022.10020593). URL: <http://dx.doi.org/10.1109/BigData55660.2022.10020593> (70 pkt.)
10. Piotr Biernacki, Adam Ziębiński i Damian Grzechca. „The Adaptive Calibration Method for Single-Beam Distance Sensors”. W: *Computational Collective Intelligence*. Springer International Publishing, 2021, s. 721–732. ISBN: 9783030880811. DOI: [10.1007/978-3-030-88081-1_54](https://doi.org/10.1007/978-3-030-88081-1_54). URL: http://dx.doi.org/10.1007/978-3-030-88081-1_54 (70 pkt.)
11. Adam Ziębiński, Dariusz Mrozek, Rafał Cupek, Damian Grzechca, Marcin Fojcik, Marek Drewniak, Erik Kyrkjebø, Jerry Chun-Wei Lin, Knut Øvsthus i Piotr Biernacki. „Challenges Associated with Sensors and Data Fusion for AGV-Driven Smart Manufacturing”. W: *Computational Science – ICCS 2021*. Springer International Publishing, 2021, s. 595–608. ISBN: 9783030779702. DOI: [10.1007/978-3-030-77970-2_45](https://doi.org/10.1007/978-3-030-77970-2_45). URL: http://dx.doi.org/10.1007/978-3-030-77970-2_45 (140 pkt.)
12. Damian Grzechca, Adam Ziębiński, Witold Ilewicz, Piotr Biernacki, Weronika Gorning, Cezary Małek, Kordian Okularczyk, J. Urbanek, and W. Mazur., “Opracowanie i implementacja algorytmów do automatycznego parkowania oraz przywoływania modelu pojazdu z wykorzystaniem technologii UW”, PM News, Art. no. 23, 2020. URL: <https://delibra.bg.polsl.pl/dlibra/publication/76029/edition/66308/content>

Patenty:

1. Witold Ilewicz, Damian Grzechca, Adam Ziębiński, Piotr Biernacki, Weronika Gorning, Kordian Okularczyk, Wojciech Mazur, Jarosław Urbanek, Cezary Małek, “Sposób kalibracji układu sterowania osią skretną autonomicznego pojazdu kołowego”, nr 241075, 2022.

Dodatek C

Wyniki kalibracji pomiarów odległości przy użyciu ML

Tabela C.1: Scenariusz dopasowania - kalibracja naturalna.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
ExtraTree	0.00095	5.70E-16	7.15E-16	4.96E-16	0.00024	0.00024	9.28E-17	6.75E-17	7.24E-17	0.00006
DecisionTree	0.00095	5.75E-16	6.93E-16	5.22E-16	0.00024	0.00024	3.57E-17	4.60E-17	7.42E-17	0.00006
ExtraTrees	0.00095	1.76E-15	1.93E-15	1.93E-15	0.00024	0.00024	4.25E-18	5.04E-18	1.23E-17	0.00006
RandomForest	0.00106	1.74E-15	1.93E-15	1.87E-15	0.00027	0.00038	1.29E-17	0	0	0.00010
GB	0.00106	0.00003	0.00002	0.00002	0.00028	0.00025	0	0	0	0.00006
Bagging	0.00113	2.16E-16	2.99E-16	2.98E-16	0.00028	0.00038	1.71E-17	1.49E-17	1.94E-17	0.00010
XGB	0.00099	0.00008	0.00009	0.00010	0.00032	0.00024	0	0	0	0.00006
KNeighbors	0.00158	4.11E-17	5.10E-17	5.36E-17	0.00040	0.00073	0	0	0	0.00018
GaussianProcess	0.00655	0.00294	0.00259	0.00149	0.00340	0.00647	0.00251	0.00221	0.00125	0.00311
NuSVR	0.00663	0.00308	0.00277	0.00163	0.00353	0.00646	0.00249	0.00220	0.00124	0.00310
Lars	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
LassoLarsIC	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
LassoLarsCV	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
LarsCV	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
OMP	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
Linear	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
RANSAC	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
TransformedTarget	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
BayesianRidge	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
ARD	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
RidgeCV	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
SGD	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
Huber	0.00674	0.00409	0.00397	0.00247	0.00432	0.00652	0.00250	0.00221	0.00124	0.00312
Ridge	0.00675	0.00407	0.00398	0.00249	0.00432	0.00652	0.00250	0.00220	0.00124	0.00312
LassoCV	0.00677	0.00410	0.00401	0.00253	0.00435	0.00652	0.00250	0.00220	0.00124	0.00312
ElasticNetCV	0.00682	0.00419	0.00409	0.00264	0.00443	0.00651	0.00250	0.00220	0.00124	0.00311
TheilSen	0.00677	0.00442	0.00404	0.00257	0.00445	0.00652	0.00250	0.00220	0.00124	0.00312
LinearSVR	0.00696	0.00426	0.00422	0.00278	0.00456	0.00652	0.00250	0.00220	0.00125	0.00312
LGBM	0.00746	0.00746	0.00585	0.00257	0.00583	0.00690	0.00674	0.00480	0.00114	0.00489
HistGB	0.00764	0.00871	0.00720	0.00002	0.00589	0.00693	0.00824	0.00594	0.00000	0.00528
MLP	0.02545	0.02525	0.02576	0.02548	0.02548	0.00651	0.00251	0.00230	0.00130	0.00316
PassiveAggressive	0.04696	0.06639	0.05236	0.05024	0.05399	0.00699	0.00251	0.00230	0.00131	0.00328
SVR	0.05180	0.05333	0.05630	0.05647	0.05448	0.00569	0.00217	0.00208	0.00115	0.00277
AdaBoost	0.07871	0.07849	0.07736	0.07047	0.07626	0.00280	0.00000	0.00000	0.00000	0.00070
RadiusNeighbors	0.13904	0.13643	0.13746	0.12425	0.13430	0.00899	0.00032	0.00000	0.00071	0.00250
Tweedie	0.32295	0.31705	0.31025	0.29576	0.31150	0.00326	0.00125	0.00110	0.00062	0.00156
ElasticNet	0.54863	0.54470	0.54017	0.53051	0.54100	0.00098	0.00035	0.00029	0.00013	0.00044
Lasso	0.64580	0.63406	0.62047	0.59151	0.62296	0.00000	0.00000	0.00000	0.00000	0.00000
Dummy	0.64580	0.63406	0.62047	0.59151	0.62296	0.00000	0.00000	0.00000	0.00000	0.00000
LassoLars	0.64580	0.63406	0.62047	0.59151	0.62296	0.00000	0.00000	0.00000	0.00000	0.00000
KernelRidge	1.15677	1.17534	1.20049	1.15044	1.17076	0.00652	0.00250	0.00220	0.00124	0.00312

Tabela C.2: Scenariusz dopasowania - kalibracja resztowa.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
ExtraTree	0.00095	0	4.81E-19	0	0.00024	0.00024	0	0	0	0.00006
DecisionTree	0.00095	0	4.81E-19	0	0.00024	0.00024	0	0	0	0.00006
ExtraTrees	0.00095	8.14E-18	1.02E-17	3.07E-18	0.00024	0.00024	2.41E-18	6.93E-19	0	0.00006
RandomForest	0.00114	0.00016	0.00016	0.00005	0.00038	0.00070	0.00015	0.00013	0.00003	0.00025
Bagging	0.00123	0.00020	0.00018	0.00006	0.00042	0.00078	0.00017	0.00015	0.00003	0.00028
KNeighbors	0.00199	0.00048	0.00047	0.00017	0.00078	0.00165	0.00045	0.00039	0.00011	0.00065
XGB	0.00173	0.00111	0.00091	0.00060	0.00109	0.00158	0.00104	0.00085	0.00055	0.00100
LGBM	0.00474	0.00177	0.00149	0.00057	0.00215	0.00466	0.00174	0.00135	0.00052	0.00207
HistGB	0.00471	0.00198	0.00166	0.00051	0.00221	0.00462	0.00192	0.00144	0.00047	0.00212
GB	0.00509	0.00197	0.00160	0.00091	0.00239	0.00500	0.00184	0.00147	0.00083	0.00228
GaussianProcess	0.00655	0.00294	0.00259	0.00149	0.00340	0.00647	0.00251	0.00221	0.00125	0.00311
AdaBoost	0.00651	0.00293	0.00264	0.00151	0.00340	0.00641	0.00244	0.00206	0.00115	0.00302
NuSVR	0.00658	0.00301	0.00271	0.00165	0.00349	0.00650	0.00251	0.00220	0.00125	0.00311
RadiusNeighbors	0.00678	0.00401	0.00390	0.00229	0.00425	0.00657	0.00250	0.00222	0.00125	0.00313
Linear	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
OMP	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
Lars	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
TransformedTarget	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
Ridge	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
RidgeCV	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
BayesianRidge	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
LassoLarsIC	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
LassoLarsCV	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
LarsCV	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
SGD	0.00674	0.00406	0.00396	0.00246	0.00430	0.00652	0.00250	0.00221	0.00124	0.00312
Huber	0.00674	0.00409	0.00397	0.00247	0.00432	0.00652	0.00250	0.00221	0.00124	0.00312
LassoCV	0.00674	0.00406	0.00405	0.00246	0.00433	0.00652	0.00250	0.00221	0.00124	0.00312
ElasticNetCV	0.00674	0.00406	0.00405	0.00246	0.00433	0.00652	0.00250	0.00221	0.00124	0.00312
TheilSen	0.00677	0.00440	0.00410	0.00262	0.00447	0.00652	0.00250	0.00220	0.00124	0.00312
LinearSVR	0.00711	0.00422	0.00423	0.00270	0.00456	0.00652	0.00250	0.00221	0.00124	0.00312
Tweedie	0.00739	0.00425	0.00418	0.00246	0.00457	0.00649	0.00250	0.00221	0.00124	0.00311
RANSAC	0.00719	0.00456	0.00446	0.00260	0.00470	0.00655	0.00250	0.00220	0.00125	0.00312
ARD	0.00906	0.00479	0.00477	0.00246	0.00527	0.00646	0.00249	0.00222	0.00124	0.00310
Lasso	0.00906	0.00479	0.00477	0.00246	0.00527	0.00646	0.00249	0.00222	0.00124	0.00310
ElasticNet	0.00906	0.00479	0.00477	0.00246	0.00527	0.00646	0.00249	0.00222	0.00124	0.00310
Dummy	0.00906	0.00479	0.00477	0.00246	0.00527	0.00646	0.00249	0.00222	0.00124	0.00310
LassoLars	0.00906	0.00479	0.00477	0.00246	0.00527	0.00646	0.00249	0.00222	0.00124	0.00310
SVR	0.00920	0.00534	0.00477	0.00253	0.00546	0.00646	0.00249	0.00222	0.00124	0.00310
MLP	0.00904	0.00612	0.00634	0.00574	0.00681	0.00659	0.00254	0.00224	0.00126	0.00316
KernelRidge	0.02115	0.01214	0.00743	0.00639	0.01178	0.00652	0.00250	0.00221	0.00124	0.00312
PassiveAggressive	0.02200	0.01240	0.00789	0.00639	0.01217	0.00646	0.00249	0.00222	0.00124	0.00310

Tabela C.3: Scenariusz realistyczny - kalibracja naturalna.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
GB	0.00138	0.00003	0.00002	0.00002	0.00036	0.00030	0	0	0	0.00008
DecisionTree	0.00176	4.51E-16	4.74E-16	4.36E-16	0.00044	0.00043	1.53E-17	2.23E-17	4.64E-17	0.00011
RandomForest	0.00176	1.74E-15	1.91E-15	1.89E-15	0.00044	0.00058	8.82E-18	0	2.71E-18	0.00014
Bagging	0.00183	2.19E-16	2.39E-16	2.43E-16	0.00046	0.00053	2.39E-17	2.47E-17	5.11E-18	0.00013
XGB	0.00151	0.00012	0.00011	0.00011	0.00046	0.00034	0	0	0	0.00009
KNeighbors	0.00190	4.11E-17	5.10E-17	5.36E-17	0.00047	0.00057	0	0	0	0.00014
ExtraTrees	0.00284	0.00040	0.00048	0.00026	0.00099	0.00147	0.00018	0.00024	0.00009	0.00049
ExtraTree	0.00433	0.00000	0.00000	0.00000	0.00108	0.00134	5.98E-17	5.80E-17	5.72E-17	0.00033
GaussianProcess	0.00682	0.00305	0.00276	0.00155	0.00354	0.00641	0.00231	0.00232	0.00124	0.00307
NuSVR	0.00689	0.00315	0.00290	0.00174	0.00367	0.00641	0.00229	0.00231	0.00124	0.00306
RidgeCV	0.00688	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
SGD	0.00689	0.00399	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
ARD	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
BayesianRidge	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
OMP	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
Lars	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
LarsCV	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
LassoLarsCV	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
LassoLarsIC	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
RANSAC	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
TransformedTarget	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
Linear	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
Ridge	0.00682	0.00405	0.00405	0.00248	0.00435	0.00646	0.00230	0.00231	0.00124	0.00308
LassoCV	0.00681	0.00408	0.00407	0.00250	0.00436	0.00646	0.00230	0.00231	0.00124	0.00308
Huber	0.00689	0.00408	0.00404	0.00244	0.00436	0.00646	0.00230	0.00231	0.00124	0.00308
ElasticNetCV	0.00679	0.00418	0.00414	0.00259	0.00443	0.00645	0.00230	0.00231	0.00124	0.00308
LinearSVR	0.00693	0.00397	0.00432	0.00274	0.00449	0.00646	0.00231	0.00232	0.00124	0.00308
TheilSen	0.00680	0.00451	0.00414	0.00255	0.00450	0.00645	0.00230	0.00231	0.00124	0.00308
LGBM	0.00779	0.00666	0.00570	0.00407	0.00605	0.00577	0.00461	0.00324	0.00100	0.00365
HistGB	0.00885	0.00933	0.00952	0.00002	0.00693	0.00674	0.00679	0.00686	0.00000	0.00510
MLP	0.02898	0.02779	0.02830	0.02857	0.02841	0.00647	0.00234	0.00243	0.00132	0.00314
PassiveAggressive	0.02329	0.06693	0.08272	0.03614	0.05227	0.00625	0.00229	0.00233	0.00121	0.00302
SVR	0.05155	0.05295	0.05662	0.05536	0.05412	0.00564	0.00198	0.00218	0.00116	0.00274
AdaBoost	0.07900	0.07863	0.07753	0.07324	0.07710	0.00000	0.00000	0.00000	0.00000	0.00000
RadiusNeighbors	0.13848	0.13639	0.13746	0.12424	0.13414	0.00889	0.00014	0.00000	0.00066	0.00242
Tweedie	0.32237	0.31716	0.31024	0.29573	0.31137	0.00323	0.00115	0.00116	0.00062	0.00154
ElasticNet	0.54845	0.54473	0.54016	0.53050	0.54096	0.00097	0.00033	0.00030	0.00013	0.00043
Lasso	0.64580	0.63406	0.62047	0.59151	0.62296	0.00000	0.00000	0.00000	0.00000	0.00000
Dummy	0.64580	0.63406	0.62047	0.59151	0.62296	0.00000	0.00000	0.00000	0.00000	0.00000
LassoLars	0.64580	0.63406	0.62047	0.59151	0.62296	0.00000	0.00000	0.00000	0.00000	0.00000
KernelRidge	1.15693	1.17572	1.20054	1.15049	1.17092	0.00646	0.00230	0.00231	0.00124	0.00308

Tabela C.4: Scenariusz realistyczny - kalibracja resztowa.

Metoda	RMSE					STDEV				
	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia	RSL425 XL	microScan3	RPL A1	RPL A2	Średnia
Surowe	0.02200	0.01240	0.00789	0.00639	0.01217	0.00638	0.00246	0.00219	0.00123	0.00307
ACM	0.00652	0.00254	0.00244	0.00133	0.00321	0.00645	0.00249	0.00218	0.00123	0.00309
MSCwMF	0.00342	0.00134	0.00130	0.00081	0.00172	0.00329	0.00129	0.00114	0.00069	0.00160
DecisionTree	0.00213	0.00041	0.00048	0.00027	0.00082	0.00135	0.00023	0.00030	0.00010	0.00049
RandomForest	0.00223	0.00047	0.00055	0.00028	0.00089	0.00145	0.00034	0.00037	0.00012	0.00057
Bagging	0.00228	0.00048	0.00054	0.00028	0.00090	0.00143	0.00034	0.00037	0.00013	0.00057
ExtraTrees	0.00273	0.00043	0.00045	0.00028	0.00097	0.00145	0.00021	0.00024	0.00009	0.00050
KNeighbors	0.00281	0.00069	0.00096	0.00039	0.00121	0.00206	0.00058	0.00065	0.00022	0.00088
XGB	0.00265	0.00110	0.00117	0.00076	0.00142	0.00212	0.00089	0.00102	0.00065	0.00117
ExtraTree	0.00481	0.00042	0.00089	0.00027	0.00160	0.00253	0.00024	0.00043	0.00010	0.00082
LGBM	0.00535	0.00197	0.00186	0.00078	0.00249	0.00481	0.00167	0.00149	0.00062	0.00215
GB	0.00551	0.00206	0.00185	0.00098	0.00260	0.00506	0.00168	0.00157	0.00083	0.00229
HistGB	0.00551	0.00222	0.00209	0.00072	0.00264	0.00502	0.00183	0.00167	0.00058	0.00227
AdaBoost	0.00681	0.00304	0.00278	0.00153	0.00354	0.00636	0.00224	0.00221	0.00115	0.00299
GaussianProcess	0.00682	0.00305	0.00276	0.00155	0.00354	0.00641	0.00231	0.00232	0.00124	0.00307
NuSVR	0.00684	0.00309	0.00281	0.00169	0.00361	0.00644	0.00231	0.00231	0.00124	0.00308
RadiusNeighbors	0.00679	0.00403	0.00397	0.00226	0.00426	0.00651	0.00230	0.00232	0.00125	0.00310
Ridge	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
RidgeCV	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
BayesianRidge	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
OMP	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
Lars	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
TransformedTarget	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
Linear	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
LarsCV	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
LassoLarsCV	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
LassoLarsIC	0.00689	0.00400	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
SGD	0.00690	0.00399	0.00403	0.00244	0.00434	0.00646	0.00231	0.00231	0.00124	0.00308
Huber	0.00689	0.00408	0.00404	0.00244	0.00436	0.00646	0.00230	0.00231	0.00124	0.00308
LassoCV	0.00686	0.00428	0.00413	0.00244	0.00443	0.00646	0.00230	0.00232	0.00124	0.00308
ElasticNetCV	0.00686	0.00428	0.00413	0.00244	0.00443	0.00646	0.00230	0.00232	0.00124	0.00308
Tweedie	0.00708	0.00425	0.00425	0.00244	0.00451	0.00643	0.00230	0.00232	0.00124	0.00307
LinearSVR	0.00718	0.00398	0.00425	0.00268	0.00452	0.00647	0.00231	0.00232	0.00124	0.00308
RANSAC	0.00698	0.00436	0.00437	0.00244	0.00454	0.00646	0.00230	0.00231	0.00124	0.00308
TheilSen	0.00680	0.00470	0.00420	0.00253	0.00456	0.00645	0.00230	0.00231	0.00124	0.00308
ARD	0.00855	0.00482	0.00484	0.00244	0.00516	0.00640	0.00230	0.00232	0.00124	0.00307
Lasso	0.00855	0.00482	0.00484	0.00244	0.00516	0.00640	0.00230	0.00232	0.00124	0.00307
ElasticNet	0.00855	0.00482	0.00484	0.00244	0.00516	0.00640	0.00230	0.00232	0.00124	0.00307
Dummy	0.00855	0.00482	0.00484	0.00244	0.00516	0.00640	0.00230	0.00232	0.00124	0.00307
LassoLars	0.00855	0.00482	0.00484	0.00244	0.00516	0.00640	0.00230	0.00232	0.00124	0.00307
SVR	0.00867	0.00524	0.00484	0.00252	0.00532	0.00640	0.00230	0.00232	0.00124	0.00307
MLP	0.00999	0.00737	0.00732	0.00701	0.00792	0.00654	0.00235	0.00236	0.00127	0.00313
KernelRidge	0.02131	0.01238	0.00750	0.00641	0.01190	0.00646	0.00231	0.00231	0.00124	0.00308
PassiveAggressive	0.02190	0.01267	0.00797	0.00641	0.01224	0.00640	0.00230	0.00232	0.00124	0.00307