



**Politechnika
Śląska**

Wydział Automatyki, Elektroniki i Informatyki

mgr inż. Krzysztof Paszek

Wykorzystanie sieci neuronowej oraz systemu rozmytego do predykcji
pozycji i wyboru ścieżki poruszającego się obiektu w lokalnym systemie
pozycjonowania opartym na technologii UWB

Rozprawa doktorska napisana pod kierunkiem
dr. hab. inż. Damiana Grzechcy, prof. Pol. Śl.

Gliwice 2022



Rzeczpospolita
Polska

Unia Europejska
Europejski Fundusz Społeczny



Niniejsza praca doktorska powstała w ramach projektu:

***„CyPhiS – Projekt nowoczesnych studiów doktoranckich
w dziedzinie systemów cyber-fizycznych”***

Projekt ten był dofinansowany z Funduszy Europejskich
w ramach Programu Operacyjnego Wiedza Edukacja Rozwój 2014-2020
przez Wydział Automatyki, Elektroniki i Informatyki Politechniki Śląskiej
w ramach Działania 3.2 Studia doktoranckie
na podstawie umowy nr POWR.03.02.00-00-I007/17-00

Spis treści

Wykaz najważniejszych akronimów i skrótów	1
1 Wstęp	3
1.1 Historia pojazdów bezzałogowych i autonomicznych.....	4
1.2 Poziomy automatyzacji	6
1.3 Pozycjonowanie a pojazdy autonomiczne	8
1.4 Motywacja.....	11
1.5 Cel pracy.....	14
2 Pozycjonowanie obiektów	17
2.1 Systemy pozycjonowania	22
2.2 Globalny system pozycjonowania	25
2.3 Ultra-wideband (UWB).....	27
2.4 Nawigacja inercyjna	38
2.5 Nawigacja zliczeniowa.....	40
3 Symulator systemu UWB	41
3.1 Analiza rzeczywistego systemu pozycjonowania	42
3.2 Wyznaczenie parametrów modelu	44
3.3 Opis scenariusza testowego w symulatorze	58
3.4 Przykładowa ścieżka referencyjna	61
3.5 Wyznaczenie odległości	63
3.6 Wprowadzanie przeszkód i detekcja warunków LOS, NLOS.....	65
3.7 Podsumowanie symulatora systemu UWB.....	66
4 System wyznaczania i wyboru ścieżki	69
4.1 Przygotowanie danych z dostępnych systemów.....	71
4.2 Korekta odległości.....	77
4.3 Wpływ metody trilateracji i liczby odległości na błąd pozycji.....	82
4.4 Predykcja pozycji obiektu.....	87
4.5 Rozmyty system ekspercki wyboru ścieżki poruszania się obiektu	104
4.6 Analiza czasu przetwarzania, wyniki eksperymentu	110
4.7 Podsumowanie.....	113
5 Podsumowanie i wnioski końcowe	117
6 Spis tabel	121
7 Spis rysunków.....	123
8 Bibliografia	125

Wykaz najważniejszych akronimów i skrótów

ACC	– <i>ang. adaptive cruise control</i> , adaptacyjny tempomat
ADAS	– <i>ang. advanced driver assistance systems</i> , zaawansowane systemy wspomagania kierowcy
ADS-TWR	– <i>ang. asymmetrical double-sided two-way ranging</i>
AGV	– <i>ang. automated guided vehicle</i> , automatycznie prowadzony pojazd
A-GPS	– <i>ang. assisted global positioning system</i> , wspomagany system nawigacji satelitarnej
AHRS	– <i>ang. attitude and heading reference system</i> , system odniesienia położenia i kursu
AoA	– <i>ang. angle of arrival</i>
BLE	– <i>ang. Bluetooth low energy</i>
CCD	– <i>ang. charge-coupled device camera</i> , kamera CCD
CPS	– <i>ang. cyber physical systems</i> , systemy ceberfizyczne
DECT	– <i>ang. digital enhanced cordless telephony</i> , system cyfrowej łączności bezprzewodowej
GDOP	– <i>ang. geometrical dilution of precision</i> , geometryczny współczynnik geometrycznej dokładności
GNSS	– <i>ang. global navigation satellite systems</i> , globalny system nawigacji satelitarnej
GPS	– <i>ang. global positioning system</i> , system nawigacji satelitarnej
GSM	– <i>ang. global system for mobile communications</i> , globalny system łączności ruchomej
IMU	– <i>ang. inertial measurement unit</i> , inercyjna jednostka pomiarowa
IPS	– <i>ang. indoor positioning system</i> , system pozycjonowania wewnątrz pomieszczeń
IR	– <i>ang. infrared</i> , podczerwień
LSTM	– <i>ang. long short-term memory</i>
MBE	– <i>ang. mean bias error</i> , średni błąd obciążenia, systematyczny
MEMS	– <i>ang. microelectromechanical system</i> , mikroukład elektromechaniczny
MSE	– <i>ang. mean squared error</i> , błąd średniokwadratowy
NAVSTAR	– <i>ang. navigation system with timing and ranging</i>
OPS	– <i>ang. outdoor positioning system</i> , system pozycjonowania na zewnątrz pomieszczeń

OWR	– <i>ang. one-way ranging</i> , jednostronne wymiarowanie
POI	– <i>ang. point of interest</i> , punkty zainteresowania
RFID	– <i>ang. radio-frequency identification</i> , system identyfikacji radiowej
RMSE	– <i>ang. root mean square error</i> , pierwiastek średniej kwadratowej błędów
RTT	– <i>ang. round trip time</i> , czas podróży w obie strony
RSD	– <i>ang. relative standard deviation</i> , względne odchylenie standardowe
RSS	– <i>ang. received signal strength</i>
SD	– <i>ang. standard deviation</i> , odchylenie standardowe
SDS-TWR	– <i>ang. symmetrical double-sided two-way ranging</i>
SLAM	– <i>ang. simultaneous localization and mapping</i> , jednoczesna lokalizacja i mapowanie
SS-TWR	– <i>ang. single-sided two-way ranging</i>
TDoA	– <i>ang. time difference of arrival</i>
ToA	– <i>ang. time of arrival</i> , czas przybycia
ToF	– <i>ang. time of flight</i> , czas przelotu
TWR	– <i>ang. two-way ranging</i> , dwustronne wymiarowanie
UGV	– <i>ang. unmanned ground vehicle</i> , bezzałogowy pojazd samojezdny
UWB	– <i>ang. ultra wideband</i> , ultraszerokopasmowa
V2I	– <i>ang. vehicle to infrastructure</i> , model komunikacji pomiędzy pojazdem, a infrastrukturą
V2V	– <i>ang. vehicle to vehicle</i> , model komunikacji pomiędzy pojazdami
WLAN	– <i>ang. wireless local area network</i> , bezprzewodowa sieć lokalna

1 Wstęp

Rozwijająca się gospodarka i tym samym przemysł opiera się w dużej mierze na automatyzacji procesów. Wraz z postępowaniem technologicznym szereg procesów produkcyjnych, czy też świadczone przez ludzi usługi stają się możliwe do zautomatyzowania (w pełni lub częściowo) tym samym skraca się czas produkcji lub wykonywanej usługi albo zmniejsza się ryzyko popełnienia błędu przez człowieka. Postęp ten jest również zauważalny w przemyśle motoryzacyjnym. Już w 1913 roku uruchomiono pierwszą ruchomą linię montażową w fabryce Forda. Dzięki niej skrócono czas produkcji aż ośmiokrotnie, a pracownicy zajmowali się pojedynczymi zadaniami, a nie jak dotychczas uczestniczyli w budowie całego samochodu [1].

Automatyczne hale magazynowe są w kręgu zainteresowania wielu firm i naukowców [2], [3]. Już teraz w takich miejscach można zauważyć, że towary są przewożone przez autonomiczne roboty (pojazdy samojezdne). Dzieje się to zazwyczaj po ściśle wytyczonych trasach, jednakże w procesie transportu nie jest zaangażowany człowiek. Automatyczne linie do pakowania towarów, czy zautomatyzowane samochodowe linie produkcyjne, gdzie elementy i części pojazdów są przewożone bez udziału człowieka, są kolejnymi przykładami, które pokazują jak dużą rolę pełni automatyzacja procesów i transportu dla przemysłu.

Zautomatyzowanie transportu jest nieodzownym elementem przyszłości, nie tylko w halach magazynowych, ale również na drogach publicznych, gdzie będą wspomagać (co częściowo jest już osiągnięte) lub zastępować ludzi w procesie kierowania pojazdem. Już teraz firmy oferują transport publiczny wykorzystując pojazdy autonomiczne, przykładowo firma Transdev Autonomous Transport Systems przetransportowała już 3,5 mln pasażerów, a pojazdy przejechały 1,6 mln kilometrów [4]. Przyszłość pojazdów autonomicznych potwierdzana jest również przez prace, które prowadzone są nie tylko w temacie wykorzystywanych na pokładzie pojazdu systemów czy urządzeń, ale również poruszane są aspekty takie jak planowanie rozkładu jazdy [5], względy etyczne i finansowe [6] oraz taki aspekt jak dostępność (czyli łatwość komunikacji) [7].

Rozwój technologiczny napędza gospodarkę. Nowoczesny przemysł nie tylko podnosi standard oferowanych produktów, ale również zachowuje powtarzalność procesu, przez co oferowane produkty są tej samej jakości, a usługi są na tym samym poziomie. W celu zautomatyzowania – w pełni lub częściowo, transportu ludzi lub towarów zarówno w halach magazynowych, produkcyjnych jak również w ruchu miejskim, należy zapewnić wysoki poziom percepcji otoczenia. Duża dokładność pozycji obiektu w lokalnym układzie odniesienia jest jednym z elementów, który przyczynia się do zwiększenia możliwości percepcyjnych i tym

samym wpływa na bezpieczeństwo uczestników ruchu. Prace nad pozycjonowaniem pojazdów nie tylko w układzie bezwzględny, ale również w stosunku do innych obiektów prowadzone są od wielu lat.

1.1 Historia pojazdów bezzałogowych i autonomicznych

Masowa produkcja samochodów, która w USA przypada na lata dwudzieste (a w Europie na lata pięćdziesiąte) XX wieku spowodowała duży wzrost wypadków na drogach [8]. W celu wyeliminowania błędów ludzkich już wtedy myślano o automatyzacji procesu jakim jest prowadzenie czy sterowanie pojazdem. Bezzałogowy pojazd zaprezentowano już w 1921 r., jednakże nie był to pojazd autonomiczny (w dzisiejszym rozumieniu tego słowa), a zdalnie sterowany radiowo przez kierowcę, który znajdował się w innym pojeździe. W 1925 r. szerokiej publiczności przedstawiono kolejny zdalnie sterowany pojazd – „American Wonder”. W obydwóch projektach istotną rolę odgrywało wojsko, które udostępniło swoją bazę wiedzy technicznej wymaganej do budowy tego typu pojazdu. To nie były jedyne zdalnie sterowane pojazdy zaprezentowane światu, można tutaj jeszcze wymienić taki pojazd jak Phantom Auto. W 1958 r. zakończono pierwsze testy automatycznie sterowanego samochodu. Zmodyfikowany Chevrolet automatycznie wykonywał ruch kierownicą tak aby podążać za ścieżką wytyczoną przez przewód umieszczony na torze testowym (wytwarzający pole elektromagnetyczne).

Przemysł motoryzacyjny nie był jedynym, w którym starano się zrewolucjonizować transport. W 1954 r. w firmie Barrett Electronics zaprezentowano pierwszy pojazd - Guide-O-Matic, poruszający się całkowicie bez kierowcy. Pojazd typu AGV (*ang. automated guided vehicle* – termin ten powstał dopiero w latach osiemdziesiątych XX w.) podążał za drutem umieszczonym w posadzce [9]. Pojazd ten zapewnił świetlaną przyszłość firmie, która stała się głównym dostawcą wyposażenia dla centrów logistycznych i dystrybucyjnych. W Europie pojazdy AGV pojawiły się nieco później. W Niemczech w 1963 r. firma Wagner Fördertechnik wprowadziła swój pierwszy AGV. W latach osiemdziesiątych i dziewięćdziesiątych XX w. firma ta była znana na całym świecie ze swoich produktów. Pojazdy AGV zrewolucjonizowały przemysł pozwalając zredukować czas na transport elementów w fabrykach, który dotychczas był wykonywany ręcznie przez pracowników.

Kolejna warta uwagi konstrukcja pojazdu autonomicznego została zaprezentowana w Japonii w 1977 r. Zespół z Mechanical Engineering Laboratory skonstruował pojazd, który był sterowany na podstawie danych pochodzących z systemu wizyjnego (dwóch kamer wykrywających dwie boczne linie drogi lub toru). Pojazd nagrywał i przetwarzał obraz na

pokładzie, co było dużym osiągnięciem. Pojazd osiągał prędkość do 20 mil/h i mógł przejechać dystans do 50 m.

Przełomowym okresem dla pojazdów autonomicznych były lata osiemdziesiąte XX wieku. W 1984 r. w Niemczech opracowano pierwszy pojazd autonomiczny sterowany na podstawie wizji, który bazował na rozróżnianiu wielu elementów wyznaczających krawędzie (już nie tylko pojedynczych znaczników), był wyposażony w cyfrowy procesor i wykorzystywał modele dynamiczne. Był to 5 tonowy van – Mercedes 508 D o akronimie VaMoRs, który w 1987 roku, wyłącznie przy wykorzystaniu systemu wizyjnego (bez pomocy radarów czy GPS), pokonał dystans 20 km osiągając prędkość 96 km/h. Początkowo przyszłość autonomicznych pojazdów wiązano z naprowadzaniem przy pomocy pola magnetycznego (kable wbudowane na stałe w jezdnię), jednakże duży wpływ zespołu Dickmann'a na europejski projekt PROMETHEUS (1987-1995) doprowadził do zmiany kierunku na rzecz systemów wizyjnych. Wieloletnia współpraca zespołu Dickmann'a z firmą Daimler-Benz AG zaowocowała pojazdem (Mercedes Benz 500 – VaMoRs-P), w którym przyspieszanie, hamowanie i sterowanie było kontrolowane w pełni automatycznie. Systemy wizyjne pojazdu (kamery CCD, *ang. charge-coupled device cameras*) nie obserwowały tylko przodu, ale również tył pojazdu, wykorzystywały systemy inercyjne (przyspieszenie i prędkość kątową) i przetwarzanie równoległe (60 transputerów). Zakończenie projektu uwieńczono pokazem pojazdu, który przejechał ponad 1000 km z prędkością do 130 km/h w dużym ruchu ulicznym (Paryż, 1994) [8], [10], [11]. W tym samym czasie w USA powstał model testowy samochodu Navlab 5, pojazd ten był częściowo autonomiczny – sieć neuronowa wykorzystywana była do sterowania pojazdem (na podstawie danych wizyjnych), natomiast przyspieszanie i hamowanie było wykonywane przez człowieka o czym wprost informuje nazwa projektu „*No Hands Across America*”. Opracowany algorytm – Ralph (*Rapidly Adapting Lateral Position Handler*) z dużą dokładnością potrafił określić pozycję i orientację względem drogi [12].

Powyższe przykłady (oczywiście nie jedyne, ponieważ prace prowadzone są na całym świecie przez różne zespoły naukowców, firmy produkujące roboty przemysłowe, czy firmy motoryzacyjne) pokazują, że autonomia pojazdów (pełna lub częściowa) jest przyszłością motoryzacji, a pojazdy bezzałogowe są przyszłością przemysłu. W dzisiejszych czasach pojazdy AGV nie tylko przemieszczają elementy w fabrykach, ale również umieszczają je na odpowiednich stanowiskach, czy też dostarczają produkty do odbiorców końcowych – konsumentów. Autonomiczne poruszanie się wózków samojezdnych czy pojazdów samochodowych możliwe jest dzięki znanej pozycji obiektów (bezwzględnej lub względnej) oraz percepcji otoczenia. Wymienione dwa czynniki pozwalają również na zwiększenie

bezpieczeństwa poprzez predykcję możliwych sytuacji niebezpiecznych. Wyeliminowanie błędów ludzkich jest potrzebne, aby coraz to bardziej zatłoczone ulice z coraz to bardziej skomplikowaną organizacją były bezpieczne dla wszystkich uczestników ruchu – tych żywych i mechanicznych. Ciasne ulice i skrzyżowania czy place manewrowe, drogi transportowe w magazynach lub fabrykach nie ułatwiają analizy przez systemy obserwujące obszary wokół pojazdu (dokonujące percepcji otoczenia). Automatyczne hale magazynowe, pojazdy AGV są w fabrykach coraz bardziej popularne, a często nawet niezbędne w nowoczesnych przedsiębiorstwach. Z tego też powodu wiedza o pozycji obiektu jest potrzebna, aby „dostrzec” go na drodze, gdy jest poza polem widzenia kamer, lidarów czy radarów oraz aby AGV nie zderzył się z innym pojazdem, pracownikiem czy elementami infrastruktury w przedsiębiorstwie. Informacja o obiekcie zbliżającym się pozwala ostrzec kierowcę, systemy wspomaganie kierowcy, czy też system sterujący pojazdem AGV dużo wcześniej, przed wystąpieniem ewentualnej niebezpiecznej sytuacji.

Mimo wielu różnic pomiędzy poszczególnymi samochodami autonomicznymi i pojazdami AGV takimi jak przeznaczenie, konstrukcja, prędkości poruszania czy dynamika, badania nad nimi mają wiele punktów wspólnych (np.: wykorzystywane systemy i technologie, sposoby analizy danych i informacji) oraz zbieżny cel, którym jest minimalizacja błędów ludzkich, podnosząc tym samym bezpieczeństwo uczestników ruchu drogowego, czy też wewnątrzzakładowego. Prace nad pojazdami i robotami autonomicznymi lub bezzałogowymi prowadzone są od ponad 100 lat.

1.2 Poziomy automatyzacji

Wraz z rozwojem motoryzacji, systemów wspomaganie kierowcy (ADAS – *ang. advanced driver assistance systems*) [13], czy samych pojazdów autonomicznych narodziła się potrzeba wyznaczenia granic pomiędzy klasami lub typami pojazdów. W 2014 roku SAE opracowało i wprowadziło sześciostopniową skalę klasyfikacji pojazdów, która pozwala jednoznacznie zdefiniować stopień autonomiczności pojazdu [14]. Każdy kolejny stopień w skali SAE wskazuje na coraz większą ingerencję systemów komputerowych w proces prowadzenia pojazdu (patrz tab. 1). Tym samym poziom 0 wskazuje na pojazdy, które prowadzone są wyłącznie przez kierowcę, to kierowca ma cały czas obserwować otoczenie i podejmować decyzje. Natomiast poziom 5 wskazuje pełną automatyzację (autonomię), systemy komputerowe odpowiedzialne są za poruszanie się pojazdu i obserwację otoczenia. To systemy komputerowe podejmują decyzje w razie incydentów drogowych, czy też w razie wystąpienia niebezpieczeństwa (patrz tab. 2).

Tab. 1. Poziomy automatyzacji SAE

Poziom	Nazwa	Kierowanie, przyspieszenia i hamowanie	Obserwowanie otoczenia	Reakcja w nagłych sytuacjach	Tryb jazdy
(1)	(2)	(4)	(5)	(6)	(7)
0	Brak automatyzacji	K	K	K	Brak
1	Wspomaganie kierowcy	K i S	K	K	Niektóre tryby jazdy
2	Częściowa automatyzacja	S	K	K	Niektóre tryby jazdy
3	Warunkowa automatyzacja	S	S	K	Niektóre tryby jazdy
4	Wysoki poziom automatyzacji	S	S	S	Niektóre tryby jazdy
5	Pełna automatyzacja	S	S	S	Wszystkie tryby jazdy

Legenda: K – kierowca, S – system.

Tab. 2. Poziomy automatyzacji SAE – opis poziomów

Poziom	Nazwa	Definicja
(1)	(2)	(3)
0	Brak automatyzacji	Pojazd w pełni kontrolowany przez kierowcę, mogą występować systemy ostrzegania, jednakże nie ingerują one w proces kierowania.
1	Wspomaganie kierowcy	Wspomaganie kierowcy przez system w zakresie pojedynczej akcji: kierowania lub przyspieszenia, hamowania. Kierowca musi stale kontrolować sytuację i interweniować w razie potrzeby.
2	Częściowa automatyzacja	Wspomaganie kierowcy przez system w zakresie pojedynczej lub wielu akcji: kierowania lub przyspieszenia, hamowania. Kierowca musi stale kontrolować sytuację i interweniować w razie potrzeby.
3	Warunkowa automatyzacja	Pojazd kierowany w pełni przez system. Kierowca może zaniechać kontroli otoczenia, jednakże w każdej chwili musi być zdolny do przejęcia kontroli.
4	Wysoki poziom automatyzacji	Pojazd kierowany w pełni przez system nawet w sytuacjach, w których kierowca nie reaguje na prośbę o interwencję.
5	Pełna automatyzacja	Pojazd kierowany w pełni przez system nawet w sytuacjach.

Duża liczba systemów wykorzystywanych w automatyzacji procesu prowadzenia pojazdu i obserwacji otoczenia, wymaga dużej mocy obliczeniowej. Dane z różnych podsystemów wyznaczania pozycji względnej lub bezwzględnej (kamery, radary, lidary, itd.) nie tylko muszą być zebrane, ale również przygotowane oraz przetworzone przez wiele algorytmów (np. sztuczną sieć neuronową). Do takich celów wymagana jest wydajna jednostka obliczeniowa

(superkomputer), która jednocześnie musi być energooszczędna, charakteryzować się niskim poborem mocy, zapewniać wysoko wydajne oprogramowanie oraz zajmować mało miejsca [15].

1.3 Pozycjonowanie a pojazdy autonomiczne

Wyznaczenie dokładnej pozycji poruszającego się obiektu, np. z zastosowaniem systemu UWB, niesie ze sobą wiele korzyści m.in. podnoszenie wydajności procesów produkcyjnych czy jakości oferowanych usług, oraz zwiększenie bezpieczeństwa w ruchu po drogach czy też w halach magazynowych gdzie jest ono równie ważne [16], [17]. Schemat postępowania z danymi pozyskanymi z urządzeń umożliwiających wyznaczenie pozycji jest taki sam niezależnie od tego, czy jest to bezzałogowy pojazd samojezdny (UGV – *ang. unmanned ground vehicle*), czy pojazd samochodowy (samochód osobowy, ciężarówka, autobus). Mimo że zastosowanie wymienionych pojazdów jest inne to w obu przypadkach cel jest zbieżny – dokładna pozycja obiektu.

W 2019 r. w Polsce odnotowano 455 454 kolizje i 30 288 wypadków co łącznie daje 485 742 zdarzenia drogowe [18]. Druga grupa jest o wiele ważniejsza, ponieważ w wyniku wypadków są osoby poszkodowane – ranni oraz zabici. Krajowa Rada Bezpieczeństwa Ruchu Drogowego prowadzi obszerne statystyki dotyczące wypadków. Zbierane są takie informacje jak pora dnia, warunki atmosferyczne, rodzaj drogi, wiek ofiary, rodzaj wypadku itd. Na 30 288 wypadków odnotowano 38, które bezpośrednio wynikały z niesprawności technicznej pojazdu co daje 1,3‰ wszystkich wypadków w 2019 r. – w 99% głównym czynnikiem jest błąd ludzki.

Pojazdy autonomiczne i wykorzystywane w nich technologie dostarczają wielu obaw co do ich bezpieczeństwa i niezawodności. Występują problemy nie tylko natury technicznej, ale również moralnej. Szerokim zagadnieniem jest sposób testowania bezpieczeństwa, niezawodności pojazdów autonomicznych oraz sprawdzenia czy pojazdy autonomiczne i tym samym systemy w nich wykorzystywane mają mniejszy współczynnik popełniania błędów niż kierowcy – ludzie. Problem jest złożony, liczba wypadków w stosunku do wszystkich zdarzeń drogowych nie jest duża (w omawianym przykładzie za rok 2019 jest to 6%). Jeżeli testy bezpieczeństwa mają być wiarygodne, przed branżą motoryzacyjną stoi duże wyzwanie, ponieważ należy opracować nowe metody wyznaczania bezpieczeństwa i niezawodności. Na bazie danych z 2015 r. Biura Statystyki Transportu Departamentu Transportu Stanów Zjednoczonych oszacowano, że pojazdy w pełni autonomiczne musiałyby przejechać setki milionów (a nawet miliardów) mil aby wykazać niezawodność pod względem wypadków [19].

Ciągła obserwacja otoczenia nie jest prosta, kierowca (w szczególności zawodowy), operator wózka magazynowego po wielu godzinach pracy traci koncentrację, ponadto dużym

problemem jest martwe pole widzenia, które wynika z konstrukcji pojazdu lub złego ustawienia lusterek bocznych oraz wstecznego (metody wykrywania obiektów w otoczeniu pojazdu w celu eliminacji martwych stref są opracowywane i wdrażane przez duże koncerny motoryzacyjne [20]–[22]), przez co kierowca, operator może nie być świadomy niebezpiecznej sytuacji. Częściowo autonomiczne pojazdy doprowadzają również do sytuacji, w której kierowca traci zainteresowanie czynnością prowadzenia pojazdu na rzecz innych czynności mimo tego, że może być wymagana jego natychmiastowa reakcja, przez co jego odpowiedź na zdarzenie jest opóźniona [23].

Znana pozycja obiektów w ruchu pozwoli zwiększyć bezpieczeństwo pojazdów autonomicznych i innych uczestników ruchu w przyszłości, gdzie ich udział na drodze będzie coraz to większy. Opracowywane są również technologie i protokoły, które umożliwią komunikację pomiędzy pojazdami (V2V – *ang. vehicle to vehicle*) oraz pomiędzy pojazdami a infrastrukturą (V2I – *ang. vehicle to infrastructure*). Ciągła komunikacja z otoczeniem pozwoli nie tylko dostarczyć informacji kierowcy o aktualnie panujących przepisach na danym odcinku drogi, ale również o pracach drogowych, czy też zdarzeniach drogowych (np. kolizji, zatorze) [24]. Kierowca może jedynie zareagować na sytuacje, które jest w stanie dostrzec lub też system pojazdu autonomicznego może podjąć odpowiednią decyzję tylko w sytuacjach lub zagrożeniach, o których dowiaduje się na podstawie danych z podsystemów, w które pojazd jest wyposażony. Jednakże, żeby wykorzystać informację o możliwym niebezpieczeństwie oraz aby komunikacja V2V/V2I była możliwa, wymagana jest dokładna pozycja obiektu, aby komunikaty docierające do kierowcy, operatora, czy systemów wspomagania w pojeździe były użyteczne. Nadmierna liczba komunikatów lub błędny adresat danej wiadomości z otoczenia wpłynąć będą na przeciążenie systemów analizujących te komunikaty w pojeździe, a w najgorszym przypadku na generowanie błędnych komunikatów przez systemy nadrzędne pojazdu. Sytuacja taka może mieć miejsce, jeżeli dokładność wyznaczonej pozycji będzie mała, a organizacja ruchu będzie złożona i ruch będzie pokaźny (duża liczba dostawców komunikatów).

Stosowanych jest wiele technologii, które dostarczają dodatkowych informacji dla kierowcy, pozwalają dostrzec rzeczy normalnie niewidoczne dla kierującego, jak np. pojazd znajdujący się w martwym polu widzenia. Systemy radarowe, lidarowe i ultradźwiękowe obserwują i skanują otoczenie pojazdu i w każdej chwili mogą dostarczyć informacji o zbliżającym się niebezpieczeństwie (czyli wyznaczana jest pozycja obiektu względem przeszkody, czy innego uczestnika ruchu). Mogą też podjąć decyzję i wykonać akcję bez interwencji kierowcy np.: awaryjnie zahamować, zaparkować pojazd we wskazanym miejscu (aktywny asystent parkowania) [25]. Systemy te pozwalają również na monitorowanie odległości

do poprzedzającego samochodu, a to pozwala ostrzec kierowcę o niezachowaniu dostatecznej odległości, czy też automatycznie dostosowywać prędkość do ruchu aktualnie panującego na drodze [26].

Znana pozycja obiektu ułatwia przeprowadzenie komunikacji pomiędzy pojazdami, która daje możliwość ostrzeżenia systemów pojazdu i tym samym kierowcy o zbliżaniu się do potencjalnie niebezpiecznego miejsca [27]. Z kolei predykcja pozycji pozwoliłaby na zwiększenie czasu, który system miałby na podjęcie stosownej reakcji. Wszystkie systemy, które teraz służą pomocą kierowcy, w wyższych stopniach autonomii będą dostarczały informacji systemowi nadrzędnemu, który za człowieka będzie podejmował decyzje o sposobie prowadzenia pojazdu i ewentualnych reakcjach na nieoczekiwane sytuacje. Niemniej jednak wykorzystywane systemy muszą „zobaczyć” innego uczestnika ruchu, czy też przeszkodę, aby system nadrzędny mógł podjąć odpowiednią decyzję, czy też informacja o pozycji przeszkody musi być dostarczona odpowiednio wcześniej, aby system miał czas na podjęcie decyzji. Jednakże co w sytuacji, kiedy przeszkoda jest całkowicie niewidoczna np. uszkodzony pojazd, powalone drzewo znajdujące się na drodze bezpośrednio za ostrym zakrętem, czy wózek transportowy przesłonięty przez linię regałów magazynowych lub też, gdy częstotliwość pozyskiwania informacji z systemu pozycjonowania jest zbyt niska? Przy dużej prędkości kierujący może nie mieć szansy na ominięcie, czy też zahamowanie przed przeszkodą. Z kolei wózki magazynowe przewożące ciężkie towary charakteryzuje się bezwładnością, która może spowodować, że mimo szybkiej reakcji czas, w którym wygenerowano ostrzeżenie był zbyt długi.

Opracowanie skutecznych metod analizy pozyskanych danych z różnych systemów dla różnych scenariuszy testowych jest problemem złożonym. Podczas analizy skuteczności wykorzystywanych systemów największą trudność przysparza system dostarczający danych referencyjnych (*ang. ground truth*). Symulatory systemów pozwalających na wyznaczenie pozycji obiektu (np. Lidar, radar, IMU) są szeroko stosowane do testowania algorytmów analizy danych z nich pochodzących [28], [29]. Technologia UWB również posiada symulator, który umożliwia przygotowanie transmisji na niskim poziomie [30]. Jednakże do zamodelowania konkretnego systemu rozpoczynając od niskiego poziomu wymagane są szczegółowe informacje dotyczące np. transmisji, które często nie są udostępniane przez producentów gotowych rozwiązań. Dane z symulacji są łatwiejsze do pozyskania, nie wymagają czasochłonnych testów w terenie i pozwalają na większy zakres scenariuszy testowych.

1.4 Motywacja

Systemy pozycjonowania choć szeroko stosowane i niezbędne, to wciąż posiadają pewne wady, z których największą jest stosunkowo duże opóźnienie w stosunku do rzeczywistej, aktualnej pozycji obiektu jakim może być człowiek, pojazd samochodowy, czy też wózek samojezdny. Problem ten jest aktualny i ważny ze względu na ciągle rozwijające się miasta i przemysł, w których wymagania co do płynności i bezpieczeństwa przewozu ludzi i towarów stale rosną. Zauważyć należy, że wzrost prędkości poruszających się obiektów zwiększa różnicę pomiędzy rzeczywistą (aktualną w danym momencie) pozycją obiektu, a wyznaczoną z wykorzystaniem systemów pozycjonowania, która ze względu na czas potrzebny na akwizycję danych oraz ich analizę (przy założeniu, że obiekt jest w ciągłym ruchu) zawsze jest pozycją historyczną (dlatego m.in. systemy GNSS nie znajdują powszechnego zastosowania wtedy, kiedy wymagana jest większa precyzja lub mniejsze opóźnienie). Aspekt ten jest szczególnie ważny w systemach, które powinny działać w czasie rzeczywistym. Dlatego tak ważna jest predykcja ścieżki poruszającego się obiektu, co nie tylko powinno zniwelować wskazany problem, ale zapewnić ciągłość wyznaczania pozycji przy krótkotrwałych zanikach danych z systemu pozycjonującego oraz również pozwolić na poprawę bezpieczeństwa.

Do pozycjonowania obiektów można wykorzystać różne systemy, które będą spełniać swoje zadanie na różnych obszarach, jednakże co w sytuacji, w której informacja o pozycji jest nieaktualna, częstość pozyskiwania pozycji jest zbyt mała w stosunku do osiągniętych przez poruszający się obiekt prędkości lub w najgorszym przypadku system w wyniku krótkotrwałego błędu nie dostarczy informacji o pozycji? Problem ten jest krytyczny biorąc pod uwagę jak dużo szkód może wyrządzić rozpędzony pojazd. Może nasunąć się bardzo proste rozwiązanie – w wyniku braku komunikacji z systemem pozycjonowania należy zatrzymać pojazd. Jednakże rozwiązanie to może spowodować paraliż w ruchu drogowym, czy w łańcuchu dostaw w przedsiębiorstwie. Chwilowy brak komunikacji z sensorem, czy też brak użytecznych danych nie może wpływać drastycznie na działanie całego systemu pozycjonowania. Niezbędne jest opracowanie systemu, który zapewni ciągłość wyznaczanej pozycji obiektu biorąc pod uwagę dostępne systemy w danej chwili, czy też prędkość poruszającego się pojazdu. Rozwiązaniem na chwilowy brak dostępności pozycji jest już przytoczona predykcja, która nie tylko pozwoli wyeliminować problem wynikający z opóźnień i prędkości obiektu, ale pozwoli również na bazie danych historycznych i niepełnych danych aktualnych estymować pozycję obiektu podczas krótkotrwałych problemów z wykorzystywanym systemem pozycjonowania.

Zaproponowano już wiele rozwiązań bazujących na różnych technologiach, które mają swoje ograniczenia. Przykładem jest system pozycjonowania bazujący na polu magnetycznym, które generowane jest przez cewki rozmieszczone w budynku. Systemy tego typu charakteryzują się odpornością na warunki niepełnej widoczności, jednakże ze względu na zasięg działania i duże koszty systemy tego typu nie są powszechne. Biorąc pod uwagę istniejące systemy pozycjonowania, ich ograniczenia, ale również zalety, wymienić tutaj należy głównie systemy GNSS (*ang. global navigation satellite systems*, globalny system nawigacji satelitarnej) oraz nawigację zliczeniową i inercyjną, wyraźnie widać brak systemu, który umożliwiłby rzetelną ocenę jakości pozyskiwanej z poszczególnych systemów pozycji i porównania jej do lokalnego lub globalnego systemu odniesienia. W celu wyznaczenia pozycji obiektu, pojazdu na rzecz predykcji pozycji oraz wyboru ścieżki wykorzystana będzie stosunkowo nowa technologia pozycjonowania oparta na impulsach szerokopasmowych UWB (*ang. ultra wideband*). System ten cechuje się dokładnością kilkudziesięciu, niekiedy kilkunastu centymetrów i może być stosowany zarówno do pozycjonowania wewnątrz jak i na zewnątrz budynków. Wyznaczona pozycja obiektu może być niskim kosztem naniesiona na plany budynku lub magazynu, czy też drogi lub skrzyżowania. System ten w przyszłości może stać się alternatywą dla systemu GPS (*ang. global positioning system*, system nawigacji satelitarnej) w obszarach, w których sygnał satelitarny jest niedostępny np. hale magazynowe, hale produkcyjne, parkingi podziemne oraz w newralgicznych punktach infrastruktury drogowej jak skrzyżowania czy tunele – czyli w miejscach, gdzie sygnał GPS może być zakłócony przez wysokie budynki czy zwały ziemi. Moduły UWB są stosunkowo tanie i ogólnodostępne co powoduje, że są one bardziej atrakcyjne ze strony biznesowej. System wykorzystujący technologię UWB wymaga do wyznaczenia pozycji obiektu na płaszczyźnie co najmniej trzech odległości. Czas akwizycji danych (odległości) wprowadza opóźnienie, które przekłada się na przesunięcie obiektu w stosunku do pozycji, w których obiekt pozyskał dane o odległościach. W wyniku ruchu obiektu otrzymywana pozycja jest w rzeczywistości pozycją historyczną. Raz zbudowana infrastruktura sieci UWB (stacjonarne punkty referencyjne) może obsłużyć wiele obiektów mobilnych, które będą w zasięgu jej działania. Warunkiem jest to, że obiekt mobilny (pieszy, samochód, wózek samojezdny, rowerzysta) zostanie wyposażony w odpowiednio skonfigurowany znacznik UWB.

Zastosowanie kilku technologii do wyznaczania pozycji obiektów można nie tylko zwiększyć dokładność wyznaczanej pozycji, ale również pozwala zbudować system bardziej uniwersalny – o większym pokryciu. Ponadto dane z kilku podsystemów do wyznaczania pozycji mogą umożliwić dokładniejszą predykcję oraz mogą pozwolić systemowi decyzyjnemu dokonać oceny, które dane o pozycji powinny być wykorzystane przez system nadrzędny.

Podczas analizy danych o ruchu obiektu dane referencyjne należy pozyskać z innego systemu, którego dokładność powinna być o co najmniej rząd wielkości wyższa (mniejszy błąd) niż dokładność systemu testowanego lub można też dany scenariusz testowy powtórzyć wielokrotnie przy zachowaniu tych samych parametrów i uśrednione wartości z wszystkich przejazdów uznać za dane referencyjne na co wskazuje norma ISO/IEC 18305 [31]. Jednakże biorąc pod uwagę platformę pomiarową, którą jest samochód, wózek samojezdny czy też pojazd zdalnie sterowany, jest to trudne do wykonania, aby przejazd wykonywany przez kierowcę, operatora był powtórzony wielokrotnie przy zachowaniu takich samych parametrów ruchu. Z uwagi na to, że dokładność systemu UWB przy odpowiedniej analizie danych jest rzędu kilkunastu, a nawet kilku centymetrów, system referencyjny musiałby się charakteryzować dokładnością rzędu milimetrów przez co znalezienie systemu referencyjnego jest trudne. Często praktyką jest wyznaczanie dokładności w punktach referencyjnych, w których obiekt się zatrzymuje, przez przejazd nad tego typu punktem i odczytanie znacznika wykorzystując np.: RFID lub analizę wideo. Jednakże w takim podejściu nie ma informacji na temat dokładności pozycji w każdym z punktów ścieżki, w którym dostępne są dane o pozycji z systemu UWB, po której poruszał się obiekt. Innym sposobem jest wyznaczenie dokładności na podstawie porównania ścieżki wykreślonej na podstawie danych z systemu UWB z możliwą do otrzymania pozycją, czyli czy mieści się w ramach założonej ścieżki poruszania się obiektu np. korytarz o długości 50m i szerokości 2m. Z kolei w takim podejściu pomijana jest informacja o czasie, w którym dana pozycja była pozyskana [32], [33]. Ważnym aspektem jest również synchronizacja pomiędzy systemem referencyjnym a systemem testowanym, które często posiadają różną częstość pozyskiwania danych o pozycji. Rozwiązaniem są symulatory wykorzystywanych systemów pozycjonowania, które dostarczają nie tylko dane z wybranego systemu, ale również informacje o pozycji referencyjnej. W momencie rozpoczęcia prac nie znaleziono narzędzi symulacyjnych systemu UWB, które brałyby pod uwagę zmienną charakterystykę działania wraz z odległością i które dałyby możliwość odwzorowania pracy posiadanego systemu rzeczywistego. Ponadto aktualnie dostępne symulatory systemu UWB operują na poziomie modulacji sygnału co powoduje, że zasymulowanie systemu bez dokładnych informacji staje się niemożliwe.

1.5 Cel pracy

W związku z przedstawionymi powyżej potrzebami związanymi z pozycjonowaniem obiektów będących w ruchu, szczególnie w newralgicznych miejscach infrastruktury, proponuje się wykorzystanie systemu pozycjonującego UWB. Niestety system ten pomimo wielu zalet posiada również pewne niedoskonałości i dlatego postawiono za cel opracowanie systemu decyzyjnego pozycjonowania obiektów będących w ruchu na podstawie danych z systemów: UWB i nawigacji inercyjnej INS (AHRS), umieszczonego w newralgicznych miejscach infrastruktury, działającego w czasie rzeczywistym. W pracy zostanie zaproponowany system kooperacyjnego pozycjonowania obiektów, który obejmuje następujące systemy pozwalające na wyznaczenie pozycji obiektu: UWB, IMU (*ang. inertial measurement unit*)/AHRS (*ang. attitude and heading reference system*). Zaproponowany system umieszczony w newralgicznych miejscach infrastruktury powinien umożliwić pozyskanie pozycji w akceptowalnym czasie. W momencie rozpoczęcia prac nad rozprawą dokorską brakowało symulacyjnego narzędzia do przeprowadzania analiz komputerowych systemu UWB, dlatego postawiono cel poboczny rozprawy, którym jest opracowanie symulatora systemu UWB odzwierciedlającego pracę rzeczywistego dostępnego systemu UWB, na podstawie obserwacji jego zachowania. Symulator powinien udostępniać dane referencyjne, które umożliwią określenie dokładności wyznaczanych pozycji.

Nadrzędnym elementem pracy jest opracowanie metody, która umożliwi wykorzystanie nowej technologii szerokopasmowej UWB do pozycjonowania obiektów będących w ruchu, która wraz z zastosowaniem filtracji komplementarnej umożliwi pozyskanie pozycji w akceptowalnym czasie. W związku z tym postawiono następującą tezę: Wykorzystanie lokalnego podsystemu pozycjonowania UWB oraz zastosowanie filtracji komplementarnej zwiększa dokładność przy dopuszczalnym czasie wyznaczania pozycji poruszającego się obiektu.

Mając na uwadze redundancję systemów umożliwiających pozyskiwanie pozycji w postaci nawigacji inercyjnej oraz wykorzystywanego w pracy systemu szerokopasmowego UWB postanowiono opracować system decyzyjny, który na podstawie informacji z wymienionych systemów i z wykorzystaniem inteligencji obliczeniowej oraz systemu eksperckiego pozwoli określić, czy do wyznaczenia aktualnej pozycji obiektu należy wykorzystać pozycję znajdującą się na ścieżce zbudowanej z pozycji pozyskanych z danych aktualnych, czy wykorzystać dane pochodzące z predykcji, czy też posiadane dane nie są wystarczające do wyznaczenia pozycji obiektu. W tym celu postawiono drugą tezę: Fuzja danych pochodzących

z podsystemów pozycjonowania wraz z wykorzystaniem systemu rozmytego i sieci neuronowej umożliwią wybór aktualnej i predykcję ścieżki poruszania się obiektu w akceptowalnym czasie.

W pracy określony zostanie czas potrzebny na pozyskiwanie pozycji obiektu, który z kolei rzutuje na możliwe przesunięcie obiektu zgodnie z jego prędkością. Pod tym kątem przeanalizowane zostaną m.in. czas akwizycji, proces korekty odległości i metody trilateracji. W pracy poddano analizie różne scenariusze testowe dla ruchu jednostajnego oraz jednostajnie przyspieszonego. Czasy poszczególnych etapów przetwarzania zostały pozyskane na tym samym komputerze klasy PC (6 rdzeni z taktowaniem do 3,6 GHz, 32 GB pamięci operacyjnej) co umożliwią ich równoczesne wzajemne porównanie.

Należy podkreślić, że postawione cele w niniejszej rozprawie są wynikiem współpracy z branżą motoryzacyjną oraz konsultacji przeprowadzonych ze specjalistami zaangażowanymi w projekty z sektora motoryzacyjnego i przemysłowego, a otrzymane rezultaty badań są odpowiedzią na wskazane problemy.

Niniejsza praca została zorganizowana w następujący sposób. W rozdziale 2 przedstawiono systemy i technologie wykorzystywane do pozycjonowania obiektów, zaproponowano system pozycjonowania kooperacyjnego oraz opis wykorzystanych w nim systemów z wyróżnieniem ich wad oraz zalet. Przeanalizowano również wskaźniki efektywności, które wykorzystywane są podczas oceny systemów pozwalających na wyznaczenie pozycji obiektu w wybranym zastosowaniu. Wskazano różnice pomiędzy lokalnym i globalnym układem odniesienia oraz przeanalizowano metody pozyskiwania wartości referencyjnych, które stosowane są podczas wyznaczania dokładności badanego systemu. Przeanalizowane zostały najpopularniejsze techniki wymiarowania, w szczególności te wykorzystujące czas przelotu sygnału jak również metody trilateracji, które umożliwiają wyznaczenie pozycji obiektu wykorzystując zebrane odległości pomiędzy obiektem lokalizowanym a punktami referencyjnymi. W rozdziale 3 opracowano symulator systemu UWB, który odzwierciedla pracę rzeczywistego systemu bazującego na technologii UWB. Zaproponowano metodę analizy danych z systemu rzeczywistego oraz metodę odwzorowania pracy systemu w warunkach symulacyjnych. Zaproponowano również sposób definiowania ścieżki referencyjnej. W rozdziale 4 zaproponowano procedurę analizy pozyskanych danych, która umożliwi wyznaczenie pozycji obiektu. Zaproponowano zastosowanie filtru Kalmana oraz sieci neuronowej do zagadnienia filtracji, pozycjonowania i predykcji pozycji. Przeanalizowano błędy występujące w procesie wymiarowania oraz zaproponowano sposoby redukcji ich wpływu na proces trilateracji. Przeanalizowano również wpływ liczby dostępnych odległości na proces trilateracji w zależności

od zastosowanej metody. Poddano analizie czasy wykonywania poszczególnych etapów procesu pozyskiwania pozycji i jej predykcji oraz zaproponowano obszar bezpieczeństwa w zależności od typu obiektu będącego w ruchu. W rozdziale 5 zawarto wnioski końcowe, efekty końcowe niniejszej rozprawy oraz nakreślono kierunek kontynuacji badań w kontekście pozycjonowania.

2 Pozycjonowanie obiektów

Pozycjonowanie obiektów odgrywa kluczową rolę zarówno w skali globalnej (w globalnym układzie odniesienia – kula ziemską) jak i lokalnej (w lokalnym układzie odniesienia obejmującym ograniczony obszar np. plac manewrowy, skrzyżowanie, hala magazynowa). Informacja o pozycji w lokalnym systemie odniesienia może być przekonwertowana i naniesiona np. na schemat budynku hali, czy mapę miejscowości, co pozwala na lokalizację obiektów w szerszym ujęciu. Systemy i technologie pozwalające na wyznaczenie pozycji obiektu różnią się od siebie i mają swoje zalety i wady, gdzie wady jednej technologii należy wyeliminować przez zalety drugiej (w tym zadaniu pomocne są wskaźniki efektywności) lub przez odpowiednią analizę otrzymywanych danych. Dane z różnych systemów są łączone w celu polepszenia np. dokładności, pokrycia, czy częstotliwości lub też formują pozycjonowanie kooperacyjne (*ang. cooperative positioning*), które pozwala na wymianę informacji pomiędzy różnymi systemami, ich integrację oraz wykorzystanie najlepszych z systemów na danym obszarze lub w danym czasie.

W literaturze wyróżnia się następujące wskaźniki efektywności do oceny systemów pozycjonowania wewnątrz pomieszczeń (IPS – *ang. indoor positioning system*) – te same wskaźniki można odnieść to systemów stosowanych na zewnątrz budynków (OPS – *ang. outdoor positioning system*) [31], [34]–[37]:

- dokładność (*ang. accuracy*) – mówi o tym jak bardzo wartość zmierzona różni się od wartości referencyjnej. Do wyznaczenia różnicy (błędu) pomiędzy pozycją referencyjną a pozycją zmierzoną stosuje się metrykę euklidesową. Najczęściej stosowane miary to: średni błąd bezwzględny, pierwiastek średniej kwadratowej błędów (RMSE – *ang. root mean square error*), błąd średniokwadratowy (MSE – *ang. mean squared error*);
- precyzja (*ang. precision*) – określa powtarzalność pomiarów i ich rozrzut (koncentrację pomiarów). Wskaźnik ten wymaga wielu próbek zebranych w takich samych warunkach np.: wielokrotny pomiar odległości bez zmiany pozycji obiektów biorących udział w pomiarze. Najczęściej wykorzystywane miary to odchylenie standardowe (SD – *ang. standard deviation*), względne odchylenie standardowe (RSD – *ang. relative standard deviation*) oraz ogólny (geometryczny) współczynnik geometrycznej dokładności (GDOP – *ang. geometrical dilution of precision*);
- dostępność (*ang. availability*) – określa w jakim procencie czasu usługa (system) pozycjonowania jest dostępny biorąc pod uwagę pożądaną dokładność;

- pokrycie (*ang. coverage*) – obszar, który pokryty jest przez system i determinowany jest przez zasięg danego systemu pozycjonowania. Wyróżnia się trzy stopnie pokrycia: lokalne (obszar działania systemu jest ściśle zdefiniowany i niezmienny), skalowalne (obszar działania systemu może być zwiększony) i globalne (system dostępny jest na całym świecie);
- złożoność (*ang. complexity*) – zróżnicowany wskaźnik efektywności, który może brać pod uwagę złożoność sprzętową lub oprogramowania oraz czynniki o charakterze operacyjnym (*ang. operation factors*);
- stabilność (*ang. robustness*) – wskaźnik mówiący o odporności systemu na problemy wynikające z komunikacji lub zakłóceń, np. system działa normalnie nawet gdy część punktów referencyjnych nie bierze udziału w komunikacji (brak zasięgu, sygnał zaszumiony, niepełne dane);
- skalowalność (*ang. scalability*) – określa zdolność systemu pozycjonowania do skalowania (zwiększania) w jednym z wymiarów (liczba obsługiwanych obiektów lub obszaru działania) jednocześnie zapewniając poprawność działania;
- koszt (*ang. cost*) – zróżnicowany wskaźnik, który mówi o poniesionych nakładach i może odnosić się do różnych części systemu (np. urządzeń, instalacji, wsparcia, infrastruktury) wyrażany w czasie, pieniądzu, przestrzeni i zapotrzebowaniu na energię;
- prywatność (*ang. privacy*) – określa jak prywatne dane dotyczące użytkowników systemu są chronione, przechowywane i wykorzystywane.

Nie wszystkie wskaźniki muszą być brane pod uwagę jednocześnie, ich wykorzystanie pozwala porównać systemy ze sobą i określić, który jest najbardziej korzystny w danym zastosowaniu. Przykładem pozycjonowania kooperacyjnego jest system składający się z UWB, IMU/AHRS i GPS. Poniżej przedstawiono niektóre wskaźniki efektywności w odniesieniu do zastosowanych technologii:

- UWB – system ten cechuje się dużą dokładnością oraz precyzją pomiarów w pozycjonowaniu statycznym, dostępność systemu określa się na średnim poziomie i zależy od prędkości poruszającego się obiektu, stopień pokrycia jest lokalny (z ograniczoną możliwością skalowania), stabilność systemu jest duża przy zapewnieniu ograniczeń wynikających z metod wyznaczania pozycji 2D/3D, koszt systemu jest relatywnie niski (niski koszt modułów), jednakże wymagana jest dodatkowa infrastruktura.


- IMU/AHRS – system pozycjonowania wykorzystujący IMU/AHRS cechuje się ograniczoną w czasie dokładnością ze względu na kumulację błędów w czasie, jednakże niewątpliwą zaletą tego systemu jest częstotliwość pozyskiwania danych, pokrycie globalne (z uwagi na brak zewnętrznej infrastruktury), niski koszt.
- GPS – system ten pełni ważną rolę w pozycjonowaniu kooperacyjnym z uwagi na globalne pokrycie. Dokładność, precyzja i stabilność są niskie na terenach o zwartej zabudowie oraz wewnątrz budynków, jednakże koszt modułów jest niski.

Powyższych systemów nie analizowano pod kątem złożoności, skalowalności i prywatności. Do pozycjonowania kooperacyjnego obiektów nie jest wykorzystywana tylko jedna technologia, a dzięki temu wady jednej technologii mogą być kompensowane przez zalety innej np. system o niskiej częstotliwości pozyskiwania danych, ale dużej dokładności, może być uzupełniony przez system o wysokiej częstotliwości pozyskiwania danych, ale za to niższej dokładności.

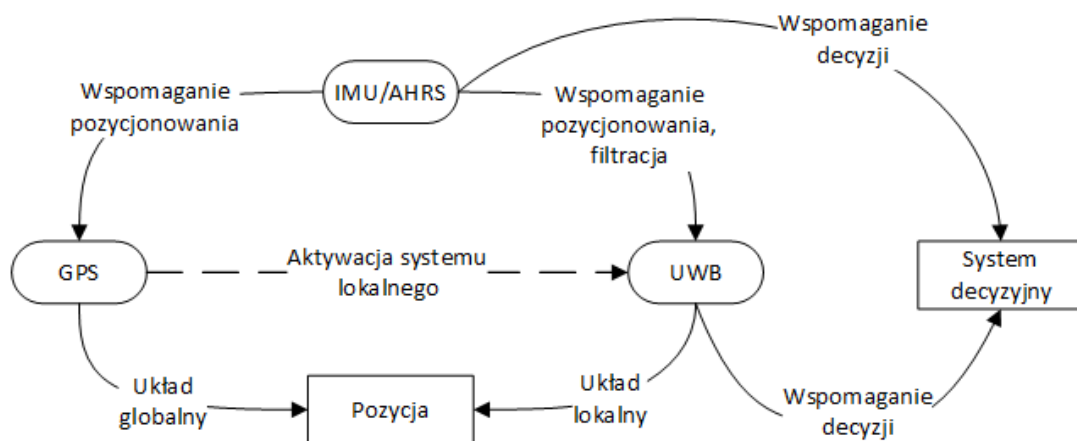
Fuzja danych z różnych systemów powinna zwiększyć dokładność pozyskiwanych informacji przy jednoczesnym zapewnieniu ciągłości dostarczania pozycji obiektu, który nie posiada kompletu informacji ze wszystkich podsystemów [38], [39]. Chwilowy brak pozycji z jednego systemu (UWB) nie może zakłócić jego pracy, tak więc predykcja pozycji obiektu na podstawie danych historycznych i danych aktualnych z pozostałych podsystemów (IMU/AHRS) powinna sprostać tym wymaganiom. Każdy z systemów odgrywa ważną rolę, a ich zalety oraz odpowiedni proces przetwarzania danych pozwalają na osiągnięcie celu jakim jest wyznaczenie pozycji w newralgicznych punktach infrastruktury drogowej (patrz rys. 1).

Proces pozycjonowania i podejmowania decyzji jest wieloetapowy i angażuje dane z systemów pozycjonowania oraz danych z ich analizy (rys. 2). W przedstawionym systemie pozycjonowania kooperacyjnego pojazd pozycjonowany jest z wykorzystaniem systemu GPS, który pozwala określić przybliżoną pozycję obiektu w globalnym układzie odniesienia i podczas zbliżania się do obszaru, który jest krytyczny pod względem zapewnienia bezpieczeństwa i płynności ruchu obiektów oraz pozwala uaktywnić system UWB. Znając przybliżoną lokalizację, obiekt posiada informacje o infrastrukturze UWB, która będzie wykorzystana w celu zwiększenia dokładności wyznaczonej pozycji na ograniczonym obszarze. System GPS w dalszym ciągu pełni ważną rolę, ponieważ wykorzystywany jest do wyznaczenia pozycji części punktów referencyjnych systemu UWB tak aby możliwa była konwersja pozycji z lokalnego systemu odniesienia do globalnego układu odniesienia. System UWB wykorzystywany jest do wyznaczania pozycji obiektu w lokalnym układzie odniesienia, na ograniczonym obszarze, na

zewnątrz budynku lub wewnątrz budynku, tak więc jego zastosowanie jest wszechstronne, jednakże z uwagi na charakter procesu wyznaczania pozycji (wielokrotna wymiana komunikatów pomiędzy węzłami) system ten dla obiektów będących w ruchu wprowadza przesunięcia od pozycji aktualnej. Sensory inercyjne wspomagają zarówno pracę systemu GPS jak i systemu UWB. Nawigacja inercyjna z uwagi na niezależność od infrastruktury pozwala zachować ciągłość pozycjonowania przy chwilowych zanikach danych z systemu GPS czy UWB. Umożliwia również zwiększenie częstości pozyskiwania danych dotyczących pozycji pomiędzy kolejnymi odczytami z systemu dostarczającego pozycje bezwzględną. Ponadto, dane z sensorów inercyjnych mogą być wykorzystywane w procesie analizy danych do wyboru odpowiednich metod filtracji, czy też jako składowa do podejmowania decyzji o wyborze ścieżki rzeczywistej lub ścieżki predykowanej.



Rys. 1. Przykładowy system pozycjonowania kooperacyjnego



Rys. 2. Oddziaływanie poszczególnych elementów systemu na proces wyznaczania pozycji

W efekcie końcowym informacja o pozycji może być wykorzystana na wiele różnych sposobów, od dostarczania informacji o innych poruszających się uczestnikach ruchu i elementach infrastruktury w najbliższym otoczeniu, jak również możliwych sytuacjach niebezpiecznych, po informacje związane z danym obszarem (np. obowiązujące ograniczenie prędkości, najbliższa stacja ładowania).

W niniejszej pracy w kontekście pozycjonowania obiektów będących w ruchu wyróżnia się następujące terminy:

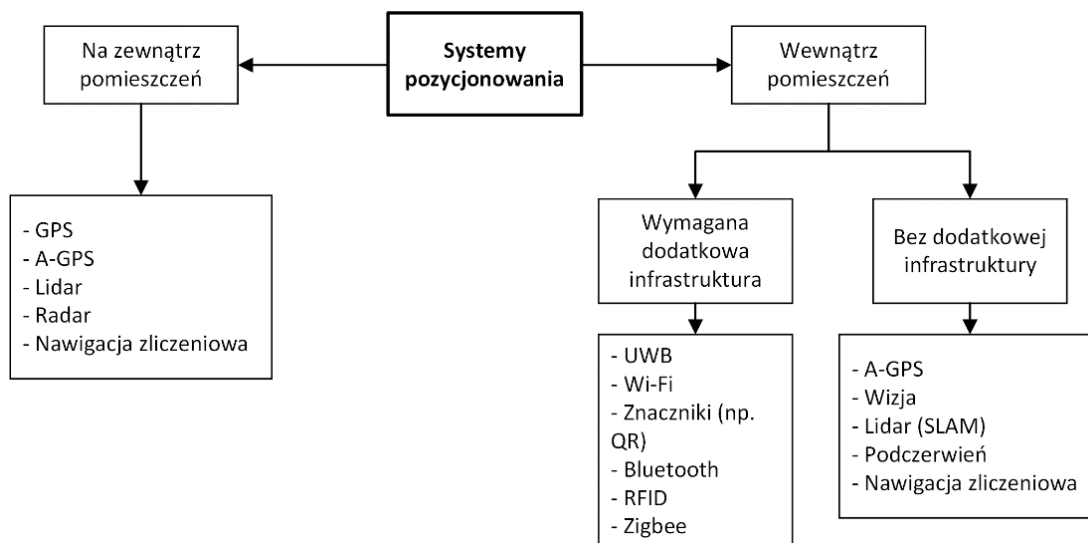
- **Pozycja obiektu** (np. pojazdu) to miejsce, w którym znajduje się obiekt na płaszczyźnie lub w przestrzeni, wyznaczone na podstawie odległości od znanych punktów referencyjnych. Pozycja obiektu może być wyznaczona w lokalnym lub globalnym systemie odniesienia w zależności od zastosowanej technologii, czy też stawianych wymagań co do wykorzystywanego systemu. W niniejszej pracy punktami referencyjnymi są kotwice wykorzystujące technologię UWB do pomiaru czasu przelotu sygnału pomiędzy węzłami (co przekłada się na odległość pomiędzy nimi) w zdefiniowanej sieci w lokalnym układzie odniesienia.
- **Pozycja predykowana** to następna pozycja obiektu, w której powinien znaleźć się poruszający się obiekt na podstawie posiadanych informacji o jego ruchu (np.: przyspieszeniu, prędkości) i wcześniejszej bezwzględnej pozycji w lokalnym lub globalnym systemie odniesienia.
- **Predykcja pozycji** to proces, w którym estymowana jest pozycja następna obiektu będącego w ruchu. Do predykcji pozycji wykorzystywane są dane historyczne z poprzednich odczytów z systemu UWB oraz dane aktualne, które nie pozwalają na bezwzględne wyznaczenie pozycji – dane z IMU/AHRS. Predykcja może obejmować krótki przedział czasu (np. predykcja jednej pozycji w systemie dostarczającym dane co 12 ms będzie dotyczyła pozycji, którą obiekt powinien osiągnąć w czasie 12 ms) lub też predykcja może być długoterminowa (np. predykcja 10 pozycji, co dla wyżej wymienionego czasu pozyskiwania danych będzie dotyczyła pozycji, które obiekt powinien osiągnąć w czasie 120 ms).
- **Ścieżka** to zbiór punktów (pozycji) wraz z czasem ich wystąpienia, po których porusza się obiekt. Ścieżka może obejmować punkty wyznaczone wykorzystując aktualne informacje o bezwzględnej pozycji obiektu – systemu UWB (**ścieżka aktualna**) lub informacje pozyskane w procesie predykcji pozycji (**ścieżka predykowana**). Z kolei

ścieżka referencyjna to zbiór punktów na trasie przejazdu obiektu, które uznawane są za prawdziwe – charakteryzują się dużą dokładnością. Pozycje referencyjne wykorzystywane są jako odniesienie podczas wyznaczania statystyk błędu w wyznaczonej pozycji z systemów pozycjonowania.

- **Wybór ścieżki** to proces, w którym podejmowana jest decyzja czy powinny być wykorzystywane pozycje pozyskane z danych aktualnych, czy też powinna być wykorzystywana predykcja pozycji na podstawie informacji o dostępnych podsystemach pozwalających na wyznaczenie pozycji obiektu, prędkości obiektu i przyspieszenia.

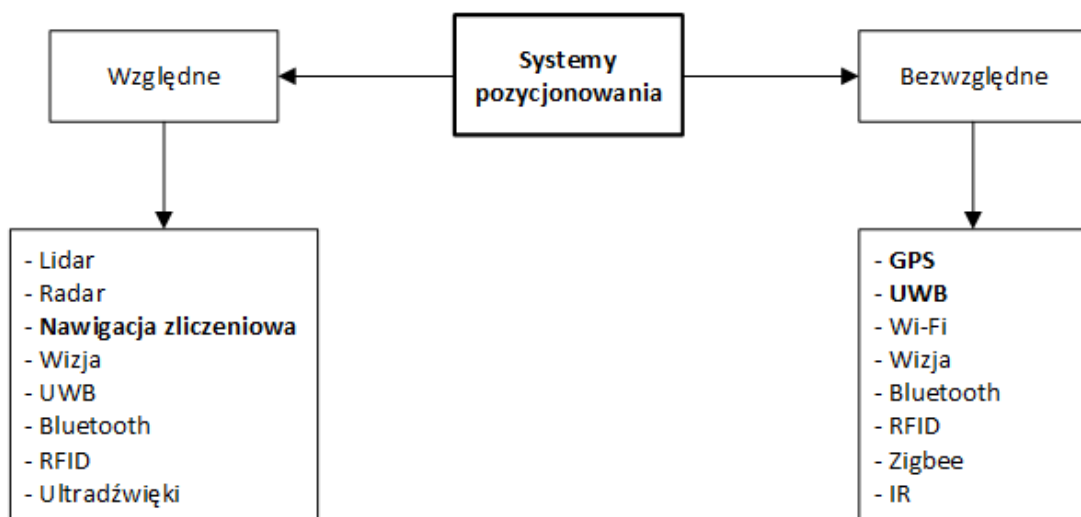
2.1 Systemy pozycjonowania

Stosowane są różne podziały systemów pozwalających na wyznaczenie pozycji obiektu, ale tym najbardziej fundamentalnym jest podział na systemy, technologie do pozycjonowania wewnątrz (*ang. indoor*) i na zewnątrz (*ang. outdoor*) budynków (patrz rys. 3). Do systemów pozycjonowania wewnątrz budynków zaliczamy te wykorzystujące m. in.: WLAN (*ang. wireless local area network*), Bluetooth, DECT (*ang. digital enhanced cordless telephony*), ZigBee, RFID (*ang. radio-frequency identification*), UWB, IR (*ang. infrared*), ultradźwięki, systemy inercyjne, nawigacja zliczeniowa, systemy wizyjne, pseudosatelity. Jednakże nic nie stoi na przeszkodzie (pamiętając o ograniczeniach każdej z technologii), aby systemy te wykorzystać do pozycjonowania na zewnątrz budynków. Systemy wykorzystywane do pozycjonowania na zewnątrz budynków to m.in. GPS, A-GPS (*ang. assisted global positioning system*), GSM (*ang. global system for mobile communications*) [34], [35], [40]–[42].



Rys. 3. Podział systemów pozycjonowania ze względu na obszar zastosowania

Technologie wykorzystywane w pojazdach do wyznaczania pozycji obiektu oraz percepcji otoczenia różnią się np. zasięgiem systemu, kosztem, niedziałaniem w określonych warunkach (np. pogodowych, wewnątrz pomieszczeń). Przykładowe technologie szeroko już stosowane w autonomicznych pojazdach czy AGV to: lidar, radar, GPS, nawigacja zliczeniowa i nawigacja inercyjna bazująca na sensorach MEMS (*ang. microelectromechanical system*), ultradźwięki, czy analiza obrazu. Systemy te można podzielić również ze względu na sposób w jaki wyznaczana jest pozycja: bezpośrednie i pośrednie (patrz rys. 4). Jak można zauważyć część systemów zalicza się do obu grup z uwagi na możliwe różne ich wykorzystanie np. systemy wizyjne, które są częścią infrastruktury obszaru, po którym porusza się obiekt mogą wyznaczać bezwzględną jego pozycję, natomiast zastosowane w pojeździe odpowiedzialne są za percepcję otoczenia i tym samym oszacowanie pozycji obiektu na podstawie obrazu w stosunku do innych obiektów na scenie. Innym przykładem jest system UWB, który można wykorzystać do bezwzględnego wyznaczenia pozycji obiektu na obszarze zdefiniowanym przez węzły stacjonarne lub też system ten można wykorzystać do oceny odległości do zbliżającego się obiektu. Informacje z wielu podsystemów pozwalają analizować obszar w bezpośrednim otoczeniu poruszającego się pojazdu, na większych odległościach oraz wyznaczyć jego pozycję w globalnym albo lokalnym systemie odniesienia lub w stosunku do innych obiektów otaczających.



Rys. 4. Podział systemów pozycjonowania ze względu na sposób wyznaczonej pozycji

Zastosowane w pojazdach (w pełni lub częściowo) autonomicznych, czy wózkach samojezdnych systemy pozycjonowania tworzą system cyberfizyczny (CPS – *ang. cyber physical systems*), który na podstawie danych z różnych urządzeń i podsystemów w pojeździe podejmuje za człowieka decyzję lub dostarcza informacji i wskazówek, które ułatwiają podjęcie decyzji przez kierowcę, czy operatora. Systemy cyberfizyczne wykorzystywane były już we wczesnych

systemach wbudowanych branży motoryzacyjnej [43] – nie tylko w pojazdach autonomicznych, AGV czy zdalnie sterowanych. CPS łączą część obliczeniową (*ang. cyber*) oraz część fizyczną (*ang. physical*) systemów wbudowanych. Obydwie części oddziałują na siebie: część obliczeniowa odpowiada za sterowanie pewnym procesem (czyli częścią fizyczną np.: układem hamulcowym pojazdu, przyspieszeniem pojazdu), natomiast część fizyczna dostarcza informację zwrotną do systemu, która może wpłynąć na jego dalsze decyzje (np.: zablokowanie kół, zbyt bogata mieszanka paliwa) [44].

Pojazdy (w pełni lub częściowo) autonomiczne należą do systemów krytycznych dla bezpieczeństwa, ponieważ ich awaria lub błędna decyzja systemów pokładowych może doprowadzić do tragicznego w skutkach zdarzenia [45]. Aby bezpieczeństwo uczestników ruchu zostało zapewnione, wykorzystywane w pojazdach systemy muszą się uzupełniać w trakcie realizacji zamierzonego celu (np. aktywny asystent parkowania bazujący na danych z sensorów ultradźwiękowych i danych z kamery wizyjnej [46]). Znana pozycja obiektów również znacząco przyczyni się do poprawy bezpieczeństwa w ruchu po drodze, czy sektorach magazynowych, przemysłowych. Jednakże należy zapewnić ciągłość w wyznaczaniu pozycji obiektu będącego w ruchu. W tym celu pojazdy powinny być wyposażone nie w jeden, a w kilka systemów umożliwiających wyznaczenie pozycji lub percepcję otoczenia tak, aby niezależnie od warunków proces poruszania się obiektu mógł być nieprzerwanie kontynuowany. Do najczęściej stosowanych systemów, czy technologii w obszarze pojazdów autonomicznych czy wózków samojezdnych m. in. należą:

- Wielowiązkowe lidary oraz radary dalekiego, średniego i krótkiego zasięgu wykorzystywane są w pojazdach głównie w celu detekcji innych uczestników ruchu (np. pieszych, pojazdów) lub elementów infrastruktury (np. barier, słupów, krawężników, czy znaków poziomych) [47], [48]. Dzięki tym urządzeniom pojazdy wyposażone są w takie systemy, które umożliwiają wykrywanie pieszych i unikanie kolizji poprzez awaryjne hamowanie (w sytuacjach, gdy reakcja kierowcy jest zbyt wolna) [49], czy utrzymywanie bezpiecznej odległości pomiędzy pojazdami – adaptacyjny tempomat [50]. Systemy te wykorzystywane są również do wyznaczenia pozycji obiektu korzystając z metody SLAM (*ang. simultaneous localization and mapping*) [51], [52].
- Analiza wideo pozwala na wyznaczenie pozycji pojazdu wykorzystując technikę SLAM nie tylko w budynkach [53], ale również w środowisku miejskim we współpracy z GPS [54]. Analiza wideo pozwala na obserwowanie bezpośredniego otoczenia obiektu [55], [56]. Odpowiedzialna jest za wykrywanie znaczników czy znaków drogowych [57], [58]

(ich analiza pozwala np. na dostosowanie prędkości do aktualnie obowiązującego limitu prędkości na danym obszarze), wykrywanie pasa ruchu, obiektów w martwym polu, obiektów na drodze ruchu pojazdu, czy też wspomaga kierowcę podczas parkowania (wyświetlając na konsoli obszar znajdujący się za pojazdem lub dookoła pojazdu i informując o przeszkodach) [59]–[61].


- Czujniki ultradźwiękowe skanują najbliższe sąsiedztwo pojazdu, stosowane są głównie w celu wspomaganie kierowcy podczas parkowania ostrzegając o zbliżaniu się do przeszkody [62]. System ten może ostrzegać o obiektach znajdujących się zarówno przed jak i za pojazdem i nic nie stoi na przeszkodzie, aby system ten monitorował również boki pojazdu.

Systemy pozycjonowania wykorzystujące sieć węzłów, które do wyznaczenia pozycji obiektu wykorzystują informacje o kącie natarcia sygnału lub czasie (odległości) przelotu sygnału (fali elektromagnetycznej) pomiędzy węzłami, wymagają kilka punktów odniesienia o znanej pozycji do wyznaczenia pozycji obiektu lokalizowanego. Punkt odniesienia czy też inaczej punkt referencyjny jest to punkt o znanej pozycji w lokalnym lub globalnym systemie odniesienia. Metoda trilateracji wykorzystywana jest w technikach pozycjonowania obiektów wewnątrz i na zewnątrz pomieszczeń. Szeroko stosowana nawigacja satelitarna jest oparta właśnie na trilateracji, gdzie odległości do co najmniej 3 satelitów biorą udział w wyznaczaniu pozycji w globalnym układzie odniesienia. Wyznaczanie pozycji obiektu wewnątrz budynku, korzystając z systemów ultradźwiękowych czy UWB również oparte jest na metodzie trilateracji. Znana pozycja pozwala w dalszym przetwarzaniu informacji rzutować pozycje obiektów na plany budynków czy też mapy.

2.2 Globalny system pozycjonowania

Początki tej technologii sięgają lat 50 XX w., gdzie satelity były śledzone dzięki zjawisku Dopplera. W latach 60 XX w. wojsko Stanów Zjednoczonych rozpoczęło prace nad systemem pozycjonowania do celów militarnych. Już w 1978 r. Departament Obrony Stanów Zjednoczonych uruchomił system NAVSTAR (*ang. navigation system with timing and ranging*), który dostępny był globalnie zarówno do celów militarnych jak i cywilnych. Początkowo dokładność systemu do celów cywilnych była celowo obniżana aż do 2001 r., kiedy ze względów na globalne interesy zaniechano celowego obniżania wydajności sygnałów niewojskowych [63]. Nawigacja GPS pozwala zlokalizować obiekt w globalnym układzie odniesienia. Dokładność systemu opartego na sygnale GPS zależy od pozycji obiektu na kuli ziemskiej. Z uwagi na fakt, że kula ziemską jest geoidą, odległość pomiędzy dwoma stopniami szerokości geograficznej


i dwoma stopniami długości geograficznej zmienia się. Opis geoidy jest skomplikowany przez co istnieje wiele systemów odniesienia, które przybliżają kształt kuli ziemskiej korzystając z elipsoidy. Najczęściej stosowanym przybliżeniem (geodezyjnym układem odniesienia) jest system odniesienia WGS-84 (*ang. World Geodetic System '84*) – światowy system geodezyjny, który wyznacza standardy w kartografii, geodezji i nawigacji satelitarnej wykorzystywany na lądzie oraz do nawigacji w powietrzu [64], [65]. System nawigacji satelitarnej jest jednym z podstawowych systemów OPS wykorzystywanych w pojazdach (patrz rys. 5).



Rys. 5. System nawigacji satelitarnej

Pozycja obiektu z wykorzystaniem różnych technik pozycjonowania może być względna, czyli wyznaczona w stosunku do innych obiektów znajdujących się w pobliżu obiektu pozycjonowanego lub bezwzględna. Pozycja bezwzględna jasno definiuje, gdzie znajduje się obiekt na płaszczyźnie lub w przestrzeni bazując na znanej pozycji punktów referencyjnych – w układzie współrzędnym lokalnym lub globalnym. Lokalny układ odniesienia odnosi się do pozycji obiektu wyznaczonej np. wewnątrz obiektu, czy na małym obszarze. Lokalny układ odniesienia definiowany jest przez punkty referencyjne zlokalizowane na małej przestrzeni przez co też dokładność tych systemów (opartych na technologii np.: UWB, Bluetooth, Wi-Fi) jest często wyższa niż systemu GPS. Z kolei globalny układ odniesienia rozumiany jest przez kulę ziemską, w związku z czym znając pozycję w globalnym układzie odniesienia (przedstawioną jako długość i szerokość geograficzną oraz wysokość) możliwe jest naniesienie jej na mapę świata albo miasta [66]. W razie potrzeby pozycja w lokalnym układzie odniesienia może być przekonwertowana na pozycję w globalnym układzie odniesienia znając koordynaty punktów

referencyjnych (np.: kotwic UWB) w globalnym układzie odniesienia (rys. 6). Konwersja pozycji z jednego układu na drugi jest wykorzystywana w pozycjonowaniu kooperacyjnym, gdzie do pozycjonowania obiektów wykorzystuje się różne systemy w zależności, gdzie dany obiekt się porusza np.: GPS na zewnątrz budynku, a system UWB wewnątrz budynku zapewniając cały czas informację o długości i szerokości geograficznej.



Rys. 6. Globalny a lokalny układ odniesienia

Po skorelowaniu danych o pozycji globalnej z odpowiadającym punktem na mapie można również pozyskać dodatkowe informacje o stałych elementach infrastruktury drogowej (POI – *ang. point of interest*). Jednakże wadą systemu GPS jest niska dokładność w obszarach zurbanizowanych, która związana jest z występowaniem problemu wielotorowości sygnału, zaniku sygnału, czy rozsynchronizowania zegarów pomiędzy nadajnikiem a odbiornikiem.

2.3 Ultra-wideband (UWB)

Systemy ultraszerokopasmowe UWB [67]–[69] stanowią aktualnie realną alternatywę dla systemów GPS w zastosowaniach na ograniczonym obszarze tj. dla lokalnego systemu pozycjonowania. Zdolność systemu UWB do przesyłania informacji z dużą szybkością [70]–[72] oraz do pozycjonowania przy zachowaniu niskich kosztów i niskiego zapotrzebowania na energię czyni go systemem spełniającym wymagania inteligentnych miast – miast przyszłości, jednocześnie nie należy zapomnieć o jego lokalnym zastosowaniu (np. w newralgicznych miejscach infrastruktury). Ponadto koncerny motoryzacyjne, które poniekąd wyznaczają trendy, zainteresowane są tą technologią nie tylko ze względu na możliwość pozycjonowania, ale również ze względu na bezpieczeństwo. Bezkluczkowy dostęp do samochodu (*ang. keyless*) jest coraz częściej spotykaną propozycją oferowaną przez producentów samochodów. Jednakże aktualnie stosowany system nie jest wolny od wad [73]. System do bezprzewodowego otwierania i uruchamiania pojazdów jest w rękach „*Car Connectivity Consortium*”. Konsorcjum to, powołane przez takie firmy jak Apple, GM, Samsung, opracowuje specyfikację ekosystemu, który pozwala na wykorzystanie urządzeń mobilnych do przechowywania, autentykacji

i udostępniania cyfrowych kluczy („Digital Key”). W 2020 roku firma BMW (jako pierwsza firma z branży motoryzacyjnej) udostępniła posiadaczom smartfonów Apple możliwość pełnoprawnego otwarcia i uruchomienia pojazdu za pomocą Digital Key (przechowywany w Apple Wallet) [74]. Wersja 3.0 Digital Key’a integruje BLE (*ang. Bluetooth low energy*) oraz UWB w celu pasywnego bezkluczykowego otwierania i uruchamiania pojazdu (bez wykonywania akcji przez kierowcę), jednocześnie zapewniając pozycjonowanie i tym samym bezpieczeństwo [75]. Co prawda system ten nie jest jeszcze szeroko stosowany przez firmy motoryzacyjne, jednakże nowy kluczyk BMW Digital Key Plus (dla BMW iX) współpracuje już z nowymi produktami firmy Apple, które wyposażane są w moduł UWB (technologia UWB wykorzystywana jest do przesyłania danych pomiędzy urządzeniami oraz do lokalizacji przedmiotów z dołączonymi znacznikami), co świadczy o tym, że technologia UWB w przyszłości będzie szeroko stosowana przez koncerny samochodowe do implementacji pasywnego Digital Key’a [76]. Jako że docelowo system UWB wykorzystywany będzie w systemie bezkluczykowym (zgodnie z mapą drogową) i pojazdy będą wyposażone w moduły UWB (zapewne nie jeden na co wskazują badania prowadzone we współpracy z firmą BMW nad rozmieszczeniem anten UWB w pojazdach [77]) nic nie stoi na przeszkodzie, aby system ten mógł odgrywać również ważną rolę w pozycjonowaniu pojazdów w newralgicznych miejscach infrastruktury, zwiększając tym samym bezpieczeństwo w ruchu, a może przede wszystkim, żeby system ten wykorzystać do komunikacji V2V czy też V2I.

Z uwagi na szereg zalet i możliwych zastosowań system UWB jest coraz częściej wykorzystywany wraz z innymi systemami umożliwiającymi wyznaczenie pozycji obiektu tworząc system pozycjonowania kooperacyjnego. Jednakże cały czas należy pamiętać o ograniczeniach systemu jakimi jest częstość pozyskiwania pozycji, generowanie przesunięć, czy możliwość wystąpienia błędów komunikacji. Autorzy w artykule [32] przedstawiają system wielosensorowy wykorzystujący UWB do pozycjonowania obiektów wewnątrz budynku, gdzie nie dociera sygnał satelitarny (GNSS). Wykorzystują oni pozycjonowanie kooperacyjne, które bazuje na wymianie danych pomiędzy użytkownikami wewnątrz sieci, którą tworzą przy użyciu dwóch systemów UWB (4 węzły dynamiczne – wyposażone dodatkowo w GNSS, Wi-Fi, kamerę oraz sensory inercyjne, i 30 węzłów statycznych). Węzły statyczne (kotwice, punkty referencyjne) i dynamiczne budujące sieć, dystrybuują dane o swoim stanie (pozycji) oraz dane w odniesieniu do sąsiednich węzłów, co pozwala osiągnąć dobrą dokładność pozycjonowania. Zaproponowany system został przetestowany w realnych warunkach – pozycjonowanie pieszych wewnątrz budynku (obiekty poruszające się z niską prędkością). Wymiana danych (proces wymiarowania, wyznaczania odległości) odbywała się zarówno pomiędzy węzłami mobilnymi


(P2P – *ang. peer-to-peer*) oraz pomiędzy węzłami mobilnymi a węzłami statycznymi (P2I – *ang. peer-to-infrastructure*). Ruch lokalizowanego obiektu odbywał się po korytarzu (długie wąskie pomieszczenie, na tym fragmencie ruchu skupili się autorzy), klatce schodowej oraz przed budynkiem. Pozycja obiektu analizowana była w przestrzeni dwuwymiarowej gdzie zastosowano rozszerzony filtr Kalmana. Zbilansowana komunikacja zwiększyła dokładność pozycjonowania, jednakże zauważono, że przy dobrej geometrii systemu, pozycjonowanie kooperacyjne korzystające jedynie z komunikatów wymienianych pomiędzy węzłami mobilnymi a węzłami statycznymi daje lepsze rezultaty. Należy jednak zaznaczyć, że dokładność pozycjonowania przedstawiana przez autorów nie odnosi się do całej ścieżki testowej a do wyznaczonych punktów referencyjnych, które znajdowały się w obszarze korytarza. Dla jednego z węzłów mobilnych w większości punktów referencyjnych RMSE mieścił się w zakresie od 13 cm do 27 cm. Zauważono również wpływ warunków NLOS (*ang. non-line-of-sight*) na wynik wymiarowania, gdzie w niektórych punktach referencyjnych odnotowano spadek dokładności do 71-127 cm. Dla drugiego węzła mobilnego pozycjonowanie kooperacyjne, obejmujące komunikaty P2P i P2I, pozwoliło zwiększyć dokładność o 95% w stosunku do pozycjonowania opartego jedynie na komunikatach P2I. Jednakże duży błąd pozycjonowania wynikał z tego, że obiekt komunikował się jedynie z jednym węzłem statycznym. W takiej sytuacji trudno mówić o pozycji obiektu w płaszczyźnie dwuwymiarowej, jeżeli dysponujemy tylko jedną odległością, a system powinien informować o niedostatecznej liczbie punktów referencyjnych i jego wiarygodność powinna być bardzo mała.

Warunki NLOS często pogarszają dokładność pozycjonowania i są częstym zjawiskiem w budynkach, gdzie infrastruktura i wyposażenie wprowadza wiele przeszkód dla sygnału. Systemy bezprzewodowe korzystające z propagacji fal elektromagnetycznych muszą być dobrze zaprojektowane, aby unikać tego typu scenariuszy. Autorzy [33] proponują rozwiązanie, które odporne jest na warunki NLOS jednakże charakteryzujące się niskim zasięgiem działania – pozycjonowanie bazujące na polu magnetycznym, które generowane jest przez cewki rozmieszczone w budynku, w którym odbywać się ma pozycjonowanie obiektu. W celu zwiększenia pokrycia systemu autorzy korzystają z dodatkowych danych o przyspieszeniu i prędkości kątowej, a do wyznaczenia zmiany wysokości wykorzystują pomiar ciśnienia atmosferycznego (pozycjonowanie w przestrzeni trójwymiarowej). Dane z IMU poddawane są filtracji średnią krocząca natomiast dane z barometru poddawane są filtracji adaptacyjnej. Informacje z systemu inercyjnego są łączone z danymi o polu magnetycznym za pośrednictwem filtra Kalmana. Sztucznie generowane sygnały magnetyczne pozwalają na pozycjonowanie obiektu z dokładnością do 50 cm na odległość 12 m od punktu referencyjnego (cewki). Dane

o polu magnetycznym są poddawane obróbce. Szum o niskiej częstotliwości jest usuwany przez stworzenie (rekonstrukcję) sygnału o znanym wzorze. Natomiast wpływ innych źródeł emitujących pole magnetyczne jest usuwany poprzez zmianę polaryzacji każdej z cewek. Należy zaznaczyć dużą wadę zaproponowanego systemu, do wyznaczenia pozycji obiektu wymagane są ciągłe (nie zmieniające się) sygnały z otaczających mobilny obiekt cewek. W związku z czym, aby poprawnie wyliczyć pozycję obiektu powinien on się zatrzymać i pozostać nieruchomym w fazie wymiarowania. Efekt dryftu można wyeliminować poprzez wykorzystanie metody najmniejszych kwadratów i regresji liniowej, jednakże przy założeniu, że pojazd będzie poruszał się ze stałą prędkością i niezmiennym kierunkiem w czasie przełączania. Autorzy pomiar błędu wyznaczonej pozycji również wykonywali w punktach referencyjnych (13 punktów o znanej pozycji, wykrywane przez poruszającą się platformę za pomocą kamery). W końcowym efekcie fuzja danych pozwoliła osiągnąć dokładność na poziomie 1,5 m na płaszczyźnie.

Na rynku istnieją już komercyjne produkty, które ukierunkowane są na pozycjonowanie obiektów w budynkach (np. Pozyx, DecaWave – patrz rys. 7). Systemy pozycjonowania różnych producentów oparte na technologii UWB (a dokładniej na modułach DW1000) różnią się następującymi parametrami:

- dokładnością wyznaczonej odległości,
- precyzją,
- maksymalną częstością pozyskiwania danych o pozycji,
- zasięgiem.



Rys. 7. Przykładowe systemy UWB z modułami marki DecaWave

Mimo zalet systemu UWB (m.in. dokładności wyznaczanej pozycji statycznej), częstość pozyskiwania informacji o pozycji jest zależna od liczby pozycjonowanych obiektów i może okazać się zbyt niska podczas pozycjonowania obiektów będących w ruchu (szczególnie z dużymi szybkościami). Ruch obiektu powoduje również, że wyznaczona pozycja odnosi się do pozycji obiektu z przeszłości. W zależności od prędkości obiektu generowane jest przesunięcie, które wymaga minimalizacji. W tym celu proponuje się predykcję pozycji obiektu, która jednocześnie minimalizować powinna wpływ chwilowych braków danych z systemu UWB.


2.3.1 Techniki wymiarowania

Odległość pomiędzy dwoma węzłami może być wyznaczana korzystając z różnych technik wymiarowania:

- a. ToA (*ang. time of arrival*) – jest to klasyczna metoda wymiarowania, która bierze za podstawę czas, w którym wiadomość wysłana z jednego węzła w sieci, jest odebrana przez węzeł odbiorczy. Metoda ta wykorzystuje dwa główne schematy wymiany wiadomości OWR (*ang. one-way ranging*) oraz TWR (*ang. two-way ranging*) [78], [79].
 - OWR – jest najprostszą i najszybszą metodą wyznaczania czasu przelotu sygnału ToF (*ang. time of flight*), ponieważ opiera się jedynie na przesłaniu jednej wiadomości pomiędzy znacznikiem a kotwicą (patrz rys. 8). W tym modelu wymiany, wyznaczony ToF znajduje się po stronie odbiorcy wiadomości. Metoda ta wymaga synchronizacji zegarów pomiędzy węzłami w sieci, aby można było wyznaczyć różnicę czasu pomiędzy wysłaniem wiadomości (znacznik czasu wysłania umieszczony jest w wiadomości) na jednym węźle a odbiorem tej samej wiadomości na innym węźle w sieci. Wadą tej metody jest dokładność wyznaczanego ToF (i tym samym odległości), który obarczony jest błędem wynikającym z rozsynchronizowania zegarów pomiędzy węzłami oraz z dokładności zastosowanych zegarów. Czas przelotu sygnału obliczany jest według wzoru (1).

$$t_{ToF} = t_{BRx} - t_{ATx} \quad (1)$$

gdzie: t_{ATx} – czas wysłania ramki; t_{BRx} – czas otrzymania ramki.




Rys. 8. Schemat wymiany OWR

- TWR – metoda ta znajduje zastosowanie wszędzie tam, gdzie nie jest zapewniona synchronizacja zegarów pomiędzy węzłami biorącymi udział w wymianie wiadomości. Bazuje na czasie, który jest wymagany na przesłanie wiadomości od nadawcy do odbiorcy i z powrotem (RTT – *ang. round trip time*) oraz czasie, który jest wymagany na przygotowanie odpowiedzi na otrzymaną wiadomość. Technika ta minimalizuje wpływ błędów zegarów, ponieważ RTT i czas potrzebny na wysłanie wiadomości jest obliczany niezależnie pomiędzy węzłami, co wpływa na dokładność wyznaczonej odległości. Metoda ta posiada kilka odmian: SS-TWR (*ang. single-sided two-way ranging*), SDS-TWR (*ang. symmetrical double-sided two-way ranging*) oraz ADS-TWR (*ang. asymmetrical double-sided two-way ranging*).

SS-TWR jest najprostszą implementacją techniki TWR, bazuje ona na wymianie dwóch wiadomości (patrz rys. 9) i wykorzystuje czas, który jest wymagany na przesłanie wiadomości od nadawcy do odbiorcy i z powrotem do węzła inicjującego wymiarowanie i czas potrzebny na wysłanie odpowiedzi z drugiego z węzłów (2). Po zakończeniu wymiarowania ToF znajduje się po stronie węzła inicjującego.

$$t_{ToF} = \frac{t_{ARTT} - t_{Breply}}{2} \quad (2)$$

gdzie: t_{ARTT} – czas od wysłania ramki z węzła A do otrzymania odpowiedzi z węzła B; t_{Breply} – czas od otrzymania ramki z węzła A do wysłania odpowiedzi do węzła A.



Rys. 9. Schemat wymiany SS-TWR

SDS-TWR (*ang. symmetrical double-sided two-way ranging*) wprowadza do procesu wymiarowania dodatkową wiadomość (patrz rys. 10) przez co końcowa wartość ToF wynika z uśrednienia trzech pomiarów co przekłada się na zwiększenie dokładności i stabilność (powtarzalność) otrzymywanych rezultatów. ToF obliczany jest zgodnie ze wzorem (3) zakładając, że czasy odpowiedzi dla obydwóch węzłów są równe i stałe (4). Po zakończeniu wymiarowania informację o ToF posiada węzeł odpowiadający.


$$t_{ToF} = \frac{t_{ARTT} - t_{Breply} + t_{BRTT} - t_{Areply}}{4} \quad (3)$$

$$t_{Areply} = t_{Breply} = const \quad (4)$$

gdzie: t_{ARTT} – czas od wysłania ramki z węzła A do otrzymania odpowiedzi z węzła B; t_{Areply} – czas od otrzymania ramki z węzła B do wysłania odpowiedzi do węzła B; t_{BRTT} – czas od wysłania ramki z węzła B do otrzymania odpowiedzi z węzła A; t_{Breply} – czas od otrzymania ramki z węzła A do wysłania odpowiedzi do węzła A.

ADS-TWR (*ang. asymmetrical double-sided two-way ranging*) jest modyfikacją techniki SDS-TWR, która zapewnia mały błąd w sytuacji, gdy nie jest zachowana zależność (4). ToF obliczane jest ze wzoru (5).

$$t_{ToF} = \frac{t_{ARTT} \cdot t_{BRTT} - t_{Areply} \cdot t_{Breply}}{t_{ARTT} + t_{BRTT} + t_{Areply} + t_{Breply}} \quad (5)$$



Rys. 10. Schemat wymiany SDS-TWR/ADS-TWR

- b. TDoA (*ang. time difference of arrival*) – jest to metoda, która bazuje na różnicy czasów otrzymania wiadomości. Jest realizowana w wersji pasywnej, w której to kotwice wysyłają wiadomości i na podstawie różnic czasów ich otrzymania znacznik może wyznaczyć pozycję oraz wersji aktywnej, w której to znacznik wysyła wiadomość i na podstawie różnicy czasów otrzymania tej wiadomości przez kotwice wyznaczana jest pozycja znacznika inicjującego połączenie. Metoda ta wykorzystuje wymianę wiadomości typu OWR przez co wymagana jest synchronizacja czasu na wszystkich węzłach biorących udział w wymiarowaniu.
- c. AoA (*ang. angle of arrival*) – metoda, która bazuje na kącie, pod którym sygnał dotarł do węzła. W tej metodzie wymagany jest szereg antenowy (*ang. antenna array*), który pozwoli na wyznaczenie kierunku natarcia sygnału, na podstawie różnicy czasu otrzymania sygnału przez poszczególne anteny w szeregu. Szereg antenowy wpływa negatywnie na cenę oraz wielkość urządzenia.
- d. RSS (*ang. received signal strength*) – metoda, w której do wyznaczenia odległości pomiędzy dwoma węzłami w sieci wykorzystuje się informacje o mocy odebranego sygnału. Metoda ta wykorzystywana jest m.in. do pozycjonowania obiektów wewnątrz budynków wykorzystując infrastrukturę bezprzewodową sieci lokalnej. Wykorzystywana jest zależność pomiędzy odległością a siłą odbieranego sygnału, czyli wykorzystywany jest model tłumienia sygnału w przestrzeni (6) (FSPL – *ang. free-space path loss*, tłumienie wolnej przestrzeni). Znając moc sygnału – mierzoną w [dB], w odległości referencyjnej oraz współczynnik odległościowy zaniku mocy – dobierany eksperymentalnie w zależności od środowiska (zwykle od 2 do 6), można na podstawie aktualnie zmierzonej wartości mocy sygnału wyznaczyć przybliżoną

odległość obiektu od punktu dostępowego (7). Metoda ta jest jednak niedokładna z uwagi na niedoskonałość modelu, czy zmieniającą się siłę (moc) sygnału nadajnika.

$$RSS = RSS_0 - 10\eta \cdot \log_{10} \frac{d}{d_0} \quad (6)$$

$$d = d_0 \cdot 10^{\frac{RSS - RSS_0}{10\eta}} \quad (7)$$

gdzie: d_0 – odległość, w której wykonano referencyjny pomiar siły sygnału (zwykle w odległości 1 m); RSS_0 – moc sygnału w odległości referencyjnej; η – współczynnik odległościowy zaniku mocy; RSS – aktualna moc sygnału.


2.3.2 Wyznaczanie pozycji obiektu

Korzystając z systemu UWB, w procesie wymiarowania wyznaczone są odległości pomiędzy węzłami w sieci (patrz rys. 11), które w procesie trilateracji umożliwiają wyznaczenie pozycji obiektu. Do wyznaczenia pozycji obiektu na płaszczyźnie dwuwymiarowej (2D – *ang. two-dimensional*) potrzebne są minimum 3 punkty odniesienia natomiast do wyznaczenia pozycji w przestrzeni trójwymiarowej (3D – *ang. three-dimensional*) wymagane są co najmniej 4 punkty odniesienia [42], [80].

Odległość pomiędzy węzłami w systemie UWB wyznaczana jest na podstawie czasu przelotu sygnału (ToF) od nadajnika do odbiornika korzystając z wzoru (8) znając prędkość rozchodzenia się fali w próżni c . Dokładniej ujmując wyznaczone są odległości pomiędzy obiektem pozycjonowanym (znacznikiem) a punktami referencyjnym (kotwicami), tworzącymi infrastrukturę, sieć punktów stacjonarnych, będącymi w zasięgu znacznika, które następnie wykorzystywane są w procesie trilateracji.


$$d = t_{ToF} \cdot c \quad (8)$$

gdzie: t_{ToF} – czas przelotu sygnału pomiędzy dwoma węzłami; c – prędkość rozchodzenia się fali elektromagnetycznej w próżni.



Rys. 11. Sieć węzłów w sieci UWB

Trilateracja jest procesem, w którym wyznaczana jest pozycja obiektu – oczekuje się jednego punktu, pozycji obiektu na płaszczyźnie lub w przestrzeni (2D/3D) (patrz rys. 12). W idealnym przypadku wyznaczone okręgi, sfery, o środku w węźle referencyjnym i promieniu równemu odległości pomiędzy pozycjonowanym obiektem a poszczególnymi punktami referencyjnymi, mają jeden punkt wspólny. W takim przypadku wyznaczenie punktu przecięcia okręgów (pozycji) sprowadza się do rozwiązania układu trzech równań okręgu. Można stwierdzić, że sytuacja tego typu jest niespotykana, a najczęściej występujący przypadek to obszar lub przestrzeń. Związane jest to z dokładnością wyznaczanego czasu, na który ma wpływ wiele czynników takich jak rozsynchronizowanie zegarów, różna dokładność zastosowanych zegarów, czy też sama konfiguracja systemu (opóźnień). Błąd w wyznaczonym czasie przelotu sygnału wpływa bezpośrednio na wyznaczaną odległość, która w efekcie może charakteryzować się przeszacowaniem lub niedoszacowaniem. Patrząc na system oparty na technologii UWB, gdzie czasy przesyłanych impulsów są bardzo małe, niewielki błąd w wyznaczonym czasie rzędu 1 ns generuje błąd 30 cm w wyznaczonym dystansie [81, s. 226].



Rys. 12. Idealny przypadek wymiarowania, w którym okręgi mają jeden punkt wspólny

Otrzymane odległości pomiędzy obiektem pozycjonowanym a punktami referencyjnymi pozwalają na wyznaczenie pozycji w globalnym lub lokalnym układzie odniesienia. Z uwagi na fakt, że przypadek idealny jest niespotykany problem sprowadza się do poszukiwania pozycji, dla której błąd będzie możliwie najmniejszy. Metody trilateracji są w dalszym ciągu rozwijane i ulepszone, aby osiągnąć pożądaną dokładność wyznaczanej pozycji [80], [82]–[84]. Do estymacji pozycji można wykorzystać metodę najmniejszych kwadratów linearyzując wykorzystywany układ równań [85]. Metoda ta minimalizuje sumę błędów, które otrzymywane są przy rozwiązywaniu każdego z równań. Metoda ta wymaga, aby równań było więcej niż

niewiadomych w związku z czym potrzebne są co najmniej 3 odległości do określenia pozycji na płaszczyźnie oraz 4 odległości do wyznaczenia pozycji w przestrzeni (9). Dokonując linearyzacji równania przez wybór jednego z punktów referencyjnych (dla omawianego przykładu będzie to węzeł pierwszy), po odpowiednich przekształceniach i uszeregowaniu składników równania otrzymywana jest postać (10) i (11) – odpowiednio dla lewej i prawej strony równania. W celu zmniejszenia liczby każdorazowo wykonywanych operacji – tym samym skracając czas na wyznaczenie pozycji, można wyznaczyć kwadrat odległości od środka lokalnego układu współrzędnych dla każdego z punktów referencyjnych (12). Końcowe równanie z kolei przekształca do postaci macierzowej (13). Tak przygotowane równanie rozwiązuje się korzystając z algebry liniowej (14,15) – metody najmniejszych kwadratów.

$$\begin{cases} (x - x_1)^2 + (y - y_1)^2 + (z - z_1)^2 = d_1^2 \\ (x - x_2)^2 + (y - y_2)^2 + (z - z_2)^2 = d_2^2 \\ \vdots \\ (x - x_n)^2 + (y - y_n)^2 + (z - z_n)^2 = d_n^2 \end{cases} \quad (9)$$

gdzie: x_i, y_i, z_i – pozycja i -tego punktu referencyjnego; d_i – odległość pomiędzy i -tym punktem referencyjnym a obiektem.

$$L = \begin{cases} -2x(x_1 + x_2) - 2y(y_1 + y_2) - 2z(z_1 + z_2) \\ -2x(x_1 + x_3) - 2y(y_1 + y_3) - 2z(z_1 + z_3) \\ \vdots \\ -2x(x_1 + x_n) - 2y(y_1 + y_n) - 2z(z_1 + z_n) \end{cases} \quad (10)$$

$$P = \begin{cases} d_1^2 - d_2^2 - x_1^2 - y_1^2 - z_1^2 + x_2^2 + y_2^2 + z_2^2 \\ d_1^2 - d_3^2 - x_1^2 - y_1^2 - z_1^2 + x_3^2 + y_3^2 + z_3^2 \\ \vdots \\ d_1^2 - d_n^2 - x_1^2 - y_1^2 - z_1^2 + x_n^2 + y_n^2 + z_n^2 \end{cases} \quad (11)$$

$$l_i = x_i^2 + y_i^2 + z_i^2 \quad (12)$$

$$2 \begin{bmatrix} (x_2 - x_1) & (y_2 - y_1) & (z_2 - z_1) \\ (x_3 - x_1) & (y_3 - y_1) & (z_3 - z_1) \\ \vdots & \vdots & \vdots \\ (x_n - x_1) & (y_n - y_1) & (z_n - z_1) \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} d_1^2 - d_2^2 - l_1 + l_2 \\ d_1^2 - d_3^2 - l_1 + l_3 \\ \vdots \\ d_1^2 - d_n^2 - l_1 + l_n \end{bmatrix} \quad (13)$$

$$\mathbf{Ax} = \mathbf{b} \quad (14)$$

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{b} \quad (15)$$

Macierz odwrotną można stworzyć, gdy jest ona kwadratowa i wiersze są liniowo niezależne. Z uwagi na błędy pomiarowe w wyniku których okręgi nie posiadają jednego punktu wspólnego, przygotowany układ równań nie będzie posiadał jednoznacznego rozwiązania lub

rozwiązań będzie wiele. W celu otrzymania rozwiązania metodą najmniejszych kwadratów wykorzystuje się uogólnioną macierz odwrotną Moore-Penrose'a, którą otrzymuje się przez rozkład według wartości osobliwych (SVD – *ang. singular value decomposition*) [86]. Rozwiązanie (pozycję obiektu) otrzymuje się wtedy z równania (16).

$$\mathbf{x} = \mathbf{A}^+ \mathbf{b} = \mathbf{V} \mathbf{D}^+ \mathbf{U}^T \mathbf{b} \quad (16)$$

gdzie: \mathbf{V}, \mathbf{U} – macierze ortogonalne; \mathbf{D} – macierz diagonalna z nieujemnymi wartościami osobliwymi macierzy \mathbf{A} .

Wyznaczanie najlepszej estymacji pozycji można również zdefiniować jako problem optymalizacyjny. Poszukiwania pozycji obiektu zmierzają do minimalizacji błędu średniokwadratowego (17). W celu znalezienia rozwiązania (minimum funkcji) wykorzystuje się iteracyjną metodę sympleksowego spadku (metodę Nelder-Meada) [87]. W kolejnych przebiegach algorytmu dąży się do minimalizacji MSE estymowanej pozycji obiektu.

$$MSE = \frac{1}{k} \sum_{i=1}^k (d_i - \hat{d}_i)^2 \quad (17)$$

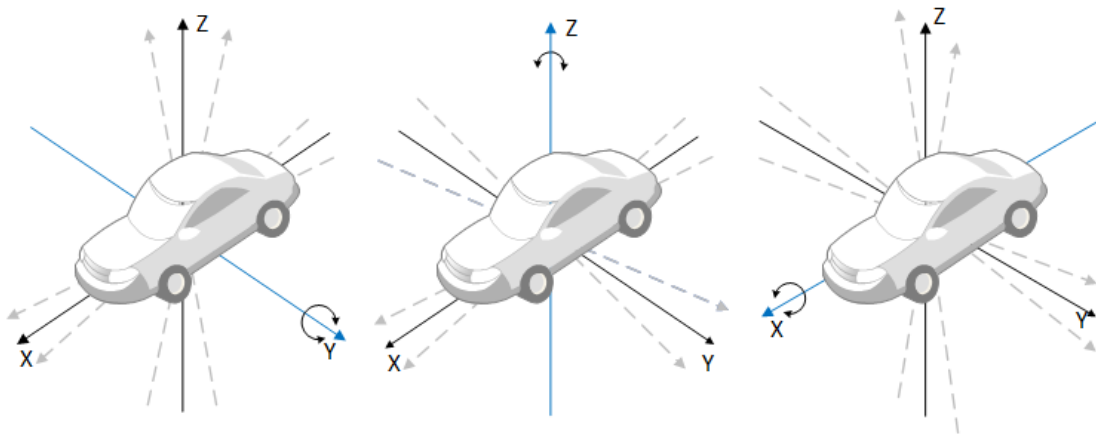
gdzie: d_i – odległość pomiędzy znacznikiem a i -tą kotwicą; \hat{d}_i – odległość euklidesowa pomiędzy estymowaną pozycją a i -tym punktem referencyjnym; k – liczba punktów referencyjnych.

Czas potrzebny na wyznaczenie pozycji zależy od przyjętych parametrów funkcji iteracyjnego poszukiwania rozwiązania takich jak liczba iteracji, minimalna zmiana wartości funkcji oraz minimalny krok. Ważnym elementem jest również punkt startowy poszukiwań, który dla pierwszej wyznaczonej pozycji zazwyczaj jest środkiem ciężkości wielokąta zbudowanego na węzłach referencyjnych, a dla następnych pozycji poprzednio wyznaczoną pozycją obiektu pozycjonowanego.

2.4 Nawigacja inercyjna

Nawigacja inercyjna polega na wyznaczeniu względnego przemieszczenia obiektu, jego orientacji (patrz rys. 13) na podstawie danych o przyspieszeniu działającym na obiekt, prędkości kątowej czy też polu magnetycznym. Znając siły działające na ciało oraz punkt, pozycję początkową możliwe jest wyznaczenie kolejnych pozycji. Nowoczesne jednostki, urządzenia do nawigacji inercyjnej wykonywane są jako mikroukłady elektromechaniczne (MEMS), które można podzielić na:

- IMU – jednostka wyposażona w akcelerometr – do pomiaru przyspieszeń działających na ciało w trzech osiach oraz żyroskop – do pomiaru prędkości kątowej również w trzech osiach,
- AHRS – jednostka wyposażona w akcelerometr, żyroskop oraz magnetometr – do pomiaru ziemskiego pola magnetycznego w trzech osiach.



Rys. 13. Orientacja obiektu – pochYLENIE, odchylenie i przechYLENIE

Dużą zaletą nawigacji inercyjnej jest jej niezależność od infrastruktury (pojedyncze urządzenie znajduje się na pozycjonowanym pojeździe, czy osobie [88]) oraz posiadają wysoką częstość pozyskiwania informacji. Ta druga zaleta powoduje, że układy te znajdują zastosowanie w wielu systemach pozycjonowania jako systemy wspomagające. Wykorzystując dane z sensorów inercyjnych podczas procesu wyznaczania pozycji, ważnym elementem jest odpowiednia transformacja danych o ruchu i rotacji obiektu. Dane każdego z sensorów należy poddać transformacji w taki sposób, aby układ współrzędnych wykorzystywanego sensora odpowiadał zdefiniowanemu lokalnemu układowi współrzędnych, po którym porusza się obiekt [89]. Brak transformacji będzie skutkowało tym, że dane np. z akcelerometru nie będą pomagać w filtracji z wykorzystaniem filtru komplementarnego, a wręcz ją pogarszać lub też kierunek ruchu nie będzie odpowiadał kierunkowi rzeczywistemu. Duży wpływ na wyniki pozycjonowania tą techniką ma jakość wykorzystanych modułów, ich kalibracja, warunki zewnętrzne wpływające na poruszający się obiekt oraz czas od ostatniej aktualizacji pozycji (bezwzględnej w lokalnym lub globalnym układzie odniesienia) z systemu o wyższej dokładności.

W kontekście pojazdów autonomicznych, czy samojezdnych dane z sensorów inercyjnych można również wykorzystać w inny sposób niż do samej nawigacji [90]–[92]. Dane z akcelerometru mogą być wykorzystane do identyfikacji stanu poruszającego się pojazdu i uzależnić od tego czynnika proces analizy danych, czy też filtrację danych innego systemu


pozycjonowania [93]. Dane z akcelerometru można również wykorzystać do aktywacji systemów wspomagania, czy też wykrywać zdarzenia (np. zderzenie z elementami infrastruktury drogowej lub magazynowej, czy też innym uczestnikiem ruchu) i minimalizować ich skutki [94].

2.5 Nawigacja zliczeniowa

Nawigacja zliczeniowa (*ang. dead reckoning*) jest jedną z najstarszych technik wyznaczania pozycji obiektu, która opiera się o punkty charakterystyczne na danym obszarze i nie wymaga skomplikowanych urządzeń pomiarowych. Znając koordynaty punktu referencyjnego możliwe jest – np. na podstawie kierunku i prędkości poruszania się, wyznaczenie kolejnych pozycji obiektu. Technika ta w dalszym ciągu jest stosowana często w połączeniu z innymi systemami do pozycjonowania takimi jak wizja, UWB, radar, lidar, czy najczęściej stosowanym systemem na zewnątrz budynków GPS [95], [96]. Dużą zaletą tej techniki jest częstość pozyskiwania kolejnych danych, a w konsekwencji pozycji czy prędkości. Jednakże dokładność tej techniki maleje wraz z czasem od ostatniej znanej pozycji obiektu pozyskanej w inny sposób np. obserwacji punktów charakterystycznych, innego systemu o większej dokładności. Związane jest to z kumulacją błędu w czasie, ponieważ pokonany dystans, czy prędkość obiektu wyznaczana jest w stosunku do znanych danych z innego źródła, które czasowo są niedostępne (np. z uwagi na niższą częstotliwość próbkowania, czy brak punktów charakterystycznych na danym obszarze). Wada ta ogranicza czas stosowania nawigacji zliczeniowej bez korekty z innego źródła np.: systemu UWB, wizji, czy lidar [97].

3 Symulator systemu UWB

W niniejszym rozdziale opisano autorski symulator systemu UWB [98], który odzwierciedla działanie rzeczywistego systemu opartego na modułach DWM1000 firmy Decawave z zewnętrzną anteną dookólną przedstawiony na rys. 14. Transmisja tych modułów oparta jest na standardzie IEEE 802.15.4-2011 [71]. Niemniej jednak procedura tworzenia symulatora może być zastosowana dla innych, nowo powstałych modułów UWB (aktualnie pojawił się na rynku moduł DWM3000 tej samej firmy). Budowany symulator powinien cechować się możliwością zadania parametrów różnych systemów bazujących na technologii UWB, a sposób pozyskania parametrów potrzebnych do uruchomienia symulatora był możliwy bez znajomości dokładnych parametrów transmisji. Odległości pomiędzy punktem na ścieżce referencyjnej a kotwicami powinny uwzględniać ruch obiektu. Projektowany symulator powinien również charakteryzować się błędem oraz zmiennością odległości na poziomie systemu rzeczywistego uwzględniając jego zmienną charakterystykę wraz z odległością pomiędzy węzłami w sieci. Dane wyjściowe powinny umożliwić wyznaczenie pozycji obiektu w sposób podobny co dane z systemu rzeczywistego.



Rys. 14. Węzeł systemu wymiarowania oparty na module DWM1000

Posiadany system potraktowany zostanie jako „czarna skrzynka” i na bazie otrzymywanych informacji o odległości w procesie analizy danych zamodelowana zostanie jego praca. Podejście to wybrano z uwagi na brak pełnych informacji dotyczących parametrów transmisji i konfiguracji wymiany danych pomiędzy węzłami posiadanych systemów UWB (gotowych systemów, które nie wymagają zaprogramowania, a jedynie konfiguracji) przez co

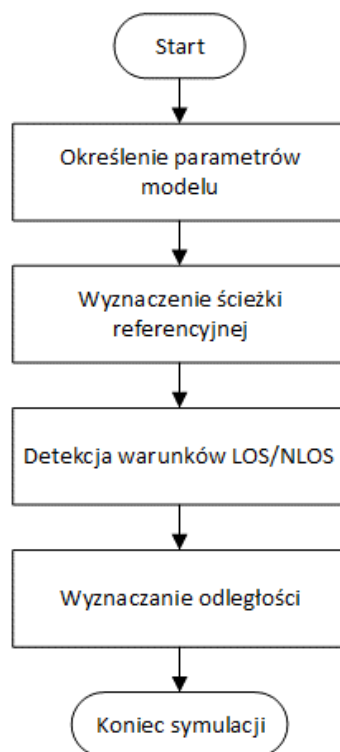
niemożliwym jest zbudowanie symulatora – rozpoczynając od niskiego poziomu transmisji ramek w sieci.

3.1 Analiza rzeczywistego systemu pozycjonowania

Punktem startowym tworzonego symulatora są odległości pomiędzy węzłami sieci zdefiniowanej przez użytkownika, które najlepiej pozyskać zarówno w linii widoczności (LOS – *ang. line-of-sight*) jak i przy braku widoczności (NLOS) pomiędzy węzłami w sieci. W rzeczywistych warunkach obiekt poruszałby się wedle zaplanowanego scenariusza, jednocześnie pozyskując dane z wszystkich węzłów sieci, które są w zasięgu znacznika. Danymi wejściowymi symulatora są funkcje drogi w ruchu jednostajnie przyspieszonym w dziedzinie czasu, które odzwierciedlają wzorcowy przejazd obiektu dla zadanego scenariusza testowego.

Symulator został podzielony na cztery główne moduły (diagram przepływu symulatora przedstawiono na rys. 15), które od definicji parametrów systemu UWB przez wyznaczenie ścieżki referencyjnej prowadzą do wyznaczenia odległości pomiędzy węzłem mobilnym a punktami referencyjnymi:

- Ustawienie parametrów modelu – w fazie inicjalizacyjnej należy ustalić parametry modelu (z możliwością wykorzystania wartości domyślnych MBE (*ang. mean bias error*) i odchylenia standardowego), pozycje punktów referencyjnych, częstotliwość próbkowania oraz opisać ruch obiektów wykorzystując proste i łuki w dziedzinie czasu. Na tym etapie możliwe jest również opisanie przeszkód, które wpływają na warunki pozycjonowania – LOS, NLOS.
- Wyznaczenie ścieżki referencyjnej – dla wszystkich funkcji opisujących ścieżkę tworzony jest wektor punktów zgodnie z zadanym czasem wymiany informacji pomiędzy węzłami. Dla danej chwili wyznaczana jest pozycja obiektu w lokalnym układzie odniesienia zdefiniowanym przez punkty referencyjne.
- Detekcja warunków LOS, NLOS – jeżeli wprowadzono funkcje opisujące przeszkody, możliwe jest wyznaczenie dla każdego punktu na ścieżce referencyjnej możliwości wystąpienia warunków NLOS dla każdego z punktów referencyjnych.
- Wyznaczanie odległości – dla każdego punktu na ścieżce wyznaczana jest odległość do wszystkich punktów referencyjnych i nakładany jest szum zgodnie z parametrami ustawionymi w kroku pierwszym, tj. ustawianie parametrów modelu.

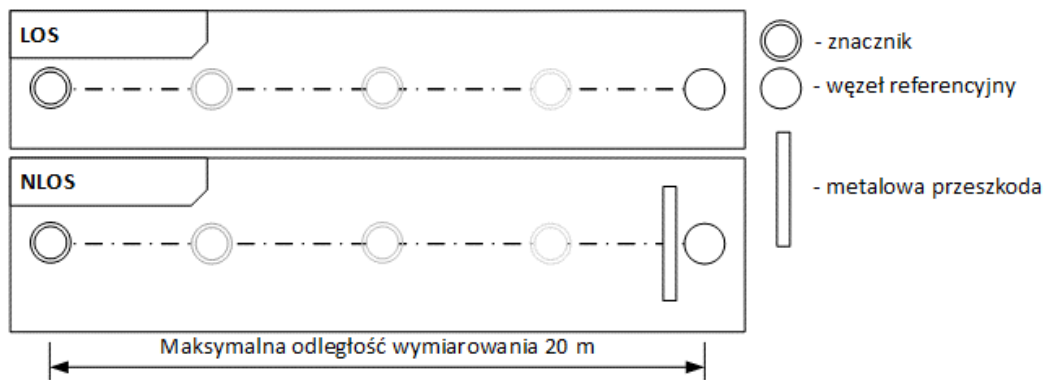


Rys. 15. Ogólny diagram przepływu symulatora

W celu wyznaczenia parametrów statystycznych zebrano dane o odległości pomiędzy węzłami we wskazanych w tab. 3 odległościach. Pomiaru dokonywano statycznie w dwóch wariantach: w warunkach LOS oraz warunkach NLOS, które zasymulowano przez zasłonięcie jednego z węzłów metalową przeszkodą o wymiarach 0,5 m x 0,5 m (patrz rys. 16). Każdy ze scenariuszy obejmuje 10 000 odczytów odległości. Tak zebrane dane posłużą do wyznaczenia parametrów statystycznych rozkładu prawdopodobieństwa odległości.

Tab. 3. Odległości, w których wykonano pomiary statyczne

Dystans [cm]	Liczba pomiarów na dystans	Liczba pomiarów w warunkach LOS	Liczba pomiarów w warunkach NLOS	łącznie pomiarów
(1)	(2)	(3)	(4)	(5)
50; 100; 150; 200; 250; 300; 350; 400; 450; 500; 550; 600; 650; 700; 750; 800; 850; 900; 950; 1000; 1100; 1200; 1300; 1400; 1500; 1600; 1700; 1800; 1900; 2000	10 000	300 000	300 000	600 000

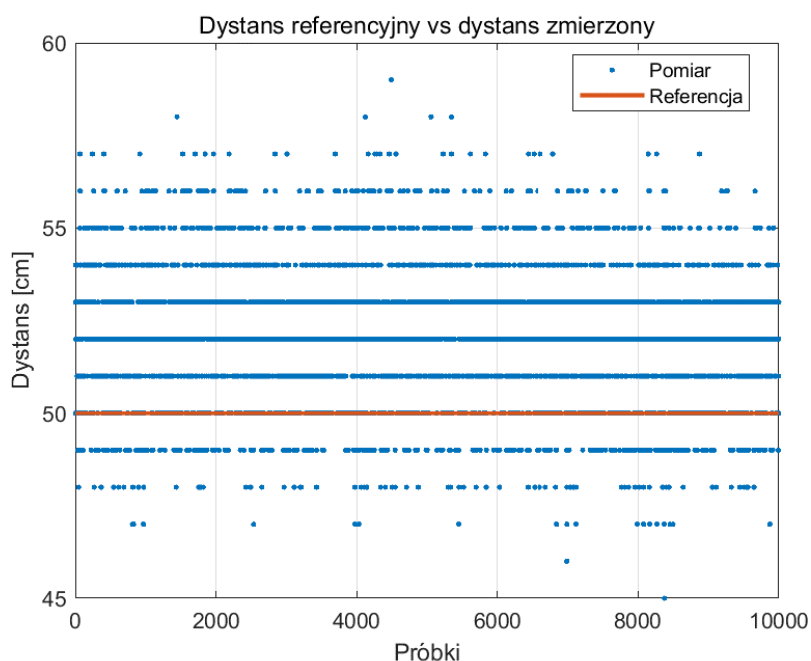


Rys. 16. Rozmieszczenie elementów na stanowisku pomiarowym w dwóch wariantach wymiarowania – w warunkach LOS i NLOS

Dwuetapowa analiza zebranych danych pozwoli wyznaczyć parametry dla warunków LOS i NLOS. Zebrane statystyki pozwolą odpowiedzieć na pytanie czy przeszkoda ma wpływ na pomiar odległości i czy warunki LOS i NLOS mogą być opisane wspólnymi parametrami.

3.2 Wyznaczenie parametrów modelu

W pierwszym kroku przeanalizowane zostały dane o odległości pomiędzy węzłami w warunkach LOS (brak przeszkody w obrębie stanowiska pomiarowego). Przykładowe odczyty systemu pomiędzy węzłami zaprezentowano na rys. 17 dla odległości 50 cm. Należy zaznaczyć, że rozdzielczość wykorzystywanego systemu wynosi 1 cm.



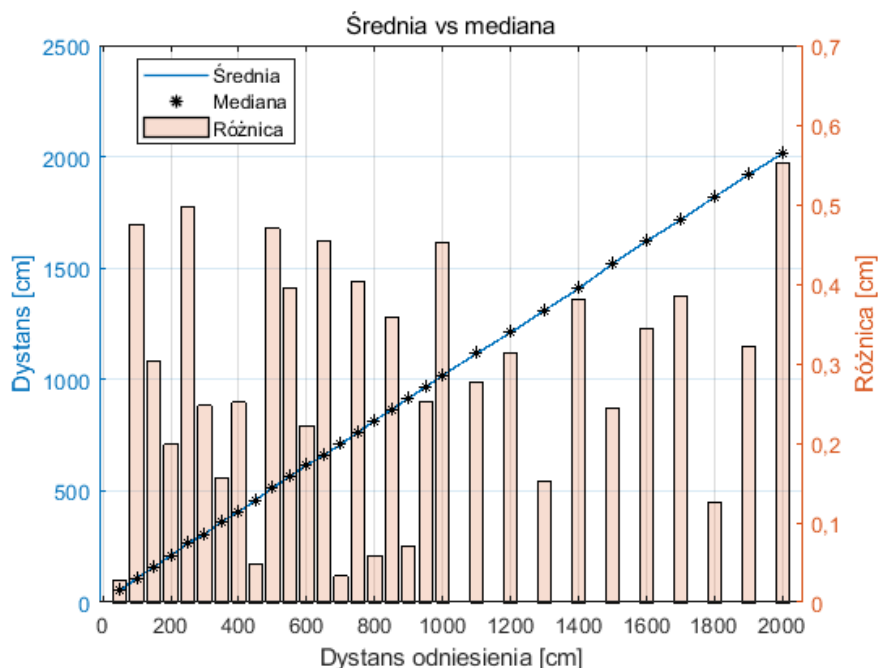
Rys. 17. Wyznaczone odległości dla odległości referencyjnej 50 cm

W tab. 4 przedstawiono zebrane statystyki testowe odnoszące się do pomiaru odległości w warunkach LOS. Wartość średnia (d_{mean}) jest bliska medianie (d_{med}) co wskazuje na

stosunkowo równomierną koncentrację pomiarów wokół wartości średniej (patrz rys. 18). Maksymalna wartość bezwzględna różnicy wartości średniej i mediany (kolumna numer 7) wynosi 0,6 cm (dla odległości referencyjnej 20 m). Porównując wartość referencyjną oraz średnią wartość pozyskanych odległości można jednoznacznie stwierdzić, że badany system charakteryzuje się przeszacowaniem wartości odległości dla wszystkich badanych odległości.

Tab. 4. Statystyki testowe pomiaru odległości w warunkach LOS.

Odległość referencyjna [cm]	Średnia [cm]	Mediana [cm]	STD [cm]	Min [cm]	Max [cm]	(2)-(3) [cm]
d_{ref}	d_{mean}	d_{med}	d_{std}	d_{min}	d_{max}	$ d_{mean} - d_{med} $
(1)	(2)	(3)	(4)	(5)	(6)	(7)
50	52,0	52	1,8	45	59	0,0
100	108,5	109	2,4	94	118	0,5
150	157,7	158	2,4	147	166	0,3
200	209,2	209	2,3	200	218	0,2
250	264,5	265	2,1	254	273	0,5
300	305,2	305	2,1	299	318	0,2
350	362,2	362	2,5	353	371	0,2
400	407,3	407	1,9	401	414	0,3
450	459,0	459	1,5	453	466	0,0
500	513,5	513	2,2	503	522	0,5
550	565,6	566	2,5	554	572	0,4
600	614,2	614	1,9	607	621	0,2
650	660,5	661	1,4	653	665	0,5
700	707,0	707	1,4	702	713	0,0
750	763,4	763	1,8	758	770	0,4
800	816,1	816	2,0	807	823	0,1
850	865,6	866	2,1	856	875	0,4
900	916,1	916	2,6	908	925	0,1
950	967,3	967	2,2	959	976	0,3
1000	1018,5	1019	2,4	1010	1026	0,5
1100	1117,3	1117	2,0	1111	1124	0,3
1200	1210,7	1211	1,4	1205	1216	0,3
1300	1311,2	1311	1,0	1308	1315	0,2
1400	1407,6	1408	1,5	1402	1415	0,4
1500	1519,8	1520	1,6	1513	1525	0,2
1600	1621,3	1621	1,6	1616	1627	0,3
1700	1716,4	1716	1,8	1710	1724	0,4
1800	1820,1	1820	1,5	1814	1826	0,1
1900	1919,3	1919	1,5	1913	1925	0,3
2000	2015,6	2015	1,7	2010	2021	0,6

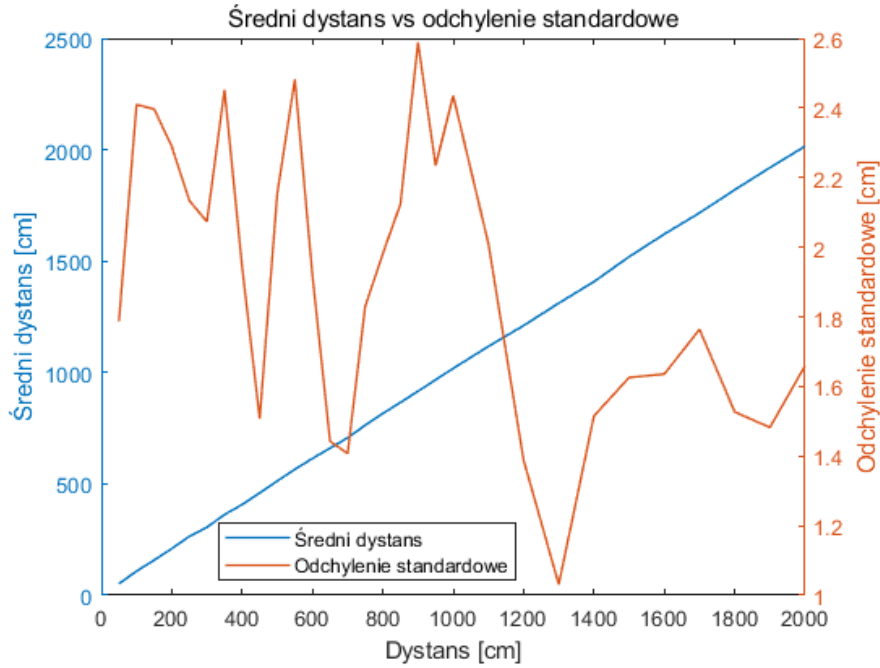


Rys. 18. Wartość średniej i mediany odległości dla badanych odległości referencyjnych

Wyznaczone parametry rozkładu pozwolą nałożyć odpowiedni szum na dane dokładne pozyskane ze zbudowanego symulatora (na podstawie zdefiniowanej ścieżki) i traktowane będą jak dane pochodzące z systemu referencyjnego (które w zaprezentowanym przykładzie będą dokładnymi odległościami pomiędzy dwoma współrzędnymi w kartezjańskim układzie współrzędnych).

Pomimo, że testy Lillieforsa i Kołmogorowa-Smirnowa odrzucają hipotezę zerową, że dane pochodzą z rozkładu normalnego, to na podstawie centralnego twierdzenia granicznego zakłada się, że średnia wartość zmiennej losowej jest zbliżona do rozkładu normalnego, gdy populacja jest wystarczająco duża. Mając zatem odpowiednio dużą próbę, możliwe jest przybliżenie rozkładu statystyki testowej do rozkładu normalnego przy zadanej wartości średniej i odchyleniu standardowym.

Odchylenie standardowe zmienia się wraz z badaną odległością i mieści się w zakresie 1,0 – 2,6 cm (patrz rys. 19). Stosunkowo mała wartość odchylenia standardowego wskazuje na dużą koncentrację danych wokół wartości średniej, co z kolei świadczy o małej liczbie wartości skrajnie odstających.



Rys. 19. Wartość średniej i odchylenia standardowego odległości dla badanych odległości referencyjnych

Korzystając z dokładnej wartości referencyjnej (którą wyznaczono wykorzystując dalmierz laserowy oraz taśmę mierniczą w trakcie badań na stanowisku testowym) wyznaczono dokładność badanego systemu UWB. Najważniejsze statystyki dotyczące błędu zebrano w tab. 5. Analizując wartość minimalną i maksymalną (kolumny 5 i 6) różnicy wartości pomiaru i wartości referencyjnej (18) można zauważyć, że wraz ze wzrostem odległości przeszacowanie systemu nie jest stałe.

$$\varepsilon_i = d_i - \hat{d}_i \quad (18)$$

gdzie: d_i – odległość zmierzona; \hat{d}_i – odległość oczekiwana (referencyjna).

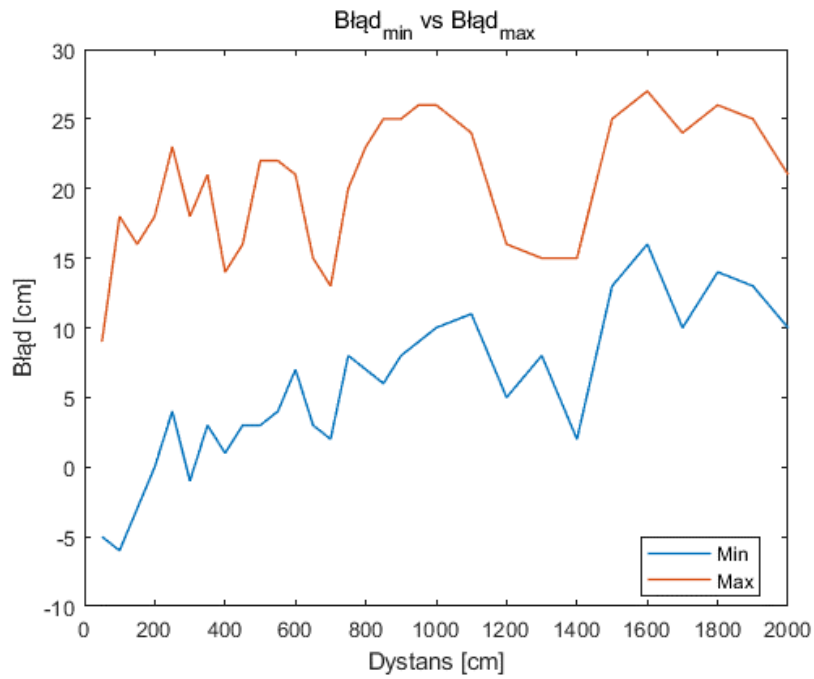
Tab. 5. Statystyki testowe dokładności pomiaru odległości w warunkach LOS

Odległość referencyjna [cm]	MBE [cm]	RMSE [cm]	STD [cm]	Min [cm]	Max [cm]	Min [cm]	Max [cm]
d_{ref}	MBE	$RMSE$	STD	ε_{min}	ε_{max}	$ \varepsilon _{min}$	$ \varepsilon _{max}$
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
50	2,0	2,7	1,8	-5	9	0	9
100	8,5	8,9	2,4	-6	18	0	18
150	7,7	8,1	2,4	-3	16	0	16
200	9,2	9,5	2,3	0	18	0	18
250	14,5	14,7	2,1	4	23	4	23
300	5,2	5,6	2,1	-1	18	0	18
350	12,2	12,4	2,5	3	21	3	21

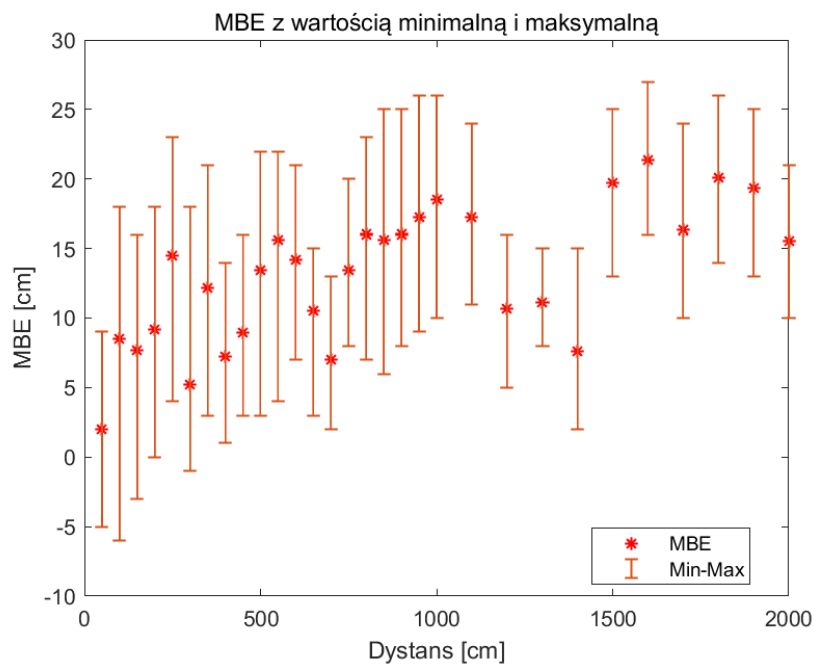
400	7,3	7,5	1,9	1	14	1	14
450	9,0	9,1	1,5	3	16	3	16
500	13,5	13,6	2,2	3	22	3	22
550	15,6	15,8	2,5	4	22	4	22
600	14,2	14,4	1,9	7	21	7	21
650	10,5	10,6	1,4	3	15	3	15
700	7,0	7,2	1,4	2	13	2	13
750	13,4	13,5	1,8	8	20	8	20
800	16,1	16,2	2,0	7	23	7	23
850	15,6	15,8	2,1	6	25	6	25
900	16,1	16,3	2,6	8	25	8	25
950	17,3	17,4	2,2	9	26	9	26
1000	18,5	18,7	2,4	10	26	10	26
1100	17,3	17,4	2,0	11	24	11	24
1200	10,7	10,8	1,4	5	16	5	16
1300	11,2	11,2	1,0	8	15	8	15
1400	7,6	7,8	1,5	2	15	2	15
1500	19,8	19,8	1,6	13	25	13	25
1600	21,3	21,4	1,6	16	27	16	27
1700	16,4	16,5	1,8	10	24	10	24
1800	20,1	20,2	1,5	14	26	14	26
1900	19,3	19,4	1,5	13	25	13	25
2000	15,6	15,6	1,7	10	21	10	21

Maksymalna (ε_{max}) i minimalna (ε_{min}) wartość różnicy wartości błędu i wartości referencyjnej oraz MBE zmienia się wraz z odległością bez wyraźnej korelacji z wartością referencyjną odległości (patrz rys. 20 i rys. 21). Średni obszar zmienności wynosi 14,8 cm, najmniejszy wynosi 7 cm (dla pomiarów w odległości 13 m), a największy wynosi 24 cm (dla pomiarów w odległości 1 m).

Parametrem określającym dokładność w systemach pozycjonowania jest RMSE (19). Dla badanego systemu pierwiastek średniej kwadratowej błędów odległości zmienia się wraz z dystansem bez wyraźnej monotoniczności. Średnia wartość RMSE dla wszystkich odległości referencyjnych wynosi 13,3 cm, wartość maksymalna 21,4 cm (dla odległości 16 m), a wartość minimalna 2,7 cm (dla odległości 50 cm) (patrz rys. 22). Z uwagi na dominujące przeszacowanie wartości odległości MBE (20) jest zbliżona do wartości RMSE (patrz rys. 23). Jednakże, gdy system charakteryzuje się nie tylko przeszacowaniem, ale również niedoszacowaniem odległości, wtedy różnice pomiędzy MBE i RMSE zwiększają się. Wartość błędu systematycznego (MBE) może być wykorzystana do korekty danych o odległości, co z kolei wpływa na dokładność wyznaczonej pozycji obiektu [93], [99].



Rys. 20. Minimalna i maksymalna wartość błędu dla badanych odległości

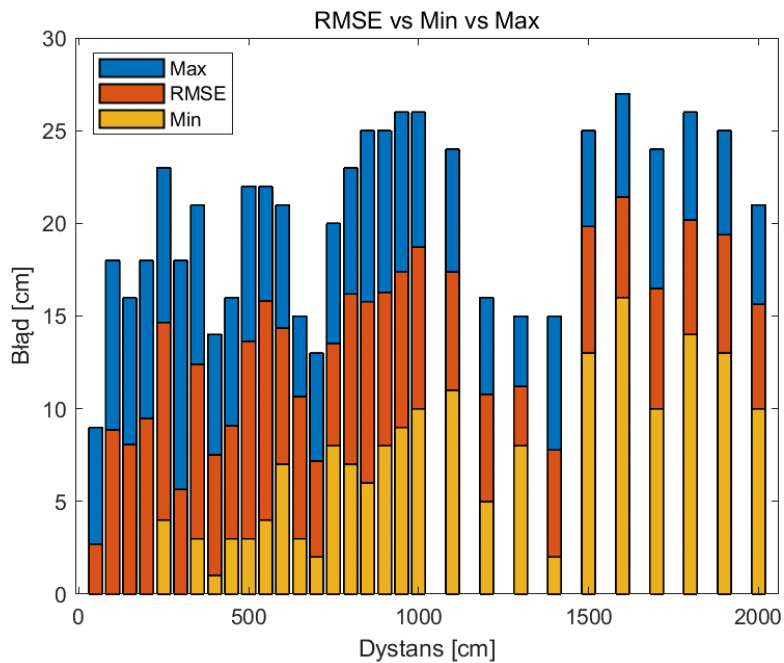


Rys. 21. MBE z wartością minimalną i maksymalną błędu dla badanych odległości


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (d_i - \hat{d}_i)^2} \quad (19)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (d_i - \hat{d}_i) \quad (20)$$

gdzie d_i – odległość zmierzona; \hat{d}_i – odległość oczekiwana (referencyjna); N – liczba pomiarów.



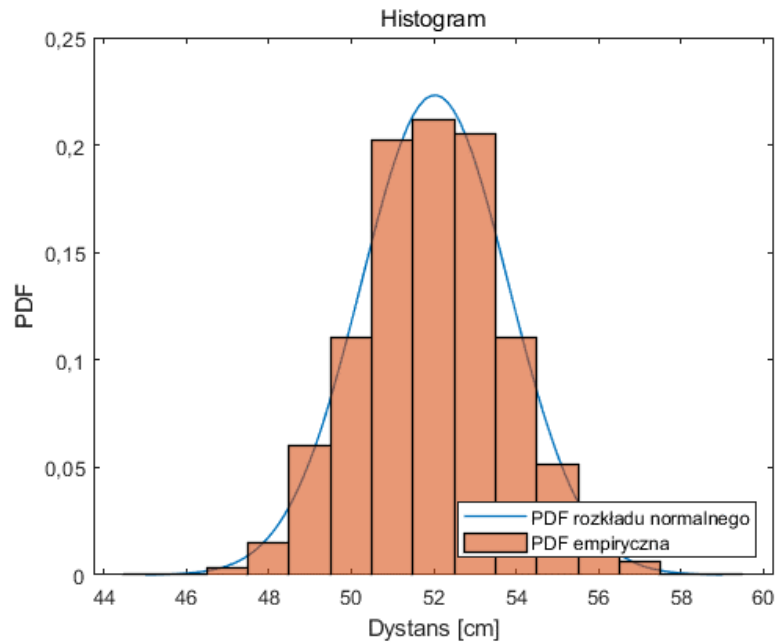
Rys. 22. RMSE z wartością minimalną i maksymalną błędów dla badanych odległości



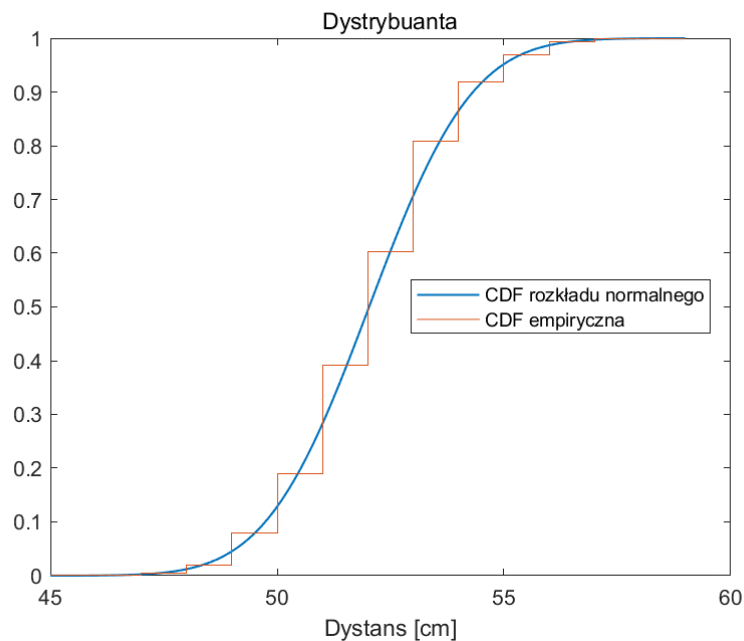
Rys. 23. Porównanie RMSE z MBE dla badanych odległości

Dla wszystkich odległości referencyjnych wyznaczono parametry rozkładu normalnego (wartość średnią i odchylenie standardowe) na badanej próbie 10 000 próbek. Przykładową

funkcję gęstości prawdopodobieństwa, dystrybuantę rozkładu normalnego oraz wartości empiryczne przedstawiono odpowiednio na rys. 24 oraz rys. 25 (dla dystansu 50 cm). Tak dopasowany rozkład normalny w dużym stopniu przybliża rozkład badanej próby i pozwala odwzorować działanie systemu.



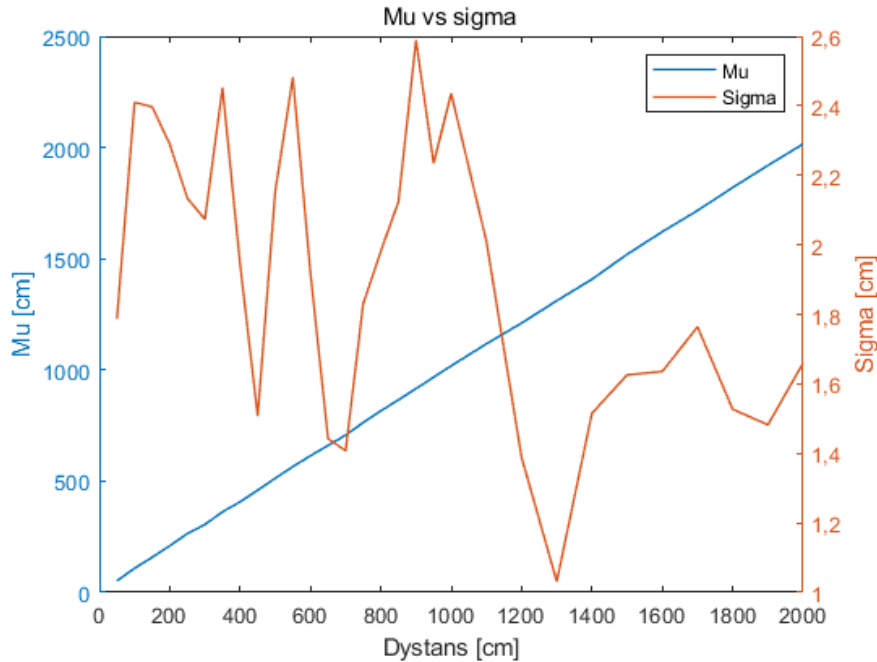
Rys. 24. Funkcja gęstości prawdopodobieństwa dopasowanego rozkładu normalnego



Rys. 25. Dystrybuanta dopasowanego rozkładu normalnego dla badanej próby

Wyznaczone parametry rozkładów opisują dane, które zbierane były w ustalonych odstępach i w celu odzwierciedlenia pracy systemu (również w odległościach innych niż

w odległościach referencyjnych), należy zamodelować zmiany parametrów rozkładu. Na rys. 26 przedstawiono parametry rozkładów normalnych (μ – wartość średnią oraz σ – odchylenie standardowe) dopasowanych do zebranych danych w odległościach pomiarowych.



Rys. 26. Parametry rozkładów normalnych dopasowanych do każdej z badanych odległości

Do aproksymacji parametrów rozkładów wykorzystano funkcję wielomianową w postaci (21). Jednakże do lepszego zamodelowania zmian parametru wraz ze zmianą odległości referencyjnej d_{ref} należy podzielić funkcję na fragmenty – w tym celu należy wyznaczyć minima lokalne. Minimalna liczba punktów pomiarowych $n_{d_{ref}}$ pomiędzy kolejnymi minimami lokalnymi l_j wykorzystana jest jako parametr ograniczający tworzenie nadmiernej liczby funkcji – parametr dobierany jest empirycznie i w niniejszych rozważaniach przyjęto $n_{d_{ref}} = 2$ (dla badanego systemu można przyjąć również wartość trzy).

$$f(d_{ref}) = a_n d_{ref}^n + a_{n-1} d_{ref}^{n-1} + \dots + a_1 d_{ref} + a_0 \quad (21)$$

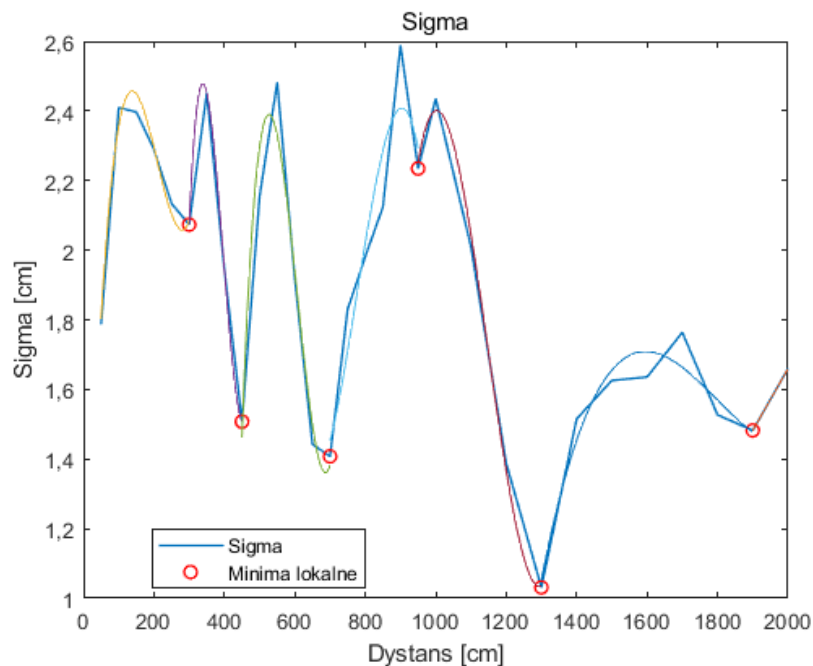
gdzie: a_0, a_1, \dots, a_n – współczynniki wielomianu; $d_{ref} \in [l_j, l_{j+1}]$.

W kolejnym kroku dopasowano wielomian najwyżej trzeciego stopnia w przedziałach określonych przez kolejne minima lokalne – wybór stopnia wielomianu zależy od liczby punktów pomiarowych w wyznaczonym przez kolejne dwa minima lokalne przedziale, ponieważ ostatni fragment może obejmować jedynie dwa punkty pomiarowe, na których wykonywana jest aproksymacja, tak więc do aproksymacji zmian w ostatnim fragmencie będzie wykorzystana funkcja liniowa. Aproksymując funkcje w przedziałach zaprezentowanych w tab. 6,

zamodelowano zmianę odchylenia standardowego w funkcji odległości (patrz rys. 27). Możliwe jest również wykorzystanie funkcji wielomianowych czy potęgowych do aproksymacji [93].

Tab. 6. Współczynniki i przedziały funkcji aproksymujących zmianę SD

Współczynniki wielomianu	Dolna granica [cm]	Górna granica [cm]
(1)	(2)	(3)
2,81E-07; -1,76E-04; 3,25E-02; 5,83E-01	50	300
1,28E-06; -1,52E-03; 5,88E-01; -7,24E+01	300	450
4,99E-07; -9,09E-04; 5,42E-01; -1,04E+02	450	700
-1,29E-07; 2,99E-04; -2,26E-01; 5,71E+01	700	950
1,11E-07; -3,82E-04; 4,32E-01; -1,58E+02	950	1300
8,37E-09; -4,51E-05; 8,00E-02; -4,51E+01	1300	1900
1,77E-03; -1,89E+00	1900	2000



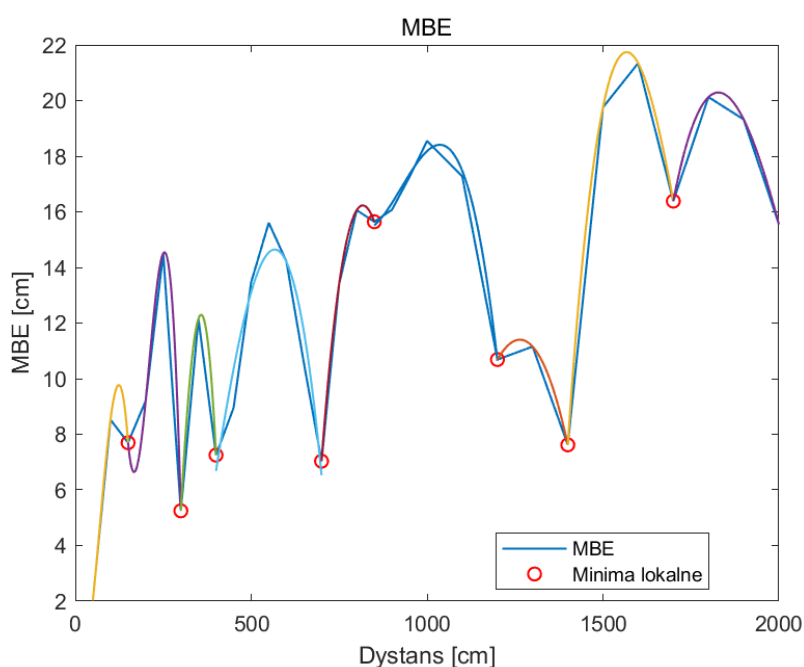
Rys. 27. Podział odchylenia standardowego (wyznaczonych rozkładów) na fragmenty

Procedurę należy powtórzyć dla drugiego parametru rozkładu normalnego jakim jest średnia μ . Funkcja aproksymująca średnią dla danej odległości mogłaby być funkcją liniową rosnącą co jest naturalne z uwagi na ciągły wzrost odległości pomiędzy znacznikiem a kotwicą w kolejnych punktach pomiarowych. Jednakże jak pokazano na rys. 23 błąd systemu zmienia się wraz z odległością w nieregularny sposób w związku z czym do zamodelowania zmian w działaniu systemu należy znaleźć inny parametr niż średnią wartość odległości. Parametrem, który opisuje błąd odległości i odzwierciedla wartość średnią w oparciu o wartość referencyjną jest MBE. Parametr ten reprezentuje średnie przesunięcie (*ang. bias*) pomiarów (błąd systematyczny

systemu). Badany system charakteryzuje się przeszacowaniem odległości w związku z czym błąd ten jest zawsze dodatni. Tak samo jak dla odchylenia standardowego w celu odwzorowania wartości MBE w punktach znajdujących się pomiędzy kolejnymi punktami pomiarowymi należy zmianę błędu zamodelować. W tym celu wyznaczono minima lokalne z minimalną odległością dwóch próbek $n_{d_{ref}} = 2$ (podobne wyniki uzyskuje się dla trzech próbek) i wykonano aproksymację wielomianem co najwyżej 3 stopnia (patrz rys. 28) – współczynniki wielomianu oraz przedziały odpowiadające zaprezentowanym funkcjom przedstawiono w tab. 7.

Tab. 7. Współczynniki i przedziały funkcji aproksymujących zmianę MBE w warunkach LOS

Współczynniki wielomianu	Dolna granica [cm]	Górna granica [cm]
(1)	(2)	(3)
-1,47E-03; 3,50E-01; -1,18E+01	50	150
-2,45E-05; 1,55E-02; -3,11E+00; 2,10E+02	150	300
-2,36E-03; 1,67E+00; -2,84E+02	300	400
-5,70E-07; 5,87E-04; -1,17E-01; -4,15E+00	400	700
8,53E-07; -2,66E-03; 2,64E+00; -8,30E+02	700	850
-5,90E-07; 1,64E-03; -1,50E+00; 4,67E+02	850	1200
-2,00E-04; 5,04E-01; -3,07E+02	1200	1400
6,67E-07; -3,53E-03; 6,15E+00; -3,51E+03	1400	1700
2,63E-07; -1,65E-03; 3,39E+00; -2,27E+03	1700	2000



Rys. 28. Podział MBE na fragmenty oraz funkcje aproksymujące zmiany w przedziałach

Zebrane funkcje aproksymujące odchylenie standardowe oraz MBE jak również przedziały ich zastosowania, pozwalają na odwzorowanie pracy systemu rzeczywistego dla różnych odległości w warunkach LOS.

Analizę przeprowadzić należy również dla pomiarów w warunkach NLOS. Zebrane statystyki dotyczące odczytów odległości zamieszczono w tab. 8. Odnotowano wpływ metalowej przeszkody na pomiar odległości. Średnia wartość odchylenia standardowego dla wszystkich pomiarów wzrosła do 6,1 cm, a wartość maksymalna wzrosła do 18 cm.

Tab. 8. Statystyki testowe pomiaru odległości w warunkach NLOS

Odległość referencyjna [cm]	Średnia [cm]	Mediana [cm]	STD [cm]	Min [cm]	Max [cm]	(2)-(3) [cm]
d_{ref}	d_{mean}	d_{med}	d_{std}	d_{min}	d_{max}	$ d_{mean} - d_{med} $
(1)	(2)	(3)	(4)	(5)	(6)	(7)
50	99,8	100	1,1	96	107	0,2
100	179,4	181	7,9	120	186	1,6
150	225,6	228	5,6	190	234	2,4
200	227,4	230	17,6	196	279	2,6
250	262,3	258	10,9	251	323	4,3
300	309,6	310	1,4	305	315	0,4
350	433,3	433	3,1	375	439	0,3
400	408,4	408	1,4	403	414	0,4
450	511,2	511	10,6	476	538	0,2
500	548,7	547	10,5	518	582	1,7
550	635,2	638	8,6	591	645	2,8
600	602,9	603	1,5	597	609	0,1
650	650,8	651	1,3	646	657	0,2
700	769,5	770	8,9	720	784	0,5
750	824,3	824	1,3	808	829	0,3
800	803,2	803	1,5	798	810	0,2
850	852,3	852	4,5	845	934	0,3
900	898,6	895	8,9	890	940	3,6
950	955,0	955	2,5	950	999	0,0
1000	1009,9	1010	1,9	1003	1026	0,1
1100	1163,0	1163	2,7	1136	1169	0,0
1200	1207,7	1208	1,6	1201	1213	0,3
1300	1348,2	1349	9,2	1319	1372	0,8
1400	1403,6	1399	10,5	1390	1471	4,6
1500	1498,4	1498	1,2	1494	1503	0,4
1600	1660,9	1661	9,8	1626	1677	0,1
1700	1757,3	1757	1,9	1751	1764	0,3
1800	1835,5	1836	14,2	1800	1873	0,5

1900	1901,3	1901	1,4	1896	1907	0,3
2000	2014,9	2015	18,0	1993	2077	0,1

Błąd systemu również uległ zmianie (patrz tab. 9). Patrząc na parametr RMSE odnotowuje się średni wzrost do 35,1 cm, wartość minimalna RMSE zmalała do 1,5 cm, a wartość maksymalna RMSE wzrosła do 85,6 cm. Średni obszar zmienności również wzrósł i wynosi 43,1 cm.

Tab. 9. Statystyki testowe dokładności pomiaru odległości w warunkach NLOS

Odległość referencyjna [cm]	MBE [cm]	RMSE [cm]	STD [cm]	Min [cm]	Max [cm]	Min [cm]	Max [cm]
d_{ref}	MBE	$RMSE$	STD	ε_{min}	ε_{max}	$ \varepsilon _{min}$	$ \varepsilon _{max}$
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
50	49,8	49,8	1,1	46	57	46	57
100	79,4	79,8	7,9	20	86	20	86
150	75,6	75,8	5,6	40	84	40	84
200	27,4	32,6	17,6	-4	79	0	79
250	12,3	16,4	10,9	1	73	1	73
300	9,6	9,8	1,4	5	15	5	15
350	83,3	83,3	3,1	25	89	25	89
400	8,4	8,5	1,4	3	14	3	14
450	61,2	62,1	10,6	26	88	26	88
500	48,7	49,8	10,5	18	82	18	82
550	85,2	85,6	8,6	41	95	41	95
600	2,9	3,3	1,5	-3	9	0	9
650	0,8	1,5	1,3	-4	7	0	7
700	69,5	70,1	8,9	20	84	20	84
750	74,3	74,3	1,3	58	79	58	79
800	3,2	3,5	1,5	-2	10	0	10
850	2,3	5,0	4,5	-5	84	0	84
900	-1,4	9,0	8,9	-10	40	0	40
950	5,0	5,5	2,5	0	49	0	49
1000	9,9	10,1	1,9	3	26	3	26
1100	63,0	63,1	2,7	36	69	36	69
1200	7,7	7,9	1,6	1	13	1	13
1300	48,2	49,1	9,2	19	72	19	72
1400	3,6	11,1	10,5	-10	71	0	71
1500	-1,6	2,0	1,2	-6	3	0	6
1600	60,9	61,7	9,8	26	77	26	77
1700	57,3	57,3	1,9	51	64	51	64
1800	35,5	38,3	14,2	0	73	0	73
1900	1,3	1,9	1,4	-4	7	0	7
2000	14,9	23,3	18,0	-7	77	0	77

Następnie należy wyznaczyć parametry rozkładu normalnego, po czym zamodelować zmiany odchylenia standardowego (tab. 10) oraz MBE (tab. 11) w funkcji odległości (dla $n_{d_{ref}} = 2$). Opracowane funkcje aproksymujące odchylenie standardowe oraz MBE jak również przedziały ich zastosowania oddzielnie dla warunków LOS i NLOS, pozwalają na odwzorowanie pracy systemu rzeczywistego w różnych warunkach z zachowaniem parametrów zbliżonych do rzeczywistego systemu.

Tab. 10. Współczynniki i przedziały funkcji aproksymujących zmianę odchylenia standardowego w warunkach NLOS

Współczynniki wielomianu	Dolna granica [cm]	Górna granica [cm]
(1)	(2)	(3)
-1,83E-03; 4,10E-01; -1,48E+01	50	150
2,13E-05; -1,65E-02; 4,05E+00; -3,02E+02	150	300
-6,59E-04; 4,61E-01; -7,77E+01	300	400
5,26E-06; -8,81E-03; 4,82E+00; -8,54E+02	400	650
-3,04E-03; 4,26E+00; -1,48E+03	650	750
-1,61E-06; 3,94E-03; -3,16E+00; 8,38E+02	750	1000
-9,18E-05; 2,01E-01; -1,07E+02	1000	1200
-7,44E-07; 2,59E-03; -2,91E+00; 1,05E+03	1200	1500
-8,26E-04; 2,65E+00; -2,11E+03	1500	1700
-1,26E-03; 4,53E+00; -4,06E+03	1700	1900
1,66E-01; -3,13E+02	1900	2000

Tab. 11. Współczynniki i przedziały funkcji aproksymujących zmianę MBE w warunkach NLOS

Współczynniki wielomianu	Dolna granica [cm]	Górna granica [cm]
(1)	(2)	(3)
3,42E-05; -1,94E-02; 2,97E+00; -5,48E+01	50	300
-2,97E-02; 2,08E+01; -3,55E+03	300	400
-1,30E-02; 1,21E+01; -2,76E+03	400	500
2,65E-04; -4,61E-01; 2,66E+02; -5,06E+04	500	650
5,51E-05; -1,31E-01; 1,03E+02; -2,66E+04	650	900
-2,08E-05; 6,37E-02; -6,45E+01; 2,17E+04	900	1200
2,08E-05; -8,52E-02; 1,16E+02; -5,24E+04	1200	1500
4,47E-06; -2,43E-02; 4,37E+01; -2,60E+04	1500	1900
1,36E-01; -2,56E+02	1900	2000

3.3 Opis scenariusza testowego w symulatorze

Poniżej zostanie przedstawiony scenariusz testowy dla pojazdu poruszającego się po płaszczyźnie. W pierwszej kolejności na płaszczyźnie testowej umieszcza się kotwice, czyli punkty referencyjne w lokalnym układzie odniesienia. Definiowane są również parametry modelu systemu UWB: średni błąd systematyczny odległości – MBE, oraz odchylenie standardowe – σ (jeżeli parametry te nie zostaną zdefiniowane przy inicjalizacji systemu, to zostaną wykorzystane domyślne, przedstawiono je w poprzednim rozdziale). Definiowany jest również czas pomiędzy kolejnymi wymianami komunikatów w systemie (domyślna wartość wynosi $t_m = 1 \text{ ms}$). Ścieżkę ruchu pojazdu (samochodu czy modelu RC) postanowiono przybliżyć przez linie proste i łuki (promień skrętu w pojazdach jest ograniczony). Zamodelowanie ruchu przy pomocy prostych i łuków pozwala na prostą adaptację scenariusza wirtualnego w rzeczywistych warunkach np. przez kierowcę lub obiekt typu AGV. Tak więc ruch pojazdu modelowany jest przez połączenie ze sobą fragmentów ścieżki składającej się z prostych i łuków, jednakże zmienna trajektoria ruchu nie jest jedynym wyznacznikiem z ilu krzywych będzie składała się droga. Należy wziąć pod uwagę również zmianę przyspieszenia. Dzieląc ścieżkę na fragmenty definiuje się następujące parametry:

a) inicjalizacja:

- współrzędne początkowe – (x_0, y_0) [m],
- prędkość początkową – v_0 [m/s],
- początek ruchu – t_0 [s],
- koniec ruchu – t_k [s],

b) ścieżka po prostej:

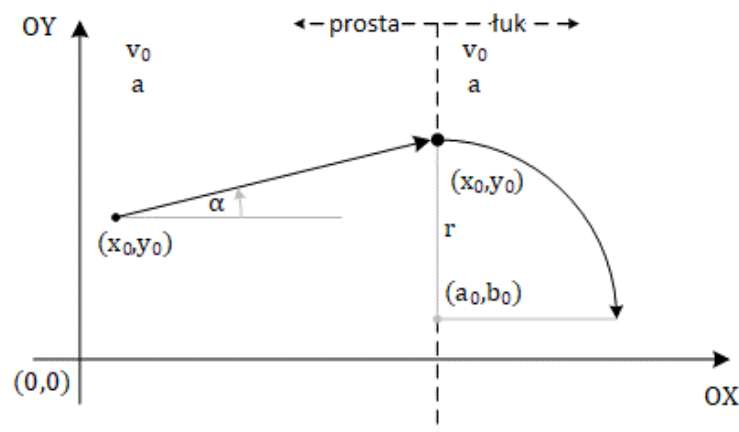
- kierunek poruszania się obiektu (w ruchu po prostej), jako kąt w stosunku do dodatniej osi X w lokalnym układzie współrzędnych – α [rad],
- przyspieszenie (może być stałe lub zmienne wyrażone w funkcji czasu – co wpływa na funkcje opisujące współrzędne obiektu, rozważania ograniczona do przyspieszenia stałego na danym odcinku) – a [m/s²],

c) ścieżka po łuku:

- środek okręgu – (a_0, b_0) [m],
- promień skrętu (okręgu) – r [m],

- kierunek rotacji,
- kąt punktu początkowego w stosunku do dodatniej osi X w lokalnym układzie współrzędnych – α_0 [rad],
- przyspieszenie styczne (może być stałe lub zmienne wyrażone w funkcji czasu – co wpływa na funkcje opisujące współrzędne obiektu, rozważania ograniczona do przyspieszenia stałego na danym odcinku) – a [m/s²].

Tworząc ścieżkę należy zadbać, aby koniec fragmentu wcześniejszego był początkiem fragmentu następnego (patrz rys. 29), tak więc punkt początkowy i prędkość początkowa fragmentu następnego jest punktem końcowym i prędkością końcową fragmentu wcześniejszego ($x_0 = x_{k_i}$, $y_0 = y_{k_i}$, $v_0 = v_{k_i}$) i czas rozpoczęcia ruchu fragmentu następnego jest czasem końca fragmentu poprzedniego ($t_0 = t_{k_i}$).



Rys. 29. Parametry fragmentów ścieżki referencyjnej (prostych i łuków)

Krzywe (proste i łuki) opisujące drogę zaimplementowano w funkcji czasu, zakładając stałe przyspieszenie ($a = const$). W kontekście prostych, korzystając ze wzoru na drogę w ruchu jednostajnie przyspieszonym (22) oraz z funkcji trygonometrycznych (23) i (24) można wyznaczyć współrzędne obiektu w funkcji czasu (25) i (26).

$$s = v_0 t + \frac{1}{2} a t^2 \quad (22)$$

$$\sin(\alpha) = \frac{y}{s} \quad (23)$$

$$\cos(\alpha) = \frac{x}{s} \quad (24)$$

$$x(t) = x_0 + \cos(\alpha) \left(v_0 t + \frac{1}{2} a t^2 \right) \quad (25)$$

$$y(t) = y_0 + \sin(\alpha) \left(v_0 t + \frac{1}{2} a t^2 \right) \quad (26)$$

W kontekście łuków, korzystając ze wzoru na drogę w ruchu jednostajnie przyspieszonym (22), z równania parametrycznego okręgu (27) oraz wzoru na długość łuku (28) otrzymywane są współrzędne obiektu w funkcji czasu (29) i (30) poruszającego się po łuku (przeciwie do ruchu wskazówek zegara) o zadanym promieniu.


$$\begin{cases} x = a_0 + r \cos(\alpha) \\ y = b_0 + r \sin(\alpha) \end{cases} \quad (27)$$

$$s = r\alpha \quad (28)$$

$$x(t) = a_0 + r \cos \left(\alpha_0 \pm \frac{v_0 t + \frac{1}{2} a t^2}{r} \right) \quad (29)$$


$$y(t) = b_0 + r \sin \left(\alpha_0 \pm \frac{v_0 t + \frac{1}{2} a t^2}{r} \right) \quad (30)$$

W zależności od punktu zaczepienia łuku z poprzednim fragmentem ścieżki (punktu startowego (x_0, y_0)) i kierunku poruszania się, należy zmodyfikować kąt we wzorach (29) i (30). Przykładowe modyfikacje z dokładnością do $\frac{\pi}{2}$ przedstawiono na rys. 30.a dla ruchu zgodnego z ruchem wskazówek zegara, a na rys. 30.b dla ruchu przeciwnego do ruchów wskazówek zegara.



Rys. 30. Zmiana punktu startowego łuku (z dokładnością do 90°) dla ruchu zgodnego z ruchem wskazówek zegara (a) oraz dla ruchu przeciwnego do ruchu wskazówek zegara (b).

Przykładowo (patrz rys. 31) dla punktu startowego znajdującego się pod kątem $\frac{\pi}{2}$ i ruchu zgodnego z ruchem wskazówek zegara (ruch w I ćwiartce), wzór (29) przyjmuje postać (31), a wzór (30) przyjmuje postać (32).



Rys. 31. Przykładowy ruch po okręgu zgodnie z ruchem wskazówek zegara rozpoczynający się w kącie 90° .

$$x(t) = a_0 + r \cos\left(\frac{\pi}{2} - \frac{v_0 t + \frac{1}{2} a t^2}{r}\right) \quad (31)$$

$$y(t) = b_0 + r \sin\left(\frac{\pi}{2} - \frac{v_0 t + \frac{1}{2} a t^2}{r}\right) \quad (32)$$


Korzystając z równania parametrycznego okręgu (27) oraz punktu początkowego wyznaczane są współrzędne środka okręgu (33) i (34) na podstawie, którego budowany jest łuk.

$$a_0 = x_0 - r \cos(\alpha_0) \quad (33)$$

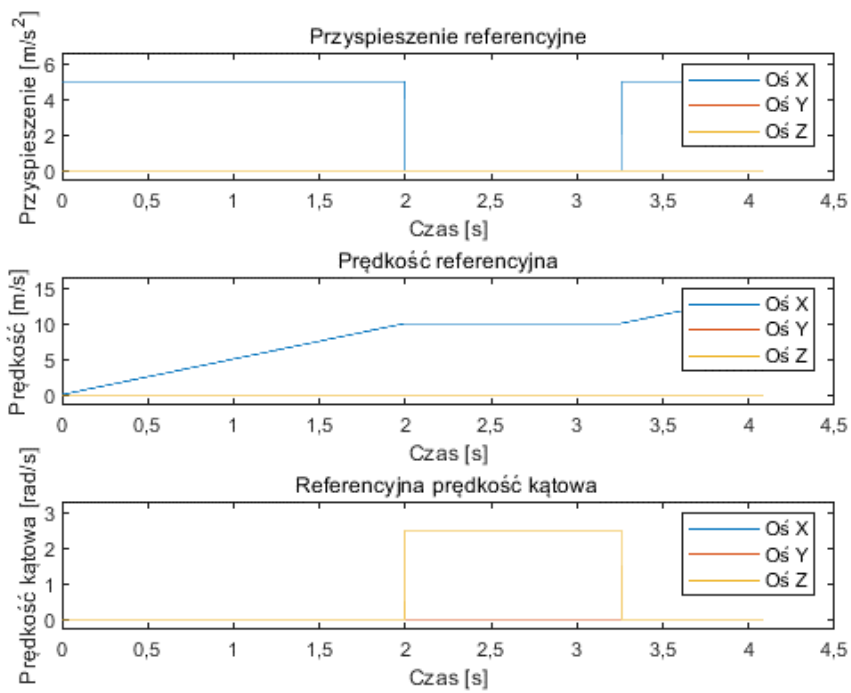
$$b_0 = y_0 - r \sin(\alpha_0) \quad (34)$$

3.4 Przykładowa ścieżka referencyjna

Na podstawie wprowadzonego we wcześniejszym rozdziale opisu scenariusza testowego wyznaczona zostanie przykładowa ścieżka ruchu obiektu. Parametry wykorzystane do budowy ścieżki wraz z jej przebiegiem przedstawiono na rys. 32. Liczba punktów definiujących ścieżkę jest uzależniona od czasu, który przyjęto na wykonanie pojedynczej wymiany informacji pomiędzy dwoma węzłami UWB (domyślnie wartość ta została ustalona na $t_m = 1 \text{ ms}$) oraz aktualnej prędkości (wraz ze wzrostem prędkości odległość pomiędzy kolejnymi pozycjami na ścieżce będzie wzrastać). Dodatkowo dla ścieżki wyznaczone są dane referencyjne o prędkości, przyspieszeniu, prędkości kątowej dla każdej z osi (dane te dla powyższej ścieżki zaprezentowano na rys. 33).



Rys. 32. Przykładowa ścieżka referencyjna składająca się z prostych i łuku



Rys. 33. Prędkość, przyspieszenie i prędkość kątowa dla przykładowej ścieżki

3.5 Wyznaczenie odległości

Po zdefiniowaniu parametrów modelu systemu UWB oraz scenariusza testowego wyznaczone są odległości dla każdego punktu na ścieżce referencyjnej – odległości euklidesowe pomiędzy znacznikiem a każdą z kotwic umieszczoną na płaszczyźnie testowej (35). Obliczone odległości są wartościami dokładnymi i są wykorzystywane w dalszej analizie jako wartość referencyjna podczas testowania opracowanych algorytmów.

$$d_{k,i} = \sqrt{(x_{A_k} - x_{T_i})^2 + (y_{A_k} - y_{T_i})^2} \quad (35)$$

gdzie: (x_{A_k}, y_{A_k}) – współrzędne k -tej kotwicy, (x_{T_i}, y_{T_i}) – i -ta współrzędna znacznika.

Na podstawie wcześniej wyznaczonych funkcji opisujących model (średniego błędu systematycznego odległości – MBE oraz odchylenia standardowego – σ) do wartości referencyjnej odległości dodawany jest szum zgodnie ze wzorem (36).


$$d'_{k,i} = d_{k,i} + MBE_{d_{k,i}} + R\sigma_{d_{k,i}} \quad (36)$$

gdzie: $d_{k,i}$ – odległość pomiędzy k -tą kotwicą a i -tym punktem na ścieżce, $MBE_{d_{k,i}}$ – średni błąd systematyczny odpowiadający wyznaczonej odległości referencyjnej, R – zmienna losowa o standardowym rozkładzie normalnym, $\sigma_{d_{k,i}}$ – odchylenie standardowe odpowiadające wyznaczonej odległości referencyjnej.

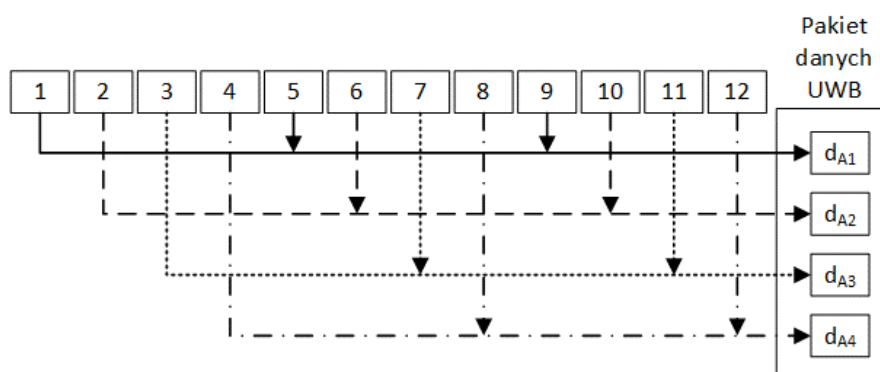
Na rys. 34 zaprezentowano przykładowy fragment ścieżki referencyjnej wraz z zasymulowanymi odległościami z systemu UWB, które zaprezentowano w postaci okręgów o promieniu zgodnym z otrzymaną odległością (odległości te pozyskano dla punktu zaznaczonego niebieskim znacznikiem). Otrzymane dystanse pozwalają na wyznaczenie pozycji obiektu w procesie trilateracji. Można zaobserwować, że okręgi nie przecinają się w jednym punkcie, tak więc jak już wspomniano wcześniej – idealny przypadek w procesie trilateracji nie występuje.

W odwzorowywanym systemie do wyznaczania odległości wykorzystywany jest schemat TWR. Pomiędzy znacznikiem a wybraną kotwicą wysyłane są trzy wiadomości, na podstawie, których wyznaczany jest ToF. Podczas gdy obiekt jest w ruchu jego pozycja ulega zmianie co z kolei wpływa na odległość pomiędzy znacznikiem a kotwicą. W efekcie na końcową wartość ToF wpływają czasy odpowiadające odległościom, które wyznaczono w poprzednich pozycjach, w których znajdował się obiekt będący w ruchu. Otrzymane odległości (w przykładowym systemie z 4 najbliższych kotwic) udostępniane są w postaci pakietu danych w stałych odstępach czasu. W celu odwzorowania tego mechanizmu w opracowanym symulatorze przyjęto stały czas

otrzymywania informacji od punktów referencyjnych na poziomie $t_m = 1 \text{ ms}$ (parametr ten można zmienić podczas konfiguracji systemu) i wyznaczono okno czasowe odpowiadające 12 pomiarom odległości (dla przyjętego czasu pojedynczego wymiarowania – $t_m = 1 \text{ ms}$, pakiet danych udostępniany jest co $t_p = 12 \text{ ms}$). W celu odzwierciedlenia ruchu obiektu odległość w ramce do pojedynczej kotwicy jest średnią arytmetyczną z 3 odległości pozyskanych z symulacji (rys. 35). W oknie czasowym ($t_p = 12 \text{ ms}$) wybierane są 4 punkty referencyjne, które znajdują się najbliżej w stosunku do pierwszej pozycji w oknie czasowym. Dla najbliższego z wybranych punktów referencyjnych do średniej wchodzi odległości pozyskane w 1, 5 i 9 ms, a dla najdalszej kotwicy odległości pozyskane w 4, 8 i 12 ms okna czasowego t_p . Tak pozyskane średnie odległości w oknie czasowym udostępniane są w formie pakietu danych zawierającego odległości (uwzględniające ruch obiektu) do 4 najbliższych kotwic $\{d_{A1}, d_{A2}, d_{A3}, d_{A4}\}$.



Rys. 34. Odległości dla przykładowego punktu na ścieżce referencyjnej




Rys. 35. Tworzenie pakietu danych UWB

Pakiet danych z systemu UWB następnie przetwarzany jest w kolejnych etapach analizy danych, gdzie w efekcie końcowym otrzymywana jest pozycja obiektu w lokalnym układzie odniesienia. Możliwe jest również ustawienie pakietowej stopy błędów w związku z czym nie wszystkie pakiety danych UWB opuszczają symulator.

3.6 Wprowadzanie przeszkód i detekcja warunków LOS, NLOS

Ostatnim elementem opisującym przygotowywany scenariusz testowy są przeszkody, które należy dodać do symulowanego stanowiska pomiarowego. Budowa przeszkody opiera się o jej opis funkcjami liniowymi lub nieliniowymi w zależności od kształtu. Wysokość przeszkody nie jest brana pod uwagę – zakłada się, że dodana przeszkoda jest wysokości powodującej wygenerowanie warunków NLOS, w związku z czym wykrywanie przeszkody ogranicza się do przestrzeni dwuwymiarowej. Znajomość kształtu przeszkody i jej umiejscowienie pozwala sprawdzić czy transmisja pomiędzy dwoma węzłami w sieci odbywa się w warunkach LOS czy NLOS. Przykładową przeszkodę umiejscowioną na płaszczyźnie zaprezentowano na rys. 36. Do opisu przeszkody wykorzystywane są funkcje, które tworzą układ nierówności (37), tym samym wyznaczają płaszczyznę, na której znajduje się przeszkoda.



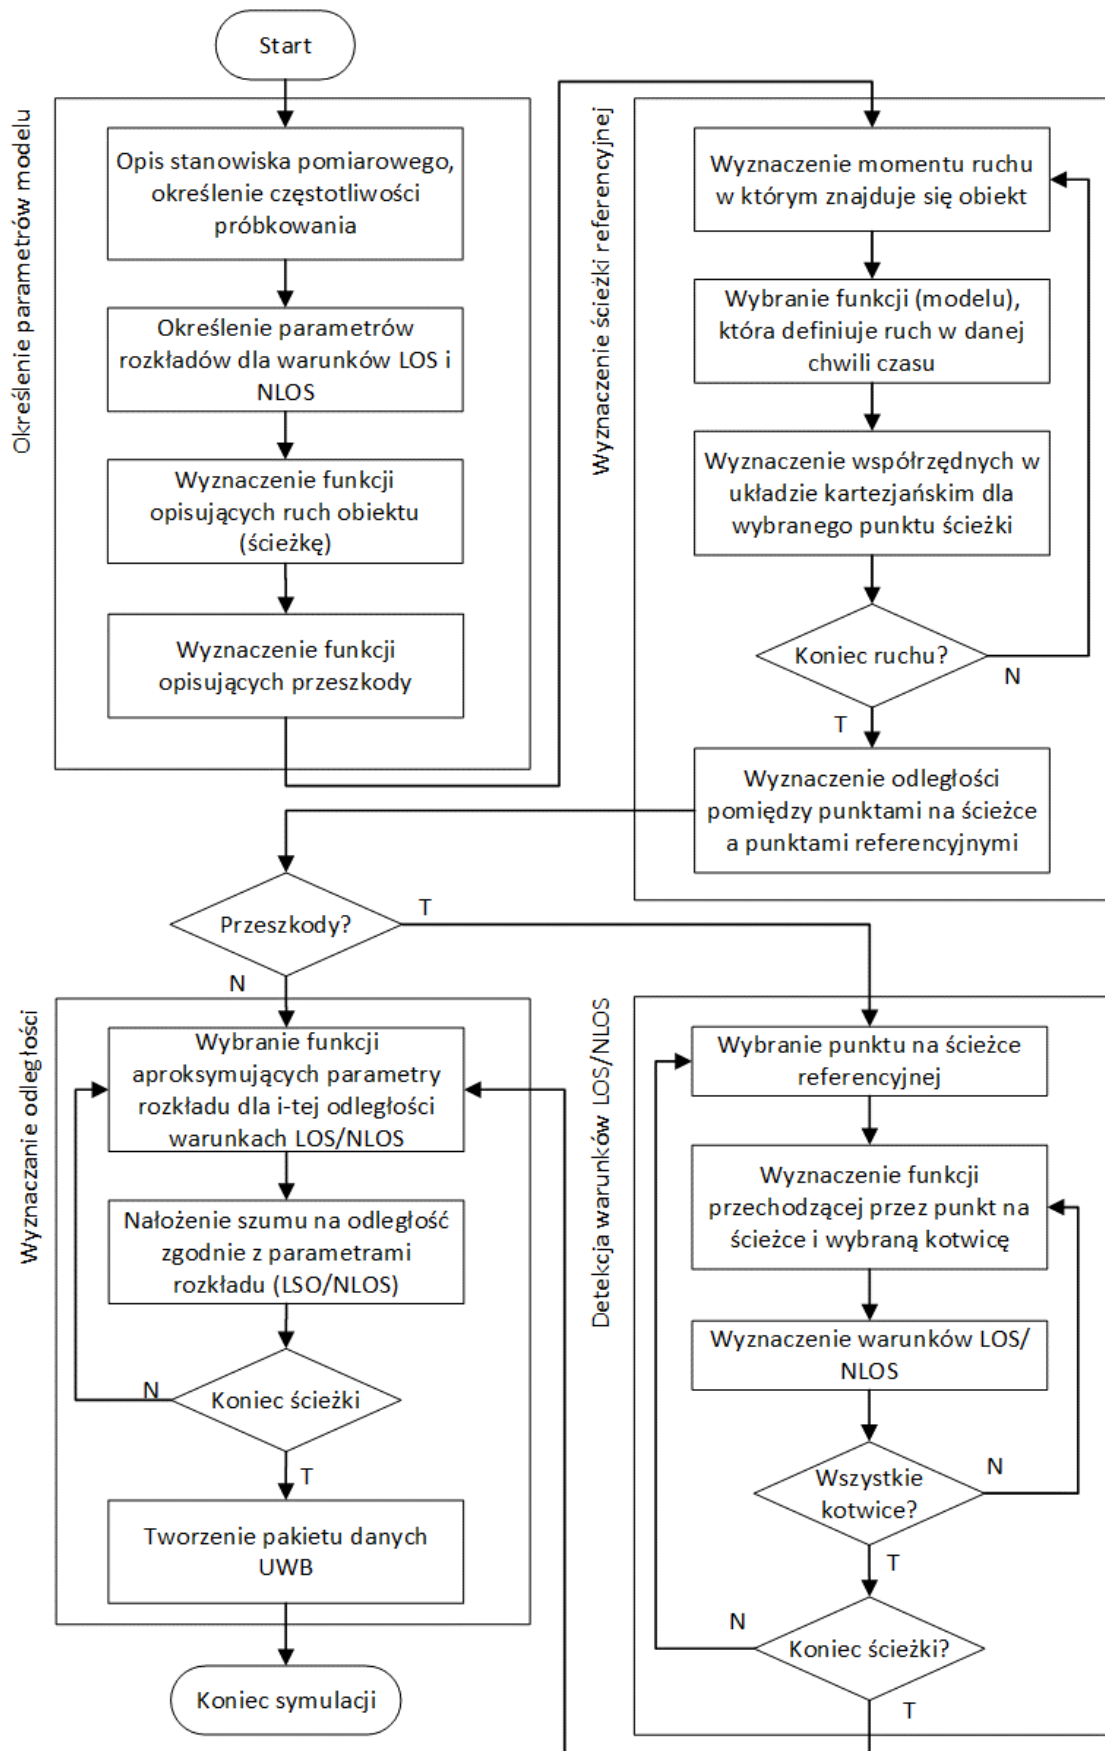
Rys. 36. Przykładowy opis przeszkody i detekcja NLOS dla wybranego punktu na ścieżce

$$\begin{cases} y \geq \frac{1}{2} \sin(2x) + 6 \\ y \leq 8 \\ x \geq -2,5 \\ x \leq 4 \\ y = -1,2x + 10 \end{cases} \quad (37)$$

Znając położenie przeszkody należy sprawdzić dla każdej z pozycji na ścieżce czy prosta przechodząca przez znacznik i wybraną kotwicę przechodzi przez przeszkodę (należy sprawdzić czy prosta ma co najmniej jeden punkt wspólny z przeszkodą). Możliwe jest rozwiązanie układu nierówności (37) i wyznaczenie grupy możliwych rozwiązań (zbiór wartości). Jednakże celem tego zadania jest wyznaczenie czy aktualnie badana odległość została wyznaczona w warunkach LOS czy NLOS w związku z czym nie jest ważna dokładna grupa rozwiązań, a jedynie to czy jakiegokolwiek rozwiązanie istnieje. Ograniczając się jedynie do zbadania czy istnieje rozwiązanie – punkt wspólny pomiędzy prostą przechodzącą przez badaną pozycję i wybrany punkt referencyjny oraz przeszkodę, zadanie to należy potraktować jako problem optymalizacyjny. Jeżeli rozwiązanie nie jest znalezione oznacza to, że odległość jest wyznaczona w warunkach LOS natomiast jeżeli rozwiązanie jest znalezione oznacza to, że odległość jest wyznaczona w warunkach NLOS. Jeżeli do opisu przeszkody wykorzystane zostały jedynie funkcje liniowe to problem optymalizacji rozwiązywany jest w oparciu o algorytm sympleksowy [100]. Natomiast jeżeli przeszkoda opisana jest przez funkcje nieliniowe to do optymalizacji wykorzystywana jest funkcja oparta na gradiencie [101]. Z uwagi na to, że są to algorytmy iteracyjne ich czas działania zależy od dobranych parametrów (np. liczby iteracji, minimalna wartość kroku, minimalna zmiana wartości funkcji). Liczba wykonywanych testów (detekcji warunków LOS, NLOS) zależy od liczby punktów na ścieżce, kotwic oraz przeszkód. W celu przyspieszenia obliczeń, nie licząc doboru parametrów stopu algorytmu, obliczenia zostały zrównoleżone przez podzielenie punktów na ścieżce w grupy, skracając tym samym czas symulacji (jest to możliwe wyłącznie w warunkach symulacyjnych).

3.7 Podsumowanie symulatora systemu UWB

W przedstawionym podrozdziale zaproponowano i stworzono symulator systemu UWB, który odzwierciedla działanie systemu rzeczywistego. W momencie rozpoczęcia prac badawczych takie narzędzie nie było dostępne, przez co proces dokładnej analizy pozyskanych danych był niemożliwy. Zaprezentowana analiza danych z rzeczywistego systemu UWB (traktując go jako „czarną skrzynkę”) pozwala w łatwy sposób opisać pracę dowolnego systemu UWB charakteryzującego się taką samą lub podobną strukturą wymiany informacji pomiędzy węzłami i jest łatwa do powtórzenia z wykorzystaniem innego systemu UWB. Modułowa budowa symulatora pozwala na jego prostą modyfikację, jeżeli zajdzie taka potrzeba (szczegółowy diagram przepływu zaprezentowano na rys. 37), a kolejne etapy mogą być przeprowadzone niezależnie.



Rys. 37. Diagram przepływu symulatora

Zaproponowany opis scenariusza testowego pozwala w stosunkowo prosty sposób przenieść wirtualny scenariusz testowy na rzeczywiste stanowisko pomiarowe. W przyjętych rozważaniach budowę ścieżki referencyjnej ograniczono do prostych i łuków, jednakże możliwe jest wykorzystanie dowolnej krzywej opisanej w dziedzinie czasu do opisu ruchu. Przedstawione funkcje zakładają również stałe przyspieszenie obiektu, jednakże możliwe jest również zadanie funkcji dla ruchu ze zmiennym przyspieszeniem. Dystanse pomiędzy znacznikiem a kotwicami otrzymywane z systemu UWB udostępniane są w stałych odstępach czasu. Podczas ruchu obiektu dystanse te nawiązują do pozycji z chwili, w której zostały pozyskane, a nie do pozycji, w której zostały opublikowane. Wynika to ze sposobu komunikacji pomiędzy węzłami w sieci i został on również zamodelowany w procesie tworzenia pakietu danych. Stworzony symulator dostarcza dokładną wartość referencyjną, o którą trudno w warunkach terenowych (od której oczekuje się dokładności rzędu milimetrów). Dane referencyjne ułatwiają proces przygotowania np.: systemów decyzyjnych, czy systemów i algorytmów przetwarzania danych z systemu UWB, których celem jest np. zwiększenie dokładności wyznaczonej pozycji obiektu.

Korzyści płynące z budowy symulatora nie tylko wpływają na dokładną analizę wyników, ale również pozwalają zaoszczędzić czas, który należy poświęcić na testy w rzeczywistych warunkach oraz umożliwiają kontynuowanie prac w sytuacjach, gdy dostęp do infrastruktury testowej jest ograniczony np.: przez warunki pogodowe, ograniczenia wynikające z pandemii COVID19. Symulator w łatwy sposób pozwala opisać różne scenariusze testowe i wygenerować wyniki odzwierciedlając rzeczywisty system pozycjonujący – odwzorowanie systemu ze średnim błędem na poziomie 21% zarówno dla MBE jak i odchylenia standardowego. Symulator umożliwia analizę ścieżek trudnych do uzyskania w warunkach rzeczywistych ze względów bezpieczeństwa, czy kosztów (kolizje). Ponadto symulator umożliwia definiowanie przeszkód na płaszczyźnie testowej przez co możliwa jest również analiza wpływu przeszkody (warunków NLOS) na dokładność wyznaczonej pozycji w dalszych pracach nad pozycjonowaniem obiektów.

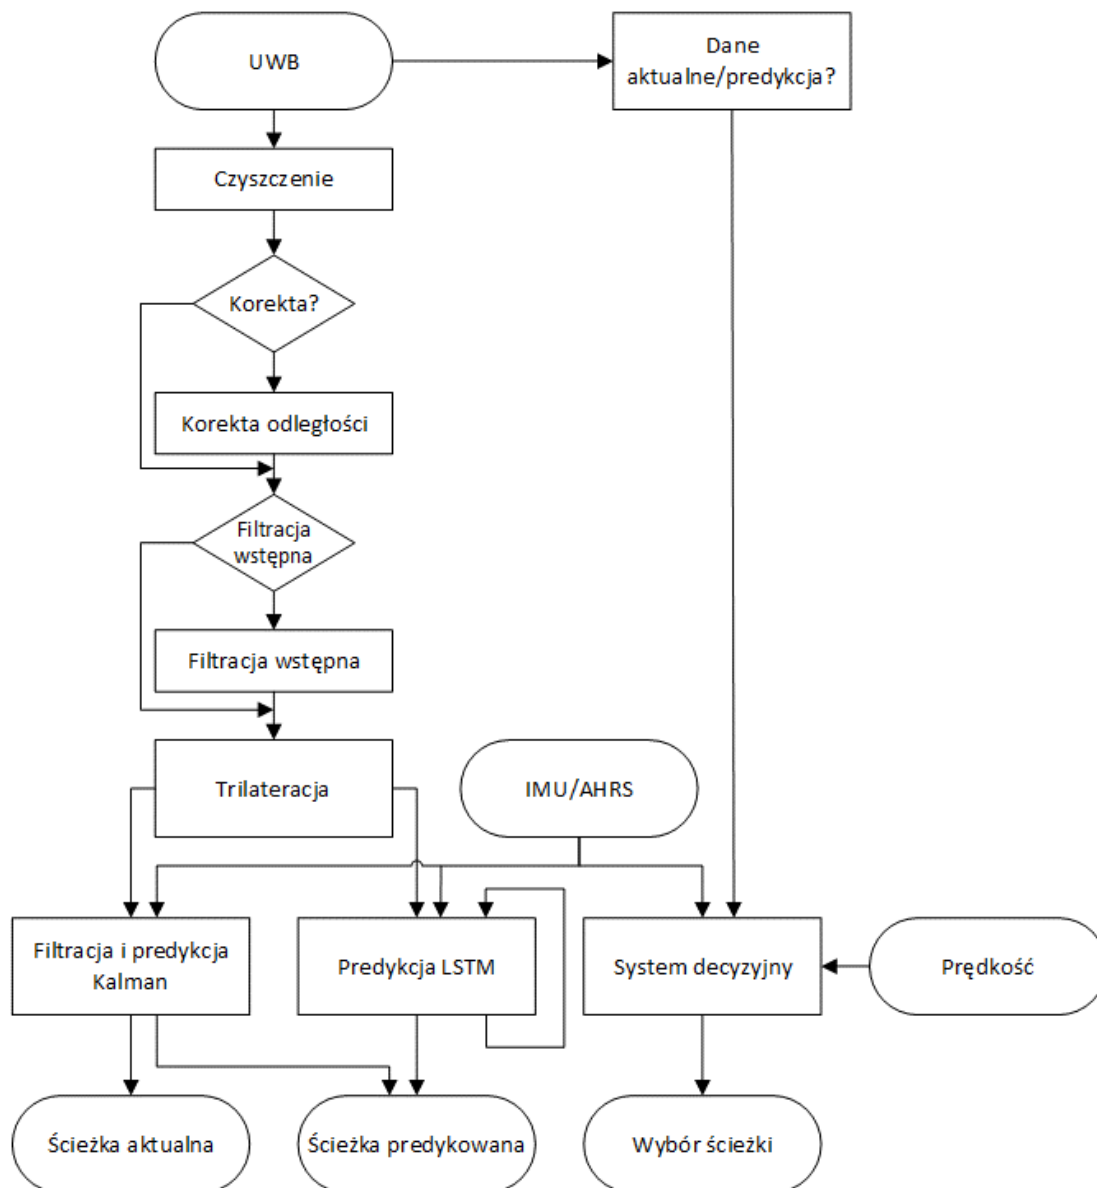
4 System wyznaczania i wyboru ścieżki

Dane pochodzące z różnych systemów charakteryzują się różną częstością pozyskiwania danych, innym typem błędów czy dokładnością. Z uwagi na niedoskonałości systemu UWB w postaci błędów w procesie wymiarowania wymagana jest analiza otrzymywanych odległości, która w efekcie końcowym prowadzić ma do wyznaczenia pozycji obiektu. Tak więc potrzebne są metody, które pozwolą zmniejszyć wpływ niedoskonałości systemu w procesie wyznaczania pozycji. Inteligencja obliczeniowa to szereg różnych metod (np.: sztuczne sieci neuronowe, logika rozmyta, algorytmy genetyczne, systemy ekspertowe, czy też systemy neuronowo rozmyte) do analizy i przetwarzania. Metody te wykorzystywane są do rozwiązywania zadań, które często trudno jest przedstawić w sposób algorytmiczny, proces jest zbyt złożony, aby w sposób efektywny go przetwarzać lub też klasyczne metody modelowania nie sprawdzają się. Na podstawie zebranych danych, otrzymanej wiedzy, czy faktów – pozyskuje się (odkrywa) nowe informacje, nową wiedzę.

Zauważono, że dane pozyskiwane z poszczególnych podsystemów są albo mocno zaszumione albo niepełne albo uzyskuje się dane przypadkowo przeszacowane lub niedoszacowane co wpływa na proces wyznaczania pozycji obiektu. W niniejszej pracy zaproponowano proces korekty odległości pozyskanej z systemu UWB w funkcji otrzymanej odległości z systemu. System UWB wprowadza przesunięcie, które wynika z czasu potrzebnego na wymiarowanie i które zależne jest od prędkości obiektu. Ponadto udostępnione przez system odległości do wybranych punktów pozyskiwane są w przeszłości – w poprzednich pozycjach, w których znajdował się poruszający się obiekt. W niniejszej pracy proponuje się wykorzystanie sztucznej sieci neuronowej typu LSTM (*ang. long short-term memory*) do predykcji pozycji w celu redukcji przesunięcia oraz minimalizacji wpływu chwilowych braków danych. Sieć LSTM może być wykorzystana zarówno do klasyfikacji jak i regresji. W kontekście pozycjonowania obiektów sieć tego typu wykorzystywana jest na różne sposoby np. do wyznaczania pozycji na bazie pozyskanych odległości obiektu z punktów referencyjnych [102], [103].

Proces przetwarzania danych podzielono na etap korekty i fuzji. W związku z czym proponuje się proces przetwarzania danych, który zaprezentowano na rys. 38. W początkowej fazie dane są oczyszczane z wartości wynikających z nieprawidłowego działania systemu. Następnie należy dane o odległościach skorygować i przefiltrować. Po przygotowaniu danych o odległościach do poszczególnych węzłów, należy wyznaczyć pozycję obiektu, która wraz z danymi z jednostki inercyjnej wykorzystywana jest do predykcji pozycji (z wykorzystaniem filtru

Kalmana lub sieci typu LSTM). Jednocześnie należy podjąć decyzję o tym, która ze ścieżek powinna być wykorzystana przez system nadrzędny.



Rys. 38. Diagram procesu analizy danych

Zakłada się, że dostępne są: system UWB udostępniający odległości do czterech węzłów referencyjnych (38), dane z sensorów inercyjnych: akcelerometru, żyroskopu i magnetometru w osi X, Y, Z (39) oraz prędkość obiektu v . Na wyjściu systemu dostępne są informacje o pozycji na płaszczyźnie na ścieżce aktualnej (40) i ścieżce predykowanej (41) oraz informacja o tym, czy system nadrzędny powinien wybrać pozycję ze ścieżki aktualnej, predykowanej czy też dane nie są wiarygodne. Zaproponowana analiza uwzględnia czas potrzebny na wykonanie najważniejszych jej etapów w celu określenia wpływu na przesunięcie obiektu.

$$D = \{d_{A1}, d_{A2}, d_{A3}, d_{A4}\} \quad (38)$$

gdzie: d_{Ai} – odległość pomiędzy znacznikiem a i -tym węzłem.

$$A = \{a_x, a_y, a_z, g_x, g_y, g_z, m_x, m_y, m_z\} \quad (39)$$

gdzie: a_x, a_y, a_z – dane z akcelerometru odpowiednio w osi X, Y oraz Z ; g_x, g_y, g_z – dane z żyroskopu odpowiednio w osi X, Y oraz Z ; m_x, m_y, m_z – dane z magnetometru odpowiednio w osi X, Y oraz Z .

$$P = \{x, y\} \quad (40)$$

gdzie: x – współrzędna w osi X pozycji na ścieżce aktualnej; y – współrzędna w osi Y pozycji na ścieżce aktualnej.

$$P_p = \{x_p, y_p\} \quad (41)$$

gdzie: x_p – współrzędna w osi X pozycji na ścieżce predykowanej; y_p – współrzędna w osi Y pozycji na ścieżce predykowanej.

4.1 Przygotowanie danych z dostępnych systemów

Analiza wstępna, korekta i filtracja danych pozwalają na usunięcie przypadkowych błędów systemu czy niedokładności pomiarowych wykorzystywanego urządzenia lub czujnika. Na pomiar ma wpływ wiele czynników począwszy od czynników produkcyjnych danego urządzenia pomiarowego po czynniki środowiskowe, które występują w chwili pomiaru. Nie bez znaczenia jest również sama kalibracja urządzenia pomiarowego w celu usunięcia np. stałego przesunięcia pomiarów (*ang. bias*). Skupiając się na danych z systemu UWB, na dokładność wyznaczanych odległości mają wpływ warunki otoczenia, które mogą generować odbicia sygnału, czy też jego tłumienie (np. przechodząca osoba, przejeżdżający pojazd na linii węzłów systemu UWB), czy też błędy w pomiarze odległości. Czas każdego z etapów w procesie pozyskiwania i przetwarzania danych powinien być znany, aby oszacować możliwe przemieszczenie obiektu z nim związane. W tym celu przeanalizowane zostaną czasy poszczególnych etapów przetwarzania w procesie wyznaczania pozycji oraz wyznaczone zostaną możliwe przesunięcia obiektu w zależności od prędkości poruszania się.

4.1.1 Czyszczenie danych

Czyszczenie danych wykorzystywane jest do usuwania wartości błędnych pozyskanych danych. System UWB z uwagi na sposób wymiarowania (wymiana kilku komunikatów pomiędzy węzłami) może nie dostarczyć odległości w wyznaczonym oknie czasowym lub też nie wszystkie

odległości będą dostępne. W niniejszej pracy wartości błędne odległości (wartości równe zero lub wykraczające poza obszar testowy) zastępowane są przez wartość poprzednią z danego węzła (42):

$$d'_{k,i} = \begin{cases} d_{k,i} & \text{dla } 0 < d_{k,i} < d_{max} \\ d_{k,i-1} & \text{dla } d_{k,i} = 0 \wedge d_{k,i} \geq d_{max} \end{cases} \quad (42)$$


gdzie: $d_{k,i}$ – i -ta odległość pomiędzy k -tą kotwicą a znacznikiem; d_{max} – maksymalna możliwa odległość w lokalnym układzie odniesienia.

4.1.2 Filtracja wstępna

Filtry fundamentalne z kroczącym oknem takie jak filtr uśredniający, medianowy, Savitzky-Golay, czy filtr Hampel'a dobrze eliminują przypadkowe błędy systemu, jak i niedokładności jakimi charakteryzuje się dany system pomiarowy [97]. W kontekście pozycjonowania filtry tego typu z uwagi na przesuwne okno (patrz rys. 39) dostarczają dane przefiltrowane z opóźnieniem – otrzymywana pozycja w danym momencie dotyczy pozycji z przeszłości, a nie pozycji aktualnej co wynika z długości zastosowanego okna (43):


$$t_f = \left\lfloor \frac{N}{2} \right\rfloor \cdot \Delta t \quad (43)$$

gdzie: N – długość okna; Δt – czas pomiędzy kolejnymi odczytami z systemu.



Rys. 39. Opóźnienie filtra z przesuwym oknem

Oczywistym jest, że okno filtra wprowadza opóźnienie wynikające z liczby próbek (w kontekście UWB będą to pakiety danych z systemu), które wykorzystywane są w oknie, jednak ze względu na specyfikę zastosowania (wyznaczanie pozycji w akceptowalnym czasie) istotne jest określenie zależności przemieszczenia w funkcji prędkości i długości okna. W tym celu przeprowadzono analizę, która pozwala określić maksymalne możliwe przemieszczenie dla czasu akwizycji danych z systemu $t_p = 12 \text{ ms}$ – wyniki zaprezentowano na rys. 40.



Rys. 40. Przeszczenie obiektu w zależności od długości okna wykorzystanego filtra

Przy dużych prędkościach zastosowanie tego typu filtrów w systemach czasu rzeczywistego nie jest dobrym rozwiązaniem, ponieważ maksymalne możliwe przeszczenie poruszającego się obiektu (zmiana pozycji) jest równoważne z iloczynem prędkości i czasu potrzebnego na akwizycję danych w liczbie odpowiadającej połowie długości okna filtra (nie licząc próbek bieżącej), co przekłada się na znaczące (od kilkudziesięciu centymetrów do kilku metrów) przesunięcia obiektu – dla okna filtra o długości 19 próbek pojazd poruszający się z prędkością 20 m/s przesunie się o ponad 2 m. Natomiast przy małych prędkościach poruszania się obiektu, gdzie odległości pomiędzy kolejnymi pozycjami są małe, ich zastosowanie może okazać się wystarczające tak samo jak w analizie danych poza systemem (nie w czasie rzeczywistym). Przykładowo dla okna 7 próbek i obiektu typu AGV poruszającego się z prędkością 2 m/s skutkować będzie przeszczeniem o 7 cm co można uznać za akceptowalne.

4.1.3 Filtr komplementarny

Filtr Kalmana jest filtrem rekursywnym, czyli informacje przetwarzane są sukcesywnie wraz z kolejnymi krokami na bazie danych z kroku poprzedniego. Filtr znalazł szerokie zastosowanie wszędzie tam, gdzie analizowane są sygnały z sensorów, a w szczególności w nawigacji pojazdów, czy robotów [104], [105]. Filtr ten jest bardzo dobrym estymatorem pomimo wykorzystania danych z systemów, które są zaszumione. Filtr ten można podzielić na dwie fazy: aktualizację czasu (predykcję) oraz aktualizację pomiaru (korekcję).

Ogólna postać równania stanu (modelu procesu) przyjmuje formę (44) – predykcja a priori:

$$\hat{\mathbf{x}}_{n+1,n} = \mathbf{F}\hat{\mathbf{x}}_{n,n} + \mathbf{G}\mathbf{u}_n + \mathbf{w}_n \quad (44)$$

gdzie: $\hat{\mathbf{x}}_{n+1,n}$ – predykcja wektor stanu w kroku $n + 1$, wykonana w kroku n , uwzględniająca pomiar \mathbf{z}_n ; $\hat{\mathbf{x}}_{n,n}$ – estymata wektor stanu w kroku n , uwzględniająca pomiar \mathbf{z}_n ; \mathbf{F} – macierz transformacji stanu, macierz przejścia (*ang. state transition matrix*); \mathbf{G} – macierz transformacji wejścia (*ang. control matrix*); \mathbf{u}_n – zmienne wejściowe (*ang. control variable*); \mathbf{w}_n – szum procesowy (*ang. process noise*) – niemierzalna część wejścia wpływająca na stan.

Macierz pomiarów (wyjścia) dana jest przez (45):

$$\mathbf{z}_n = \mathbf{H}\mathbf{x}_n + \mathbf{v}_n \quad (45)$$

gdzie: \mathbf{z}_n – wektor pomiarów (*ang. output vector*); \mathbf{H} – macierz wyjścia (*ang. observation matrix*); \mathbf{v}_n – wektor szumu pomiarowego (*ang. measurement noise vector*).

Macierz kowariancji a priori przyjmuje postać (46):

$$\mathbf{P}_{n+1,n} = \mathbf{F}\mathbf{P}_{n,n}\mathbf{F}^T + \mathbf{Q} \quad (46)$$

gdzie: $\mathbf{P}_{n+1,n}$ – predykcja macierzy niepewności w kroku następnym $n + 1$ wykonana w kroku aktualnym (*ang. estimate uncertainty*); $\mathbf{P}_{n,n}$ – estymata macierzy niepewności w kroku bieżącym n ; \mathbf{F} – macierz transformacji stanu (*ang. state transition matrix*); \mathbf{Q} – macierz szumu procesowego (*ang. process noise uncertainty*).

Równanie aktualizacji stanu (*ang. state update equation*) ma postać (47):

$$\hat{\mathbf{x}}_{n,n} = \hat{\mathbf{x}}_{n,n-1} + \mathbf{K}_n(\mathbf{z}_n - \mathbf{H}\hat{\mathbf{x}}_{n,n-1}) \quad (47)$$

gdzie $\hat{\mathbf{x}}_{n,n}$ – estymowany wektor stanu w kroku n ; $\hat{\mathbf{x}}_{n,n-1}$ – predykowany wektor stanu w kroku $n - 1$, czyli nie uwzględniający pomiaru \mathbf{z}_n ; \mathbf{K}_n – wzmacnienie Kalmana (*ang. Kalman gain*); \mathbf{z}_n – wektor pomiarów; \mathbf{H} – macierz pomiarów, macierz wyjścia (*ang. observation matrix*).

Równanie aktualizacji macierzy kowariancji dane jest wzorem (48):

$$\mathbf{P}_{n,n} = (\mathbf{I} - \mathbf{K}_n\mathbf{H})\mathbf{P}_{n,n-1}(\mathbf{I} - \mathbf{K}_n\mathbf{H})^T + \mathbf{K}_n\mathbf{R}_n\mathbf{K}_n^T \quad (48)$$

gdzie: $\mathbf{P}_{n,n}$ – estymata macierzy niepewności w kroku aktualnym n ; $\mathbf{P}_{n,n-1}$ – predykowana macierzy niepewności w kroku n wykonana w kroku poprzednim; \mathbf{K}_n – wzmacnienie Kalmana; \mathbf{H} – macierz obserwacji; \mathbf{R}_n – macierz niepewności pomiaru (*ang. measurement uncertainty*).

Wzmocnienie Kalmana (\mathbf{K}_n) przyjmuje postać (49):

$$\mathbf{K}_n = \mathbf{P}_{n,n-1} \mathbf{H}^T (\mathbf{H} \mathbf{P}_{n,n-1} \mathbf{H}^T + \mathbf{R}_n)^{-1} \quad (49)$$

gdzie: $\mathbf{P}_{n,n-1}$ – predykowana macierzy niepewności w kroku n wykonana w kroku poprzednim; \mathbf{H} – macierz obserwacji; \mathbf{R}_n – macierz niepewności pomiaru.

Do wyznaczenia macierzy: transformacji stanu \mathbf{F} , transformacji wejścia \mathbf{G} oraz szumu procesowego \mathbf{Q} i pomiaru \mathbf{R} (zakładając, że nie występuje korelacja pomiędzy zakłóceniami) wykorzystuje się odpowiednio wzory (50), (51), (52) i (53):

$$\mathbf{F} = e^{\mathbf{A}\Delta t} = \mathbf{I} + \mathbf{A}\Delta t \quad (50)$$

$$\mathbf{G} = \int_0^{\Delta t} e^{\mathbf{A}\Delta t} dt \cdot \mathbf{B} \quad (51)$$

$$\mathbf{Q} = E(\mathbf{w}\mathbf{w}^T) = \mathbf{G}\sigma_a^2\mathbf{G}^T \quad (52)$$

$$\mathbf{R} = E(\mathbf{v}\mathbf{v}^T) = \begin{bmatrix} \sigma_{x_1}^2 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sigma_{x_m}^2 \end{bmatrix} \quad (53)$$

gdzie: \mathbf{A} – macierz stanu systemu (*ang. system dynamics matrix*); \mathbf{B} – macierz wejścia (*ang. input matrix*); \mathbf{w} – szum procesowy; \mathbf{v} – szum pomiarowy; σ_a^2 – wariancja przyspieszenia.

W kontekście pozycjonowania znany jest model opisujący przemieszczenie, bazując na równaniu ruchu Newtona, który dla trzech wymiarów ma postać (54). Dla jednostajnego ruchu przyspieszonego wektor stanu przyjmie postać (55):

$$\begin{cases} x = x_0 + v_{x_0}\Delta t + \frac{1}{2}a_x\Delta t^2 \\ y = y_0 + v_{y_0}\Delta t + \frac{1}{2}a_y\Delta t^2 \\ z = z_0 + v_{z_0}\Delta t + \frac{1}{2}a_z\Delta t^2 \end{cases} \quad (54)$$

gdzie: x_0, y_0, z_0 – pozycje początkowe odpowiednio w osi X, Y oraz Z ; $v_{x_0}, v_{y_0}, v_{z_0}$ – prędkość początkowa w każdej z osi; a_x, a_y, a_z – przyspieszenie w każdej z osi.

$$\mathbf{x}_n = \begin{bmatrix} \hat{x}_n \\ \hat{\dot{x}}_n \\ \hat{y}_n \\ \hat{\dot{y}}_n \\ \hat{z}_n \\ \hat{\dot{z}}_n \end{bmatrix} \quad (55)$$

gdzie: x_n, y_n, z_n – pozycja obiektu w osi X, Y oraz Z ; $\dot{x}_n, \dot{y}_n, \dot{z}_n$ – prędkości w każdej z osi.

Zmienną wejściową będzie przyspieszenie w każdej z osi (56):

$$\mathbf{u}_n = \begin{bmatrix} ax_n \\ ay_n \\ az_n + g \end{bmatrix} \quad (56)$$

gdzie: ax_n – przyspieszenie w osi X ; ay_n – przyspieszenie w osi Y ; az_n – przyspieszenie w osi Z ; g – przyspieszenie ziemskie.

Zgodnie ze wzorami (50), (51) otrzymuje się odpowiednio macierze: transformacji stanu \mathbf{F} (57), transformacji wejścia \mathbf{G} (58) dla rozpatrywanego przypadku ruchu jednostajnie przyspieszonego. Macierze szumu procesowego \mathbf{Q} oraz szumu pomiarowego \mathbf{R} przyjmują postać odpowiednio (59) i (60):

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} + \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \Delta t = \begin{bmatrix} 1 & \Delta t & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & \Delta t & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (57)$$

$$\mathbf{G} = \Delta t \left(\begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} + \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \frac{\Delta t}{2} \right) \begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} =$$

$$= \begin{bmatrix} \Delta t & \frac{1}{2}\Delta t^2 & 0 & 0 & 0 & 0 \\ 0 & \Delta t & 0 & 0 & 0 & 0 \\ 0 & 0 & \Delta t & \frac{1}{2}\Delta t^2 & 0 & 0 \\ 0 & 0 & 0 & \Delta t & 0 & 0 \\ 0 & 0 & 0 & 0 & \Delta t & \frac{1}{2}\Delta t^2 \\ 0 & 0 & 0 & 0 & 0 & \Delta t \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} \frac{1}{2}\Delta t^2 & 0 & 0 \\ \Delta t & 0 & 0 \\ 0 & \frac{1}{2}\Delta t^2 & 0 \\ 0 & \Delta t & 0 \\ 0 & 0 & \frac{1}{2}\Delta t^2 \\ 0 & 0 & \Delta t \end{bmatrix} \quad (58)$$

$$\mathbf{Q} = \begin{bmatrix} \frac{1}{4}\Delta t^4 & \frac{1}{2}\Delta t^3 & 0 & 0 & 0 & 0 \\ \frac{1}{2}\Delta t^3 & \Delta t^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{4}\Delta t^4 & \frac{1}{2}\Delta t^3 & 0 & 0 \\ 0 & 0 & \frac{1}{2}\Delta t^3 & \Delta t^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & \frac{1}{4}\Delta t^4 & \frac{1}{2}\Delta t^3 \\ 0 & 0 & 0 & 0 & \frac{1}{2}\Delta t^3 & \Delta t^2 \end{bmatrix} \sigma_a^2 \quad (59)$$

$$\mathbf{R} = \begin{bmatrix} \sigma_a^2 & 0 & 0 \\ 0 & \sigma_x^2 & 0 \\ 0 & 0 & \sigma_z^2 \end{bmatrix} \quad (60)$$

gdzie: σ_a^2 – wariancja przyspieszenia; $\sigma_x^2, \sigma_y^2, \sigma_z^2$ – wariancje pozycji dla każdej z osi.

Macierz wyjścia przyjmuje postać (61), wybierając z wektora stanu jedynie pozycje w osi X, Y oraz Z .

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (61)$$


Tak zbudowany filtr pozwala na filtrację i jednoczesną fuzję danych z systemu UWB i IMU(AHRS). Podczas normalnej pracy filtru otrzymywana jest również predykcja pozycji obiektu o czym więcej w dziale 4.4.2. Filtr ten ma znacząca przewagę nad filtrami z przesuwym oknem z uwagi na czas przetwarzania, który wynosi $10,7 \mu s$ (dla komputera klasy PC o parametrach przedstawianych we wstępie w punkcie 1.5) co dla 2 m/s będzie skutkowało przemieszczeniem $0,02 \text{ mm}$, a dla 14 m/s przemieszczeniem $0,15 \text{ mm}$. Tak więc można stwierdzić, że filtracja filtrem Kalmana pozwala na predykcję pozycji obiektu nie wprowadzając znaczącego przesunięcia.

4.2 Korekta odległości


System UWB posiada zmienny błąd wymiarowania, który zmienia się wraz z odległością, w związku z czym proponuje się mechanizm korekty oparty na MBE, który odzwierciedla średni błąd systematyczny systemu [93], [98], [99], [106]. Testowane systemy charakteryzują się różną zmianą błędów w związku z czym korekta powinna być dostosowana do danego systemu indywidualnie.

Funkcje korekty zaproponowane w niniejszym rozdziale zostały zamodelowane na danych rzeczywistych z systemu UWB pozyskanych w pomiarach statycznych. Testy zaproponowanych funkcji korekty przetestowane zostaną z wykorzystaniem danych pochodzących z symulacji, w których obiekt jest w ruchu.

Zasymulowane zostały przejazdy obiektu ze stałą prędkością po torze o długości 45 m (patrz rys. 41), dla każdej pozycji na ścieżce dostępne są odległości do czterech punktów referencyjnych. Liczbę pozycji pozyskanych z systemu UWB ($t_p = 12 \text{ ms}$) dla każdego przejazdu (każdej prędkości poruszania się obiektu po torze z przedziału od $0,25 \text{ m/s}$ do 20 m/s z krokiem $0,25 \text{ m/s}$) przedstawiono na rys. 42.



Rys. 41. Ścieżka referencyjna do pomiaru dokładności funkcji korekty odległości



Rys. 42. Liczba pozycji na ścieżce i maksymalna odległość pomiędzy kolejnymi odczytami

Do zamodelowania korekty w funkcji odległości na danych rzeczywistych z systemu UWB zastosowano następujące funkcje:

- a) wielomiany stopnia pierwszego, drugiego, trzeciego oraz czwartego w postaci:

$$f(x) = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0 \quad (62)$$

gdzie: a_0, a_1, \dots, a_n – współczynniki wielomianu.

b) funkcje potęgowe w postaci:

$$f(x) = a_0 x^{a_1} \quad (63)$$

$$f(x) = a_0 x^{a_1} + a_2 \quad (64)$$

gdzie: a_0, a_1, a_2 – współczynniki funkcji potęgowej.


c) funkcje wykładnicze w postaci:

$$f(x) = a_0 e^{a_1 x} \quad (65)$$

$$f(x) = a_0 e^{a_1 x} + a_2 e^{a_3 x} \quad (66)$$

gdzie: a_0, a_1, a_2, a_3 – współczynniki funkcji wykładniczej.

W celu wybrania odpowiedniej funkcji aproksymującej MBE (patrz rys. 43) wyznaczono średni RMSE (kolumna 2), MBE (kolumna 3), minimalny (kolumna 4) i maksymalny (kolumna 5) błąd pozycji dla wszystkich prędkości (patrz tab. 12). Kolumny 6 i 7 zawierają odpowiednio minimalny i maksymalny błąd pozycji dla wszystkich przejazdów. Średnia wartość RMSE pozycji – wyznaczonej bez korekty, dla wszystkich przejazdów wynosi 17,93 cm, a maksymalny błąd 28,41 cm. Zastosowanie korekty odległości pozwala zmniejszyć RMSE wyznaczonej pozycji o ponad 10 cm w zależności od zastosowanej funkcji aproksymującej.



Rys. 43. Aproksymacja MBE w celu korekty odległości

Tab. 12. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja metodą sympleksową)


Korekta	$RMSE_{AVG}$ [cm]	MBE_{AVG} [cm]	$\epsilon_{Min_{AVG}}$ [cm]	$\epsilon_{Max_{AVG}}$ [cm]	$\epsilon_{Min_{min}}$ [cm]	$\epsilon_{Max_{max}}$ [cm]	Średni czas korekty [μ s]
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
Brak	17,93	17,48	4,01	24,19	1,04	28,41	-
poly1	6,97	6,60	2,15	12,90	0,01	19,99	0,61
poly2	6,88	6,51	2,01	12,57	0,02	19,74	0,64
poly3	6,90	6,55	2,22	12,53	0,01	19,63	0,63
poly4	6,98	6,61	2,04	12,91	0,00	20,03	0,64
power1	6,92	6,55	2,05	12,77	0,00	19,91	1,03
power2	6,93	6,56	2,03	12,80	0,01	19,95	1,04
exp1	7,07	6,70	2,22	13,11	0,01	20,14	0,66
exp2	6,99	6,61	2,03	13,05	0,01	20,17	0,79

Z przetestowanych funkcji najkorzystniejszym wyborem jest wielomian drugiego stopnia. Funkcja ta pozwala dobrze odzwierciedlić zmiany błędu zachowując jednocześnie niską złożoność obliczeniową, co jest z kolei ważne podczas analizy danych w czasie rzeczywistym. Średni RMSE zmalał do 6,88 cm, a czas na przeprowadzenie korekty wynosi 0,64 μ s.

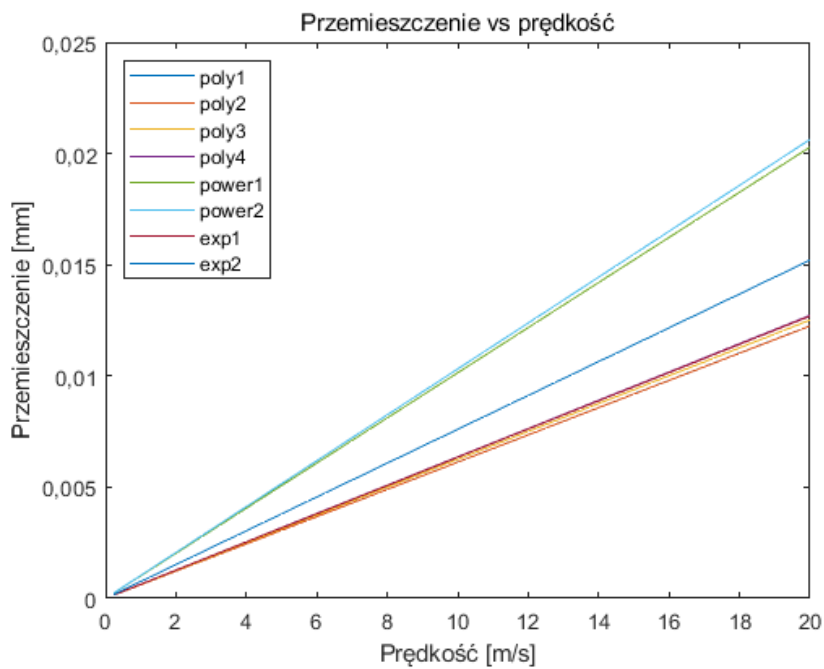
W tym miejscu należy również przypomnieć, że wykorzystywane odległości – do wybranych punktów referencyjnych, w procesie trilateracji powiązane są z pozycjami wcześniejszymi, a nie aktualną pozycją obiektu z uwagi na jego ciągłe przemieszczanie. W związku z czym na błąd wyznaczonej pozycji wpływa również prędkość obiektu. Czas analizy powinien być możliwie jak najkrótszy, z tego też powodu przeprowadzono porównanie czasów poszczególnych etapów w procesie wyznaczania pozycji obiektu. Zależność przemieszczenia od prędkości zależy w dużej mierze od czasu akwizycji danych z wybranych punktów referencyjnych. Na rys. 44 przedstawiono dystans, który poruszający się pojazd pokona w trakcie wyznaczania odległości do 4 wybranych punktów referencyjnych. Przedstawione dane z symulatora pozyskiwane są co $t_p = 12$ ms, co dla prędkości 20 m/s będzie skutkowało przemieszczeniem obiektu o 24 cm (dla 2 m/s – 2,4 cm, a dla 14 m/s – 16,8 cm). Jeden z dostępnych rzeczywistych systemów pozycjonowania UWB dostarcza ramki danych w odstępach 100 ms, co dla 20 m/s będzie skutkowało przemieszczeniem obiektu o 2 m (dla 2 m/s – 20 cm, a dla 14 m/s – 1,4 m).

Przedstawione przemieszczenia dotyczą opóźnienia systemu pozycjonującego wynikające z czasu wymiarowania t_p i nie uwzględniają czasu, który potrzebny jest na analizę danych i wyznaczenie pozycji. Jednakże częstość pozyskiwania pakietu danych z systemu UWB ma największy wpływ na dokładność wyznaczonej pozycji dla obiektów będących w ruchu. Dla

porównania korekta odległości z wykorzystaniem wcześniej przedstawionych funkcji będzie skutkowało przemieszczeniem poniżej 1 mm wynikającym z czasu jej wykonania dla wszystkich badanych prędkości (patrz rys. 45) co jest do zaniedbania w stosunku do korzyści wynikających z zastosowania zaproponowanych funkcji korekty.



Rys. 44. Przemieszczenie obiektu w zależności od prędkości i czasu akwizycji danych



Rys. 45. Przemieszczenie obiektu w zależności od czasu wykonania funkcji korekcyjnej

4.3 Wpływ metody trilateracji i liczby odległości na błąd pozycji

W tym podrozdziale określono jaki wpływ na dokładność wymiarowania ma wybrana metoda trilateracji oraz liczba dostępnych odległości do punktów referencyjnych. Przeanalizowane zostały dwie metody (szerzej opisane w punkcie 2.3.2), które wykorzystano do znalezienia rozwiązania w procesie trilateracji. Są to: standardowa metoda najmniejszych kwadratów (której czas wykonywania jest stały) – metoda ta jest najczęściej stosowana oraz zaproponowana w niniejszej rozprawie metoda optymalizacyjna (której czas wykonywania jest uzależniony od aktualnych danych i przyjętych kryteriów stopu). Porównanie powyższych metod uwzględnia czas potrzebny na wyznaczanie pozycji i pozwoli określić jak duży wpływ na przesunięcie obiektu ma wybrana metoda. Porównanie przeprowadzono dla trzech wariantów dostępnych odległości: wariant A – 4 odległości do punktów referencyjnych (67), wariant B – 3 odległości do punktów referencyjnych (68) i wariant C – 2 odległości do punktów referencyjnych (69).

$$D = \{d_{A1}, d_{A2}, d_{A3}, d_{A4}\} \quad (67)$$

$$D = \{d_{A1}, d_{A2}, d_{A3}\} \quad (68)$$

$$D = \{d_{A1}, d_{A2}\} \quad (69)$$

Porównanie pozwoli odpowiedzieć na to jak duży wpływ na dokładność wyznaczonej pozycji ma liczba dostępnych punktów referencyjnych. W celu porównania wyznaczono błędy pozyskiwanych pozycji dla przedstawionej ścieżki poruszania się obiektu, z wykorzystaniem następujących metod: dla zastosowanej już metody sympleksowej, w której punktem początkowym poszukiwań był środek wielokąta, którego wierzchołki znajdowały się w punktach referencyjnych – wariant I, dla metody sympleksowej, w której punktem początkowym poszukiwań była pozycja wcześniejsza – wariant II oraz metody najmniejszych kwadratów.

A. Cztery odległości do punktów referencyjnych

Porównano metody sympleksową w wariantach I (tab. 12) i wariantach II (tab. 13) oraz metodę najmniejszych kwadratów (tab. 14) dla czterech odległości pozyskanych z systemu UWB. Patrząc na RMSE dla opracowanych trzech wariantów trilateracji, w przypadku braku korekty najmniejszy błąd generowany jest dla metody LSM – o około 2 cm mniejszy niż w przypadku metody sympleksowej w obydwóch wariantach. Jednakże po korekcie odległości metody sympleksowe charakteryzują się mniejszym błędem – dla korekty wielomianem drugiego stopnia błąd jest mniejszy o 1,77 cm (dla wariantu I) oraz 1,74 cm (dla wariantu II). Średnia wartość

maksymalna $\varepsilon_{Max_{AVG}}$ dla metody LSM jest wyższa i wynosi ponad 18 cm, gdy dla metod sympleksowych wynosi około 13 cm.

Tab. 13. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 4 odległości, metodą sympleksową w wariancie II)

Korekta	$RMSE_{AVG}$ [cm]	MBE_{AVG} [cm]	$\varepsilon_{Min_{AVG}}$ [cm]	$\varepsilon_{Max_{AVG}}$ [cm]	$\varepsilon_{Min_{min}}$ [cm]	$\varepsilon_{Max_{max}}$ [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)
Brak	17,63	17,23	4,78	24,28	1,04	32,08
poly1	7,01	6,62	2,14	13,15	0,01	19,98
poly2	6,91	6,53	1,97	12,83	0,02	19,73
poly3	6,90	6,55	2,17	12,58	0,01	19,63
poly4	6,99	6,62	2,01	13,07	0,01	20,03
power1	6,94	6,56	2,05	12,99	0,00	19,91
power2	6,94	6,57	2,03	12,91	0,01	19,94
exp1	7,09	6,70	2,21	13,20	0,01	20,13
exp2	7,00	6,62	2,01	13,31	0,01	30,10

Tab. 14. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 4 odległości, metodą najmniejszych kwadratów)

Korekta	$RMSE_{AVG}$ [cm]	MBE_{AVG} [cm]	$\varepsilon_{Min_{AVG}}$ [cm]	$\varepsilon_{Max_{AVG}}$ [cm]	$\varepsilon_{Min_{min}}$ [cm]	$\varepsilon_{Max_{max}}$ [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)
Brak	15,82	15,01	1,41	26,50	0,06	30,53
poly1	8,53	7,63	0,46	18,74	0,02	25,50
poly2	8,65	7,72	0,48	18,91	0,01	25,64
poly3	8,47	7,66	0,55	18,73	0,03	25,39
poly4	8,48	7,66	0,48	18,57	0,02	25,29
power1	8,55	7,68	0,50	18,79	0,04	25,52
power2	8,55	7,70	0,51	18,82	0,03	25,52
exp1	8,47	7,61	0,46	18,69	0,03	25,44
exp2	8,52	7,69	0,49	18,75	0,01	25,45

Ponadto różnica pomiędzy RMSE i MBE dla metody LSM jest dwukrotnie wyższa w stosunku do metod sympleksowych, co świadczy o występowaniu większej liczby pozycji skrajnie odstających.

B. Trzy odległości do punktów referencyjnych

W kolejnym wariancie określono wpływ zredukowanej liczby dostępnych odległości (do trzech) na dokładność wyznaczonej pozycji obiektu z wykorzystaniem metody sympleksowej w wariancie II (dla wariantu I wyniki są podobne) oraz metody najmniejszych kwadratów. Porównując statystyki dla metody sympleksowej – w wariancie II (tab. 15) oraz metody

najmniejszych kwadratów (tab. 16), zauważa się wzrost wartości RMSE dla metody sympleksowej – w przypadku braku korekty o 1,28 cm, a po wykonaniu korekty wielomianem drugiego stopnia o 0,70 cm, natomiast dla metody LSM w przypadku braku korekty błąd zwiększył się o 2,22 cm, natomiast w przypadku korekty wielomianem drugiego stopnia pozostał na tym samym poziomie (różnica 1 mm). W dalszym ciągu dokładność metody sympleksowej jest wyższa.

Tab. 15. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 3 odległości, metodą sympleksową w wariancie II)

Korekta	$RMSE_{AVG}$ [cm]	MBE_{AVG} [cm]	$\varepsilon_{Min_{AVG}}$ [cm]	$\varepsilon_{Max_{AVG}}$ [cm]	$\varepsilon_{Min_{min}}$ [cm]	$\varepsilon_{Max_{max}}$ [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)
Brak	18,91	18,37	5,75	31,44	0,80	36,82
poly1	7,87	7,42	1,38	14,15	0,03	19,85
poly2	7,61	7,17	1,62	14,14	0,01	19,68
poly3	7,55	7,14	1,60	13,84	0,01	19,52
poly4	7,73	7,29	1,38	13,84	0,03	19,92
power1	7,67	7,23	1,52	14,18	0,01	19,81
power2	7,62	7,19	1,56	13,95	0,01	19,86
exp1	8,00	7,55	1,30	14,29	0,02	19,96
exp2	7,74	7,30	1,37	13,93	0,00	20,04

Tab. 16. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 3 odległości, metodą najmniejszych kwadratów)

Korekta	$RMSE_{AVG}$ [cm]	MBE_{AVG} [cm]	$\varepsilon_{Min_{AVG}}$ [cm]	$\varepsilon_{Max_{AVG}}$ [cm]	$\varepsilon_{Min_{min}}$ [cm]	$\varepsilon_{Max_{max}}$ [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)
Brak	18,03	17,42	5,72	29,12	2,44	33,38
poly1	8,76	8,15	1,13	17,04	0,02	22,04
poly2	8,64	7,96	1,45	17,38	0,01	22,22
poly3	8,26	7,69	1,43	16,03	0,04	20,95
poly4	8,40	7,82	1,25	16,24	0,03	21,25
power1	8,51	7,89	1,32	16,81	0,04	21,73
power2	8,40	7,79	1,38	16,53	0,03	21,46
exp1	8,78	8,20	1,02	16,60	0,07	21,67
exp2	8,40	7,83	1,20	16,25	0,01	21,26

C. Dwie odległości do punktów referencyjnych

Przeprowadzono również porównanie obydwóch metod przy dostępności danych jedynie z dwóch punktów referencyjnych w celu sprawdzenia jak dużym błędem będzie charakteryzować się pozycja obiektu przy niewystarczającej liczbie odległości wymaganych do jej wyznaczenia. Porównując RMSE można zauważyć, że błąd generowany przez metodę LSM –

807 cm (tab. 17), jest ponad dwukrotnie wyższy niż w metodzie sympleksowej – 302 cm (tab. 18). Duża wartość błędu w metodzie LSM wynika z dużej wariancji estymatora, która dąży do nieskończoności. Dla metody sympleksowej można zauważyć korzystny wpływ korekty odległości na dokładność (RMSE wynoszące 264 cm dla korekty wielomianem drugiego stopnia), natomiast błąd dla metody LSM pozostaje na tym samym poziomie. Średni maksymalny błąd pozycji $\epsilon_{Max_{AVG}}$ dla wszystkich przejazdów z wykorzystaniem metody LSM wynosi 14 m, co dyskwalifikuje tą metodę do pozycjonowania przy braku minimalnej liczby odległości.

Tab. 17. Błąd pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 2 odległości, metodą sympleksową w wariancie II)

Korekta	$RMSE_{AVG}$ [cm]	MBE_{AVG} [cm]	$\epsilon_{Min_{AVG}}$ [cm]	$\epsilon_{Max_{AVG}}$ [cm]	$\epsilon_{Min_{min}}$ [cm]	$\epsilon_{Max_{max}}$ [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)
Brak	302,25	208,17	1,56	716,05	0,05	820,12
poly1	264,93	173,50	2,17	643,73	0,03	802,59
poly2	264,36	177,13	1,70	640,57	0,10	822,80
poly3	282,62	187,86	1,89	679,47	0,10	800,59
poly4	283,68	189,87	2,14	674,75	0,14	800,77
power1	287,61	193,07	2,06	677,74	0,13	800,92
power2	294,74	198,62	1,80	686,81	0,08	800,10
exp1	255,50	168,92	2,29	617,08	0,01	802,81
exp2	281,53	188,55	2,16	678,33	0,21	800,44

Tab. 18. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 2 odległości, metodą najmniejszych kwadratów)

Korekta	$RMSE_{AVG}$ [cm]	MBE_{AVG} [cm]	$\epsilon_{Min_{AVG}}$ [cm]	$\epsilon_{Max_{AVG}}$ [cm]	$\epsilon_{Min_{min}}$ [cm]	$\epsilon_{Max_{max}}$ [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)
Brak	807,03	643,13	14,23	1399,99	10,64	1400,06
poly1	806,98	642,77	4,06	1399,99	0,00	1400,05
poly2	806,97	642,75	3,38	1399,99	0,53	1400,05
poly3	806,97	642,75	3,31	1399,99	0,43	1400,05
poly4	806,97	642,76	3,53	1399,99	0,78	1400,05
power1	806,97	642,76	3,50	1399,99	0,72	1400,05
power2	806,97	642,75	3,34	1399,99	0,47	1400,05
exp1	806,98	642,77	4,33	1399,99	0,36	1400,05
exp2	806,97	642,76	3,55	1399,99	0,80	1400,05

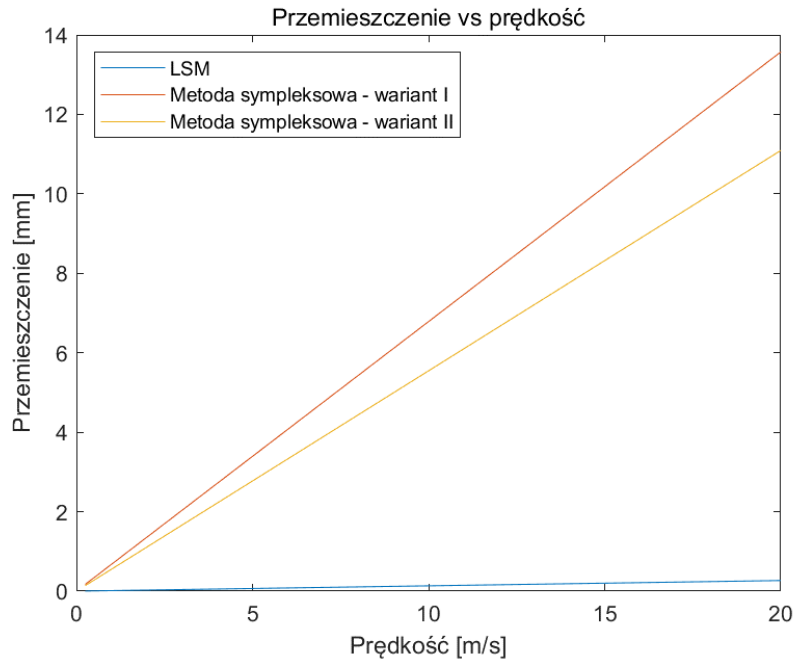
Podczas wyboru metody trilateracji należy kierować się nie tylko możliwością do uzyskania dokładnością, ale również czasem, który potrzebny jest wybranej metodzie na wyznaczenie pozycji. Jest to kolejny element wpływający na przemieszczenie obiektu od rozpoczęcia wymiarowania do otrzymania pozycji obiektu. W tab. 19 wyznaczono średnie czasy potrzebne

na obliczenie pozycji obiektu metodami: sympleksową w wariancie I II oraz najmniejszych kwadratów. Metoda LSM jest najszybsza (wykonuje się w czasie o rząd wielkości krótszym w stosunku do metody sympleksowej) i potrzebuje taką samą ilość czasu na znalezienie rozwiązania niezależnie od aktualnej pozycji obiektu, natomiast czas potrzebny na wyznaczenie pozycji w metodzie sympleksowego spadku (metody optymalizacyjnej) zależy od przyjętych kryteriów stopu algorytmu (dla przedstawionego przykładu maksymalna liczbę iteracji ograniczono do 100, minimalna wartość kroku i minimalna zmiana wartość funkcji ustalona została na 10^{-4}) i punktu rozpoczęcia poszukiwań (środką ciężkości wielokąta zbudowanego na węzłach referencyjnych biorących udział w wymiarowaniu – wariant I, lub pozycji poprzedniej obiektu – wariant II). Zmiana punktu rozpoczęcia poszukiwań rozwiązania w metodzie sympleksowej z wariantu I na wariant II pozwoliła zmniejszyć czas o 0,124 ms.

Tab. 19. Czas wyznaczania pozycji w zależności od wykorzystanej metody trilateracji

Metoda trilateracji	Czas [ms]
(1)	(2)
Metoda sympleksowa – wariant I	0,679
Metoda sympleksowa – wariant II	0,555
Metoda najmniejszych kwadratów	0,013

Przesunięcie wynikające z czasu potrzebnego na korektę odległości wybraną metodą i aktualnej prędkości obiektu zaprezentowano na rys. 46. Dla prędkości 20 m/s metoda LSM generuje przesunięcie 0,27 mm (2 m/s – 0,03 mm, 14 m/s – 0,19 mm), metoda sympleksowa w wariancie I 13,57 mm (dla 2 m/s – 1,36 mm, 14 m/s – 9,5 mm), a w wariancie II 11,09 mm (dla 2 m/s – 1,11 mm, 14 m/s – 7,77 mm). Przesunięcie wynikające z korekty odległości w procesie przetwarzania danych w systemie jest niskie w porównaniu do przesunięcia wynikającego z akwizycji danych o odległościach. W kontekście pojazdów typu AGV i samochodowych przesunięcie nie przekracza 1 cm, gdzie dokładność systemu jest na poziomie kilku, kilkunastu centymetrów.



Rys. 46. Przemieszczenie obiektu w zależności od zastosowanej metody trilateracji

4.4 Predykcja pozycji obiektu

Na podstawie badań i analiz przeprowadzonych w działach: 4.1, 4.2 oraz 4.3, dotyczących pozyskiwania pakietu danych UWB, filtracji oraz wpływu korekty odległości i metody trilateracji – stwierdzono, że najistotniejszy wpływ na dokładność wyznaczanych pozycji ma opóźnienie czasowe wynikające z procesu wymiarowania pomiędzy znacznikiem umieszczonym na poruszającym się obiekcie a punktami referencyjnymi (w przedstawionym symulatorze $t_p = 12$ ms). Zaproponowana korekta odległości poprawia dokładność wyznaczanych odległości tym samym zwiększając dokładność wyznaczanej pozycji, jednakże nie jest rozwiązaniem na przesunięcia wynikające z czasu transmisji danych, gdy obiekt jest w ciągłym ruchu lub też na chwilowe braki danych z systemu UWB. Z tego powodu postanowiono wprowadzić predykcję pozycji poruszającego się obiektu, która pozwoli zminimalizować wpływ opóźnień wynikających z czasu potrzebnego na proces wymiarowania i analizy danych lub braku danych z systemu UWB. Do predykcji pozycji obiektu zaproponowano sieć typu LSTM oraz filtr Kalmana (wstęp do zagadnienia w punkcie 4.1.3), które na podstawie sekwencji danych historycznych dokonają predykcji pozycji następnej.

4.4.1 Predykcja pozycji obiektu za pomocą sieci LSTM

Danymi wejściowymi do sieci LSTM są przemieszczenia obiektu wyznaczone korzystając z danych historycznych z systemu UWB – gdzie przemieszczenie obiektu do pozycji aktualnej z pozycji wcześniejszej jest zdefiniowane jako przemieszczenie w każdej osi z odpowiednim


znakiem (70) oraz dane pozyskane z systemu IMU (AHRS): akcelerometru, żyroskopu i magnetometru w każdej osi (39), w stałych odstępach czasu. Dane z wymienionych podsystemów tworzą wektor parametrów (71), który wykorzystywany jest w procesie uczenia sieci, a następnie predykcji.

$$\Delta P = \{\Delta x, \Delta y\} \quad (70)$$

$$W = \{\Delta x, \Delta y, a_x, a_y, a_z, g_x, g_y, g_z, m_x, m_y, m_z\} \quad (71)$$

gdzie: Δx – przemieszczenie w osi X ; Δy – przemieszczenie w osi Y ; a_x, a_y, a_z – dane z akcelerometru odpowiednio w osi X, Y oraz Z ; g_x, g_y, g_z – dane z żyroskopu odpowiednio w osi X, Y oraz Z ; m_x, m_y, m_z – dane z magnetometru odpowiednio w osi X, Y oraz Z .

Sieć LSTM jest typem sieci rekurencyjnej, czyli wykorzystywana jest sekwencyjność informacji (informacja z poprzedniej chwili wykorzystywana jest w chwili obecnej). Sieć tego typu posiada trzy bramki (patrz rys. 47): wejściową (*ang. input gate*), wyjściową (*ang. output gate*) oraz zapomnij (*ang. forget gate*) [107].



Rys. 47. Struktura sieci LSTM

Wektor \mathbf{h}_t odpowiada stanowi krótkoterminowemu (oraz wyjściowemu) (72) natomiast wektor \mathbf{c}_t odpowiada stanowi długoterminowemu (73). Bramka typu zapomnij f_t jako pierwsza decyduje, które informacje długoterminowe będą w dalszym ciągu przemierzać sieć. Decyduje o tym, które z informacji pozostają, a które ulegają usunięciu (74). Następnie wybierani są kandydaci do dodania g_t do stanu długoterminowego (75). Nowe informacje dodawane są przez bramkę wejściową i_t do stanu długoterminowego (76). Następnie tworzony jest stan krótkoterminowy przez bramkę wyjściową o_t (77):

$$\mathbf{h}_t = o_t \odot \sigma_c(\mathbf{c}_t) \quad (72)$$

$$\mathbf{c}_t = f_t \odot \mathbf{c}_{t-1} + i_t \odot g_t \quad (73)$$

$$f_t = \sigma_g(W_f \mathbf{x}_t + R_f \mathbf{h}_{t-1} + b_f) \quad (74)$$

$$g_t = \sigma_c(W_g \mathbf{x}_t + R_g \mathbf{h}_{t-1} + b_g) \quad (75)$$

$$i_t = \sigma_g(W_i \mathbf{x}_t + R_i \mathbf{h}_{t-1} + b_i) \quad (76)$$

$$o_t = \sigma_g(W_o \mathbf{x}_t + R_o \mathbf{h}_{t-1} + b_o) \quad (77)$$

gdzie: \mathbf{W} – wagi wejściowe; \mathbf{R} – wagi rekurencyjne (łącznie z poprzednim stanem krótkoterminowym); b – bias (przesunięcie progu funkcji aktywacji); σ_g, σ_c – funkcje aktywacji.

Funkcja aktywacji dla bramek to funkcja sigmoidalna (78), natomiast funkcja aktualizacji stanu to tangens hiperboliczny (79):

$$\sigma_g = (1 + e^{-x})^{-1} \quad (78)$$

$$\sigma_c = \tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (79)$$

Algorytmy uczenia maszynowego są w większości przypadków (szczególnie te, które do optymalizacji wykorzystują metody gradientowe – *ang. gradient descent*) wrażliwe na dane (cechy) o różnych rzędach i przedziałach wartości czy jednostkach (80). W związku z czym dane powinny być przeskalowane przed etapem uczenia – w fazie przetwarzania wstępnego należy wykonać normalizację lub standaryzację danych.

$$\boldsymbol{\theta}_{l+1} = \boldsymbol{\theta}_l - \alpha \nabla E(\boldsymbol{\theta}_l) \quad (80)$$

gdzie: $\boldsymbol{\theta}$ – wektor parametrów sieci (wag i przesunięć); α – współczynnik uczenia; $E(\boldsymbol{\theta})$ – funkcja strat.

Do przeskalowania danych o przesunięciu oraz danych z sensorów inercyjnych wybrano normalizację min-max. Metoda ta w sposób liniowy przekształca dane dożądanego przedziału $\langle \min'_x, \max'_x \rangle$ (81). Wybrano przedział $\langle 0, 1 \rangle$ przez co wzór upraszcza się do postaci (82). Normalizacja tego typu zapewnia, że żadna z cech nie będzie zdominowana przez inną cechę.

$$x' = \frac{x - \min_x}{\max_x - \min_x} \cdot (\max'_x - \min'_x) + \min'_x \quad (81)$$

$$x' = \frac{x - \min_x}{\max_x - \min_x} \quad (82)$$

gdzie: \min_x – wartość minimalna cechy x ; \max_x – wartość maksymalna cechy x ; \min'_x – oczekiwana wartość minimalna cechy x ; \max'_x – oczekiwana wartość maksymalna cechy x .

Podczas, gdy dane wykorzystane w procesie uczenia sztucznej sieci neuronowej są znormalizowane (83), to podczas procesu predykcji przesunięcia obiektu, wartości otrzymywane z sieci również będą znormalizowane. W związku z czym przed przystąpieniem do dalszej analizy, dane należy poddać denormalizacji zgodnie z wcześniej przyjętymi wartościami skrajnymi (84).

$$W' = \{\Delta x', \Delta y', a'_x, a'_y, a'_z, g'_x, g'_y, g'_z, m'_x, m'_y, m'_z\} \quad (83)$$

$$x = x' \cdot (max_x - min_x) + min_x \quad (84)$$

gdzie: min_x – wartość minimalna przyjętego przedziału dla cechy x ; max_x – wartość maksymalna przyjętego przedziału dla cechy x .


Estymacja kolejnej pozycji wiąże się z wykorzystaniem danych, które nie będą opisywać podobnych przypadków, a cały zbiór różnych przejazdów, które powinny w pewnym stopniu pokryć możliwe sytuacje, które mogą wystąpić w lokalnym układzie odniesienia. Należy zaznaczyć, że w zaproponowanym podejściu na wejściu do sieci wprowadzane są kolejne przemieszczenia ΔP w lokalnym układzie współrzędnych, przez co sieć uczy się na danych o przemieszczeniu, a nie na bezwzględnych pozycjach w przyjętym układzie odniesienia, przez co sekwencje (ścieżki) są w pewnym stopniu do siebie podobne (dla danej prędkości i przyspieszenia). Takie podejście czyni system bardziej uniwersalnym i niezależnym od przyjętego układu współrzędnych, przez co możliwa jest predykcja na dowolnym odcinku ścieżki, po której poruszał się obiekt niezależnie od jego bezwzględnej pozycji. Należy również nadmienić, że łuk (zakręt) można aproksymować przez skończoną liczbę prostych.

Analiza w niniejszym rozdziale pozwoli odpowiedzieć na pytanie jak będzie zmieniać się błąd predykcji kolejnych pozycji z wykorzystaniem sieci typu LSTM. Analiza uwzględni również czas potrzebne na inicjalizację sieci i predykcję. Rozważano dwa warianty ruchu obiektu: wariant A – ruch jednostajny z prędkościami w zakresie 0,25 m/s – 20 m/s i wariant B – ruch jednostajnie przyspieszony z zerową prędkością początkową z przyspieszeniem w zakresie 0,1 m/s² – 10 m/s² w linii prostej. Przejazdy realizowane były w taki sposób, aby odzwierciedlały zmiany nie tylko w wartości przesunięcia, ale również ze względu na kierunek poruszania się obiektu. W tab. 20 przedstawiono zbiorcze dane przygotowanych scenariuszy testowych (ścieżek poruszania się obiektu), które wykorzystano do budowy i analizy sieci. W procesie trilateracji wykorzystano metodę sympleksową w wariantcie I z uwagi na najwyższą dokładność wyznaczanej pozycji, a do korekty danych o pozycji – wielomian drugiego stopnia.

Tab. 20. Opis serii pomiarowych

Przyspieszenie a [m/s²]	0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,9; 1; 2; 3; 4; 5; 6; 7; 8; 9; 10
Prędkość v [m/s]	0,25; 0,5; 0,75; 1; 1,25; 1,5; 1,75; 2; 2,5; 3; 3,5; 4; 5; 6; 7; 8; 9; 10; 11; 12; 13; 14; 15; 16; 17; 18; 19; 20
Kierunek poruszania [rad]	$\{0, \pi, 2\pi\} \pm \left\{ \frac{\pi}{10}, \frac{\pi}{9}, \frac{\pi}{8}, \frac{\pi}{7}, \frac{\pi}{6}, \frac{\pi}{5}, \frac{\pi}{4}, \frac{\pi}{3} \right\}$
Długość ścieżki [m]	20
Łączna liczba przejazdów	1716

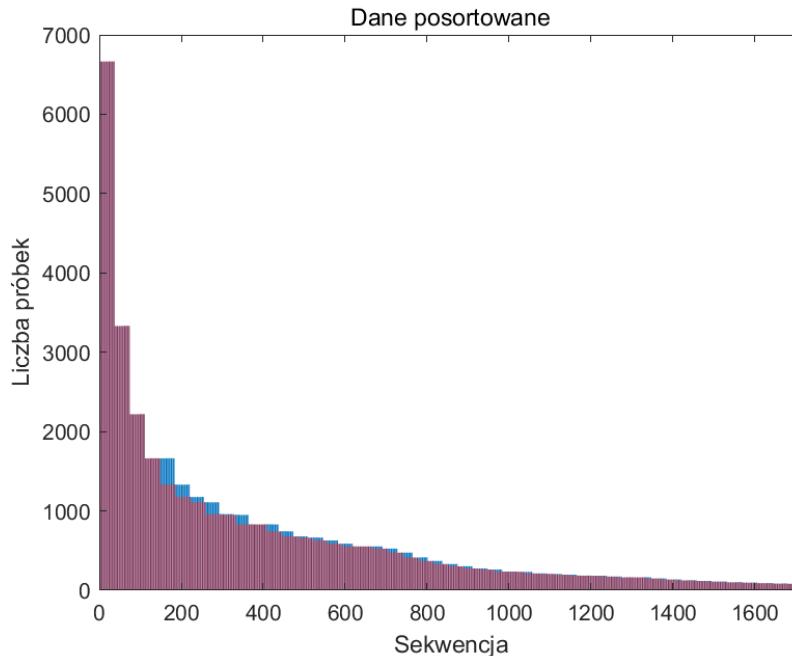
Z uwagi na dużą liczbę serii pomiarowych (średnia długość serii to 707 pozycji) i ograniczoną ilość pamięci operacyjnej, dane zostały podzielone na partie (ograniczony zbiór serii pomiarowych o tej samej długości), które sekwencyjnie wprowadzane są do sieci typu LSTM. W rozwiązaniu tym parametry sieci aktualizowane są po każdej z partii, a długość danych pomiędzy kolejnymi partiami może się różnić. Ważne jest, aby serie danych w pojedynczej partii były tej samej długości, ponieważ w całości będą przemierzać sieć. W tym celu po uszeregowaniu serii pomiarowych (patrz rys. 48 i rys. 49) i analizie długości wszystkich serii pomiarowych zdecydowano, że najkorzystniejszy rozmiar partii to 37 serii.



Rys. 48. Liczba pakietów danych UWB w seriach pomiarowych (serie nieposortowane)

Taki zbiór serii nie wymaga dużej ingerencji w długość danych (około 4% wszystkich pozycji) oraz pozwoli na przeprowadzenie uczenia z dostępną pamięcią operacyjną. Partie składające się z 37 serii pomiarowych zdecydowano się wyrównać przez skrócenie serii dłuższych do najkrótszej w danej partii (czerwona część wykresu rys. 49). Innym sposobem jest

rozszerzenie przyjętą wartością serii krótszych do najdłuższej serii. W tym rozwiązaniu nie traci się danych z serii pomiarowej, jednakże zabieg ten może wprowadzić szum do sieci, który negatywnie wpływa na właściwości predykcyjne.

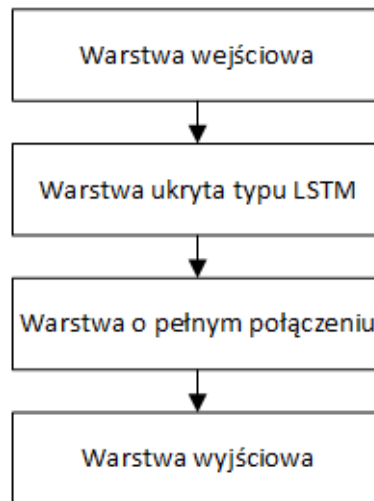


Rys. 49. Liczba pakietów danych UWB w seriach pomiarowych (serie posortowane)

Eksperyment przeprowadzono z wykorzystaniem sieci neuronowej typu LSTM o różnej liczbie komórek pamięci (ogólny schemat sieci przedstawiono na rys. 50). Skupiono się na sieci z jedną warstwą ukrytą, ponieważ w problemie predykcji pozycji zauważono wzrost błędu wraz z liczbą warstw ukrytych przy jednoczesnym znaczącym wydłużeniu czasu uczenia sieci [102]. Warstwa wejściowa składa się z 11 parametrów (71), które poddane są procesowi normalizacji otrzymując wektor (83). Warstwa ukryta składająca się z komórek LSTM (przeanalizowano sieci zawierające 20, 70, 100, 150 elementów pamięci w warstwie ukrytej), warstwa o pełnym połączeniu (*ang. fully connected layer*) oraz warstwa wyjściowa w pełni połączona z ostatnią warstwą ukrytą (warstwa regresyjna na której otrzymywane są predykowane wartości przemieszczenia (85)). Proces uczenia oparto na optymalizatorze ADAM (*ang. adaptive moment estimation*).

$$\Delta P' = \{\Delta x', \Delta y'\} \quad (85)$$

gdzie: $\Delta x'$ – predykowane przemieszczenie w osi X ; $\Delta y'$ – predykowane przemieszczenie w osi Y .



Rys. 50. Ogólna struktura proponowanej sieci neuronowej typu LSTM

Do inicjalizacji stanu wyuczonej sieci wykorzystano dane z dwudziestu wcześniejszych pozycji. Predykcja pozycji pierwszej wykonywana jest na znanych danych z systemu UWB i sensorów inercyjnych (akcelerometru, żyroskopu oraz kompasu), natomiast każda kolejna predykcja bazuje na danych z sensorów inercyjnych (dostępne dane z systemu) oraz wcześniejszej predykcji (brak danych z systemu UWB).

W tab. 21 przedstawiono RMSE dla predykcji 10 pozycji w zależności od liczby komórek pamięci oraz z podziałem na wariant ruchu (jednostajny i przyspieszony). Pozycję początkową predykcji umiejscowiono w 30%, 50% i 80% ruchu dwudziestometrowej ścieżki, co pozwala na analizę dokładności pozycji na różnych etapach ruchu obiektu, obejmując różne zakresy odległości od punktów referencyjnych (co wpływa na wartości korekty odległości i tym samym na wynik trilateracji). Liczba komórek pamięci wynosząca 150 pozwala zmniejszyć błąd o około 2% przy zwiększeniu liczby komórek pamięci o 50 w stosunku do sieci składającej się z 100 komórek pamięci, tak więc wykorzystanie sieci powyżej 100 komórek pamięci nie przynosi dużych korzyści, a jedynie zwiększa czas potrzebny na uczenie sieci oraz zajętość pamięci. Z tego powodu dalsze badania zostaną przeprowadzone z wykorzystaniem sieci, której warstwa ukryta składa się ze 100 komórek pamięci.

Tab. 21. RMSE dla predykcji 10 pozycji, predykcja od pozycji i bez korekty odległości

Liczba komórek pamięci	Typ ruchu	RMSE [cm]								
		Brak korekty odległości				Korekta odległości				
		80%	50%	30%	Średnia	80%	50%	30%	Średnia	
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	
20	$a = 0$	14,73	17,92	24,67	19,11	6,23	6,40	9,46	7,36	
	$a \neq 0$	15,88	20,60	17,72	18,07	5,76	6,49	9,81	7,36	
70	$a = 0$	14,76	17,36	24,00	18,71	5,76	5,22	8,36	6,45	

	$a \neq 0$	15,70	20,64	17,83	18,05	5,13	6,21	9,32	6,89
100	$a = 0$	14,92	17,02	23,53	18,49	5,68	4,57	7,77	6,01
	$a \neq 0$	15,24	20,32	17,99	17,85	4,49	5,75	9,29	6,51
150	$a = 0$	15,28	16,71	23,01	18,33	5,78	4,37	7,31	5,82
	$a \neq 0$	14,90	19,42	17,56	17,29	4,14	5,10	9,45	6,23

Porównano dokładność predykcji w zależności od liczby pozycji predykowanych. Dla losowo wybranych przejazdów z wariantu A i B wykonano predykcje do 1, 5, 10, 20, 40, 60, 80 i 100 pozycji (do wyznaczenia pozycji wykorzystano dane po korekcie odległości). W tab. 22 przedstawiono skumulowany RMSE dla ścieżki predykowanej – w kolumnie (2) RMSE predykcji dla jednej pozycji, w kolumnie (3) RMSE dla dwóch predykcji pozycji, w kolumnie (4) RMSE dla 10 predykcji pozycji, itd. Wraz ze wzrostem liczby pozycji predykowanych błąd rośnie od 6,53 cm dla pierwszej predykcji – do 94,25 cm dla 100 predykcji pozycji.

Tab. 22 Skumulowany RMSE dla predykcji pozycji obiektu

		Liczba predykcji							
		1	5	10	20	40	60	80	100
(1)	(2)	(3)	(4)	(5)	(7)	(8)	(9)	(10)	
RMSE [cm]	6,53	6,82	7,54	10,44	21,49	39,12	63,31	94,25	

Czas inicjalizacji sieci wynosi 1,7 ms, a czas na pojedynczą predykcję 1,9 ms. Inicjalizację sieci należy wykonać w trakcie okna czasowego, w którym pozyskiwane są dane z systemu UWB w związku z czym czas ten nie wpływa na przesunięcie obiektu. Natomiast czas predykcji wpływa na przesunięcie obiektu, który dla pojazdu samochodowego (14 m/s) będzie skutkować przesunięciem o 2,7 cm, a dla pojazdu typu AGV (2 m/s) przesunięciem o 0,4 cm. Przesunięcie wynikające z predykcji z wykorzystaniem sieci typu LSTM jest ponad 6 krotnie mniejsze niż przesunięcie wynikające z czasu akwizycji danych.

Dokładne porównanie błędu predykcji pozycji obiektu w wariantach A (z podziałem na prędkości) i B (z podziałem na przyspieszenia) zostanie przeprowadzone do 10 pozycji (co odpowiada 120 ms). Do korekty odległości wykorzystano funkcje wielomianową stopnia drugiego (którą przedstawiono w podrozdziale 4.2).

A. Wariant A (ruch ze stałą prędkością)

Wpierw przeanalizowano dokładność systemu UWB dla ruchu jednostajnego. W tab. 23 przedstawiono skumulowany RMSE dla dziesięciu pozycji obiektu pozyskanych z systemu UWB w stosunku do wartości referencyjnej (w kolumnie (2) RMSE dla jednej pozycji, w kolumnie (3) RMSE dla dwóch pozycji, itd.). Dokładność systemu wraz z kolejnymi pozycjami jest stała (odchylenie standardowe 1,09 cm) – co jest zgodne z oczekiwaniami ze względu na charakter

systemu, ponieważ każda pozycja następną jest niezależna od pozycji wcześniejszej. Można zauważyć, że błąd systemu maleje wraz ze wzrostem prędkości, spowodowane jest to błędem wynikającym z trilateracji, który jest duży w stosunku do pokonywanych odległości, które przy niskich prędkościach są małe.

Tab. 23. RMSE od 1 do 10 pozycji (dane testowe), prędkość stała

v [m/s]	RMSE [cm]									
	1	2	3	4	5	6	7	8	9	10
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
0,25	13,90	14,19	14,12	14,26	14,41	14,39	14,47	14,54	14,51	14,55
0,5	14,97	15,05	15,01	15,03	14,84	14,74	14,69	14,62	14,53	14,55
0,75	14,12	14,07	14,36	14,27	14,28	14,29	14,27	14,35	14,32	14,45
1	13,52	14,11	14,19	14,29	14,27	14,28	14,24	14,26	14,30	14,27
1,25	14,60	14,32	14,14	13,94	14,12	14,02	14,09	14,12	14,14	14,15
1,5	13,90	13,73	13,98	13,93	13,97	13,90	14,01	14,01	14,05	14,13
1,75	13,75	14,03	14,10	14,21	14,11	14,14	14,18	14,28	14,32	14,32
2	13,22	13,26	13,42	13,48	13,48	13,53	13,66	13,74	13,76	13,91
2,5	13,38	13,56	13,59	13,79	14,04	14,02	14,03	14,13	14,26	14,24
3	13,34	13,60	13,54	13,46	13,54	13,57	13,64	13,71	13,79	13,91
3,5	13,08	13,64	13,97	14,10	13,98	13,99	13,92	13,94	14,03	14,10
4	13,46	13,18	13,15	13,15	13,33	13,50	13,51	13,54	13,62	13,72
5	12,01	12,34	12,84	12,82	13,10	13,28	13,34	13,35	13,40	13,39
6	12,04	12,44	12,57	12,48	12,65	12,82	12,86	13,05	13,14	13,18
7	11,89	12,10	12,03	12,13	12,23	12,31	12,46	12,62	12,75	12,89
8	11,85	11,89	12,18	12,25	12,52	12,77	12,93	12,92	12,96	13,03
9	11,82	12,13	11,96	12,08	12,11	12,23	12,35	12,50	12,70	12,75
10	11,36	11,75	11,91	11,91	11,99	12,12	12,23	12,34	12,45	12,61
11	11,09	11,40	11,40	11,61	11,73	12,04	12,15	12,25	12,34	12,43
12	10,85	11,13	11,20	11,41	11,60	11,69	11,83	11,97	12,15	12,33
13	10,98	11,14	11,42	11,61	11,85	12,05	12,13	12,17	12,37	12,53
14	11,48	11,52	11,52	11,68	11,81	11,99	12,12	12,19	12,27	12,39
15	11,41	11,51	11,49	11,65	11,78	11,89	12,12	12,27	12,39	12,49
16	11,11	11,29	11,55	11,80	11,89	12,00	12,13	12,31	12,42	12,58
17	10,99	11,00	11,30	11,57	11,79	11,91	12,09	12,26	12,40	12,51
18	11,19	11,57	11,70	11,86	11,96	12,10	12,25	12,34	12,54	12,65
19	10,77	11,20	11,23	11,32	11,61	11,85	12,08	12,31	12,43	12,51
20	10,74	11,07	11,31	11,46	11,74	11,85	12,08	12,23	12,35	12,49
Średnia	12,39	12,58	12,68	12,77	12,88	12,97	13,07	13,15	13,24	13,32

Przeprowadzono predykcję pozycji symulując tym samym brak danych z systemu UWB. Jako, że na wyjściu sieci otrzymywane są przemieszczenia obiektu z pozycji wcześniejszej do pozycji następnej $\{\Delta x, \Delta y\}$, do wyznaczenia pozycji predykowanej wymagana jest ostatnia znana pozycja z systemu UWB, od której zostanie obliczona predykowana pozycja następna. W tab. 24

przedstawiono RMSE dla kolejnych predykcji pozycji obiektu będącego w ruchu. Dla pierwszej predykowanej pozycji RMSE utrzymuje się na tym samym poziomie co do wartości średniej co pozycja wyznaczona bezpośrednio z odległości systemu UWB (wzrost o 1 mm). Każda kolejna predykowana pozycja bazuje na predykcji z kroku wcześniejszego w związku z czym będzie ona obciążona błędem z predykcji wcześniejszej - dokładność predykcji 10 pozycji zmalał do 14,92 cm z 13,32. Zakładając, że obiekt będzie oddalał się od ostatniego znanego punktu (punktu początkowego) to błąd ten będzie miał charakter rosnący – co jest prawdziwe dla obiektów z niezerową prędkością i posiadających inercję.

Tab. 24. RMSE dla predykcji od pozycji bez korekty, prędkość stała

v [m/s]	RMSE [cm]									
	1	2	3	4	5	6	7	8	9	10
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
0,25	15,00	15,13	15,21	15,30	15,40	15,49	15,60	15,71	15,83	15,96
0,5	15,22	15,32	15,41	15,51	15,60	15,71	15,81	15,93	16,04	16,17
0,75	14,37	14,47	14,55	14,63	14,72	14,81	14,91	15,02	15,14	15,26
1	13,94	14,02	14,08	14,15	14,23	14,31	14,39	14,47	14,56	14,66
1,25	13,99	14,06	14,14	14,22	14,31	14,40	14,50	14,60	14,71	14,82
1,5	13,49	13,51	13,57	13,63	13,69	13,76	13,84	13,92	14,00	14,10
1,75	14,61	14,75	14,92	15,10	15,29	15,49	15,71	15,94	16,18	16,43
2	14,31	14,46	14,64	14,82	15,01	15,21	15,42	15,64	15,87	16,11
2,5	13,78	13,95	14,12	14,30	14,49	14,69	14,91	15,13	15,37	15,61
3	13,70	13,86	14,04	14,22	14,41	14,61	14,81	15,03	15,26	15,50
3,5	13,01	13,15	13,31	13,49	13,67	13,86	14,06	14,27	14,49	14,73
4	13,11	13,34	13,57	13,81	14,07	14,36	14,65	14,97	15,30	15,64
5	12,41	12,57	12,80	13,05	13,31	13,59	13,89	14,22	14,57	14,93
6	12,59	12,86	13,16	13,50	13,86	14,23	14,62	15,03	15,45	15,89
7	12,24	12,58	12,89	13,26	13,65	14,08	14,53	15,02	15,52	16,05
8	12,29	12,59	12,95	13,38	13,83	14,32	14,84	15,40	15,98	16,60
9	11,54	11,76	12,04	12,38	12,75	13,15	13,58	14,04	14,53	15,06
10	11,52	11,79	12,12	12,47	12,88	13,34	13,82	14,35	14,91	15,50
11	11,65	11,96	12,30	12,68	13,10	13,58	14,09	14,64	15,25	15,89
12	10,03	10,20	10,42	10,70	11,03	11,43	11,89	12,40	12,97	13,57
13	10,39	10,60	10,85	11,14	11,50	11,90	12,35	12,86	13,40	13,97
14	10,57	10,80	11,12	11,50	11,96	12,46	13,05	13,67	14,37	15,12
15	10,87	11,14	11,45	11,84	12,29	12,76	13,29	13,88	14,51	15,19
16	10,84	11,03	11,26	11,54	11,89	12,29	12,75	13,23	13,77	14,35
17	10,28	10,31	10,45	10,69	10,99	11,36	11,78	12,29	12,83	13,45
18	10,01	10,02	10,11	10,29	10,56	10,90	11,31	11,76	12,27	12,85
19	10,49	10,44	10,50	10,65	10,89	11,19	11,56	12,00	12,48	13,03
20	10,87	10,58	10,41	10,30	10,28	10,33	10,46	10,66	10,91	11,24
Średnia	12,40	12,54	12,73	12,95	13,20	13,49	13,80	14,15	14,52	14,92

Podczas wyznaczania ścieżki predykowanej nie bez znaczenia jest dokładność ostatniej pozycji otrzymanej z systemu UWB, od której wyznaczone są kolejne pozycje wykorzystując predykowane przemieszczenie. W tab. 25 przedstawiono efekty predykcji, dla której pozycje na ścieżce predykowanej obliczane są od ostatniej znanej pozycji wyznaczonej – korzystając ze skorygowanych danych o odległościach. Można zaobserwować spadek RMSE co do wartości średniej, który do siódmej predykcji pozycji utrzymuje się poniżej 5 cm.

Tab. 25. RMSE dla predykcji od pozycji skorygowanej, prędkość stała

v [m/s]	RMSE [cm]									
	1	2	3	4	5	6	7	8	9	10
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
0,25	4,90	4,98	5,06	5,14	5,24	5,35	5,47	5,60	5,74	5,89
0,5	3,71	3,76	3,81	3,87	3,93	4,01	4,10	4,20	4,32	4,44
0,75	3,40	3,45	3,48	3,54	3,60	3,69	3,79	3,90	4,02	4,17
1	2,63	2,69	2,74	2,79	2,87	2,95	3,05	3,16	3,29	3,42
1,25	2,96	3,00	3,04	3,08	3,13	3,20	3,27	3,35	3,44	3,54
1,5	3,20	3,21	3,24	3,28	3,33	3,39	3,46	3,54	3,63	3,74
1,75	3,33	3,38	3,46	3,57	3,72	3,89	4,09	4,32	4,57	4,85
2	3,22	3,30	3,42	3,57	3,72	3,90	4,11	4,34	4,58	4,86
2,5	2,59	2,67	2,74	2,84	2,96	3,12	3,30	3,51	3,74	3,98
3	2,56	2,60	2,67	2,75	2,86	3,00	3,17	3,39	3,63	3,89
3,5	2,99	2,97	2,97	3,02	3,11	3,23	3,38	3,56	3,76	3,99
4	3,13	3,13	3,18	3,28	3,43	3,64	3,88	4,16	4,47	4,82
5	3,06	2,98	2,95	2,99	3,11	3,29	3,53	3,83	4,16	4,54
6	3,19	3,22	3,31	3,49	3,74	4,06	4,42	4,83	5,26	5,73
7	3,33	3,34	3,42	3,62	3,91	4,29	4,71	5,19	5,70	6,25
8	3,30	3,19	3,23	3,46	3,77	4,20	4,68	5,23	5,81	6,45
9	3,99	3,77	3,70	3,77	3,94	4,22	4,58	5,00	5,47	6,01
10	4,36	4,09	3,96	3,98	4,15	4,44	4,81	5,28	5,80	6,38
11	4,67	4,31	4,12	4,11	4,26	4,56	4,96	5,43	6,00	6,62
12	5,90	5,40	4,99	4,73	4,63	4,71	4,93	5,29	5,74	6,27
13	6,29	5,89	5,55	5,38	5,35	5,46	5,68	6,01	6,40	6,87
14	6,38	5,80	5,37	5,14	5,11	5,27	5,61	6,06	6,63	7,29
15	6,79	6,20	5,75	5,47	5,41	5,53	5,82	6,24	6,76	7,35
16	7,54	7,04	6,63	6,37	6,24	6,26	6,41	6,66	7,01	7,44
17	8,39	7,81	7,27	6,85	6,59	6,50	6,55	6,76	7,06	7,47
18	9,40	8,75	8,23	7,77	7,41	7,17	7,07	7,12	7,30	7,60
19	10,02	9,48	8,91	8,44	8,07	7,82	7,70	7,71	7,84	8,08
20	10,08	9,41	8,95	8,45	8,03	7,68	7,41	7,24	7,17	7,21
Średnia	4,83	4,64	4,50	4,45	4,49	4,60	4,78	5,03	5,33	5,68

B. Wariant B (ruch z różnym przyspieszeniem)

Kolejne porównania przeprowadzono dla ruchu przyspieszonego. W tab. 26 przedstawiono RMSE dla dziesięciu pozycji obiektu pozyskanych z symulacji systemu UWB. Dokładność systemu wraz z kolejnymi pozycjami jest stała (odchylenie standardowe wynosi 1,54 cm). Z uwagi na fakt, że ruch przyspieszony rozpoczynał się od $v_0 = 0$ [m/s] to początkowe przemieszczania pomiędzy kolejnymi pozycjami były niewielkie i największy wpływ na RMSE ma niedokładność wynikająca z trilateracji, a nie przemieszczenia obiektu. Dokładność systemu zawiera się w przedziale od 15,98 cm do 16,23 cm.

Tab. 26. RMSE od 1 do 10 pozycji (dane testowe), ruch przyspieszony

a [m/s ²]	RMSE [cm]									
	1	2	3	4	5	6	7	8	9	10
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
0,1	13,67	14,24	14,30	14,36	14,32	14,28	14,21	14,21	14,23	14,17
0,2	15,56	14,80	14,67	14,75	14,67	14,58	14,54	14,43	14,43	14,40
0,3	14,94	14,76	14,60	14,57	14,61	14,58	14,65	14,70	14,63	14,65
0,4	14,31	14,32	14,42	14,41	14,36	14,37	14,46	14,51	14,49	14,60
0,5	14,37	14,47	14,91	14,93	14,86	14,83	14,85	14,85	14,92	14,99
0,6	15,43	15,39	15,31	15,28	15,15	15,23	15,25	15,22	15,24	15,22
0,7	15,47	15,52	15,54	15,36	15,37	15,32	15,29	15,29	15,27	15,26
0,8	14,88	14,83	15,18	15,21	15,18	15,04	15,09	15,08	15,01	15,00
0,9	15,32	15,41	15,23	15,10	15,16	15,12	15,15	15,20	15,26	15,31
1	15,12	15,28	15,15	15,28	15,15	15,23	15,33	15,38	15,38	15,34
2	15,55	15,45	15,72	15,66	15,79	15,82	15,88	15,85	15,78	15,69
3	16,12	16,18	16,46	16,44	16,46	16,52	16,59	16,60	16,53	16,43
4	17,12	17,04	17,13	17,15	17,02	17,01	16,95	16,98	16,87	16,79
5	16,90	17,03	16,98	17,09	17,15	17,23	17,22	17,19	17,06	16,95
6	18,22	17,92	18,06	18,05	18,07	18,03	17,90	17,84	17,64	17,40
7	18,12	18,14	18,06	18,10	18,21	18,27	18,13	18,03	17,90	17,68
8	19,07	18,79	18,52	18,59	18,39	18,24	18,10	17,96	17,71	17,43
9	18,35	18,48	18,54	18,77	18,93	18,98	18,84	18,65	18,38	18,12
10	19,09	19,27	19,29	19,23	19,23	19,15	18,97	18,72	18,38	18,14
Średnia	16,19	16,17	16,22	16,23	16,21	16,20	16,18	16,14	16,06	15,98

W tab. 27 przedstawiono RMSE dla kolejnych predykcji pozycji obiektu będącego w ruchu jednostajnie przyspieszonym. Ostatnia znana pozycja została wyznaczona bez korekty odległości i średnia wartość RMSE dla predykcji 10 pozycji zawiera się w przedziale od 15,24 cm do 16,21 cm. Można zauważyć wzrost dokładności, dolna wartość przedziału zmalała o 0,74 cm natomiast górna wzrosła o 0,02 cm, co świadczy o właściwościach filtracyjnych sieci.

Odnotowuje się wzrost RMSE wraz ze wzrostem przyspieszenia co związane jest ze zwiększającą się dynamiką obiektu.

Tab. 27. RMSE dla predykcji od pozycji bez korekty, ruch przyspieszony

a [m/s ²]	RMSE [cm]									
	1	2	3	4	5	6	7	8	9	10
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
0,1	13,90	13,89	13,86	13,83	13,80	13,78	13,75	13,73	13,72	13,71
0,2	14,17	14,13	14,07	14,01	13,95	13,89	13,84	13,79	13,74	13,69
0,3	14,09	14,06	14,01	13,98	13,95	13,93	13,92	13,92	13,93	13,96
0,4	15,21	15,20	15,18	15,16	15,14	15,12	15,10	15,09	15,09	15,09
0,5	14,65	14,60	14,54	14,48	14,41	14,35	14,30	14,24	14,20	14,16
0,6	15,35	15,31	15,27	15,23	15,20	15,16	15,13	15,11	15,09	15,08
0,7	15,04	14,97	14,91	14,84	14,78	14,71	14,65	14,59	14,53	14,48
0,8	15,09	15,07	15,01	14,94	14,88	14,82	14,77	14,72	14,68	14,65
0,9	15,25	15,18	15,11	15,03	14,96	14,89	14,83	14,77	14,72	14,68
1	15,10	15,01	14,90	14,81	14,72	14,63	14,55	14,46	14,39	14,32
2	15,75	15,60	15,46	15,33	15,20	15,08	14,97	14,86	14,77	14,69
3	16,68	16,59	16,47	16,35	16,22	16,11	16,01	15,92	15,84	15,77
4	17,48	17,42	17,36	17,27	17,19	17,11	17,02	16,94	16,86	16,78
5	17,15	16,98	16,81	16,65	16,48	16,32	16,17	16,02	15,89	15,77
6	17,48	17,31	17,13	16,95	16,79	16,63	16,48	16,35	16,23	16,13
7	17,42	17,16	16,92	16,68	16,43	16,17	15,93	15,69	15,47	15,27
8	18,17	17,99	17,76	17,56	17,35	17,13	16,92	16,73	16,56	16,41
9	18,96	18,81	18,62	18,43	18,21	18,01	17,82	17,63	17,47	17,32
10	19,34	19,16	18,96	18,77	18,56	18,35	18,15	17,96	17,77	17,60
Średnia	16,12	16,02	15,91	15,81	15,70	15,59	15,49	15,40	15,31	15,24

Dla przypadku, w którym pozycja startowa otrzymywana jest ze skorygowanych odległości, predykcja pozycji charakteryzuje się błędem mniejszym o ponad 10 cm co do wartości średnich w porównaniu z RMSE dla danych testowych (patrz tab. 28), co pokazuje jak duży wpływ na dokładność wyznaczonej pozycji ma zaproponowany w procesie analizy etap korekty odległości. W dalszym ciągu widoczna jest tendencja wzrostu RMSE wraz ze wzrostem przyspieszenia co związane jest z większą dynamiką zmian w przemieszczeniu, jednakże wartość średnia RMSE wynosi około 5 cm co jest porównywalne z wynikami otrzymanymi dla ruchu jednostajnego.

Tab. 28. RMSE dla predykcji od pozycji skorygowanej, ruch przyspieszony

a [m/s ²]	RMSE [cm]									
	1	2	3	4	5	6	7	8	9	10
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
0,1	2,74	2,76	2,77	2,79	2,84	2,91	3,00	3,12	3,25	3,39

0,2	2,95	2,90	2,87	2,83	2,82	2,83	2,87	2,92	2,99	3,08
0,3	2,86	2,86	2,92	3,02	3,16	3,33	3,54	3,75	4,01	4,27
0,4	3,93	3,92	3,92	3,91	3,91	3,91	3,93	3,96	4,00	4,08
0,5	3,20	3,12	3,04	2,97	2,92	2,90	2,89	2,93	2,99	3,08
0,6	3,67	3,57	3,49	3,44	3,40	3,37	3,36	3,38	3,42	3,49
0,7	3,62	3,49	3,39	3,29	3,20	3,12	3,06	3,03	3,01	3,01
0,8	3,74	3,70	3,63	3,56	3,51	3,49	3,48	3,51	3,55	3,62
0,9	3,97	3,86	3,76	3,69	3,62	3,58	3,56	3,58	3,64	3,72
1	4,21	4,10	3,99	3,90	3,82	3,77	3,75	3,75	3,79	3,85
2	5,19	5,00	4,82	4,67	4,55	4,44	4,37	4,31	4,29	4,30
3	5,79	5,60	5,40	5,22	5,05	4,91	4,81	4,74	4,72	4,75
4	7,06	6,95	6,85	6,72	6,60	6,48	6,36	6,25	6,16	6,08
5	6,44	6,21	5,94	5,69	5,43	5,21	5,02	4,88	4,78	4,76
6	7,23	6,93	6,63	6,33	6,09	5,85	5,67	5,54	5,46	5,44
7	7,61	7,27	6,94	6,62	6,28	5,97	5,70	5,47	5,31	5,22
8	8,33	8,07	7,74	7,43	7,14	6,84	6,59	6,38	6,24	6,16
9	8,76	8,49	8,16	7,83	7,48	7,15	6,85	6,58	6,38	6,24
10	9,49	9,21	8,88	8,58	8,25	7,92	7,61	7,31	7,05	6,83
Średnia	5,30	5,16	5,01	4,87	4,74	4,63	4,55	4,49	4,48	4,49

Dla pojazdów AGV, które poruszają się zwykle z prędkością do 2 m/s oraz przyspieszeniem do 2 m/s² średnia wartość RMSE dla predykcji ścieżki składającej się z 10 pozycji wynosi 4,9 cm oraz 4,3 cm odpowiednio dla ruchu jednostajnego i przyspieszonego (dla wartości maksymalnych). Dla pojazdów samochodowych poruszających się w ruchu miejskim z prędkością do 14 m/s oraz przyspieszeniem do 10 m/s² średnia wartość RMSE również dla predykcji ścieżki składającej się z 10 pozycji wynosi 7,3 cm oraz 6,8 cm odpowiednio dla ruchu jednostajnego i przyspieszonego (dla wartości maksymalnych). Otrzymana dokładność ścieżki predykowanej zarówno dla AGV jak i pojazdu samochodowego jest wystarczająca, aby umożliwić nieprzerwane śledzenie obiektu w trakcie chwilowych (do 120 ms) zaników sygnału z systemu UWB oraz pozwala przewidzieć następną pozycję obiektu.

Przeprowadzone eksperymenty i porównania pozwalają potwierdzić, że predykcja pozycji obiektu jest możliwa korzystając z sieci typu LSTM i umożliwia wyznaczenie pozycji obiektu z dokładnością poniżej 10 cm do 10 pozycji. Liczbę pozycji predykowanych można zwiększyć biorąc pod uwagę jednoczesny wzrost błędu wyznaczanych predykcji. Należy mieć na uwadze, że na dokładność większej liczby predykcji będzie miała zmiana parametrów ruchu obiektu, w związku z czym, aby utrzymać dokładność systemu sieć będzie wymagać częstych inicjalizacji (np. z każdą kolejnym pakietem danych z systemu UWB).

4.4.2 Predykcja pozycji obiektu z wykorzystaniem filtru Kalmana

Filtr Kalmana (FK) pozwala na filtrację danych wykorzystując dwa niezależne źródła sygnału, które są nieskorelowane ze sobą, ale odzwierciedlają przemieszczenie. Wykonywana jest więc fuzja danych pochodzących z różnych źródeł. Podczas przetwarzania danych uwzględnia się prawdopodobieństwo wystąpienia błędu i szacuje się stan następny i prawdopodobieństwo jego wystąpienia. Stan następny – w kontekście pracy, jest właśnie predykcją pozycji obiektu w kolejnej dyskretniej chwili czasu (przy założeniu, że czas akwizycji danych z poszczególnych systemów jest stały). Przygotowano model filtru zgodnie z opisem w dziale 4.1.3. Na wejście filtru podawane są pozycje z systemu UWB oraz przyspieszenia z akcelerometru (86). W eksperymencie zakłada się normalny cykl pracy filtru, tak więc ścieżka aktualna budowana jest z przefiltrowanych danych o pozycji (40), a ścieżka predykowana z pozycji wyznaczonych a priori (41).

$$W = \{x, y, a_x, a_y\} \quad (86)$$

gdzie: x – pozycja w osi X ; y – pozycja w osi Y ; a_x, a_y – dane z akcelerometru odpowiednio w osi X oraz Y .

Eksperyment przeprowadzono z użyciem danych symulacyjnych, które wykorzystano również w punkcie 4.4.1. Analizie poddano całe przejazdy, które porównano oddzielnie dla ruchu ze stałą prędkością wariant A oraz ruchu przyspieszonego wariant B. Do wyznaczania pozycji obiektu wykorzystano dane o odległościach, które zostały skorygowane wielomianem drugiego stopnia (funkcje korekty zaproponowane zostały w podrozdziale 4.2). Przeprowadzona analiza pozwoli odpowiedzieć na pytanie jaką dokładnością charakteryzuje się pozycja na ścieżce predykowanej składająca się z pozycji wyznaczonych a priori.

A. Wariant A (ruch ze stałą prędkością)

Wpierw przeanalizowano dane o ruchu jednostajnym. W tab. 29 przedstawione w kolumnach 2-4 statystyki dotyczą danych bez filtracji filtrem Kalmana, w kolumnach 5-7 danych o pozycji aktualnej przefiltrowanej filtrem Kalmana, a kolumny 8-10 danych predykowanych (czyli dokładności wyznaczonej pozycji a priori). Filtracja pozwala zwiększyć dokładność wyznaczonej pozycji co do wartości średniej RMSE z 6,75 cm do 6,68 cm. Jednocześnie można zauważyć zmniejszenie błędu maksymalnego z 13,80 cm do 12,37 cm. Błąd predykcji pozycji wzrósł o 0,36 cm w stosunku do średniego RMSE dla pozycji aktualnej po filtracji filtrem Kalmana.

Tab. 29. Błąd pozycji obiektu, prędkość stała, filtracja FK

v [m/s]	Brak filtracji FK			Filtracja FK			Predykcja FK		
	RMSE [cm]	ε_{min} [cm]	ε_{max} [cm]	RMSE [cm]	ε_{min} [cm]	ε_{max} [cm]	RMSE [cm]	ε_{min} [cm]	ε_{max} [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)
0,25	4,64	0,07	15,64	4,66	0,19	13,93	4,71	0,18	14,18
0,5	4,56	0,08	15,00	4,58	0,24	13,76	4,63	0,23	14,01
0,75	4,32	0,11	12,67	4,13	0,17	10,46	4,13	0,15	10,63
1	4,31	0,11	13,14	4,24	0,23	11,04	4,28	0,21	11,23
1,25	4,39	0,16	12,69	4,31	0,26	11,40	4,34	0,21	11,63
1,5	4,38	0,18	12,49	4,28	0,31	10,86	4,31	0,28	11,07
1,75	4,36	0,17	12,13	4,24	0,28	10,63	4,28	0,24	10,93
2	4,51	0,20	12,66	4,60	0,47	11,76	4,67	0,46	12,06
2,5	4,47	0,18	11,91	4,41	0,36	10,53	4,47	0,34	10,95
3	4,58	0,24	11,52	4,67	0,46	10,58	4,75	0,45	11,04
3,5	4,66	0,26	11,85	4,66	0,42	10,14	4,74	0,43	11,19
4	4,74	0,34	10,54	4,83	0,52	9,37	4,93	0,53	10,41
5	5,05	0,40	10,79	5,13	0,42	9,80	5,26	0,48	11,93
6	5,43	0,51	11,24	5,61	0,37	10,46	5,79	0,36	13,44
7	5,81	0,76	11,75	6,10	0,60	10,92	6,35	0,54	15,24
8	6,17	1,07	11,77	6,28	0,85	11,27	6,55	0,74	16,89
9	6,61	1,35	12,14	6,53	1,16	11,45	6,83	0,92	18,37
10	7,12	1,82	13,00	7,22	1,56	12,36	7,61	1,35	20,23
11	7,67	2,21	14,49	7,60	2,17	13,23	8,03	1,93	22,11
12	8,02	2,65	13,67	8,06	2,52	13,03	8,57	2,25	23,48
13	8,55	3,18	14,01	8,44	3,03	13,28	9,02	2,71	25,24
14	9,02	3,72	15,17	8,89	3,38	13,73	9,56	3,02	27,08
15	9,64	4,27	17,09	9,33	3,76	14,14	10,06	3,42	29,46
16	10,13	4,63	16,23	9,81	4,24	14,56	10,63	3,81	30,97
17	10,56	4,97	16,51	10,27	4,83	14,91	11,20	4,39	33,22
18	11,12	5,86	17,82	10,74	5,48	15,39	11,75	4,95	35,11
19	11,94	6,18	20,34	11,48	5,84	17,03	12,62	5,25	37,47
20	12,18	6,71	18,00	11,88	6,33	16,47	13,11	5,67	38,42
Średnia	6,75	1,87	13,80	6,68	1,80	12,37	7,04	1,62	19,21

Widoczny jest wzrost wartości RMSE wraz ze wzrostem prędkości obiektu, który dla pozycji aktualnej zawiera się w przedziale od 4,13 cm do 11,88 cm, a dla pozycji predykowanej zawiera się w przedziale od 4,13 cm do 13,11 cm. Można uznać, że dokładność pozycji aktualnej i pozycji predykowanej jest na tym samym poziomie.

B. Wariant B (ruch z różnym przyspieszeniem)

Następnie przeanalizowano działanie filtru Kalmana dla ruchu przyspieszonego (patrz tab. 30). Wartość maksymalna błędu pozycji aktualnej zmalała z 13,24 (bez FK) do 11,81 cm po

zastosowaniu filtru Kalmana. Dla pozycji predykowanej wartość maksymalna błędu wzrosła o 0,12 cm w stosunku do wartości maksymalnej błędu pozycji aktualnej. Wraz ze wzrostem przyspieszenia błąd rośnie. Dla pozycji aktualnej RMSE zawiera się w przedziale od 4,10 cm do 7,77 cm, a dla pozycji predykowanej zawiera się w przedziale od 4,14 cm do 7,87 cm. Porównując końce przedziałów z wariantem A zauważalne jest zawężenie przedziałów o ponad 4 cm dla pozycji aktualnej oraz o ponad 5 cm dla pozycji predykowanej.

Tab. 30. Błąd pozycji obiektu, ruch przyspieszony, filtracja FK

a [m/s ²]	Brak filtracji FK			Filtracja FK			Predykcja FK		
	RMSE [cm]	ε_{min} [cm]	ε_{max} [cm]	RMSE [cm]	ε_{min} [cm]	ε_{max} [cm]	RMSE [cm]	ε_{min} [cm]	ε_{max} [cm]
(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)
0,1	4,21	0,15	11,35	4,10	0,28	9,82	4,14	0,27	9,98
0,2	4,28	0,10	12,67	4,19	0,31	11,00	4,23	0,27	11,24
0,3	4,27	0,18	11,86	4,16	0,32	10,45	4,20	0,33	10,57
0,4	4,35	0,22	11,94	4,41	0,37	11,16	4,48	0,34	11,38
0,5	4,45	0,19	12,20	4,46	0,46	11,01	4,52	0,40	11,23
0,6	4,45	0,34	11,22	4,43	0,41	10,09	4,48	0,42	10,28
0,7	4,54	0,28	12,24	4,47	0,47	10,74	4,52	0,48	10,94
0,8	4,59	0,32	12,29	4,65	0,45	11,45	4,72	0,40	11,68
0,9	4,62	0,29	11,30	4,64	0,45	10,46	4,70	0,37	10,64
1	4,62	0,34	10,91	4,54	0,47	10,11	4,58	0,44	10,23
2	5,16	0,31	12,10	5,19	0,48	11,20	5,26	0,46	11,36
3	5,51	0,34	12,50	5,41	0,58	11,29	5,47	0,55	11,33
4	5,91	0,44	13,90	5,98	0,61	12,40	6,08	0,58	12,57
5	6,25	0,44	14,18	6,40	0,51	12,94	6,51	0,42	13,13
6	6,61	0,48	15,32	6,59	0,54	13,17	6,67	0,58	13,21
7	6,93	0,42	15,75	6,82	0,56	13,52	6,89	0,61	13,54
8	7,17	0,66	16,13	7,05	0,49	13,91	7,12	0,54	13,83
9	7,51	0,77	16,77	7,48	0,60	14,55	7,57	0,56	14,50
10	7,72	0,74	16,93	7,77	0,68	15,05	7,87	0,67	14,99
Średnia	5,43	0,37	13,24	5,41	0,48	11,81	5,47	0,46	11,93

Dostępność predykowanej pozycji obiektu charakteryzującej się małym błędem jest kluczowa do zmniejszenia lub wyeliminowania problemu przesunięcia obiektu. Przeprowadzone eksperymenty i porównania pozwalają potwierdzić, że predykcja pozycji obiektu z wykorzystaniem filtru Kalmana jest możliwa, a dokładność pozycji predykowanej jest porównywalna do dokładności pozycji aktualnej.

Otrzymane wyniki są zadawalające zarówno dla pojazdów AGV (poruszających się zwykle z prędkością do 2 m/s oraz przyspieszeniem do 2 m/s²), jak również dla pojazdów samochodowych (poruszających się z prędkością do 14 m/s oraz przyspieszeniem do 10 m/s²).

Dla brzegowych wartości dla ruchu jednostajnego oraz przyspieszonego RMSE dla predykcji wynosi odpowiednio 4,7 cm i 5,3 cm dla AGV oraz 9,6 cm i 7,9 cm dla pojazdu samochodowego.

Otrzymana dokładność ścieżki predykowanej zarówno dla AGV jak i pojazdu samochodowego jest wystarczająca, aby przewidzieć następną pozycję obiektu, co pozwoli dostarczyć systemowi nadrzędnemu odpowiednich informacji i umożliwi wcześniejsze podjęcie decyzji o możliwej sytuacji niebezpiecznej.

Predykcja przy pomocy filtru Kalmana, czy sieci typu LSTM charakteryzuje się błędem poniżej 10 cm. Przewagą filtru Kalmana jest szybkość predykcji na poziomie 10,7 μ s co generuje przesunięcie poniżej 1 mm dla prędkości 20 m/s, co nie jest wartością znaczącą, gdzie dla sieci LSTM przesunięcie wynosi 3,4 cm (które również jest akceptowalne patrząc na dokładność systemu UWB). Sieć LSTM z kolei pozwala na predykcję do 10 pozycji, których dokładność jest na poziomie pojedynczej predykcji otrzymywanej z wykorzystaniem filtru Kalmana. Tak więc zaproponowaną sieć typu LSTM należy wykorzystać w sytuacjach, w których dochodzi do kilkukrotnych braków danych z systemu UWB następujących po sobie.

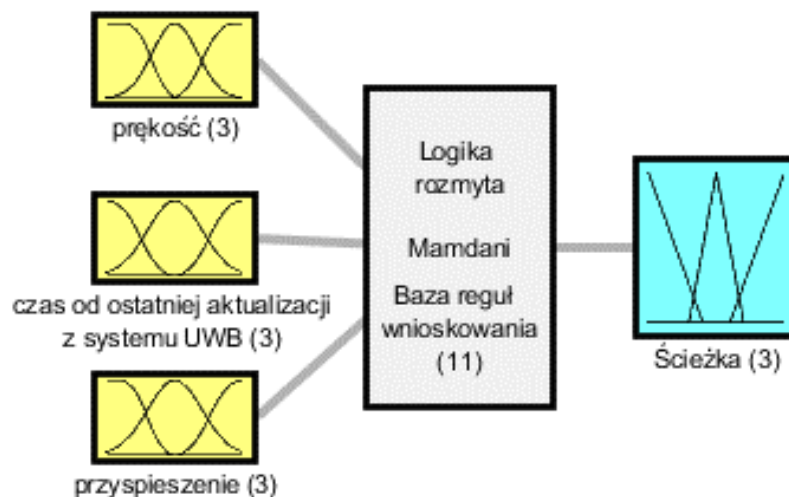
4.5 Rozmyty system ekspercki wyboru ścieżki poruszania się obiektu

Systemy rozmyte w odróżnieniu od logiki binarnej pozwalają na opis pracy układu w sposób bardziej zrozumiały dla człowieka – nie tylko posługując się wartościami 0 i 1, ale również pozostałymi wartościami z tego przedziału. Zacierane są sztywne granice pomiędzy stanami przy zastosowaniu różnych funkcji przynależności. Logika ta stosowana jest w wielu dziedzinach, w których opis matematyczny problemu, zjawiska jest skomplikowany lub niemożliwy. Często posiadane dane nie są precyzyjne (dane z czujników pomiarowych obarczone są błędem systemowym lub losowym) lub nie opisują całej dziedziny problemu. Systemy rozmyte można wykorzystać do sterowania np. układami automatyki przemysłowej, urządzeniami w gospodarstwach domowych, czy też w przemyśle motoryzacyjnym, również gdy występują braki w otrzymywanych danych [108]–[110]. System tego typu jest stabilny przez co mała różnica na wejściu modelu rozmytego będzie skutkować małymi zmianami na jego wyjściu.

Przy budowie systemu rozmytego bardzo ważna jest wiedza eksperta, który na podstawie przeprowadzonych badań, eksperymentów i doświadczenia konstruuje reguły wnioskowania (bazę reguł) oraz dobiera odpowiednie funkcje przynależności. Dane wprowadzane do systemu z różnych źródeł podlegają rozmyciu na bazie przygotowanych reguł i wybranej funkcji przynależności. Po rozmyciu następuje wnioskowanie, czyli na podstawie otrzymanych wartości aktywowane są wybrane reguły i otrzymywana jest wartość, którą należy poddać wyostrzeniu.

Najczęściej spotykane metody wnioskowania to metoda Mamdaniego oraz Sugeno. W niniejszej pracy skupiono się na pierwszym modelu ze względu na małą liczbę wykorzystywanych zmiennych. Reguły tego modelu są bliskie rozumowania człowieka z uwagi na formę instrukcji warunkowej „jeśli-to”, czyli na podstawie części przesłankowej (zdefiniowanych warunków połączonych operatorem „i” lub „lub”) podejmowana jest decyzja.

Do wyboru ścieżki poruszania się obiektu proponuje się decyzyjny system ekspercki oparty na logice rozmytej, który pozwoli podjąć decyzje czy w systemie nadrzędnym do wyznaczenia pozycji obiektu należy wykorzystać pozycję ze ścieżki aktualnej, czy też ścieżki predykowanej lub też poinformować go o braku pozycji o wystarczającej dokładności pozycji. Do zdefiniowania problemu przyjmuje się ruch pojazdu typu AGV, który charakteryzuje się niskimi prędkościami oraz ruch pojazdów samochodowych poruszających się w ruchu miejskim. Zakłada się, że system otrzymuje informacje o tym, że dane z systemu są aktualne (dostępne są dane z systemu UWB), pochodzą z pierwszej predykcji (brak danych z systemu UWB występujący po raz pierwszy) lub bazują na predykcjach kolejnych (brak danych z systemu UWB występujący drugi lub kolejny raz z kolei). Wprowadza się następujące zmienne lingwistyczne: prędkość (v), czas od ostatniej aktualizacji pozycji z systemu UWB (t_{UWB} , jako wielokrotność czasu akwizycji danych z systemu UWB t_p) oraz przyspieszenie obiektu w osi wzdłużnej pojazdu (a) – patrz rys. 51. Zaproponowany system bazuje na metodzie wnioskowania opartego na pojedynczych regułach (FITA – *ang. first infer then aggregate*), w którym stosowane jest wnioskowanie a po nim agregacja reguł.



Rys. 51. Model wnioskowania rozmytego

W tab. 31 zebrano zmienne lingwistyczne oraz przestrzeń rozważań dla każdej ze zmiennych wejściowych oraz konkluzję wyjściową.

Tab. 31. Zmienne i wartości lingwistyczne oraz przestrzeń rozważań wnioskowania

Zmienna lingwistyczna	Wartość lingwistyczna	Przeźrzeń rozważań	
(1)	(2)	(3)	
Wejście	Prędkość (v)	mała, normalna, duża	$\langle 0, 15 \rangle$
	Czas od ostatniej aktualizacji UWB (t_{UWB})	aktualna, predykcja, stara	$\langle 0, 2 \rangle$
	Przyspieszenie (a)	małe, średnie, duże	$\langle 0, 10 \rangle$
Wyjście	Ścieżka (S)	aktualna, predykcja, mała dokładność	$\langle 0, 1 \rangle$

Przyjęto następujące funkcje przynależności wejścia: funkcje gaussowskie (87) oraz funkcje S (88) i Z (89) – na krańcach przedziałów. Funkcje przynależności wyjścia modelu ustala się na funkcję trójkątną (90). W tab. 32 zaprezentowano przyjęte wartości parametrów wykorzystywanych funkcji przynależności. Wykorzystano typowe operatory T-normy (minimum), S-normy (maksimum), implikacji (minimum) i agregacji (maksimum). Precyzowanie wykonywane jest metodą środka ciężkości, a następnie przez progowanie na wyjściu decyzyjnego systemu eksperckiego otrzymywana jest informacja, czy należy wykorzystać dane ze ścieżki aktualnej, predykowanej, czy też dostępne dane są małej dokładności. Analiza różnych T-norm i S-norm, metody wyostrozania, implikacji czy agregacji jest możliwa, ale wykracza poza główny wątek tej pracy.

$$\mu(x; a, b) = e^{-\left(\frac{x-b}{a}\right)^2} \quad (87)$$

$$\mu(x; a, b) = \begin{cases} 0 & \text{dla } x < a \\ \frac{x-a}{b-a} & \text{dla } a \leq x \leq b \\ 1 & \text{dla } x > b \end{cases} \quad (88)$$

$$\mu(x; a, b) = \begin{cases} 1 & \text{dla } x < a \\ \frac{a-x}{a-b} & \text{dla } a \leq x \leq b \\ 0 & \text{dla } x > b \end{cases} \quad (89)$$

$$\mu(x; a, b, c) = \begin{cases} 0 & \text{dla } x \leq a \\ \frac{x-a}{b-a} & \text{dla } a < x \leq b \\ \frac{c-x}{c-b} & \text{dla } b < x \leq c \\ 0 & \text{dla } x > c \end{cases} \quad (90)$$

gdzie: a, b, c – parametry funkcji przynależności.

Tab. 32. Parametry funkcji przynależności zmiennych lingwistycznych

Zmienna lingwistyczna	Wartość lingwistyczna	Funkcja przynależności	Parametry [a;b;c]
(1)	(2)	(3)	(4)
Prędkość	mała	Z	[2; 8]
	normalna	Gausa	[2,5; 7,5]
	duża	S	[7; 14]
Czas od ostatniej aktualizacji UWB	aktualna	Z	[0; 1]
	predykcja	Gausa	[0,4; 1]
	stara	S	[1; 2]
Przyspieszenie	małe	Z	[1; 5]
	średnie	Gausa	[2; 5]
	duże	S	[5; 10]
Ścieżka	aktualna	trójkątna	[0; 0; 0,4]
	predykcja	trójkątna	[0,3; 0,5; 0,7]
	mała dokładność	trójkątna	[0,6; 1; 1]


Teoretyczna liczba reguł rośnie wykładniczo wraz z liczbą zmiennych w przestrzeni, tak więc liczba wszystkich możliwych reguł na podstawie zdefiniowanych zmiennych i wartości lingwistycznych wynosi 27. Wraz ze wzrostem liczby reguł trudniej ocenić ich dopasowanie do analizowanego problemu oraz trudniej zrozumieć relacje między przesłankami i konsekwencjami. Z tego powodu istotna jest wiedza ekspercka i doświadczenie w danej klasie problemu. Na bazie zdobytej wiedzy proponuje się wprowadzenie reguł w liczbie 11 (tab. 33).

Tab. 33. Reguły wnioskowania


Jeśli	To
(1)	(2)
$v==\text{mała} \ \& \ (t_UWB\sim=\text{stara})$	$(S=\text{aktualna})$
$(v==\text{normalna}) \ \& \ (t_UWB==\text{aktualna})$	$(S=\text{aktualna})$
$(v==\text{duża}) \ \& \ (t_UWB\sim=\text{stara}) \ \& \ (a\sim=\text{duże})$	$(S=\text{predykcja})$
$(t_UWB==\text{stara})$	$(S=\text{mała dokładność})$
$(v\sim=\text{duża}) \ \& \ (t_UWB==\text{aktualna})$	$(S=\text{aktualna})$
$(t_UWB==\text{stara}) \ \& \ (a==\text{duże})$	$(S=\text{mała dokładność})$
$(a==\text{duże})$	$(S=\text{mała dokładność})$
$(v\sim=\text{duża}) \ \& \ (t_UWB\sim=\text{stara}) \ \& \ (a==\text{duże})$	$(S=\text{predykcja})$
$(v==\text{duża}) \ \& \ (t_UWB==\text{aktualna})$	$(S=\text{predykcja})$
$(v==\text{normalna}) \ \& \ (t_UWB\sim=\text{stara}) \ \& \ (a\sim=\text{duże})$	$(S=\text{predykcja})$
$(v==\text{mała}) \ \& \ (t_UWB==\text{stara}) \ \& \ (a==\text{małe})$	$(S\sim=\text{mała dokładność})$

Na rys. 52, rys. 53 i rys. 54 przedstawiono wynikowe płaszczyzny wyjścia, będące rezultatem przygotowanych reguł wnioskowania odpowiednio dla prędkości i czasu od ostatniej aktualizacji z systemu UWB, prędkości i przyspieszenia oraz przyspieszenia i czasu od ostatniej


aktualizacji z systemu UWB. Wraz z czasem od pozyskania ostatniej pozycji i z prędkością obiektu, pojazd oddala się od pozycji, w których pozyskane zostały dane o odległościach, w związku z czym wraz ze wzrostem tych zmiennych wybierana będzie kolejno: pozycja aktualna, predykcja lub mała dokładność pozycji. Przyspieszenie poruszającego się obiektu również wpływa na decyzję co do jakości pozycji. Wraz ze wzrostem przyspieszenia obiektu system nadrzędny otrzyma analogiczne informacje.



Rys. 52. Płaszczyzna wyjścia prędkości od czasu ostatniej aktualizacji z systemu UWB




Rys. 53. Płaszczyzna wyjścia przyspieszenia od prędkości



Rys. 54. Płaszczyzna wyjścia przyspieszenia od czasu ostatniej aktualizacji z systemu UWB

Działanie wnioskowania rozmytego zaprezentowano w funkcji prędkości i przyspieszenia na rys. 55 (dane aktualne – oznaczone linią ciągłą, dane po pierwszej predykcji – linią kreskową, dane po drugiej i kolejnej predykcji (stare) – linią punktową).



Rys. 55. Wnioskowanie rozmyte

Wraz ze wzrostem czasu od ostatniej aktualizacji z systemu UWB t_{UWB} zaprojektowany decyzyjny system ekspercki wskazuje małą jakość pozycji. Dla danych aktualnych z systemu UWB oraz małej prędkości oraz małego przyspieszenia system wskazuje na wykorzystanie ścieżki aktualnej. Wraz ze wzrostem przyspieszenia i prędkości system będzie wskazywał ścieżkę predykowaną. Dla dużych prędkości i dużego przyspieszenia decyzyjny system ekspercki podaje informację o małej dokładności posiadanych pozycji na wyjściu systemu. Dla starych próbek i małych prędkości system podpowiada, aby wykorzystać dane ze ścieżki predykowanej natomiast dla pozostałych prędkości informuje o małej dokładności pozycji.

Wyjście zaproponowanego decyzyjnego systemu eksperckiego podaje informację, czy do pozycjonowania obiektu w danym momencie należy wykorzystać dane o pozycji ze ścieżki aktualnej, ścieżki predykowanej czy też dostępne na wyjściu pozycje są małej dokładności.

4.6 Analiza czasu przetwarzania, wyniki eksperymentu

W systemach pozycjonowania czas przetwarzania danych jest kluczowy, aby pozycja pozyskana na podstawie zebranych i przeanalizowanych danych była możliwie jak najbardziej dokładna. W przypadku wyznaczania pozycji obiektu wiąże się to z otrzymaniem informacji o pozycji lub jej predykcji, uwzględniając czas pozyskania i przetwarzania danych, możliwie jak najbliższej pozycji aktualnej obiektu. W tab. 34 zebrano wyznaczone w pracy czasy wykonywania zaproponowanych poszczególnych etapów analizy danych z systemu UWB.

Tab. 34. Czas przetwarzania poszczególnych etapów analizy danych

Etap analizy danych	Wariant	Czas przetwarzania [μs]
(1)	(2)	(3)
Akwizycja danych	Pakiet danych UWB co 12 ms	12000
Korekta odległości	Wielomian drugiego stopnia	0,64
Metoda trilateracji	LSM	13
	Sympleksowa wariant II	555
Metoda predykcji	Filtr Kalmana	10,7
	Sieć typu LSTM	1900
Wnioskowanie	Rozmyty system wnioskowania	122,9

Zestawienie czasów wykonywania poszczególnych etapów przetwarzania danych pozwala wyznaczyć dystans, który obiekt pokona w trakcie akwizycji i analizy danych. W tab. 35 przedstawiono całościowe czasy przetwarzania oddzielnie dla zaproponowanych metod trilateracji (metody najmniejszych kwadratów, metody sympleksowej – wariant II) oraz metod wyznaczania ścieżki predykowanej (filtru Kalmana oraz sieci neuronowej typu LSTM) wraz

z odpowiadającymi im przebytymi dystansami dla warunków brzegowych, oddzielnie dla pojazdu typu AGV (kolumna 4) oraz pojazdu samochodowego (kolumna 5).

Tab. 35. Całościowy czas przetwarzania danych w zaproponowanym systemie

Metoda trilateracji	Metoda predykcji	Czas przetwarzania [ms]	AGV 2 m/s [cm]	Pojazd sam. 14 m/s [cm]
(1)	(2)	(3)	(4)	(5)
LSM	Filtr Kalmana	12,02	2,40	16,83
	Sieć LSTM	13,91	2,78	19,48
Sympleksowa – wariant II	Filtr Kalmana	12,57	2,51	17,59
	Sieć LSTM	14,46	2,89	20,24

Przedstawione dystanse odpowiadają najgorszemu z możliwych przypadków, kiedy obiekt porusza się stale w jednym kierunku. Biorąc pod uwagę czas przetwarzania i bezwładność analizowanych obiektów można przyjąć, że taki przypadek będzie występował zawsze pomiędzy kolejnymi odczytami z systemu UWB. Biorąc pod uwagę możliwy do pokonania przez obiekt dystans w trakcie przetwarzania danych oraz maksymalne błędy systemu UWB dla pozycji i predykcji oraz przyjęty współczynnik bezpieczeństwa proponuje się minimalne obszary bezpieczeństwa przedstawione w tab. 36 obliczone według wzoru (91). Obszar ten dla pojazdu typu AGV wynosi 50 cm, a dla pojazdu samochodowego 110 cm – czyli dopuszcza się możliwość wystąpienia powyższych błędów systemu podczas normalnego ich działania przy zadanych brzegowych parametrach prędkości i przyspieszenia.

$$O_b = (d_p + \varepsilon_{max}) \cdot \alpha \quad (91)$$


gdzie: d_p – maksymalne przesunięcie wynikające z czasu przetwarzania; ε_{max} – maksymalny błąd systemu UWB; α – współczynnik bezpieczeństwa.

Tab. 36. Obszary bezpieczeństwa

Typ pojazdu	d_p [cm]	ε_{max} [cm]	α	O_b [cm]
(1)	(2)	(3)	(4)	(5)
AGV	3	24	2	50
Pojazd samochodowy	20	36		110

Działanie zaproponowanego systemu wyznaczania pozycji obiektu będącego w ruchu zostało przetestowane z wykorzystaniem pojazdu typu AGV poruszającego się z prędkością 0,9 m/s po torze o znanym kształcie. AGV został wyposażony w lidar (dalmierz laserowy) o dokładności 2 cm, który na bieżąco określał odległość do ściany (punktu końcowego). Stanowisko testowe wyposażone w cztery punkty referencyjne systemu UWB, ścieżkę

referencyjną, po której poruszał się obiekt (pozyskaną na bazie danych pozyskanych z lidar) i wyznaczone pozycje obiektu w procesie analizy danych zaproponowanym systemem, zaprezentowano na rys. 56. Do wyznaczania pozycji obiektu wykorzystano metodę trilateracji opartą na metodzie LSM. Na ścieżce poruszania się obiektu zaznaczono miejsca, w których system rekomendował wykorzystanie pozycji ze ścieżki predykowanej ze względu na brak danych z systemu UWB, w pozostałych sytuacjach system rekomendował wykorzystanie ścieżki aktualnej, ponieważ prędkość obiektu była mała, a dane z systemu UWB były aktualne.



Rys. 56. Przejazd pojazdu typu AGV

Dokładność pozycji obiektu, wyznaczonej na podstawie danych pochodzących bezpośrednio z systemu UWB wynosi 27 cm – RMSE, błąd maksymalny 145 cm. Po wykonaniu czyszczenia danych (metodą opisaną w punkcie 4.1.1) i korekcie odległości (zaproponowaną funkcją korekty w podrozdziale 4.2) błąd RMSE zmalał do 16 cm, przy błędzie maksymalnym wynoszącym 87 cm. Pozycja na ścieżce aktualnej, wyznaczona z wykorzystaniem filtra Kalmana, charakteryzuje się błędem RMSE wynoszącym 13 cm (błąd maksymalny 54 cm) co w stosunku do pozycji wyznaczonej bezpośrednio na danych pochodzących z systemu UWB daje błąd RMSE niższy o 14 cm. Decyzyjny system ekspercki oparty na logice rozmytej automatycznie wskazuje, jakie dane należy wykorzystać do wyznaczenia pozycji obiektu, co pozwoliło poprawić dokładność wyznaczonej pozycji obiektu o 3 cm w pozycjach, w których wykorzystano

rekomendowaną predykcję. W efekcie końcowym zaproponowany system i zawarte w nim poszczególne etapy przetwarzania danych pozwoliły zwiększyć dokładność wyznaczonej pozycji z 27 cm do 13 cm co jest wynikiem zadawalającym i mieszczącym się w wyznaczonych obszarach bezpieczeństwa.

4.7 Podsumowanie

Dokładność procesu wyznaczania pozycji zależy od dokładności wyznaczonych odległości pomiędzy węzłami w sieci. Analiza czasów poszczególnych etapów przetwarzania danych pokazuje, że największy wpływ na dokładność wyznaczonej pozycji ma opóźnienie (wynikające z czasu potrzebnego na pomiar odległości pomiędzy węzłami w sieci, ich udostępnienie oraz filtrację wstępną), w związku z tym nie zaleca się stosowania filtrów z kroczącym oknem dla systemów działających w czasie rzeczywistym w szczególności, gdy obiekt porusza się z prędkościami powyżej 2 m/s. Redukcja czasu nie jest możliwa, ale określenie predykcji pozycji na podstawie danych historycznych jest możliwe za pomocą filtru Kalmana, który nie generuje przesunięcia (jak filtry wstępne), a ponadto dostarcza informację o pozycji następnej w związku z czym jest lepszym wyborem w zastosowaniach czasu rzeczywistego. Należy pamiętać, że implementacja filtru Kalmana wymaga modelu matematycznego opisywanego zjawiska fizycznego, który w kontekście pozycjonowania jest zmianą w położeniu w każdej z osi (w niniejszej pracy wykorzystano równanie dla ruchu jednostajnie przyspieszonego). Model uwzględnia pozycję obiektu wyznaczoną na podstawie otrzymanych odległości z systemu UWB i przyspieszenia działające na obiekt odczytanych z akcelerometru. W tej metodzie należy wykonać odpowiednią transformację układu odniesienia obiektu (sensorów inercyjnych) do lokalnego układu pozycjonowania. Ponadto zastosowanie filtru Kalmana pozwala nie tylko na filtrację i fuzję danych, ale również na predykcję pozycji obiektu z dokładnością na poziomie pozycji po filtracji, uwzględniając całościowy czas przetwarzania.

Zaproponowana funkcja korekty odległości (funkcją wielomianową drugiego stopnia) pozwala poprawić dokładność wyznaczonej odległości z 17,9 cm do 6,9 cm w odniesieniu do RMSE oraz z 17,5 cm do 6,5 cm w odniesieniu do MBE. Jednocześnie funkcja ta ma niską złożoność obliczeniową, nie wprowadzając znacznego przesunięcia wynikającego z czasu wykonania korekty (poniżej 1 mm dla wszystkich badanych prędkości co jest wartością pomijalnie małą), co jest z kolei ważne podczas analizy danych w czasie rzeczywistym. Dokładność wymiarowania wprost przekłada się na dokładność wyznaczonej pozycji obiektu w metodzie trilateracji. Funkcja korekty powinna być dopasowana do wykorzystywanego systemu UWB zgodnie z procedurą opisaną w podrozdziale 4.2. Do odwzorowania błędu

pomiaru odległości i tym samym wyznaczania wartości korekty w funkcji odległości wykorzystano MBE, czyli błąd systematyczny systemu.

Wybór algorytmu trilateracji zależy od konkretnego przeznaczenia, gdzie do wyznaczania pozycji w czasie rzeczywistym poleca się metodę LSM, która nie generuje znaczącego przesunięcia (poniżej 1 mm dla wszystkich badanych odległości, co przestaje mieć znaczenie przy dokładności systemu rzędu centymetrów). Zastosowanie metody sympleksowej wiąże się ze zwiększeniem przesunięcia obiektu wynikającego z czasu potrzebnego na jej wykonanie, jednakże dla obiektów typu AGV można uznać, że przesunięcie poniżej 1,4 mm nie jest znaczące w stosunku do przemieszczenia, które generowane jest przez czas potrzebny do pozyskiwania pakietu danych UWB. W stosunku do pojazdów samochodowych przesunięcie to również nie jest duże (poniżej 1 cm) i przy gabarytach pojazdu samochodowego można również uznać, że przemieszczenie to nie jest znaczące. Wykorzystując korektę odległości wielomianem drugiego stopnia i posiadając cztery odległości od punktów referencyjnych, korzyści płynące z zastosowania metody sympleksowej (dla przykładu w wariancie I) w stosunku do metody najmniejszych kwadratów, będą zredukowane przez przemieszczenie obiektu spowodowane czasem potrzebnym na wyznaczenie pozycji. W pesymistycznym przypadku dla prędkości 20 m/s (AGV – 2 m/s, pojazd samochodowy – 14 m/s) przełoży się to na poprawę dokładności wyznaczonej pozycji o około 0,66 cm (AGV – 1,63 cm, pojazd samochodowy – 0,98 cm), a nie 1,74 cm (w stosunku do RMSE). Zastosowanie metody sympleksowej jest korzystne i rekomendowane w sytuacjach, w których liczba dostępnych odległości jest niewystarczająca (2 odległości w pozycjonowaniu na płaszczyźnie 2D), ponieważ w takiej sytuacji błąd tej metody jest trzykrotnie mniejszy niż metody LSM.

Rozwiązaniem problemu przesunięcia (wynikającego z opóźnień systemu pozycjonowania) jest predykcja pozycji obiektu bazująca na danych historycznych. Ponadto predykcja pozycji pozwala na kontynuację pozycjonowania w sytuacjach, w których występuje chwilowy zanik sygnału z systemu UWB (brak pakietu danych). Wówczas bez predykcji nie ma możliwości wyznaczenia bezwzględnej pozycji obiektu w lokalnym systemie odniesienia, a w zaproponowanym podejściu wyznaczenie pozycji jest możliwe.

Zaproponowany sposób predykcji pozycji z wykorzystaniem sieci typu LSTM poprzez wyznaczenie przemieszczeń w każdej z osi na podstawie danych z systemu UWB pozwala stworzyć system bardziej uniwersalny, który nie jest zależny od rozmiaru obszaru (od przyjętego układu współrzędnych), po którym poruszać będzie się obiekt – predykcja możliwa jest na dowolnym odcinku ścieżki niezależnie od bezwzględnej pozycji obiektu. Jako, że nie są

predykowane bezwzględne pozycje w lokalnym układzie odniesienia, nie ma problemu ze skalowalnością systemu i jednocześnie proces normalizacji jest łatwy do przeprowadzenia. Podkreślić należy, że zaproponowane przykładowe przejazdy obejmują różne scenariusze ruchu obiektu, które pozwoliły przetestować zaproponowaną metodę i wyznaczyć jej skuteczność. Dobór struktury sieci jest zadaniem wymagającym wielu eksperymentów i testów. Z przeprowadzonej analizy wynika, że sieć z jedną warstwą ukrytą z stoma komórkami pamięci, pozwala na predykcję 10 pozycji z dokładnością rzędu centymetrów. Zaproponowana sieć wykazuje również funkcję filtrującą co pozwala zminimalizować wpływ błędu systemu na pozycję obiektu. Potwierdzono również, że dokładność pojedynczej predykcji z wykorzystaniem filtra Kalmana jest rzędu dokładności pozycji aktualnej.

Zaproponowany decyzyjny system ekspercki, oparty na logice rozmytej, jest źródłem informacji dla systemów wyższego poziomu. System ten na podstawie rekomendacji decyzyjnego systemu eksperckiego zdecyduje, czy dostępne dane o pozycji pozwalają na bezpieczne poruszanie się obiektu. Uwzględnione zostały takie parametry jak prędkość, czas od ostatniej aktualizacji pozycji z systemu UWB, czy przyspieszenie ruchu obiektu. Wyjście systemu eksperckiego po progowaniu wskazuje, czy należy wykorzystać dane o pozycji aktualnej, predykcje, czy też dostępne pozycje są małej dokładności.

Przeprowadzona analiza czasów wykonywania poszczególnych etapów przetwarzania danych w celu otrzymania pozycji lub jej predykcji, jak również otrzymane błędy dla poszczególnych metod predykcji pozycji pozwalają wyznaczyć minimalny obszar bezpieczeństwa. Obszar ten powinien być zachowany pomiędzy poruszającymi się obiektami lub też poruszającymi się obiektami i elementami infrastruktury w celu zapewnienia bezpieczeństwa w trakcie pozyskiwania i przetwarzania kolejnych danych z systemów pozycjonowana. Proponuje się następujące minimalne obszary bezpieczeństwa: na poziomie 50 cm dla AGV oraz 110 cm dla pojazdu samochodowego. Obszary zależą od konkretnego zastosowania ze względu na różne czasy akwizycji danych w różnych systemach UWB oraz od dostępnej platformy obliczeniowej na wyposażeniu pojazdu.

Testy przeprowadzone zostały w warunkach laboratoryjnych, tak więc oszacowane czasy wykonywania poszczególnych etapów dotyczą wykorzystania komputera klasy PC, tak więc modele i obszary bezpieczne będą wymagać dostrojenia w zależności od dostępnej platformy obliczeniowej.

5 Podsumowanie i wnioski końcowe

Przedstawiona rozprawa doktorska dotyczy opracowania systemu decyzyjnego pozycjonowania obiektów będących w ruchu na podstawie danych z systemów: UWB i nawigacji inercyjnej INS (AHRS), umieszczonego w newralgicznych miejscach infrastruktury, działającego w czasie rzeczywistym. Zaproponowany system pozycjonowania jest systemem pozycjonowania kooperacyjnego, który wykorzystując dane z różnych systemów i technologii pozwala poprawić jakość pozycjonowania oraz niweluje opóźnienia wprowadzane przez system pozycjonowania UWB, dodatkowo zwiększając pokrycie systemu. W pracy zaproponowano sposób przetwarzania danych z systemu UWB obejmujący zastosowanie korekty odległości, predykcję z wykorzystaniem sieci typu LSTM, ekspercki system decyzyjny oparty na logice rozmytej, jak również zaprojektowano i zbudowano symulator systemu pozycjonowania UWB.

Zaproponowane metody oraz analiza pozyskanych danych pozwalają stwierdzić, że wykorzystanie sieci neuronowej oraz systemu rozmytego do predykcji pozycji i wyboru ścieżki poruszającego się obiektu w lokalnym systemie pozycjonowania opartym na technologii UWB, zwiększają dokładność wyznaczonej pozycji oraz pozwalają na nieprzerwane pozycjonowanie w trakcie krótkotrwałych braków danych z systemu UWB.

Do oryginalnych osiągnięć Autora zalicza się:

- opracowanie symulatora systemu UWB wraz z procedurą pozyskania danych umożliwiającą odwzorowanie rzeczywistego systemu bez znajomości dokładnych parametrów transmisji,
- stworzenie funkcji korekty odległości pozyskanych z systemu UWB z wykorzystaniem funkcji wielomianowej, która redukuje niedokładności wyznaczonej pozycji w procesie trilateracji,
- adaptację metody sympleksowej do wyznaczania pozycji obiektu w procesie trilateracji wraz z wyborem punktu początkowego,
- opracowanie procedury predykcji pozycji obiektu będącego w ruchu z wykorzystaniem sieci neuronowej typu LSTM, która redukuje opóźnienie wprowadzane przez system pozycjonowania UWB,
- wprowadzenie decyzyjnego systemu eksperckiego opartego na logice rozmytej, który umożliwia rekomendację ścieżki poruszania się obiektu,

- zaproponowanie obszarów bezpieczeństwa z uwzględnieniem czasu całego procesu przetwarzania danych zarówno dla pojazdów AGV, jak i pojazdów samochodowych.

Połączenie danych z systemu UWB i IMU oraz wykorzystanie sieci neuronowej lub filtra Kalmana pozwala na predykcję pozycji obiektu, co przy dużych prędkościach obiektu przekłada się na wyznaczenie pozycji aktualnej (ze względu na czas, który potrzebny jest na akwizycję oraz analizę danych). Przeprowadzone analizy opracowanych metod trilateracji, korekty odległości oraz filtracji z wykorzystaniem filtra Kalmana dowodzą słuszności stawianej tezy: „Wykorzystanie lokalnego podsystemu pozycjonowania UWB oraz zastosowanie filtracji komplementarnej zwiększa dokładność przy dopuszczalnym czasie wyznaczania pozycji poruszającego się obiektu.”

Fuzja danych przy pomocy filtra Kalmana, czy też sieci neuronowej, możliwość predykcji pozycji z zastosowaniem tych dwóch metod oraz zbudowany decyzyjny system ekspercki oparty na logice rozmytej prowadzą do potwierdzenia słuszności tezy: „Fuzja danych pochodzących z podsystemów pozycjonowania wraz z wykorzystaniem systemu rozmytego i sieci neuronowej umożliwia wybór aktualnej i predykcję ścieżki poruszania się obiektu w akceptowalnym czasie”.

Na podstawie powyższego należy stwierdzić, że cel pracy: „Opracowanie systemu decyzyjnego pozycjonowania obiektów będących w ruchu na podstawie danych z systemów: UWB i nawigacji inercyjnej INS (AHRS), umieszczonego w newralgicznych miejscach infrastruktury, działającego w czasie rzeczywistym” został osiągnięty a tezy udowodnione.

Zbudowany symulator systemu UWB otwiera szereg możliwości w testowaniu algorytmów pozycjonowania, czy metod analizy danych. Przyszłe badania będą w dalszym ciągu ukierunkowane na procesie poprawy dokładności wyznaczonej pozycji obiektu oraz jej predykcji, a to z kolei będzie miało wpływ na bezpieczeństwa pojazdów samojezdnych.

Przewiduje się również rozszerzyć badania w kontekście obiektów latających, co będzie kolejnym wyzwaniem, aby zapewnić bezpieczne poruszanie się obiektu nie tylko na płaszczyźnie dwuwymiarowej, ale również w przestrzeni. Małe obiekty latające z uwagi na małą wagę charakteryzują się inną dynamiką ruchu, przez co opracowywane dotychczas metody oraz analiza danych muszą być zmodyfikowane.

Elementy niniejszej rozpraw są wynikiem współpracy z firmami z branży motoryzacyjnej oraz konsultacji z ekspertami zaangażowanymi w projekty z sektora motoryzacyjnego i przemysłowego, a otrzymane rezultaty badań są odpowiedzią na wskazane problemy. Autor chciałby podziękować za możliwość udziału w projektach:

- "Innowacyjna technologia tworzenia wydarzeń multimedialnych opartych o walki dronów z synergią między poziomami: wirtualnym, rozszerzonym i fizycznym",
- "CoBoAGV: Automated Guided Vehicles integrated with Collaborative Robots for Smart Industry Perspective",
- "WrightBroS: Working in a Collaborative Factory of the Flight Simulators Branch of RISE",
- "ReACTIVE Too: Reliable Electronics for Tomorrow's Active Systems".

Dzięki doświadczeniu zebranemu podczas realizacji wymienionych projektów możliwe było wypracowanie ostatecznych metod i procedur zamieszczonych w niniejszej pracy.

6 Spis tabel

Tab. 1. Poziomy automatyzacji SAE	7
Tab. 2. Poziomy automatyzacji SAE – opis poziomów	7
Tab. 3. Odległości, w których wykonano pomiary statyczne	43
Tab. 4. Statystyki testowe pomiaru odległości w warunkach LOS.....	45
Tab. 5. Statystyki testowe dokładności pomiaru odległości w warunkach LOS.....	47
Tab. 6. Współczynniki i przedziały funkcji aproksymujących zmianę SD	53
Tab. 7. Współczynniki i przedziały funkcji aproksymujących zmianę MBE w warunkach LOS ...	54
Tab. 8. Statystyki testowe pomiaru odległości w warunkach NLOS	55
Tab. 9. Statystyki testowe dokładności pomiaru odległości w warunkach NLOS.....	56
Tab. 10. Współczynniki i przedziały funkcji aproksymujących zmianę odchylenia standardowego w warunkach NLOS	57
Tab. 11. Współczynniki i przedziały funkcji aproksymujących zmianę MBE w warunkach NLOS	57
Tab. 12. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja metodą sympleksową)	80
Tab. 13. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 4 odległości, metodą sympleksową w wariancie II)	83
Tab. 14. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 4 odległości, metodą najmniejszych kwadratów)	83
Tab. 15. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 3 odległości, metodą sympleksową w wariancie II)	84
Tab. 16. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 3 odległości, metodą najmniejszych kwadratów)	84
Tab. 17. Błąd pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 2 odległości, metodą sympleksową w wariancie II)	85
Tab. 18. Statystyka błędu pozycji obiektu na torze testowym bez korekty oraz z korektą odległości (trilateracja – 2 odległości, metodą najmniejszych kwadratów)	85
Tab. 19. Czas wyznaczania pozycji w zależności od wykorzystanej metody trilateracji	86
Tab. 20. Opis serii pomiarowych.....	91
Tab. 21. RMSE dla predykcji 10 pozycji, predykcja od pozycji z i bez korekty odległości	93
Tab. 22. Skumulowany RMSE dla predykcji pozycji obiektu	94
Tab. 23. RMSE od 1 do 10 pozycji (dane testowe), prędkość stała.....	95
Tab. 24. RMSE dla predykcji od pozycji bez korekty, prędkość stała	96
Tab. 25. RMSE dla predykcji od pozycji skorygowanej, prędkość stała	97
Tab. 26. RMSE od 1 do 10 pozycji (dane testowe), ruch przyspieszony	98
Tab. 27. RMSE dla predykcji od pozycji bez korekty, ruch przyspieszony.....	99
Tab. 28. RMSE dla predykcji od pozycji skorygowanej, ruch przyspieszony	99
Tab. 29. Błąd pozycji obiektu, prędkość stała, filtracja FK	102
Tab. 30. Błąd pozycji obiektu, ruch przyspieszony, filtracja FK.....	103
Tab. 31. Zmienne i wartości lingwistyczne oraz przestrzeń rozważań wnioskowania.....	106
Tab. 32. Parametry funkcji przynależności zmiennych lingwistycznych	107
Tab. 33. Reguły wnioskowania	107
Tab. 34. Czas przetwarzania poszczególnych etapów analizy danych	110
Tab. 35. Całościowy czas przetwarzania danych w zaproponowanym systemie	111
Tab. 36. Obszary bezpieczeństwa	111

7 Spis rysunków

Rys. 1. Przykładowy system pozycjonowania kooperacyjnego.....	20
Rys. 2. Oddziaływanie poszczególnych elementów systemu na proces wyznaczania pozycji....	20
Rys. 3. Podział systemów pozycjonowania ze względu na obszar zastosowania	22
Rys. 4. Podział systemów pozycjonowania ze względu na sposób wyznaczonej pozycji.....	23
Rys. 5. System nawigacji satelitarnej	26
Rys. 6. Globalny a lokalny układ odniesienia	27
Rys. 7. Przykładowe systemy UWB z modułami marki DecaWave	30
Rys. 8. Schemat wymiany OWR	32
Rys. 9. Schemat wymiany SS-TWR	33
Rys. 10. Schemat wymiany SDS-TWR/ADS-TWR.....	34
Rys. 11. Sieć węzłów w sieci UWB.....	35
Rys. 12. Idealny przypadek wymiarowania, w którym okręgi mają jeden punkt wspólny	36
Rys. 13. Orientacja obiektu – pochylenie, odchylenie i przechylenie	39
Rys. 14. Węzeł systemu wymiarowania oparty na module DWM1000.....	41
Rys. 15. Ogólny diagram przepływu symulatora.....	43
Rys. 16. Rozmieszczenie elementów na stanowisku pomiarowym w dwóch wariantach wymiarowania – w warunkach LOS i NLOS.....	44
Rys. 17. Wyznaczone odległości dla odległości referencyjnej 50 cm.....	44
Rys. 18. Wartość średniej i mediany odległości dla badanych odległości referencyjnych	46
Rys. 19. Wartość średniej i odchylenia standardowego odległości dla badanych odległości referencyjnych	47
Rys. 20. Minimalna i maksymalna wartość błędu dla badanych odległości	49
Rys. 21. MBE z wartością minimalną i maksymalną błędu dla badanych odległości	49
Rys. 22. RMSE z wartością minimalną i maksymalną błędu dla badanych odległości	50
Rys. 23. Porównanie RMSE z MBE dla badanych odległości	50
Rys. 24. Funkcja gęstości prawdopodobieństwa dopasowanego rozkładu normalnego	51
Rys. 25. Dystrybuanta dopasowanego rozkładu normalnego dla badanej próby	51
Rys. 26. Parametry rozkładów normalnych dopasowanych do każdej z badanych odległości...	52
Rys. 27. Podział odchylenia standardowego (wyznaczonych rozkładów) na fragmenty	53
Rys. 28. Podział MBE na fragmenty oraz funkcje aproksymujące zmiany w przedziałach	54
Rys. 29. Parametry fragmentów ścieżki referencyjnej (prostych i łuków).....	59
Rys. 30. Zmiana punktu startowego łuku (z dokładnością do 90°) dla ruchu zgodnego z ruchem wskazówek zegara (a) oraz dla ruchu przeciwnego do ruchu wskazówek zegara (b).	60
Rys. 31. Przykładowy ruch po okręgu zgodnie z ruchem wskazówek zegara rozpoczynający się w kącie 90°.	61
Rys. 32. Przykładowa ścieżka referencyjna składająca się z prostych i łuku.....	62
Rys. 33. Prędkość, przyspieszenie i prędkość kątowna dla przykładowej ścieżki	62
Rys. 34. Odległości dla przykładowego punktu na ścieżce referencyjnej	64
Rys. 35. Tworzenie pakietu danych UWB.....	64
Rys. 36. Przykładowy opis przeszkody i detekcja NLOS dla wybranego punktu na ścieżce.....	65
Rys. 37. Diagram przepływu symulatora.....	67
Rys. 38. Diagram procesu analizy danych	70
Rys. 39. Opóźnienie filtra z przesuwным oknem	72
Rys. 40. Przemieszczenie obiektu w zależności od długości okna wykorzystanego filtra.....	73
Rys. 41. Ścieżka referencyjna do pomiaru dokładności funkcji korekty odległości	78

Rys. 42. Liczba pozycji na ścieżce i maksymalna odległość pomiędzy kolejnymi odczytami	78
Rys. 43. Aproksymacja MBE w celu korekty odległości	79
Rys. 44. Przemieszczenie obiektu w zależności od prędkości i czasu akwizycji danych	81
Rys. 45. Przemieszczenie obiektu w zależności od czasu wykonania funkcji korekcyjnej	81
Rys. 46. Przemieszczenie obiektu w zależności od zastosowanej metody trilateracji	87
Rys. 47. Struktura sieci LSTM	88
Rys. 48. Liczba pakietów danych UWB w seriach pomiarowych (serie nieposortowane)	91
Rys. 49. Liczba pakietów danych UWB w seriach pomiarowych (serie posortowane)	92
Rys. 50. Ogólna struktura proponowanej sieci neuronowej typu LSTM	93
Rys. 51. Model wnioskowania rozmytego	105
Rys. 52. Płaszczyzna wyjścia prędkości od czasu ostatniej aktualizacji z systemu UWB	108
Rys. 53. Płaszczyzna wyjścia przyspieszenia od prędkości	108
Rys. 54. Płaszczyzna wyjścia przyspieszenia od czasu ostatniej aktualizacji z systemu UWB ...	109
Rys. 55. Wnioskowanie rozmyte	109
Rys. 56. Przejazd pojazdu typu AGV	112

8 Bibliografia

- [1] H. Ford, *Today and tomorrow: commemorative edition of Ford's 1926 classic*. 2019.
- [2] L. Raizer, „Automatic warehouse system”, US10259649B2, kwiecień 2019 [Online]. Dostępne na: <https://patents.google.com/patent/US10259649B2>
- [3] R. Sullivan, J. Lert, S. C. Toebes, N. Ulrich, i F. Hinshaw, „Autonomous transports for storage and retrieval systems”, US10207870B2, luty 2019 [Online]. Dostępne na: <https://patents.google.com/patent/US10207870B2>
- [4] TRANSDEV, „Shared autonomous transport services”. <https://www.transdev.com/en/our-innovations/shared-autonomous-mobility/> (dostęp 24 wrzesień 2020).
- [5] Z. Cao, A. (Avi) Ceder, i S. Zhang, „Real-time schedule adjustments for autonomous public transport vehicles”, *Transp. Res. Part C Emerg. Technol.*, t. 109, s. 60–78, grudz. 2019, doi: 10.1016/j.trc.2019.10.004.
- [6] N. Adnan, S. Md Nordin, M. A. bin Bahruddin, i M. Ali, „How trust can drive forward the user acceptance to the technology? In-vehicle technology for autonomous vehicle”, *Transp. Res. Part Policy Pract.*, t. 118, s. 819–836, grudz. 2018, doi: 10.1016/j.tra.2018.10.019.
- [7] J. Meyer, H. Becker, P. M. Bösch, i K. W. Axhausen, „Autonomous vehicles: The next jump in accessibilities?”, *Res. Transp. Econ.*, t. 62, s. 80–91, cze. 2017, doi: 10.1016/j.retrec.2017.03.005.
- [8] F. Kröger, „Automated Driving in Its Social, Historical and Cultural Contexts”, w *Autonomous Driving*, M. Maurer, J. C. Gerdes, B. Lenz, i H. Winner, Red. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016, s. 41–68. doi: 10.1007/978-3-662-48847-8_3.
- [9] „«No-hands» train”, *Popular Electronics Magazine*, nr 6, 1958.
- [10] K. Bimbraw, „Autonomous Cars: Past, Present and Future - A Review of the Developments in the Last Century, the Present Scenario and the Expected Future of Autonomous Vehicle Technology”, w *Proceedings of the 12th International Conference on Informatics in Control, Automation and Robotics*, Colmar, Alsace, France, 2015, s. 191–198. doi: 10.5220/0005540501910198.
- [11] E. D. Dickmanns i in., „The seeing passenger car «VaMoRs-P»”, w *Proceedings of the Intelligent Vehicles '94 Symposium*, Paris, France, 1994, s. 68–73. doi: 10.1109/IVS.1994.639472.
- [12] D. Pomerleau i T. Jochem, „Rapidly adapting machine vision for automated vehicle steering”, *IEEE Expert*, t. 11, nr 2, s. 19–27, kwi. 1996, doi: 10.1109/64.491277.
- [13] D. Grzechca, P. Rybka, i K. Paszek, „Evaluation of the Accuracy of ADAS Module Readings Based on an Analysis of the Transient Supply Current and Neural Network Application”, *Elektron. Ir Elektrotechnika*, t. 24, nr 3, cze. 2018, doi: 10.5755/j01.eie.24.3.20944.
- [14] „Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles”, SAE International, Standard J3016, 2018.
- [15] Michael A. Ditty i in., „Systems and methods for safe and reliable autonomous vehicles”, US20190258251A1, sierpień 2019 [Online]. Dostępne na: <https://patents.google.com/patent/US20190258251A1>
- [16] R. Bostelman, W. Shackelford, G. Cheok, i R. Norcross, „Standard test procedures and metrics development for automated guided vehicle safety standards”, w *Proceedings of the Workshop on Performance Metrics for Intelligent Systems - PerMIS '12*, College Park, Maryland, 2012, s. 160. doi: 10.1145/2393091.2393123.
- [17] L. Zamora-Cadenas, I. Velez, i J. E. Sierra-Garcia, „UWB-Based Safety System for Autonomous Guided Vehicles Without Hardware on the Infrastructure”, *IEEE Access*, t. 9, s. 96430–96443, 2021, doi: 10.1109/ACCESS.2021.3094279.
- [18] „Stan bezpieczeństwa ruchu drogowego oraz działania realizowane w tym zakresie w 2019 r.” Krajowa Rada Bezpieczeństwa Ruchu Drogowego, 2020. Dostęp: 1 wrzesień 2020.

- [Online]. Dostępne na: https://www.krbrd.gov.pl/files/file_add/download/513_stan-bezpieczenstwa-ruchu-drogowego-oraz-dzialania-realizowane-w-tym-zakresie-w-2019-r..pdf
- [19] N. Kalra i S. M. Paddock, „Driving to Safety: How Many Miles of Driving Would It Take to Demonstrate Autonomous Vehicle Reliability?”, RAND Corporation, Santa Monica, 2016. [Online]. Dostępne na: https://www.rand.org/pubs/research_reports/RR1478.html
- [20] Manoharprasad K. Rao, Mark Cuddihy, i Eric L. Reed, „System and method for combined blind spot detection and rear crossing path collision warning”, US8552848B2, październik 2013 [Online]. Dostępne na: <https://patents.google.com/patent/US8552848B2>
- [21] Christopher Hinninger, Makoto Murata, Masahito Shingyoji, Fumie Nakamura, i Yasuhiko Fujita, „Vehicle blind spot detection and indicator system”, US8310353B2, listopad 2012 [Online]. Dostępne na: <https://patents.google.com/patent/US8310353B2>
- [22] Seiji Matsumoto, Takayuki Seto, Yoshikazu Nobutoki, Takayuki Sato, Kazunori Isomoto, i Yasuhiro Enno, „Blind-spot detection system for vehicle”, US7477137B2, styczeń 2009 [Online]. Dostępne na: <https://patents.google.com/patent/US7477137B2>
- [23] M. Blanco *i in.*, „Automated Vehicles: Take-Over Request and System Prompt Evaluation”, w *Road Vehicle Automation 3*, G. Meyer i S. Beiker, Red. Cham: Springer International Publishing, 2016, s. 111–119. doi: 10.1007/978-3-319-40503-2_9.
- [24] M. Torrent-Moreno, J. Mittag, P. Santi, i H. Hartenstein, „Vehicle-to-Vehicle Communication: Fair Transmit Power Control for Safety-Critical Information”, *IEEE Trans. Veh. Technol.*, t. 58, nr 7, s. 3684–3703, wrz. 2009, doi: 10.1109/TVT.2009.2017545.
- [25] Vern Stempnik, Brian Choi, Mark Crawford, Aric David Shaffer, i Michael David Kane, „Enhanced alignment method for park assist”, US8957786B2, luty 2015 [Online]. Dostępne na: <https://patents.google.com/patent/US8957786B2>
- [26] L. Xiao i F. Gao, „A comprehensive review of the development of adaptive cruise control systems”, *Veh. Syst. Dyn.*, t. 48, nr 10, s. 1167–1192, paź. 2010, doi: 10.1080/00423110903365910.
- [27] E. Uhlemann, „Time for Autonomous Vehicles to Connect [Connected Vehicles]”, *IEEE Veh. Technol. Mag.*, t. 13, nr 3, s. 10–13, wrz. 2018, doi: 10.1109/MVT.2018.2848342.
- [28] J. Fang *i in.*, „Augmented LiDAR Simulator for Autonomous Driving”, *IEEE Robot. Autom. Lett.*, t. 5, nr 2, s. 1931–1938, kwi. 2020, doi: 10.1109/LRA.2020.2969927.
- [29] T. Brunner, J.-P. Lauffenburger, S. Changey, i M. Basset, „Magnetometer-Augmented IMU Simulator: In-Depth Elaboration”, *Sensors*, t. 15, nr 3, s. 5293–5310, mar. 2015, doi: 10.3390/s150305293.
- [30] A. Lecointre, A. Berthe, D. Dragomirescu, J. Turbert, i Robert. Plana, „Performance evaluation of Impulse Radio Ultra Wide band Wireless Sensor Networks”, w *MILCOM 2009 - 2009 IEEE Military Communications Conference*, Boston, MA, USA, paź. 2009, s. 1–7. doi: 10.1109/MILCOM.2009.5379751.
- [31] „Information technology – Real time locating systems – Test and evaluation of localization and tracking systems”, International Organization for Standardization, Geneva, CH, Standard ISO/IEC 18305, 2016.
- [32] J. Gabela *i in.*, „Experimental Evaluation of a UWB-Based Cooperative Positioning System for Pedestrians in GNSS-Denied Environment”, *Sensors*, t. 19, nr 23, s. 5274, lis. 2019, doi: 10.3390/s19235274.
- [33] H. Hellmers, Z. Kasmi, A. Norrdine, i A. Eichhorn, „Accurate 3D Positioning for a Mobile Platform in Non-Line-of-Sight Scenarios Based on IMU/Magnetometer Sensor Fusion”, *Sensors*, t. 18, nr 2, s. 126, sty. 2018, doi: 10.3390/s18010126.
- [34] A. Alarifi *i in.*, „Ultra Wideband Indoor Positioning Technologies: Analysis and Recent Advances”, *Sensors*, t. 16, nr 5, s. 707, maj 2016, doi: 10.3390/s16050707.
- [35] H. Liu, H. Darabi, P. Banerjee, i J. Liu, „Survey of Wireless Indoor Positioning Techniques and Systems”, *IEEE Trans. Syst. Man Cybern. Part C Appl. Rev.*, t. 37, nr 6, s. 1067–1080, lis. 2007, doi: 10.1109/TSMCC.2007.905750.

- [36] „Evaluation of measurement data – Guide to the expression of uncertainty in measurement JCGM 100:2008 (GUM 1995 with minor corrections)”. BIPM Joint Committee for Guides in Metrology, wrzesień 2008.
- [37] S. L. R. Ellison i A. Williams, *Eurachem/CITAC guide: Quantifying Uncertainty in Analytical Measurement*, Third edition. London: Eurachem, 2012. Dostęp: 2 październik 2020. [Online]. Dostępne na: https://www.eurachem.org/images/stories/Guides/pdf/QUAM2012_P1.pdf
- [38] L. Yao, Y.-W. A. Wu, L. Yao, i Z. Z. Liao, „An integrated IMU and UWB sensor based indoor positioning system”, w *2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Sapporo, wrz. 2017, s. 1–8. doi: 10.1109/IPIN.2017.8115911.
- [39] Q. Tian, K. I.-K. Wang, i Z. Salcic, „A Low-Cost INS and UWB Fusion Pedestrian Tracking System”, *IEEE Sens. J.*, t. 19, nr 10, s. 3733–3740, maj 2019, doi: 10.1109/JSEN.2019.2894714.
- [40] B. R. C. C. K. M, i M. T, „Indoor and Outdoor Positioning in Mobile Environments—a Review and some Investigations on WLAN-Positioning”, *Ann. GIS*, t. 10, nr 2, s. 91–98, grudz. 2004, doi: 10.1080/10824000409480660.
- [41] Guolin Sun, Jie Chen, Wei Guo, i K. J. R. Liu, „Signal processing techniques in network-aided positioning: a survey of state-of-the-art positioning designs”, *IEEE Signal Process. Mag.*, t. 22, nr 4, s. 12–23, lip. 2005, doi: 10.1109/MSP.2005.1458273.
- [42] Z. B. Tariq, D. M. Cheema, M. Z. Kamran, i I. H. Naqvi, „Non-GPS Positioning Systems: A Survey”, *ACM Comput. Surv.*, t. 50, nr 4, s. 1–34, lip. 2018, doi: 10.1145/3098207.
- [43] D. Broman, E. A. Lee, S. Tripakis, i M. Törngren, „Viewpoints, formalisms, languages, and tools for cyber-physical systems”, w *Proceedings of the 6th International Workshop on Multi-Paradigm Modeling - MPM '12*, Innsbruck, Austria, 2012, s. 49–54. doi: 10.1145/2508443.2508452.
- [44] P. Derler, E. A. Lee, i A. S. Vincentelli, „Modeling Cyber-Physical Systems”, *Proc. IEEE*, t. 100, nr 1, s. 13–28, sty. 2012, doi: 10.1109/JPROC.2011.2160929.
- [45] J. C. Knight, „Safety critical systems: challenges and directions”, w *Proceedings of the 24th international conference on Software engineering - ICSE '02*, Orlando, Florida, 2002, s. 547. doi: 10.1145/581339.581406.
- [46] S. Lange, „Increased Convenience with Parking”, *ATZextra Worldw.*, t. 15, nr 7, s. 70–76, lip. 2010, doi: 10.1365/s40111-010-0227-6.
- [47] A. Y. Hata i D. F. Wolf, „Feature Detection for Vehicle Localization in Urban Environments Using a Multilayer LIDAR”, *IEEE Trans. Intell. Transp. Syst.*, t. 17, nr 2, s. 420–429, luty 2016, doi: 10.1109/TITS.2015.2477817.
- [48] S. M. Patole, M. Torlak, D. Wang, i M. Ali, „Automotive radars: A review of signal processing techniques”, *IEEE Signal Process. Mag.*, t. 34, nr 2, s. 22–35, mar. 2017, doi: 10.1109/MSP.2016.2628914.
- [49] E. Coelingh, A. Eidehall, i M. Bengtsson, „Collision Warning with Full Auto Brake and Pedestrian Detection - a practical example of Automatic Emergency Braking”, w *13th International IEEE Conference on Intelligent Transportation Systems*, Funchal, Madeira Island, Portugal, wrz. 2010, s. 155–160. doi: 10.1109/ITSC.2010.5625077.
- [50] Y. A. Harfouch, S. Yuan, i S. Baldi, „An Adaptive Switched Control Approach to Heterogeneous Platooning With Intervehicle Communication Losses”, *IEEE Trans. Control Netw. Syst.*, t. 5, nr 3, s. 1434–1444, wrz. 2018, doi: 10.1109/TCNS.2017.2718359.
- [51] Y.-T. Wang, C.-C. Peng, A. Ravankar, i A. Ravankar, „A Single LiDAR-Based Feature Fusion Indoor Localization Algorithm”, *Sensors*, t. 18, nr 4, s. 1294, kwi. 2018, doi: 10.3390/s18041294.
- [52] D. Grzechca, **K. Paszek** i in., „How Accurate Can UWB and Dead Reckoning Positioning Systems Be? Comparison to SLAM Using the RPLidar System”, *Sensors*, t. 20, nr 13, s. 3761, lip. 2020, doi: 10.3390/s20133761.

- [53] H. Zhou, D. Zou, L. Pei, R. Ying, P. Liu, i W. Yu, „StructSLAM: Visual SLAM With Building Structure Lines”, *IEEE Trans. Veh. Technol.*, t. 64, nr 4, s. 1364–1375, kwi. 2015, doi: 10.1109/TVT.2015.2388780.
- [54] D. Schleicher, L. M. Bergasa, M. Ocana, R. Barea, i M. E. Lopez, „Real-Time Hierarchical Outdoor SLAM Based on Stereovision and GPS Fusion”, *IEEE Trans. Intell. Transp. Syst.*, t. 10, nr 3, s. 440–452, wrz. 2009, doi: 10.1109/TITS.2009.2026317.
- [55] M. Friebe i J. Petzold, „Visualisation Functions in Advanced Camera-Based Surround View Systems”, w *Advanced Microsystems for Automotive Applications 2014*, J. Fischer-Wolfarth i G. Meyer, Red. Cham: Springer International Publishing, 2014, s. 267–276. doi: 10.1007/978-3-319-08087-1_24.
- [56] T. Liu, J. Zhang, K. Zhang, J. Xu, D. Wang, i X. Wang, „Vehicle-mounted surround vision algorithm based on heterogeneous architecture”, *Multimed. Tools Appl.*, t. 79, nr 33–34, s. 24707–24730, wrz. 2020, doi: 10.1007/s11042-020-09209-6.
- [57] A. Mogelmoose, M. M. Trivedi, i T. B. Moeslund, „Vision-Based Traffic Sign Detection and Analysis for Intelligent Driver Assistance Systems: Perspectives and Survey”, *IEEE Trans. Intell. Transp. Syst.*, t. 13, nr 4, s. 1484–1497, grudz. 2012, doi: 10.1109/TITS.2012.2209421.
- [58] J. Greenhalgh i M. Mirmehdi, „Real-Time Detection and Recognition of Road Traffic Signs”, *IEEE Trans. Intell. Transp. Syst.*, t. 13, nr 4, s. 1498–1506, grudz. 2012, doi: 10.1109/TITS.2012.2208909.
- [59] Edward D. Tate, JR., Alan G. HolmesHsiu-Pang, Chan Donald, i EngFred W. Huntzicker, „Park assist system”, US8700258B2, kwiecień 2014 [Online]. Dostępne na: <https://patents.google.com/patent/US8700258B2>
- [60] C. Wang, H. Zhang, M. Yang, X. Wang, L. Ye, i C. Guo, „Automatic Parking Based on a Bird’s Eye View Vision System”, *Adv. Mech. Eng.*, t. 6, s. 847406, sty. 2014, doi: 10.1155/2014/847406.
- [61] D. Dooley, B. McGinley, C. Hughes, L. Kilmartin, E. Jones, i M. Glavin, „A Blind-Zone Detection Method Using a Rear-Mounted Fisheye Camera With Combination of Vehicle Detection Methods”, *IEEE Trans. Intell. Transp. Syst.*, t. 17, nr 1, s. 264–278, sty. 2016, doi: 10.1109/TITS.2015.2467357.
- [62] J. Ledvina, L. Vykydal, i P. Horsky, „Fast Automatic Tuning of a Synthetic Inductor for Automotive Transformer-Less Ultrasonic Sensor in Park Assist Systems”, *IEEE Sens. J.*, t. 19, nr 22, s. 10568–10573, lis. 2019, doi: 10.1109/JSEN.2019.2932300.
- [63] „Global Positioning System Precise Positioning Service Performance Standard”. 2007.
- [64] „Department Of Defense World Geodetic System 1984: Its Definition and Relationships with Local Geodetic Systems”, National Geospatial-Intelligence Agency, Office of Geomatics, lip. 2014.
- [65] „World Geodetic System - 1984 (WGS-84) Manual”, International Civil Aviation Organization, sty. 2002.
- [66] G. Taylor, G. Blewitt, D. Steup, S. Corbett, i A. Car, „Road Reduction Filtering for GPS-GIS Navigation”, *Trans. GIS*, t. 5, nr 3, s. 193–207, cze. 2001, doi: 10.1111/1467-9671.00077.
- [67] R. J. Fontana, „Recent System Applications of Short-Pulse Ultra-Wideband (UWB) Technology”, *IEEE Trans. Microw. Theory Tech.*, t. 52, nr 9, s. 2087–2104, wrz. 2004, doi: 10.1109/TMTT.2004.834186.
- [68] M. Nowakowski i A. Idzkowski, „Ultra-wideband signal transmission according to European regulations and typical pulses”, w *2020 International Conference Mechatronic Systems and Materials (MSM)*, Białystok, Poland, lip. 2020, s. 1–4. doi: 10.1109/MSM49833.2020.9202219.
- [69] D. Grzechca, K. Hanzel, i **K. Paszek**, „Accuracy analysis for object positioning on a circular trajectory based on the UWB location system”, w *2018 14th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, Lviv-Slavske, Ukraine, luty 2018, s. 69–74. doi: 10.1109/TCSET.2018.8336158.

- [70] L. Guo, X. Chen, i C. G. Parini, „Miniature ultra-wideband antenna for wireless universal serial bus dongle applications”, *IET Microw. Antennas Propag.*, t. 6, nr 1, s. 113, 2012, doi: 10.1049/iet-map.2011.0023.
- [71] K. Hanzel, **K. Paszek**, i D. Grzechca, „Possibilities of using data from the UWB system for the validation of ADAS subsystems”, w *Networking issues in innovative applications based on cyber-physical systems paradigm : Praca zbiorowa*, 2020, s. s. 108-124.
- [72] K. Hanzel, **K. Paszek**, i D. Grzechca, „The influence of the data packet size on positioning parameters of UWB system for the purpose of tagging smart city infrastructure”, *Bull. Pol. Acad. Sci. Tech. Sci.*, t. 68, nr 4, s. 857–868, sie. 2020, doi: 10.24425/BPASTS.2020.134173.
- [73] A. Francillon, B. Danev, i S. Capkun, „Relay Attacks on Passive Keyless Entry and Start Systems in Modern Cars”, s. 15 p., 2011, doi: 10.3929/ETHZ-A-006708714.
- [74] BMW, „BMW announces support for Digital Key for iPhone”. 22 czerwiec 2020. Dostęp: 20 wrzesień 2020. [Online]. Dostępne na: <https://www.press.bmwgroup.com/global/article/detail/T0309827EN/bmw-announces-support-for-digital-key-for-iphone-a-secure-and-easy-way-to-use-iphone-as-a-car-key-to-lock-unlock-drive-and-share-keys-with-friends>
- [75] „Digital Key – The Future of Vehicle Access”, Car Connectivity Consortium, Whitepaper, 2020. [Online]. Dostępne na: https://global-carconnectivity.org/wp-content/uploads/2020/04/CCC_Digital_Key_2.0.pdf
- [76] „BMW announces BMW Digital Key Plus with Ultra-Wideband technology coming to the BMW iX”. BMW Corporate Communications, 13 styczeń 2021. Dostęp: 20 luty 2021. [Online]. Dostępne na: <https://www.press.bmwgroup.com/global/article/detail/T0324128EN/bmw-announces-bmw-digital-key-plus-with-ultra-wideband-technology-coming-to-the-bmw-ix>
- [77] F. Berens *in.*, „UWB car attenuation measurements”, w *2007 16th IST Mobile and Wireless Communications Summit*, Budapest, Hungary, lip. 2007, s. 1–5. doi: 10.1109/ISTMWC.2007.4299240.
- [78] IEEE Computer Society, LAN/MAN Standards Committee, Institute of Electrical and Electronics Engineers, i IEEE-SA Standards Board, *IEEE standard for local and metropolitan area networks. Part 15.4, Part 15.4.*. New York: Institute of Electrical and Electronics Engineers, 2011. Dostęp: 29 wrzesień 2021. [Online]. Dostępne na: <http://ieeexplore.ieee.org/servlet/opac?punumber=6012485>
- [79] „DW1000 User Manual”. Decawave, 2017.
- [80] A. Typiak, Ł. Rykała, i R. Typiak, „Location detection of a static object using Ultra Wideband technology”, Yogyakarta, Indonesia, 2018, s. 020076. doi: 10.1063/1.5066538.
- [81] Decawave, „DW1000 User Manual”. 2017.
- [82] J. Li, X. Yue, J. Chen, i F. Deng, „A Novel Robust Trilateration Method Applied to Ultra-Wide Bandwidth Location Systems”, *Sensors*, t. 17, nr 4, s. 795, kwi. 2017, doi: 10.3390/s17040795.
- [83] F. Thomas i L. Ros, „Revisiting trilateration for robot localization”, *IEEE Trans. Robot.*, t. 21, nr 1, s. 93–101, luty 2005, doi: 10.1109/TRO.2004.833793.
- [84] W. Murphy i W. Hereman, „Determination of a position in three dimensions using trilateration and approximate distances”, *Dep. Math. Comput. Sci. Colo. Sch. Mines Gold. Colo. MCS-95*, t. 7, s. 19, 1995.
- [85] M. Pelka, „Position Calculation with Least Squares based on Distance Measurements”, *Lüb. Univ. Appl. Sci. Tech Rep*, 2015.
- [86] G. H. Golub i C. Reinsch, „Singular Value Decomposition and Least Squares Solutions”, w *Handbook for Automatic Computation*, F. L. Bauer, A. S. Householder, F. W. J. Olver, H. Rutishauser, K. Samelson, i E. Stiefel, Red. Berlin, Heidelberg: Springer Berlin Heidelberg, 1971, s. 134–151. doi: 10.1007/978-3-642-86940-2_10.

- [87] J. C. Lagarias, J. A. Reeds, M. H. Wright, i P. E. Wright, „Convergence Properties of the Nelder–Mead Simplex Method in Low Dimensions”, *SIAM J. Optim.*, t. 9, nr 1, s. 112–147, sty. 1998, doi: 10.1137/S1052623496303470.
- [88] N. Bai, Y. Tian, Y. Liu, Z. Yuan, Z. Xiao, i J. Zhou, „A High-Precision and Low-Cost IMU-Based Indoor Pedestrian Positioning Technique”, *IEEE Sens. J.*, t. 20, nr 12, s. 6716–6726, cze. 2020, doi: 10.1109/JSEN.2020.2976102.
- [89] D. Feng, C. Wang, C. He, Y. Zhuang, i X.-G. Xia, „Kalman-Filter-Based Integration of IMU and UWB for High-Accuracy Indoor Positioning and Navigation”, *IEEE Internet Things J.*, t. 7, nr 4, s. 3133–3146, kwi. 2020, doi: 10.1109/JIOT.2020.2965115.
- [90] R. Ali, R. Liu, A. Nayyar, B. Qureshi, i Z. Cao, „Tightly Coupling Fusion of UWB Ranging and IMU Pedestrian Dead Reckoning for Indoor Localization”, *IEEE Access*, t. 9, s. 164206–164222, 2021, doi: 10.1109/ACCESS.2021.3132645.
- [91] X. Feng, T. Zhang, T. Lin, H. Tang, i X. Niu, „Implementation and Performance of a Deeply-Coupled GNSS Receiver with Low-Cost MEMS Inertial Sensors for Vehicle Urban Navigation”, *Sensors*, t. 20, nr 12, s. 3397, cze. 2020, doi: 10.3390/s20123397.
- [92] W. You, F. Li, L. Liao, i M. Huang, „Data Fusion of UWB and IMU Based on Unscented Kalman Filter for Indoor Localization of Quadrotor UAV”, *IEEE Access*, t. 8, s. 64971–64981, 2020, doi: 10.1109/ACCESS.2020.2985053.
- [93] **K. Paszek**, D. Grzechca, M. Tomczyk, i A. Marciniak, „UWB Positioning System with the Support of MEMS Sensors for Indoor and Outdoor Environment”, *J. Commun.*, t. 15, nr 6, s. 511–518, cze. 2020, doi: 10.12720/jcm.15.6.511-518.
- [94] Md. S. Amin, M. B. Ibne Reaz, S. S. Nasir, i M. A. S. Bhuiyan, „Low Cost GPS/IMU Integrated Accident Detection and Location System”, *Indian J. Sci. Technol.*, t. 9, nr 10, mar. 2016, doi: 10.17485/ijst/2016/v9i10/80221.
- [95] Y. Xu, Y. S. Shmaliy, Y. Li, X. Chen, i H. Guo, „Indoor INS/LiDAR-Based Robot Localization With Improved Robustness Using Cascaded FIR Filter”, *IEEE Access*, t. 7, s. 34189–34197, 2019, doi: 10.1109/ACCESS.2019.2903435.
- [96] H. Sadruddin, A. Mahmoud, i M. Atia, „An Indoor Navigation System using Stereo Vision, IMU and UWB Sensor Fusion”, w *2019 IEEE SENSORS*, Montreal, QC, Canada, paź. 2019, s. 1–4. doi: 10.1109/SENSORS43011.2019.8956942.
- [97] D. Grzechca i **K. Paszek**, „Short-term positioning accuracy based on MEMS sensors for smart city solutions”, *Metrol. Meas. Syst.*, t. 26, nr 1, s. 95–107, 2019, doi: 10.24425/MMS.2019.126325.
- [98] **K. Paszek**, D. Grzechca, i A. Becker, „Design of the UWB Positioning System Simulator for LOS/NLOS Environments”, *Sensors*, t. 21, nr 14, s. 4757, lip. 2021, doi: 10.3390/s21144757.
- [99] **K. Paszek**, K. Hanzel, i D. Grzechca, „The Use of Artificial Neural Network to Increase the Accuracy of the UWB Positioning System”, w *Networking issues in innovative applications based on cyber-physical systems paradigm : Praca zbiorowa*, 2020, s. s. 164-179.
- [100] A. Koberstein, „Progress in the dual simplex algorithm for solving large scale LP problems: techniques for a fast and stable implementation”, *Comput. Optim. Appl.*, t. 41, nr 2, s. 185–204, lis. 2008, doi: 10.1007/s10589-008-9207-4.
- [101] J. J. Moré i D. C. Sorensen, „Computing a Trust Region Step”, *SIAM J. Sci. Stat. Comput.*, t. 4, nr 3, s. 553–572, wrz. 1983, doi: 10.1137/0904038.
- [102] A. Poulou i D. S. Han, „UWB Indoor Localization Using Deep Learning LSTM Networks”, *Appl. Sci.*, t. 10, nr 18, s. 6290, wrz. 2020, doi: 10.3390/app10186290.
- [103] S. Capobianco, L. M. Millefiori, N. Forti, P. Braca, i P. Willett, „Deep Learning Methods for Vessel Trajectory Prediction Based on Recurrent Neural Networks”, *IEEE Trans. Aerosp. Electron. Syst.*, t. 57, nr 6, s. 4329–4346, grudz. 2021, doi: 10.1109/TAES.2021.3096873.
- [104] R. E. Kalman, „A New Approach to Linear Filtering and Prediction Problems”, *J. Basic Eng.*, t. 82, nr 1, s. 35–45, mar. 1960, doi: 10.1115/1.3662552.
- [105] E. J. Krakiwsky, C. B. Harris, i R. V. C. Wong, „A Kalman filter for integrating dead reckoning, map matching and GPS positioning”, w *IEEE PLANS '88., Position Location and Navigation*

- Symposium, Record. „Navigation into the 21st Century“.*, Orlando, FL, USA, 1988, s. 39–46.
doi: 10.1109/PLANS.1988.195464.
- [106] C. Willmott i K. Matsuura, „Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance”, *Clim. Res.*, t. 30, s. 79–82, 2005, doi: 10.3354/cr030079.
- [107] S. Hochreiter i J. Schmidhuber, „Long Short-Term Memory”, *Neural Comput.*, t. 9, nr 8, s. 1735–1780, lis. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [108] V. Ivanov, „A review of fuzzy methods in automotive engineering applications”, *Eur. Transp. Res. Rev.*, t. 7, nr 3, s. 29, wrz. 2015, doi: 10.1007/s12544-015-0179-z.
- [109] K. R. S. Kodagoda, W. S. Wijesoma, i E. K. Teoh, „Fuzzy speed and steering control of an AGV”, *IEEE Trans. Control Syst. Technol.*, t. 10, nr 1, s. 112–120, sty. 2002, doi: 10.1109/87.974344.
- [110] R. Nowicki, „On classification with missing data using rough-neuro-fuzzy systems”, *Int. J. Appl. Math. Comput. Sci.*, t. 20, nr 1, s. 55–67, mar. 2010, doi: 10.2478/v10006-010-0004-8.