



**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

Streszczenie

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

Gliwice 2022

Spis treści

1	Wstęp	1
1.1	Motywacja	1
1.2	Cel pracy	2
2	Pozycjonowanie obiektów	4
3	Simulator systemu UWB	6
3.1	Wyznaczenie parametrów modelu	6
3.2	Opis scenariusza testowego w symulatorze	9
3.3	Wyznaczenie odległości	10
3.4	Wprowadzanie przeszkód i detekcja warunków LOS, NLOS	10
4	System wyznaczania i wyboru ścieżki	12
4.1	Korekta odległości	14
4.2	Wpływ metody trilateracji i liczby odległości na błąd pozycji	16
4.3	Predykcja pozycji obiektu	18
4.4	Rozmyty system ekspercki wyboru ścieżki poruszania się obiektu	23
4.5	Analiza czasu przetwarzania, wyniki eksperymentu	25
5	Podsumowanie i wnioski końcowe	28
6	Bibliografia	30

1 Wstęp

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. 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 wymagana jest dokładna pozycja obiektu, aby komunikaty docierające do kierowcy, operatora, czy systemów wspomagania w pojeździe były użyteczne. 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 [1], czy monitorować odległości do poprzedzającego samochodu [2]. 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 [3]. Z kolei predykcja pozycji pozwoliłaby na zwiększenie czasu, który system miałby na podjęcie stosownej reakcji. 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 [4], [5]. Technologia UWB również posiada symulator, który umożliwia przygotowanie transmisji na niskim poziomie [6]. 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.

1.1 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. Zauważyć należy, że wzrost prędkości poruszających się obiektów zwiększa różnice pomiędzy rzeczywistością (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 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.

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 została stosunkowo nowa technologia pozycjonowania oparta na impulsach szerokopasmowych UWB (*ang. ultra wideband*) [32]. System ten cechuje się dokładnością kilkudziesięciu, niekiedy kilkunastu centymetrów i może być stosowany zarówno do pozycjonowania wewnątrz jak i na zewnątrz budynków. Czas akwizycji danych z systemu UWB (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.

Znalezienie systemu referencyjnego do oceny dokładności systemu UWB jest trudne 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). 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.

1.2 Cel pracy

W związku z 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 został 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 doktorską 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 umożliwia 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 co umożliwia ich równoczesne wzajemne porównanie.

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 wiele wskaźników 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*) [7]–[11]. 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.

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 [12], [13]. 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). 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).



Rys. 1. Przykładowy system pozycjonowania kooperacyjnego

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. 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, pseudosatellity. 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*) [7], [8], [14]–[16].

Systemy ultraszerokopasmowe UWB [17]–[19] stanowią aktualnie realną alternatywę dla systemów GPS w zastosowaniach na ograniczonym obszarze tj. dla lokalnego systemu pozycjonowania. Zdolność systemu UWB do przenoszenia informacji z dużą szybkością [20]–[22] 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 niewralgicznych miejscach infrastruktury). 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.

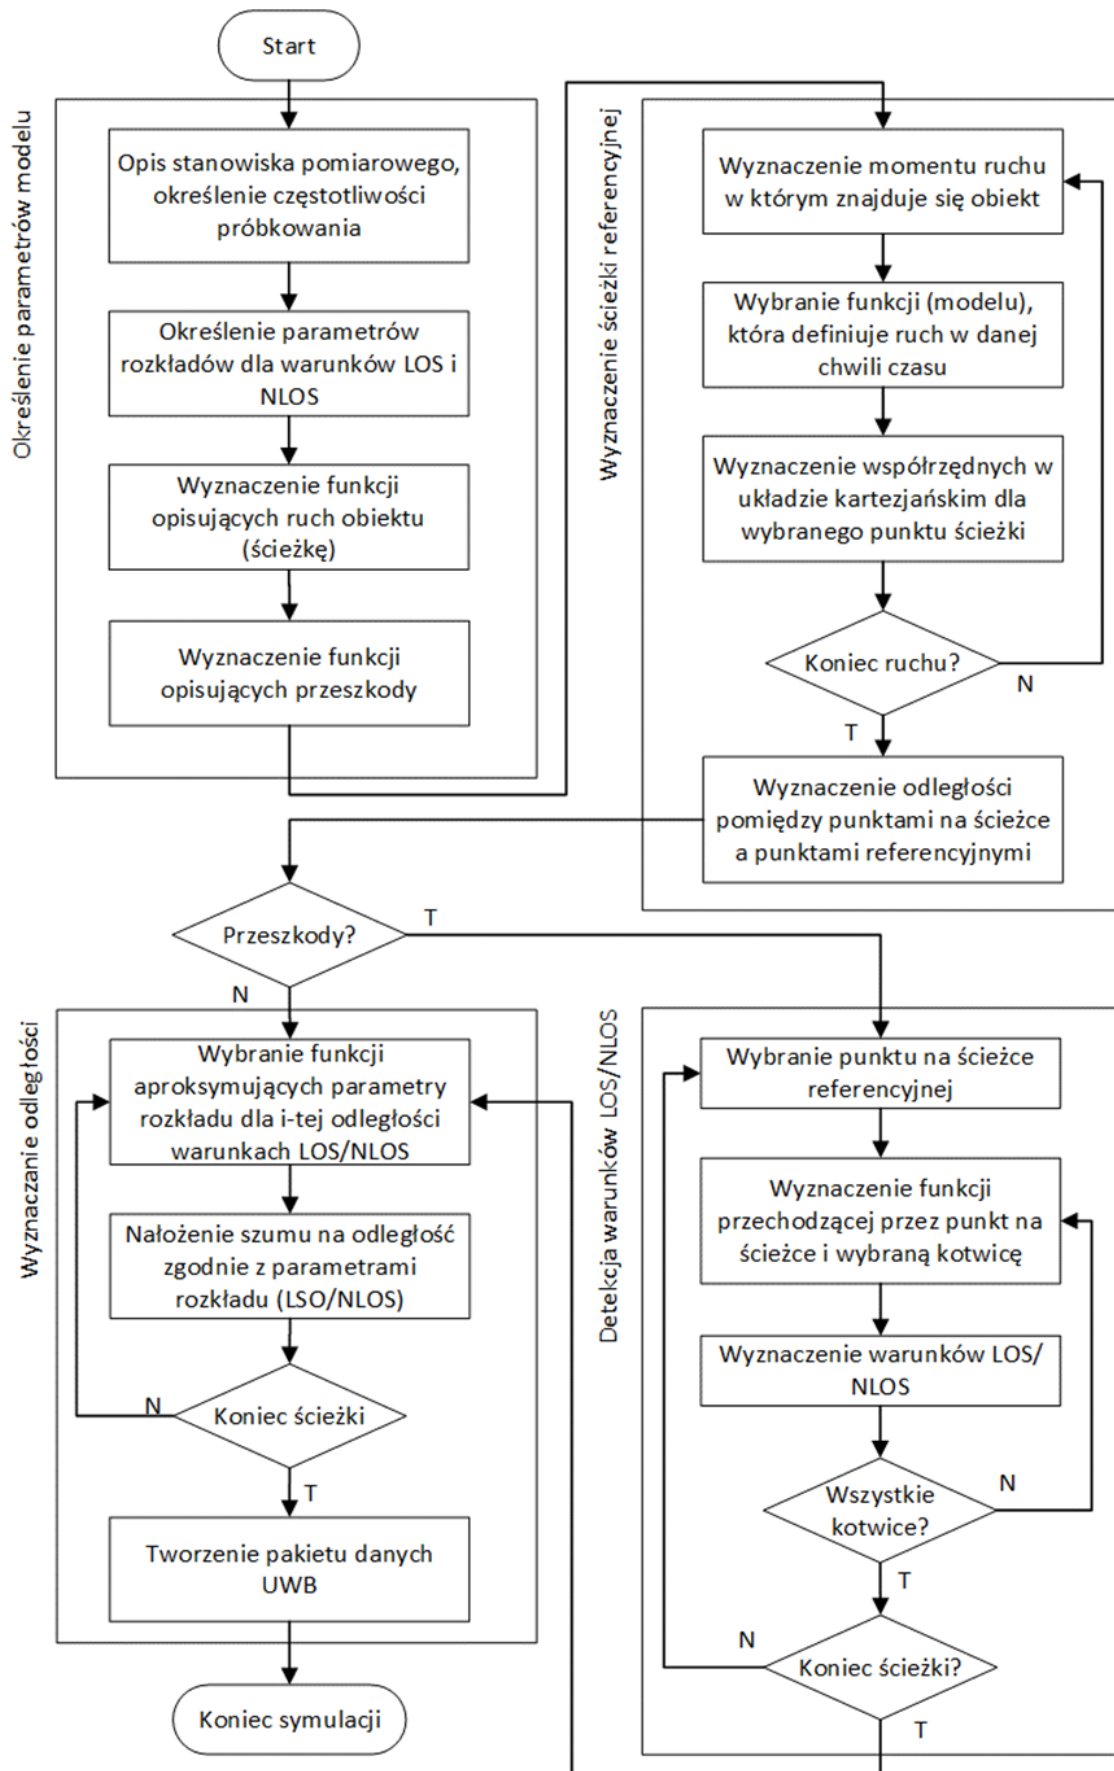
3 Symulator systemu UWB

W niniejszym pracy zaproponowano autorski symulator systemu UWB [23], który odzwierciedla działanie rzeczywistego systemu opartego na modułach DWM1000 firmy Decawave. 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. Odległości pomiędzy punktem na ścieżce referencyjnej a kotwicami uwzględniają ruch obiektu. Zaprojektowany symulator również charakteryzuje się błędem oraz zmiennością odległości na poziomie systemu rzeczywistego uwzględniając jego zmienną charakterystykę wraz z odległością pomiędzy węzłami w sieci. Posiadany system potraktowano jako „czarną skrzynkę” i na bazie otrzymywanych informacji o odległości w procesie analizy danych zamodelowano jego pracę. 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).

Punktem startowym tworzonego symulatora są odległości pomiędzy węzłami sieci zdefiniowanej przez użytkownika, które najlepiej pozyskać zarówno w linii widoczności (LOS) jak i przy braku widoczności (NLOS) pomiędzy węzłami w sieci. 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: ustawienie parametrów modelu, wyznaczenie ścieżki referencyjnej, detekcja warunków LOS, NLOS, wyznaczanie odległości (patrz rys. 2), które od definicji parametrów systemu UWB przez wyznaczenie ścieżki referencyjnej prowadzą do wyznaczenia odległości pomiędzy węzłem mobilnym a punktami referencyjnymi. W celu wyznaczenia parametrów statystycznych zebrano dane o odległości pomiędzy węzłami w dystansach od 0,5 m do 20 m w warunkach LOS i NLOS. Każdy ze scenariuszy obejmuje 10 000 odczytów odległości. Tak zebrane dane wykorzystano do wyznaczenia parametrów statycznych rozkładu prawdopodobieństwa odległości.


3.1 Wyznaczenie parametrów modelu

W pierwszym kroku przeanalizowane zostały dane o odległości pomiędzy węzłami w warunkach LOS (brak przeszkody w obrębie stanowiska pomiarowego. Wartość średnia jest bliska medianie co wskazuje na stosunkowo równomierną koncentrację pomiarów wokół wartości średniej). Maksymalna wartość bezwzględna różnicy wartości średniej i mediany 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.



Rys. 2. Diagram przepływu symulatora

Odchylenie standardowe odwzorowywanego systemu zmienia się wraz z badaną odległością i mieści się w zakresie 1,0 – 2,6 cm. 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). Z uwagi na dominujące przeszacowanie wartości odległości błąd systematyczny MBE jest zbliżona do wartości RMSE. Jednakże, gdy system charakteryzuje się nie tylko przeszacowaniem, ale również niedoszacowaniem odległości, wtedy różnice pomiędzy MBE i RMSE zwiększają się. Wartość MBE może być wykorzystana do korekty danych o odległości, co z kolei wpływa na dokładność wyznaczonej pozycji obiektu [24], [25]. Dla wszystkich odległości referencyjnych wyznaczono parametry rozkładu normalnego (wartość średnią i odchylenie standardowe) na badanej próbie 10 000 próbek oddzielnie dla warunków LOS i NLOS. Dopasowany rozkład normalny w dużym stopniu przybliża rozkład badanej próby i pozwala odwzorować działanie systemu. 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. Do aproksymacji parametrów rozkładów wykorzystano funkcję wielomianową (patrz rys. 3). Jednakże do lepszego zamodelowania zmian parametru wraz ze zmianą odległości referencyjnej podzielono funkcję na fragmenty – w tym celu wyznaczono minima lokalne. Minimalna liczba punktów pomiarowych pomiędzy kolejnymi minimami lokalnymi wykorzystana jest jako parametr ograniczający tworzenie nadmiernej liczby funkcji – parametr dobierany jest empirycznie i w niniejszych rozważaniach przyjęto $n_{d_{ref}} = 2$.

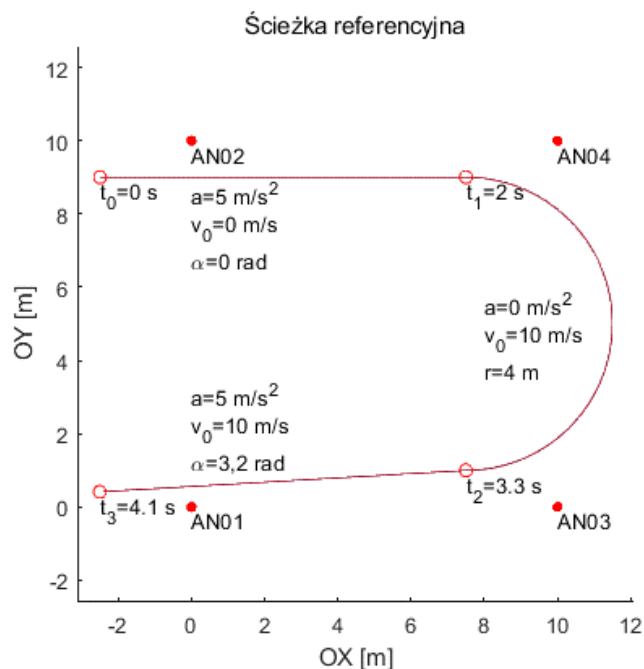


Rys. 3. Podział odchylenia standardowego (wyznaczonych rozkładów) na fragmenty

Procedurę należy powtórzyć dla drugiego parametru rozkładu normalnego jakim jest średnia μ . Jednakże 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 (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 błędów zamodelować.

3.2 Opis scenariusza testowego w symulatorze

Na płaszczyźnie testowej umieszcza się kotwice, czyli punkty referencyjne w lokalnym układzie odniesienia. Definiowane są parametry modelu systemu UWB: średni błąd systematyczny odległości oraz odchylenie standardowe. Ścieżkę ruchu pojazdu postanowiono przybliżyć przez linie proste i łuki. Zamodelowanie ruchu przy pomocy prostych i łuków pozwala na prostą adaptację scenariusza wirtualnego w rzeczywistych warunkach np. przez kierowcę lub obiekt typu AGV. Krzywe (proste i łuki) opisujące drogę zaimplementowano w funkcji czasu, zakładając stałe przyspieszenie obiektu. Przykładową ścieżkę wraz z parametrami przedstawiono na rys. 4. Dla ścieżek wyznaczane są również dane referencyjne o prędkości, przyspieszeniu, prędkości kątowej dla każdej z osi.



Rys. 4. Przykładowa ścieżka referencyjna składająca się z prostych i łuku

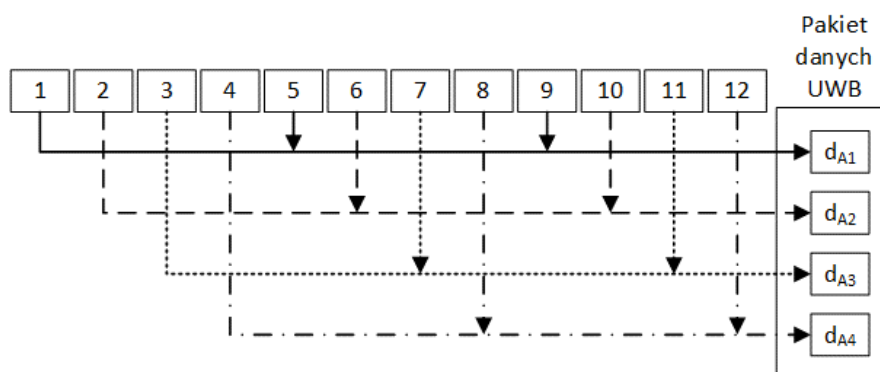
3.3 Wyznaczenie odległości

W końcowej fazie wyznaczane są odległości euklidesowe pomiędzy znacznikiem a każdą z kotwic umieszczoną na płaszczyźnie testowej. Obliczone odległości są wartościami dokładnymi i są wykorzystywane w dalszej analizie jako wartość referencyjna. 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 (1).

$$d'_{k,i} = d_{k,i} + MBE_{d_{k,i}} + R\sigma_{d_{k,i}} \quad (1)$$

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.

W odwzorowywanym systemie do wyznaczania odległości wykorzystywany jest schemat TWR. Pomędzy 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 celu odwzorowania tego mechanizmu w opracowanym symulatorze przyjęto stały czas otrzymywania informacji od 4 punktów referencyjnych 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. 5).

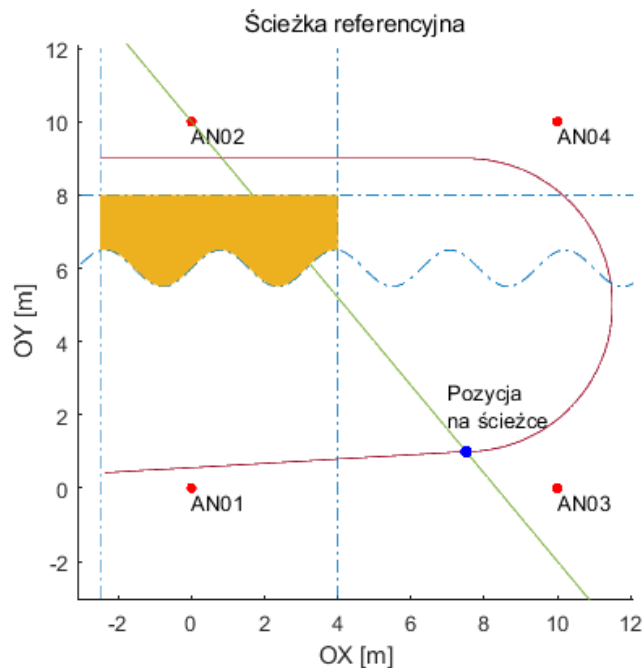


Rys. 5. Tworzenie pakietu danych UWB

3.4 Wprowadzanie przeszkód i detekcja warunków LOS, NLOS

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. 6. Do opisu przeszkody wykorzystywane są funkcje, które tworzą układ nierówności, tym samym wyznaczają płaszczyznę, na której znajduje się przeszkoda.



Rys. 6. Przykładowy opis przeszkody i detekcja NLOS dla wybranego punktu na ścieżce

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 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 wybranym punktem referencyjnym oraz przeszkodą, zadanie to potraktowano 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.

4 System wyznaczania i wyboru ścieżki

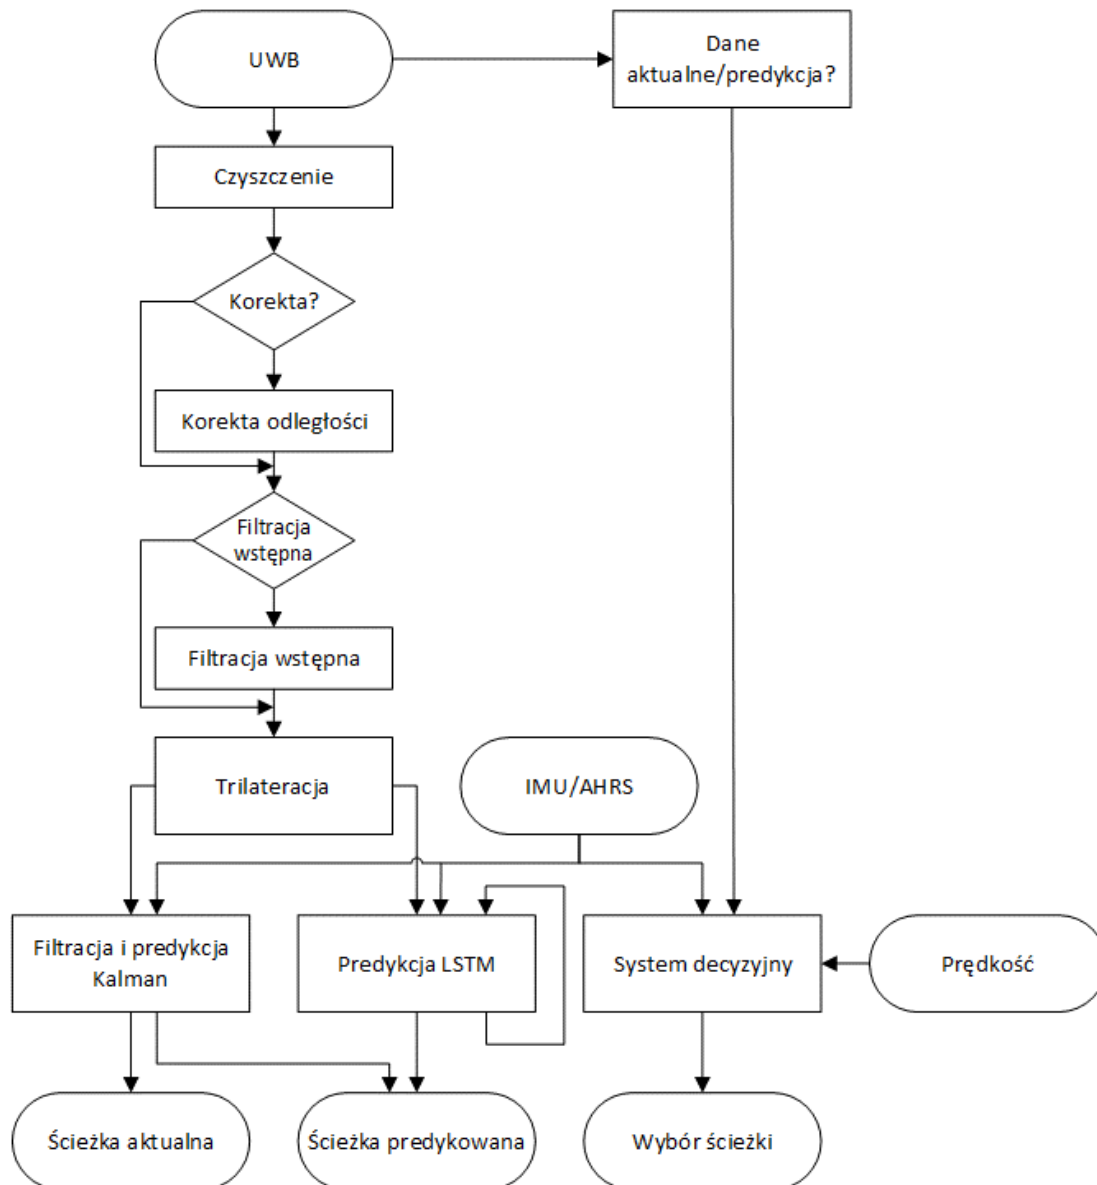
Zauważono, że dane pozyskiwane z poszczególnych podsystemów są albo mocno zaszumione albo niepełne albo uzyskuje się dane przypadkowo przeszacowane lub niedoszacowane co wpływa na proces wyznaczania pozycji obiektu. W niniejszej pracy zaproponowano proces korekty odległości pozyskanej z systemu UWB w funkcji otrzymanej odległości. 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 [26], [27].

Proces przetwarzania danych podzielono na etap korekty i fuzji. W związku z czym proponuje się proces przetwarzania danych, który zaprezentowano na rys. 7. 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 filtra Kalmana lub sieci typu LSTM). Jednocześnie należy podjąć decyzję o tym, która ze ścieżek powinna być wykorzystana przez system nadrzędny.

Zakłada się, że dostępne są: system UWB udostępniający odległości do czterech węzłów referencyjnych $D = \{d_{A1}, d_{A2}, d_{A3}, d_{A4}\}$, dane z sensorów inercyjnych: akcelerometru, żyroskopu i magnetometru w osi X, Y i Z, oraz prędkość obiektu v . Na wyjściu systemu dostępne są informacje o pozycji na płaszczyźnie na ścieżce aktualnej i ścieżce predykowanej 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.

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. 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.



Rys. 7. Diagram procesu analizy 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.

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 [28]. W kontekście pozycjonowania filtry tego typu z uwagi na przesuwne okno dostarczają dane przefiltrowane z opóźnieniem – otrzymywana pozycja w danym momencie dotyczy pozycji z przeszłości, a nie pozycji aktualnej. Przy dużych prędkościach zastosowanie tego typu filtrów w systemach czasu rzeczywistego nie jest dobrym rozwiązaniem, ponieważ maksymalne możliwe przemieszczenie poruszającego się obiektu (zmiana pozycji) jest równoważne z iloczynem prędkości i czasu potrzebnego na akwizycję danych w liczbie odpowiadającej połowie długości okna filtru (nie licząc próbki bieżącej), co przekłada się na znaczące (od kilkudziesięciu centymetrów do kilku metrów) przesunięcia obiektu – dla okna filtru o długości 19 próbek pojazd poruszający się z prędkością 20 m/s przemieści 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 przemieszczeniem o 7 cm co można uznać za akceptowalne.

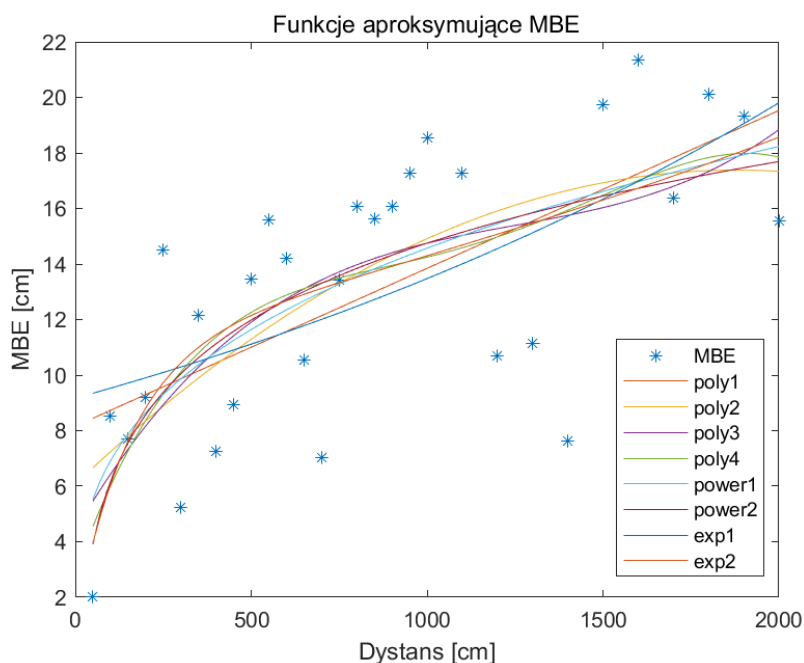
Filtr Kalmana jest filtrem rekursywnym, czyli informacje przetwarzane są sukcesywnie wraz z kolejnymi krokami na bazie danych z kroku poprzedniego. Filtr znalazł szerokie zastosowanie wszędzie tam, gdzie analizowane są sygnały z sensorów, a w szczególności w nawigacji pojazdów, czy robotów [29], [30]. 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). W kontekście pozycjonowania znany jest model opisujący przemieszczenie, bazując na równaniu ruchu Newtona, na podstawie którego projektowany jest filtr Kalmana. Filtr ten pozwala na filtrację i jednoczesną fuzję danych z systemu UWB i IMU(AHRS). Podczas normalnej pracy filtru otrzymywana jest również predykcja pozycji obiektu. Filtr ten ma znacząca przewagę nad filtrami z przesuwym oknem z uwagi na czas przetwarzania, który wynosi 10,7 μ s co dla 2 m/s będzie skutkowało przemieszczeniem 0,02 mm, a dla 14 m/s przemieszczeniem 0,15 mm. Tak więc można stwierdzić, że filtracja filtrem Kalmana pozwala na predykcję pozycji obiektu nie wprowadzając znaczącego przesunięcia.

4.1 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 [23]–[25], [31]. Testowane systemy charakteryzują się różną zmianą błędów w związku z czym korekta powinna być dostosowana do danego systemu indywidualnie. Funkcje korekty

zostały zamodelowane na danych rzeczywistych z systemu UWB pozyskanych w pomiarach statycznych. Testy zaproponowanych funkcji korekty przetestowane zostały z wykorzystaniem danych pochodzących z symulacji, w których obiekt jest w ruchu. Zasymlowane zostały przejazdy obiektu ze stałą prędkością po torze o długości 45 m, 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 m/s do 20 m/s z krokiem 0,25 m/s).

Do zamodelowania korekty w funkcji odległości na danych rzeczywistych z systemu UWB zastosowano następujące funkcje: wielomiany stopnia pierwszego, drugiego, trzeciego oraz czwartego, funkcje potęgowe i funkcje wykładnicze. W celu wybrania odpowiedniej funkcji aproksymującej MBE (patrz rys. 8) wyznaczono średni RMSE (tab. 1), który dla 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. 8. Aproksymacja MBE w celu korekty odległości

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 μs .

Tab. 1. 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

Na błąd wyznaczanej pozycji wpływa również czas akwizycji i prędkość obiektu. Dane z symulatora pozyskiwane są co $t_p = 12\text{ ms}$, 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). Dla porównania korekta odległości z wykorzystaniem wcześniej przedstawionych funkcji będzie skutkowało przemieszczeniem poniżej 1 mm wynikającym z czasu jej wykonania dla wszystkich badanych prędkości co jest do zaniedbania w stosunku do korzyści wynikających z zastosowania zaproponowanych funkcji korekty.

4.2 Wpływ metody trilateracji i liczby odległości na błąd pozycji

Przeanalizowane zostały dwie metody, 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 wyznaczenie 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, wariant B – 3 odległości do punktów referencyjnych i wariant C – 2 odległości do punktów referencyjnych, oraz z wykorzystaniem następujących metod: dla 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.

Porównano metody sympleksową w wariancie I i wariancie II oraz metodę najmniejszych kwadratów 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 dla metody LSM jest wyższa i wynosi ponad 18 cm, gdy dla metod sympleksowych wynosi około 13 cm. 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.

W tab. 2 wyznaczono średnie czasy potrzebne na obliczenie pozycji obiektu metodami: sympleksową w wariancie I 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 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. 2. 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

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.

4.3 Predykcja pozycji obiektu

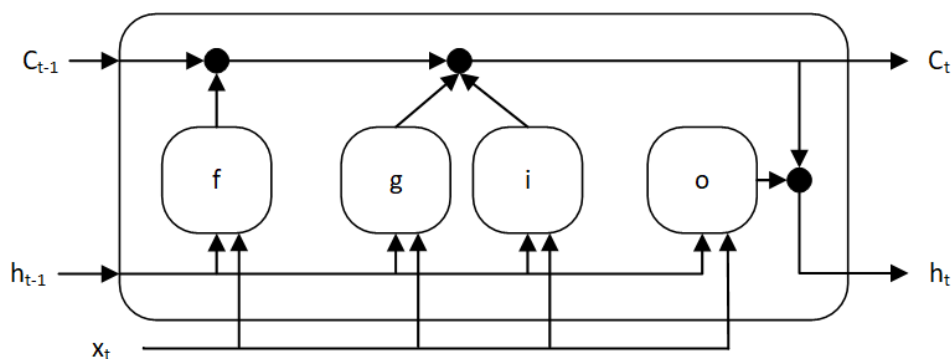
Zaproponowana korekta odległości poprawia dokładność wyznaczanych odległości tym samym zwiększając dokładność wyznaczanej pozycji, jednakże nie jest rozwiązaniem na przesunięcia wynikające z czasu transmisji danych, gdy obiekt jest w ciągłym ruchu lub też na chwilowe braki danych z systemu UWB. Z tego 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.

4.3.1 Predykcja pozycji obiektu za pomocą sieci LSTM

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. 9): wejściową (*ang. input gate*), wyjściową (*ang. output gate*) oraz zapomnij (*ang. forget gate*) [32]. 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 $\{\Delta x, \Delta y\}$ oraz dane pozyskane z systemu IMU (AHRS): akcelerometru, żyroskopu i magnetometru w każdej osi, w stałych odstępach czasu. Dane z wymienionych podsystemów tworzą wektor parametrów (2), który wykorzystywany jest w procesie uczenia sieci, a następnie predykcji.

$$W = \{\Delta x, \Delta y, a_x, a_y, a_z, g_x, g_y, g_z, m_x, m_y, m_z\} \quad (2)$$

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 .



Rys. 9. Struktura sieci LSTM

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, a ich łączna liczba wyniosła 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. 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 i analizie długości wszystkich serii pomiarowych zdecydowano, że najkorzystniejszy rozmiar partii to 37 serii.

Eksperyment przeprowadzono z wykorzystaniem sieci neuronowej typu LSTM o różnej liczbie komórek pamięci. 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 [26]. Warstwa wejściowa składa się z 11 parametrów (2). 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 – $\Delta P' = \{\Delta x', \Delta y'\}$). 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. 3 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.

Porównano dokładność predykcji w zależności od liczby pozycji predykowanych. Dla losowo wybranych przejazdów wykonano predykcje do 1, 5, 10, 20, 40, 60, 80 i 100 pozycji (do wyznaczenia pozycji wykorzystano dane po korekcie odległości). W tab. 4 przedstawiono skumulowany RMSE dla

ścieżki predykowanej. Wraz ze wzrostem liczby pozycji predykowanych błąd rośnie od 6,53 cm dla pierwszej predykcji – do 94,25 cm dla 100 predykcji pozycji.

Tab. 3. RMSE dla predykcji 10 pozycji, predykcja od pozycji z 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

Tab. 4 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.

A. Wariant A (ruch ze stałą prędkością)

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. Zauważono, 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. 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. 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 zmalała 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. Podczas wyznaczania ścieżki predykowanej nie bez znaczenia jest dokładność ostatniej pozycji otrzymanej z systemu UWB, od której wyznaczone są kolejne pozycje wykorzystując predykowane przemieszczenie. Tak więc przeprowadzono predykcję, 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.

B. Wariant B (ruch z różnym przyspieszeniem)

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. Dla predykcji 10 pozycji, której ostatnia znana pozycja została wyznaczona bez korekty odległości i średnia wartość 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. 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, 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.

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.

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).

4.3.2 Predykcja pozycji obiektu z wykorzystaniem filtra 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). Na wejście filtra podawane są pozycje z systemu UWB oraz przyspieszenia z akcelerometru.

Eksperyment przeprowadzono z użyciem danych symulacyjnych, które wykorzystano przy ocenie sieci LSTM. 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 zaproponowanym wielomianem drugiego stopnia. Przeprowadzona analiza pozwoliła odpowiedzieć na pytanie jaką dokładnością charakteryzuje się pozycja na ścieżce predykowanej składająca się z pozycji wyznaczonych a priori.

Wpierw przeanalizowano dane o ruchu jednostajnym – wariant A. Filtracja pozwala zwiększyć dokładność wyznaczanej 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. Widoczny jest również 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.

Następnie przeanalizowano działanie filtra Kalmana dla ruchu przyspieszonego – wariant B. Wartość maksymalna błędu pozycji aktualnej zmalała z 13,24 (bez FK) do 11,81 cm po zastosowaniu filtra Kalmana. Dla pozycji predykowanej wartość maksymalna błędu wzrosła o 0,12 cm w stosunku do wartości maksymalnej błędu pozycji aktualnej. Wraz ze wzrostem przyspieszenia błęd 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.

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.

Przewagą filtra 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 filtra Kalmana. Tak więc zaproponowaną sieć typu LSTM należy wykorzystać w sytuacjach, w których dochodzi do kilkukrotnych braków danych z systemu UWB następujących po sobie.

4.4 Rozmyty system ekspercki wyboru ścieżki poruszania się obiektu

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. W niniejszej pracy skupiono się na modelu Mamdaniego ze względu na małą liczbę wykorzystywanych zmiennych.

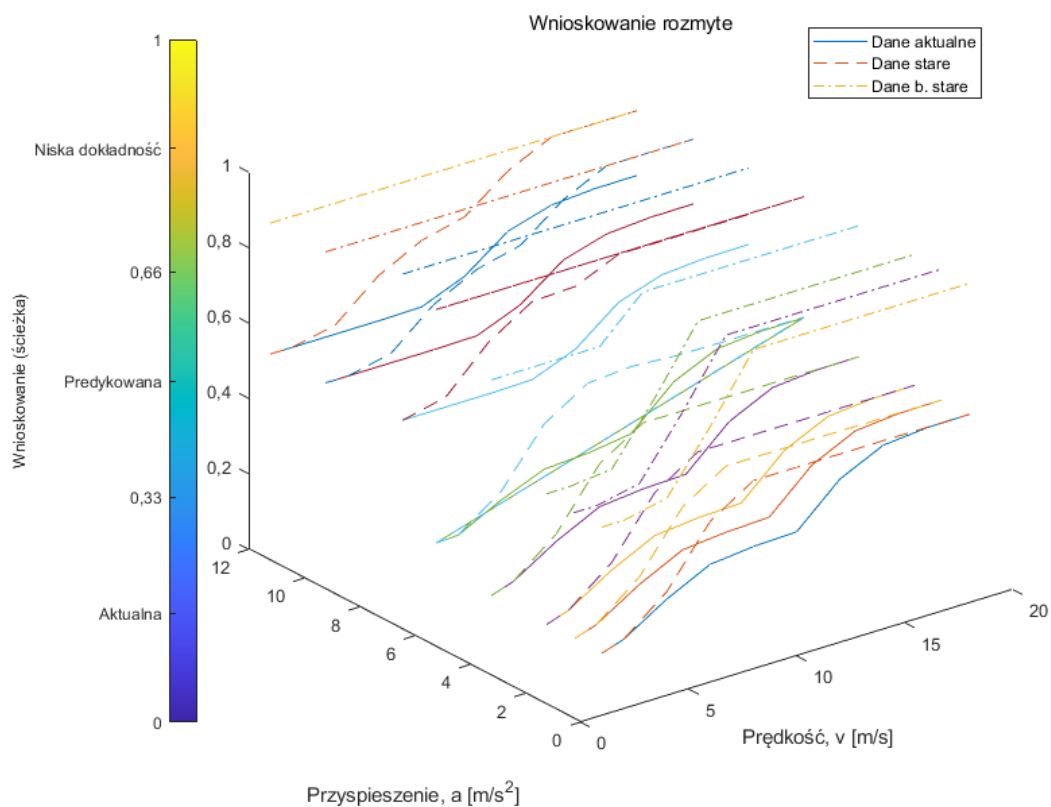
Do wyboru ścieżki poruszania się obiektu zaproponowano decyzyjny system ekspercki oparty na logice rozmytej, który pozwoli podjąć decyzje czy w systemie nadrzędnym do wyznaczenia pozycji obiektu należy wykorzystać pozycję ze ścieżki aktualnej, czy też ścieżki predykowanej lub też poinformować go o braku pozycji o wystarczającej dokładności pozycji. Wprowadzono 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). 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. Przyjęto następujące funkcje przynależności wejścia: funkcje gaussowskie oraz funkcje S i Z – na krańcach przedziałów. Funkcje przynależności wyjścia modelu ustala się na funkcję trójkątną. W tab. 5 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.

Tab. 5. 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]
	predykacja	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]
	predykacja	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. Działanie wnioskowania rozmytego zaprezentowano

w funkcji prędkości i przyspieszenia na rys. 10 (dane aktualne – oznaczone linią ciągłą, dane po pierwszej predykcji – linią kreskową, dane po drugiej i kolejnej predykcji (stare) – linią punktową). Wraz ze wzrostem czasu od ostatniej aktualizacji z systemu 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.



Rys. 10. Wnioskowanie rozmyte

4.5 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 i aktualna. W tab. 6 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. 6. 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

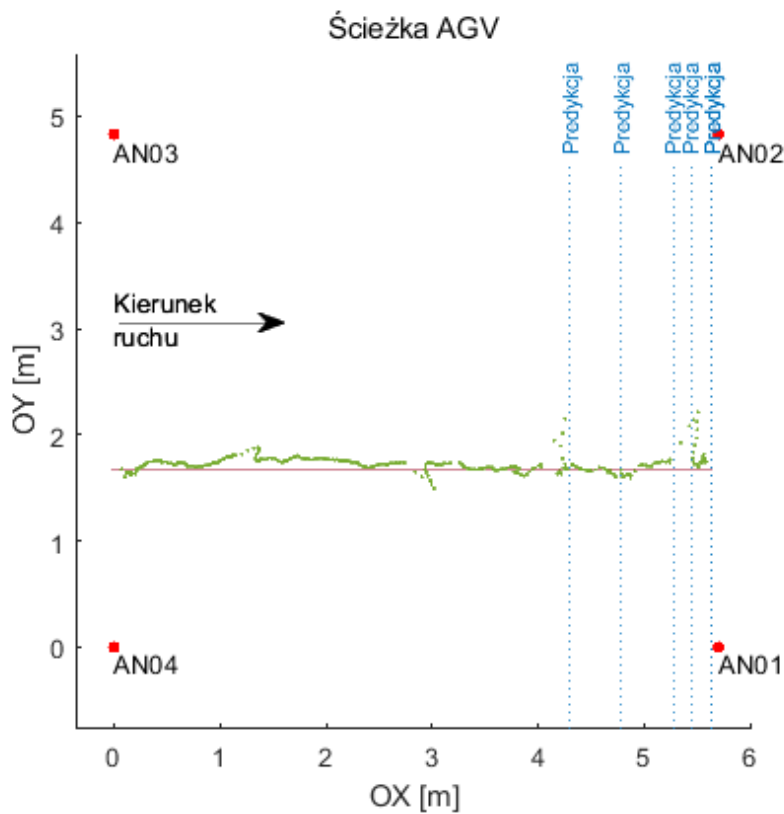
Biorąc pod uwagę możliwy do pokonania przez obiekt dystans w trakcie przetwarzania danych oraz maksymalne błędy systemu UWB dla pozycji i predykcji oraz przyjęty współczynnik bezpieczeństwa proponuje się minimalne obszary bezpieczeństwa obliczone według wzoru (3). Obszar ten dla pojazdu typu AGV wynosi 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.

$$O_b = (d_p + \varepsilon_{max}) \cdot \alpha \quad (3)$$

gdzie: d_p – maksymalne przesunięcie wynikające z czasu przetwarzania; ε_{max} – maksymalny błąd systemu UWB; α – współczynnik bezpieczeństwa (równy 2).

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 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. 11. 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.

Dokładność pozycji obiektu, wyznaczonej na podstawie danych pochodzących bezpośrednio z systemu UWB wynosi 27 cm – RMSE, błąd maksymalny 145 cm. Po wykonaniu czyszczenia danych i korekcie odległości (zaproponowaną funkcją korekty) 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.



Rys. 11. Przejazd pojazdu typu AGV

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 umożliwi 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 wyznaczanej pozycji obiektu oraz jej predykcji, a to z kolei będzie miało wpływ na bezpieczeństwa pojazdów samojezdnych.

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

6 Bibliografia

- [1] 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>
- [2] 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.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] „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.
- [10] 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
- [11] „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.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] 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.
- [17] 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.

- [18] 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.
- [19] 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.
- [20] 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.
- [21] 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.
- [22] 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.
- [23] 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.
- [24] 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.
- [25] 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.
- [26] A. Poulouse 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.
- [27] 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.
- [28] 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.
- [29] 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.
- [30] 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.
- [31] 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.
- [32] 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.