

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA AUTOMATYKA, ELEKTRONIKA,
ELEKTROTECHNIKA I TECHNOLOGIE KOSMICZNE
DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa doktorska

mgr inż. Rafał Więckowski

**Ocena przejezdności trasy w systemach autonomicznej jazdy lądowych
platform mobilnych pracujących w terenach przygodnych**

Promotor

dr. hab. Barbara Siemiątkowska, prof. Uczelni

WARSZAWA 2025

Streszczenie

Rozwój zastosowań bezzałogowych pojazdów lądowych (BPL) stawia przed badaczami nowe wyzwania związane z autonomią oraz zdolnością do skutecznej nawigacji w skomplikowanych środowiskach terenowych. Niniejsza rozprawa doktorska koncentruje się na opracowaniu i weryfikacji metody oceny przejezdności terenu dla bezzałogowych pojazdów lądowych, bazującej na integracji analizy geometrii terenu i cech materiałowych otoczenia. Praca rozpoczyna się od analizy problemu badawczego i uzasadnienia jego znaczenia w kontekście rosnącej roli systemów autonomicznych na teatrze działań wojennych. W przeglądzie stanu wiedzy przedstawiono kluczowe technologie, takie jak sensory Lidar, kamery hiperspektralne oraz pojęcia takie jak mobilność, przejezdność i zdolność terenowa. Zaprezentowano także istniejące rozwiązania w zakresie systemów SLAM oraz budowania map 3D w środowiskach off-road. W ramach badań własnych opracowano metodę oceny przejezdności terenu, która uwzględnia zarówno geometrię podłoża, jak i jego charakterystykę materiałową. Kluczowym elementem tej metody jest zastosowanie kamer hiperspektralnych do analizy nawierzchni oraz integracja mapy 2,5D w celu otrzymania mapy przejezdności. Przeprowadzono również analizę rozwinięcia metody o możliwość planowania trasy z uwzględnieniem dynamiki autonomicznych bezzałogowych pojazdów lądowych, co umożliwiło optymalizację planowania trasy do zdolności terenowych pojazdu. W części eksperymentalnej przeprowadzono testy terenowe, które obejmowały weryfikację zdolności terenowych bezzałogowych pojazdów lądowych Łukasiewicz-PIAP. Badania zostały przeprowadzone na poligonach testowych z wykorzystaniem pojazdów PIAP ATENA, PIAP HUNTeR oraz PIAP PATROL. Wyniki eksperymentów wykazały, że opracowana metoda poprawia dokładność oceny przejezdności i zwiększa efektywność nawigacji autonomicznych pojazdów w trudnych warunkach terenowych. Wyniki badań zostały wdrożone w projekcie ATENA oraz częściowo w pojeździe PIAP HUNTeR. System ATENA z algorytmem oceny przejezdności terenu został zaprezentowany ekspertom z Ministerstwa Obrony Narodowej podczas ich wizyty w Łukasiewicz-PIAP. Podsumowując, niniejsza praca stanowi wkład w rozwój technologii nawigacji autonomicznych systemów bezzałogowych, proponując nowatorskie podejście do oceny przejezdności, które uwzględnia deterministyczną metodę segmentacji semantycznej opartej o pomiary wykonywane kamerą hiperspektralną.

Słowa kluczowe: BPL, obrazowanie hiperspektralne, ocena przejezdności, planowanie trasy

Abstract

The development of unmanned ground vehicle (UGV) applications presents new challenges for researchers related to autonomy and effective navigation in complex terrain environments. This doctoral dissertation focuses on developing and validating a terrain traversability estimation method for UGVs, based on the integration of terrain geometry analysis and material property evaluation. The study begins with an analysis of the research problem and its significance in the context of the growing role of autonomous systems in military operations. The literature review presents key technologies such as Lidar sensors, hyperspectral cameras, and concepts including mobility, traversability, and terrain capability. Existing solutions in SLAM systems and 3D map generation for off-road environments are also discussed. As part of the research, a terrain traversability estimation method was developed, incorporating both terrain geometry and material characteristics. A key aspect of this method is the use of hyperspectral cameras for surface analysis and the integration of a 2.5D map to generate a traversability map. Additionally, the method was expanded to include trajectory planning that considers the dynamics of unmanned ground vehicles, enabling route optimization based on terrain capability. The experimental phase involved field tests to verify the terrain capabilities of Łukasiewicz-PIAP's UGVs. The tests were conducted at dedicated test sites using the PIAP ATENA, PIAP HUNTeR, and PIAP PATROL vehicles. The results demonstrated that the proposed method enhances the accuracy of traversability estimation and improves the navigation efficiency of autonomous vehicles in challenging terrain conditions. The research findings were implemented in the ATENA project and partially in the PIAP HUNTeR vehicle. The ATENA system, featuring the traversability estimation algorithm, was presented to experts from the Ministry of National Defense of Poland during their visit to Łukasiewicz-PIAP. In summary, this dissertation contributes to the advancement of autonomous navigation technologies for unmanned systems by proposing an innovative approach to traversability estimation, incorporating a deterministic semantic segmentation method based on hyperspectral camera measurements.

Keywords: UGV, hyperspectral imaging, traversability estimation, route planning

Spis treści

Spis treści	5
1. Wstęp.....	11
1.1 Wprowadzenie – systemy bezzałogowe w Polsce	14
1.2 Przewodnik po treści pracy	15
2. Cel pracy, opis wdrożenia i teza.....	17
2.1 Problem badawczy	19
2.1.1 Uzasadnienie wyboru problemu badawczego	19
2.1.2 Proponowane rozwiązanie problemu badawczego	21
2.2 Metodyka badań	21
3. Przegląd stanu wiedzy – stan techniki.....	26
3.1 Sensory do budowy modelu otoczenia	26
3.1.1 LiDAR (Light Detection and Ranging).....	26
3.1.2 Kamery	31
3.2 Kamery hiperspektralne, opis i zastosowania	35
3.2.1 Zastosowania w różnych dziedzinach	36
3.2.2 Budowa kamer hiperspektralnych	37
3.2.3 Różnice i zastosowania	38
3.3 Badania podstawowe w zakresie robotyki mobilnej	38

3.4	Zestawienie badań w zakresie autonomii robotów mobilnych pracujących złożonych i otwartych terenach.....	40
3.4.1	Systemy SLAM i skanowania 3D w terenach otwartych.....	40
3.4.2	Budowanie mapy i nawigacja w terenie złożonym.....	41
3.4.3	Przejezdność.....	42
3.4.4	Różne podejścia do przejezdności terenu.....	43
3.4.5	Mobilność.....	45
3.4.6	Zdolność terenowa	47
3.4.7	Segmentacja semantyczna w terenie off-road	47
3.4.8	Algorytmy sterowania robotami mobilnymi o różnych konfiguracjach napędowych.....	48
3.4.9	Interoperacyjność systemów bezzałogowych	48
3.4.10	Zastosowania wojskowe i inżynieryjne.....	48
3.4.11	Adaptacyjne zachowanie robotów mobilnych	49
3.5	Przegląd zbliżonych rozwiązań	49
3.6	Wnioski ze stanu wiedzy	51
4.	Opis teoretycznych prac własnych	53
4.1	Badania wstępne.....	53
4.1.1	Kontekst projektów autonomii jazdy i rozwój technologii PIAP	54
4.1.2	PIAP ATENA.....	61
4.1.3	PIAP DEZROB	63


4.1.4	PIAP HUNTeR.....	65
4.1.5	Sposób sterowania pojazdami PIAP	67
4.1.6	Ćwiczenia eksperymentalne FEX i potrzeby wojska	70
4.1.7	Podsumowanie badań wstępnych.....	71
4.1.8	Wytyczne do budowy modelu przejezdności dla BPL.....	73
4.1.9	Parametry oceny przejezdności dla pojazdów PIAP	74
4.2	Ocena przejezdności – krótki opis realizacji zagadnienia.....	77
4.3	Metoda oceny przejezdności w oparciu o geometrie terenu	79
4.3.1	Mapa wysokości 2,5D	79
4.3.2	Analiza przejezdności z wykorzystaniem mapy 2,5D.....	83
4.4	Metoda oceny przejezdności z analizą materiałów otoczenia.....	89
4.4.1	Analiza materiałów otoczenia z wykorzystaniem kamery hiperspektralnej ..	90
4.4.2	Integracja danych geometrycznych i semantycznych	97
4.4.3	Mapa przejezdności z uwzględnieniem semantyki	99
4.4.4	Kroki realizacji metody oceny przejezdności, w wyniku której powstaje mapa przejezdności – podsumowanie.....	100
4.5	Planowanie trasy z uwzględnieniem zmiennej dynamiki pojazdu na różnych materiałach podłoża.....	103
4.5.1	Siły działające na pojazd i ich wpływ na planowanie trasy	104
4.5.2	Uwzględnienie parametrów dynamicznych dla planera trajektorii.....	110
4.5.3	Kontroler dynamiki	112

5.	Badania eksperymentalne.....	117
5.1	Opis narzędzi umożliwiających badania	117
5.1.1	Demonstrator technologii PIAP ATENA.....	117
5.1.2	Kamera hiperspektralna Cubert Q285.....	120
5.1.3	Sterownik autonomii PIAP.....	122
5.1.4	Parametry terenowe wybranych pojazdów PIAP	123
5.2	Badanie rozmieszczenia lidarów na pojeździe – dane dla mapy 2,5D.....	129
5.3	Badania mapy 2,5D	139
5.3.1	Dobór parametrów mapy 2,5D.....	142
5.4	Weryfikacja zdolności terenowych	143
5.4.1	Tereny testowe	143
5.4.2	Testy terenowe	154
5.5	Testy terenowe oceny przejezdności opartej o geometrie terenu - eksperyment.	159
5.6	Badania kamery hiperspektralnej na poligonie	162
5.7	Metoda oceny przejezdności z analizą materiałów otoczenia - eksperyment.....	165
5.8	Uwzględnienie cech materiałowych nawierzchni na planowanie trasy z uwzględnieniem dynamiki - eksperyment.....	166
6.	Wdrożenie wyników prac.....	169
6.1	Wdrożenie – projekt ATENA	169
6.2	Wdrożenie wyników badań do pojazdu PIAP HUNTeR	170

6.3	Integracja mapy przejezdności, zdolności terenowej i autonomii w projektach Łukasiewicz-PIAP.....	176
7.	Podsumowanie i perspektywa dalszych badań.....	177
7.1	Wnioski	178
7.2	Wyzwania i kierunki dalszych badań.....	180
7.3	Znaczenie i potencjał rozwoju.....	180
7.4	Istotne nowości pracy	181
7.5	Podsumowanie	182
8.	Bibliografia.....	183
	Spis tabel	194
	Spis ilustracji	195

1. Wstęp

Niniejsza rozprawa doktorska powstaje w okresie, gdy stosowanie skutecznych systemów bezzałogowych w dziedzinie obronności staje się wyznacznikiem przewagi na współczesnym teatrze działań wojennych [1]. Rozwój i dostępność nisko-kosztowych bezzałogowych statków powietrznych (BSP – ang. Unmanned Aerial Vehicles, UAV), będących technologią podwójnego zastosowania, przyczyniły się do wzrostu popularności ich użycia na polu walki. Obecnie tanie BSP stosowane w zastosowaniach militarnych pełnią funkcję nośników granatów lub są wykorzystywane jako amunicja krążąca [2]. W zakresie bezzałogowych pojazdów lądowych (BPL – ang. Unmanned Ground Vehicles, UGV) na współczesnym polu walki coraz częstsze jest ich wykorzystanie jako pojazdów kamikaze, jednostek transportowych do dostarczania amunicji i zaopatrzenia, pojazdów do neutralizacji improwizowanych ładunków wybuchowych (ang. Explosive Ordnance Disposal, EOD), urządzeń do minowania i rozminowywania terenu, jak również pojazdów rozpoznawczych i bojowych [3], [4], [5]. Wzrost wykorzystywania tego typu rozwiązań można zauważyć również wśród innowacyjnych firm i startupów, czego efektem jest fakt powstawania programów akceleryacyjnych dla działalności związanej z systemami bezzałogowymi [6].



Rysunek 1. Różne rodzaje zastosowań BPL na polu walki (klatka z filmu) [7].

Popularność systemów bezzałogowych doprowadziła do rozwoju licznych systemów przeciwdziałania tego typu zagrożeniom. Oprócz metod kinetycznego zwalczania BSP lub BPL, jedną z podstawowych i bardzo skutecznych metod jest stosowanie systemów zakłócających komunikację między systemem bezzałogowym a jego operatorem. Odpowiedzią producentów systemów bezzałogowych na tego rodzaju neutralizację są systemy autonomii jazdy dla BPL oraz systemy autonomii lotu dla BSP. Wykorzystanie BSP na polu walki stało się powszechne podczas II wojny o Górski Karabach (konflikt między

Armenią a Azerbejdżanem w 2020 roku) [8]. Z kolei użycie BPL na polu bitwy jest coraz bardziej popularne podczas trwającego konfliktu zbrojnego pomiędzy Rosją a Ukrainą na terytorium Ukrainy. W filmach i materiałach fotograficznych z tego konfliktu można zauważyć zarówno zaawansowane technicznie rozwiązania, takie jak BPL Themis wytwarzanego przez estońską firmę Milrem Robotics, jak i tanie, produkowane w małych seriach konstrukcje przeznaczone do wykorzystania jako "amunicja jeżdżąca" (pot. robot kamikaze) [9].

Obecnie większość BPL używanych w konflikcie na Ukrainie korzysta z łączności radiowej do wykonywania zadań operacyjnych. Konieczność utrzymywania łączności z robotem ogranicza ich zastosowanie w rejonach aktywnych działań bojowych, gdzie używane są systemy zakłócające łączność radiową oraz sygnały nawigacji satelitarnej. Rozwiązaniem umożliwiającym stosowanie systemów bezzałogowych w warunkach walki radioelektronicznej jest wykorzystanie systemów autonomii jazdy. BPL wyposażony w mapę terenu i korzystający z nawigacji inercyjnej wspomaganą przez systemy wizyjne może realizować proste misje i zadania w trybie autonomicznym, bez potrzeby odbierania sygnałów radiowych i ich nadawania. Istnieją systemy łączności oparte na światłowodach, ale często ograniczają zdolność pojazdu w zakresie manewrowości.

Systemy autonomii jazdy zyskały popularność w ostatnich latach dzięki dynamicznemu rozwojowi sektora motoryzacyjnego, gdzie funkcje autonomiczne stają się standardem w nowoczesnych pojazdach. Technologie takie jak adaptacyjny tempomat, asystent pasa ruchu czy automatyczne parkowanie znacząco podnoszą komfort i bezpieczeństwo użytkowników. Jednakże zastosowanie systemów autonomii jazdy o różnym stopniu zaawansowania jest znane w przemyśle już od początku XXI wieku, na przykład w autonomicznych wózkach widłowych wykorzystywanych w magazynach lub w maszynach górniczych działających w trudnych warunkach podziemnych.

Nowym i wymagającym wyzwaniem są systemy autonomii jazdy do pracy w terenach nieustrukturyzowanych, czyli pozbawionych elementów infrastruktury takich jak asfalt, namalowane pasy czy ściany. W takich środowiskach systemy autonomiczne muszą sprostać dynamicznie zmieniającym się warunkom terenowym, które obejmują nierówności, naturalne przeszkody (jak kamienie czy drzewa) oraz zmienne warunki atmosferyczne.

Systemy autonomii jazdy BPL wykorzystywane na polu walki muszą radzić sobie z dynamicznie zmieniającymi się warunkami terenowymi wynikającymi zarówno z działań wojennych, jak i wpływu wielotonowych pojazdów pancernych, które mogą tworzyć koleiny zmieniające przejezdność terenu. Poza standardowymi wyzwaniami związanymi z nawigacją w trudnym terenie, systemy te muszą być odporne na zakłócenia elektromagnetyczne, działania przeciwnika oraz zdolne do samodzielnego wykrywania i omijania niebezpieczeństw, takich jak miny czy improwizowane ładunki wybuchowe. Dlatego technologie wykorzystywane w wojskowych systemach autonomii jazdy często obejmują zaawansowane sensory, sztuczną inteligencję oraz metody uczenia maszynowego, które pozwalają na szybkie i precyzyjne dostosowywanie się do zmieniających się warunków bojowych.

Systemy autonomicznej jazdy w bezzałogowych pojazdach lądowych składają się z kilku kluczowych komponentów, które współpracują w celu zapewnienia efektywnego poruszania się pojazdu w złożonym, nieustrukturyzowanym środowisku. Przede wszystkim są to sensory, które zbierają dane o otoczeniu pojazdu – kamery, lidary (ang. Light Detection and Ranging) oraz radary. Kamery dostarczają obraz w czasie rzeczywistym, umożliwiając wykrywanie i identyfikację obiektów oraz analizę wizualną otoczenia. Lidar tworzy chmurę punktów, umożliwiając opracowanie szczegółowej trójwymiarowej mapy otoczenia. Radar z kolei sprawdza się w różnych warunkach atmosferycznych, takich jak mgła czy deszcz, dostarczając precyzyjnych informacji o prędkości i odległości do obiektów.

Kolejnym istotnym elementem systemów autonomicznej jazdy jest jednostka obliczeniowa, która przetwarza dane z czujników. Odpowiada ona za wydajność i sprawność całego systemu, wykorzystując zaawansowane algorytmy uczenia maszynowego i sztucznej inteligencji, aby interpretować dane i podejmować decyzje dotyczące ruchu pojazdu. Algorytmy te są zdolne do analizowania dużych ilości danych w czasie rzeczywistym, co umożliwia pojazdowi samodzielne planowanie trasy, omijanie przeszkód oraz dostosowywanie prędkości do aktualnych warunków terenowych. Wykorzystuje się tutaj techniki, takie jak głębokie uczenie (ang. deep learning), sieci neuronowe oraz modele predykcyjne, które pozwalają na dynamiczne reagowanie na zmieniające się warunki i przewidywanie potencjalnych zagrożeń.

Kolejnym aspektem systemów autonomicznej jazdy jest układ napędowy i system sterowania pojazdem. Obejmuje on mechanizmy odpowiedzialne za kierowanie, przyspieszanie oraz hamowanie pojazdu zgodnie z decyzjami podejmowanymi przez jednostkę obliczeniową. Układ napędowy musi być precyzyjnie zsynchronizowany z systemem sterowania, aby zapewnić płynność i dokładność ruchów pojazdu. System sterowania wykorzystuje sygnały z jednostki obliczeniowej do zarządzania silnikami, hamulcami oraz układem kierowniczym, co zapewnia optymalne działanie w zróżnicowanych warunkach terenowych. W pojazdach załogowych, które posiadają funkcje autonomii jazdy, stosuje się zaawansowane technologie, takie jak systemy drive-by-wire, które pozwalają na elektroniczne sterowanie pojazdem.

Podsumowując, można zauważyć aktualny kierunek rozwoju lądowych systemów bezzałogowych przeznaczonych do pracy w terenach przygodnych. Kierunek ten wynika z rosnącego zapotrzebowania na technologie pozwalające zastąpić człowieka w wykonywaniu niebezpiecznych zadań bojowych, wymagających bezpośredniego kontaktu z przeciwnikiem, przy wykorzystaniu BPL. Realizacja takiego celu wymaga intensywnych prac badawczych i inżynierskich, mających na celu udoskonalanie technologii autonomicznych, niezależnie od warunków otoczenia. Pociąga to za sobą konieczność innowacyjnego podejścia oraz rozwój rozwiązań wcześniej pomijanych ze względu na niskie zapotrzebowanie rynkowe.

1.1 Wprowadzenie – systemy bezzałogowe w Polsce

W Polsce pionierem rozwiązań w zakresie bezzałogowych systemów lądowych przeznaczonych do zastosowań specjalnych jest Sieć Badawcza Łukasiewicz – Przemysłowy Instytut Automatyki i Pomiarów PIAP (Łukasiewicz-PIAP). Instytut od lat 90-tych XX wieku opracowuje i produkuje roboty mobilne dla Policji, Straży Granicznej, Straży Pożarnej oraz Sił Zbrojnych. Do tej pory Łukasiewicz-PIAP dostarczył na rynek niemal 700 egzemplarzy robotów mobilnych do 27 krajów na trzech kontynentach, co czyni go liderem tego rodzaju rozwiązań w Polsce. Naukowcy Łukasiewicz-PIAP biorą udział w grupach badawczych organizacji takich jak NATO Science and Technology Organization (NATO STO), Europejska Agencja Obrony (EDA) oraz Ministerstwo Obrony Narodowej (MON). Instytut uczestniczy również w opracowywaniu norm i rekomendacji dla systemów bezzałogowych, m.in. w zakresie protokołów wymiany danych w ramach NATO STANREC 4818 (NATO ROBOTIC AUTONOMOUS SYSTEMS – GROUND INTEROPERABILITY

PROFILE), struktury systemów sterowania w ramach NATO STANAG 4817 (Interoperable Command and Control (C2) of Multi-Domain Unmanned Platform Control Systems) oraz potencjału i zakresu wykorzystania sztucznej inteligencji do zastosowań militarnych (w ramach von Karman Horizon Scanning[10]). Bierze także udział w badaniach nad przejezdnością terenu dla pojazdów wojskowych (NATO AVT-247). W ramach badań krajowych oraz projektów dofinansowanych z dziedziny bezpieczeństwa i obronności Łukasiewicz-PIAP realizował również badania nad systemami autonomii jazdy w projektach ATENA[11] i DEZROB[12], których byłem pomysłodawcą, autorem wniosków projektowych oraz kierownikiem.

Kolejną dużą jednostką realizującą zaawansowane badania w zakresie robotyki mobilnej w Polsce jest Wojskowa Akademia Techniczna (WAT). WAT od ponad pięćdziesięciu lat prowadzi intensywne prace badawczo-rozwojowe w dziedzinie robotyki mobilnej, koncentrując się na opracowywaniu i doskonaleniu bezzałogowych platform lądowych. Kluczowym osiągnięciem w tym obszarze jest otwarcie 29 października 2024 roku Centrum Robotów Mobilnych, które znacząco podnosi jakość badań i edukacji w zakresie systemów bezzałogowych. Nowo powstałe centrum, będące częścią Instytutu Robotów i Konstrukcji Maszyn Wydziału Inżynierii Mechanicznej WAT, obejmuje nowoczesny budynek szkolno-laboratoryjny oraz poligon testowy. Jego infrastruktura umożliwia prowadzenie zaawansowanych badań nad platformami bezzałogowymi, manipulatorami, interfejsami człowiek-maszyna oraz systemami funkcjonalnymi, takimi jak lokalizacja, nawigacja czy detekcja [13].

1.2 Przewodnik po treści pracy

W rozdziale 1 przedstawiono wprowadzenie do tematyki systemów bezzałogowych w Polsce, omawiając ich rozwój oraz obszary zastosowań. Zawarto także przewodnik po treści pracy, ułatwiający zrozumienie jej struktury oraz głównych zagadnień.

Rozdział 2 koncentruje się na celu pracy, definiując problem badawczy oraz hipotezę, a także prezentując metodykę badań, obejmującą analizę przejezdności terenu z wykorzystaniem kamer hiperspektralnych.

W rozdziale 3 dokonano przeglądu stanu wiedzy i techniki w zakresie autonomii robotów mobilnych. Omówiono w nim technologie wykorzystywane do budowy modelu otoczenia, w tym sensory takie jak lidar, kamery różnego rodzaju w tym kamery hiperspektralne. Przedstawiono również badania dotyczące lokalizacji, mapowania, oceny przejezdności oraz sterowania robotami mobilnymi.

Rozdział 4 zawiera szczegółowy opis prac własnych autora, obejmujący badania wstępne realizowane w ramach projektów PIAP (ATENA, HUNTeR, DEZROB), schemat ogólny proponowanego systemu, a także rozwój metody oceny przejezdności terenu. Przedstawiono w nim analizę materiałów podłoża z wykorzystaniem kamer hiperspektralnych oraz integrację tych danych z modelami geometrycznymi.

Rozdział 5 zawiera opis badań eksperymentalnych, w tym testów terenowych pojazdów autonomicznych oraz eksperymentów z wykorzystaniem kamer hiperspektralnych. Przedstawiono wyniki testów i ocenę skuteczności opracowanego systemu.

W rozdziale 6 zaprezentowano wdrożenie wyników badań, omawiając implementację metod oceny przejezdności w ramach projektów Łukasiewicz-PIAP.

Rozdział 7 zawiera podsumowanie pracy, wnioski oraz perspektywę dalszych badań nad integracją systemów autonomicznych z analizą przejezdności. Praca kończy się bibliografią, spisem symboli, tabel oraz rysunków.

Wyniki badań prowadzonych w ramach pracy doktorskiej zostały opublikowane w pracach [14], [15], [16], [17].

2. Cel pracy, opis wdrożenia i teza

Celem mojej pracy doktorskiej jest rozwinięcie tej części systemu autonomii robota mobilnego, która odpowiada za interakcję z otoczeniem. Skupiam się na algorytmie, który tworzy mapę przejezdności na podstawie danych o otoczeniu, dostosowaną do zdolności terenowych danej platformy.

W ramach niniejszej pracy doktorskiej stworzyłem nowatorskie rozwiązanie, które dotychczas nie było dostępne na rynku ani szeroko analizowane w literaturze naukowej. Proponuję użycie kamery hiperspektralnej do określenia rodzaju materiałów w otoczeniu bezzałogowego pojazdu lądowego, co umożliwi bardziej precyzyjne dopasowanie modelu przejezdności terenu. Oznacza to, że praca skupia się na wprowadzeniu komponentu materiałowego do mapy przejezdności, co umożliwi lepszą analizę i adaptację do różnorodnych warunków terenowych, w których operować będzie pojazd.

Zdolność do autonomicznego planowania trasy w terenach nieznanych i nieustrukturyzowanych jest kluczową i wysoce pożądaną funkcjonalnością robotów autonomicznych, szczególnie w kontekście ich zastosowań militarnych, m.in. w Siłach Zbrojnych Rzeczypospolitej Polskiej oraz Wojskach Obrony Terytorialnej.

W zakresie części wdrożeniowej pracy i w kontekście doświadczeń zdobytych przez Łukasiewicz-PIAP oraz strategii rozwoju robotów mobilnych PIAP, zidentyfikowano potrzebę wdrożenia systemu oceny przejezdności terenu na potrzeby planowania trasy dla systemów sterowania robotów PIAP. Niniejsza rozprawa doktorska, realizowana w ramach programu „Doktorat Wdrożeniowy”, ma na celu opracowanie metody oceny przejezdności trasy dla różnych robotów mobilnych Łukasiewicz-PIAP, które mogą zostać wyposażone w Moduł Autonomii PIAP. Dotyczy to szczególnie robotów PIAP PATROL, PIAP HUNTeR oraz demonstratora technologii autonomicznej jazdy na platformie samochodu typu pick-up – PIAP ATENA.

Dzięki temu opracowaniu roboty te będą w stanie lepiej nawigować w zróżnicowanym terenie oraz omijać przeszkody, co znacząco zwiększy ich funkcjonalność i możliwości zastosowania w różnych scenariuszach operacyjnych. Wyniki pracy doktorskiej będą wdrażane bezpośrednio w instytucie, poprzez implementację funkcji trójwymiarowego obrazowania

otoczenia, co umożliwi ocenę przejezdności pojazdów Łukasiewicz-PIAP, ze szczególnym uwzględnieniem modeli PIAP HUNTER oraz PIAP ATENA.

Wdrożenie wyników rozprawy doktorskiej obejmie również przygotowanie wiedzy i know-how na potrzeby planowania projektów z obszaru Bezpieczeństwa i Obronności, zarówno krajowych, jak i europejskich (konkursy organizowane przez Europejską Agencję Obrony – EDA oraz Europejski Fundusz Obronny – EDF). Pozyskanie projektów i finansowania dla rozwoju technologii autonomicznych w obszarze bezzałogowych pojazdów lądowych (BPL) pozwoli Łukasiewicz-PIAP utrzymać status lidera na krajowym rynku produkcji zaawansowanych robotów mobilnych przeznaczonych do zastosowań specjalnych.

Planowane jest również wdrożenie wyników rozprawy doktorskiej w zakresie metod budowy modelu otoczenia w celu zwiększenia teleobecności operatora robotów produkcji Łukasiewicz-PIAP. Wyniki te będą przedstawiane przez Łukasiewicz-PIAP na spotkaniach grup roboczych MON, NATO STO oraz EDA jako propozycje kierunków badań, zwłaszcza w obszarze rozwoju robotów mobilnych do zastosowań specjalnych.

Oczekiwanym rezultatem wdrożenia wyników rozprawy jest pozyskanie projektów badawczo-rozwojowych (B+R) w obszarze Bezpieczeństwa i Obronności, dotyczących robotyki mobilnej. Dodatkowym efektem, mającym znaczenie aplikacyjne, będzie opracowanie metodyki trójwymiarowego obrazowania otoczenia dla operatora robotów mobilnych Łukasiewicz-PIAP, umożliwiającej zespołowi programistów implementację tej funkcjonalności w docelowych produktach instytutu.

Teza pracy brzmi: uwzględnienie informacji semantycznej o elementach otoczenia w modelu przejezdności terenu — pozyskanych za pomocą kamery hiperspektralnej — oraz ich integracja z danymi geometrycznymi umożliwiają znaczącą poprawę jakości planowania trasy i zwiększenie zdolności operacyjnych autonomicznych i zdalnie sterowanych bezzałogowych platform lądowych (BPL) w środowiskach nieustrukturyzowanych.

2.1 Problem badawczy

Problemem badawczym w niniejszej pracy jest opracowanie metod analizy przejezdności terenu dla autonomicznego systemu jazdy bezzałogowych platform lądowych (BPL) przeznaczonych do pracy w terenie nieustrukturyzowanym. Celem badań jest stworzenie reprezentacji otoczenia, która umożliwi efektywne wyznaczenie bezpiecznej i realizowalnej trasy przejazdu dla BPL w złożonych warunkach terenowych. Problem badawczy można rozłożyć na kilka kluczowych etapów analizy.

W pierwszym kroku konieczne jest zbudowanie modelu otoczenia, polegającego na integracji i agregacji danych z różnych sensorów, takich jak lidar, kamery RGB, kamery stereowizyjne oraz kamery hiperspektralne. Dane z tych sensorów muszą zostać zsynchronizowane, dane z lidarów mogą być przedstawione w postaci chmury punktów, co stanowi punkt wyjścia do analizy geometrii otoczenia.

Kolejnym krokiem jest przeprowadzenie analizy przejezdności w oparciu o parametry geometryczne, takie jak nachylenie i wysokość terenu, które są kluczowe dla planowania tras i unikania przeszkód. Podejście to jednak ma pewne ograniczenia, ponieważ może prowadzić do błędnych wniosków o nieprzejezdności obszarów, które w rzeczywistości są możliwe do pokonania przez pojazd, np. wysokie trawy mogą być błędnie interpretowane jako przeszkody nieprzejezdne oraz odwrotnie klasyfikowanie terenów nieprzejezdnych jako przejezdne np. niewielkie wzniesienie, które pokryte asfaltem jest przejezdne, ale pokryte błotem (nawierzchnią o niskim współczynniku tarcia) jest nie do pokonania.

W celu eliminacji tych błędów konieczne jest uwzględnienie dodatkowych informacji, takich jak właściwości materiałowe nawierzchni. W ramach pracy główny nacisk położono na rozwiązanie problemu analizy przejezdności terenu z uwzględnieniem informacji o materiale podłoża, pozyskiwanej za pomocą kamery hiperspektralnej.

2.1.1 Uzasadnienie wyboru problemu badawczego

Dobór problemu badawczego związany z analizą przejezdności terenu dla systemów autonomicznych opiera się na praktycznych doświadczeniach z projektów realizowanych w Łukasiewicz-PIAP, takich jak ATENA, DEZROB oraz HUNTeR. W ramach tych projektów

stwierdzono, że jednym z kluczowych ograniczeń obecnych systemów autonomii jest brak precyzyjnej analizy materiałowej otoczenia. W rezultacie pojazdy mogą być zatrzymywane przez przeszkody, które są rzeczywiście przejezdne, co ogranicza ich funkcjonalność operacyjną i zdolność do realizacji misji. Na przykład w projekcie HUNTeR, autonomiczny system jazdy często błędnie klasyfikował wysoką trawę jako przeszkodę nieprzejezdną, ponieważ obecne sensory, takie jak lidar, umożliwiają głównie analizę geometrii obiektów, nie uwzględniając ich struktury materiałowej.

Proponowane rozwiązanie, polegające na wprowadzeniu analizy materiałowej przy wykorzystaniu kamer hiperspektralnych, pozwala na dokładniejsze odwzorowanie otoczenia. Dane hiperspektralne umożliwiają identyfikację sygnatur spektralnych materiałów, takich jak rodzaj gleby, roślinność czy asfalt, co pozwala systemowi autonomii lepiej interpretować, które tereny są rzeczywiście nieprzejezdne, a które mogą być pokonane. Zastosowanie tej technologii stanowi wartość dodaną, ponieważ oferuje możliwość rozszerzenia mapy przejezdności o dodatkowy poziom szczegółowości, niedostępny dla klasycznych sensorów. Wyniki badań wskazują, że integracja informacji materiałowej może znacznie poprawić jakość planowania trasy, pozwalając pojazdom na bardziej efektywne omijanie przeszkód i adaptację do zmieniających się warunków terenowych.

W ramach niniejszej pracy przyjęto, że analiza przejezdności z uwzględnieniem materiału otoczenia powinna osiągnąć poziom dokładności pozwalający na znaczącą redukcję błędnych klasyfikacji przeszkód. W kontekście hiperspektralnego rozpoznawania materiałów optymalnym rezultatem byłoby osiągnięcie zdolności do jednoznacznej klasyfikacji materiałów, co wystarczy do rozróżnienia podstawowych kategorii terenu (np. droga asfaltowa, droga gruntowa, piasek, trawa) na potrzeby planowania trasy.

Ze względu na obecne ograniczenia technologiczne związane z przetwarzaniem danych hiperspektralnych, w szczególności wymagania obliczeniowe w czasie rzeczywistym, badania zostały przeprowadzone w trybie offline, w ramach badań eksperymentalnych. W przypadku pozytywnych wyników w trybie offline kolejne etapy badań mogą być ukierunkowane na optymalizację metody pod kątem działania w czasie rzeczywistym, co pozwoli na lepsze dostosowanie rozwiązania do przyszłych zastosowań operacyjnych w projektach realizowanych przez Łukasiewicz-PIAP.

Podsumowując, problem badawczy zakłada analizę przejezdności terenu z uwzględnieniem materiału otoczenia jako kluczowy element rozwoju autonomii jazdy dla pojazdów Łukasiewicz-PIAP. Wyniki tej pracy mają potencjał, aby znacząco podnieść funkcjonalność i efektywność pojazdów w środowiskach nieustrukturyzowanych, co jest szczególnie istotne w kontekście zadań wymagających niezawodne zrealizowanie celu.

2.1.2 Proponowane rozwiązanie problemu badawczego

Przewidywanym rozwiązaniem problemu analizy przejezdności terenu jest wdrożenie dodatkowego obrazowania otoczenia za pomocą hiperspektralnej kamery migawkowej. Obrazowanie hiperspektralne stanowi stosunkowo nową metodę w planowaniu ruchu pojazdów autonomicznych, a wstępne wyniki wskazują na duży potencjał praktycznego zastosowania tej technologii. Wykorzystując dane z kamery hiperspektralnej skorelowane z trójwymiarową chmurą punktów, możliwe jest dodanie nowego parametru do analizy przejezdności – sygnatury spektralnej otoczenia (z każdego piksela w obrazie hiperspektralnym). Na podstawie analizy sygnatur spektralnych można określić dominujący materiał w danym obszarze otoczenia pojazdu, co umożliwi bardziej precyzyjne określenie rodzaju podłoża lub przeszkody.

Wprowadzenie hiperspektralnego rozpoznania materiałowego pozwala na szczegółową analizę kosztów przejazdu przez dany obszar w zależności od rodzaju materiału, np. miękkie podłoże może zwiększać opór ruchu lub zwiększać ryzyko unieruchomienia pojazdu. W efekcie klasyfikacja materiałowa pozwala na znacząco dokładniejsze planowanie trasy i omijanie rzeczywistych przeszkód w oparciu o zdolności terenowe pojazdu.

2.2 Metodyka badań

Poniżej przedstawię metodykę jaką przyjąłem do realizacji zagadnienia oceny przejezdności. Jest to też zapis przyjętego planu realizacji, dla przejrzystości zapisów, przedstawiam również krótkie informacje dotyczące poszczególnych punktów.

1. Przegląd stanu wiedzy

Badania prowadzone w ramach niniejszej pracy doktorskiej rozpoczęto od przeglądu literatury oraz analizy dokumentacji technicznej i wyników projektów NATO związanych z

autonomicznymi pojazdami lądowymi i oceną przejeźdźności terenu, w tym projektu Next-Generation NATO Reference Mobility Model (NG-NRMM). Przegląd ten umożliwił identyfikację aktualnych podejść do analizy przejeźdźności i integracji różnych sensorów, a także określenie luk technologicznych w autonomii jazdy w terenach nieustrukturyzowanych.

2. Testy terenowe

Kolejnym etapem była realizacja testów terenowych na poligonach badawczych z udziałem wybranych pojazdów mobilnych Łukasiewicz-PIAP: PIAP ATENA, PIAP HUNTeR oraz PIAP PATROL (wersja DEZROB). Testy przeprowadzono w warunkach zbliżonych do rzeczywistych w celu dokładnego sprawdzenia zdolności terenowych pojazdów, zebrania danych niezbędnych do dalszej analizy oraz stworzenia bazy referencyjnej dla zróżnicowanych warunków terenowych. Wyniki testów posłużyły jako podstawa do porównawczej analizy przejeźdźności terenu zarówno z uwzględnieniem informacji materiałowych, jak i bez niej.

3. Opis pojazdów i narzędzi badawczych

Badania nad przejeźdźnością koncentrują się głównie na trzech pojazdach PIAP:

PIAP ATENA: Demonstrator technologii, zainstalowany na pojeździe typu pick-up, wyposażony w system autonomii jazdy oraz szeroką gamę sensorów, w tym LiDAR Velodyne VLP16, kamery Basler acA1920-48gc, a także kamerę hiperspektralną Cubert Q285. PIAP ATENA, umożliwiającą zbieranie danych zarówno w trybie autonomicznym, jak i manualnym, pozwala na przeprowadzenie kontrolowanych badań nad przejeźdźnością w trybie offline.

PIAP HUNTeR: Pojazd wysokiej mobilności przeznaczony do pracy w nieustrukturyzowanych terenach, posiadający układ napędowy wspomagany generatorem. Docelowo platforma HUNTeR ma pełnić rolę testową dla systemów autonomicznych wspierających ocenę przejeźdźności.

PIAP PATROL (wersja DEZROB): Kompaktowy pojazd gąsienicowy o wysokiej manewrowości, szczególnie przydatny do analizy przejeźdźności w ograniczonych przestrzeniach.

Każdy z pojazdów został wyposażony w systemy sensoryczne umożliwiające modelowanie geometrii i struktury materiałowej terenu. Wyposażenie PIAP ATENA w kamerę hiperspektralną pozwala rozszerzyć tradycyjne podejście geometryczne o analizę materiałową, która jest nowością w ocenie przejezdności.

4. Miejsca testowe i ocena zdolności terenowych pojazdów

Testy terenowe zostały zrealizowane w trzech lokalizacjach:

Teren Instytutu Łukasiewicz-PIAP: Obszar z drogami wyłożonymi płytami, w otoczeniu kontenerów i budynków, symulujący warunki miejskie.

Poligon WITU: Oferujący zróżnicowaną rzeźbę terenu, w tym drogi gruntowe, rowy i mostki, co pozwala na przeprowadzenie testów w warunkach przypominających typowe środowisko operacyjne.

Poligony wojskowe Nowa Dęba i Lipa (podczas FEX-23 i FEX-24): Testy przeprowadzone na tych obszarach uwzględniały wyzwania takie jak strome, piaszczyste wzniesienia i gęsta roślinność, co umożliwiło ocenę mobilności PIAP HUNTeR w najbardziej wymagających warunkach terenowych.

5. Wytyczne do budowy modelu przejezdności dla BPL

Na podstawie testów terenowych opracowano kluczowe wytyczne do oceny przejezdności dla autonomicznych platform lądowych:

- **Planowanie tras** po drogach utwardzonych, o ile misja nie wymaga innego działania.
- **Unikanie tras o ograniczonej widoczności** (np. przez roślinność), co zmniejsza ryzyko kolizji.
- **Unikanie poślizgów i utraty przyczepności**, które są trudne do opanowania nawet w trybie teleoperacji.
- **Omijanie przeszkód nieprzejezdnych**, aby zminimalizować ryzyko uszkodzenia sprzętu.
- **Wyświetlanie map przejezdności** dla operatora, co zwiększa świadomość sytuacyjną podczas zdalnego sterowania.

Na podstawie wyników testów określono zestaw parametrów terenowych uwzględnianych w ocenie przejezdności:

- **Parametry geometryczne:** nachylenie, skok/stopień, nierówność (wyrażona jako liczba różnic wysokości na danym obszarze).
- **Prędkości i przyspieszenie:** maksymalne i minimalne wartości dostosowane do warunków terenowych oraz klasy pojazdu.

6. Adaptacja metod analizy geometrycznej otoczenia

Pierwszym etapem prac nad modelem oceny przejezdności była adaptacja metod analizy geometrycznej otoczenia, bazujących na wynikach badań ETH Zurich [18]. Wykorzystując doświadczenia zespołu Robotic Systems Lab – Legged Robotics [19], opracowano model oceny przejezdności dostosowany do wymagań projektów Łukasiewicz-PIAP. Uwzględnia on analizę nachylenia, nierówności i różnic wysokości terenu, co umożliwia ocenę przejezdności w nieustrukturyzowanych warunkach terenowych.

7. Integracja danych geometrycznych i materiałowych na podstawie segmentacji semantycznej

Kolejnym krokiem była integracja danych geometrycznych z danymi materiałowymi z wykorzystaniem technik segmentacji semantycznej. W oparciu o badania z 2022 roku [20], przeprowadzono klasyfikację materiałów podłoża, co umożliwiło bardziej precyzyjne rozpoznawanie i klasyfikowanie różnych materiałów oraz ich wpływu na przejezdność i dynamikę jazdy.

8. Analiza materiałów otoczenia z wykorzystaniem kamery hiperspektralnej

Zastosowanie kamery hiperspektralnej było kluczowe w rozszerzeniu analizy materiałowej otoczenia. Badania z wykorzystaniem tego sensora pozwoliły na dokładne pomiary spektralne, umożliwiające klasyfikację materiałów, co z kolei wspiera ocenę przejezdności w zróżnicowanych warunkach terenowych.

9. Opracowanie autorskiej metody analizy przejezdności

Na bazie danych zebranych przez Lidar, jednostkę IMU i kamerę hiperspektralną opracowano autorską metodę analizy przejezdności. Metoda ta umożliwia dynamiczne tworzenie map

przejezdności, wspierając nawigację pojazdu zarówno w trybie autonomicznym, jak i zdalnym. Opracowane narzędzie zostanie w przyszłości wdrożone jako system wsparcia operatorskiego na platformie PIAP HUNTeR.

10. Wdrożenie

Implementacja opracowanej analizy przejezdności w oparciu o geometrię otoczenia została wdrożona w systemie ATENA. Dodatkowo elementy systemu oceny przejezdności zostały wdrożone w PIAP HUNTeR jako system wsparcia dla operatora, dostarczający informacji o modelu otoczenia oraz przejezdności w czasie rzeczywistym. Tego rodzaju wdrożenie pozwoliło przetestować efektywność systemu i dostosować go do rzeczywistych warunków operacyjnych, a także umożliwić przyszłą optymalizację metod pod kątem działania w czasie rzeczywistym.

3. Przegląd stanu wiedzy – stan techniki

Poniższy rozdział stanowi przegląd stanu wiedzy w obszarze szeroko pojętej robotyki mobilnej i pojazdów autonomicznych, uwzględniający zarówno technologie związane z pozyskiwaniem danych (m.in. różnego typu sensory), jak i przetwarzanie informacji na potrzeby lokalizacji, mapowania oraz podejmowania decyzji w złożonych środowiskach. Współczesne systemy autonomiczne, niezależnie od ich docelowego zastosowania (wojskowe, ratownicze, komercyjne), wymagają zintegrowanych rozwiązań łączących metody komputerowego przetwarzania obrazu, fuzję wielorodzajowych danych pomiarowych, a także algorytmów planowania trasy i zaawansowanego sterowania.


3.1 Sensory do budowy modelu otoczenia

W budowie modelu otoczenia dla pojazdów autonomicznych kluczową rolę odgrywają różne rodzaje sensorów, umożliwiające percepcję środowiska i podejmowanie decyzji na podstawie zgromadzonych informacji. Główne typy sensorów stosowane w pojazdach autonomicznych to Lidar, kamery, radar oraz GPS, a także technologie uzupełniające, takie jak sonar i czujniki ultradźwiękowe.

3.1.1 LiDAR (Light Detection and Ranging)

LiDAR jest zaawansowaną technologią skanowania laserowego, niezbędną do modelowania otoczenia i nawigacji autonomicznych pojazdów. Działa na zasadzie emisji pulsów laserowych i pomiaru czasu ich odbicia od obiektów. Pozwala to na uzyskanie szczegółowych trójwymiarowych obrazów otoczenia, co jest kluczowe dla dokładnej nawigacji autonomicznej [21], [22].

Podczas pracy LiDAR emituje tysiące impulsów laserowych na sekundę, które odbijają się od napotkanych obiektów i wracają do czujnika. Na podstawie czasu emisji i odbioru impulsu oraz prędkości światła, LiDAR oblicza odległość do obiektu. Wynikiem pomiarów jest chmura punktów, którą przekształca się na trójwymiarową mapę otoczenia, wykorzystywaną do identyfikacji i klasyfikacji obiektów. Dzięki temu LiDAR pozwala na precyzyjne wykrywanie przeszkód na drodze pojazdu, co jest kluczowe dla planowania trasy i unikania kolizji [23].



Rysunek 2. Na zdjęciu powyżej zdjęcie terenu, poniżej obraz chmury punktów z lidaru Velodyne VLP-16. (lidar zamontowany przed maską pojazdu PIAP ATENA).

Jedną z kluczowych zalet technologii LiDAR jest jej niezależność od warunków oświetleniowych – działa efektywnie zarówno w dzień, jak i w nocy, w przeciwieństwie do systemów bazujących na kamerach RGB. W porównaniu do radaru, LiDAR oferuje znacznie wyższą rozdzielczość przestrzenną, co pozwala na precyzyjniejsze odwzorowanie geometrii obiektów. Jednakże tradycyjne LiDAR-y obrotowe, mimo swojej wysokiej precyzji, mają również pewne ograniczenia, takie jak złożoność konstrukcji mechanicznej, wysokie koszty oraz podatność na awarie związane z elementami ruchomymi [24].

3.1.1.1 LiDAR 2D

LiDAR 2D (dwuwymiarowy) to uproszczona wersja technologii LiDAR, która skanuje otoczenie w jednej płaszczyźnie. Zasada działania pozostaje podobna – urządzenie emituje

impulsy laserowe, które po odbiciu od obiektów wracają do detektora, umożliwiając określenie odległości do przeszkód. Kluczową cechą 2D LiDAR jest jego ograniczony zakres skanowania – zamiast tworzyć pełną trójwymiarową chmurę punktów, generuje jedynie przekrój otoczenia w wybranej płaszczyźnie, zazwyczaj poziomej lub pionowej. Technologia LiDAR 2D jest szeroko stosowana w robotyce mobilnej oraz systemach automatyki przemysłowej, gdzie pozwala na wykrywanie przeszkód w obrębie jednej płaszczyzny, co jest wystarczające dla wielu zastosowań. Dzięki prostszej konstrukcji, 2D LiDAR charakteryzuje się niższym kosztem i mniejszym poborem energii w porównaniu do systemów 3D. Niemniej jednak, jego ograniczona zdolność do mapowania przestrzeni sprawia, że w bardziej wymagających zastosowaniach, takich jak nawigacja autonomicznych pojazdów, konieczna jest integracja z innymi sensorami [25], [26].

3.1.1.2 Obrotowy LiDAR


Obrotowy LiDAR (mechaniczny LiDAR 3D) stanowi rozwinięcie technologii LiDAR 2D poprzez zastosowanie obrotowego systemu skanującego, który umożliwia pełne mapowanie otoczenia w trzech wymiarach. W przeciwieństwie do 2D LiDAR, który skanuje tylko w jednej płaszczyźnie, systemy obrotowe wykonują pełne skanowanie przestrzenne dzięki obracającemu się modułowi laserowemu lub zestawowi wirujących zwierciadeł. Najczęściej stosowane obrotowe LiDAR-y, takie jak Velodyne VLP-16, posiadają wiele warstw skanowania, co pozwala na jednoczesną rejestrację chmury punktów z różnych kątów. Tego rodzaju systemy charakteryzują się wysoką precyzją oraz szerokim polem widzenia, dzięki czemu znajdują zastosowanie w pojazdach autonomicznych, robotyce oraz inżynierii przestrzennej. Jednakże obrotowe LiDAR-y mają również swoje ograniczenia. Ich mechaniczna konstrukcja zwiększa podatność na zużycie i awarie, a także podnosi koszt produkcji i eksploatacji. Ponadto, w porównaniu do nowoczesnych systemów solid-state, obrotowe LiDAR-y wymagają większego zasilania i przestrzeni montażowej, co może stanowić wyzwanie w aplikacjach mobilnych [27], [28].



Rysunek 3. LiDAR Velodyne VLP-16 podczas testów różnego rozmieszczenia sensora na pojeździe PIAP ATENA.

3.1.1.3 Solid-State LiDAR

W odpowiedzi na wyzwania związane z mechanicznymi komponentami tradycyjnych systemów LiDAR, opracowano technologie Solid-State LiDAR, które eliminują konieczność stosowania ruchomych części i znacząco zwiększają niezawodność urządzenia. W przeciwieństwie do konwencjonalnych skanerów LiDAR, które wykorzystują obracające się elementy optyczne do kierowania wiązki laserowej, systemy solid-state bazują na nowoczesnych rozwiązaniach fotonicznych, takich jak fazowane matryce optyczne (OPA - Optical Phased Arrays), technologie MEMS (Micro-Electro-Mechanical Systems) oraz Flash LiDAR [29], [30].



Rysunek 4. Lidar typu Solid-State firmy LSlidar

3.1.1.4 Rozszerzenie możliwości technologii LiDAR poprzez system obrotowego lustra

W pracy [31] autorzy wykorzystują lidar Livox Mid-40 o stożkowym polu widzenia, które zostało rozszerzone za pomocą dodatkowego obrotowego reflektora płaskiego. Autorzy porównują opracowane rozwiązanie z droższym lidarem Velodyne VLP-16, wykazując, że proponowany system osiąga porównywalną dokładność i zasięg pomiaru. Dzięki zachowaniu niepowtarzalnego wzorca skanowania, system pokrywa pełne pole widzenia $38,4 \times 360$ stopni. W artykule omówiono również metody kalibracji, konstrukcję mechaniczną oraz szczegóły synchronizacji, umożliwiające odtworzenie systemu. Rozwiązanie to zostało przetestowane podczas 3. Europejskiego Hackathonu Robotycznego w Elektrowni Jądrowej Zwentendorf, gdzie wykazano, że opracowany system jest w stanie dostarczyć trójwymiarowe mapy obiektu jądrowego porównywalne z tymi uzyskanymi za pomocą droższych systemów.

3.1.1.5 Zalety i ograniczenia LiDAR-u

LiDAR jest ceniony za swoją wysoką rozdzielczość i dokładność, umożliwiającą tworzenie szczegółowych map 3D, co jest szczególnie ważne w nawigacji autonomicznej. Jednak czujniki LiDAR mogą być podatne na zakłócenia w trudnych warunkach atmosferycznych,

takich jak gęsta mgła, intensywny deszcz czy śnieg, które mogą wpływać na jakość pomiarów. Dodatkowo, ze względu na aktywny charakter działania (emisję impulsów laserowych), LiDAR jest łatwo wykrywalny, co może stanowić istotne ograniczenie w kontekście militarnym. Wysokie koszty LiDAR-u mogą również ograniczać jego szerokie zastosowanie w pojazdach autonomicznych [32], [33].

Podsumowując, LiDAR jest kluczowym elementem systemów autonomicznych, który dzięki precyzyjnej mapie otoczenia pozwala na nawigację i bezpieczne poruszanie się pojazdów w złożonych środowiskach. Integracja LiDAR-u z innymi sensorami, takimi jak kamery stereo i radar, umożliwia uzyskanie kompleksowego modelu otoczenia, który wspiera autonomię lokalną i globalną.

3.1.2 Kamery

Kamery stanowią jeden z najważniejszych sensorów wykorzystywanych w pojazdach autonomicznych, umożliwiając wizualizację i interpretację otoczenia. Dzięki nim systemy autonomiczne mogą rozpoznawać i analizować różnorodne obiekty na drodze, co jest kluczowe dla bezpiecznej i efektywnej nawigacji. Kamery rejestrują obrazy w wysokiej rozdzielczości, co pozwala uzyskać szczegółowe informacje o otoczeniu. Mogą to być zarówno kamery monochromatyczne, jak i kolorowe, zależnie od potrzeb analizy. Dane zebrane przez kamery są przetwarzane przez algorytmy komputerowego rozpoznawania obrazu, które segmentują obraz, rozpoznają wzorce i klasyfikują obiekty, takie jak inne pojazdy, piesi, znaki drogowe czy sygnalizacja świetlna. Informacje te są często łączone z danymi z innych sensorów, takich jak LiDAR czy radar, aby zwiększyć dokładność percepcji otoczenia dzięki fuzji sensorycznej.[34], [35]. Kamery można podzielić ze względu na ich zdolność do rejestracji obrazu w różnych długościach fal. Poniżej opisy dla różnych typów kamer.

3.1.2.1 Kamery światła widzialnego

Kamery światła widzialnego (RGB) rejestrują obrazy w zakresie widma elektromagnetycznego widocznego dla ludzkiego oka (od około 400 do 700 nm). Dzięki zdolności do rejestrowania szczegółowych obrazów są szeroko stosowane do identyfikacji i śledzenia obiektów, takich jak pojazdy, piesi, znaki drogowe i sygnalizacja świetlna, a także

do analizy stanu nawierzchni, rozpoznawania linii drogowych oraz detekcji przeszkód. Kamera tego typu dostarcza szczegółowych informacji o kolorach i kształtach, co jest szczególnie ważne przy interpretacji oznaczeń drogowych i sygnalizacji świetlnej.

W praktyce kamery te mają jednak pewne ograniczenia. Ich skuteczność spada w warunkach słabego oświetlenia, takich jak noc oraz w obecności intensywnego światła, co może prowadzić do efektu przeświecenia obrazu. Ponadto, działanie kamer światła widzialnego jest zakłócanie przez trudne warunki pogodowe, takie jak mgła, deszcz czy śnieg, które mogą pogorszyć widoczność i jakość obrazu.[36]

3.1.2.2 Kamery termowizyjne


Zgodnie z informacjami z [37], [38] kamery termowizyjne rejestrują promieniowanie podczerwone emitowane przez obiekty, co umożliwia wizualizację różnic temperatur, nawet w całkowitej ciemności. Zazwyczaj działają w zakresie fal od 8 do 14 mikrometrów. Są przydatne do wykrywania ciepłokrwistych obiektów, takich jak ludzie i zwierzęta, oraz do monitorowania otoczenia w warunkach ograniczonej widoczności, np. w obecności mgły lub dymu. Kamery termowizyjne są podzielone na dwa główne typy, opisane poniżej.

Kamery bolometryczne (niechłodzone) wykorzystują detektory bolometryczne, najczęściej wykonane z tlenku wanadu (VOx) lub amorficznego krzemu (a-Si). Detektory te zmieniają swoje właściwości elektryczne pod wpływem ciepła, co pozwala na generowanie obrazu termicznego. Kamery bolometryczne są bardziej niezawodne i tańsze w produkcji oraz konserwacji, ponieważ nie wymagają ruchomych części ani systemów chłodzenia. Niemniej, mają niższą czułość i rozdzielczość termiczną w porównaniu z kamerami chłodzonymi.

Kamery chłodzone wykorzystują detektory schładzane do bardzo niskich temperatur, zwykle około -196°C , przy użyciu systemów kriogenicznych. Schłodzone detektory charakteryzują się wyższą czułością na subtelne różnice temperatur oraz wyższą rozdzielczością, co czyni je idealnymi do detekcji małych różnic temperatur w ekstremalnych warunkach, takich jak gęsta mgła czy intensywne opady deszczu. Są jednak droższe i bardziej wymagające w utrzymaniu z uwagi na potrzebę chłodzenia kriogenicznego, które pochłania znaczne ilości energii.

Kamery termowizyjne są wykorzystywane w różnych zakresach podczerwieni, takich jak SWIR (Short-Wave Infrared), MWIR (Mid-Wave Infrared) i LWIR (Long-Wave Infrared), co pozwala na dostosowanie ich funkcji do specyficznych zastosowań[39], [40], [41]:

- SWIR (900–2500 nm) – jest używany do detekcji przez mgłę, dym i cienkie chmury, co ma znaczenie w ratownictwie i zastosowaniach wojskowych.
- MWIR (3000–5000 nm) – charakteryzuje się wysoką czułością termiczną i wymaga chłodzenia, co sprawia, że jest przydatny do detekcji źródeł ciepła i analiz termicznych w trudnych warunkach.
- LWIR (8000–14 000 nm) – nie wymaga chłodzenia i jest stosunkowo tani w produkcji. Jest używany do wykrywania ciepłokrwestych obiektów i wykrywania intruzów w ciemności.





Rysunek 5. Porównanie obrazów z kamer SWIR, MWIR, LWIR [42].

3.1.2.3 Kamery hiperspektralne

Kamery hiperspektralne rejestrują obrazy w szerokim zakresie długości fal, dzieląc je na setki wąskich pasm spektralnych, co pozwala na uzyskanie szczegółowych informacji o składzie materiałowym obserwowanych obiektów. Dzięki temu można analizować nawierzchnię

drogi, identyfikować różne materiały oraz wykrywać specyficzne obiekty w oparciu o ich unikalne podpisy spektralne. W rolnictwie kamery hiperspektralne są wykorzystywane do monitorowania stanu roślin, a w monitoringu środowiskowym – do oceny jakości wód lub stanu gleby. Kamery hiperspektralne są bardziej kosztowne i wymagają zaawansowanych algorytmów przetwarzania, ponieważ ilość danych spektralnych jest duża, a analiza czasochłonna [43].



Rysunek 6. Obrazy z kamery hiperspektralnej Cubert Q285 - kolorowe zdjęcie to fuzja danych ze wszystkich długości fal w celu uzyskania obrazu pseudo RGB, poniżej zdjęcia w długości fal od 450 nm do 626 nm

3.1.2.4 Zalety i ograniczenia kamer

Każdy typ kamery ma swoje unikalne zalety. Kamery światła widzialnego dostarczają szczegółowych obrazów o wysokiej rozdzielczości, umożliwiając identyfikację kolorów i kształtów, co jest ważne w interpretacji znaków drogowych i sygnalizacji świetlnej. Kamery termowizyjne działają niezależnie od oświetlenia, co jest szczególnie przydatne w warunkach nocnych lub w ograniczonej widoczności, np. we mgle. Z kolei kamery hiperspektralne

pozwalają na uzyskanie precyzyjnych informacji o składzie materiałowym otoczenia, co może mieć kluczowe znaczenie w analizach terenowych i środowiskowych.

Kamery mają jednak swoje ograniczenia. Kamery światła widzialnego są podatne na warunki pogodowe i zmienność oświetlenia, co może wpływać na jakość zbieranych danych. Kamery termowizyjne bolometryczne mają niższą czułość niż ich chłodzone odpowiedniki, a kamery hiperspektralne wymagają zaawansowanego przetwarzania danych, co może być kosztowne i czasochłonne.

3.1.2.5 Integracja kamer w systemach autonomicznych

W pojazdach autonomicznych różne typy kamer są stosowane w sposób komplementarny. Kamery światła widzialnego dostarczają podstawowych informacji o strukturze otoczenia, kamery termowizyjne umożliwiają detekcję obiektów w warunkach słabej widoczności, a kamery hiperspektralne pozwalają na szczegółową analizę materiałową terenu [44]. Dzięki fuzji danych z różnych typów kamer możliwe jest tworzenie bardziej kompleksowych i dokładnych modeli otoczenia, co wspiera bezpieczną i efektywną nawigację pojazdów autonomicznych. W kontekście badań prowadzonych w tej pracy, kamery hiperspektralne mają szczególne znaczenie i zostaną omówione bardziej szczegółowo w następnym podrozdziale.

3.2 Kamery hiperspektralne, opis i zastosowania

Kamery hiperspektralne to jedno z najbardziej zaawansowanych narzędzi analizy spektralnej, zdolne do rejestrowania obrazów w setkach wąskich pasm spektralnych (np. dla w przedziale 450 nm do 950 nm, z podziałem co 4 nm, pasmo 1 nm), co umożliwia szczegółową identyfikację materiałów na poziomie chemicznym i strukturalnym. W przeciwieństwie do tradycyjnych kamer multispektralnych, które ograniczają się do kilku szerokich pasm, kamery hiperspektralne pozwalają na precyzyjną analizę unikalnych właściwości spektralnych obiektów, co rewolucjonizuje wiele dziedzin nauki i przemysłu [45], [46].

3.2.1 Zastosowania w różnych dziedzinach

3.2.1.1 *Rolnictwo*

Kamery hiperspektralne są kluczowym narzędziem w rolnictwie precyzyjnym, gdzie umożliwiają szczegółowe monitorowanie stanu zdrowia roślin i wykrywanie problemów na wczesnym etapie. Dzięki analizie spektralnej liści możliwa jest ocena zawartości chlorofilu, który jest wskaźnikiem zdrowia roślin. Obrazowanie hiperspektralne pozwala na identyfikację stresu roślinnego wywołanego przez suszę, braki składników odżywczych lub infekcje patogenami, co umożliwia szybką interwencję. W ramach rolnictwa precyzyjnego kamery hiperspektralne umożliwiają tworzenie szczegółowych map różnorodności upraw, identyfikację obszarów o zróżnicowanej produktywności i planowanie działań takich jak nawożenie czy nawadnianie. Pozwalają także na śledzenie wzrostu roślin w czasie, co jest kluczowe dla planowania zbiorów i optymalizacji cykli uprawnych [47], [48], [49].

3.2.1.2 *Ekologia i ochrona środowiska*

W ekologii kamery hiperspektralne wspierają monitorowanie różnorodności gatunkowej w ekosystemach. Ich zdolność do rozróżniania subtelnych różnic w składzie roślinnym pozwala na identyfikację inwazyjnych gatunków roślin, co ma znaczenie dla ochrony lokalnych ekosystemów. Obrazowanie hiperspektralne jest również wykorzystywane do badania reakcji ekosystemów na zmiany klimatyczne, takie jak wzrost temperatury lub zmiany wilgotności. Dane te pomagają naukowcom prognozować długoterminowe zmiany w środowisku naturalnym i planować działania ochronne [50], [51], [52].

3.2.1.3 *Geologia i eksploracja surowców*

Kamery hiperspektralne są powszechnie stosowane w geologii, gdzie służą do mapowania składu mineralnego powierzchni Ziemi. Umożliwiają identyfikację różnych typów skał i minerałów, co jest szczególnie przydatne w eksploracji złóż surowców, takich jak rudy metali. Analiza hiperspektralna jest wykorzystywana do wykrywania potencjalnych złóż surowców oraz monitorowania procesów erozji i osuwisk, co ma znaczenie dla oceny stabilności terenu w projektach inżynierskich i górniczych [53], [54].

3.2.1.4 Medycyna

W medycynie kamery hiperspektralne otwierają nowe możliwości diagnostyczne. Dzięki zdolności do rozróżniania różnych tkanek na podstawie ich unikalnych charakterystyk spektralnych, mogą być stosowane do wczesnego wykrywania zmian patologicznych, takich jak nowotwory. Analiza hiperspektralna pozwala na identyfikację biomarkerów nowotworowych, co wspiera wczesną diagnostykę i zwiększa skuteczność leczenia. Kamery hiperspektralne mogą być także wykorzystywane podczas zabiegów chirurgicznych, aby precyzyjnie określić granice nowotworów [55], [56].

3.2.1.5 Obronność i bezpieczeństwo

W obszarze bezpieczeństwa i obrony kamery hiperspektralne służą do detekcji materiałów wybuchowych oraz substancji chemicznych, co jest kluczowe dla ochrony przed zagrożeniami terrorystycznymi. Dzięki zdolności do rozróżniania materiałów na poziomie chemicznym kamery te mogą identyfikować ukryte obiekty i zagrożenia, co jest nieocenione w operacjach wojskowych oraz działaniach ratunkowych [57].

3.2.2 Budowa kamer hiperspektralnych

Budowa kamer hiperspektralnych różni się w zależności od ich typu, co wpływa na specyficzne zastosowania.

Kamery matrycowe (snapshot) – Kamery te jednocześnie rejestrują dane przestrzenne i spektralne dla całej sceny. Matryca detektorów pozwala uchwycić pełny obraz w jednym momencie, co jest szczególnie przydatne w sytuacjach wymagających szybkiego rejestrowania dynamicznych scen, takich jak monitoring z dronów czy analiza procesów biologicznych w medycynie. Kamery matrycowe wykorzystują często dyspersję pryzmatyczną lub filtry Fabry-Perot, które pozwalają na dokładną separację pasm spektralnych [58], [59].

Kamery linijkowe (pushbroom) – Działają na zasadzie skanowania sceny linią po linii, rejestrując dane spektralne dla każdej linii osobno. Wyposażone są w jednowymiarowy detektor oraz mechanizm skanujący, co umożliwia uzyskanie bardzo wysokiej rozdzielczości

spektralnej. Kamery linijkowe są szczególnie użyteczne w teledetekcji satelitarnej i lotniczej, a także w przemyśle, np. do kontroli jakości na taśmach produkcyjnych [60].

3.2.3 Różnice i zastosowania

Kamery matrycowe i linijkowe różnią się pod względem konstrukcji i sposobu rejestrowania danych. Kamery matrycowe są bardziej wszechstronne i szybkie, co czyni je idealnymi w zastosowaniach, gdzie wymagana jest natychmiastowa rejestracja całego pola widzenia, np. w badaniach medycznych lub dynamicznym monitoringu środowiska. Z kolei kamery linijkowe oferują wyższą rozdzielczość spektralną i sprawdzają się w teledetekcji dużych obszarów, gdy możliwe jest zorganizowanie ruchu liniowego względem obiektu skanowanego, co jest szczególnie korzystne w przemyśle oraz teledetekcji.

3.2.3.1 *Znaczenie kamer hiperspektralnych w badaniach nad autonomią i przejezdnością terenu*

Kamery hiperspektralne stanowią zaawansowane narzędzie analizy spektralnej, które znajduje szerokie zastosowanie w projektach realizowanych przez Łukasiewicz-PIAP, zwłaszcza w kontekście badania autonomii pojazdów lądowych i oceny przejezdności terenu. W projektach takich jak ATENA i HUNTeR kamery hiperspektralne umożliwiają szczegółową analizę nawierzchni terenu, identyfikując właściwości materiałowe podłoża oraz potencjalne przeszkody. Dane hiperspektralne dostarczają informacji o składzie materiałowym, co pozwala na klasyfikację nawierzchni pod kątem ich przejezdności i przewidywania interakcji pojazdu z różnymi rodzajami podłoża, takimi jak miękkie grunty, kamienie czy roślinność. Dzięki tej technologii możliwe jest bardziej precyzyjne dostosowanie tras pojazdów autonomicznych do warunków terenowych oraz unikanie zagrożeń, co wspiera niezawodność i bezpieczeństwo misji w złożonym środowisku [44].

3.3 Badania podstawowe w zakresie robotyki mobilnej

W obszarze robotyki mobilnej obszerna praca [61] autorstwa Sebastiana Thruna, Wolframa Burgarda i Dietera Foxa stanowi kluczowe źródło wiedzy dotyczące metod, planowania trasy oraz mapowania terenu. Autorzy przedstawiają szeroki zakres algorytmów lokalizacji, w tym Monte Carlo Localization (MCL), filtr Kalmana oraz metody Markov Localization,

podkreślając ich zastosowanie w rzeczywistych warunkach operacyjnych. Dzięki probabilistycznemu podejściu do niepewności sensorycznej praca stanowi fundament teoretyczny dla współczesnych systemów autonomicznych. W kontekście mapowania i lokalizacji, monografia szczegółowo omawia zagadnienie SLAM (Simultaneous Localization and Mapping), koncentrując się na metodach fuzji danych z różnych sensorów. Autorzy prezentują przykłady mapowania terenów miejskich oraz otwartych przestrzeni, w tym opisują eksperyment w Victoria Park w Sydney. W badaniu tym zastosowano samochód typu pick-up, wyposażony w LIDAR 2D, system GNSS oraz system odometrii kół, fuzja tych danych pozwoliła na precyzyjną lokalizację pojazdu. Analiza wyników pokazuje skuteczność metod probabilistycznych w ograniczaniu błędów wynikających z szumu danych sensorycznych i niepewności modelu ruchu. Istotnym zagadnieniem poruszonym w pracy jest również analiza mapowania w przestrzeni trójwymiarowej. Autorzy porównują zalety i ograniczenia map 2D oraz 3D, wskazując, że choć mapy 2D są bardziej efektywne pod względem obliczeniowym, to mapy 3D zapewniają dokładniejsze odwzorowanie rzeczywistego środowiska, co jest kluczowe dla robotów poruszających się w skomplikowanych przestrzeniach. W zakresie planowania trajektorii i sterowania ruchem praca przedstawia metody bazujące na eksploracji przestrzeni stanów, takie jak Rapidly-exploring Random Trees (RRT) oraz algorytm A*. Zastosowanie tych technik pozwala robotom na unikanie kolizji oraz wyznaczanie optymalnych tras w dynamicznych środowiskach. Praca stanowi jedno z najważniejszych opracowań w dziedzinie robotyki mobilnej, łącząc solidną podbudowę teoretyczną z licznymi eksperymentami i studiami przypadków. Dzięki precyzyjnemu omówieniu zagadnień związanych z lokalizacją, mapowaniem oraz planowaniem ruchu, praca jest źródłem wiedzy dla inżynierów i badaczy zajmujących się autonomicznymi systemami mobilnymi.

Artykuł [62], którego autorami są między innymi Wolfram Burgard oraz Roland Siegwart, stanowi ważne opracowanie dotyczące autonomicznego mapowania dla samochodów autonomicznych, w którym jednym z zagadnień jest klasyfikacja terenu pod kątem przejezdności. W pracy są wyróżnione trzy klasy terenu: teren przejezdny, teren nieprzejezdny oraz przeszkoda pionowa. Autorzy przedstawili system fuzji sensorycznej, który integruje dane z LIDAR-u, odometrii i GNSS w celu tworzenia dokładnych map. Praca pokazuje również skuteczność metod probabilistycznych w redukcji niepewności i aktualizacji map w czasie rzeczywistym. Zastosowane podejście jest istotne dla rozwoju systemów

autonomicznych, które muszą dynamicznie analizować środowisko, dostosowując trajektorię jazdy w oparciu o bieżące dane. Badania te mają znaczący wpływ na rozwój technologii autonomicznych pojazdów oraz systemów robotyki mobilnej stosowanych w przestrzeniach miejskich.

3.4 Zestawienie badań w zakresie autonomii robotów mobilnych pracujących złożonych i otwartych terenach

Wraz z rosnącym zapotrzebowaniem na autonomiczne systemy robotów mobilnych — wspierające szerokie spektrum zadań od akcji ratowniczych po inspekcje infrastruktury — obserwuje się intensywny rozwój różnorodnych technologii i metod. Niniejszy przegląd koncentruje się na najnowszych osiągnięciach w dziedzinie lokalizacji i mapowania (SLAM), planowania ruchu, sterowania robotami o różnych konfiguracjach oraz interoperacyjności systemów bezzałogowych.

3.4.1 Systemy SLAM i skanowania 3D w terenach otwartych

W obszarze lokalizacji i mapowania opartego na algorytmach SLAM (Simultaneous Localization and Mapping) kluczowe znaczenie ma łączenie danych z różnych sensorów — takich jak LIDAR, kamera RGB-D czy IMU. Dr hab. inż. Janusz Będkowski w swoich publikacjach [63], [64], [65], [66] opisuje wykorzystanie takiej fuzji w terenach o dużej zmienności środowiskowej. Metody te umożliwiają jednoczesne tworzenie map 3D i precyzyjną lokalizację pojazdu, co jest szczególnie użyteczne w operacjach ratunkowych oraz podczas inspekcji trudno dostępnych obiektów.

W kontekście praktycznych zastosowań dr hab. inż. Janusz Będkowski przedstawia również systemy skanowania 3D z wykorzystaniem robotów mobilnych do lokalizacji w terenach leśnych. Dzięki analizie i przetwarzaniu chmur punktów możliwe jest uzyskanie szczegółowych modeli lasów i drzew do późniejszej analizy z wykorzystaniem algorytmów sztucznej inteligencji do ewentualnego wykrywania chorób drzew, badania tego typu są szczegółowo opisane w [67]. Tego typu projekty pokazują, jak technologia SLAM wspiera automatyzację w dziedzinie inwentaryzacji i kontroli stanu lasów.

Michał Nowicki, w pracy [68], skupił się na badaniach nad SLAM opartym na cechach dla robotów wielonożnych. Wykorzystując sensory RGB-D, autor przeprowadził eksperymenty, które potwierdziły możliwość jednoczesnej lokalizacji i mapowania w złożonych środowiskach. Publikacja podkreśla znaczenie odpowiedniego doboru algorytmów i właściwego przetwarzania danych sensorycznych dla poprawy dokładności nawigacji.

Warto wspomnieć o pracy [69], [70] przedstawiającej zastosowanie metod SLAM (Simultaneous Localization and Mapping) w kontrolowaniu autonomicznych robotów mobilnych. Publikacja ta dostarcza kompleksowego przeglądu technik SLAM i ich implementacji w trudnym terenie.

Z istotnych publikacji należy również wymienić obszerną pracę [71] autorstwa Cyrilla Stachnissa opisującą algorytmy SLAM dla robotów autonomicznych w tym z uwzględnieniem środowiska dynamicznego.

3.4.2 Budowanie mapy i nawigacja w terenie złożonym

W kontekście robotów wielonożnych pracujących w złożonym terenie warto również zaznaczyć publikację [72] Dominika Beltera, który opisał system umożliwiający robotom krocącym samodzielne przemieszczanie się po nierównym terenie. Kluczowym elementem było opracowanie algorytmu tworzenia lokalnych map wysokościowych oraz precyzyjnego wyboru punktów podparcia, co pozwala na stabilny i bezpieczny ruch robota nawet w trudnych warunkach.

Dodatkowo, praca [73] porusza zagadnienie adaptacyjnego planowania ruchu w trudnych warunkach terenowych. Zaletą omawianego podejścia jest możliwość dynamicznego dostosowywania trajektorii na podstawie danych z sensorów. Jednocześnie konieczna jest jednak wysoka moc obliczeniowa, co może stanowić wyzwanie w zastosowaniach wymagających pracy w czasie rzeczywistym.

3.4.3 Przejezdność

Przejezdność terenu to kluczowy czynnik wpływający na zdolność autonomicznych robotów do poruszania się w trudnych i nieznanym środowiskach. Roboty kołowe, gąsienicowe i kroczące napotykać na liczne wyzwania związane z pokonywaniem przeszkód, stromych wzniesień i nierówności terenu. Problem przejezdności terenu jest poruszony i sparametryzowany w pracy [74].

Jednymi z najbardziej zaawansowanymi badaniami jakie są opublikowane z dziedziny nawigacji robotów z analizą przejezdności w terenie złożonym są badania prowadzone na ETH Zürich, przez m.in. Martina Wermelinger [18]. Skupił się on, na ocenie przejezdności terenu i planowaniu nawigacji dla robotów kroczących. Opracował ramy planowania bezpiecznych i efektywnych ścieżek dla robotów w nierównym terenie, pozwalając im na wykorzystanie unikalnych zdolności pokonywania przeszkód. Jego podejście obejmowało analizę cech terenu, takich jak nachylenie, nierówności i stopnie, w celu stworzenia mapy przejezdności. Ta mapa była następnie wykorzystywana do oceny kosztów poszczególnych kroków robota w zależności od jego zdolności do pokonywania przeszkód. Wermelinger zastosował algorytm RRT* do optymalizacji długości i bezpieczeństwa planowanej ścieżki.

Dodatkowo, Wermelinger współpracował przy tworzeniu oprogramowania do oceny przejezdności terenu, dostępnego na platformie GitHub. Projekt ten, nazwany "traversability_estimation" [19], dostarcza narzędzi do analizy i oceny terenu pod kątem nawigacji robotów kroczących. Oprogramowanie to umożliwia integrację z systemami robotycznymi, wspierając autonomiczne planowanie ruchu w złożonych środowiskach.

Badania prowadzone w ETH Zürich [75] w zakresie oceny przejezdności terenu mają na celu rozwój autonomicznych systemów robotycznych zdolnych do poruszania się w różnorodnych i wymagających warunkach terenowych. Prace te obejmują zarówno teoretyczne aspekty modelowania i analizy terenu, jak i praktyczne implementacje w rzeczywistych robotach kroczących. Dzięki tym badaniom możliwe jest tworzenie bardziej zaawansowanych i niezawodnych robotów, które mogą znaleźć zastosowanie w misjach ratunkowych, eksploracji czy pracach budowlanych w trudnodostępnych miejscach.

Kolejnymi ważnymi publikacjami są [76], [77], które opisują ocenę powierzchni podparcia nogi robota kroczącego. Główną innowacją zaprezentowaną w publikacji jest opracowanie systemu, który umożliwia detekcję i klasyfikację materiałów podłoża na podstawie analizy trzech kluczowych cech fizycznych: twardości, przyczepności i stabilności. Podejście to opiera się na zaawansowanym przetwarzaniu danych z różnych źródeł sensorycznych, w tym lidarów, kamer RGB-D oraz czujników siły zamontowanych w nogach robota, co pozwala na wieloaspektową ocenę powierzchni w czasie rzeczywistym.

3.4.4 Różne podejścia do przejezdności terenu

W literaturze dotyczącej autonomicznych pojazdów lądowych szczególnie poruszających się w środowiskach terenowych, analiza przejezdności jest jednym z kluczowych aspektów badań [78]. Wyznaczanie obszarów przejezdnych wymaga zaawansowanej analizy danych sensorycznych, umożliwiającej identyfikację nawierzchni nadających się do poruszania się pojazdu. Podejścia do tego problemu można podzielić na kilka kategorii, różniących się zastosowanymi technologiami oraz metodologią.

Pomiary materiałów otoczenia mogą być wykonywane metodą dotykową i bezdotykową. Metoda dotykowa została opisana w raporcie NATO STO AVT – tam została wykorzystana specjalnie zaprojektowana aparatura pomiarowa, o nazwie „bewameter” i jej celem jest zbadanie nośności oraz podatności gruntu na ścinanie. Metoda ta daje informacje o parametrach podłoża, w którym może zostać zaplanowana trasa natomiast wprost nie mówi o materiale z jakiego otoczenia się składa [79], [80].



Rysunek 7. Bewameter [80]

Bezdotykowe podejścia obejmują:

- spektroskopię i analizę hiper- i multispektralną – metody te wykorzystują unikalne właściwości spektralne materiałów, co pozwala na ich identyfikację na podstawie charakterystycznych pasm absorpcji. Kamery hiperspektralne i multispektralne rejestrują szeroki zakres długości fal, umożliwiając szczegółową analizę materiałową terenu, co sprawdza się przy identyfikacji składników organicznych, wilgotności gleby i obecności minerałów.
- Radar Penetracyjny (GPR) – GPR jest techniką, która za pomocą fal radiowych penetruje podłoże i analizuje jego struktury podpowierzchniowe. Wykorzystywana jest do oceny właściwości takich jak gęstość, wilgotność czy skład warstw geologicznych, co jest kluczowe przy określaniu przejezdności.

Przykładem metody z wykorzystaniem algorytmów sztucznej inteligencji może być segmentacja semantyczna obrazu z kamery światła widzialnego. Opisana dość szeroko w [20]. Artykuł prezentuje metodę analizy przejezdności terenu w warunkach nieustrukturyzowanych, integrującą segmentację semantyczną z obrazu z kamery RGB, z analizą geometrii terenu.

Kluczowym elementem przedstawionego badania jest wykorzystanie segmentacji semantycznej, umożliwiającej klasyfikację typów terenu na podstawie obrazów z kamery RGB. Każdy piksel obrazu jest przyporządkowany do jednej z zdefiniowanych kategorii terenu, takich jak trawa, kałuża czy błoto, co pozwala na dokładniejsze odwzorowanie środowiska. W badaniach zastosowano dwie architektury sieci neuronowych: Gated-SCNN oraz ERFNet, przy czym ERFNet została wybrana do ostatecznego wdrożenia ze względu na wyższą wydajność operacyjną, istotną dla mobilnych systemów autonomicznych.

3.4.5 Mobilność

Badania nad mobilnością pojazdów w terenie prowadzone są od wielu lat, a jednym z ważniejszych projektów w tej dziedzinie jest Next-Generation NATO Reference Mobility Model (NG-NRMM), realizowany przez NATO Science and Technology Organisation (STO) w ramach projektu AVT-248 [79], [81]. Celem projektu jest opracowanie nowej generacji modelu przejeźdźności terenu dla pojazdów lądowych, zarówno kołowych, gąsienicowych, jak i załogowych oraz autonomicznych. Model NG-NRMM ma na celu stworzenie narzędzia, które umożliwi bardziej precyzyjne przewidywanie mobilnych dla pojazdów w zróżnicowanych warunkach terenowych, co jest kluczowe dla operacyjnej skuteczności i bezpieczeństwa załóg.

Zgodnie z definicją z [80] - „Mobilność pojazdu lądowego to zdolność do szybkiego poruszania się po różnych nawierzchniach i terenach. Jest ona określana przez maksymalną osiągalną prędkość między dwoma punktami w danym obszarze, co stanowi kluczowy wskaźnik uwzględniający złożone interakcje między pojazdem a jego środowiskiem operacyjnym”.

W przypadku pojazdów załogowych ocena zdolności do pokonania terenu przed planowaniem misji jest kluczowa dla bezpieczeństwa załogi. Niewłaściwe planowanie może prowadzić do zakopania pojazdu, co naraża załogę na dodatkowe ryzyko w warunkach bojowych. Choć autonomiczne pojazdy eliminują to zagrożenie personalne, problem zakopania nadal skutkuje niepowodzeniem misji i potencjalną utratą kosztownego sprzętu, co pociąga za sobą straty finansowe i operacyjne.

Dla wojska istotne jest dokładne przewidywanie mobilności pojazdów w różnych warunkach terenowych, co jest niezbędne dla skutecznego planowania i realizacji misji. Kluczową rolę odgrywa zdolność oceny czy pojazdy będą w stanie poruszać się po danym terenie – jest to fundament skuteczności operacyjnej i bezpieczeństwa. Rozwój nowoczesnych modeli, takich jak NG-NRMM, zakłada integrację podejścia fizykalnego zamiast wyłącznie danych empirycznych. Takie podejście pozwala na precyzyjne i niezawodne przewidywania zdolności mobilnych, co przekłada się na lepsze wsparcie operacyjne i ulepszenia w projektowaniu pojazdów.

Przed wprowadzeniem NG-NRMM korzystano z klasycznego NRMM, który miał kilka istotnych ograniczeń: zależność od lokalnych pomiarów gleby, brak analizy dynamicznej pojazdów oraz ograniczone możliwości modelowania w 3D. Te ograniczenia sprawiały, że modelowanie mobilności pojazdów w różnorodnych, zmiennych warunkach terenowych było trudne, a w niektórych przypadkach wręcz niemożliwe. Nowy model NG-NRMM ma na celu zwiększenie elastyczności i dokładności przewidywań, co umożliwia bardziej kompleksowe planowanie operacyjne i wsparcie projektowania nowych pojazdów.

Ważnym elementem nowego podejścia do mobilności jest zastosowanie metod stochastycznych, które pozwalają na ocenę wpływu niepewności na przewidywaną mobilność pojazdów. Dzięki temu można lepiej zarządzać ryzykiem wynikającym z nieprzewidywalnych warunków terenowych. Ponadto integracja technologii autonomicznych oraz zaawansowanych systemów kontroli – takich jak ABS (system zapobiegający blokowaniu kół przy hamowaniu), TCS (kontrola trakcji) oraz systemy aktywnego zawieszenia – pozwala na dalsze zwiększenie adaptacyjności pojazdów do zmieniających się warunków.

Dokładne planowanie misji dla załogowych pojazdów wojskowych ma bezpośredni wpływ na ich bezpieczeństwo i skuteczność operacyjną. Przewidywanie, które obszary są dostępne i które trasy są optymalne, minimalizuje ryzyko utknięcia w trudnym terenie, co mogłoby prowadzić do niebezpiecznych sytuacji i strat operacyjnych. Model NG-NRMM ma na celu dostarczenie bardziej wiarygodnych danych wspierających decyzje na poziomie taktycznym i strategicznym, co bezpośrednio wpływa na zwiększenie skuteczności i bezpieczeństwa operacji wojskowych.

3.4.6 Zdolność terenowa

Analizując bezzałogowe pojazdy lądowe (UGV), istotne jest zrozumienie ich konstrukcji i zdolności terenowych. Pojazdy te składają się z bazy mobilnej, której możliwości terenowe zależą od rodzaju zastosowanego napędu – kołowego, gąsienicowego lub kroczącego. Zdolność terenowa, zwłaszcza w kontekście UGV, obejmuje zdolność pojazdów do poruszania się po zróżnicowanych i trudnych powierzchniach, takich jak podłoża o niskiej nośności, niskim współczynniku tarcia oraz tereny z licznymi przeszkodami. Rodzaj napędu znacząco wpływa na te możliwości. Na przykład napędy gąsienicowe charakteryzują się niskim naciskiem na podłoże, co sprawdza się na miękkich gruntach, lecz wykazują wysoki opór toczenia i duże zużycie energii. Natomiast napędy kołowe są lżejsze i bardziej energooszczędne, ale mogą mieć problemy z pokonywaniem bardzo nierównych terenów. Konstrukcja i konfiguracja układu jezdnego, w tym rozstaw osi, wielkość kół lub gąsienic oraz system zawieszenia, mają kluczowe znaczenie dla zdolności pojazdu do pokonywania przeszkód terenowych. Oprócz konstrukcji bazy mobilnej na zdolność terenową wpływają także parametry, jak masa, maksymalna prędkość, przyspieszenie oraz długość pracy na baterii – czynniki te determinują m.in. długość misji pojazdu. Optymalizacja rozkładu nacisków na podłoże jest kluczowa dla zdolności poruszania się po miękkim terenie bez nadmiernego zagłębiania się, co z kolei umożliwia realizację zadań w trudnym środowisku. UGV o wysokiej zdolności terenowej znajdują zastosowanie w misjach ratunkowych, rolnictwie precyzyjnym, eksploracji kosmicznej oraz operacjach wojskowych. Każde z tych zastosowań wymaga dostosowania pojazdu do specyficznych wymagań terenowych, co podkreśla znaczenie badań nad mobilnością w terenie oraz ciągłego doskonalenia technologii napędów i systemów kontroli. Zdolność terenowa UGV obejmuje zarówno mechaniczne aspekty konstrukcji, jak i zaawansowane systemy nawigacyjne. Dalszy rozwój tej dziedziny jest kluczowy dla zwiększenia efektywności i wszechstronności bezzałogowych pojazdów lądowych w różnych środowiskach i zastosowaniach [82], [83].

3.4.7 Segmentacja semantyczna w terenie off-road

W zakresie autonomii pojazdów lądowych (UGV) w terenie off-road, wkład wnosi Konrad Małek z Łukasiewicz – Przemysłowego Instytutu Motoryzacji (PIMOT) [84]. Autor wraz ze współautorami przedstawiają otwarty zestaw danych OffRoadSynth oraz podejście do semantycznej segmentacji obrazów z użyciem sieci neuronowych pretrenowanych na danych

syntetycznych. Technika ta pozwala na lepsze rozpoznawanie elementów otoczenia w surowych warunkach terenowych, co wpływa na zwiększenie autonomii pojazdu przy jednoczesnym zachowaniu wysokiej precyzji w trudnych warunkach oświetleniowych i terenowych.

3.4.8 Algorytmy sterowania robotami mobilnymi o różnych konfiguracjach napędowych

Wkład prof. Macieja Marcina Michałka dotyczy przede wszystkim algorytmów sterowania robotów z napędem różnicowym [85]. Kluczowym elementem jest metoda sterowania oparta na orientacji pól wektorowych (VFO), która w uproszczeniu pozwala pojazdowi „podążać” za wirtualnymi liniami sił kierującymi go do celu.

W kolejnych pracach dla pojazdów z przyczepami [86], [87] Michałek analizuje problemy nieminimalnofazowości (ang. non-minimum-phase) w układach wieloprzyczepowych oraz proponuje podejścia skalowalne, przydatne np. w logistyce czy zarządzaniu flotą autonomicznych pojazdów. Omawiane metody stanowią fundament rozwoju zaawansowanych układów sterowania, jednak pełne zastosowanie w przemyśle wymaga dalszych badań nad wydajnością obliczeniową i odpornością na zakłócenia.

3.4.9 Interoperacyjność systemów bezzałogowych

Jakub Główka z Sieci Badawczej Łukasiewicz – Przemysłowego Instytutu Automatyki i Pomiarów (PIAP) podejmuje temat interoperacyjności bezzałogowych systemów lądowych (UGS) i systemów dowodzenia i kontroli (C2) [88]. Zastosowanie standardów takich jak Joint Architecture for Unmanned Systems (JAUS) czy Interoperability Profile (IOP) jest kluczowe w operacjach wielonarodowych, gdzie systemy różnych producentów muszą ze sobą współpracować. W innym projekcie [89] Sprońska i Główka opisują z kolei mobilny system nadzoru TALOS, przeznaczony do autonomicznego patrolowania i ochrony granic. Choć technologia ta wykazuje duży potencjał w zwiększaniu bezpieczeństwa, bariery stanowią kwestie związane z niezawodnością łączności i integracją z innymi systemami.

3.4.10 Zastosowania wojskowe i inżynieryjne

Badania z Wojskowej Akademii Technicznej wnoszą istotny wkład w dziedzinie robotyki wojskowej [3], [90], [91] koncentrując się na lukach technologicznych w systemach

bezzałogowych pojazdów lądowych. Józef Wrona podkreśla znaczenie rozwijania zaawansowanych interfejsów człowiek-maszyna, które pozwalają na bardziej intuicyjną współpracę operatorów z robotami. Jednym z kluczowych obszarów jest opracowanie koncepcji operacji inżynierskich związanych z IED/EOD (ang. Improvised Explosive Device / Explosive Ordnance Disposal) — zespoły robotów mogą w takich działaniach znacząco obniżyć ryzyko dla personelu.

3.4.11 Adaptacyjne zachowanie robotów mobilnych

Kwestie adaptacyjnego zachowania w systemach mobilnych porusza Piotr Szynkarczyk [92]. Autor przedstawia nowatorskie podejście do problemu wyboru działania w czasie rzeczywistym, uwzględniające zmieniające się warunki otoczenia oraz niepewność danych sensorycznych. Metoda ta pozwala robotom na podejmowanie decyzji w sposób optymalny z punktu widzenia celu misji, jednocześnie utrzymując wysoki poziom bezpieczeństwa. Wyzwaniem pozostaje jednak skalowalność i integracja tych algorytmów z bardziej złożonymi systemami sterowania, zwłaszcza gdy robot działa w grupie lub w ścisłej współpracy z człowiekiem.

3.5 Przegląd zbliżonych rozwiązań

W pracy [93], opracowano system nawigacji robota mobilnego oparty na mapach semantycznych budowanych na podstawie danych z lidar 3D. Wykorzystano algorytmy klasyfikacji przestrzeni, które pozwalały na rozróżnienie klas takich jak chodnik czy trawa. Dane te integrowano z informacjami geometrycznymi, co umożliwiło robotowi nie tylko unikanie przeszkód, ale także optymalizację trasy.

W badaniu przedstawionym w [94] połączono dane z kamer oraz sensorów Lidar w celu opracowania szczegółowych map semantycznych. Wykorzystano segmentację obrazów rejestrowanych przez kamery światła widzialnego do klasyfikacji różnych typów nawierzchni, takich jak asfalt czy asfalt pokryty liśćmi. Następnie, połączono te dane z analizą chmury punktów, co pozwoliło na precyzyjne odwzorowanie terenu i optymalizację procesu planowania tras w skomplikowanych środowiskach terenowych.

Inne podejście, zaprezentowane w [95], skupiło się na wykorzystaniu sieci neuronowych do przetwarzania obrazów i analizy trajektorii pojazdu. Dzięki temu udało się uzyskać dokładniejsze odwzorowanie terenów trudnych do nawigacji, takich jak lasy czy obszary skaliste. Kluczowym aspektem tej metody była integracja danych wizualnych i geometrycznych, co pozwoliło na dynamiczne aktualizowanie map przejezdności w czasie rzeczywistym, co jest istotne w kontekście zmiennych warunków otoczenia.

Jednym z nowoczesnych podejść łączących dane z różnych czujników oraz wykorzystujących uczenie maszynowe jest metoda Bird's Eye View (BEV). System TerrainNet [96] zastosował tę technikę do modelowania terenu w celu wspomagania autonomicznej nawigacji w wymagających warunkach. Podejście to umożliwia przetwarzanie obrazu w taki sposób, aby odwzorowywać zarówno strukturę geometryczną, jak i semantyczną terenu w przestrzeni BEV, co przekłada się na lepsze planowanie tras. Istotnym elementem tego systemu jest proces rzutowania cech obrazu na przestrzeń BEV. TerrainNet wykorzystuje metodę „lift-splat”, w której cechy pikselowe są najpierw transformowane do przestrzeni trójwymiarowej na podstawie danych o głębokości (pochodzących z kamer stereo lub sensorów LiDAR), a następnie rzutowane na mapę BEV poprzez zastosowanie techniki miękkiej kwantyzacji. Miękką kwantyzacja ogranicza błędy projekcji, co prowadzi do bardziej dokładnego odwzorowania w czasie rzeczywistym. Wejściowe dane wizualne pochodzą zarówno z kamer mono, jak i stereo, co pozwala na uzyskanie bogatszych informacji na temat struktury terenu. Ponadto, algorytm implementuje mechanizm uzupełniania danych o głębokości (depth completion), który koryguje błędy i wypełnia luki w zbiorze danych, co jest szczególnie istotne w przypadku terenów o skomplikowanej topografii. Uzyskane mapy BEV zawierają warstwy semantyczne i geometryczne, pozwalając na odwzorowanie nie tylko samej nawierzchni, ale także elementów nadziemnych, takich jak gałęzie drzew. Integracja różnych podejść, w tym metod geometrycznych, wizyjnych i hybrydowych, odgrywa kluczową rolę w ocenie przejezdności terenu w nieustrukturyzowanych środowiskach. Takie podejście umożliwia tworzenie bardziej zaawansowanych systemów nawigacyjnych dla robotów lądowych, które lepiej adaptują się do trudnych warunków i są bardziej odporne na zmienne otoczenie.

W artykule [20] wykorzystano mapę wysokościową (2.5D) uzyskiwaną z chmury punktów LiDAR oraz danych z systemu nawigacyjnego GPS/IMU, co umożliwia uzyskanie informacji

na temat cech terenu, takich jak nachylenie, chropowatość i wysokość przeszkód. Oprócz ogólnej koncepcji systemu zawierającego analizę przejezdności z wykorzystaniem segmentacji semantycznej obrazu z kamery światła widzialnego, przedstawiono również metodę generowania mapy kosztów przejazdu, łączącej dane semantyczne i geometryczne podobnie jak w artykule którego byłem współautorem [16]. Mapa ta jest tworzona poprzez przypisanie różnym obszarom terenu kosztów przejazdu, zależnych od ich charakterystyki i właściwości geometrycznych.

W pracy [97] autorzy skupiają się na problemie przewidywania przejezdności terenu dla bezzałogowych pojazdów lądowych. Ich głównym celem jest opracowanie metody uczenia maszynowego, która nie wymaga ręcznej anotacji dużych zbiorów danych, co jest często kluczowym problemem w innych metodach. Aby to osiągnąć, wykorzystują syntetyczne dane generowane w symulacji, uczenie samonadzorowane (self-supervised learning) oraz nienadzorowaną adaptację domenową (unsupervised domain adaptation). Autorzy definiują, że teren nieprzejezdny cechuje się zbyt dużym nachyleniem terenu, występowaniem kamieni i drzew oraz występowanie błota lub piasku. Warto podkreślić, że zaproponowany system opiera się wyłącznie na kamerach RGB. Proces ekstrakcji cech realizowany jest za pomocą sieci DeepLabV2 z architekturą ResNet-101. Autorzy wskazują, że system ten przewyższa alternatywne podejścia, w tym metody oparte na wzmocnionym uczeniu się, w zakresie odporności na niepewne warunki terenowe oraz braku konieczności długotrwałego procesu trenowania.

3.6 Wnioski ze stanu wiedzy

Zaprezentowane prace wskazują, że rozwój autonomii robotów mobilnych to wielowymiarowe wyzwanie łączące zagadnienia z obszaru lokalizacji i mapowania (SLAM), planowania ruchu, zaawansowanego sterowania, interoperacyjności systemów i interfejsów człowiek–maszyna. Każda z omawianych metod wnosi nowe możliwości, ale także stawia kolejne pytania o skalowalność, niezawodność oraz integrację z istniejącą infrastrukturą.

Analiza przejezdności terenu stanowi obecnie kluczowy obszar badań nie tylko w kontekście autonomii pojazdów, lecz także dla wszystkich pojazdów wojskowych. Na współczesnym teatrze działań wojennych zdolność do szybkiego i bezpiecznego przemieszczania się po trudnym, nieprzewidywalnym terenie jest czynnikiem decydującym o sukcesie misji. Błędne

określenie stanu terenu lub przejezdności przeszkód może prowadzić do zakopania pojazdu, unieruchomienia kolumny, a w konsekwencji niepowodzenia całej operacji. Potrzeba analizy przejezdności terenu potwierdzona jest przez liczne działania w ramach projektów NATO Science and Technology Organization (STO), w szczególności projektu Next Generation NATO Reference Mobility Model (NG-NRMM) [81]. Jego celem jest opracowanie nowoczesnych metod oceny mobilności pojazdów wojskowych, zarówno kołowych, jak i gąsienicowych, uwzględniających różnorodność terenów operacyjnych oraz specyficzne wymagania współczesnych misji.

Analizując aktualny stan wiedzy, można zauważyć istnienie rozwiązań dotyczących oceny przejezdności dla różnych typów robotów mobilnych oraz algorytmów predykcji mobilności pojazdów. Wspólnym elementem tych podejść jest wykorzystanie algorytmów sztucznej inteligencji do semantycznej segmentacji obrazu otoczenia w celu pozyskania informacji o jego charakterystyce.

Jednym z przykładów budowania mapy mobilności w oparciu o pomiary fizyczne jest projekt NG-NRMM, w którym zastosowano specjalistyczne narzędzie o nazwie bewameter. Urządzenie to mierzy nośność gruntu w sposób kontaktowy. Alternatywnie, w zakresie oceny właściwości terenu bez wykorzystania algorytmów sztucznej inteligencji, stosowane są metody bazujące na pomiarach spektralnych.

Klasyczne podejścia do budowy mapy otoczenia w pojazdach autonomicznych, opisywane szeroko w literaturze, koncentrują się głównie na strukturze terenu i geometrii przeszkód, a ich źródłem są przede wszystkim dane z lidarów, radarów i kamer stereo. Tego rodzaju podejścia umożliwiają tworzenie dokładnych modeli 3D, które następnie mogą być przekształcane na mapy dwuwymiarowe do nawigacji. W przypadku terenów nieustrukturyzowanych takie podejście jest jednak niewystarczające, gdyż wymaga uwzględnienia zmieniających się warunków środowiskowych oraz właściwości materiałowych otoczenia, co może wpływać na przejezdność terenu.

Z przeglądu rozwiązań wynika, że jakość gruntu jest zwykle oceniana metodami wymagającymi kontaktu robota z podłożem. Rozpoznanie oblodzonej powierzchni w momencie, gdy robot już się na niej znajduje może być nieprzydatne z punktu widzenia sterowania (robot już wpadł w poślizg). Parametry pojazdu takie jak prędkość powinny być dostosowane do rodzaju powierzchni i określone z pewnym wyprzedzeniem. W mojej pracy skupiam się na rozwiązaniu postawionego wyżej zadania.

4. Opis teoretycznych prac własnych

W rozdziale zostaną przedstawione badania nad oceną przejezdności dla bezzałogowych platform lądowych (BPL). Na początku zostaną przedstawione badania wstępne, których celem było dopracowanie właściwego problemu do rozwiązania w tym celu przedstawiam kontekst projektów autonomii jazdy i rozwój technologii Łukasiewicz-PIAP następnie przeprowadzam testy terenowe pojazdów PIAP w celu określenia ich zdolności terenowych. W głównej części prac przedstawię rozwój metody oceny przejezdności od opartej tylko na danych geometrycznych, następnie po dodaniu danych o materiale podłoża. Ocena przejezdności będzie związana z budowaniem mapy przejezdności, ale na koniec zostanie przedstawiona optymalizacja metody do obliczania przejezdności podczas procesu planowania trasy bez konieczności obecności mapy przejezdności w systemie BPL.

4.1 Badania wstępne

Badania wstępne wymagają przedstawienia informacji dotyczących działalności Łukasiewicz-PIAP, odniesienia ich bezpośrednio do problemu badawczego oraz opisu zdolności terenowych pojazdów PIAP. Opis został opracowany tak, aby zintegrować wiedzę na temat problemu badawczego z badaniami prowadzonymi przez Dział Systemów Mobilnych (OSM) Łukasiewicz-PIAP nad systemami autonomii jazdy w pojazdach wykorzystywanych w analizach tej rozprawy doktorskiej. Poniżej przedstawiono krótkie opisy projektów realizowanych przez Łukasiewicz-PIAP, które są związane z tematyką rozprawy.

Warto zaznaczyć, że badania związane z rozprawą doktorską oraz programem doktoratu wdrożeniowego są realizowane od ostatniego kwartału 2020 roku. W związku z tym projekty ATENA, DEZROB i HUNTER [98] są zgodne tematycznie z rozprawą doktorską, a moje prace wdrożeniowe w ich ramach prowadzone były równolegle z pracami nad rozprawą. Wnioski cząstkowe z badań były wdrażane do projektów na bieżąco, co pozwoliło na osiągnięcie synergii między realizowanymi projektami a rozprawą doktorską.

4.1.1 Kontekst projektów autonomii jazdy i rozwój technologii PIAP

Realizacja projektów ATENA, HUNTeR oraz DEZROB w Łukasiewicz-PIAP stworzyła podstawy technologiczne oraz praktyczne doświadczenie w zakresie rozwoju systemów autonomii jazdy dla bezzałogowych platform lądowych (UGV). Każdy z tych projektów wniósł kluczowe elementy do rozwoju uniwersalnego sterownika autonomii, który stanowi centralny komponent technologiczny omawiany w tej pracy doktorskiej. Projekt ATENA był pierwszym krokiem w opracowaniu systemu autonomicznej jazdy dla pojazdów terenowych; w jego ramach powstał prototypowy sterownik autonomii, zdolny do nawigacji w terenach nieustrukturyzowanych na podstawie modelu otoczenia 3D. Projekt HUNTeR rozszerzył zapotrzebowanie Łukasiewicz-PIAP o algorytmy dla dużych platform mobilnych o większych możliwościach terenowych i funkcjonalnych, z dodatkowymi algorytmami wykrywania przeszkód. Z kolei projekt DEZROB rozwijał technologię autonomii w kontekście zastosowań cywilnych, adaptując sterownik do robotów przeznaczonych do autonomicznej dezynfekcji zamkniętych przestrzeni. Ćwiczenia FEX (ANAKONDA23 FEX oraz FEX-24) stanowiły okazję do przetestowania platformy PIAP HUNTeR w rzeczywistych scenariuszach wojskowych i oceny jej przydatności w operacjach wspierających Siły Zbrojne RP.

Sterownik autonomii, wywodzący się z doświadczeń zdobytych w tych projektach, ewoluował od prototypu przeznaczonego do testów na otwartym terenie po zaawansowane urządzenie mobilne zdolne do pracy w trudnych warunkach środowiskowych, wyposażone w nowoczesne komponenty obliczeniowe i chłodzenie cieczą. Zebrane podczas tych projektów doświadczenia, w tym obserwacje związane z odpornością systemu na fałszywe wykrycia przeszkód i wymagania dotyczące operacji w terenach nieustrukturyzowanych, stanowiły podstawę do rozwoju algorytmów autonomii jazdy. Wnioski te wykorzystano w ramach badań do niniejszej rozprawy doktorskiej, gdzie kluczową rolę odgrywa ocena przejezdności terenu, niezbędna do realizacji autonomicznych misji w zróżnicowanych środowiskach.

4.1.1.1 *Podejście do zagadnienia autonomii jazdy w Dziale systemów mobilnych (OSM) Łukasiewicz-PIAP*

Algorytmy autonomii jazdy są złożone już w przypadku autonomicznych pojazdów poruszających się po autostradach czy w miastach, gdzie drogi są najczęściej dobrze oznakowane, a pojazdy korzystają z wyraźnych pasów ruchu, znaków drogowych i

dokładnych map ulic. W klasycznym systemie autonomii zadaniem pojazdu jest przemieszczanie się od punktu do punktu, z zachowaniem ustalonych zasad ruchu, takich jak ograniczenia prędkości i sygnały drogowe. W miarę możliwości systemy te uwzględniają również inne pojazdy, które mogą poprawiać płynność jazdy (np. poprzez podążanie za pojazdem na autostradzie). W środowisku nieustrukturyzowanym pojawia się konieczność rozdzielenia algorytmów na dwa poziomy: lokalny, który opiera się na budowanej w czasie rzeczywistym mapie najbliższego otoczenia pojazdu, oraz globalny, który wykorzystuje mapę topograficzną lub terenową do planowania trasy w szerszym kontekście [99].

Algorytmy autonomii lokalnej muszą dynamicznie tworzyć mapę otoczenia, która posłuży do analizy przejezdności terenu i wyznaczenia optymalnej ścieżki. Oznacza to nie tylko klasyfikację przeszkód pod kątem geometrii, ale także ocenę ich przejezdności, szczególnie w przypadku elementów takich jak wysoka trawa, rzeki, błotniste tereny czy śnieg. Algorytm autonomii lokalnej musi stale dostosowywać prędkość i kierunek jazdy w oparciu o zmienną geometrię terenu, przeszkody i aktualne warunki pogodowe, które mogą znacząco wpłynąć na możliwości pojazdu. Na przykład intensywny deszcz może ograniczyć przyczepność podłoża, a śnieg – utrudnić dokładne odwzorowanie modelu świata na mapie lokalnej. Co więcej, wszystkie obliczenia muszą być wykonywane w czasie rzeczywistym, co stanowi istotne wyzwanie.

System autonomii lokalnej koncentruje się zatem na bezpośrednim otoczeniu robota, obliczając krótkoterminowe trasy i reagując na przeszkody w miarę ich pojawiania się. System autonomii globalnej natomiast planuje długoterminowe trasy, biorąc pod uwagę cele misji oraz topografię terenu. Skuteczne działanie wymaga współpracy obu systemów, aby robot mógł dostosowywać się do zmieniających się warunków i realizować główne cele misji. Dzięki połączeniu danych z sensorów z algorytmami lokalnej i globalnej autonomii możliwe jest dynamiczne planowanie trasy i skuteczna reakcja na nieprzewidziane przeszkody.

W Łukasiewicz-PIAP prowadzone są prace nad rozwojem algorytmów autonomii lokalnej i globalnej. W projekcie ATENA skupiono się głównie na autonomii lokalnej, obejmującej omijanie przeszkód i podążanie za liderem w czasie rzeczywistym, co pozwalało unikać problemów związanych z planowaniem globalnym – cel był zawsze widoczny, więc pojazd nie musiał stale weryfikować jego pozycji w szerszym kontekście. Natomiast projekt DEZROB stanowił przykład zastosowania planowania trasy na poziomie globalnym. Jego

głównym celem było umożliwienie robotowi autonomicznego przejścia przez wszystkie korytarze w celu ich dezynfekcji, z uwzględnieniem konieczności dokładnego pokrycia środkiem dezynfekcyjnym wszystkich powierzchni. Taki cel wymaga precyzyjnego zaplanowania trasy i sprawnego zbierania oraz przetwarzania danych z sensorów w celu wygenerowania efektywnej mapy przejezdności i trajektorii dezynfekcji.

W pracy doktorskiej omówione zostaną trzy platformy Łukasiewicz-PIAP, które wykorzystano na różnych etapach badań z różnymi systemami autonomii. Pierwszą z nich jest PIAP ATENA, przekształcony pojazd typu pick-up, używany do zbierania danych zarówno w trybie autonomicznym, jak i zdalnie sterowanym. Drugą platformą jest PIAP PATROL w wersji DEZROB, testujący możliwości globalnego planowania trasy na podstawie danych o przejezdności. Trzecia platforma to PIAP HUNTeR, największy robot Łukasiewicz-PIAP, który wykorzystuje algorytmy opracowane w ramach rozprawy doktorskiej. Na przykładzie tego robota zostaną zaprezentowane zdolności terenowe i przejezdność w warunkach poligonowych, symulujących zastosowania wojskowe.

4.1.1.2 Mapa przejezdności

Mapa przejezdności jest kluczowym elementem w systemach autonomii lokalnej, umożliwiającym pojazdom autonomicznym skuteczne poruszanie się w złożonych i dynamicznie zmieniających się środowiskach. Integracja pojazdów autonomicznych z takim otoczeniem wymaga zaawansowanej technologii sensorów oraz algorytmów do analizy danych terenowych. Mapa przejezdności, oceniająca i klasyfikująca obszary pod kątem ich dostępności dla pojazdu autonomicznego, stanowi fundament planowania ścieżki i efektywnej nawigacji w terenie.

Mapa przejezdności to reprezentacja przestrzeni terenowej, zawierająca informacje o kluczowych właściwościach, takich jak nachylenie, struktura powierzchni, obecność przeszkód i charakterystyka gruntowa. Te czynniki mają istotny wpływ na zdolność pojazdu do poruszania się w danym obszarze. Tworzenie takiej mapy to proces wymagający integracji wielu technologii i metod analizy. Pierwszym krokiem jest gromadzenie danych z różnych sensorów, takich jak kamery hiperspektralne, lidary, radary i systemy GPS. W szczególności kamery hiperspektralne są przydatne do identyfikacji materiałów powierzchniowych, co umożliwia dokładną ocenę właściwości terenowych, takich jak nośność czy przyczepność.

Zebrane dane są następnie przetwarzane przez algorytmy uczenia maszynowego i techniki przetwarzania obrazów, które klasyfikują teren na podstawie jego właściwości, takich jak nośność, tarcie czy nachylenie. Dzięki temu możliwe jest stworzenie dynamicznej mapy przejezdności, która klasyfikuje teren na kategorie, np. obszary łatwo przejezdne, trudne lub nieprzejezdne.

Mapa przejezdności jest aktualizowana w czasie rzeczywistym, aby odzwierciedlać zmieniające się warunki terenowe, co ma kluczowe znaczenie dla autonomii lokalnej. Jest ona podstawowym źródłem informacji dla algorytmów planowania ruchu i podejmowania decyzji. Dzięki tej mapie pojazd może planować optymalną trasę, unikać przeszkód oraz dostosowywać prędkość i trajektorię do aktualnych warunków terenowych.

Budowanie mapy przejezdności wiąże się z szeregiem wyzwań, takich jak zapewnienie wysokiej dokładności, integracja różnych źródeł informacji oraz reagowanie na dynamicznie zmieniające się warunki środowiskowe. Rozwój technologii sensorowych, algorytmów sztucznej inteligencji oraz systemów komunikacji może znacząco poprawić jakość map przejezdności, zwiększając autonomię i bezpieczeństwo pojazdów autonomicznych.


Mapa przejezdności jest więc nieodzownym elementem systemów autonomicznych, który umożliwia skuteczne i bezpieczne poruszanie się pojazdów w trudnych środowiskach terenowych. Integracja zaawansowanych technologii i metod analizy pozwala na tworzenie coraz dokładniejszych i dynamiczniejszych map, które wspierają rozwój autonomii lokalnej, zwiększając zdolności adaptacyjne pojazdów i ich efektywność w złożonych scenariuszach operacyjnych.

Opracowanie mapy przejezdności wymaga sparametryzowania pojęcia przejezdności. W tym celu przyjmuje podejście opisane przez Chiliana [74], które po niewielkiej zmianie w zakresie odwrócenia określania przedziału przejezdności również zastosował Wermelinger [18], powstało z myślą o analizie przejezdności dla robotów koczujących, jednakże uniwersalność tych parametrów sprawia, że mogą być wykorzystane do pojazdów kołowych i gąsienicowych. Kluczowym elementem analizy wg Chiliana jest przypisanie dla każdej komórki mapy wartości oceny przejezdności zawierającej się w przedziale $[0,1]$, gdzie 0 oznacza w komórkę łatwo przejezdną, a 1 oznacza komórkę nieprzejezdną. Wartość oceny przejezdności składa się z trzech parametrów: wartości lokalnego nachylenia (s - slope),

wartości lokalnej nierówności (r - roughness) i wartości lokalnej różnicy wysokości (h - step high). W tej metodzie wyniki poszczególnych parametrów są zależne od założonego promienia regionu referencyjnego względem badanej komórki oraz od ustalonych wartości krytycznych dostosowanych do zdolności terenowych robota (są to wartości: s_{crit} , r_{crit} oraz h_{crit}).

$$t = a \frac{s}{s_{crit}} + b \frac{r}{r_{crit}} + c \frac{h}{h_{crit}} \quad (1)$$

Na podstawie sumy wartości lokalnych pomnożonych przez ich wagę (a, b, c), Chilian oblicza wartość przejezdności (t – traversability) dla każdej komórki mapy przejezdności. Chilian nie wskazał wprost, w jaki sposób należy dobrać parametry wagowe a, b, c , co sugeruje konieczność ich empirycznego doboru. Oznacza to, że optymalne wartości wag powinny być określone poprzez testowanie różnych konfiguracji na rzeczywistym sprzęcie lub w symulacji, dostosowując je do specyficznych właściwości danego robota oraz warunków terenowych. Poniżej wizualizacja parametrów i mapy przejezdności.



Rysunek 8. Parametry i mapa przejezdności według Chiliana [74].

Na rysunku powyżej dla mapy przejezdności i jej komponentów w celu wizualizacji wartości zastosowano skalę kolorów od zielonego dla terenów przejezdnych (wartość równa 0) do bordowego dla terenów nieprzejezdnych (wartość równa 1).

Lokalne nachylenie jest wyliczane na podstawie kąta nachylenia komórki mapy do regionu o średnicy jaki zajmuje obrys robota na mapie.

Lokalna nierówność jest tożsama z odchyleniem standardowym płaszczyzny na tym samym regionie co w lokalnym nachyleniu.

Natomiast lokalna różnica wysokości jest wyliczana w dwóch krokach. W pierwszym kroku w regionie o średnicy jaką zajmuje obrys robota, szukana jest największa różnica wysokości między środkiem okręgu, a najwyższą komórką. Po jej znalezieniu sprawdzane jest czy wartość ta przekracza wartość krytyczną różnicy wysokości, jeśli przekracza to ustawiana jest ta wartość jako tymczasową wartość stopnia dla tej komórki. W drugim kroku, analizowane są komórki wokół analizowanej komórki, jeżeli ilość komórek o wartości przekraczającej h_{crit} przekracza ustaloną wartość krytyczną ilości takich komórek wtedy wartość parametru jest ustalana jako wysoka. 0

$$h = \min \left(h_{max}, h_{max} \cdot \frac{n}{n_{crit}} \right) \quad (2)$$

gdzie:


h_{max} – największy uskok w regionie.

n – liczba komórek w regionie która ma różnice wysokości większą niż h_{crit} .

n_{crit} – minimalna liczba komórek mapy w regionie,
od której włączamy maksymalną wartość dla tego parametru.

W pracy przyjmuje następujące interpretacje powyższych komponentów przejezdności, które było konieczne do określenia zdolności terenowych pojazdów PIAP w ramach badań

eksperymentalnych. Poniżej rysunek z zaznaczonymi parametrami pojazdu kołowego (bardziej złożony przypadek niż pojazd gąsienicowy).



Rysunek 9. Wizualizacja kątów natarcia i zejścia oraz prześwitu pojazdu kołowego. [100]

Lokalne nachylenie – jest to wartość nachylenia wzniesienia lub dołu względem terenu, wartość ta jest skorelowana ze zdolnością fizyczną pojazdu do podjazdu na wzniesienie, wyznaczona poprzez kąt natarcia i kąt zejścia.

Lokalna nierówność – jest to wartość odchylenie standardowe odległości od płaszczyzny terenu albo opisowo wartość nierówności na danym obszarze. Jest to wartość skorelowana z prześwitem i kątem rampowym pojazdu. Wartość wyższa niż nierówność krytyczna (która w uproszczeniu może być oznaczona jako prześwit pojazdu) oznaczać może zawiśnięcie pojazdu na terenie/przeszkodzie. Dobrą wizualizacją takiej powierzchni jest gruzowisko lub kamienista górską ścieżka jak na rysunku poniżej.



Rysunek 10. Kamienista górską ścieżka, teren, który oddaje istotę parametru nierówności. [101]

Lokalna różnica wysokości – jest to wartość wysokości stopnia w terenie, można tę wartość porównać do wysokości krawężnika przy drodze albo odwrotnie do wyrwy w terenie. Wartość oznacza zmianę wysokości terenu na wielkości większej niż założona w parametrze, ważność tego parametru będzie odnosić się do sytuacji, w której wyrwa w terenie jest większa niż powierzchnia koła i głębokość tej wyrwy przewyższa skok zawieszenia pojazdu.

4.1.2 PIAP ATENA

Projekt ATENA koncentrował się na opracowaniu autonomicznego systemu dla odpowiednio przystosowanych platform lądowych. Celem było wyposażenie pojazdu bezzałogowego w zdolność do autonomicznego podążania za wybranym celem. W ramach projektu pojazd miał śledzić lidera (np. samochód, robota mobilnego, człowieka) w czasie rzeczywistym, tworząc cyfrowy model otoczenia na podstawie danych sensorycznych.

Algorytm wykorzystywał sensory, takie jak lidar i kamery wizyjne, do wykrywania i modelowania otoczenia, tworząc chmurę punktów jako podstawę dla trójwymiarowego modelu. Na podstawie tego modelu, przy uwzględnieniu parametrów przeszkód (np. ich wysokości i nachylenia) oraz zdolności terenowych platformy, którą sterował system, algorytm obliczał optymalną trasę do celu. Do realizacji projektu wykorzystano dwa samochody typu pick-up Ford Ranger, w których zaprojektowałem i wdrożyłem system drive-by-wire. System ten pozwalał na elektroniczne sterowanie układem kierowniczym, hamulcowym oraz pedałem przyspieszenia, co stanowiło fundament do uruchomienia systemu autonomii jazdy w tego typu pojazdach.

W rozdziale 6 zostanie zaprezentowany demonstrator technologii ATENA na przykładzie jednego z pojazdów PIAP ATENA. W wyniku realizacji projektu opracowano system autonomii jazdy działający w terenach nieustrukturyzowanych dla pojazdów o kinematyce Ackermanna. Projekt był realizowany przez Łukasiewicz-PIAP w okresie od lipca 2018 do stycznia 2021 roku w ramach programu badań naukowych na rzecz obronności i bezpieczeństwa państwa, zatytułowanego „Przyszłościowe technologie dla obronności – konkurs młodych naukowców” (konkurs nr 2/P/2017 „Młodzi naukowcy 2017”) [102]. Pełna nazwa projektu brzmi: „Autonomiczny system dla terenowych platform lądowych z funkcją podążania za celem”, akronim ATENA. Byłem jednym z inicjatorów i twórców wniosku projektowego, a następnie pełniłem funkcję kierownika projektu. Wyniki projektu zostały zaprezentowane m.in. podczas wydarzenia Defence24Day w 2022 roku.



Rysunek 11. Wynik projektu ATENA prezentowany na wydarzeniu Defence24Day [103].

W ramach projektu ATENA powstała pierwsza wersja Sterownika Autonomii PIAP, którego główne komponenty były oparte na zaawansowanych elementach komputerowych. W projekcie zakupiono również kamerę hiperspektralną, która posłużyła do badań nad zdolnością systemu do oceny przejezdności terenu jako elementu autonomii jazdy. Wyniki projektu, w postaci opracowanego algorytmu autonomii jazdy dla pojazdów Łukasiewicz-PIAP, zostały wykorzystane jako dane wejściowe w kolejnych projektach badawczych z obszaru obronności i bezpieczeństwa, prowadzonych w instytucie. Dodatkowo, wnioski z badań do tej rozprawy doktorskiej zostały włączone do wyników projektu ATENA pod koniec jego realizacji.

4.1.3 PIAP DEZROB

Drugim projektem Łukasiewicz-PIAP z zakresu systemów autonomii jazdy jest projekt DEZROB, którego byłem kierownikiem i brałem aktywny udział. Celem projektu było opracowanie autonomicznego systemu do dezynfekcji korytarzy i ciągów pieszych,

stanowiącego rozwinięcie technologii wypracowanej w projekcie ATENA. Skupiono się szczególnie na rozwoju sterownika autonomii, wykorzystaniu sensorów oraz na metodach komunikacji i protokołach niezbędnych do integracji systemu autonomii z systemem operacyjnym produkcyjnych robotów mobilnych Łukasiewicz-PIAP.

Projekt DEZROB miał na celu stworzenie narzędzi do autonomicznej dezynfekcji z użyciem robotów patrolowych i rozpoznawczych, będących na wyposażeniu Sił Zbrojnych RP. Opracowane technologie zwiększają funkcjonalność robotów mobilnych Łukasiewicz-PIAP, umożliwiając przeprowadzanie dezynfekcji za pomocą oprysków, zamgławiania chemicznymi środkami dezynfekcyjnymi oraz naświetlania otoczenia lampą UV-C. Narzędzia DEZROB obejmują moduł autonomii w formie zewnętrznego urządzenia łączonego z robotem mobilnym przez złącze akcesyjne. Moduł ten pozwala na autonomiczne przeprowadzanie dezynfekcji w pomieszczeniach, korytarzach, halach oraz na ciągach pieszych. W ramach projektu opracowano zestaw narzędzi DEZROB montowany na robocie PIAP PATROL. Moduł ten rozwija funkcje Sterownika Autonomii PIAP z projektu ATENA, a jego konstrukcja, oparta na komponentach mobilnych, została zminiaturyzowana do rozmiarów umożliwiających montaż w robotach mobilnych PIAP, takich jak PIAP GRYF, PIAP PATROL, PIAP IBIS oraz PIAP HUNTER.

Projekt realizowano w Łukasiewicz-PIAP od listopada 2021 do lutego 2024 roku w ramach Programu badań naukowych na rzecz obronności i bezpieczeństwa państwa, zatytułowanego „Rozwój nowoczesnych, przełomowych technologii służących bezpieczeństwu i obronności państwa” (pod kryptonimem „Szafir”). Pełna nazwa projektu to „Kompleksowe narzędzie do dezynfekcji pomieszczeń i ciągów pieszych zabudowane na bazie mobilnej”, akronim DEZROB. Byłem jednym z inicjatorów i twórców wniosku projektowego, a następnie pełniłem funkcję kierownika projektu.

Projekt DEZROB, w zakresie zbieżnym z rozprawą doktorską, obejmował autonomiczne poruszanie się w zamkniętych przestrzeniach na podstawie zbudowanej mapy 2D, która stanowiła mapę przejezdności dostosowaną do wysokości przeszkód i zdolności terenowych robota. Kluczową różnicą w stosunku do projektu ATENA była ograniczona analiza przejezdności. W DEZROB robot musiał jedynie zweryfikować, czy zmieści się między przeszkodami i czy jest w stanie je pokonać. Podejście to było możliwe dzięki ustrukturyzowanemu charakterowi przestrzeni, w której operował robot, tj. w korytarzach,

magazynach i pomieszczeniach biurowych, gdzie występują elementy infrastruktury, takie jak oznaczenia, płaskie powierzchnie czy namalowane linie.

W ramach rozprawy doktorskiej badania z wykorzystaniem prototypu PIAP DEZROB przeprowadzono na poziomie analizy przejezdności z użyciem dostępnych sensorów pojazdu. W badaniach tych rozszerzona analiza przejezdności została przeprowadzona na poziomie planera trajektorii globalnej. Szczegółowy opis badań znajduje się w rozdziale 6 oraz w artykule[16]. Opis zdolności terenowych pojazdu PIAP PATROL w wersji DEZROB został przedstawiony również w rozdziale 6. Projekt DEZROB prezentowałem również w audycji „Eureka” Polskiego Radia Jedyńka [104].



Rysunek 12. Główny wynik projektu DEZROB: Prototyp Robota PIAP PATROL w wersji DEZROB z systemem oprysku i modulem autonomii. [materiały własne doktoranta]

4.1.4 PIAP HUNTeR

Celem projektu HUNTeR realizowanego w Łukasiewicz-PIAP było opracowanie zrobotyzowanej platformy mobilnej (UGV) do wspierania działań interwencyjnych w

terenach przygranicznych. W projekcie stworzono bezzałogową platformę lądową o masie 3500 kg, z możliwością integracji bezzałogowego statku powietrznego (BSP) pracującego na uwięzi. Platforma została wyposażona w akumulator trakcyjny o wysokim napięciu oraz generator energii elektrycznej, który umożliwia pracę systemu obserwacyjnego z dronem na uwięzi przez wiele godzin. W zakresie systemów autonomii jazdy robot wyposażono w czujniki i algorytmy zapewniające korekcję trajektorii lub hamowanie awaryjne w przypadku wykrycia przeszkód dynamicznych lub statycznych.

Jednym z wniosków wynikających z badań systemu autonomii jazdy w projekcie HUNTeR była obserwacja dotycząca błędów wykrywania przeszkód – system zatrzymywał pojazd po wykryciu wysokiej trawy, która nie stanowiła rzeczywistej przeszkody dla tej klasy pojazdu. Projekt HUNTeR był realizowany przez Łukasiewicz-PIAP od stycznia 2017 do września 2020 roku w ramach Programu Operacyjnego Innowacyjny Rozwój 2014–2020, współfinansowanego przez Unię Europejską w ramach Europejskiego Funduszu Rozwoju Regionalnego (Działanie 1.2 „Sektorowe programy B+R”). Pełna nazwa projektu to „Opracowanie wysoko mobilnej bezzałogowej platformy hybrydowej do zadań szybkiego reagowania” (akronim HUNTeR). Byłem jednym z wykonawców projektu.



Rysunek 13. Wynik projektu „Opracowanie wysoko mobilnej bezzałogowej platformy hybrydowej do zadań szybkiego reagowania” – BPL HUNTeR wraz z dronem na uwięzi. [materiały własne doktoranta]

W ramach pracy doktorskiej analizowano zdolności terenowe pierwotnej wersji BPL HUNTeR oraz wersji po modernizacji do wersji bojowej, oznaczonej jako PIAP HUNTeR. Przeprowadzone w ramach rozprawy badania terenowe tej platformy miały na celu opracowanie informacji o zdolnościach terenowych, które zostały przedstawione w rozdziale 6. Na podstawie wniosków z badań opracowano wymagania dotyczące niezbędnych modyfikacji pojazdu w celu zwiększenia jakości i ilości zbieranych danych potrzebnych do analizy parametrów jazdy w trudnym terenie w trybie autonomicznym. Wyniki tych badań pozwoliły na przygotowanie dwóch wniosków inwestycyjnych o przyznanie środków finansowych na realizację projektów naukowych związanych z wytworzeniem aparatury oraz wystąpienia konferencyjnego [17].

W kolejnych latach Łukasiewicz-PIAP zainicjował projekt finansowany ze środków własnych, mający na celu opracowanie bojowej wersji pojazdu HUNTeR. W nowej wersji dokonano modyfikacji algorytmów sterowania napędami oraz systemu zbierania danych o stanie pojazdu, bazując na wnioskach z wcześniejszych badań terenowych. Dodatkowo platformę wyposażono w moduł uzbrojenia ZMU-03 dostarczany przez Zakład Automatyki i Urządzeń Pomiarowych AREX (spółka WB Group). W celu ochrony nowych elementów sterowania powstał stelaż z obudową, który zmodyfikował wygląd UGV [105].

Punktami kontrolnymi dla rozwoju PIAP HUNTeR były ćwiczenia eksperymentalne ANAKONDA23 FEX oraz FEX-24, w trakcie których badano m.in. efektywność systemów autonomicznych [106]. Dalsze prace wdrożeniowe nad systemami do analizy przejezdności pojazdu PIAP HUNTeR zostaną opisane w rozdziale 7.

4.1.5 Sposób sterowania pojazdami PIAP

Roboty mobilne PIAP wykorzystują jednolity system sterowania w trybie teleoperacji, oparty na konsoli sterowania PIAP. Metoda ta polega na manipulacji joystickami, umożliwiając precyzyjne zarządzanie ruchem platform mobilnych oraz robotów wyposażonych w manipulatory. Konsola sterowania PIAP stanowi zaawansowany interfejs użytkownika, pozwalający na przypisywanie funkcji sterowania poszczególnym elementom sterowniczym, co czyni system elastycznym i dostosowanym do specyfiki każdego robota.

4.1.5.1 Konsola sterowania PIAP

Konsola sterowania PIAP została zaprojektowana w taki sposób, aby zapewnić intuicyjne oraz ergonomiczne sterowanie robotami mobilnymi i ich manipulatorami. Wyposażona jest w dwa joysticki główne, które w większości przypadków są konfigurowane do zarządzania bazą mobilną robota. Oprócz joysticków, konsola posiada również slidery i inne elementy sterownicze, które mogą być dowolnie mapowane w celu kontroli poszczególnych stopni swobody manipulatora.



Rysunek 14. Zdjęcie konsoli sterowania pojazdów PIAP (użytej do badań dla PIAP HUNTeR oraz dla PIAP PATROL)[107].

4.1.5.2 Sterowanie bazą mobilną z konsoli sterowania PIAP

W przypadku robotów mobilnych, takich jak PIAP Hunter oraz PIAP Patrol, joysticki główne są wykorzystywane do sterowania napędami. PIAP Hunter, ze względu na zastosowanie układu kierowniczego typu Ackermanna, zazwyczaj posiada joystick odpowiadający za przyspieszanie i hamowanie oraz drugi joystick przeznaczony do skręcania. Natomiast PIAP Patrol, charakteryzujący się napędem opartym na sterowaniu różnicowym, zazwyczaj posiada uproszczony układ sterowania, w którym jeden joystick umożliwia zarówno przyspieszanie, jak i sterowanie kierunkiem jazdy.

Przeanalizujemy zachowanie operatora pojazdu w zróżnicowanym terenie. Operator steruje pojazdem poprzez wychylenie joysticka. Dynamika robota jest powiązana z szybkością z jaką operator wychyla joystick oraz stopniem jego wychylenia. W robota PIAP wychylenie joysticka jest powiązane z zadaną prędkością jazdy, natomiast szybkość wychylania joysticka wpływa na to jak szybko ta prędkość będzie narastać w czasie. Przekładając to na parametry fizyczne. Maksymalne wychylenie joysticka to maksymalna prędkość robota, przy bardzo dynamicznym wychyleniu joysticka robot osiągnie maksymalne przyspieszenie dopuszczalne dla danej konstrukcji.

4.1.5.3 Specyfika sterowania pojazdem PIAP Atena

PIAP Atena stanowi wyjątek wśród pojazdów PIAP pod względem metody sterowania. W przeciwieństwie do pozostałych platform mobilnych, w przypadku tego robota nie stosuje się konsoli sterowania PIAP. Testy przejezdności realizowane były z wykorzystaniem klasycznych metod sterowania, takich jak kierownica oraz pedały gazu i hamulca obsługiwane przez operatora-kierowcę. Robot ten wyposażono w system drive-by-wire, który umożliwia przejęcie kontroli nad układem kierowniczym, przyspieszaniem oraz hamowaniem przez sterownik autonomii. W przypadku przejścia do trybu autonomicznego, robot podlega tym samym ograniczeniom dynamicznym, co inne platformy PIAP.

4.1.5.4 Ograniczenia dynamiczne w systemach sterowania PIAP

Wszystkie roboty mobilne PIAP posiadają możliwość programowej konfiguracji parametrów dynamicznych, m.in. maksymalna prędkość oraz czas, w którym robot osiągnie maksymalną prędkość. Wyjątek stanowi robot PIAP Atena w trybie sterowania manualnego przez operatora-kierowcę, gdyż żaden system PIAP nie pośredniczy w sterowaniu. Jednak w trybie autonomicznym robot podlega analogicznym ograniczeniom dynamicznym jak pozostałe jednostki.

Warto podkreślić, że parametry te są przypisane do danego robota i ustalane jako wartości maksymalne osiągalne przez dany system. W trakcie jazdy operator reguluje prędkość poprzez manipulację joystickiem, analogicznie do sposobu, w jaki kierowca samochodu kontroluje prędkość za pomocą pedału gazu i hamulca.

4.1.6 Ćwiczenia eksperymentalne FEX i potrzeby wojska

Od 2023 roku CEDiSZ organizuje ćwiczenia eksperymentalne FEX, których celem jest ocena zdolności pojazdów UGV w kontekście potrzeb Sił Zbrojnych RP. Pierwsze ćwiczenia, ANAKONDA23 FEX (Field Experimentation Exercises), miały na celu weryfikację możliwości taktycznego wykorzystania różnego typu bezzałogowych platform lądowych w ramach koncepcji Sztabu Generalnego WP „Future Task Force” – batalionu przyszłości.[108] Łukasiewicz-PIAP uczestniczył w tygodniowych ćwiczeniach, podczas których PIAP HUNTeR realizował zadania obserwacyjne, rozpoznawcze oraz wspierał działania taktyczne jako pojazd wsparcia ogniowego. Wnioski z tych ćwiczeń posłużyły do zaplanowania ewentualnych modyfikacji platformy na przyszłe ćwiczenia.[109]



Rysunek 15. PIAP HUNTeR podczas FEX-23[110]

Zakres modyfikacji związanych z analizą przejezdności i wsparciem operatora zostanie opisany w rozdziale 7, poświęconym wdrożeniu systemów autonomicznych. Na ćwiczeniach FEX-24 zaprezentowano te modyfikacje, które wspierały proces sterowania pojazdem w warunkach rzeczywistych. W 2024 roku w ćwiczeniach wzięły udział UGV różnych producentów, co umożliwiło porównanie ich możliwości na wspólnym torze testowym [111].

Warto zwrócić uwagę na różnice w systemie percepcji pojazdu PIAP HUNTeR widoczne na rysunku 15 oraz 16. Na rysunku 16 widać dołożony lidar typu Solid-State, dodatkową kamerę oraz kamerę stereowizyjną. Lidar został dołożony w celu poprawienia zdolności operatora do percepcji otoczenia przy okazji badań prowadzonych w pracy doktorskiej.



Rysunek 16. PIAP HUNTeR z wprowadzonymi modyfikacjami wspomagającymi operatora jazdy na ćwiczeniach FEX-24.[112]

4.1.7 Podsumowanie badań wstępnych

W projektach badawczych Łukasiewicz-PIAP pojawił się problem związany z ograniczeniami obecnie stosowanych sensorów, które koncentrują się głównie na rejestracji geometrii otoczenia, ignorując istotne właściwości materiałowe przeszkód terenowych. Przykładem jest zatrzymywanie się autonomicznego pojazdu PIAP HUNTeR na wysokiej trawie, która, choć nie stanowi rzeczywistej przeszkody, bywa interpretowana jako nieprzejezdna przez system autonomii jazdy, analizujący wyłącznie chmurę punktów generowaną przez lidar. Problem ten ujawnia konieczność rozszerzenia klasycznej analizy geometrii terenu o charakterystykę

materiałową, która pozwoli na bardziej precyzyjną ocenę przejezdności w środowisku nieustrukturyzowanym.

Podstawą do oceny przejezdności terenu jest budowa mapy przejezdności, która dostosowana jest do specyficznych zdolności terenowych pojazdu. Mapa ta umożliwia wytyczenie realizowalnej trasy, dostosowanej do dynamiki pojazdu oraz specyficznych właściwości terenu.

Nowoczesnym narzędziem, które może dostarczyć takich informacji, jest kamera hiperspektralna. Pozwala ona na bezdotykowe rozpoznanie składu materiałowego otoczenia na podstawie sygnatur spektralnych, co umożliwia dokładniejsze klasyfikowanie przeszkód i ocenę ich przejezdności. Kamery hiperspektralne mają zdolność do rejestracji setek pasm spektralnych, co pozwala na identyfikację różnorodnych materiałów, takich jak gleba, roślinność czy minerały, dzięki czemu analiza przeszkód terenowych może być wzbogacona o ich właściwości fizyczne. Takie podejście otwiera nowe możliwości w systemach autonomii jazdy, zwłaszcza w kontekście Łukasiewicz-PIAP, gdzie rozwiązania te mogą zostać zintegrowane w ramach projektów takich jak ATENA czy HUNTeR.

Na podstawie powyższych analiz można sformułować główne założenia problemu badawczego oraz wytyczne dla założeń wdrożeniowych:

- **Doprecyzowanie mapy przejezdności poprzez klasyfikację materiałową.**

Precyzyjne określenie, czy dany teren lub przeszkoda jest przejezdna, wymaga zbudowania mapy przejezdności, która uwzględnia skład materiałowy otoczenia. Tę informację można pozyskać poprzez fuzję danych z kamery hiperspektralnej lub z wykorzystaniem algorytmu sztucznej inteligencji. Rozpoznanie właściwości materiałowych, takich jak struktura gleby, rodzaj roślinności czy obecność przeszkód typu skały, pozwoli na bardziej świadome i precyzyjne planowanie trasy.

- **Mapa przejezdności w ujęciu lokalnym i globalnym**

Mapa przejezdności powinna obejmować zarówno ujęcie lokalne, jak i globalne. Mapa globalna umożliwia planowanie wstępnej trasy misji, natomiast mapa lokalna wspiera dynamiczną adaptację trasy w odpowiedzi na zmieniające się warunki terenowe. Dzięki temu pojazd autonomiczny może operować efektywnie i bezpiecznie, a

zarazem dostosowywać swoją trasę do bieżących warunków, unikać zagrożeń i omijać potencjalnie nieprzejezdne obszary.

- **Skalowalność i optymalizacja kosztowa rozwiązania**

Biorąc pod uwagę wymogi projektów wdrożeniowych w Łukasiewicz-PIAP, opracowane rozwiązanie powinno być skalowalne, co oznacza możliwość zastosowania technologii na różnych typach pojazdów. Jednocześnie, aby wdrożenie mogło być efektywne, konieczna jest optymalizacja kosztowa systemu, tak aby system przejezdności mógł być implementowany na szeroką skalę w pojazdach wojskowych, uwzględniając specyfikę i wymagania budżetowe instytucji operacyjnych.

Podsumowując, doprecyzowanie map przejezdności otoczenia na podstawie analizy materiałowej może znacząco zwiększyć niezawodność autonomicznych systemów nawigacyjnych w pojazdach wojskowych i umożliwić operacje w trudnych warunkach terenowych. Założenia te wyznaczają kierunki badań i wdrożeń, wspierając rozwój autonomicznych systemów jazdy w projektach realizowanych przez Łukasiewicz-PIAP, jak również przyczyniając się do wprowadzenia nowych standardów w analizie mobilności dla pojazdów operujących w środowiskach nieustrukturyzowanych.

4.1.8 Wytyczne do budowy modelu przejezdności dla BPL

Na podstawie wyników testów, opisanych w rozdziale 6.3, sformułowano wytyczne, które są kluczowe dla bezpiecznej i optymalnej jazdy bezzałogowych platform lądowych (BPL) w różnych warunkach. Wytyczne te mogą wspierać systemy autonomiczne w planowaniu tras i wyborze manewrów, ograniczając ryzyko operacyjne:

- Preferowane jest planowanie trasy po drogach, chyba że charakter misji jest inny.
- Preferowane jest unikanie tras w których roślinności przesłania widoczność gdyż istnieje ryzyko kolizji z ukrytą przeszkodą, ale nie jest to wykluczające planowanie trasy – parametry jazdy należy dostosować do wartości bezpiecznej dla pojazdu (dostosowanej do wytrzymałości pojazdu na kolizje).
- Preferowane jest unikanie zrywania/utruty przyczepności, wszelkie uślizgi są trudne do opanowania nawet przez operatora sterującego pojazdem w trybie teleoperacji.
- Preferowane jest dostosowanie prędkości do warunków otoczenia.

- Preferowana jest możliwość wyświetlenia mapy przejezdności dla operatora, dla wsparcia jego świadomości sytuacyjnej podczas teleoperowania BPL (ewentualny algorytm powinien działać zarówno dla potrzeby planera ruchu jak i operatora systemu).
- Należy podzielić przejezdność na tereny, w których pracują BPL, czyli: droga utwardzona, droga gruntowa, trawa, błoto, ziemia, piasek.

4.1.9 Parametry oceny przejezdności dla pojazdów PIAP

W oparciu o analizę testów w ramach weryfikacji zdolności terenowych opisanych w rozdziale 6.3, opracowano parametry oceny przejezdności, które stanowią podstawę przyszłych modeli terenowych. Parametry te uwzględniają specyfikę każdego rodzaju terenu oraz charakterystykę poszczególnych BPL, takich jak PIAP HUNTeR, PIAP PATROL oraz PIAP ATENA:

- Parametry geometryczne terenu:

Uwzględniono maksymalne kąty nachylenia, wysokości przeszkód, a także wartość nierówności terenu. Wartości te różnią się w zależności od klasy pojazdu, dlatego dokładne pomiary są kluczowe dla precyzyjnego modelowania przejezdności. Parametry „Kąt nachylenia”, „Stopień” oraz „Nierówność” bezpośrednio odnoszą się do parametrów opisanych w podrozdziale 5.1.1

- Prędkości maksymalne i minimalne:

Na podstawie testów określono prędkości dostosowane do różnych warunków terenowych i ich dopasowanie do konkretnych klas pojazdów. Przykładowo, dla PIAP ATENA ustalono ograniczenia dopuszczalnej prędkości maksymalnej w zależności od charakteru terenu i złożoności otoczenia. Osiąganie minimalnej prędkości może pojawić się w terenie, w którym możliwe jest zakopanie pojazdu takim jak kopny piach czy grząskie błoto. W ramach analizy przejezdności nie wprowadzono ograniczenia w postaci osiągnięcia minimalnej prędkości w tych terenach, ze względu na brak wiarygodnej metody odróżniania rodzaju terenów błotnistych i piaszczystych.

Tabele z wynikami testów uwzględniają wszystkie parametry oceny przejeźdźności, przedstawiając wytyczne dopasowane do różnych warunków terenowych na podstawie preferencji sterowania operatorów BPL. Poniższe wyniki zostały zapisane na podstawie porównań osiąganych prędkości pojazdów w danej klasie terenu przy sterowaniu manualnym przez operatorów pojazdów PIAP.

Tabela 1. Parametry oceny przejeźdźności dla pojazdów PIAP HUNTeR, PIAP PATROL w wersji DEZROB, PIAP ATENA, dla materiałów: trawa, droga utwardzona, droga gruntowa, błoto, piach, woda, nieznaną.

Trawa	PIAP HUNTER	PIAP PATROL [DEZROB]	PIAP ATENA	[jednostka]
Kąt nachylenia	30	40	30	stopnie
Stopień	60	25	25	cm
Nierówność	50	25	20	cm
Vmax	50	8	30	km/h

Droga utwardzona	PIAP HUNTER	PIAP PATROL [DEZROB]	PIAP ATENA	[jednostka]
Kąt nachylenia	35	45	38	stopnie
Stopień	40	25	15	cm
Nierówność	50	25	15	cm
Vmax	50	8	30	km/h

Droga gruntowa	PIAP HUNTER	PIAP PATROL [DEZROB]	PIAP ATENA	[jednostka]
Kąt nachylenia	30	40	30	stopnie
Stopień	40	25	15	cm
Nierówność	40	25	15	cm
Vmax	50	8	30	km/h

Błoto	PIAP HUNTER	PIAP PATROL [DEZROB]	PIAP ATENA	[jednostka]
Kąt nachylenia	20	40	20	stopnie
Stopień	60	25	25	cm
Nierówność	30	10	10	cm
Vmax	30	8	20	km/h

Piach	PIAP HUNTER	PIAP PATROL [DEZROB]	PIAP ATENA	[jednostka]
Kąt nachylenia	20	40	20	stopnie
Stopień	60	25	25	cm
Nierówność	30	8	10	cm
Vmax	30	8	20	km/h

Woda	PIAP HUNTER	PIAP PATROL [DEZROB]	PIAP ATENA	[jednostka]
Kąt nachylenia	2	2	2	stopnie
Stopień	60	25	25	cm
Nierówność	1	1	1	cm
Vmax	15	8	15	km/h


Nieznany	PIAP HUNTER	PIAP PATROL [DEZROB]	PIAP ATENA	[jednostka]
Kąt nachylenia	30	40	30	<i>stopnie</i>
Stopień	30	25	15	<i>cm</i>
Nierówność	30	8	10	<i>cm</i>
Vmax	30	5	20	<i>km/h</i>

Powyższe dane odwzorowują zachowania doświadczonych operatorów co do stylu jazdy i sterowanie bezzałogowych pojazdów lądowych. Klasa terenu nieznanego została przyjęta jako podobna do terenu pokrytego trawą lub błotem, ze względu na charakter pojazdów PIAP ich mobilność musi być zachowana na wysokim poziomie nawet w trudnych i niesparametryzowanych warunkach.

4.2 Ocena przejezdności – krótki opis realizacji zagadnienia

Po wykonaniu badań wstępnych i określeniu potrzeb oraz wymagań jakim ma sprostać algorytm oceny przejezdności przystępuje do głównej części badawczej pracy.

Realizacja zagadnienia opiera się na integracji rozwiązań analizy geometrycznej otoczenia z rozwiązaniami wypracowanymi w badaniach ETH Zurich [18], [19] oraz analizy materiałów otoczenia, które wpływają na zmianę parametrów analizy geometrycznej i stanowią źródło ograniczeń dynamicznych dla planera trasy robota mobilnego. Poniżej prezentuje uproszczony schemat proponowanego systemu.



Rysunek 17. Ogólny schemat systemu proponowanego w pracy doktorskiej.

Na początku zostanie opisany dostosowany model analizy geometrycznej bazujący na wynikach badań ETH Zurich [18], [19]. Kolejnym krokiem będą badania dotyczące fizycznego pomiaru materiałów otoczenia z wykorzystaniem kamery hiperspektralnej. Następnie przedstawione zostaną badania dotyczące integracji danych geometrycznych z danymi materiałowymi w oparciu o segmentację semantyczną, zgodnie z metodą z badań z 2022 roku prowadzonych w Wielkiej Brytanii [20].

Po omówieniu powyższych zagadnień zaprezentowane zostaną kroki metody analizy przejezdności, wykorzystującej dane z lidarów, jednostki IMU oraz kamery hiperspektralnej. Przedstawiona zostanie możliwość zastosowania tej metody zarówno w kontekście budowania globalnej mapy terenu, jak i lokalnej mapy przeznaczonej do pracy na pojeździe. Zostaną zdefiniowane możliwe parametry przejezdności, które można ustawiać w ramach tego podejścia.

4.3 Metoda oceny przejezdności w oparciu o geometrie terenu

Prace nad realizacją zagadnienia w pracy doktorskiej rozpoczęto od dostosowania metody analizy przejezdności w oparciu o opublikowane wyniki badań w zakresie algorytmów do estymacji przejezdności na podstawie informacji o geometrii otoczenia [19].

Pojazdy PIAP najczęściej pracują w terenie o nieznanym wcześniej ukształtowaniu. Może napotkać przeszkody w postaci drzew, wzgórz, rowów, kamieni. Do realizacji zadań system autonomii lub operator potrzebuje określić bezpieczną dla platformy trasę w tym celu prowadzona jest analiza przejezdności. W obrębie siatki z przeprowadzoną analizą przejezdności odbywa się planowanie drogi.

Danymi wejściowymi są:

-dane z lidarów + dane z IMU + dane z odometrii, po fuzji tych danych możliwe jest stworzenie chmury punktów wokół BPL (sumarycznie są to dane o geometrii otoczenia).

4.3.1 Mapa wysokości 2,5D

Z danych z lidarów tworzona jest chmura punktów, która poprzez zastosowanie implementacji [19], jest przetworzona na mapę 2,5D otoczenia. W celu osiągnięcia wysokiej jakości danych umożliwiających analizę przejezdności należy rozważyć dokładne pokrycie otoczenia punktami pomiarowymi. W celu jak najlepszego odwzorowania terenu przeprowadzono badania rozmieszczenia lidarów na pojeździe PIAP ATENA, opisane w rozdziale 5.2. a następnie w rozdziale 5.3 przeprowadzono badania mapy 2.5D w celu zdobycia informacji o jej ograniczeniach oraz w celu dostosowania głównych parametrów mapy.

Stworzenie mapy 2,5D wymaga danych wejściowych w postaci chmury punktów, która reprezentuje wysokościowe odwzorowanie otoczenia. W przypadku wykorzystania sensorów Velodyne VLP-16 oraz środowiska ROS, surowe dane z lidarów obrotowych są początkowo rejestrowane w układzie biegunowym, gdzie każdemu pomiarowi przypisana jest odległość od sensora oraz kąty azymutu i elewacji. Następnie, w ramach przetwarzania w ROS, dane te są konwertowane do układu kartezjańskiego, co umożliwia ich dalsze przetwarzanie, analizę i rzutowanie na mapę wysokościową.

Współrzędne punktów pomiarowych wykonywanych przez lidary obrotowe są reprezentowane w układzie biegunowym i opisane są przez:

- Odległość (d): mierzona od lidarów do punktu odbicia,
- Kąt azymutu (θ): określający obrót sensora w płaszczyźnie poziomej (0° – 360°),
- Kąt elewacji (ϕ): określony dla każdej z wiązek lasera, zgodnie z charakterystyką czujnika.

Aby przekształcić te współrzędne do układu kartezjańskiego, stosuje się następujące równania:

$$x = d \cdot \cos(\phi) \cdot \sin(\theta)$$


$$y = d \cdot \cos(\phi) \cdot \cos(\theta) \quad (3)$$

$$z = d \cdot \sin(\phi)$$

gdzie:

- x, y, z – współrzędne kartezjańskie danego punktu,
- d – odległość od sensora,
- θ – kąt azymutu,
- ϕ – kąt elewacji lasera.

Transformacja ta pozwala na łatwiejszą integrację chmur punktów z wielu lidarów w celu poprawy jakości końcowej mapy 2,5D, w systemach wieloczujnikowych istotna jest synchronizacja czasowa pomiarów, w przypadku systemów opartych o ROS możliwe jest wykorzystanie programowej synchronizacji czasowej (takie podejście wykorzystano w pracy).



Rysunek 18. Mapa 2,5D otoczenia budowana przez pojazd ATENA

Powyżej przedstawiona jest mapa budowana w systemie ATENA. Mapa powstaje w wyniku fuzji danych z 4 lidarów oraz danych z IMU i odometrii. Fuzja danych z dodatkowych czujników poprawia jakość budowanej mapy, redukując błędy wynikające z dryftu oraz niepewności pomiarowej pojedynczych sensorów.

IMU dostarcza informacji o orientacji platformy, rejestrując przyspieszenia i prędkości kątowe, co pozwala na kompensację przechyłów i stabilizację danych z lidarów. Dzięki temu możliwe jest precyzyjne odwzorowanie terenu, nawet w dynamicznych warunkach, gdzie występują nagłe zmiany nachylenia.

Odometria z kół dostarcza informacji o przebytej drodze oraz zmianie pozycji w układzie współrzędnych lokalnych, co umożliwia stabilizację trajektorii i wspomaga śledzenie pozycji pojazdu w dłuższym okresie czasu. W połączeniu z danymi lidarowymi pozwala to na eliminację błędów wynikających z chwilowych niedokładności sensorów.

Informacje pochodzące z wszystkich czujników są łączone z wykorzystaniem Filtra Kalmana, który estymuje najbardziej prawdopodobną trajektorię ruchu oraz pozycję w przestrzeni, uwzględniając niepewności pomiarowe poszczególnych sensorów. Dzięki temu system ATENA generuje mapę o wysokiej dokładności, odporności na zakłócenia oraz dobrej jakości odwzorowania geometrii otoczenia.

Na podstawie chmur punktów generowana jest mapa 2,5D, odwzorowująca ukształtowanie terenu w postaci siatki wysokościowej o regularnym podziale przestrzeni. Punkty lidarowe są przekształcane do siatki o ustalonej rozdzielczości, a wysokość w każdej komórce wyznaczana jest na podstawie mediany wartości wysokościowych punktów przypisanych do danej komórki. Chmura punktów może być reprezentowana jako zbiór S [16]:

$$S = \{x_i, y_i, z_i\} \quad (4)$$

gdzie:

- x_i, y_i, z_i – to współrzędne 3D punktu pomiarowego.

W celu utworzenia mapy 2,5D należy przeprowadzić dyskretyzację chmury punktów, w celu utworzenia mapy o siatce prostokątnej każdy punkt można przypisać do komórki tak jak poniżej [113]:

$$x_s = \lfloor x / w \rfloor \quad (5)$$

$$y_s = \lfloor y / w \rfloor$$

gdzie:

- x, y – oryginalne współrzędne w chmurze punktów,
- x_s, y_s – dyskretne współrzędne w siatce kwadratowej,
- w – szerokość jednej komórki.

Wysokość powierzchni jednej komórki jest obliczana na podstawie [16]:

$$z_s = \frac{1}{n} \sum_{i=1}^n z_i \quad (6)$$

gdzie:

- z_s – wysokość obszaru reprezentowanego przez komórkę,
- n – liczba punktów przypisanych do komórki,
- z_i – współrzędna z dla punktu i , który jest przypisany do danej komórki.

Do dalszej analizy przyjęto wielkość mapy, w której prowadzona jest analiza jako okno o wymiarach 45m x 45m, w formie siatki kwadratowej o wielkości komórki 0,5m.

Przy okazji badań przedstawionych w artykule [113], w którym wykorzystano dane zbudowane przez pojazd PIAP ATENA, udowodniono że warto również rozważać zastosowanie mapy o siatce heksagonalnej jako bazy do analizy przejezdności. Na mapie z siatką heksagonalną są prowadzone analizy w dalszej części pracy, w której dodatkowo jest analizowana informacja semantyczna o otoczeniu.

4.3.2 Analiza przejezdności z wykorzystaniem mapy 2,5D

Do analizy przejezdności przyjęto rozwiązanie wzorowane na metodzie Chiliana [74] opisanym szeroko w podrozdziale 4.1.1.2, ale w wersji zmodyfikowanej przez Wermelingera [18] i m.in. w oparciu o pakiet ROS *traversability_estimation* rozwijany przez Robotic Systems Lab - Legged Robotics ETH Zürich [19], w rozwoju tego pakietu uczestniczył m.in. Wermelinger.

W ramach analizy przejezdności uwzględniane są trzy komponenty przejezdności. Wynikowa przejezdność z zakresu $[0, 1]$ (zupełnie nieprzejezdny, bezproblemowo przejezdny) wyznaczana jest jako ważona suma komponentów, zerowana w przypadku przekroczenia, którejkolwiek wartości krytycznej, tak jak poniżej:

$$\begin{aligned} \text{Przejezdność} = \\ = 1 - a \cdot \text{Lokalne nachylenie} - b \cdot \text{Lokalna nierówność} - c \cdot \\ \cdot \text{Lokalna różnica wysokości} \end{aligned} \quad (7)$$

Parametry komponentów zostały dobrane empirycznie na podstawie odtwarzania zapisanych przejazdów pojazdu PIAP ATENA przez zróżnicowane tereny na poligonie testowym. W zakresie parametrów a, b, c , nie zastosowano zróżnicowania wag w sumie ważonej i przyjęto dla każdego z nich wartość $\frac{1}{3}$.

Dla wszystkich komponentów definiowana jest wartość krytyczna, służąca do normalizacji oraz określenia możliwości jezdnych platformy. Po przekroczeniu wartości krytycznej przejezdność komponentu jest ustawiana na 0. Sposób wyznaczania zaczerpnięto z [74]. Implementacja bazuje na pakiecie *traversability_estimation* [19].

Tabela 2. Komponenty oceny przejezdności.

Komponent	Sposób wyznaczania	Parametry
Lokalne nachylenie (Kąt nachylenia)	Wyznaczenie normalnych do powierzchni (uśrednione w promieniu). Następnie wyznaczenie kąta nachylenia (arcus cosinus). Ostateczna przejezdność oparta na komponencie lokalnego nachylenia normalizowana jako: $\text{Lokalne nachylenie} = 1 - \frac{\text{kąt}}{\text{kąt krytyczny}} \quad (8)$ (0 po przekroczeniu wartości krytycznej)	Promień Kąt krytyczny
Lokalna nierówność (Nierówność)	Wyznaczenie płaszczyzny w promieniu. Nierówność jako odchylenie standardowe odległości od płaszczyzny. Ostateczna przejezdność oparta na komponencie lokalnej nierówności normalizowana jako: $\text{Lokalna nierówność} = 1 - \frac{\text{nierówność}}{\text{nierówność krytyczna}} \quad (9)$ (0 po przekroczeniu wartości krytycznej)	Promień Nierówność krytyczna
Lokalna różnica wysokości (Stopień)	Wyznaczanie w dwóch krokach. W większym promieniu wyznaczana maksymalna różnica wysokości, zapisywana jako lokalna. W mniejszym promieniu określana maksymalna różnica (z uprzednio wyznaczonej) oraz zliczana liczba komórek przekraczających wartość krytyczną. $\begin{aligned} \text{stopień} = \\ = \min \left(\text{maksymalna_różnica}, \text{maksymalna_różnica} \cdot \right. \\ \left. \cdot \frac{\text{liczba_komórek}}{\text{liczność_krytyczna_komórek}} \right) \end{aligned} \quad (10)$ Ostatecznie przejezdność normalizowana jako:	Promień 1 Promień 2 Stopień krytyczny Liczność krytyczna komórek


Komponent	Sposób wyznaczania	Parametry
	$\text{Lokalna różnica wysokości} =$ $= 1 - \frac{\text{stopień}}{\text{stopień krytyczny}} \quad (11)$ 0 po przekroczeniu wartości krytycznej)	

Dla pojazdu ATENA poniżej uwzględniono poniższe parametry przejezdności. Parametry dobrano na podstawie analizy porównawczej nagranych przejazdów pojazdu PIAP ATENA przez system ATENA. W trybie analizy offline w której po włączeniu wizualizacji przejezdności dopasowano parametry do terenów, w których pojazd radził sobie z terenem.

Tabela 3. Parametry przejezdności przyjęte do badań.


Nazwa parametru	Wartość parametru	[jednostka]
Kąt nachylenia (Kąt krytyczny)	30	stopnie
Stopień (Stopień krytyczny)	25	cm
Nierówność (Nierówność krytyczna)	20	cm
Liczność krytyczna komórek	8	n/d
Promień 1	60	cm
Promień 2	50	cm
Promień	100	cm
Wielkość komórki	50	cm
Waga „a”	1/3	n/d
Waga „b”	1/3	n/d
Waga „c”	1/3	n/d

Poniżej wizualizacja pojedynczych map oraz ich sumy jako przejezdności. Na rysunku niżej zaprezentowana jest mapa 2,5D, która zawiera komórki jako dane wejściowe do oceny przejezdności. Kolory na tym rysunku oznaczają tylko wysokość komórki, dodatkowo jest naniesiona wizualizacja 3D otoczenia dzięki czemu mapa nie jest płaska. Na rysunku są dodane ujęcia z kamer pojazdu PIAP ATENA, na których widać, jak wygląda teren który jest odwzorowywany przez mapę 2,5D.




Rysunek 19. Na górze, wejście dla analizy przejezdności - mapa 2.5D (kolorem odwzorowano wysokość), na dole ujęcie z lewej strony na teren odwzorowywany przez mapę (zdjęcie wykonane przy innej pogodzie)

Na rysunku niżej, przedstawiona jest wizualizacja pierwszego komponentu przejezdności dotyczącego nachylenia terenu w komórce mapy. Skala koloru zmienia się w zależności od wartości w zależności – im bliżej wartości krytycznej tym kolor bardziej zmienia się z zielonego na czerwony. Komórki o kolorze czerwonym oznaczają wartość krytyczną oraz jej przekroczenie. Czyli tereny o nachyleniu większym niż 30° są zaznaczone na czerwono. Warto zaznaczyć, że na rysunku niżej widać pojedyncze komórki, których nachylenie przekracza wartość krytyczną, nie są one jednak zaznaczone na czerwono, gdyż ich nachylenie zostało jedynie zwizualizowane w danej chwili wykonania zdjęcia mapy. Na zdjęciu powyżej widać, że trasa pomiędzy dwoma wzniesieniami jest płaska. Chwilowe anomalie map zostały odfiltrowane i nie wpłynęły na analizę przejezdności.




Rysunek 20. Analiza przejezdności komponent nachylenie (slope, odwzorowane kolorem)

Na rysunku niżej, przedstawiona jest wizualizacja drugiego komponentu przejezdności dotyczącego nierówności terenu jako odchylenia standardowego od powierzchni o promieniu 100cm (więc dla siatka 50cm x 50cm – wpływ na wynik mają wszystkie 9 sąsiadujących komórek). Przyjęta nierówność krytyczna o wartości 20cm dokładnie analizuje złożoność powierzchni i nawet kostka, którą są wyłożone zbocza i która jest porośnięta roślinnością (małe źdźbła trawy wystające ponad kostkę) generuje wartości bliskie krytycznej nierówności.




Rysunek 21. Analiza przejezdności - komponent lokalna nierówność (roughness, odwzorowane kolorem)

Na rysunku wyżej, przedstawiona jest wizualizacja trzeciego komponentu przejezdności dotyczącego lokalnej różnicy wysokości między komórkami. Na czerwono zaznaczone są te elementy terenu (wraz z zapasową odległością), które przekraczają zdolności skoku zawieszenia (stopień krytyczny przyjęty jako 25 cm), a więc wjazd powodowałby podniesienie któregoś z kół, zawiśnięcie na przeszkodzie lub wpadnięcie któregoś z kół w dół. Promienie przyjęte w analizie odnoszą się do wielkości koła, liczność komórek zaś do rozstawu osi mierzonych w komórkach (8 komórek po 50cm to 4m).



Rysunek 22. Analiza przejeźdności - komponent lokalna różnica wysokości (step, odwzorowane kolorem)

Na rysunku niżej przedstawiono natomiast, sumę powyższych komponentów zgodnie ze wzorem (7), która odwzorowuje poprzez kolor zielony teren, w którym można bezpiecznie planować manewry. Informacja ta jest zarówno pomocna dla operatora pojazdu jak i może być wykorzystana do planowania trasy w trybie autonomicznej jazdy.



Rysunek 23. Analiza przejeźdności - sumaryczna przejeźdność (ważona suma, wyzerowana, jeżeli którykolwiek składnik przekroczy wartość krytyczną)

W rozdziale 5.5 zostały zaprezentowane wnioski z przeprowadzenia eksperymentu polegającego na sprawdzeniu implementacji powyższych rozważań w sterowniku autonomii w projekcie PIAP ATENA.

4.4 Metoda oceny przejezdności z analizą materiałów otoczenia

W eksperymencie opisanym w rozdziale 5.5, wykazano, że metoda oparta wyłącznie na analizie geometrycznej posiada istotne ograniczenia wynikające z jej charakteru, co ogranicza skuteczność pomiaru otoczenia. Na przykład, wysoka pojedyncza roślinność może być błędnie zaklasyfikowana jako nieprzekraczalna przeszkoda, a system nie reaguje na zmieniające się warunki drogowe. Planowanie trasy odbywa się na podstawie tych samych parametrów, bez względu na rodzaj podłoża – drogi, trawy czy śniegu. Tymczasem operator pojazdu dostosowuje prędkość, przewiduje długość hamowania i ogranicza przyspieszanie, co pozwala na zachowanie przyczepności i stabilności. System autonomii, który nie uwzględnia rodzaju podłoża, nie jest w stanie dokonywać takich dostosowań ani logicznie wybrać trasy po utwardzonej drodze, preferując najprostszą ścieżkę prowadzącą przez teren płaski.

Dla zwiększenia efektywności planowania trasy konieczne jest wzbogacenie danych używanych do mapowania przejezdności o informacje o materiale podłoża. Dane te mogą być pozyskiwane zarówno metodami dotykowymi i bezdotykowymi oraz deterministycznymi jak i niedeterministycznymi (np. algorytmy wykorzystujące sztuczną inteligencję).

Na podstawie powyższych badań poniżej przedstawiam metodę oceny przejezdności dla autonomicznego BPL z uwzględnieniem z analizą materiałów otoczenia dla potrzeb operatora systemu do planowania trasy, czy też do zwiększenia świadomości sytuacyjnej wokół BPL.

Metoda zakłada wykorzystanie standardowych sensorów występujących w BPL (Lidar, IMU, czujnik obrotu kół/gąsienic) oraz dodatkowego sensora w postaci kamery hiperspektralnej.

Metoda jest zaprojektowana w sposób ogólny, aby było możliwe jej aplikowanie do różnych sensorów czy klas BPL. Metoda umożliwia zastosowanie sensorów tylko na BPL, bez konieczności dodatkowego mapowania terenu z powietrza, za pomocą np. BSP. Nie mniej możliwe jest wykorzystanie metody do przygotowania mapy offline do globalnego planowania trasy co zaprezentowane zostało w publikacji [16].

Danymi wejściowymi są:

-dane z lidar + dane z IMU + dane z odometrii, po fuzji tych danych możliwe jest stworzenie chmury punktów wokół BPL (sumarycznie są to dane o geometrii otoczenia),

-dane z kamery hieprspektralnej – przebiegi spektralne otoczenia przed BPL, na podstawie tych danych możliwe jest stworzenie deterministycznej segmentacji semantycznej (sumarycznie są to dane o sygnaturze materiałowej otoczenia).

W metodzie używana jest mapa 2,5D opisana już wcześniej w poprzednim podrozdziale.

4.4.1 Analiza materiałów otoczenia z wykorzystaniem kamery hiperspektralnej

Badania zastosowania kamery hiperspektralnej zostały zawarte w mojej i współautorów publikacjach [14] i [15] oraz w rozdziale 5.6.

Kamera hiperspektralna wykorzystana do badań to Cubert Q285, która mierzy intensywność światła w zakresie spektralnym 450 nm - 950 nm podzielonym na 125 pasm spektralnych (czyli co 4 nm). Takie parametry oznaczają, że jeden zapisany piksel spektralny zawiera informacje o intensywności odbicia światła dla każdej długości fali od 450 nm do 950 nm z podziałem co 4 nm (czyli pasma: 450 nm, 454 nm, (...), 946 nm, 950 nm). Na rysunku poniżej przedstawiono, na wykresie po prawej stronie zawartość danych jednego piksela spektralnego.



Rysunek 24. Po lewej obraz z kamery hiperspektralnej Cubert Q285, po prawej wykres przebiegu hiperspektralnego dla jednego piksela zaznaczonego na czerwono na rysunku po lewej.

Obraz otoczenia widoczny na powyższym rysunku to efekt nałożenia obrazu z kamery panchromatycznej o rozdzielczości 1000 pikseli x 1000 pikseli na dane z kamery hiperspektralnej o rozdzielczości 50 pikseli x 50 pikseli (w uproszczeniu na płaszczyźnie 2D – w rzeczywistości sam sensor hiperspektralny jest reprezentowany jako obiekt przestrzenny o rozdzielczości dla kamery Cubert Q285 - 50 pikseli x 50 pikseli x 125 pasm spektralnych). Nałożenie obrazów nie wprowadza zniekształceń, bo kamery „współdzielą” ten sam obiekt.

W publikacji [14] koncentruję się na badaniach nad wykorzystaniem kamery hiperspektralnej do klasyfikacji różnych typów podłoża w kontekście autonomicznych pojazdów terenowych. W artykule przedstawiono wyniki eksperymentów przeprowadzonych w rzeczywistym środowisku, gdzie kamera hiperspektralna była wykorzystywana do rozpoznawania takich powierzchni jak asfalt, droga leśna, droga gruntowa czy trawa. W przeprowadzonym eksperymencie w rozdziale 5.6, potwierdzono możliwość otrzymania obrazu segmentacji semantycznej otoczenia na podstawie danych z kamery hiperspektralnej umiejscowionej na BPL, co umożliwia stosowanie tej metody zarówno do tworzenia globalnej mapy przejezdności zmapowanego terenu, jak i lokalnej mapy przejezdności podczas mapowania terenu.

W przeprowadzonych badaniach w [14] i [15], wykorzystano metodę porównywania histogramów jako technikę klasyfikacji rodzaju podłoża na podstawie danych z kamery hiperspektralnej. Metoda ta umożliwia ocenę stopnia podobieństwa między zarejestrowanymi obrazami a wcześniej opracowanymi modelami klas powierzchni. Każdy fragment (w uproszczeniu piksel) obrazu hiperspektralnego jest analizowany pod kątem rozkładu intensywności odbitego światła w różnych pasmach spektralnych, a następnie przypisywany do odpowiedniej klasy powierzchni na podstawie porównania histogramów.

W celu analizy powierzchni dane hiperspektralne są przekształcane w histogramy odzwierciedlające rozkład intensywności odbicia w określonych długościach fali. Każdy histogram reprezentuje charakterystyczny sygnał spektralny danego fragmentu obrazu (Rysunek 24.)

4.4.1.1 *Metody porównywania histogramów*

Odległość korelacyjna - pierwszą analizowaną metodą była odległość korelacyjna, która określa stopień zgodności kształtu rozkładów intensywności między histogramami. Jest to podejście, które sprawdza się w przypadku powierzchni o stabilnych i wyraźnie rozpoznawalnych charakterystykach spektralnych. Metoda ta wykazuje wysoką skuteczność w sytuacjach, w których kluczowe znaczenie ma zachowanie proporcji między wartościami intensywności odbicia. Jednakże jej ograniczeniem jest podatność na zmiany ogólnej jasności obrazu, co może prowadzić do błędów w klasyfikacji w zmiennych warunkach oświetleniowych.

Metoda części wspólnej histogramów - drugą testowaną metodą była metoda części wspólnej histogramów, która bazuje na porównaniu minimalnych wartości intensywności w odpowiadających sobie przedziałach histogramów. Podejście to umożliwia określenie, w jakim stopniu dwa rozkłady pokrywają się ze sobą. Metoda ta jest szczególnie skuteczna w przypadku powierzchni o podobnych właściwościach spektralnych, ale różniących się intensywnością odbicia. Zaletą tej metody jest jej odporność na lokalne zmiany oświetlenia, jednak nie zawsze pozwala ona na precyzyjne rozróżnienie powierzchni o podobnym kształcie rozkładu spektralnego.

Metoda chi-kwadrat - najlepsze wyniki klasyfikacji uzyskano przy zastosowaniu metody chi-kwadrat. Jest to podejście bazujące na sumie różnic pomiędzy odpowiadającymi sobie wartościami histogramów, uwzględniające ich rozkład i intensywność. Dzięki temu metoda ta jest w stanie precyzyjnie identyfikować nawet niewielkie różnice w strukturze spektralnej badanych powierzchni. Zastosowanie tej metody pozwoliło na skuteczne rozróżnienie różnych typów podłoża, w tym asfaltu, dróg gruntowych oraz terenów pokrytych roślinnością.

4.4.1.2 *Klasyfikacja obrazu hiperspektralnego*

Tradycyjne metody klasyfikacji, takie jak klasyczna metoda najbliższego sąsiada (Nearest Neighbor, NN), przypisują nowej próbce klasę na podstawie odległości od najbliższego punktu w zbiorze uczącym. W kontekście obrazowania hiperspektralnego podejście to jest jednak niewystarczające, ponieważ sygnał spektralny jest złożony i wymaga bardziej zaawansowanych metod analizy. W związku z tym zaproponowano zmodyfikowaną metodę

najbliższego sąsiada, która rozszerza klasyczne podejście poprzez wykorzystanie porównywania histogramów oraz uwzględnienie informacji o lokalnym sąsiedztwie.

Proponowana metoda składa się z dwóch głównych etapów:

1. Wstępna klasyfikacja piksela na podstawie testu chi-kwadrat.
2. Analiza sąsiedztwa i korekta przypisanej klasy.

Pierwszym krokiem klasyfikacji jest porównanie histogramu spektralnego badanego piksela z zestawem wzorcowych histogramów reprezentujących różne klasy powierzchni. Zamiast klasycznych miar odległości, takich jak metryka euklidesowa, zastosowano test chi-kwadrat, który pozwala ocenić różnice w strukturze rozkładów spektralnych [15]:

$$d_{\chi^2}(X, Y) = \sum_{i=1}^n \frac{(x_i - y_i)^2}{x_i + y_i} \quad (12)$$

gdzie:

- X to histogram badanego piksela,
- Y to histogram wzorcowy danej klasy,
- x_i i y_i to wartości intensywności w poszczególnych przedziałach histogramu,
- n oznacza liczbę przedziałów histogramu, czyli liczbę różnych wartości, które są porównywane w dwóch histogramach X i Y .

Piksel zostaje zapisany do klasy C^* , dla której wartość testu chi-kwadrat jest najmniejsza:

$$C^* = \arg \min_C \sum_{i=1}^n \frac{(H_{P,i} - H_{C,i})^2}{H_{P,i} + H_{C,i}} \quad (13)$$

gdzie:

- C^* – klasa, do której przypisujemy badany piksel (np. asfalt, trawa, droga gruntowa).
- C – indeks klasy referencyjnej w bazie wzorcowych histogramów,
- n – liczba przedziałów histogramu (liczba pasm spektralnych w analizie hiperspektralnej),

- $H_{P,i}$ – wartość histogramu dla badanego piksela w przedziale i (czyli intensywność odbicia światła w danym paśmie spektralnym),
- $H_{C,i}$ – wartość histogramu dla klasy wzorcowej C w przedziale i (czyli referencyjna intensywność odbicia dla danej klasy).

Wzór (13) pozwala znaleźć klasę wzorcową, do której najbardziej pasuje piksel, poprzez porównanie jego histogramu z referencyjnymi histogramami różnych klas. Dzięki temu metoda ta sprawdza podobieństwo sygnału spektralnego:

- Jeżeli histogram badanego piksela H_P jest bardzo podobny do histogramu klasy wzorcowej H_C to różnice $(H_{P,i} - H_{C,i})$ będą małe, więc wynik testu chi-kwadrat będzie mały.
- Jeżeli histogram badanego piksela znacznie różni się od histogramu klasy wzorcowej, to suma błędów będzie większa, a wynik testu chi-kwadrat większy.
- Wybierana jest najmniejsza wartość testu chi-kwadrat, bo oznacza ona największe dopasowanie.

Po przypisaniu klasy do piksela na podstawie testu chi-kwadrat następuje analiza otoczenia piksela w celu eliminacji błędów klasyfikacji wynikających z lokalnych zakłóceń, granic między klasami lub szumów spektralnych. W tym celu dla każdego piksela sprawdzane jest jego najbliższe sąsiedztwo, na przykład w postaci okna 3x3.


Jeżeli większość sąsiadujących pikseli należy do innej klasy niż przypisana wstępnie, klasyfikacja zostaje skorygowana zgodnie z regułą dominującej klasy w otoczeniu:

$$C^{\text{final}} = \arg \max_C \sum_{Q \in S(P)} \delta(C_Q, C) \quad (14)$$

Gdzie:

- $S(P)$ to zbiór sąsiednich pikseli badanego piksela P ,
- C_Q to klasa sąsiedniego piksela Q ,
- $\delta(C_Q, C) = 1$, jeśli $C_Q = C$, w przeciwnym razie 0.


Jeśli np. test chi-kwadrat przypisał pikselowi klasę "asfalt", ale większość jego sąsiadów należy do klasy "trawa", oznacza to, że prawdopodobnie został on błędnie sklasyfikowany i należy go przeklasyfikować na "trawę". W ten sposób eliminowane są artefakty klasyfikacyjne na granicach klas oraz błędy wynikające z pojedynczych anomalii spektralnych. Na rysunku poniżej graficznie jest przedstawiona metoda. Dla każdego piksela obrazu hiperspektralnego prowadzona jest analiza przebiegu histogramu, jeśli histogram zgadza się ze znanym z bazy wiedzy to piksel jest zaklasyfikowany jako obszar o konkretnej nawierzchni. Następnie przeprowadzona jest analiza sąsiedztwa danego piksela, jeżeli materiał dominujący w sąsiedztwie jest inny to obszar piksela jest klasyfikowany do dominującego materiału nawierzchni w sąsiedztwie.



Rysunek 25. Dopasowanie klas materiałów do odpowiedzi spektralnych każdego z pikseli obrazu zebranego przez kamerę hiperspektralną. [15].

Najważniejsze cechy przyjętej metody to odporność na pojedyncze anomalie wynikające z „zabrudzenia” terenu elementami innych klas (piach na asfaltowej drodze) oraz minimalizacja błędów na granicy klas (wielkość badanego obszaru w granicach piksela hiperspektralnego jest znacząca i przebieg hiperspektralny jest uśrednieniem odbić od różnych materiałów).

Wynik klasyfikacji obrazu hiperspektralnego umożliwia wygenerowanie maski segmentacji semantycznej.



Rysunek 26. Maska semantyczna z przypisanymi klasami otoczenia. Po lewej obraz wejściowy, po prawej obraz po segmentacji (zielone - trawa, szare - droga asfaltowa). [15]

W rozprawie doktorskiej dla celów oceny przejeźdźności rozróżniam 6 klas terenu (rodzajów nawierzchni) oraz wartość nieznaną:

- Trawa
- Droga utwardzona
- Droga nieutwardzona
- Błoto
- Piach
- Woda
- Nieznany

Kolejnym krokiem jest rzutowanie informacji z segmentacji semantycznej z danych z kamery hiperspektralnej na model mapy wysokościowej będącej wynikiem analizy chmury punktów wytworzonych przez lidary.

4.4.2 Integracja danych geometrycznych i semantycznych

Dane semantyczne do danych geometrycznych można przypisać na poziomie chmury punktów na poziomie kalibracji danych z lidar z kamerą. Taka realizacja jest opisana w [114] i została przeprowadzona do realizacji funkcji podążania za celem w projekcie ATENA.

Lidar oraz kamera są fizycznie umieszczone na pojeździe, ale każde z tych urządzeń operuje w swoim lokalnym układzie współrzędnych. Ze względu na charakter danych z kamery i lidar, zdecydowanie łatwiej jest rzutować dane z chmury punktów (dane 3D) na obraz (dane 2D), ze względu na brak informacji o głębi z obrazu. Następnie w ramach tego samego układu współrzędnych można przypisać informacje semantyczne do konkretnych punktów pomiarowych z chmury punktów. Następnie na podstawie tych punktów z danymi semantycznymi generuje się mapę 2,5D zawierającą informacje o wysokości obszaru komórki i dominującym materiale nawierzchni. Kluczowym krokiem w tym procesie jest odpowiednia kalibracja oraz przekształcenie danych pomiędzy układami współrzędnych.

Dopasowanie danych z lidar do kamery wymaga określenia wzajemnego położenia kamery i lidar. Kalibracja definiuje przekształcenie między układem współrzędnych lidar $\mathbf{L}$, a układem kamery $\mathbf{C}$. Opisana jest ona macierzą transformacji:

$$\mathbf{T}_{L \rightarrow C} = \begin{bmatrix} \mathbf{R} & \mathbf{t} \\ 0 & 1 \end{bmatrix} \quad (15)$$

gdzie:

- $\mathbf{R} \in \mathbb{R}^{3 \times 3}$ – macierz obrotu opisująca rotację układu lidar względem kamery.
- $\mathbf{t} \in \mathbb{R}^{3 \times 1}$ – wektor translacji opisujący przesunięcie układu lidar względem kamery.

Przekształcenie współrzędnych punktu $\mathbf{P}_L$ z układu lidar do układu kamery zapisujemy jako:

$$\mathbf{P}_C = \mathbf{T}_{L \rightarrow C} \cdot \mathbf{P}_L \quad (16)$$

gdzie:

- $\mathbf{P}_L = (X_L, Y_L, Z_L, 1)^T$ – współrzędne punktu w układzie lidar,
- $\mathbf{P}_C = (X_C, Y_C, Z_C, 1)^T$ – współrzędne tego samego punktu w układzie kamery.

Konieczna jest jeszcze kalibracja optyczna kamery. Współrzędne punktu w układzie kamery muszą zostać przekształcone na współrzędne obrazu (piksele). Jest to realizowane za pomocą macierzy kalibracji wewnętrznej kamery:

$$K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (17)$$

gdzie:

- f_x, f_y – ogniskowe kamery w poziomie i pionie (w pikselach),
- c_x, c_y – współrzędne środka optycznego obrazu.

Po przeprowadzeniu kalibracji można przekształcić chmurę punktów z układu lidar do układu kamery (transformacja chmury punktów lidar do układu odniesienia kamery). Każdy punkt w chmurze $P_L(X,Y,Z)$ jest transformowany do układu kamery za pomocą wcześniej wyznaczonej macierzy $T_{L \rightarrow C}$, zgodnie z równaniem (16).

Po tej operacji każdy punkt z chmury ma nowe współrzędne względem kamery, które są wykorzystywane do rzutowania na obraz.

Rzutowanie chmury na obraz z wykorzystaniem modelu pinhole camera w [115], [116], polega na przekształceniu współrzędnych 3D do układu współrzędnych obrazu 2D, co pozwala każdemu punktowi z chmury punktów znaleźć odpowiedni piksel w obrazie. Rzutowanie jest realizowane według wzoru:


$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = K \cdot P_C \quad (18)$$

co w postaci rozwiniętej daje:

$$\begin{aligned} u &= \frac{f_x X_C}{Z_C} + c_x \\ v &= \frac{f_y Y_C}{Z_C} + c_y \end{aligned} \quad (19)$$

Kolejnym krokiem jest przypisanie informacji z obszaru obrazu, w którym są punkty z lidar, osiągając chmurę punktów zawierających dodatkową informację z obrazu. Po podstawieniu za obraz wyniku segmentacji semantycznej opisanej w podrozdziale 4.4.1.2 i pobraniu wartości piksela z maski semantycznej określającej materiał otoczenia osiągniemy chmurę z punktami o parametrach $P_{LM}(X,Y,Z,Material)$.

Usprawnieniem powyżej opisanej metody jest podejście opisane w [20], które różni się od powyższej metody tylko tym, że zamiast przypisywania materiału do pojedynczego punktu pomiarowego z lidar przypisuje się materiał do komórki mapy 2,5D. Kalibracja odbywa się na poziomie całej mapy 2,5D względem umiejscowionego wyniku segmentacji semantycznej (obrazu z kamery). Podejście, w którym zamiast chmury punktów podstawiana jest już przekształcona informacja w formie komórek mapy 2,5D jest szybsze, gdyż nie generuje ono zbyt dużej ilości obliczeń na poziomie łączenia danych semantycznych z geometrią terenu. Koncepcja [20] jest przedstawiona na rysunku poniżej.



Rysunek 27. Przypisanie punktów z wyniku segmentacji semantycznej do współrzędnych mapy 2,5D opisane w [20]

Podsumowując, przypisanie danych semantycznych z kamery hiperspektralnej do danych geometrycznych jest możliwe z wykorzystaniem metody pinhole camera, kolejnym krokiem będzie opracowanie mapy przejezdności.

4.4.3 Mapa przejezdności z uwzględnieniem semantyki

Na podstawie kroków opisanych do tej pory, możliwe jest obliczenie przejezdności dla każdej z komórek wykorzystując tablice danych z parametrami krytycznymi przejezdności dla każdego z materiałów które są analizowane.

Podstawową różnicą względem podejścia zespołu z ETH Zurich [18] oraz rozwiązania opartego jedynie o geometryczny model sprawdzony na poligonie z demonstratorem ATENA i opisany w podrozdziale 5.3, jest przyjęcie parametrów przejezdności dla danej komórki mapy w zależności od materiału otoczenia do którego te parametry się odnoszą. Mapa przejezdności będzie się, więc składać z komórek, będących wynikiem obliczenia przejezdności dla każdej z nich na podstawie kąta nachylenia, nierówności, wysokości stopnia oraz materiału. W ten sposób rozszerzona zostanie mapa przejezdności, która była badana na początku pracy o dane materiałowe co umożliwi optymalniejsze planowanie trasy. Poprawienie jakości planowania trasy z uwzględnieniem materiałów otoczenia udowodniliśmy wraz ze współautorami w publikacji [15], opis i wyniki eksperymentu potwierdzającego wzrost jakości planowania trasy jest zawarty w rozdziale 6.6. Wzrost jakości planowania trasy był spowodowany zmianą w wynikowej mapie kosztów przejazdu, preferencyjny materiał nawierzchni wpływa znacząco na rozkład kosztów na mapie.

4.4.4 Kroki realizacji metody oceny przejezdności, w wyniku której powstaje mapa przejezdności – podsumowanie

1. Generowanie mapy wysokościowej 2.5D

Dane z LiDAR i IMU są przetwarzane w celu stworzenia mapy 2.5D otoczenia:

- Algorytm mapowania wysokościowego - Stosuje się metodę elevation przetwarzania danych z LiDAR przy użyciu algorytmu [19]
- Precyzyjna lokalizacja - Dane z odometrii są wykorzystywane do eliminacji błędów w pozycji, natomiast w przypadku obecności sygnału nawigacji satelitarnej lokalizacja może być wsparta tymi danymi.

2. Segmentacja semantyczna materiałów

Dane z kamery hiperspektralnej są wykorzystywane do rozpoznania materiału podłoża:

- Analiza spektralna - Każdy piksel obrazu hiperspektralnego jest klasyfikowany do jednej z siedmiu klas: trawa, droga utwardzona, droga gruntowa, błoto, piach, woda, nieznany. Możliwość klasyfikacji potwierdzona w [14].
- Algorytm klasyfikacji - Wykorzystywana jest metoda porównania histogramów i najbliższego sąsiada dla pikseli hiperspektralnych zgodnie z [15].

- Powstaje obraz po segmentacji semantycznej z danych z kamery hiperspektralnej.

3. Tworzenie zintegrowanej mapy „Elevation and Material Map”

Dane z mapy wysokościowej oraz segmentacji semantycznej są łączone:

- Algorytm przypisania danych materiałowych - Metoda pinhole_camera do projekcji danych z kamery hiperspektralnej na mapę 2,5D. Zgodnie z algorytmem łączenia wyniku segmentacji semantycznej z mapą 2,5D z [20].

4. Ocena przejezdności

Na podstawie zintegrowanej mapy wyznaczane są kluczowe parametry na podstawie tablic z parametrami dla wybranego pojazdu i dla danego materiału. Dla pojazdu PIAP ATENA to będzie:

Tabela 4. Dane tabelaryczne parametrów przejezdności dla PIAP ATENA

Wartości krytyczne	Trawa	Droga utwardzona	Droga gruntowa	Bloto	Piach	Woda	Nieznany	[jednostka]
Kąt nachylenia	30	38	30	20	20	2	30	stopnie
Stopień	25	25	25	30	30	25	15	cm
Nierówność	20	15	15	10	10	1	10	cm

Poniżej zapis algorytmu w pseudokodzie:

```
def calculate_traversability(lidar_data, imu_data, odometry_data, hyperspectral_data):
    elevation_map = generate_elevation_map(lidar_data, imu_data, odometry_data)
    material_map = classify_material(hyperspectral_data)
    traversability_map = create_empty_map()

    for cell in elevation_map:
        material_type = material_map[cell]

    # Calculate local slope, roughness, and step
    slope = calculate_slope(cell, elevation_map)
    roughness = calculate_roughness(cell, elevation_map)
    step = calculate_step(cell, elevation_map)

    # Get critical values based on material type
    critical_slope_material, critical_roughness_material, critical_step_material =
    get_critical_values(material_type)

    # Normalize traversability parameters
    slope_traversability = max(0, 1 - slope / critical_slope_material)
    roughness_traversability = max(0, 1 - roughness / critical_roughness_material)
    step_traversability = max(0, 1 - step / critical_step_material)


    # Combine traversability with components
    traversability_score = 1 - slope_traversability - roughness_traversability -
    step_traversability

    # Assign traversability score to map cell
    traversability_map_material[cell] = traversability_score

    return traversability_map_material
```

4.5 Planowanie trasy z uwzględnieniem zmiennej dynamiki pojazdu na różnych materiałach podłoża

Kolejnym krokiem rozwoju metody jest rozszerzenie podejścia opartego o tabeli z parametrami czysto geometrycznymi o dodatkowe parametry określające dynamikę przejazdu po terenie. Takie parametry dynamiczne rozszerzają mapę przejezdności do takiego stopnia, że można ją nazwać mapą mobilności. Tego typu mapy zawierające informacje o ograniczeniach terenu dla danych rodzajów pojazdów stosowane są dla szybkiego planowania realizowalnej i szybkiej trasy, w nomenklaturze stosowanej w badaniach nad NG-NRMM[81] jest to mapa „Speed-Made-Good” poniżej przykład takiej mapy globalnej.




Rysunek 28. Przykład mapy Speed-Made-Good zgodnej z NRMM.[81]

Mapa taka ma szczególne znaczenie dla planowania przemieszczenia kolumn wojskowych, czy też planowania misji specjalnych w których liczy się szybkie dotarcie na miejsce docelowe.

4.5.1 Siły działające na pojazd i ich wpływ na planowanie trasy

W planowaniu trasy dla autonomicznych pojazdów terenowych kluczowe jest uwzględnienie sił działających na pojazd, które mają bezpośredni wpływ na jego zdolność do poruszania się w różnych warunkach terenowych. Te siły determinują maksymalną możliwą prędkość, zdolność do pokonywania wzniesień, przyspieszanie, hamowanie oraz stabilność w zakrętach.



Rysunek 29. Siły działające na pojazd podczas wjazdu na wzniesienie [16].

Każdy pojazd terenowy podlega działaniu sił wynikających z jego interakcji z podłożem, grawitacji oraz oporów ruchu. Możemy podzielić te siły na kilka podstawowych kategorii:

1. Siła napędowa F_t

Siła napędowa jest generowana przez układ napędowy i odpowiada za ruch pojazdu. Jest ona ograniczona przez:

- Moc silnika i moment obrotowy,
- Przyczepność opon do nawierzchni (maksymalna siła przenoszona przez tarcie),
- Rodzaj nawierzchni, na której porusza się pojazd.

Wzór na siłę napędową:

$$F_t = T_w \cdot r_w \quad (20)$$

gdzie:

- T_w – moment obrotowy na kołach,
- r_w – *promień kół*.

oraz:

$$F_t = \frac{P}{v} \quad (21)$$

gdzie:

- P – *moc pojazdu*,
- v – *prędkość pojazdu*.

2. Siła oporu toczenia F_r

Siła oporu toczenia zależy od współczynnika tarcia między oponą a podłożem oraz od masy pojazdu. Określa, ile energii jest tracone na odkształcenia opon i podłoża.

$$F_r = \mu_r \cdot m \cdot g \cdot \cos \alpha \quad (22)$$

gdzie:

- μ_r – współczynnik oporu toczenia,
- m – masa pojazdu,
- g – przyspieszenie ziemskie,
- α – kąt nachylenia terenu.

3. Siła grawitacji na zboczu F_g

Siła ta działa w dół stoku i jest odpowiedzialna za trudności w podjazdach i zwiększoną prędkość na zjazdach.

$$F_g = m \cdot g \cdot \sin \alpha \quad (23)$$

gdzie:

- m – masa pojazdu,
- g – przyspieszenie ziemskie,
- α – kąt nachylenia terenu.

4. Siła dośrodkowa w zakręcie F_c

Siła ta ma istotny wpływ na stabilność pojazdu w zakrętach i ogranicza maksymalną dopuszczalną prędkość.

$$F_c = \frac{mv^2}{R} \quad (24)$$

gdzie:

- m – masa pojazdu,
- v – prędkość pojazdu,
- R – promień skrętu pojazdu.

Aby uniknąć poślizgu, siła ta nie może przekroczyć siły tarcia bocznej:

$$\frac{mv^2}{R} \leq \mu_s mg \quad (25)$$

co po uproszczeniu daje maksymalną prędkość w zakręcie:

$$v_{\max} = \sqrt{\mu_s g R} \quad (26)$$

To ograniczenie prędkości jest kluczowe dla bezpieczeństwa jazdy w zakrętach i wpływa na globalne planowanie trasy (np. poprzez ustalenie konserwatywnego $R_{\min}$).

$$v_{\max} = \sqrt{\mu_s g R_{\min}} \quad (27)$$

Ustawienie stałego dopuszczalnego promienia minimalnego pokonywania zakrętów $R_{\min}$, umożliwia obliczenie wartości dopuszczalnej prędkości maksymalnej na danej nawierzchni, która cechuje się przewidywalnym współczynnikiem tarcia. Maksymalna prędkość wynika z warunku równowagi sił działających na pojazd:

$$F_t = F_r + F_g + F_c \quad (28)$$

Podstawiając wzory dla tych sił, otrzymujemy:


$$T_w \cdot r_w = \mu_r mg \cos \alpha + mg \sin \alpha + \frac{mv_{\max}^2}{R_{\min}} \quad (29)$$

Rozwiązując powyższe równanie względem v , dostajemy:

$$v_{\max} = \sqrt{\frac{R_{\min}}{m} (T_w r_w - \mu_r mg \cos \alpha - mg \sin \alpha)} \quad (30)$$

Przy założeniu parametrów pojazdu PIAP ATENA poniżej przedstawiam wykres zależności pomiędzy promieniem skrętu a maksymalną dopuszczalną prędkością dla nawierzchni typu błoto oraz asfalt. Przyjęte parametry:

- Masa pojazdu PIAP ATENA - 2200kg
- Moment obrotowy - 470Nm
- Średnica koła - 805mm
- Minimalny promień skrętu - 6,5m
- Współczynnik tarcia asfalt suchy - 0,8
- Współczynnik tarcia błoto - 0,2



Rysunek 30. Wykres maksymalnych dopuszczalnych prędkości w zależności od promienia zakrętu dla pojazdu PIAP ATENA.

Należy zwrócić dodatkowo uwagę, że w przypadku pominięcia w rozważaniach analizy sytuacji związanych z manewrami skręcania, czyli z obliczaniem trajektorii, głównymi parametrami, na których należy się skupić jest zapewnienie siły napędowej do pokonania siły oporów toczenia, siły grawitacji w przypadku podjazdu oraz siły rzeczywistej powodującej przyspieszenie pojazdu.

$$F_t = F_r + F_g + F \quad (31)$$

gdzie:


$$F = m \cdot a \quad (32)$$

- m – masa pojazdu,
- a – przyspieszenie pojazdu.

W złożonym terenie, gdzie występuje odkształcenie terenu należy rozważyć jednak jeszcze siłę reakcji podłoża.

5. Siła reakcji podłoża f_f [16]

Siła reakcji podłoża f_f , przeszkadza w ruchu pojazdu. Obejmuje zarówno tarcie, jak i inne efekty związane z interakcją opony z gruntem takie jak odkształcanie się opony i podłoża (błoto, piasek, śnieg) które zostało przedstawione na rysunku niżej.



Rysunek 31. Odkształcenie gruntu w trakcie jazdy [80].

W uproszczeniu siłę f_f można wyrazić jako:

$$f_f = k_f \cdot mg \cos \alpha \quad (33)$$

gdzie:

- k_f – współczynnik zależny od rodzaju podłoża (np. błoto ma wysoki k_f , asfalt niski).
- $mg \cos \alpha$ – składowa ciężaru działająca prostopadłe do podłoża.

Siła reakcji podłoża f_r może przyjmować różne wartości w zależności od nawierzchni:

- na twardej nawierzchni (asfalt, beton):
 - $f_r \approx 0$ (zaniedbywalne efekty odkształcenia),
 - opór pochodzi głównie z tarcia tocznego.
- Na miękkim podłożu (błoto, piasek, śnieg)
 - f_r jest duże, bo grunt się odkształca i „pochłania” energię.
 - Może być obliczane jako funkcja ciśnienia na podłożu i głębokości zanurzenia koła.
- Na trudnym terenie (grząskie błoto, mokry śnieg)
 - f_r może być większe niż siła napędowa, co spowoduje zakopanie pojazdu.

Warto zaznaczyć, że siła f_r w warunkach rzeczywistych może zmieniać się wraz z prędkością pojazdu, ciśnieniem opon oraz wilgotnością podłoża. Prosta reprezentacja zaproponowana w pracy powinna być stosowana do pojazdów generujących względnie niskie prędkości przejazdu oraz względnie niskie ciśnienie na grunt (niska masa pojazdu lub duża powierzchnia styku z gruntem).

Wartości F , F_r , F_g i f_r będą odpowiadać za zużycie energii i predykcje mobilności w kontekście zasięgu energetycznego pojazdu oraz są kluczowe w rozważania czy bezzałogowy pojazd pokona teren, innymi słowy to te parametry są istotne z perspektywy oceny przejezdności.


4.5.2 Uwzględnienie parametrów dynamicznych dla planera trajektorii

W celu uwzględnienia dynamiki możliwe jest rozszerzenie opisanej metody w podrozdziale 4.4 o dodatkowe parametry w tabeli, które przypisują do komórek mapy parametr maksymalnej dopuszczalnej prędkości. Dane te nie zmieniają mapy przejezdności pod kątem tego czy teren jest przejezdny czy też nie, ale dają informacje jak można planować trasę. Rozwijając przykład dla pojazdu PIAP ATENA, poniżej została przedstawiona rozszerzona tabela o parametry dynamiczne.

Tabela 5. Dane tabelaryczne parametrów przejezdności i dynamiki dla PIAP ATENA

Material	Trawa	Droga utwardzona	Droga gruntowa	Błoto	Piach	Woda	Nieznany	[jednostka]
Kąt nachylenia	30	38	30	20	20	2	30	stopnie
Stopień	25	15	15	25	25	25	15	cm
Nierówność	20	15	15	10	10	1	10	cm
V _{max}	30	80	30	20	20	15	20	km/h

Po przypisaniu powyższych parametrów do mapy 2,5D możliwa jest wizualizacja różnych typów map, w tym mapy dopuszczalnych prędkości w zależności od materiałów. Poniżej rysunek ilustrujący mapę maksymalnych prędkości dla pojazdu PIAP ATENA dla przykładowego terenu asfaltowego pokrytego częściowo błotem. Kolorem czerwonym jest zaznaczony region z maksymalną dopuszczalną prędkością dla PIAP ATENA na poziomie 80 km/h, a dla niebieskiego koloru zgodnie z przyjętymi danymi w tabeli 20 km/h. Zgodnie z informacjami z poprzedniego podrozdziału 4.5.1, w celu osiągnięcia takich prędkości konieczne jest dostosowanie promienia skrętu do wartości, w których nie wystąpi poślizg.



Rysunek 32. Po lewej mapa z podziałem na komórki z przypisanemu materiałom (droga utwardzana na szaro, błoto na czarno), pośrodku przypisane maksymalne prędkości dla tych typów materiałów, po prawej mapa z uśrednionym przejściem pomiędzy prędkościami. Rysunek pochodzi z [16].

Natychmiastowe zastosowanie ograniczenia prędkości z 80 km/h do 20 km/h nie jest możliwe w rzeczywistych warunkach, aby zapewnić płynne przejście pomiędzy różnymi strefami prędkości i uniknąć gwałtownych zmian, zastosowano metodę iteracyjnej aktualizacji

wartości prędkości w komórkach mapy. Proces ten przebiega według następujących kroków [16]:

1. Dla każdej komórki mapy uzyskiwana jest odpowiadająca jej wartość dopuszczalnej prędkości v .
2. Analizowane są komórki sąsiednie $\{c_i\}$.
3. Jeżeli różnica między prędkościami sąsiednich komórek przekracza dopuszczalną wartość a (maksymalna dopuszczalna różnica prędkości pomiędzy sąsiednimi komórkami), to wartość prędkości w komórce v_i zostaje zaktualizowana według wzoru:

$$v_i = v_j + a \quad (34)$$

gdzie:

- v_j to wartość prędkości sąsiadującej komórki.
4. Proces ten jest powtarzany aż do uzyskania stabilności, czyli do momentu, gdy wartości w komórkach mapy przestaną się zmieniać. (wynik działania powyższych kroków jest przedstawiony na rysunku 32. po prawej stronie).


Otrzymana mapa umożliwia planowanie trasy z użyciem zarówno planera trasy lokalnej jak i globalnej lokalnej (przy pominięciu aktualnego ograniczenia szybkości przetwarzania danych z kamery hiperspektralnej, lub zastąpieniu ich danymi z segmentacji semantycznej opartej model sztucznej inteligencji). Organicznie prędkości maksymalnej oraz dodanie parametrów geometrycznych oceny przejezdności terenu umożliwia planowanie trasy w sposób podobny do tego w jaki steruje pojazdem operator.

4.5.3 Kontroler dynamiki

Powyższą metodę można zoptymalizować w taki sposób, nie było konieczności budowania mapy przejezdności dla całego obszaru, a uwzględnić parametry przejezdności podczas obliczania ścieżki od punktu startu do celu. W publikacji [16] wraz ze współautorami skupiliśmy się na zagadnieniu uwzględnienia dynamiki podczas planowania trasy BPL. Uwzględnienie dynamiki stało się możliwe po wprowadzeniu pomiarów materiałów

otoczenia i zbudowaniu mapy, w której komórki posiadają informacje o wysokości i materiale nawierzchni.

Zgodnie z badaniami terenowymi opisanymi na początku rozdziału, kwestia maksymalnej prędkości jest realizowana w sposób automatyczny i intuicyjny poprzez operatora podczas wykonywania trasy, co istotne im bardziej doświadczony operator tym bardziej prowadzi pojazd w trybie teleoperacji w sposób pewny, bez niepotrzebnych przyspieszeń czy gwałtownych hamowań oraz względnie szybko, wykorzystując swoje doświadczenie do dostosowania stylu jazdy do nawierzchni jaką widzi przez kamery pojazdu. Próbę odzwierciedlenia tej metody prowadzenia pojazdu przeprowadziliśmy w ramach artykułu [16], w którym nie budujemy klasycznej mapy przejezdności, a obliczamy ją w czasie planowania trasy na podstawie kosztu przejazdu. W artykule przedstawiono koncepcje planowania trasy z uwzględnieniem metody dyfuzyjnej dla planowania ścieżki, umożliwiającej uwzględnienie kosztu przejazdu między komórkami mapy. Dodatkowo w poniższych rozważaniach wykorzystano mapę o siatce heksagonalnej zgodnie z badaniami z artykułu [113], gdyż długość trasy pomiędzy komórkami sąsiadującymi jest taka sama i ułatwia analizę. Na rysunku poniżej (Rysunek 33), przedstawiono różnice między siatką heksagonalną a prostokątną. Największą zaletą takiego podejścia jest taka sama odległość do środków komórek sąsiadujących. Wadą takiego podejścia jest konieczność indeksowania komórki przez 3 współrzędne pierwsze dwie współrzędne działają w sposób znany z indeksowania siatki kwadratowej, natomiast trzecia współrzędna określa czy komórka jest przesunięta. W pracy przyjęto przesunięcie jako parametry (1 i -1).



Rysunek 33. Porównanie siatki heksagonalnej do prostokątnej oraz długości przejścia między środkami komórek [16].

Zawartość komórki a_{rc} jest opisywana przez dwa parametry wysokość terenu w komórce oraz materiał nawierzchni terenu w komórce:

$$a_{rc} = \{h_{a_{r,c,1}}, \text{label}_{a_{r,c,1}}\} \quad (35)$$

- $a_{r,c,1}$ – komórka "a", z numerem kolumny "c", z numerem wiersza "r" i przesunięciem „1”.
- $h_{a_{r,c,1}}$ – wysokość powierzchni,
- $\text{label}_{a_{r,c,1}}$ – materiał nawierzchni.

Koszt przejazdu zgodnie ze wzorem (36), jest obliczany z uwzględnieniem parametru $e_{a_{r,l,1}}^{a_{r,j,1}}$, którego wartość zależy od nachylenia terenu (nachylenie między komórkami $a_{r,j,1}$ i $a_{r,l,1}$ – zaznaczonymi na rysunku Rysunek 33) oraz materiału podłoża, w przypadku trudnego do przejazdu podłoża i silnego nachylenia wartość parametru jest znacząca i podwyższa koszt przejazdu do tej komórki mapy. Parametr $e_{a_{r,l,1}}^{a_{r,j,1}}$ reprezentowany w sposób:

$$e_{a_{r,l,1}}^{a_{r,j,1}} = f(h_{a_{r,l,1}}, h_{a_{r,j,1}}, s_{a_{r,l,1}}, s_{a_{r,j,1}}) \quad (36)$$

gdzie:

- $a_{r,j,1}, a_{r,l,1}$ – komórki sąsiadujące
- $h_{a_{r,j,1}}$ – wysokość komórki, dla komórki $a_{r,j,1}$
- $h_{a_{r,l,1}}$ – wysokość komórki, dla komórki $a_{r,l,1}$
- $s_{a_{r,j,1}}$ – informacja o materiale komórki, dla komórki $a_{r,j,1}$
- $s_{a_{r,l,1}}$ – informacja o materiale komórki, dla komórki $a_{r,l,1}$

W celu znalezienia optymalnej ścieżki stosowany jest algorytm dyfuzyjny, który pozwala uwzględnić dynamiczne koszty podróży i zoptymalizować trasę. Inicjalizacja wartości kosztu przejazdu odbywa się poprzez przypisanie wartości komórki docelowej (z_G) wartości maksymalnej i wartości 0 dla pozostałych komórek. Wartość z dla każdej komórki jest następnie aktualizowana iteracyjnie według wzoru:

$$z_{a_{r,l,1}} = \max(z_{a_{r,l,1}}, \max_{c_{r,j,1} \in N^{a_{r,l,1}}} (z_{r,j,1} - e_{a_{r,l,1}}^{a_{r,j,1}} - zel_{a_{r,j,1}})) \quad (37)$$

gdzie:

- $N^{a_{r,l,1}}$ – zbiór sąsiadujących komórek,
- $zel_{a_{r,j,1}}$ – koszt przejazdu przez komórkę $a_{r,j,1}$.

Proces jest kontynuowany aż do osiągnięcia stanu równowagi, w którym wartości kosztu przejazdu przestają się zmieniać. Następnie uzyskana lista komórek służy do wyznaczenia ścieżki od aktualnej pozycji robota do celu. Pierwszą komórką w ścieżce jest pozycja początkowa pojazdu, a kolejne wybierane są na podstawie ich bliskości do poprzedniej oraz najwyższej wartości $z_{a_{r,j,1}}$. Proces ten trwa do momentu dotarcia do komórki o najwyższym z , odpowiadającej punktowi docelowemu.

Wprowadzenie parametru e pozwala na uwzględnienie dynamiki pojazdu już na etapie planowania, co umożliwia optymalne dostosowanie prędkości na poszczególnych odcinkach trasy. Takie podejście usprawnia proces planowania trasy z analizą przejeźdźności, gdyż

obliczanie przejezdności odbywa się w kierunku od punku początkowego do punktu docelowego.

Badania eksperymentalne zostały przedstawione w rozdziale 5.8. Wyniki wskazują, że zastosowanie informacji semantycznych oraz uwzględnienie parametrów pojazdu prowadzi do generowania różnych tras w tym samym środowisku – każda z nich dostosowana jest do specyficznych właściwości danego UGV, co pozwala zoptymalizować jego przejazd. Planowanie trasy dla różnych pojazdów zgodnie z tą metodą wskazuje na otrzymanie trasy dostosowanej do zdolności terenowej pojazdu.

5. Badania eksperymentalne

W tej części pracy zostaną opisane badania eksperymentalne w tym opis pojazdów PIAP, testy terenowe pojazdów PIAP, badanie kamery hiperspektralnej oraz eksperymenty w zakresie planowania trasy z uwzględnieniem danych o materiałach otoczenia.

5.1 Opis narzędzi umożliwiających badania

Ze względu na charakter wdrożeniowy pracy, wyniki badań muszą się odnosić do realnych pojazdów, sensorów i ich ograniczeń. W tym celu poniżej przedstawiam opis parametrów najważniejszego sprzętu, który był wykorzystywany podczas badań.


5.1.1 Demonstrator technologii PIAP ATENA

PIAP ATENA to demonstrator w postaci pojazdu terenowego typu pick-up, przystosowanego do cyfrowego sterowania z zainstalowanym sterownikiem autonomii, z oprogramowaniem realizującym funkcje podążania za wybranym celem (samochodem, człowiekiem). Na potrzeby pracy doktorskiej zostały wykorzystane możliwości jakie oferuje platforma, a mianowicie zintegrowany system autonomii wraz z czujnikami budującymi model otoczenia wokół pojazdu oraz algorytmy planowania trasy na mapie otoczenia.



Rysunek 34. Demonstrator technologii PIAP ATENA z kamerą hiperspektralną zamontowaną na masce pojazdu.

Pojazd jest wyposażony w komputer autonomii oraz monitor do wizualizacji pracy systemu w sposób wygodny dla operatora pojazdu.



Rysunek 35. Wnętrze demonstratora technologii PIAP ATENA

Pojazd jest wyposażony w zestaw sensorów wizyjnych:

- 4 sztuki Velodyne VLP16
- 4 kamery światła widzialnego BASLER

Poniżej parametry techniczne użytych sensorów:

Tabela 6. Parametry Velodyne VLP16

Parametr	Wartość
Zakres pomiarowy	100 m
Dokładność pomiaru	±3 cm (typowo)
Liczba kanałów (laserów)	16
Prędkość skanowania	5 Hz - 20 Hz
Rozdzielczość kątowna (pionowa)	2.0°
Pole widzenia (pionowe)	±15° (30°)
Pole widzenia (poziome)	360°
Rozdzielczość kątowna (pozioma)	0.1° - 0.4°
Szybkość generowania punktów	~300,000 - 600,000 punktów/sekundę
Wymiary	Ø103 mm x 72 mm
Stopień ochrony	IP67
Zakres temperatur pracy	-10°C do +60°C

Tabela 7. Parametry kamery Basler acA1920-48gc

Parametr	Wartość
Rozdzielczość	1920 x 1200 pikseli (2,3 MP)
Typ sensora	CMOS, Global Shutter
Model sensora	ON Semiconductor PYTHON 2000
Format sensora	2/3"
Rozmiar piksela	4.8 μm x 4.8 μm
Obszar aktywny obrazu	9.22 mm x 5.76 mm
Częstotliwość klatek	50 fps
Głębokość bitowa	10 bit
Interfejs	Gigabit Ethernet (GigE Vision), PoE
Moc poboru	3.5 W
Zasilanie	12-24 VDC, PoE
Typ migawki	Global Shutter
Zakres temperatur pracy	0°C do 50°C
Wymiary	42 mm x 29 mm x 29 mm
Masa	90 g
Mocowanie obiektywu	C-Mount

5.1.2 Kamera hiperspektralna Cubert Q285

Na potrzeby badań nad analizą przejeźdności z wykorzystaniem semantycznej informacji o materiałach otoczenia pojazd PIAP ATENA został wyposażony w kamerę hiperspektralną Cubert Q285. W toku prac koncepcyjnych prowadzonych w projekcie ATENA w 2018 roku zdecydowano, że aby poprawić jakość wykrywania przeszkód na trasie przejazdu, jeden z demonstratorów ATENA zostanie wyposażony w kamerę spektralną, która rozszerzy możliwości percepcyjne systemu, zwłaszcza w zakresie wykrywania i rozpoznawania przeszkód roślinnych. Dodatkowa klasyfikacja roślinności za pomocą kamery

hiperspektralnej ma na celu poprawę jakości planowania ścieżki, po której przemieszcza się pojazd.

Z uwagi na te oczekiwania przetestowano hiperspektralną kamerę migawkową pod kątem wykrywania sygnatur spektralnych materiałów roślinnych. Wybrano technologię migawkową (snapshot), która, w przeciwieństwie do klasycznych kamer linijkowych, pozwala na natychmiastowe budowanie pełnego obrazu spektralnego, podobnie jak w przypadku standardowych kamer matrycowych. Migawkowa konstrukcja umożliwia pozyskiwanie obrazu bez potrzeby skanowania i pozwala na natychmiastowe generowanie obrazu w czasie rzeczywistym, co jest kluczowe dla zastosowania w pojazdach naziemnych takich jak PIAP ATENA.

Tabela 8. Parametry techniczne kamery Cubert Q285

Parametr	Wartość
Zakres spektralny	450 nm - 950 nm
Liczba pasm spektralnych	125
Rozdzielczość hiperspektralna	50 x 50 pikseli
Prędkość przetwarzania	1 klatka na sekundę
Czas integracji	0,1 ms - 1000 ms
Format sensora	CMOS
Rodzaj migawki	Global Shutter
Zasilanie	PoE (Power over Ethernet) lub DC 12V
Interfejs	Gigabit Ethernet (1 Gbps)
Waga	1.6 kg
Wymiary	195 mm x 122 mm x 105 mm
Stopień ochrony	IP67 (ochrona przed kurzem i wodą)
Temperatura pracy	-20°C do +50°C



Rysunek 36. Kamera hiperspektralna Cubert Q285 [15]

Dzięki zastosowaniu kamery hiperspektralnej Cubert Q285 przedstawionej na zdjęciu powyżej, system autonomii jazdy demonstratora PIAP ATENA zyskał dostęp do dodatkowej warstwy danych o otoczeniu, umożliwiając analizę składu materiałowego terenu, co pozwala na bardziej precyzyjne planowanie ścieżki przejazdu oraz poprawę jakości oceny przejezdności.

5.1.3 Sterownik autonomii PIAP

W terenach nieustrukturyzowanych, pozbawionych infrastruktury drogowej, system Atena operował przy użyciu uproszczonego modelu otoczenia 3D oraz modelu mechanicznego pojazdu, którym sterował. Doświadczenia z tego projektu stały się podstawą do opracowania uniwersalnego sterownika autonomii, który jest zdolny do funkcjonowania w wymagających warunkach terenowych.

Uniwersalny sterownik autonomii, zbudowany na bazie doświadczeń Łukasiewicz-PIAP zdobytych w projekcie ATENA („Autonomiczny system dla terenowych platform lądowych z funkcją podążania za celem” DOB-2P-02-13-2018 ATENA, NCBR, realizowany w okresie

15.01.2018–15.01.2021), cechuje się wysoką mocą obliczeniową. Jest ona niezbędna do uruchamiania zaawansowanych algorytmów autonomii, szczególnie w fazie badawczej, kiedy optymalizacja szybkości działania oprogramowania nie jest jeszcze przeprowadzona. Sterownik, przeznaczony do testowania algorytmów autonomii jazdy w silnie nieustrukturyzowanym terenie, został zaprojektowany tak, aby był odporny na ciężkie warunki pogodowe oraz środowiskowe (odporność na wodę oraz kurz).

Aby sprostać wymaganiom obliczeniowym, sterownik wykorzystuje wysokiej klasy podzespoły komputerowe, w tym wielordzeniowy procesor oraz co najmniej dwie karty graficzne o pamięci 24 GB każda. Ze względu na te wymagania, sterownik chłodzony jest cieczą i zamknięty obudowie. W celu zwiększenia odporności na udary i wibracje, komponenty komputerowe zostały zamocowane na wzmocnionej konstrukcji wewnętrznej. Łukasiewicz-PIAP posiada doświadczenie w opracowywaniu takich sterowników, co potwierdza realizacja projektu ATENA, w ramach którego zaprojektowano wzmocniony mechanicznie sterownik autonomii jazdy dla pojazdu terenowego typu pick-up. Miałem zaszczyt być jednym z projektantów tego urządzenia, które powstało w 2018 roku. W projekcie DEZROB opracowano mobilną wersję sterownika autonomii, dostosowaną do robotów mobilnych PIAP.

5.1.4 Parametry terenowe wybranych pojazdów PIAP

Wybór pojazdów do testów nad autonomią i analizą przejeżdżalności został oparty na dostępnych platformach badawczych w Łukasiewicz-PIAP, co obejmuje różnorodne klasy pojazdów mobilnych zróżnicowane pod względem napędu i konstrukcji, w tym PIAP HUNTeR, PIAP PATROL oraz PIAP ATENA.



Rysunek 37. Pojazdy PIAP które zostały wykorzystane w badaniach.

Taki dobór odzwierciedla potrzeby instytutu oraz pozwala na kompleksowe testowanie rozwiązań w różnych scenariuszach operacyjnych, co jest spójne ze strategią rozwoju technologii dla pojazdów autonomicznych. Dobór ten jest również odpowiedzią na szeroki wachlarz wymagań wojskowych, gdzie różne klasy pojazdów mogą pełnić odmienną rolę – od wsparcia bojowego po scenariusze ewakuacji medycznej czy zastosowania logistyczne.

Demonstrator technologii PIAP ATENA bazuje na pojeździe typu pick-up FORD Ranger z 2018 roku. Poniżej parametry jezdne przedstawione w formie tabeli.

Tabela 9. Parametry jezdne PIAP ATENA

Parametr	Wartość
Moc silnika	200 KM (147 kW)
Moment obrotowy	470 Nm
Przyspieszenie 0-100 km/h	Około 10,6 sekundy
Napęd	4x4
Prześwit	237 mm
Maksymalny kąt nachylenia	32°
Kąt natarcia	28°
Kąt zejścia	28°
Maksymalna masa całkowita	3200 kg
Masa własna	2102 kg
Zużycie paliwa (cykl mieszany)	7,5 l/100 km
Pojemność zbiornika paliwa	80 litrów
Emisja CO ₂	197 g/km
Średnica koła z oponą	~ 31,7 cala (805 mm) dla opony 265/60 R18
Ilość osi skrętnych	1
Średnica zawracania	13 metrów (promień 6,5m)

Tabela 10. Parametry jezdne PIAP HUNTeR

Parametr	Wartość
Moc silników	Dwa silniki elektryczne wspomagane generatorem o mocy max 100kW
Prędkość maksymalna	50 km/h
Napęd	4x4
Prześwit	50cm
Maksymalny kąt nachylenia	45
Kąt natarcia	38
Kąt zejścia	38
Masa	4,5 tony
Średnica koła z oponą	1 metr
Ilość osi skrętnych	2
Średnica zawracania	17 metrów

Tabela 11. Parametry jezdne PIAP PATROL

Parametr	Wartość
Prędkość maksymalna	8 km/h
Napęd	Gąsienicowy
Prześwit	10 cm
Maksymalny kąt nachylenia	45
Kąt natarcia	38
Kąt zejścia	38
Maksymalna masa całkowita	120kg
Masa własna	100 kg
Średnica felgi	Brak danych (pojazd gąsienicowy)
Średnica koła z oponą	Nie dotyczy (pojazd gąsienicowy)
Średnica zawracania	<1m (pojazd nieholonomiczny)

Tabela 12. Syntetyczne porównanie zdolności terenowych rozpatrywanych pojazdów Łukasiewicz-PIAP

UGV	Łukasiewicz-PIAP ATENA	Łukasiewicz-PIAP (DEZROB Version)	PIAP HUNTeR
Prześwit	200 mm	100 mm	500 mm
Masa	2200 kg	100 kg	4000 kg
Średnica zawracania	holonomiczny 12,7 m	nieholonomiczny 980 mm	17 metrów
Długość	5389 mm	980 mm	4700 mm
Szerokość	1850 mm	570 mm	2200 mm
Wysokość	2015 mm	125 mm	1500 mm (bez payloadu)
Średnica kół	265/60 R18 ~81 cm	Brak danych	~100 cm
Gąsienice	-	Szerokość: 100 mm, Wysokość z przodu robota: 250 mm	-
Prędkość maksymalna	30 km/h	8 km/h	50 km/h
Kąt natarcia	29°	38°	38°
Kąt zejścia	21°	38°	38°
Maksymalna przeszkoda skokowa do pokonania	200 mm	250 mm	450mm
Kluczowe zastosowanie	Testy autonomii i przejezdności, uniwersalna platforma badawcza	Manewrowość, logistyka, działania specjalne	Operacje taktyczne, wsparcie bojowe

Dobór pojazdów badawczych jest zgodny z podejściem Łukasiewicz-PIAP do rozwoju systemów autonomicznych zdolnych do operowania w nieustrukturyzowanym terenie.

Pojazdy te różnią się zarówno masą, jak i typem napędu oraz zdolnościami terenowymi, co umożliwia testowanie systemu autonomii na szerokim spektrum parametrów operacyjnych. Takie podejście sprzyja rozwojowi uniwersalnego algorytmu autonomii oraz elastycznego systemu oceny przejezdności, które mogą zostać wdrożone w pojazdach różnych klas, odpowiadając na zróżnicowane wymagania wojskowe, od działań logistycznych po bezpośrednie wsparcie bojowe.

W dalszej części rozprawy doktorskiej głównym pojazdem, na którym będą prowadzone testy oraz symulacje, jest PIAP ATENA. Pojazd ten został specjalnie opracowany jako platforma badawcza, dostosowana do potrzeb analiz autonomii jazdy oraz oceny przejezdności terenu, co czyni go optymalnym wyborem do tego typu badań. PIAP ATENA umożliwia stosunkowo łatwe i bezpieczne przeprowadzanie eksperymentów, w tym nagrywanie i archiwizację niezbędnych danych o otoczeniu, co stanowi cenny materiał do dalszej analizy i symulacji w środowisku laboratoryjnym.

Pozostałe pojazdy, takie jak PIAP HUNTeR i PIAP PATROL, zostaną włączone do badań jako platformy porównawcze, które umożliwiają testowanie uniwersalności podejścia oraz ocenę przejezdności terenu w różnych warunkach operacyjnych. Taki dobór pojazdów pozwala na kompleksową ocenę algorytmu autonomii w pojazdach o zróżnicowanych parametrach terenowych, co jest kluczowe dla rozwoju uniwersalnych rozwiązań autonomicznych.

Docelowo system autonomii jazdy, rozwijany w ramach niniejszej pracy, ma być wdrożony w PIAP HUNTeR, największej platformie bezzałogowej Łukasiewicz-PIAP, której zdolności terenowe oraz potencjał adaptacyjny odpowiadają wymaganiom operacyjnym współczesnych służb wojskowych i specjalnych.

5.2 Badanie rozmieszczenia lidarów na pojeździe – dane dla mapy 2,5D

Rozmieszczenie czujników wizyjnych na platformie mobilnej jest kluczowe do optymalnej pracy całego procesu analizy przejezdności, z tego powodu przeprowadzono badania danych zbieranych z czujników w zależności od ich umieszczenia na pojeździe PIAP ATENA. Ze względu na dość niską rozdzielczość sensora typu lidar (16 warstw-Velodyne VLP-16), badania były niezbędne do podjęcia decyzji o ich lokalizacji na pojeździe.

W celu wybrania jak najlepszego rozmieszczenia sensorów, zaprojektowano i zamontowano, prototypowy stelaż umieszczony na dachu pojazdu oraz element mechaniczny do szybkiego montażu czujników w okolicy grilla.




Rysunek 38. Prototypowy stelaż na czujniki i element montażowy w okolicy grilla.

Przeprowadzono testy zbierania danych z czujnikami mocowanymi w różnych położeniach. Miejscem testu był parking oraz drogi wewnętrzne w Instytucie Łukasiewicz-PIAP. Skupiono się na pomiarach w miejscach, gdzie występowały różnego rodzaju przeszkody. Miejsca referencyjne testu to, rury przy drzewach – symulacja leżących konarów drzew (Rysunek 39 Miejsce testów-rury przy drzewach, ustawienie lidarów – na grillu, warstwy pionowe. Rysunek 39, Rysunek 41), nasyp z ziemi i kamieni (Rysunek 43) oraz przeszkoda z desek ustawionych w kształt prostokąta z krzyżem w środku (Rysunek 45). Na wymienionych rysunkach zaznaczono umiejscowienie lidarów za pomocą czerwonych okręgów. Poniżej wybrane zdjęcia miejsc, ustawień lidarów oraz zebranych chmur punktów koloru punktów pomiarowych odwzorowują intensywność sygnału pomiarowego (zielony – mała intensywność, jasnoniebieski – duża intensywność).



Rysunek 39 Miejsce testów-rury przy drzewach, ustawienie lidar – na grillu, warstwy pionowe.

Na rysunku powyżej przedstawiono miejsce testu, którego obraz chmury punktów jest przedstawiony na rysunku poniżej. Lidar jest zamontowany na grillu pojazdu, tak aby warstwy lidar były ustawione pionowo. Osiągnięto dokładne odwzorowanie faktury nawierzchni przed pojazdem, ale kosztem wąskiego pomiaru w bliskiej odległości od pojazdu (do pełnego pokrycia drogi przy parametrach lidar VLP-16, konieczne byłoby użycie 3 sztuk).




Rysunek 40 Zebrana chmura punktów z miejsca testów-rury przy drzewach, ustawienie lidar – na grillu, warstwy pionowe.



Rysunek 41 Miejsce testów-rury przy drzewach, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.

Na rysunku powyżej przedstawiono miejsce testu, którego obraz chmury punktów jest przedstawiony na rysunku poniżej. Lidar jest zamontowany na stelażu na dachu po lewej stronie pojazdu, tak aby warstwy lidar były ustawione pionowo. Osiągnięto dokładne odwzorowanie faktury nawierzchni przed pojazdem oraz pokrycie terenu z boku pojazdu i z tyłu, występuje zjawisko przesłaniania otoczenia przez obrys pojazdu.




Rysunek 42 Zebrana chmura punktów z miejsca testów-rury przy drzewach, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.



Rysunek 43 Miejsce testu-nasyp z ziemi i kamieni, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.

Na rysunku powyżej przedstawiono miejsce testu, którego obraz chmury punktów jest przedstawiony na rysunku poniżej. Lidar jest zamontowany tak aby warstwy lidar były ustawione pionowo. Ustawienie lidar jak w poprzednim teście, ale z inną sceną, można zauważyć, że ustawienie pionowe lidar daje możliwość zobrazowania wysokich drzew.




Rysunek 44 Zebrana chmura punktów z miejsca testów-nasyp z ziemi, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.




Rysunek 45 Miejsce testów - przeszkoda z krzyżem, ustawienie lidar – na dachu od strony kierowcy, warstwy pod kątem 45°.

Na rysunku powyżej przedstawiono miejsce testu, którego obraz chmury punktów jest przedstawiony na rysunkach poniżej (Rysunek 46, Rysunek 47, Rysunek 48, Rysunek 49, Rysunek 50). Na rysunku poniżej lidar jest ustawiony pod kątem 45°. Tak umiejscowiony lidar na stelażu, na dachu nie jest przesłaniany przez pojazd, ale nie jest obrazowane najbliższe otoczenia pojazdu z boku.




Rysunek 46 Zebrana chmura punktów z miejsca testów - przeszkoda z krzyżem, ustawienie lidar – na dachu od strony kierowcy, warstwy pod kątem 45°.




Rysunek 47 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.

Na rysunku powyżej przedstawiono obraz chmury punktów budowanej przez lidar, który jest zamontowany na stelażu na dachu po lewej stronie pojazdu, tak aby warstwy lidar były ustawione pionowo. Takie ustawienie daje dobre wyniki pokrycia otoczenia. Poniżej przedstawiono chmurę punktów z lidar umieszczonego pionowo na grillu pojazdu, dokładność odwzorowania faktury terenu jest lepsza, ale kosztem wielkości pokrycia terenu.




Rysunek 48 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na grillu, warstwy pionowe.



Rysunek 49 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na grillu, warstwy poziome.

Na rysunku powyżej przedstawiono obraz chmury punktów budowanej przez lidar, który jest zamontowany na grillu pojazdu, tak aby warstwy lidar były ustawione poziomo. Takie ustawienie daje niskie pokrycie w najbliższym otoczeniu pojazdu ze względu na minimalną odległość pomiaru. Poniżej przedstawiono chmurę punktów z lidar umieszczonego na dachu poziomo co daje lepsze pokrycie terenu punktami pomiarowymi, choć wciąż brak jest danych o bezpośrednim otoczeniu przed pojazdem.



Rysunek 50 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na dachu, warstwy poziome


Analizując otrzymane chmury punktów, można zauważyć, że lidar zamontowany w taki sposób by budował warstwy pionowe bardzo dobrze oddaje geometrie podłoża i przeszkód co jest istotne do wyznaczania drogi przejazdu w terenie przygodnym. Podstawową wadą takiego ułożenia jest wąskie pole widzenia. Rozszerzenie tego pola w zakresie, który nas interesuje jest możliwe poprzez odsunięcie lidar. Podczas testów szersze pole było widziane na lidarze zamontowanym na dachu.

W przypadku lidar zamontowanego tak, aby tworzył warstwy pod kątem 45 stopni, największą trudnością było zrozumienie widzianego obrazu. Rozpoznawanie przeszkód i obiektów jest bardzo utrudnione, ze względu na ciężkie do przewidzenia załamania wiązek lasera, ale największą wadą jest brak obrazowania najbliższego otoczenia z boku pojazdu przy ustawieniu pod kątem na bokach pojazdu.


Lidar zamontowany klasycznie, czyli budujący warstwy poziomo, sprawdza się najlepiej do obrazowania otoczenia dookoła. Lepsze efekty są otrzymywane dla lidar zamontowanego wysoko, niestety rozdzielczość 16 warstw, rzutuje na dość niską jakość obrazu bezpośrednio przed pojazdem. Położenie lidar w okolicy grilla poprawia jakość widzianych obiektów przed pojazdem, ale ze względu na ograniczenia dotyczące minimalnej odległości z jakiej lidar jest w stanie obrazować tracone są informacje o obiektach najbliższych (poniżej 1 metra od lidar).

Po analizie otrzymanych chmur punktów, postanowiono zainstalować dwa lidary obrócone tak, aby budować warstwy pionowe oraz dwa poziomie. Ze względu na wąski kąt rzutowania warstw, zaleca się stosowanie dwóch lidarów budujących warstwy pionowe po obu stronach dachu. Natomiast dwa lidary budujące warstwy poziomo pośrodku pojazdu, jeden w najwyższym punkcie, pochylany w kierunku jazdy (lepsze obrazowanie w bliższym planie) i drugi ustawiony prosto na masce pojazdu (zwiększenie rozdzielczości w najważniejszym przedziale widoczności z punktu tworzenia ścieżki przejazdu).

Według wniosków z powyższych badań zdecydowano o rozmieszczeniu lidarów zgodnie z poniższym schematem (Rysunek 51, Rysunek 52), umiejscowienie lidarów zostało zaznaczone czerwonymi okręgami.




Rysunek 51 Dwa czujniki zamontowane rozbieżnie w płaszczyźnie pionowej oraz jeden czujnik pośrodku dachu oraz na skraju maski pojazdu.



Rysunek 52. Zamodelowana platforma mobilna z sensorami

Poniżej wynik pracy w zakresie tworzenia chmur punktów przy pomocy skalibrowanego systemu ATENA.









Rysunek 53. Chmura punktów wytworzona przez pojazd PIAP ATENA na terenie instytutu Łukasiewicz-PIAP wykorzystana do badań w artykule [113].


5.3 Badania mapy 2,5D

Po opracowaniu położenia lidarów na pojeździe PIAP ATENA, przeprowadzono testy budowania mapy w oparciu o pakiet [19] zaimplementowany w środowisku ROS.

Tabela 13. Zestawienie wniosków po testach budowania mapy 2,5D.

Specyficzny układ sensorów (pionowo – poziomy) zapewnia siatkę dla chwilowego odczytu z sensorów bez konieczności agregacji danych w ruchu. Na obrazie widoczna jest tzw. martwa strefa niepokryta przez sensory zaznaczona czerwonym okręgiem. Kolor punktów pomiarowych jest związany z intensywnością sygnału odbitego (czerwony – duża intensywność, zielony – mała intensywność). Czerwoną kropką jest zaznaczony biały pojazd widoczny na zdjęciu w prawym górnym rogu.	 <i>Pionowe - poziome rozmieszczenie lidarów oraz problem martwej strefy</i>
Problem martwej strefy rozwiązano, przy pomocy lokalnej agregacji danych w podejściu roboto-centrycznym. W odróżnieniu od typowego w robotyce (np. SLAM) celu w postaci zbudowania globalnie spójnej mapy budowany jest jedynie model lokalnego otoczenia robota, przesuwany i uaktualniany wraz z ruchem robota. Mapa odwzorowuje wysokość terenu (wysokość od dołu zielony na górze czerwony) Czerwoną kropką jest zaznaczony biały pojazd widoczny na zdjęciu w prawym dolnym rogu.	 <i>Lokalne roboto-centriczne mapowanie wysokości</i>
Problem martwej strefy został ograniczony do rozruchu systemu. Przyjęto rozwiązanie, w którym człowiek przeprowadza rozruch systemu eliminując martwą strefę (czarne plamy przed pojazdem i po bokach)	 <i>Martwa strefa przy rozruchu systemu</i>

	 <i>Model otoczenia po przejechaniu pierwszych metrów</i>
Model 2.5D nie jest właściwy dla problemów z zadaniem, tunelami, drzewami z gałęziami nisko nad drogą. Spowodowane jest to brakiem możliwości reprezentowania takich przeszkód (każdemu elementowi siatki odpowiada jedna wysokość). Przyjęto rozwiązanie ograniczając wysokość mapowania do wysokości pojazdu.	 <i>Bez ograniczenia wysokości mapowania gałęzie drzew błędnie odwzorowane na mapie 2.5D jako wysokie przeszkody</i>
Przeprowadzono testy związane z parametryzacją mapowania, w szczególności: - rozdzielczości siatki (horyzontalna) - zasięgu lokalnego modelu otoczenia Obydwa te parametry wpływają na czas obliczeń - wprost proporcjonalnie do kwadratu zasięgu - wprost proporcjonalnie do kwadratu rozdzielczości siatki (gęstsza siatka – większa złożoność)	 <i>Gęsta siatka w połączeniu z ruchem prowadzi do licznych brakujących elementów w modelu otoczenia, znacznie komplikujących proces planowania</i>

Zasięg jest konieczny do efektywnego planowania trasy pojazdu.	
Gęstsza rozdzielczość pozwala na budowanie dokładniejszego modelu otoczenia. Jednocześnie sensory mają ograniczoną dokładność, system jest w ruchu, informacja zwrotna z systemu jest niedoskonała. Mapowanie z rozdzielczością większą niż niezbędna lub większą niż osiągalna dokładność systemu jest marnotrawstwem mocy obliczeniowej. Przy zbyt gęstej siatce dodatkowo pojawiają się problemy z elementami siatki o nieznanej wysokości komplikujące proces planowania. Czyszczenie modelu otoczenia z dynamicznych elementów również staje się bardziej skomplikowane przy gęstszej siatce (ze względu na zasadę działania – elementy usuwane są na podstawie ścieżki optycznej, jeżeli aktualnie widzimy przez obiekty zmapowane wcześniej, te musiały zmienić miejsce).	 <i>Siatka o kompromisowym rozmiarze pozwala na szybkie mapowanie w większym zakresie.]</i>

5.3.1 Dobór parametrów mapy 2,5D

Ostatecznie wielkości mapy poszukiwano w zakresie 20m – 50m (jako obszar mapowany od 20m x 20m do 50m x 50m). Przyjęto mapę o wielkości 45m x 45m.

Rozdzielczości poszukiwano w zakresie 0,1m – 0,5m. Przyjęto wielkość komórki mapy 0,5m x 0,5m.

Obydwa te parametry są w granicach innych niż typowo wykorzystywane np. w robotach krocących (zasięgi typowo znacznie mniejsze, rozdzielczości znacznie większe). Jest to związane ze skalą demonstratora systemu ATENA i jego osiąganą prędkością maksymalną.

5.4 Weryfikacja zdolności terenowych

Prace badawcze nad zdolnościami terenowymi wybranych bezzałogowych platform lądowych (BPL) rozpoczęto od weryfikacji ich praktycznych limitów mobilności w terenie, a także od obserwacji maksymalnych prędkości osiąganych w zróżnicowanych warunkach terenowych o różnych geometriach. Poniżej opisano procedury terenowe oraz przedstawiono parametry testowe, które są istotne dla dalszych analiz i budowania modelu przejezdności.


5.4.1 Tereny testowe

Testy prowadzone były w różnych lokalizacjach, umożliwiając ocenę zdolności terenowych BPL na szerokiej gamie powierzchni i w różnorodnych warunkach środowiskowych:

Testy laboratoryjne — prowadzone na terenie Instytutu Łukasiewicz-PIAP (Rysunek 54), gdzie przeważają powierzchnie wyłożone płytami betonowymi, z obecnością kontenerów, budynków i drzew. Powierzchnia obszaru testowego to prostokąt o obwodzie ok. 400 m (widoczny na rysunku poniżej), co umożliwia kontrolowane testy w ograniczonym środowisku.





Rysunek 54. Tereny Przemysłowego Instytutu Automatyki i Pomiarów PIAP (fotografia satelitarna, chmura punktów zagregowana przez system ATENA oraz zdjęcie z kamery pojazdu ATENA). Na zdjęciu oznaczono obszar, w którym prowadzono większość testów laboratoryjnych. |



Rysunek 55. Model 3D terenów Łukasiewicz-PIAP

Na podstawie chmury punktów zebranych przez pojazd PIAP ATENA, wygenerowano model 3D terenów PIAP co widoczne jest na rysunku powyżej.



Rysunek 56. Na górze zdjęcia miejsca testów robotów mobilnych Łukasiewicz-PIAP, poniżej zapis chmury punktów tego miejsca (po lewej z modelem robota PIAP PATROL)

Na terenach instytutu znajduje się również pole testowe dla robotów mobilnych na którym znajdują wzniesienie testowe. Zdjęcia i chmura punktów wygenerowana na tym terenie jest widoczna powyżej (Rysunek 56).

Testy terenowe — realizowane na poligonie Wojskowego Instytutu Technicznego Uzbrojenia, oferującym szeroki zakres naturalnych przeszkód terenowych, w tym drogi gruntowe, zróżnicowaną roślinność, mostki, depresje, rowy oraz fragmenty dróg leśnych i asfaltowych. Przeważająca powierzchnia testowa to prostokąt o obwodzie ok. 3,5 km widoczny poniżej (Rysunek 57), co pozwala na bardziej zaawansowane próby w skomplikowanych warunkach.



Rysunek 57. Poligon Zielonka (Wojskowy Instytut Techniczny Uzbrojenia) gdzie przeprowadzono większość testów terenowych z kamerą hiperspektralną oraz pojazdem PIAP ATENA i PIAP HUNTER. Na zdjęciu oznaczono obszar, w którym prowadzono większość testów terenowych.]

Zidentyfikowane przeszkody terenowe na powyższym poligonie przedstawiono na rysunkach poniżej (Rysunek 58, Rysunek 59, Rysunek 60). Przeszkody terenowe na terenie WITU zostały podzielone na doły i wyrwy, drogi i tereny piaszczyste, tereny pokryte roślinnością (wysokie trawy, tereny pokryte trawą oraz las i drogi leśne)



Rysunek 58. Tereny Poligonu Zielonka, przeszkody terenowe - część I – doły i wyrwy.



Rysunek 59. Tereny Poligonu Zielonka, przeszkody terenowe - część 2, tereny piaszczyste.



Rysunek 60. Tereny Poligonu Zielonka, przeszkody terenowe - część 3, tereny z roślinnością.

Poligony Nowa Dęba (FEX-23) i Lipa (FEX-24) — te poligony umożliwiły badania na szczególnie wymagających terenach z występującymi wzniesieniami i miękkim, kopnym piaskiem. Te testy zrealizowane na PIAP HUNTeR w latach 2023-2024 pozwoliły na doprecyzowanie parametrów przejezdności w ekstremalnych warunkach terenowych.

Na trasie przejazdu przygotowane były następujące przeszkody:

- Wąskie wzniesienie, świeżo uformowane z piasku (Rysunek 61),
- Slalom pomiędzy konarami (Rysunek 63),
- Doły (Rysunek 62),
- Koleiny, naprzemiennie po obu stronach umiejscowione na ścieżce,
- Dół, który z założenia miał być wypełniony wodą, lecz ze względu na suszę i piaszczyste podłoże był suchy (Rysunek 64),
- Nawierzchnie z kamieni, piasku i belek.



Rysunek 61. Wzniesienie przygotowane do testów pojazdów UGV podczas FEX-24



Rysunek 62. Nierówności na trasie przejazdu podczas FEX-24



Rysunek 63. Wystające korzenie na trasie przejazdu FEX-24



Rysunek 64 Dół z błotem na trasie przejazdu FEX-24



Rysunek 65. Zdjęcie satelitarne terenu testów FEX-24

Poniżej zdjęcia testów pojazdu PIAP HUNTER podczas FEX-23 (udostępnione do publikacji).




Rysunek 66. Na górze i na dole PIAP HUNTER podczas FEX-23[117]

Na rysunku powyżej (Rysunek 66) widać relacje wielkości pojazdu PIAP HUNTER do wielkości nierówności na terenie piaszczystym oraz wpływ prędkości przejazdu przez teren piaszczysty na ograniczenie widoczności przez kamery (kurz przesłaniający otoczenie).

5.4.2 Testy terenowe

Testy terenowe pojazdów PIAP ATENA, PIAP HUNTER oraz PIAP PATROL, prowadzone były na przedstawionych powyżej terenach testowych. Testy skupiały się przede wszystkim na ocenie stylu jazdy operatora w różnych warunkach terenowych oraz pogodowych. Podczas badań zwracano uwagę na poślizgi pojazdów i reakcje operatora w celu ich korekty. Sprawdzano również typowe przeszkody jak podjazdy pod górę, przejazdy przez rowy oraz wjazdy na stopnie. Ze względów logistycznych badania każdego z pojazdów były prowadzone osobno, co nie dało możliwości porównania bezpośredniego pojazdów między sobą. W trakcie badań zapisywano materiał zdjęciowy po lub w trakcie pokonywania przeszkody, dodatkowe dane otrzymano z pojazdu PIAP ATENA, ze względu na rozbudowany system zapisu danych otoczenia przedstawiony poniżej (Rysunek 67).



Rysunek 67. Testy terenowe pojazdu PIAP ATENA na terenie poligonu WITU.

Poniżej przedstawiam zdjęcia z testów (Rysunek 68, Rysunek 69, Rysunek 70), na których można zobaczyć niektóre tereny i przeszkody w których były testowane pojazdy PIAP. Badania pojazdu PIAP HUNTeR zostały również przedstawione w artykule [17], którego jestem współautorem.



Rysunek 68. Zapis z testów terenowych dla pojazdu PIAP ATENA





Rysunek 69. Zapis testów terenowych dla pojazdu PIAP HUNTeR



Rysunek 70. Zapis z testów terenowych pojazdu PIAP PATROL

5.4.2.1 Wyniki testów terenowych

Na podstawie przeprowadzonych testów terenowych na różnych poligonach (w tym teren Instytutu, WITU, poligony wojskowe Nowa Dęba i Lipa) zauważono znaczący wpływ poziomu akceptacji ryzyka przez operatorów na dynamikę jazdy i wybór tras. Operatorzy, mając większą wiedzę o stanie podłoża oraz widoczności przeszkód, dostosowywali swoje

decyzje o prędkości i agresywności manewrów do konkretnych warunków oraz wymagań misji.

W rutynowych przejazdach operatorzy stosowali bardziej zachowawcze strategie jazdy, koncentrując się na minimalizacji ryzyka uszkodzeń sprzętu. Efektem były niższe prędkości, unikanie tras o ograniczonej widoczności oraz preferowanie dróg o pewnej nawierzchni i łatwości przejazdu – nawet kosztem wydłużenia trasy. Operatorzy intuicyjnie regulowali prędkość płynnie ją zmieniając, aby uniknąć nagłych skoków momentu obrotowego, które mogłyby doprowadzić do poślizgu, zwłaszcza na grząskim lub niestabilnym podłożu. Ponadto, w zależności od rodzaju nawierzchni, dostosowywali prędkość przejazdu, by zoptymalizować stabilność i kontrolę nad pojazdem. Na twardych, stabilnych powierzchniach pozwalali sobie na wyższe prędkości, natomiast na śliskich lub grząskich terenach stosowali ostrożniejsze tempo, unikając gwałtownych manewrów.


W testach o podwyższonym poziomie akceptacji ryzyka (np. podczas zadań operacyjnych symulowanych na FEX-23 i FEX-24), operatorzy byli bardziej skłonni do zwiększenia prędkości oraz przejazdów przez bardziej wymagający teren. W takich warunkach momenty o wysokim przyspieszeniu często skutkowały nagłymi zmianami siły kontaktu opon z podłożem. Operatorzy, szczególnie podczas przejazdów przez błoto i piasek, musieli świadomie unikać nadmiernych zmian przyspieszeń, aby zminimalizować ryzyko utraty trakcji. Wysoka roślinność, sypki teren oraz nagłe zmiany rzeźby wymuszały bardziej dynamiczne reakcje, jednak najbardziej doświadczeni operatorzy potrafili dostosować swoje manewry, łagodząc zmiany przyspieszenia i ograniczając gwałtowne skoki momentu obrotowego.



Na podstawie odczuć oraz relacji operatorów pojazdów, jak również praktycznych testów, podsumowano wyniki w formie podziału terenów na typy nawierzchni oraz dobrano bezpieczne parametry jazdy. Istotnym wnioskiem było to, że operatorzy, świadomie lub podświadomie, dostosowują prędkość, co ma kluczowe znaczenie dla zachowania trakcji i efektywności jazdy. Dostosowanie prędkości do rodzaju nawierzchni okazało się kluczowe dla zwiększenia bezpieczeństwa i efektywności manewrów. Tabela z parametrami była prezentowana w podrozdziale 4.1.9.

5.5 Testy terenowe oceny przejezdności opartej o geometrie terenu - eksperyment


Testy terenowe zostały wykonane na poligonie WITU głównie w części „długa oś”. Testy są wykonywane na demonstratorze technologii autonomicznego podążania za celem PIAP ATENA. W teście biorą udział dwa samochody typu pick-up. Zdjęcia w tabeli oraz model 3d pojazdu przedstawia perspektywę pojazdu podążającego za białym samochodem. Poniżej opis testów terenowych i osiągniętych wyników pracy algorytmu. Dla przejrzystości tej części utworzono tabele w której czytelnie jest powiązany tekst wraz z wizualizacją.

Tabela 14. Zestawienie wniosków po testach terenowych metody oceny przejezdności opartej o parametry geometryczne.

Ze względu na prędkość ruchu, niedokładność sensorów, drgania i elastyczność stelaża, na którym je zamontowano, niedoskonałą synchronizację między sensorami a układem odometrii i IMU teren może być nadgorliwie interpretowany jako nieprzejezdny. Dotyczy to w szczególności bardziej odległych obszarów, próbkowanych rzadziej, o pomiarach bardziej podatnych na drgania (małe odchylenia kąta nabierają znaczenia z odległością). Problemowi częściowo zaradzono uwzględniając IMU dla danych z sensorów. W ramach projektu zaplanowano infrastrukturę do sprzętowej synchronizacji sensorów. Nie jest ona jeszcze wykorzystywana w ramach oprogramowania (niezależne znaczniki czasowe). Obszary pokryte roślinnością również mogą być interpretowane błędnie jako nieprzejezdne.	 <i>Teren z suchą roślinnością z prawej strony nadgorliwie interpretowany jako nieprzejezdny</i>
--	---

Pewną trudność stanowi takie dobranie parametrów analizy przejezdności, żeby dobrze oddawały możliwości jezdne platformy i były niewrażliwe na ww. problemy.	
Wartości nieokreślone znacznie komplikują planowanie trasy. Typowo problem rozwiązuje się przez globalny (m.in. planujący przez obszary nieznane) i lokalny (bardziej konserwatywny) planer.	 <i>Rów widoczny jako wartości nieznane mapy (brak ścieżki optycznej dla sensorów). Jednocześnie z przodu widoczne pojedyncze komórki o nieznanym wartościach (powód nieznany) utrudniające planowanie.</i> <i>Po lekkim przechyleniu pojazdu rów poprawnie zmapowany. Z przodu widoczne brakujące wartości (powód nieznany) utrudniające planowanie.</i>
Niepoprawne odczyty mają bardzo niską siłę sygnału, co umożliwia ich ew. odfiltrowanie. Podczas pracy w zaśnieżonych warunkach pojawiły się artefakty lidarów.	 <i>Niepoprawne odczyty w śniegu, poniżej rzeczywistych (czerwone – o bardzo niskiej sile sygnału)</i> <i>Niepoprawne odczyty powodują błędy mapowania. Zmapowana nieistniejąca depresja.</i>

Okazyjne artefakty w lokalnym modelu otoczenia mogą prowadzić do omijania nieistniejących przeszkód.




ATENA traversability_planning planuje ominięcie nieistniejącej przeszkody (artefakt modelu otoczenia). Jest to jednocześnie potwierdzenie poprawności działania planera i problemu w procesie modelowania otoczenia.

Artefakty, które wystąpiły podczas pracy w śniegu (opisane wcześniej, typowo jako niepoprawna depresja za pojazdem) utrudniają planowanie.


Okazyjnie pozycja startowa może być interpretowana jako niepoprawna (nieprzejezdna).

Częściowo zaradzono problemowi czyszcząc mapę przejezdności w obrysie pojazdu przed planowaniem.



Artefakty z przetwarzania danych z sensorów w śniegu (nieistniejąca depresja) mogą wpływać na planowanie (przykładowo pozycja startowa nieprzejezdna)


Przy analizie danych z wąskiej drogi otoczonej wysoką roślinnością zauważono potencjalny problem. Planer do poprawnej pracy wymaga zrelaksowania wymagań analizy przejezdności (przeciwnie niż w testach z symulowanym wtargnięciem na trasę pojazdu poprzedzającego).



Skrajnie wąska droga w wysokiej roślinności

Wnioski z przeprowadzonych testów terenowych systemu autonomii jazdy, opartego wyłącznie na geometrycznej ocenie przejezdności terenu, wskazują na istotne ograniczenia związane ze stosowaniem jednakowych parametrów jezdnych, niezależnie od rodzaju nawierzchni, po której planowana jest trasa przejazdu. Takie ujednolicone podejście może

prorowadzić do spadku zdolności manewrowych pojazdu i zwiększać ryzyko poślizgu, zakopania lub ugrzęźnięcia, zwłaszcza na podłożu miękkim i błotnistym. Włączenie metod sterowania uwzględniających właściwości materiałowe podłoża może znacząco zwiększyć mobilność pojazdu na różnorodnym terenie. Podejście to działałoby podobnie do intuicyjnych poprawek, jakie operator BPL wprowadza, bazując na doświadczeniu i wyczuciu w sterowaniu, co pozwoliłoby na lepszą adaptację systemu autonomicznego do trudnych warunków terenowych. W związku z tym zasadne jest dodanie do analizy danych o materiałach otoczenia. Poniżej (Rysunek 71) wizualizacja koncepcji pracy algorytmu po rozszerzeniu analizy o materiały otoczenia. Czerwonym okręgiem zaznaczono obszar, który fizycznie był przeszkodą przejezdną, jednak ze względu na geometrie zewnętrzną został zaklasyfikowany przez algorytm oceny przejezdności jako teren nieprzejezdny, celem włączenia analizy materiałowej jest obniżenie kosztu przejazdu przez tego typu przeszkodę do wartości umożliwiających planowanie trasy z uwzględnieniem możliwości wyznaczenia trasy przez taki teren.



Rysunek 71. Koncepcja rozszerzenia zdolności pracy algorytmu oceny przejezdności z analizą materiałów otoczenia.

5.6 Badania kamery hiperspektralnej na poligonie


Badania zastosowania kamery hiperspektralnej zostały zawarte w mojej i współautorów publikacjach [14] i [15]. Badania rozpoczęły się od przygotowania pojazdu PIAP ATENA do pracy z kamerą hiperspektralną. Integracja mechaniczna kamery hiperspektralnej z pojazdem PIAP ATENA została zaprezentowana na zdjęciu poniżej (Rysunek 72). Następnie nagrano dane z kamery hiperspektralnej na poligonie WITU w Zielonce.




Rysunek 72. Demonstrator PIAP ATENA podczas zbierania danych o otoczeniu z wykorzystaniem kamery hiperspektralnej Cubert Q285 na Poligonie w WITU. Poniżej przygotowania do testów, na zdjęciu widać miejsce montażu kamery hiperspektralnej.

W publikacji [14] koncentruję się na badaniach nad wykorzystaniem kamery hiperspektralnej do klasyfikacji różnych typów podłoża w kontekście autonomicznych pojazdów terenowych. Poniżej (Rysunek 73) wyniki eksperymentów przeprowadzonych w rzeczywistym środowisku, gdzie kamera hiperspektralna była wykorzystywana do rozpoznawania takich powierzchni jak asfalt, droga leśna, droga gruntowa czy trawa, po lewej jest zaznaczony teren a po prawej histogram przebiegu hiperspektralnego dla dominującego materiału podłoża.


a)




b)



c)



d)




Rysunek 73. Różne rodzaje dróg i odpowiadające im histogramy: a) droga gruntowa, b) droga leśna (pokryta błotem), c) droga szutrowa, d) droga pokryta asfaltem (asfalt pokryty miejscowo piachem) [14].

Na podstawie powyższych danych dokonuje porównywania histogramów danych wejściowych z danymi wzorcowymi dla danej klasy podłoża. Na wykresach po prawej stronie przedstawione są przebiegi hiperspektralne czyli funkcja jasności dla długości fal od 450nm do 950nm. Najważniejszym wnioskiem jest możliwość otrzymania obrazu segmentacji semantycznej otoczenia na podstawie danych z kamery hiperspektralnej umiejscowionej na

BPL – to umożliwia stosowanie metody zarówno do globalnej mapy przejezdności zmapowanego terenu jak i lokalnej mapy przejezdności podczas mapowania terenu. Wynik segmentacji semantycznej zbudowanej na podstawie zebranych danych przedstawiono wcześniej w rozdziale 4.4.1.

5.7 Metoda oceny przejezdności z analizą materiałów otoczenia - eksperyment

W publikacji [15] razem ze współautorami przeprowadziliśmy badania nad planowanie trasy z wykorzystaniem danych o materiałach nawierzchni otoczenia z wykorzystaniem zmodyfikowanej metody najbliższego sąsiada do analizy danych hiperspektralnych. Badania wykazały pozytywny wpływ informacji o materiale otoczenia na mapie 2.5D na jakość planowanej trasy robota.



Rysunek 74. Wyniki planowania trasy, na górze (a i b) planowanie trasy bez klasyfikacji materiału otoczenia, poniżej (c i d) planowanie trasy po klasyfikacji materiału otoczenia (kolorem szarym została zaznaczona nawierzchnia pokryta asfaltem) [15].

Eksperyment został przeprowadzony z wykorzystaniem chmury punktów terenów Łukasiewicz-PIAP. Wyniki eksperymentu zostały przedstawione na rysunku powyżej (Rysunek 74). Na górze (a i b) przedstawiono trasę zaplanowaną bez uwzględnienia klasyfikacji materiału otoczenia, natomiast na dole (c i d) pokazano trasę, w której uwzględniono identyfikację nawierzchni (szarym kolorem oznaczono asfalt). Zielonym kolorem zaznaczono tereny, które technicznie są przejezdne przez pojazd, a czerwonym tereny nieprzejezdne. Punkt **R** na rysunkach oznacza początek trasy robota, a punkt **G** to punkt docelowy. Porównanie dwóch podejść wskazuje istotne różnice w jakości planowania trasy. W przypadku na rysunku (b), zaplanowana ścieżka jest najkrótsza, jednak nie uwzględnia rzeczywistych warunków terenowych, co prowadzi do wyboru trasy, która przecina tereny nieprzeznaczone do jazdy. Może to powodować trudności w rzeczywistym przejeździe, narażając robota na ryzyko ugrzęźnięcia lub zwiększonego zużycia energii. W przypadku na rysunku (d), trasa jest dłuższa, ale jej przebieg jest znacznie bardziej logiczny i zgodny z intuicyjnym wyborem operatora. Omija ona problematyczne obszary i prowadzi głównie po stabilnych nawierzchniach, takich jak asfalt, co minimalizuje ryzyko niepowodzenia przejazdu.


W eksperymencie zastosowano prostą interpretację kosztu przejazdu, w której droga pokryta asfaltem miała najniższy koszt przejazdu. Ustalenie tej wartości było możliwe dzięki analizie danych hiperspektralnych, które pozwoliły na rozpoznanie rodzaju podłoża.

Na podstawie eksperymentu można wysnuć wniosek, że stosując dodatkową informację o materiale nawierzchni terenu wyraźnie widać różnice w jakości zaplanowanej ścieżki przejazdu pojazdu, który jest zbliżony do naturalnego wyboru trasy przez człowieka sterującego pojazdem.

5.8 Uwzględnienie cech materiałowych nawierzchni na planowanie trasy z uwzględnieniem dynamiki - eksperyment


W celu zademonstrowania uniwersalności algorytmu w planowaniu trasy z uwzględnieniem zdolności terenowych BPL, w naszej pracy [16] został przedstawiony eksperyment w zakresie porównania zaplanowania trasy globalnej dla pojazdu PIAP PATROL oraz PIAP ATENA. Eksperyment przeprowadzono dla dwóch różnych pojazdów autonomicznych o odmiennych parametrach dynamicznych i zdolnościach terenowych (opisane w podrozdziale 5.1.4).

Pojazdy te charakteryzują się różnymi ograniczeniami dynamicznymi, co wpływa na wybór optymalnej trasy dostosowanej do ich zdolności poruszania się w terenie. Rysunek 75 przedstawia teren, dla którego została zbudowana mapa na podstawie chmury punktów z lidar OUSTER OS-1, zebranych przy pomocy Łukasiewicz–PIAP PATROL w wersji DEZROB.



Rysunek 75. Po lewej zdjęcie terenu dla którego została zbudowana mapa na podstawie chmury punktów z lidar OUSTER OS-1, przy pomocy PIAP PATROL w wersji DEZROB.[16]

Rysunek 76 prezentuje wynik eksperymentu w postaci zaplanowanych tras dla obu pojazdów zgodnie z metodą opisaną w rozdziale 4.5. Eksperyment potwierdził, że różnice w parametrach pojazdów prowadzą do wyznaczenia różnych tras w tym samym środowisku. Na podstawie informacji semantycznej o nawierzchni oraz parametrów dynamicznych pojazdów uzyskano trasy dostosowane do specyfiki danego robota.



Rysunek 76. Wynik eksperymentu w postaci zaplanowanej trasy dla parametrów przejeźdności PIAP PATROL (po lewej) i PIAP ATENA (po prawej).[16]

Ścieżka zaplanowana dla pojazdu PIAP PATROL (na rysunku powyżej oznaczonej jako a) została zoptymalizowana pod kątem czasu przejazdu, wyznaczając trasę przez wąskie i nachylone tereny, które nie stanowią przeszkody dla lekkiego (100kg) gąsienicowego pojazdu.

Ścieżka zaplanowana dla pojazdu PIAP ATENA została zoptymalizowana pod kątem przejazdu przez bardziej stabilne i nośne nawierzchnie, umożliwiając zachowanie wyższej prędkości jazdy dla pojazdu o masie ponad 2000kg.

Podstawową różnicą względem eksperymentu opisanego w 5.7, jest dobór nie tylko trasy po lepszej nawierzchni, a dobór trasy pod kątem maksymalizacji prędkości przejazdu biorąc pod uwagę współczynnik tarcia nawierzchni i parametry terenowe pojazdów. Takie podejście stało się możliwe po uwzględnieniu danych charakterystyki materiału nawierzchni w tym przypadku współczynnika tarcia.

W kontekście pracy doktorskiej powyższe wyniki eksperymentu dowodzą wpływu oceny przejezdności trasy po uwzględnieniu zdolności terenowych różnych BPL i uwzględnieniu danych o właściwości nawierzchni na podstawie klasyfikacji danych otrzymanych z kamery hiperspektralnej, na dobór przejezdnej i zoptymalizowanej pod kątem czasu przejazdu ścieżki przez pojazd autonomiczny.

6. Wdrożenie wyników prac

Wdrożenie wyników badań opierało się na wsparciu projektów badawczych i rozwojowych wynikami z pracy doktorskiej. Warto wskazać, że prace w ramach rozprawy doktorskiej w pełni wpisywały się od samego początku w strategię rozwoju systemów autonomicznych w Łukasiewicz-PIAP, m.in. ten fakt umożliwił wykorzystanie i wdrożenie badań. Jednym z pozytywnych oddziaływań prac prowadzonych ramach doktoratu są również wprowadzone modyfikacje w zakresie planowanych zmian w zawieszeniu pojazdu PIAP HUNTeR w celu zwiększenia jego zdolności terenowych. Poniżej opisy najistotniejszych wdrożeń.

6.1 Wdrożenie – projekt ATENA

Wyniki prac związanych z analizą przejezdności zostały wdrożone w projekcie ATENA. Prace te zostały odebrane przez NCBR oraz przedstawicieli Ministerstwa Obrony Narodowej. Badania naukowe zawierające geometryczną analizę przejezdności z rozdziału 3.9 zostały odebrane przez ekspertów oceniających bez zastrzeżeń, następnie projekt ATENA został oceniony pozytywnie. Wyniki projektu były następnie prezentowane m.in. Dyrektorowi Departamentu Innowacji MON [118], [119].




Rysunek 77. Demonstracja autonomicznego systemu dla terenowych platform lądowych z funkcją podążania za celem ATENA, dla DIN MON.[118]

6.2 Wdrożenie wyników badań do pojazdu PIAP HUNTeR


Z powyższych prac do pojazdu PIAP HUNTeR został wdrożony moduł wizualizacji danych z lidarów wraz z analizą obiektów. Umożliwia to rozszerzenie świadomości sytuacyjnej operatora robota HUNTeR w terenie, szczególnie podczas niekorzystnych warunków oświetleniowych dla kamer jezdnych. Dodatkowo algorytm wskazuje operatorowi takie obiekty jak samochody czy też ludzie.

Do pojazdu PIAP HUNTeR dodany został system autonomii, bazujący na rozwiązaniach opracowanych w projektach ATENA i DEZROB. Na etapie, w którym realizowane były ćwiczenia FEX-24 system wykorzystywany był do wsparcia świadomości sytuacyjnej operatora poprzez dodanie wizualizacji odczytów z lidarów oraz kamer 3D. Dodatkowo uruchomiony został system do identyfikacji obiektów znajdujących się w zasięgu wybranych kamer. Poniżej rysunki (Rysunek 78, Rysunek 79, Rysunek 80, Rysunek 81, Rysunek 82) z danych jakie wyświetlają się na konsoli robota PIAP HUNTeR.




Rysunek 78. Wizualizacja odczytu z lidarów

W wizualizacji chmur punktów przed pojazdem dodano wykrywanie obiektów i zaznaczanie za pomocą prostokątnej ramki. Kolor punktów zależy od intensywności odbicia od powierzchni (dla powierzchni słabo odbijających kolor punktów jest czerwony dla dobrze odbijających kolor jest zielony). Czerwony kształt na obrazie z chmurami punktów jest odwzorowaniem obrysu robota PIAP HUNTER.



Rysunek 79. Przykład identyfikacji obiektów znajdujących się w obszarze widzenia wybranych kamer.

Dla danych wizyjnych dodano wykrywanie obiektów takich jak ludzie, zwierzęta, pojazdy itp. Co zostało zaprezentowane na rysunku powyżej. Tak informacja dla operatora robota jest niezwykle cenna podczas zdalnego sterowania pojazdem, gdyż pozwala mu zachować szczególną ostrożność. Na powyższych ujęciach z kamer i lidarów można zaobserwować różnice w dokładności rozpoznawania obiektów na danych z lidarów oraz na danych z kamery RGB (analiza obiektów na kamerach RGB osiąga większą dokładność).



Rysunek 80. Przykład identyfikacji obiektów znajdujących się w obszarze widzenia wybranych kamer oraz na wizualizacji 3D

Na rysunku powyżej jest zaprezentowana różnica w percepcji otoczenia i odległości dla obiektów znajdujących się tuż przy pojeździe pomiędzy danymi z lidar oraz z kamery RGB – odległość do człowieka na kamerze jest obierana jako bardziej bliska niż na modelu otoczenia z chmury punktów.

Jednym z testów przygotowanych przez organizatora ćwiczeń FEX-24 było sprawdzenie zdolności terenowych platform poprzez wjazd na usypane wzniesienie. Wdrożony do pojazdu system aktywnie wspierał operatora pojazdu podczas wykonywania tego skomplikowanego manewru. Na poniższych zrzutach ekranu z konsoli robota PIAP HUNTER (Rysunek 81, Rysunek 82) przedstawiono przeszkodę, zarejestrowaną przez kamery pojazdu oraz lidar. Warto zwrócić uwagę na dwa dolne ujęcia z kamer obrysowych umożliwiających precyzyjne sterowanie pojazdem na wąskich drogach.



Rysunek 81. Zbliżanie się do przeszkody – widok operatora robota.



Rysunek 82. Pokonywanie przeszkody.

Na rysunku (Rysunek 83) poniżej zaprezentowano pokonywanie przeszkody z widoku z zewnątrz pojazdu PIAP HUNTER. Rysunek 84 przedstawia wzniesienie które było pokonywane podczas tego testu.



Rysunek 83. Robot HUNTeR na wzniesieniu podczas ćwiczenia FEX-24.



Rysunek 84. Wzniesienie przed pokonywaniem trasy przebiegającej po nim.

Wizualizacja otoczenia z wykorzystaniem danych geometrycznych z chmur punktów, wpływa pozytywnie na bezpieczeństwo użytkowania robota w terenach nieustrukturyzowanych, w

szczegółności w warunkach słabego oświetlenia otoczenia lub w nocy. System wspiera operatora w sterowaniu pojazdu i jest uzupełnieniem kamer termowizyjnych, które ze względu na swój charakter mają ograniczoną jakość obrazu.

6.3 Integracja mapy przejezdności, zdolności terenowej i autonomii w projektach Łukasiewicz-PIAP

Mapa przejezdności, zdolność terenowa oraz algorytmy autonomii lokalnej i globalnej stanowią komplementarne elementy, które razem umożliwiają skuteczne działanie bezzałogowych pojazdów lądowych (UGV) w trudnych, nieustrukturyzowanych środowiskach. W projektach realizowanych przez Łukasiewicz-PIAP, takich jak ATENA i DEZROB, budowa dynamicznej mapy przejezdności była nieodzowna dla opracowania algorytmów, które na bieżąco analizują teren i dostosowują trasę pojazdu do zmiennych warunków. Mapa przejezdności dostarcza kluczowych danych dla systemu autonomii lokalnej, wspomagając pojazd w podejmowaniu decyzji o omijaniu przeszkód i wyborze optymalnej ścieżki, w zależności od możliwości technicznych pojazdu oraz właściwości terenu, takich jak nośność i nachylenie.

Projekty ATENA i DEZROB ilustrują praktyczne wykorzystanie tej technologii. W projekcie ATENA, system autonomii lokalnej opierał się na mapie przejezdności tworzonej w czasie rzeczywistym, co umożliwiało pojazdowi poruszanie się za liderem nawet w nieznanym terenie. Z kolei w projekcie DEZROB, planowanie globalne miało kluczowe znaczenie dla precyzyjnego przemieszczania się po zamkniętych przestrzeniach i pełnego pokrycia ich środkiem dezynfekcyjnym. W obu przypadkach mapa przejezdności, uwzględniająca zdolność terenową pojazdów, była nieodzowna do oceny przejezdności różnych obszarów i wyznaczania odpowiednich tras. Ponadto, zaawansowane algorytmy przetwarzania danych z sensorów, takich jak kamery hiperspektralne i lidary, umożliwiały dokładną klasyfikację terenu oraz dynamiczną adaptację pojazdu do zmieniających się warunków środowiskowych, co zwiększało niezawodność i bezpieczeństwo misji.

Integracja mapy przejezdności z systemami autonomii lokalnej i globalnej w praktycznych projektach nie tylko wspiera planowanie operacyjne, ale także wskazuje dalsze kierunki badań, takie jak poprawa dokładności map oraz zarządzanie ryzykiem w nieprzewidywalnych środowiskach.

7. Podsumowanie i perspektywa dalszych badań

Na podstawie obserwacji zachowań operatorów BPL zapisano wytyczne dotyczące metody sterowania pojazdem przez algorytm autonomiczny. Przy realizacji tej metody skupiono się na zagadnieniach związanych z wpływem modelu otoczenia na jakość sterowania pojazdem. W ramach dekompozycji zagadnienia wybrano najważniejsze parametry wejściowe dotyczące modelu otoczenia oraz parametry zależne od sterowania pojazdami. Parametry te umożliwiły zbudowanie zależności między modelem otoczenia a sterowaniem pojazdami. Z uzyskanych zależności opracowano metodę oceny przejezdności trasy w zależności od możliwości terenowych pojazdów.

Przedstawiono metodę sterowania opartą na tabelach parametrów oraz modelu dynamicznym, który wpływa na dobór ścieżki za pomocą znanych planerów trasy. Prace teoretyczne, w miarę możliwości, zostały sprawdzone w symulacjach, w tym pod kątem wpływu założeń teoretycznych na praktyczne wyznaczanie trasy przejazdu pojazdów w zależności od materiałów podłoża i ich zdolności terenowych. Tam, gdzie było to możliwe, badania zweryfikowano na fizycznych demonstratorach technologii w warunkach zbliżonych do rzeczywistych. W szczególności zbadano rzeczywiste zachowanie modelu geometrycznego na pojeździe PIAP ATENA.

Integracja danych z kamer hiperspektralnych z informacjami z innych sensorów, takich jak LiDAR, umożliwia budowę dynamicznej mapy przejezdności, niezbędnej dla systemów autonomii lokalnej i globalnej. Kamery hiperspektralne, rejestrując specyficzne sygnatury spektralne materiałów, przyczyniają się do poprawy dokładności systemów nawigacyjnych i pozwalają na bardziej zaawansowane planowanie misji w warunkach terenowych.

Część wyników prac teoretycznych została wdrożona w pojeździe PIAP ATENA oraz w pojeździe PIAP HUNTeR i przetestowana w 2024 roku podczas ćwiczeń eksperymentalnych FEX-24. Dalsze kroki badawcze mogą obejmować rozwój oprogramowania z projektu PIAP ATENA w celu dodania modułu analizy materiałów podłoża w czasie rzeczywistym oraz przeprowadzenie testów opracowanej metody w warunkach rzeczywistych. Wyniki prac w środowisku symulacyjnym są obiecujące i wskazują na wysoką wartość praktyczną rozszerzenia systemów autonomii jazdy w terenie nieustrukturyzowanym.

Otwartą kwestią w ramach dalszych badań pozostaje zastosowanie kamery hiperspektralnej do oceny materiałów otoczenia. Wraz z dynamicznie rozwijającymi się algorytmami opartymi na sztucznej inteligencji poziom ufności w wyniku pracy algorytmów segmentacji semantycznej będzie wzrastać, co może umożliwić skuteczne planowanie trasy na tańszych, szeroko dostępnych kamerach wizyjnych. Kolejnym krokiem rozwoju jest opracowanie kamer multispektralnych mierzących wyłącznie znaczące długości fal dla oceny podstawowych materiałów występujących w terenach nieustrukturyzowanych. Innym kierunkiem rozwoju może być jeszcze szersze wykorzystanie algorytmów sztucznej inteligencji do analizy sygnatury spektralnej otoczenia bezpośrednio na danych spektralnych co może znacząco poprawić rozdzielczość i dokładność semantycznej segmentacji badanego obszaru (prace w tym kierunku zostały wykonane w ramach jednej z prac inżynierskich jednego ze studentów którego byłem opiekunem merytorycznym i który odbywał pod moim nadzorem praktyki w Łukasiewicz-PIAP).

Dotychczasowe badania wskazują, że dalsze prace nad metodą wymagają znacznych nakładów pracy oraz środków finansowych. Kontynuacja prac będzie miała miejsce w ramach wniosków na projekty finansowane przez NCBR z dziedziny OiB, lub projektów badawczych w EDA, a docelowo jest możliwe wdrożenie systemu autonomii jazdy w terenie nieustrukturyzowanym jako elementu pojazdów militarnych załogowych i bezzałogowych, w tym takich, które mogą zostać zmodernizowane do pracy w trybie bezzałogowym.

7.1 Wnioski

W ramach niniejszej pracy doktorskiej opracowano metodę oceny przejezdności dla bezzałogowych platform lądowych (BPL), uwzględniając zarówno dane geometryczne, jak i semantyczne zawierające informacje o materiałach otoczenia. Wyniki przeprowadzonych badań potwierdziły postawioną tezę, że „uwzględnienie informacji semantycznej o elementach otoczenia w modelu przejezdności terenu — pozyskanych za pomocą kamery hiperspektralnej — oraz ich integracja z danymi geometrycznymi umożliwiają znaczącą poprawę jakości planowania trasy i zwiększenie zdolności operacyjnych autonomicznych i zdalnie sterowanych bezzałogowych platform lądowych (BPL) w środowiskach nieustrukturyzowanych”. Dodatkowo wykazano:

1. Złożoność oceny przejezdności w terenach nieustrukturyzowanych

Badania wykazały, że tradycyjne metody oceny przejezdności oparte wyłącznie na analizie geometrycznej są niewystarczające w złożonych terenach. W szczególności, systemy te mają tendencję do błędnego klasyfikowania wysokiej roślinności jako przeszkody nieprzejezdnej oraz ignorowania różnic w przyczepności na różnych rodzajach podłoża, takich jak błoto czy piasek. Włączenie analizy materiałowej do oceny przejezdności pozwala na znaczne zwiększenie precyzji planowania trasy i unikania ryzyka ugrzęźnięcia lub uszkodzenia pojazdu.

2. Zastosowanie kamer hiperspektralnych

Wprowadzenie kamer hiperspektralnych do systemu autonomii jazdy BPL umożliwia deterministyczną segmentację semantyczną otoczenia. Dzięki temu można precyzyjnie klasyfikować rodzaje podłoża i integrować te dane z mapami geometrycznymi. Chociaż zastosowanie kamer hiperspektralnych wiąże się z wyzwaniami, takimi jak wysoki koszt i złożoność przetwarzania danych, ich potencjał w zwiększaniu świadomości sytuacyjnej systemów autonomicznych został jednoznacznie potwierdzony.

3. Integracja danych geometrycznych i materiałowych

Opracowany w pracy model integracji danych geometrycznych i materiałowych w oparciu o mapę wysokościową 2,5D oraz dane z kamer hiperspektralnych pozwala na uzyskanie bardziej kompleksowego obrazu otoczenia. Połączenie tych dwóch źródeł informacji umożliwia dynamiczne dostosowywanie parametrów przejezdności w zależności od rodzaju podłoża i warunków terenowych.

4. Uniwersalność opracowanej metody

Przedstawiona metoda oceny przejezdności została zaprojektowana w sposób uniwersalny, co pozwala na jej adaptację do różnych klas pojazdów, takich jak PIAP HUNTeR, PIAP ATENA czy PIAP PATROL. Dzięki temu opracowane rozwiązanie może być skalowane zarówno do pojazdów lekkich, jak i ciężkich, a także dostosowywane do specyficznych wymagań różnych misji. Metoda ma zastosowanie do budowania map przejezdności do planowania trasy oraz map przejezdności do wsparcia operatora BPL podczas pracy w trybie teleoperacji.

7.2 Wyzwania i kierunki dalszych badań

Pomimo osiągniętych wyników, praca wskazała na kilka otwartych wyzwań, które mogą stanowić podstawę dalszych badań:

- Optymalizacja w czasie rzeczywistym - aktualne badania wskazują na wysoką skuteczność metody w analizach offline, jednak konieczne jest dalsze badanie możliwości implementacji w czasie rzeczywistym.
- Alternatywne sensory - Istnieje potencjał do zastąpienia kamery hiperspektralnej tańszymi rozwiązaniami, np. kamerami multispektralnymi, które mogłyby dostarczać uproszczone dane materiałowe z wystarczającą dokładnością.
- Integracja z systemami planowania trasy - rozwinięcie algorytmów planowania, poprzez pełne uwzględnienie dynamiki pojazdu i różnic w charakterystyce materiałowej.
- Rozwój modeli AI - wraz z postępem w algorytmach sztucznej inteligencji możliwe jest zwiększenie dokładności segmentacji semantycznej bez użycia kamery hiperspektralnej, co mogłoby umożliwić wykorzystanie standardowych kamer wizyjnych.

7.3 Znaczenie i potencjał rozwoju

Przedstawione w pracy nowości mają istotne znaczenie zarówno dla rozwoju naukowego, jak i praktycznego zastosowania w systemach autonomicznych. Integracja danych geometrycznych i materiałowych otwiera nowe możliwości w modelowaniu terenu, co jest kluczowe dla bezpiecznego i efektywnego poruszania się pojazdów w terenach nieprzewidywalnych. Zastosowanie kamer hiperspektralnych, choć wymagające precyzyjnej kalibracji i przetwarzania danych, wskazuje na potencjał tego rozwiązania w przyszłych systemach autonomii.

Opracowany w ramach pracy system planowania trasy i oceny przejezdności jest uniwersalny, co pozwala na jego adaptację do różnych klas BPL, zarówno w celach militarnych, jak i cywilnych. W kolejnych etapach badań wskazane jest rozwijanie algorytmów predykcji mobilności, optymalizacja kosztowa zastosowania sensorów hiperspektralnych oraz rozszerzenie testów na inne rodzaje pojazdów i środowiska terenowe.

7.4 Istotne nowości pracy

Praca doktorska wprowadza szereg nowatorskich rozwiązań, które stanowią istotny wkład w rozwój systemów autonomicznej jazdy bezzałogowych platform lądowych (BPL) przeznaczonych do pracy w terenie nieustrukturyzowanym. Poniżej opisano kluczowe elementy nowości tej pracy:

1. Integracja danych geometrycznych i materiałowych w ocenie przejezdności terenu

Praca wprowadza unikalną metodę łączenia danych geometrycznych z danymi materiałowymi, co umożliwia bardziej kompleksowe modelowanie otoczenia. Proponowana metoda wykorzystuje mapę wysokościową 2,5D, tworzoną na podstawie danych z lidarów, oraz dane materiałowe pochodzące z analizy hiperspektralnej. Dzięki tej integracji system autonomii jazdy może uwzględniać zarówno parametry geometryczne, takie jak nachylenie terenu, chropowatość czy różnice wysokości, jak i właściwości materiałowe, np. wilgotność gleby, obecność trawy lub piasku. Taka wielowymiarowa analiza pozwala na bardziej precyzyjne planowanie trasy i ocenę ryzyka przejazdu w trudnym terenie.

2. Wykorzystanie kamer hiperspektralnych do poprawy jakości danych dla mapy przejezdności

Istotnym wkładem jest zastosowanie kamer hiperspektralnych w systemach percepcji BPL. Praca proponuje nowatorskie wykorzystanie sygnatur spektralnych, które umożliwiają segmentację semantyczną i klasyfikację materiałów terenu. Na podstawie tych danych system autonomii może lepiej zrozumieć warunki otoczenia, np. identyfikując błoto jako teren o wysokim ryzyku ugrzęźnięcia lub piasek jako obszar o niskiej przyczepności. To rozwiązanie znacząco poprawia jakość modelowania przejezdności w porównaniu z klasycznymi podejściami, które opierają się wyłącznie na danych geometrycznych.

3. Rozbudowany system planowania trasy uwzględniający charakterystykę podłoża

Praca rozwija system planowania trasy, który nie tylko analizuje geometryczne właściwości terenu, ale także uwzględnia wpływ materiałów podłoża na mobilność pojazdu. Proponowana metoda rozszerza standardowe podejścia o dynamiczną ocenę parametrów przejezdności, takich jak maksymalna prędkość czy wyliczanie trasy w oparciu o dynamikę pojazdu w

zależności od rodzaju podłoża. To rozwiązanie pozwala na realistyczne odwzorowanie zachowań operatora BPL, który dostosowuje styl jazdy do aktualnych warunków terenowych.

7.5 Podsumowanie

Wyniki badań potwierdzają, że wprowadzenie informacji materiałowych do analizy przejezdności stanowi kluczowy krok w rozwoju autonomii jazdy w terenach nieustrukturyzowanych. Proponowana metoda charakteryzuje się wysoką uniwersalnością, dokładnością i potencjałem wdrożeniowym, szczególnie w sektorze militarnym i ratowniczym. Dalsze badania skupione na implementacji w czasie rzeczywistym i redukcji kosztów sprzętowych mogą uczynić to rozwiązanie jeszcze bardziej praktycznym i szeroko stosowanym.

8. Bibliografia

- [1] X. Zhou, L. Huang, Y. Xu, Y. Chen, i F. Bai, „Research on the Development of Unmanned Systems for Joint Operations”, w *Proceedings of 2023 11th China Conference on Command and Control*, Chinese Institute of Command and Control, Red., Singapore: Springer Nature Singapore, 2024, s. 581–592.
- [2] „Advancing in Adversity: Ukraine’s Battlefield Technologies and Lessons for the U.S. | Belfer Center for Science and International Affairs”. Dostęp: 7 lipiec 2024. [Online]. Dostępne na: <https://www.belfercenter.org/publication/advancing-adversity-ukraines-battlefield-technologies-and-lessons-us>
- [3] T. Czapla i J. Wrona, „Technology Development of Military Applications of Unmanned Ground Vehicles”, w *Vision Based Systemsfor UAV Applications*, A. Nawrat i Z. Kuś, Red., Heidelberg: Springer International Publishing, 2013, s. 293–309. doi: 10.1007/978-3-319-00369-6_19.
- [4] M. Azmat i S. Kummer, „Potential applications of unmanned ground and aerial vehicles to mitigate challenges of transport and logistics-related critical success factors in the humanitarian supply chain”, *Asian Journal of Sustainability and Social Responsibility*, t. 5, nr 1, s. 3, luty 2020, doi: 10.1186/s41180-020-0033-7.
- [5] „Institute for the Study of War”, Institute for the Study of War. Dostęp: 18 styczeń 2025. [Online]. Dostępne na: <http://dev-isw.bivings.com/>
- [6] „Polski sektor obronny szuka startupów i zespołów naukowych do współpracy - ruszył nabór do drugiej edycji programu IDA Bootcamp | Serwis Spolki PFR S.A.” Dostęp: 18 styczeń 2025. [Online]. Dostępne na: <https://pfr.pl/artukul/polski-sektor-obronny-szuka-startupow-i-zespolow-naukowych-do-wspolpracy-ruszyl-nabor-do>
- [7] Rheinmetall – Der integrierte Technologiekonzern, *Rheinmetall Mission Master family – Turning the Wolf Pack concept into a reality*, (19 listopad 2020). Dostęp: 7 lipiec 2024. [Online Video]. Dostępne na: <https://www.youtube.com/watch?v=hXNJhB41L-M>
- [8] „Drones in the Nagorno-Karabakh War: Analyzing the Data”, Military Strategy Magazine. Dostęp: 9 lipiec 2024. [Online]. Dostępne na: <https://www.militarystrategymagazine.com/article/drones-in-the-nagorno-karabakh-war-analyzing-the-data/>
- [9] E. Gosselin-Malo, „Crude ground robots emerge on the battlefields of Ukraine, experts say”, Defense News. Dostęp: 9 lipiec 2024. [Online]. Dostępne na: <https://www.defensenews.com/unmanned/2023/12/15/crude-ground-robots-emerge-on-the-battlefields-of-ukraine-experts-say/>
- [10] N. C. I. Agency, „NATO launches artificial intelligence strategic initiative”, www.ncia.nato.int. Dostęp: 15 listopad 2024. [Online]. Dostępne na:

<https://www.ncia.nato.int/about-us/newsroom/nato-launches-artificial-intelligence-strategic-initiative.aspx>

- [11] „Projekt ATENA”, Sieć Badawcza ŁUKASIEWICZ – Przemysłowy Instytut Automatyki i Pomiarów PIAP. Dostęp: 14 lipiec 2024. [Online]. Dostępne na: <https://piap.lukasiewicz.gov.pl/badanie/projekt-atena/>
- [12] „DEZROB”, Sieć Badawcza ŁUKASIEWICZ – Przemysłowy Instytut Automatyki i Pomiarów PIAP. Dostęp: 14 lipiec 2024. [Online]. Dostępne na: <https://piap.lukasiewicz.gov.pl/badanie/dezrob/>
- [13] „Otwarcie Centrum Robotów Mobilnych w WAT”, Wojsko-Polskie.pl. Dostęp: 22 styczeń 2025. [Online]. Dostępne na: <https://www.wojsko-polskie.pl/wat/articles/aktualnosci-w/otwarcie-centrum-robotow-mobilnych-w-wat/>
- [14] R. Więckowski, K. Jakubczyk, i B. Siemiątkowska, „Zastosowanie kamer hiperspektralnych w nawigacji robotów mobilnych”, *Prace Naukowe Politechniki Warszawskiej. Elektronika*, t. z. 197, t. 1, s. 201–210, 2022.
- [15] K. Jakubczyk, B. Siemiątkowska, R. Więckowski, i J. Rapcewicz, „Hyperspectral Imaging for Mobile Robot Navigation”, *Sensors*, t. 23, nr 1, Art. nr 1, sty. 2023, doi: 10.3390/s23010383.
- [16] B. Siemiątkowska, R. Więckowski, J. Rapcewicz, i J. Kowaliński, „Semantic-Aware Path Planning with Hexagonal Grids and Vehicle Dynamic Constraints”, *Energies*, t. 16, nr 13, Art. nr 13, sty. 2023, doi: 10.3390/en16135127.
- [17] J. Kowaliński, T. Krakówka, R. Więckowski, i M. Zarzycki, „Wysoko mobilna bezałogowa platforma do zadań obserwacyjnych przy ochronie perymetrycznej granicy państwa”, *Pomiary Automatyka Robotyka*, t. R. 26, nr 1, 2022, doi: 10.14313/PAR_243/55.
- [18] M. Wermelinger, P. Fankhauser, R. Diethelm, P. Krüsi, R. Siegwart, i M. Hutter, „Navigation planning for legged robots in challenging terrain”, w *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, paź. 2016, s. 1184–1189. doi: 10.1109/IROS.2016.7759199.
- [19] *leggedrobotics/traversability_estimation*. (5 sierpień 2024). C++. Robotic Systems Lab - Legged Robotics at ETH Zürich. Dostęp: 16 sierpień 2024. [Online]. Dostępne na: https://github.com/leggedrobotics/traversability_estimation
- [20] T. H. Y. Leung, D. Ignatyev, i A. Zolotas, „Hybrid Terrain Traversability Analysis in Off-road Environments”, w *2022 8th International Conference on Automation, Robotics and Applications (ICARA)*, luty 2022, s. 50–56. doi: 10.1109/ICARA55094.2022.9738557.
- [21] Y. Li i J. Ibanez-Guzman, „Lidar for Autonomous Driving: The Principles, Challenges, and Trends for Automotive Lidar and Perception Systems”, *IEEE Signal Processing Magazine*, t. 37, nr 4, s. 50–61, lip. 2020, doi: 10.1109/MSP.2020.2973615.

- [22] S. Royo i M. Ballesta-Garcia, „An Overview of Lidar Imaging Systems for Autonomous Vehicles”, *Applied Sciences*, t. 9, nr 19, Art. nr 19, sty. 2019, doi: 10.3390/app9194093.
- [23] Z. Dai, Z. Guan, Q. Chen, Y. Xu, i F. Sun, „Enhanced Object Detection in Autonomous Vehicles through LiDAR—Camera Sensor Fusion”, *World Electric Vehicle Journal*, t. 15, nr 7, Art. nr 7, lip. 2024, doi: 10.3390/wevj15070297.
- [24] M. Loetscher, N. Baumann, E. Ghignone, A. Ronco, i M. Magno, „Assessing the Robustness of LiDAR, Radar and Depth Cameras Against Ill-Reflecting Surfaces in Autonomous Vehicles: An Experimental Study”, 19 wrzesień 2023, *arXiv: arXiv:2309.10504*. doi: 10.48550/arXiv.2309.10504.
- [25] S. Bi, C. Yuan, C. Liu, J. Cheng, W. Wang, i Y. Cai, „A Survey of Low-Cost 3D Laser Scanning Technology”, *Applied Sciences*, t. 11, nr 9, Art. nr 9, sty. 2021, doi: 10.3390/app11093938.
- [26] L. Mochurad, Y. Hladun, i R. Tkachenko, „An Obstacle-Finding Approach for Autonomous Mobile Robots Using 2D LiDAR Data”, *Big Data and Cognitive Computing*, t. 7, nr 1, Art. nr 1, mar. 2023, doi: 10.3390/bdcc7010043.
- [27] H. A. Lassiter, T. Whitley, B. Wilkinson, i A. Abd-Elrahman, „Scan Pattern Characterization of Velodyne VLP-16 Lidar Sensor for UAS Laser Scanning”, *Sensors*, t. 20, nr 24, Art. nr 24, sty. 2020, doi: 10.3390/s20247351.
- [28] M. Nowakowski i J. Kurylo, „Usability of Perception Sensors to Determine the Obstacles of Unmanned Ground Vehicles Operating in Off-Road Environments”, *Applied Sciences*, t. 13, nr 8, Art. nr 8, sty. 2023, doi: 10.3390/app13084892.
- [29] N. Li i in., „A Progress Review on Solid-State LiDAR and Nanophotonics-Based LiDAR Sensors”, *Laser & Photonics Reviews*, t. 16, nr 11, s. 2100511, 2022, doi: 10.1002/lpor.202100511.
- [30] Y. Wang i M. C. Wu, „Micromirror based optical phased array for wide-angle beamsteering”, w *2017 IEEE 30th International Conference on Micro Electro Mechanical Systems (MEMS)*, sty. 2017, s. 897–900. doi: 10.1109/MEMSYS.2017.7863553.
- [31] J. Będkowski i M. Pełka, „Affordable Robotic Mobile Mapping System Based on Lidar with Additional Rotating Planar Reflector”, *Sensors*, t. 23, nr 3, s. 1551, sty. 2023, doi: 10.3390/s23031551.
- [32] „RangeWeatherNet for LiDAR-only weather and road condition classification | IEEE Conference Publication | IEEE Xplore”. Dostęp: 3 styczeń 2025. [Online]. Dostępne na: https://ieeexplore.ieee.org/document/9575320?utm_source=chatgpt.com
- [33] G. Lu, H. Yang, J. Li, Z. Kuang, i R. Yang, „A Lightweight Real-Time 3D LiDAR SLAM for Autonomous Vehicles in Large-Scale Urban Environment”, *IEEE Access*, t. 11, s. 12594–12606, 2023, doi: 10.1109/ACCESS.2023.3241800.

- [34] T. Neumann, „Analysis of Advanced Driver-Assistance Systems for Safe and Comfortable Driving of Motor Vehicles”, *Sensors*, t. 24, nr 19, Art. nr 19, sty. 2024, doi: 10.3390/s24196223.
- [35] „Fusion of 3D LIDAR and Camera Data for Object Detection in Autonomous Vehicle Applications | IEEE Journals & Magazine | IEEE Xplore”. Dostęp: 3 styczeń 2025. [Online]. Dostępne na: https://ieeexplore.ieee.org/document/8957313?utm_source=chatgpt.com
- [36] M. Z. Alam, Z. Kaleem, i S. Kelouwani, „How to deal with glare for improved perception of Autonomous Vehicles”, 17 kwiecień 2024, *arXiv*: arXiv:2404.10992. doi: 10.48550/arXiv.2404.10992.
- [37] C. Meola, *Infrared Thermography Recent Advances and Future Trends*. Bentham Science Publishers, 2012.
- [38] T. X. B. Nguyen, K. Rosser, i J. Chahl, „A Review of Modern Thermal Imaging Sensor Technology and Applications for Autonomous Aerial Navigation”, *Journal of Imaging*, t. 7, nr 10, Art. nr 10, paź. 2021, doi: 10.3390/jimaging7100217.
- [39] M. Razeghi, A. Dehzangi, i J. Li, „Multi-band SWIR-MWIR-LWIR Type-II superlattice based infrared photodetector”, *Results in Optics*, t. 2, s. 100054, sty. 2021, doi: 10.1016/j.rio.2021.100054.
- [40] M. P. Hansen i D. S. Malchow, „Overview of SWIR detectors, cameras, and applications”, w *Thermosense XXX*, SPIE, mar. 2008, s. 94–104. doi: 10.1117/12.777776.
- [41] J. A. Hackwell i in., „LWIR/MWIR imaging hyperspectral sensor for airborne and ground-based remote sensing”, w *Imaging Spectrometry II*, SPIE, lis. 1996, s. 102–107. doi: 10.1117/12.258057.
- [42] C. Kwan i in., „Target Tracking and Classification Using Compressive Measurements of MWIR and LWIR Coded Aperture Cameras”, *Journal of Signal and Information Processing*, t. 10, nr 3, Art. nr 3, sie. 2019, doi: 10.4236/jsip.2019.103006.
- [43] B. Lu, P. D. Dao, J. Liu, Y. He, i J. Shang, „Recent Advances of Hyperspectral Imaging Technology and Applications in Agriculture”, *Remote Sensing*, t. 12, nr 16, Art. nr 16, sty. 2020, doi: 10.3390/rs12162659.
- [44] C. Winkens, V. Kobelt, i D. Paulus, „Robust Features for Snapshot Hyperspectral Terrain-Classification”, w *Computer Analysis of Images and Patterns*, M. Felsberg, A. Heyden, i N. Krüger, Red., Cham: Springer International Publishing, 2017, s. 16–27. doi: 10.1007/978-3-319-64689-3_2.
- [45] H. Aasen, A. Burkart, A. Bolten, i G. Bareth, „Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance”, *ISPRS Journal of Photogrammetry and Remote Sensing*, t. 108, s. 245–259, paź. 2015, doi: 10.1016/j.isprsjprs.2015.08.002.

- [46] A. Shukla i R. Kot, „An Overview of Hyperspectral Remote Sensing and its applications in various Disciplines”, *IRA-International Journal of Applied Sciences (ISSN 2455-4499)*, t. 5, nr 2, s. 85–90, grudz. 2016, doi: 10.21013/jas.v5.n2.p4.
- [47] J. Yue i in., „Estimation of Winter Wheat Above-Ground Biomass Using Unmanned Aerial Vehicle-Based Snapshot Hyperspectral Sensor and Crop Height Improved Models”, *Remote Sensing*, t. 9, nr 7, Art. nr 7, lip. 2017, doi: 10.3390/rs9070708.
- [48] M. Liu i in., „Discriminant Analysis of the Damage Degree Caused by Pine Shoot Beetle to Yunnan Pine Using UAV-Based Hyperspectral Images”, *Forests*, t. 11, nr 12, Art. nr 12, grudz. 2020, doi: 10.3390/f11121258.
- [49] H. Ma, W. Huang, Y. Dong, L. Liu, i A. Guo, „Using UAV-Based Hyperspectral Imagery to Detect Winter Wheat Fusarium Head Blight”, *Remote Sensing*, t. 13, nr 15, Art. nr 15, sty. 2021, doi: 10.3390/rs13153024.
- [50] A. Marcinkowska-Ochtyra, A. Jarocińska, K. Bzdęga, i B. Tokarska-Guzik, „Classification of Expansive Grassland Species in Different Growth Stages Based on Hyperspectral and LiDAR Data”, *Remote Sensing*, t. 10, nr 12, Art. nr 12, grudz. 2018, doi: 10.3390/rs10122019.
- [51] D. Kopeć, A. Zakrzewska, A. Halladin-Dąbrowska, J. Wylazłowska, A. Kania, i J. Niedzielko, „Using Airborne Hyperspectral Imaging Spectroscopy to Accurately Monitor Invasive and Expansive Herb Plants: Limitations and Requirements of the Method”, *Sensors*, t. 19, nr 13, Art. nr 13, sty. 2019, doi: 10.3390/s19132871.
- [52] A. Sabat-Tomala, E. Raczko, i B. Zagajewski, „Comparison of Support Vector Machine and Random Forest Algorithms for Invasive and Expansive Species Classification Using Airborne Hyperspectral Data”, *Remote Sensing*, t. 12, nr 3, Art. nr 3, sty. 2020, doi: 10.3390/rs12030516.
- [53] R. Ilehag, J. Leitloff, M. Weinmann, i A. Schenk, „URBAN MATERIAL CLASSIFICATION USING SPECTRAL AND TEXTURAL FEATURES RETRIEVED FROM AUTOENCODERS”, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, t. V-1–2020, s. 25–32, sie. 2020, doi: 10.5194/isprs-annals-V-1-2020-25-2020.
- [54] „(PDF) Processing of drone-borne hyperspectral data for geological applications”, w *ResearchGate*, doi: 10.1109/WHISPERS.2016.8071689.
- [55] E. Torti i in., „Parallel Classification Pipelines for Skin Cancer Detection Exploiting Hyperspectral Imaging on Hybrid Systems”, *Electronics*, t. 9, nr 9, Art. nr 9, wrz. 2020, doi: 10.3390/electronics9091503.
- [56] H. Fabelo i in., „Dermatologic Hyperspectral Imaging System for Skin Cancer Diagnosis Assistance”, w *2019 XXXIV Conference on Design of Circuits and Integrated Systems (DCIS)*, lis. 2019, s. 1–6. doi: 10.1109/DCIS201949030.2019.8959869.

- [57] M. Bajić, „Modeling and Simulation of Very High Spatial Resolution UXOs and Landmines in a Hyperspectral Scene for UAV Survey”, *Remote Sensing*, t. 13, nr 5, Art. nr 5, sty. 2021, doi: 10.3390/rs13050837.
- [58] P. N. Hedde, R. Cinco, L. Malacrida, A. Kamaid, i E. Gratton, „Phasor-based hyperspectral snapshot microscopy allows fast imaging of live, three-dimensional tissues for biomedical applications”, *Commun Biol*, t. 4, nr 1, s. 1–11, cze. 2021, doi: 10.1038/s42003-021-02266-z.
- [59] H. Mao i in., „Large-Area MEMS Tunable Fabry–Perot Filters for Multi/Hyperspectral Infrared Imaging”, *IEEE Journal of Selected Topics in Quantum Electronics*, t. 23, nr 2, s. 45–52, mar. 2017, doi: 10.1109/JSTQE.2016.2643782.
- [60] J. E. Fowler, „Compressive pushbroom and whiskbroom sensing for hyperspectral remote-sensing imaging”, w *2014 IEEE International Conference on Image Processing (ICIP)*, paź. 2014, s. 684–688. doi: 10.1109/ICIP.2014.7025137.
- [61] S. Thrun, W. Burgard, i D. Fox, „PROBABILISTIC ROBOTICS”.
- [62] P. Lamon i in., „Mapping with an Autonomous Car”, s. 11 p., 2006, doi: 10.3929/ETHZ-A-010079476.
- [63] J. Będkowski, „Simultaneous Localization and Mapping”, w *Large-Scale Simultaneous Localization and Mapping*, J. Będkowski, Red., Singapore: Springer Nature, 2022, s. 41–94. doi: 10.1007/978-981-19-1972-5_4.
- [64] J. Będkowski, „Building Large-Scale SLAM”, w *Large-Scale Simultaneous Localization and Mapping*, J. Będkowski, Red., Singapore: Springer Nature, 2022, s. 279–290. doi: 10.1007/978-981-19-1972-5_11.
- [65] J. Będkowski, „Open source, open hardware hand-held mobile mapping system for large scale surveys”, *SoftwareX*, t. 25, s. 101618, luty 2024, doi: 10.1016/j.softx.2023.101618.
- [66] M. Kulicki, C. Cabo, T. Trzeński, J. Będkowski, i K. Stereńczak, „Artificial Intelligence and Terrestrial Point Clouds for Forest Monitoring”, *Curr. For. Rep.*, t. 11, nr 1, s. 5, grudz. 2024, doi: 10.1007/s40725-024-00234-4.
- [67] R. Magnuson i in., „Mobile Devices in Forest Mensuration: A Review of Technologies and Methods in Single Tree Measurements”, *Remote Sensing*, t. 16, nr 19, Art. nr 19, sty. 2024, doi: 10.3390/rs16193570.
- [68] „An experimental study on feature-based SLAM for multi-legged robots with RGB-D sensors | Request PDF”, *ResearchGate*, cze. 2017, doi: 10.1108/IR-11-2016-0340.
- [69] A. Kudriashov, T. Buratowski, M. Giergiel, i P. Małka, „Introduction to Mobile Robots Navigation, Localization and Mapping”, w *SLAM Techniques Application for Mobile Robot in Rough Terrain*, A. Kudriashov, T. Buratowski, M. Giergiel, i P. Małka,

- Red., Cham: Springer International Publishing, 2020, s. 7–38. doi: 10.1007/978-3-030-48981-6_2.
- [70] A. Kudriashov, T. Buratowski, M. Giergiel, i P. Małka, „SLAM as Probabilistic Robotics Framework Approach”, w *SLAM Techniques Application for Mobile Robot in Rough Terrain*, A. Kudriashov, T. Buratowski, M. Giergiel, i P. Małka, Red., Cham: Springer International Publishing, 2020, s. 39–64. doi: 10.1007/978-3-030-48981-6_3.
- [71] C. Stachniss, *Robotic Mapping and Exploration*, t. 55. w Springer Tracts in Advanced Robotics, vol. 55. Berlin, Heidelberg: Springer, 2009. doi: 10.1007/978-3-642-01097-2.
- [72] D. Belter i P. Skrzypczyński, „Rough terrain mapping and classification for foothold selection in a walking robot”, *Journal of Field Robotics*, t. 28, nr 4, s. 497–528, 2011, doi: 10.1002/rob.20397.
- [73] D. Belter, P. Łabęcki, i P. Skrzypczyński, „Adaptive Motion Planning for Autonomous Rough Terrain Traversal with a Walking Robot”, *Journal of Field Robotics*, t. 33, nr 3, s. 337–370, 2016, doi: 10.1002/rob.21610.
- [74] A. Chilian i H. Hirschmuller, „Stereo Camera Based Navigation of Mobile Robots on Rough Terrain”, zaprezentowano na 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS 2009, lis. 2009, s. 4571–4576. doi: 10.1109/IROS.2009.5354535.
- [75] „Research”, Robotic Systems Lab. Dostęp: 3 styczeń 2025. [Online]. Dostępne na: <https://rsl.ethz.ch/research.html>
- [76] T. Homberger, L. Wellhausen, P. Fankhauser, i M. Hutter, „Support Surface Estimation for Legged Robots”, w *2019 International Conference on Robotics and Automation (ICRA)*, Montreal, QC, Canada: IEEE, maj 2019, s. 8470–8476. doi: 10.1109/ICRA.2019.8793646.
- [77] M. Tranzatto i in., „Team CERBERUS Wins the DARPA Subterranean Challenge: Technical Overview and Lessons Learned”, *FR*, t. 4, nr 1, s. 249–312, sty. 2024, doi: 10.55417/fr.2024009.
- [78] F. Islam, M. M. Nabi, i J. E. Ball, „Off-Road Detection Analysis for Autonomous Ground Vehicles: A Review”, *Sensors*, t. 22, nr 21, Art. nr 21, sty. 2022, doi: 10.3390/s22218463.
- [79] „NG-NRMM-CDT”, Michigan Technological University. Dostęp: 21 lipiec 2024. [Online]. Dostępne na: <https://www.mtu.edu/cdt/>
- [80] C. Hua i in., „The Prediction Method and Application of Off-Road Mobility for Ground Vehicles: A Review”, *World Electric Vehicle Journal*, t. 16, nr 1, Art. nr 1, sty. 2025, doi: 10.3390/wevj16010047.
- [81] „Next-Generation NATO Reference Mobility Model (NG-NRMM)”. Dostęp: 16 listopad 2024. [Online]. Dostępne na: <https://apps.dtic.mil/sti/citations/AD1011267>

- [82] M. He i in., „State of the art and future trends in obstacle-surmounting unmanned ground vehicle configuration and dynamics”, *Robotica*, t. 41, nr 9, s. 2625–2647, wrz. 2023, doi: 10.1017/S0263574723000577.
- [83] K. Iagnemma i in., „Design and Development of an Agile, Man Portable Unmanned Ground Vehicle”.
- [84] K. Małek, J. Dybała, A. Kordecki, P. Hondra, i K. Kijania, „OffRoadSynth Open Dataset for Semantic Segmentation using Synthetic-Data-Based Weight Initialization for Autonomous UGV in Off-Road Environments”, *J Intell Robot Syst*, t. 110, nr 2, s. 76, maj 2024, doi: 10.1007/s10846-024-02114-2.
- [85] „Vector-Field-Orientation Feedback Control Method for a Differentially Driven Vehicle | IEEE Journals & Magazine | IEEE Xplore”. Dostęp: 3 styczeń 2025. [Online]. Dostępne na: <https://ieeexplore.ieee.org/abstract/document/4908916>
- [86] M. M. Michałek, „A highly scalable path-following controller for N-trailers with off-axle hitching”, *Control Engineering Practice*, t. 29, s. 61–73, sie. 2014, doi: 10.1016/j.conengprac.2014.04.001.
- [87] M. Michałek, „Non-minimum-phase property of N-trailer kinematics resulting from off-axle interconnections”, *International Journal of Control*, t. 86, nr 4, s. 740–758, kwi. 2013, doi: 10.1080/00207179.2012.759662.
- [88] K. Mathiassen i in., „Demonstrating interoperability between unmanned ground systems and command and control systems”, *International Journal of Intelligent Defence Support Systems*, t. 6, nr 2, s. 100–129, sty. 2021, doi: 10.1504/IJIDSS.2021.115236.
- [89] A. Sprońska, J. Główna, M. Maciaś, i T. Rokosz, „TALOS – Mobile Surveillance System for Land Borders and Large Areas”, w *Recent Advances in Automation, Robotics and Measuring Techniques*, R. Szewczyk, C. Zieliński, i M. Kaliczyńska, Red., Cham: Springer International Publishing, 2014, s. 475–486. doi: 10.1007/978-3-319-05353-0_45.
- [90] J. Wrona, „Concept of IED/EOD Operations (CONOPs) for engineer mission support robot team”, *Journal of KONES*, sty. 2015, Dostęp: 3 styczeń 2025. [Online]. Dostępne na: https://www.academia.edu/116686460/Concept_of_IED_EOD_Operations_CONOPs_for_engineer_mission_support_robot_team
- [91] J. Wrona, „Technology gaps in Human-Machine Interfaces for autonomous construction robots”, *Automation in Construction*, paź. 2018, Dostęp: 3 styczeń 2025. [Online]. Dostępne na: https://www.academia.edu/116686463/Technology_gaps_in_Human_Machine_Interfaces_for_autonomous_construction_robots
- [92] P. Szyrkarczyk, „Adaptive behavior of autonomous mobile systems with new action selection problem solution”.

- [93] B. Siemiątkowska, J. Szklarski, i M. Gnatowski, „Mobile robot navigation with the use of semantic map constructed from 3D laser range scans”, *Control and Cybernetics*, t. Vol. 40, nr no 2, s. 437–453, 2011.
- [94] H. Roncancio, M. Becker, A. Broggi, i S. Cattani, „Traversability analysis using terrain mapping and online-trained Terrain type classifier”, w *2014 IEEE Intelligent Vehicles Symposium Proceedings*, cze. 2014, s. 1239–1244. doi: 10.1109/IVS.2014.6856427.
- [95] Z. Zhu, N. Li, R. Sun, D. Xu, i H. Zhao, „Off-road Autonomous Vehicles Traversability Analysis and Trajectory Planning Based on Deep Inverse Reinforcement Learning”, w *2020 IEEE Intelligent Vehicles Symposium (IV)*, paź. 2020, s. 971–977. doi: 10.1109/IV47402.2020.9304721.
- [96] X. Meng i in., „TerrainNet: Visual Modeling of Complex Terrain for High-speed, Off-road Navigation”, w *Robotics: Science and Systems XIX*, Robotics: Science and Systems Foundation, lip. 2023. doi: 10.15607/RSS.2023.XIX.103.
- [97] G. Vecchio, S. Palazzo, D. C. Guastella, D. Giordano, G. Muscato, i C. Spampinato, „Terrain traversability prediction through self-supervised learning and unsupervised domain adaptation on synthetic data”, *Auton Robot*, t. 48, nr 2, s. 4, mar. 2024, doi: 10.1007/s10514-024-10158-4.
- [98] „Projekt HUNTeR”, Sieć Badawcza ŁUKASIEWICZ – Przemysłowy Instytut Automatyki i Pomiarów PIAP. Dostęp: 14 lipiec 2024. [Online]. Dostępne na: <https://piap.lukasiewicz.gov.pl/badanie/projekt-hunter/>
- [99] Q. Wang, C. Lyu, i Y. Li, „A Method for All-Weather Unstructured Road Drivable Area Detection Based on Improved Lite-MobileNetv2”, *Applied Sciences*, t. 14, nr 17, Art. nr 17, sty. 2024, doi: 10.3390/app14178019.
- [100] M. Wysokowicz, „Co jest czym?”, *Las Polski*. Dostęp: 6 styczeń 2025. [Online]. Dostępne na: <https://laspolski.pl/1542-co-jest-czym/>
- [101] W. C. LLC, „Wolf Caves, LLC”, Wolf Caves, LLC. Dostęp: 6 styczeń 2025. [Online]. Dostępne na: <https://wolfcaves.com/maps>
- [102] „Start projektu ATENA”, Sieć Badawcza ŁUKASIEWICZ – Przemysłowy Instytut Automatyki i Pomiarów PIAP. Dostęp: 14 lipiec 2024. [Online]. Dostępne na: <https://piap.lukasiewicz.gov.pl/2018/09/05/start-projektu-aten/>
- [103] „Łukasiewicz o obronności na konferencji Defence24”, Sieć Badawcza Łukasiewicz. Dostęp: 14 lipiec 2024. [Online]. Dostępne na: <https://lukasiewicz.gov.pl/lukasiewicz-o-obronnosci-na-konferencji-defence24/>
- [104] „Jedynka - polskieradio.pl”, Jedynka - Polskie Radio. Dostęp: 14 lipiec 2024. [Online]. Dostępne na: <https://jedynka.polskieradio.pl/artukul/3135848,DEZROB-Jak-działa-autonomiczne-urządzenie-do-dezynfekcji>

- [105] „Eurosatory 2024: Debiut zagraniczny polskiego robota PIAP HUNTeR z wieżą ZMU-03”, MILMAG. Dostęp: 16 listopad 2024. [Online]. Dostępne na: <https://milmag.pl/eurosatory-2024-debiut-zagraniczny-polskiego-robota-piap-hunter-z-wieza-zmu-03/>
- [106] „Polski robot bojowy i robot ewakuacji medycznej na ćwiczeniu FEX-2024”, MILMAG. Dostęp: 16 listopad 2024. [Online]. Dostępne na: <https://milmag.pl/polski-robot-bojowy-i-robot-ewakuacji-medycznej-na-cwiczeniu-fex-2024/>
- [107] Redakcja, „PIAP MOBI TARGET – rewolucja w szkoleniu strzelców - Wywiad”, MILMAG. Dostęp: 2 luty 2025. [Online]. Dostępne na: <https://milmag.pl/piap-mobi-target-rewolucja-w-szkoleniu-strzelcow-wywiad/>
- [108] „CDIS SZ NA ĆWICZENIU EKSPERYMENTALNYM FEX-24 | Aktualności 2024”. Dostęp: 16 listopad 2024. [Online]. Dostępne na: <https://cdissz.wp.mil.pl/aktualnosci-2024/cdis-sz-na-cwiczeniu-eksperymentalnym-fex-24/>
- [109] 18 Dywizja Zmechanizowana, *ANAKONDA FEX 23*, (25 październik 2023). Dostęp: 21 lipiec 2024. [Online Video]. Dostępne na: <https://www.youtube.com/watch?v=mTVCbi6GoxY>
- [110] „PIAP HUNTER”. Dostęp: 21 lipiec 2024. [Online]. Dostępne na: <https://portalobronny.se.pl/galeria/piap-hunter/gg-1AVt-rBgp-2ve1/gp-eP52-LbKe-3ok4>
- [111] „«Wojny robotów» na ćwiczeniach FEX-24”. Dostęp: 21 lipiec 2024. [Online]. Dostępne na: <https://defence24.pl/technologie/wojny-robotow-na-cwiczeniach-fex-24>
- [112] „Polish combat robot and medical evacuation robot participating in the FEX-2024 exercise”, MILMAG. Dostęp: 16 listopad 2024. [Online]. Dostępne na: <https://milmag.pl/en/polish-combat-robot-and-medical-evacuation-robot-participating-in-the-fex-2024-exercise/>
- [113] P. Duszak, B. Siemiątkowska, i R. Więckowski, „Hexagonal Grid-Based Framework for Mobile Robot Navigation”, *Remote Sensing*, t. 13, nr 21, Art. nr 21, sty. 2021, doi: 10.3390/rs13214216.
- [114] G. A. Kumar, J. H. Lee, J. Hwang, J. Park, S. H. Youn, i S. Kwon, „LiDAR and Camera Fusion Approach for Object Distance Estimation in Self-Driving Vehicles”, *Symmetry*, t. 12, nr 2, Art. nr 2, luty 2020, doi: 10.3390/sym12020324.
- [115] D. A. Forsyth i J. Ponce, *Computer Vision: A Modern Approach*. Prentice Hall Professional Technical Reference, 2002.
- [116] „image_geometry: image_geometry::PinholeCameraModel Class Reference”. Dostęp: 6 styczeń 2025. [Online]. Dostępne na: https://docs.ros.org/en/diamondback/api/image_geometry/html/c++/classimage__geometry_1_1PinholeCameraModel.html

- [117] D. Ratka, „Konsultacje na bezzałogowy pojazd rozpoznawczy”. Dostęp: 16 listopad 2024. [Online]. Dostępne na: <https://defence24.pl/przemysl/konsultacje-na-bezzaalogowy-pojazd-rozpoznawczy>
- [118] Defence24, „Dyrektor Departamentu Innowacji MON z wizytą w Łukasiewicz - PIAP”. Dostęp: 11 styczeń 2025. [Online]. Dostępne na: <https://defence24.pl/przemysl/dyrektor-departamentu-innowacji-mon-z-wizyta-w-lukasiewicz-piap>
- [119] J. Link-Lenczowski, „Dyrektor Departamentu Innowacji MON w Łukasiewicz PIAP”, MILMAG. Dostęp: 11 styczeń 2025. [Online]. Dostępne na: <https://milmag.pl/dyrektor-departamentu-innowacji-mon-w-lukasiewicz-piap/>

Spis tabel

Tabela 1. Parametry oceny przejezdności dla pojazdów PIAP HUNTeR, PIAP PATROL w wersji DEZROB, PIAP ATENA, dla materiałów: trawa, droga utwardzona, droga gruntowa, błoto, piach, woda, nieznany,	75
Tabela 2. Komponenty oceny przejezdności.....	84
Tabela 3. Parametry przejezdności przyjęte do badań.	85
Tabela 4. Dane tabelaryczne parametrów przejezdności dla PIAP ATENA	101
Tabela 5. Dane tabelaryczne parametrów przejezdności i dynamiki dla PIAP ATENA	111
Tabela 6. Parametry Velodyne VLP16.....	119
Tabela 7. Parametry kamery Basler acA1920-48gc.....	120
Tabela 8. Parametry techniczne kamery Cubert Q285.....	121
Tabela 9. Parametry jezdne PIAP ATENA	125
Tabela 10. Parametry jezdne PIAP HUNTeR.....	126
Tabela 11. Parametry jezdne PIAP PATROL	127
Tabela 12. Syntetyczne porównanie zdolności terenowych rozpatrywanych pojazdów Łukasiewicz-PIAP.....	128
Tabela 13. Zestawienie wniosków po testach budowania mapy 2,5D.....	140
Tabela 14. Zestawienie wniosków po testach terenowych metody oceny przejezdności opartej o parametry geometryczne.	159

Spis ilustracji

Rysunek 1. Różne rodzaje zastosowań BPL na polu walki (klatka z filmu) [7].	11
Rysunek 2. Na zdjęciu powyżej zdjęcie terenu, poniżej obraz chmury punktów z lidar Velodyne VLP-16. (lidar zamontowany przed maską pojazdu PIAP ATENA).	27
Rysunek 3. LiDAR Velodyne VLP-16 podczas testów różnego rozmieszczenia sensora na pojeździe PIAP ATENA.	29
Rysunek 4. Lidar typu Solid-State firmy LSlidar	30
Rysunek 5. Porównanie obrazów z kamer SWIR, MWIR, LWIR [42].	33
Rysunek 6. Obrazy z kamery hiperspektralnej Cubert Q285 - kolorowe zdjęcie to fuzja danych ze wszystkich długości fal w celu uzyskania obrazu pseudo RGB, poniżej zdjęcia w długości fal od 450 nm do 626 nm	34
Rysunek 7. Bewameter [80]	44
Rysunek 8. Parametry i mapa przejezdności według Chiliana [74].	58
Rysunek 9. Wizualizacja kątów natarcia i zejścia oraz prześwitu pojazdu kołowego.[100]	60
Rysunek 10. Kamienista górską ścieżką, teren, który oddaje istotę parametru nierówności. [101]	61
Rysunek 11. Wynik projektu ATENA prezentowany na wydarzeniu Defence24Day [103].	63
Rysunek 12. Główny wynik projektu DEZROB: Prototyp Robota PIAP PATROL w wersji DEZROB z systemem oprysku i modułem autonomii. [materiały własne doktoranta]	65
Rysunek 13. Wynik projektu „Opracowanie wysoko mobilnej bezzałogowej platformy hybrydowej do zadań szybkiego reagowania” – BPL HUNTeR wraz z dronem na uwięzi. [materiały własne doktoranta]	66

Rysunek 14. Zdjęcie konsoli sterowania pojazdów PIAP (użytej do badań dla PIAP HUNTeR oraz dla PIAP PATROL)[107].	68
Rysunek 15. PIAP HUNTeR podczas FEX-23[110]	70
Rysunek 16. PIAP HUNTeR z wprowadzonymi modyfikacjami wspomagającymi operatora jazdy na ćwiczeniach FEX-24.[112]	71
Rysunek 17. Ogólny schemat systemu proponowanego w pracy doktorskiej.	78
Rysunek 18. Mapa 2,5D otoczenia budowana przez pojazd ATENA	81
Rysunek 19. Na górze, wejście dla analizy przejezdności - mapa 2.5D (kolorem odwzorowano wysokość), na dole ujęcie z lewej strony na teren odwzorowywany przez mapę (zdjęcie wykonane przy innej pogodzie)	86
Rysunek 20. Analiza przejezdności komponent nachylenie (slope, odwzorowane kolorem)	87
Rysunek 21. Analiza przejezdności - komponent lokalna nierówność (roughness, odwzorowane kolorem)	87
Rysunek 22. Analiza przejezdności - komponent lokalna różnica wysokości (step, odwzorowane kolorem)	88
Rysunek 23. Analiza przejezdności - sumaryczna przejezdność (ważona suma, wyzerowana, jeżeli którykolwiek składnik przekroczy wartość krytyczną)	88
Rysunek 24. Po lewej obraz z kamery hiperspektralnej Cubert Q285, po prawej wykres przebiegu hiperspektralnego dla jednego piksela zaznaczonego na czerwono na rysunku po lewej.	90
Rysunek 25. Dopasowanie klas materiałów do odpowiedzi spektralnych każdego z pikseli obrazu zebranego przez kamerę hiperspektralną.[15].	95
Rysunek 26. Maska semantyczna z przypisanymi klasami otoczenia. Po lewej obraz wejściowy, po prawej obraz po segmentacji (zielone - trawa, szare - droga asfaltowa). [15]	96

Rysunek 27. Przypisanie punktów z wyniku segmentacji semantycznej do współrzędnych mapy 2,5D opisane w [20]	99
Rysunek 28. Przykład mapy Speed-Made-Good zgodnej z NRMM.[81].....	103
Rysunek 29. Siły działające na pojazd podczas wjazdu na wzniesienie [16].	104
Rysunek 30. Wykres maksymalnych dopuszczalnych prędkości w zależności od promienia zakrętu dla pojazdu PIAP ATENA.	108
Rysunek 31. Odkształcenie gruntu w trakcie jazdy [80]......	109
Rysunek 32. Po lewej mapa z podziałem na komórki z przypisanemu materiałem (droga utwardzana na szaro, błoto na czarno), pośrodku przypisane maksymalne prędkości dla tych typów materiałów, po prawej mapa z uśrednionym przejściem pomiędzy prędkościami. Rysunek pochodzi z [16]......	111
Rysunek 33. Porównanie siatki heksagonalnej do prostokątnej oraz długości przejścia między środkami komórek [16].	114
Rysunek 34. Demonstrator technologii PIAP ATENA z kamerą hiperspektralną zamontowaną na masce pojazdu.	117
Rysunek 35. Wnętrze demonstratora technologii PIAP ATENA	118
Rysunek 36. Kamera hiperspektralna Cubert Q285 [15]	122
Rysunek 37. Pojazdy PIAP które zostały wykorzystane w badaniach.	124
Rysunek 38. Prototypowy stelaż na czujniki i element montażowy w okolicy grilla.....	130
Rysunek 39 Miejsce testów-rury przy drzewach, ustawienie lidar – na grillu, warstwy pionowe.	131
Rysunek 40 Zebrana chmura punktów z miejsca testów-rury przy drzewach, ustawienie lidar – na grillu, warstwy pionowe.	131

Rysunek 41 Miejsce testów-rury przy drzewach, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.....	132
Rysunek 42 Zebrana chmura punktów z miejsca testów-rury przy drzewach, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.	132
Rysunek 43 Miejsce testu-nasyp z ziemi i kamieni, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.....	133
Rysunek 44 Zebrana chmura punktów z miejsca testów-nasyp z ziemi, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.	133
Rysunek 45 Miejsce testów - przeszkoda z krzyżem, ustawienie lidar – na dachu od strony kierowcy, warstwy pod kątem 45°.....	134
Rysunek 46 Zebrana chmura punktów z miejsca testów - przeszkoda z krzyżem, ustawienie lidar – na dachu od strony kierowcy, warstwy pod kątem 45°.....	134
Rysunek 47 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na dachu od strony kierowcy, warstwy pionowe.	135
Rysunek 48 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na grilu, warstwy pionowe.	135
Rysunek 49 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na grillu, warstwy poziome.	136
Rysunek 50 Zebrana chmura punktów z miejsca - przeszkoda z krzyżem, ustawienie lidar – na dachu, warstwy poziome	136
Rysunek 51 Dwa czujniki zamontowane rozbieżnie w płaszczyźnie pionowej oraz jeden czujnik pośrodku dachu oraz na skraju maski pojazdu.	138
Rysunek 52. Zamodelowana platforma mobilna z sensorami.....	138
Rysunek 53. Chmura punktów wytworzona przez pojazd PIAP ATENA na terenie instytutu Łukasiewicz-PIAP wykorzystana do badań w artykule [113].	139

Rysunek 54. Tereny Przemysłowego Instytutu Automatyki i Pomiarów PIAP (fotografia satelitarna, chmura punktów zagregowana przez system ATENA oraz zdjęcie z kamery pojazdu ATENA). Na zdjęciu oznaczono obszar, w którym prowadzono większość testów laboratoryjnych.....	144
Rysunek 55. Model 3D terenów Łukasiewicz-PIAP	145
Rysunek 56. Na górze zdjęcia miejsca testów robotów mobilnych Łukasiewicz-PIAP, poniżej zapis chmury punktów tego miejsca (po lewej z modelem robota PIAP PATROL).....	145
Rysunek 57. Poligon Zielonka (Wojskowy Instytut Techniczny Uzbrojenia) gdzie przeprowadzono większość testów terenowych z kamerą hiperspektralną oraz pojazdem PIAP ATENA i PIAP HUNTER. Na zdjęciu oznaczono obszar, w którym prowadzono większość testów terenowych.....	146
Rysunek 58. Tereny Poligonu Zielonka, przeszkody terenowe - część 1 – doły i wyrwy...	147
Rysunek 59. Tereny Poligonu Zielonka, przeszkody terenowe - część 2, tereny piaszczyste.	148
Rysunek 60. Tereny Poligonu Zielonka, przeszkody terenowe - część 3, tereny z roślinnością.	149
Rysunek 61. Wzniesienie przygotowane do testów pojazdów UGV podczas FEX-24.....	150
Rysunek 62. Nierówności na trasie przejazdu podczas FEX-24.....	151
Rysunek 63. Wystające korzenie na trasie przejazdu FEX-24.....	151
Rysunek 64. Dół z błotem na trasie przejazdu FEX-24	152
Rysunek 65. Zdjęcie satelitarne terenu testów FEX-24	152
Rysunek 66. Na górze i na dole PIAP HUNTER podczas FEX-23[117]	153
Rysunek 67. Testy terenowe pojazdu PIAP ATENA na terenie poligonu WITU.	154

Rysunek 68. Zapis z testów terenowych dla pojazdu PIAP ATENA	155
Rysunek 69. Zapis testów terenowych dla pojazdu PIAP HUNTeR	157
Rysunek 70. Zapis z testów terenowych pojazdu PIAP PATROL	157
Rysunek 71. Koncepcja rozszerzenia zdolności pracy algorytmu oceny przejezdności z analizą materiałów otoczenia.	162
Rysunek 72. Demonstrator PIAP ATENA podczas zbierania danych o otoczeniu z wykorzystaniem kamery hiperspektralnej Cubert Q285 na Poligonie w WITU. Poniżej przygotowania do testów, na zdjęciu widać miejsce montażu kamery hiperspektralnej.	163
Rysunek 73. Różne rodzaje dróg i odpowiadające im histogramy: a) droga gruntowa, b) droga leśna (pokryta błotem), c) droga szutrowa, d) droga pokryta asfaltem (asfalt pokryty miejscowo piachem) [14].	164
Rysunek 74. Wyniki planowania trasy, na górze (a i b) planowanie trasy bez klasyfikacji materiału otoczenia, poniżej (c i d) planowanie trasy po klasyfikacji materiału otoczenia (kolorem szarym została zaznaczona nawierzchnia pokryta asfaltem) [15].	165
Rysunek 75. Po lewej zdjęcie terenu dla którego została zbudowana mapa na podstawie chmury punktów z lidarów OUSTER OS-1, przy pomocy PIAP PATROL w wersji DEZROB.[16]	167
Rysunek 76. Wynik eksperymentu w postaci zaplanowanej trasy dla parametrów przejezdności PIAP PATROL (po lewej) i PIAP ATENA (po prawej).[16]	167
Rysunek 77. Demonstracja autonomicznego systemu dla terenowych platform lądowych z funkcją podążania za celem ATENA, dla DIN MON.[118]	170
Rysunek 78. Wizualizacja odczytu z lidarów	171
Rysunek 79. Przykład identyfikacji obiektów znajdujących się w obszarze widzenia wybranych kamer.	172
Rysunek 80. Przykład identyfikacji obiektów znajdujących się w obszarze widzenia wybranych kamer oraz na wizualizacji 3D	173

Rysunek 81. Zbliżanie się do przeszkody – widok operatora robota.....	174
Rysunek 82. Pokonywanie przeszkody.....	174
Rysunek 83. Robot HUNTeR na wzniesieniu podczas ćwiczenia FEX-24.....	175
Rysunek 84. Wzniesienie przed pokonywaniem trasy przebiegającej po nim.....	175