Prepoznavanje pokreta ljudskog tijela fuzijom podataka ultraširokopojasnih lokalizacijskih senzora i inercijskih senzora.

Mihaldinec, Hrvoje

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:168:573490

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-19**

Repository / Repozitorij:

FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repozitory

Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Hrvoje Mihaldinec

PREPOZNAVANJE POKRETA LJUDSKOGA TIJELA FUZIJOM PODATAKA ULTRAŠIROKOPOJASNIH LOKALIZACIJSKIH SENZORA I INERCIJSKIH SENZORA

DOKTORSKI RAD

Zagreb, 2020.

Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Hrvoje Mihaldinec

PREPOZNAVANJE POKRETA LJUDSKOG TIJELA FUZIJOM PODATAKA ULTRAŠIROKOPOJASNIH LOKALIZACIJSKIH SENZORA I INERCIJSKIH SENZORA

DOKTORSKI RAD

Mentor: Izv. prof. dr. sc. Hrvoje Džapo

Zagreb, 2020.

University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Hrvoje Mihaldinec

HUMAN BODY MOTION RECOGNITION USING ULTRA-WIDEBAND LOCALIZATION SENSORS AND INERTIAL SENSORS DATA FUSION

DOCTORAL THESIS

Supervisor: Associate Professor Hrvoje Džapo, PhD.

Zagreb, 2020

Doktorski rad izrađen je na Sveučilištu u Zagrebu Fakultetu elektrotehnike i računarstva, na Zavodu za elektroničke sustave i obradbu informacija

Mentor: Izv. prof. dr. sc. Hrvoje Džapo

Doktorski rad ima: 179 stranica

Doktorski rad br.: _____

O mentoru

Hrvoje Džapo rođen je 15. prosinca 1975. u Zagrebu, Republika Hrvatska. Doktorat znanosti stekao je na Sveučilištu u Zagrebu, Fakultet elektrotehnike i računarstva (FER), Zagreb, Republika Hrvatska, 2007. godine, u znanstvenom području Tehničkih znanosti, polje Elektrotehnika. Titulu diplomiranog inženjera elektrotehnike stekao je na FER-u 1999. godine, na studiju Elektrotehnike, smjeru Industrijska elektronika.

Od prosinca 1999. do sada zaposlen je u Zavodu za elektroničke sustave i obradbu informacija na FER-u. U siječnju 2017. postao je izvanredni profesor. Sudjelovao je u realizaciji 12 znanstvenih projekata financiranih od strane Ministarstva znanosti, obrazovanja i športa te drugih institucija Republike Hrvatske i u realizaciji 2 međunarodna projekta. Trenutno vodi projekt "Nova generacija telemetrijske tehnologije za mjerenja na rotacijskim komponentama spojke" te aktivno sudjeluje u realizaciji projekata "Razvoj nove generacije uređaja numeričke zaštite (KONPRO 2)" i "Napredni senzorski sustavi za precizno navodnjavanje u krškom krajobrazu (SENSIRRIKA)". Autor je više od 30 članaka objavljenih u časopisima i na međunarodnim znanstvenim konferencijama u području mjerne instrumentacije, senzorskih tehnologija, elektromagnetskog modeliranja, ugradbenih računalnih sustava i obradbe signala.

Izvanredni profesor Džapo stariji je član IEEE (Institute of Electrical and Electronics Engineers), IFMBE (International Federation for Medical and Biological Engineering), i CROBEMPS (Hrvatsko društvo za biomedicinsko inženjerstvo i medicinsku fiziku). Bio je voditelj Odjela za instrumentaciju i mjerenja Hrvatske sekcije IEEE od 2009. do 2013. Voditelj je Centra karijera FER-a od osnutka 2015. godine do danas. Sudjelovao je u 2 međunarodna programska odbora konferencija i bio recenzent u 2 međunarodna časopisa. Dobitnik je Nagrade za izniman doprinos u inženjerskom obrazovanju za 2019. godinu Hrvatske sekcije IEEE, radi doprinosa u inženjerskom obrazovanju kroz povezivanje akademske zajednice i gospodarstva u području stručnih praksi, razvoja karijera i poticanja studentskih poduzetničkih aktivnosti. Dobitnik je FER-ove nagrade „Roberto Giannini" za akademsku godinu 2009./2010. za izvrsnost u nastavi i radu sa studentima. Dobitnik je FER-ove srebne plakete "Josip Lončar" za istaknutu doktorsku disertaciju za akademsku godinu 2006./2007. Za inovacije "Biomehanička vaga za dinamičku analizu posture" i "Sustav za kontinuirano mjerenje snage na brodskoj osovini" dobio je zlatnu i srebrnu medalju na Međunarodnoj izložbi inovacija ARCA 2016 and ARCA 2011.

About the Supervisor

Hrvoje Džapo was born on 15th December 1975 in Zagreb, Croatia. He received his Ph.D. degree from the University of Zagreb, Faculty of Electrical Engineering and Computing (FER), Zagreb, Croatia, in 2007 in the field of Technical Sciences, Electrical Engineering. He received his Dipl. ing. degree from FER in 1999, study of Electrical Engineering, module Industrial Electronics.

From December 1999 until now he has been working at the Department of Electronic Systems and Information Processing at FER. He was promoted to Associate Professor in January 2017. He participated in 12 scientific projects financed by the Ministry of Science, Education and Sports of the Republic of Croatia and other institutions of Republic of Croatia, and 2 international projects. He is a project leader of project "New generation telemetry technology for measurement on rotational clutch components", and actively participates in projects "Development of a new generation of numerical protection devices (KONPRO 2)" and "Advanced sensor systems for precision irrigation in karst landscape (SENSIRRIKA)". He published more than 30 papers in journals and conference proceedings in the area of measurement instrumentation, sensor technologies, electromagnetic modeling, embedded systems and signal processing.

Associate Professor Džapo is a senior member of IEEE (Institute of Electrical and Electronics Engineers), IFMBE (International Federation for Medical and Biological Engineering), and CROBEMPS (Croatian Biomedical Engineering and Medical Physics Society). Has was a chair of IEEE Instrumentation and Measurement Society Chapter of IEEE Croatia Section from 2009 to 2013. He has been the head of the Career Center at FER from its foundation at 2015 until now. He participated in 2 conference international program committees and he serves as a reviewer for 2 international journals. In 2019 he was awarded IEEE Croatia Section Outstanding Educator Award for outstanding contribution to engineering education through connecting the academic sector and industry in the fields of student internships, career development and promotion of student entrepreneurial activities. He received award „Roberto Giannini" from FER for academic year 2009/2010 for exellence in teaching and work with students. He received silver medal "Josip Lončar" from FER for outstanding Ph.D. dissertation for academic year 2006/2007. For his innovations "Biomechanical scale for dynamic posture analysis" and "System for continuous measurement of power on ship motor shaft " he received golden and silver medal award on International innovation exhibition ARCA 2016 and ARCA 2011, respectively.

Hvala

mentoru na strpljenju, pomoći i zajedničkoj borbi s ovom nemani
kolegicama i kolegama na razgovorima, šalama, pozdravima na hodniku, svađama, hamburgerima, šetnjama i pivama
sad već bivšim studenticama i studentima na entuzijastičnom odabiru da rade samnom
prijateljima zato jer jednostavno jesu
i naravno mojoj obitelji Midinec

Sažetak

PREPOZNAVANJE POKRETA LJUDSKOGA TIJELA FUZIJOM PODATAKA ULTRAŠIROKOPOJASNIH LOKALIZACIJSKIH SENZORA I INERCIJSKIH SENZORA

Praćenje pokreta ljudskog tijela (engl. Human Motion Tracking, HMT) nalazi primjenu u brojnim područjima, poput medicine, rehabilitacije, sporta, interaktivnih sustava itd. HMT sustavi prikupljaju kinetičke i kinematičke informacije o kretanju tijela ili njegovih dijelova u svrhu kvantitativne analize parametara pokreta. Tradicionalno korišteni HMT sustavi temelje se na računalnom vidu i inercijskim (IMU) senzorima, a u posljednjih nekoliko godina pojavom tržišno dostupnih ultraširokopojasnih (UWB) tehnologija otvorile su se mogućnosti za realizaciju HMT sustava boljih značajki. Istraživanje su motivirali uočeni nedostaci postojećih HMT metoda temeljenih na fuziji UWB tehnologije i IMU senzora. Razvijene su odgovarajuće metode kompenzacije mjernih pogrešaka i pokazano je da se predloženim pristupom postižu bolji rezultati u odnosu na postojeće metode. Razvijeni su specijalizirani nosivi bežični umreženi senzorski čvorovi te je razrađen model i algoritam za određivanje položaja i pokreta ljudskog tijela primjenom fuzije senzorskih podataka iz UWB i IMU senzora.

Postignuti su sljedeći znanstveni doprinosi:

- Model za određivanje položaja i pokreta ljudskog tijela iz podataka dobivenih nosivim ultraširokopojasnim lokalizacijskim senzorima i inercijskim senzorima.
- Arhitektura sklopovske i programske izvedbe mjernog postava niske potrošnje za određivanje položaja i pokreta ljudskog tijela.
- Algoritam za određivanje položaja i prepoznavanje pokreta ljudskog tijela primjenom fuzije senzorskih podataka i metoda strojnog učenja.

Ključne riječi: praćenje pokreta ljudskog tijela, ultraširokopojasna (UWB) tehnologija, inercijski senzori, senzorska fuzija, prepoznavanje pokreta, strojno učenje

Abstract

HUMAN BODY MOTION RECOGNITION USING ULTRA-WIDEBAND LOCALIZATION SENSORS AND INERTIAL SENSORS DATA FUSION

Human Motion Tracking (HMT) is used in various fields, such as medicine, rehabilitation, sports, interactive systems, etc. HMT systems collect kinetic and kinematic data about movement of the body or its individual parts for purpose of quantitative analysis of movement parameters. Traditionally, HMT systems were based on computer vision techniques and inertial (IMU) sensors, while in recent years commercial availability of ultra-wideband (UWB) technologies opened new opportunities for realization of HMT systems with better characteristics. The research was motivated by the perceived shortcomings of existing HMT approaches based on UWB and IMU sensor fusion. Methods for measurement error compensation were developed and it was shown that the proposed approach can achieve better performance compared to the existing methods. Specialized wearable wireless sensor nodes were developed, and the model and algorithm for determination of the position and motion of the human body, based on data fusion between UWB and inertial sensors, were developed.

Ultrawideband (UWB) technology represents a fast growing field of technology that enables various new possibilities and applications. Hardware solutions, measurement methods and algorithms used in UWB technology are the subject of intensive current research. Aforementioned systems are developing with a goal to increase their performance and decrease the price. In the scope of this dissertation a combination of UWB and inertial measurement units (IMU) was researched, with target application on tracking and classification of human movement. Prototype solutions and methods for distance measurement with UWB technology were developed in order to enable validation of designed methods. Accompanying software was developed to enable timely and reliable data acquisition from IMU sensors. To increase the precision of measured distances, a method for estimation of system parameters was developed. System was validated in laboratory environment so that practical accuracy limits and precision can be determined for various movement speeds. At the end of research it was shown that the proposed method can be used for better feature extraction of measured human motion for classification by means of machine learning methods.

One of the biggest drawbacks of the localization technologies is the line of sight problem (LOS) between mobile and base stations in indoor environments. Furthermore, there is a multipath problem of signal propagation caused by reflections from objects in the close vicinity. In these cases we cannot be sure in time of flight or direction of the received UWB signal. These propagation problems needed to be analyzed so that the underlying problem of distance measurement can be modelled. UWB technology is based on ultra-short signals in time domain which

occupy very large frequency band. Analysis of UWB systems is fundamentally different compared to widely researched propagation models of narrowband systems and such models cannot be simply applied to UWB technology. With regards of application and goals of the research, required propagation models were analyzed to better describe a behaviour of UWB systems. The reference setup propagation channel was analyzed with a goal of determining error sources in measurement process. UWB technology represents a viable solution for measuring distances and localization in indoor environments. It was shown that this technology is capable of high accuracy localization in closed spaces. Additional benefits are high speed communication, low price, immunity to multipath problem, and capability of localization and communication in the same time. UWB technology is based on ultra short signals that can penetrate obstructions in signal path (such as walls) because of its wide spectral band. LOS condition is not necessary for establishing UWB communication. Basic implementations of UWB systems can achieve the accuracy of 20 cm and with additional data processing even better results are possible. In applications of detecting and tracking human motion UWB technology can be used in two ways. One approach is a radar method where UWB channel is analyzed to detect, track or classify human activity in closed spaces or even behind the walls. Another option is to measure propagation time of UWB signal from transmitters placed on tracked objects or parts of the human body.

With sensor fusion of various sources of information, human movement detection and classification can be additionally improved. With carefully designed models spurious measurements can be isolated and sensor errors can be minimized. In this doctoral dissertation, a combination of UWB and IMU sensors was used so that measured data could be better interpreted. IMU sensors typically contain accelerometers, gyroscopes and magnetometers, placed together within the same case. In order for using such unit for orientation and position estimation, measured values need to be integrated in time. This in turn increases effects of integration and sensor drift errors. Therefore, sensor fusion methods are used so that multiple information sources can be combined and interpreted. This is generally achieved by virtue of Kalman and extended Kalman filters. Additionally, IMU measurements can be combined with other models, such as kinematic chains of human motion. By reviewing the existing literature, it was concluded that there is a room for further research in the area of fusion of localization sensors and inertial sensors. Previous research in the field of human movement and activities monitoring have provided a justification for this approach. The possibility of application of such approach in human-computer interaction using wearable, energy efficient localization systems, is still poorly understood and researched. While machine learning methods generally apply to the estimation of the UWB channel state, movement classifications is still not researched enough.

For the purposes of this research, it was necessary to develop a wearable hardware design of a small, compact, battery-powered and energy-efficient wireless nodes for measuring distance, motion and gesture detection. Also, a flexible software architecture for distributed system was

developed to provide the necessary functionality for experimental research, collection of sensor data for further processing, and validation and verification of developed models and methods. The software provided easy configuration of the system, data communication between nodes, time synchronization, collection of data for algorithm analysis for determination of distances from receive and send times of UWB signals, collection of data from inertial sensors, storage, and sending the collected data to the central unit for later processing. With help of the collected data, a method for time compensation of wireless UWB nodes for distance determination was developed so that accuracy and precision of the measurement system can be maximized. Different approaches to localization (such as time of arrival (TOA), time difference of arrival (TDOF), round trip of flight (RTOF), etc.) were studied and the corresponding data and signal processing algorithms, with goal to optimize the performance of the selected estimator. The experimental setup established the limits of accuracy and the applicability of the system, of the above mentioned methods and algorithms for data processing, and the obtained results were compared with the existing reference system of similar purpose.

Generally, the aim of this doctoral dissertation was to explore the application possibilities of UWB localization and inertial motion sensor fusion, whereby practical limits of accuracy and applicability were sought to be determined. Also, goal was to design methods for extracting features of motions, needed for classification by machine learning approach. Basic initial hypothesis was the assumption that a representative information for movement classification could be collected from sensory data. Defense of the stated hypothesis it is presented in five chapters.

In introduction an overview of the motivation for research in the field of human motion movement monitoring was given. This field has attracted a lot of attention over the past decade in the scientific and engineering community. Generally, systems for human movement monitoring collect kinetic and kinematic information on the movement of the body or its individual parts, for the purpose of quantitative analysis related to their relative positions. Special emphasis was placed on the analysis of the human locomotor system and the current cross-section of available methods and technologies used in motion monitoring.

An overview of positioning technologies was given in the next chapter, depending on the application, accuracy, precision, dynamic position monitoring, environmental conditions, dependence on infrastructure, energy efficiency and power consumption, hardware and software complexity, operation autonomy, cost, mass, dimensions, mobility etc. For the purposes of analyzing the existing systems and technologies for positioning, an overview of basic concepts and methods was made. Current state of scientific research was presented with a focus on determining the angle of the human joints. Also, in the context of this chapter, the applications of the IMU sensor in human activity monitoring was given for purposes of tracking position, orientation and movement of the human body as a whole or its individual parts. Also, special

emphasis was put on exploring the application of UWB technology. The advantages and disadvantages of the individual methods and technologies were presented so that to further research procedures can be justified. In the previous researches drawbacks were found when UWB was is used in tracking of human movements. It was noticed that every available research is based on models that utilize positions obtained by using UWB system, or more specifically, coordinates in the reference coordinate system. Although such an approach produces satisfactory results it also has important practical limitation. Obtaining a position from the UWB system generally implies some kind of fixed infrastructure, which was previously calibrated in a specific predefined area. Although there are automated calibration solutions approaches for UWB positioning system, they also require some form of additional infrastructure around the observed human. On other hand, when UWB technology was used without infrastructure, that is only when the distances between nodes were measured, it was noted that only high precision and sophisticated lab equipment was used and not low-cost modules of lower precision.

For these reasons in the next chapter the model for distance measurement was developed, based on compensation of the time base for mobile nodes. This approach was chosen to make distance measurements applicable and extended to cheaper systems with the use of UWB technology, without a need for expensive lab equipment with a highly stable clock sources. Also, in this way the need for fixed infrastructure was removed. The developed model also includes IMU sensors for determination of the movement of parts of human body because of their affordable price and size. Additionally, when human motion was measured with IMU sensors, the kinematic model of human motion was considered, specifically a kinematic chain that describes the movements of segments associated with joints with multiple degrees of freedom. Model of movement of individual segments have been redefined and simplified in this way with use of multiple sources of information, that is, with the use of IMU sensor pairs. Likewise, during the preliminary research, the conclusion was drawn that during a sensor fusion, or more specifically evaluation of IMU orientation, a magnetometer should be avoided.

For practical evaluation of the model proposed in the previous chapter, there was a need to develop the architecture and implementation of a measuring data collection system in the form of wearable low-power wireless sensor node. Such system was developed with the aim of being placed on the human body. Description of the node was given in fourth chapter. Developed nodes have the ability to measure distances using UWB transcievers and also acceleration and angular velocity by means of the built-in IMU sensors. Multiple versions of hardware, based on the use of the DW1000 integrated circuit, were developed. This approach was chosen because the existing commercially available development systems did not contain all the necessary hardware components for implementation and processing of measurements. Also, the manufacturer's programming libraries of the integrated circuit needed to be upgraded with new capabilities because the existing software did not provide all the necessary functionality. Deve-

loped solution, based on the DW1000 integrated circuit, also needed to be tested to validate that it does not introduce systematic measurement errors. Also, various sources of errors that could affect accuracy and precision of measurements were tested. Furthermore, attention was paid to research of the interference with narrowband communications, whose spectrum overlaps with the frequency range of the UWB communication system, and to the impact of reflections in environments with multipath sources.

In the last chapter the measurement results were summarized for the overall system and for previous research done to validate individual methods. The time base compensation method for distance estimation was explained while required parameters for the compensation algorithm were experimentally determined with help of reference robotic arm to experimentally simulate the human motion. Validation of the whole system was made in static and dynamic conditions where results showed that system behavior was within the bounds of previous research. Additionally, a procedure based on Kalman filtering was suggested to utilize the information from the IMU sensor. Machine learning represents a set of techniques and algorithms that, based on the study of statistical regularities in data, can build a model and use it to make decisions and conclusions over newly collected data. Measurements on subjects have shown that with the proposed methods one can significantly increase the classification accuracy of the individual human body part movements.

The following scientific contributions were achieved:

- model for determination of the human body position and motion from the data obtained by wearable UWB localization sensors and inertial sensors
- hardware and software architecture of low-power measurement system for determination of the human body position and motion
- algorithm for determination of the human body position and motion recognition by using sensor data fusion and machine learning methods.

Keywords: human motion tracking, ultra-wideband (UWB) technology, inertial sensors, sensor fusion, motion recognition, machine learning

Sadržaj

1. Uvod 1
1.1. Metode praćenja pokreta ljudskog tijela 1
1.2. Kinematika pokreta ljudskog tijela 4
1.3. Formulacija problema i doprinosi 7
1.4. Struktura rada 9

2. Pregled stanja tehnologije sustava za ultraširokopojasnu lokalizaciju i inercijska mjerenja 11
2.1. Metode određivanja udaljenosti i položaja 11
2.1.1. Osnovne definicije 13
2.1.2. Metode određivanja položaja mjerenjem udaljenosti 16
2.1.3. Metode određivanja položaja mjerenjem kuta dolaska signala 24
2.1.4. Analiza prostora 25
2.1.5. Određivanje lokacije neposrednom blizinom 25
2.1.6. Vizualna lokalizacija 26
2.2. Ultraširokopojasna tehnologija 26
2.2.1. Načela ultraširokopojasne komunikacije 27
2.2.2. Modeliranje propagacije (engl. *ultra-wideband*, UWB) signala 30
2.2.3. Mjerenje udaljenosti temeljeno na mjerenju vremena propagacije ultraširokopojasnog signala 38
2.2.4. Propisi i standardi za ultraširokopojasnu komunikaciju 42
2.2.5. Pregled stanja UWB tehnologije 47
2.3. Inercijski senzori 50
2.3.1. Izvedbe inercijskih senzora 51
2.3.2. Izvori pogrešaka kod inercijskih senzora 58
2.3.3. Određivanje orijentacije inercijskih senzora 64
2.3.4. Kalibracija inercijskih senzora 74
2.4. Stanje tehnologije u određivanju položaja i orijentacije ljudskog tijela 80
2.4.1. Stanje inercijske tehnologije u određivanju kuta zgloba 80

2.4.2. Stanje UWB tehnologije u određivanju položaja i kuta zgloba 84

3. Model za određivanje položaja i pokreta ljudskog tijela 88
3.1. Modeliranje mjerenja udaljenosti korištenjem ultraširokopojasnih senzora . . . 89
3.1.1. Kompenzacija vremenske baze 91
3.2. Modeliranje mjerenja korištenjem inercijskih senzora 92
3.2.1. Generalizirani model kinematskog lanca s dva segmenta 92
3.2.2. Model kinematskog lanca s dva segmenta za kutni zglob 96

4. Arhitektura i implementacija sustava za prikupljanje mjernih podataka 98
4.1. Sklopovska arhitektura i izvedbe senzorskog čvora 99
4.2. Arhitektura programske potpore senzorskog čvora 106
4.3. Inicijalna validacija prototipnog senzorskog čvora 114
4.4. Eksperimentalno ispitivanje utjecaja stanja kanala na mjerenje udaljenosti . . . 117
4.4.1. Referentna mjerenja u EMC komori bez višestaznih refleksija 119
4.4.2. Mjerenja u prostoriji s višestaznim izvorima refleksija 126

5. Metoda određivanja položaja i prepoznavanja pokreta ljudskog tijela 131
5.1. Predloženi algoritam estimacije udaljenosti 131
5.2. Validacija modela s kompenzacijom izvora vremena 135
5.2.1. Ponašanje u statičnim uvjetima 137
5.2.2. Ponašanje u dinamičkim uvjetima 137
5.3. Određivanje kuta uz pomoć IMU senzora 142
5.4. Fuzija višestrukih izvora informacija 144
5.5. Klasifikacija i prepoznavanje pokreta 146

6. Zaključak 151

Literatura 158

Kazalo pojmova 169

Životopis 177

Biography 179

Poglavlje 1

Uvod

Praćenje pokreta ljudskog tijela (engl. *human motion tracking*, HMT) područje je koje je tijekom proteklog desetljeća privuklo veliku pozornost u znanstvenoj i inženjerskoj zajednici. Sustavi za praćenje ljudskog pokreta prikupljaju kinetičke i kinematičke informacije o kretanju tijela ili njegovih pojedinih dijelova, u svrhu kvantitativne analize parametara koji se odnose na njihove relativne međusobne položaje. Područje primjene HMT sustava je široko te obuhvaća područja medicine, sporta, vojnih i sigurnosnih primjena, sučelja čovjek-računalo, zabavne industrije, interaktivnih igara, kinematografije i sl. U ovom poglavlju prikazati će se kratki pregled motivacije istraživanja ovog doktorskog rada s posebnim naglaskom na ljudski lokomotorni sustav. Izložiti će se trenutni presjek metoda i tehnologija koje se koriste prilikom praćenja pokreta ljudskog tijela. Također, izložiti će se znanstveni doprinosi, kao i struktura doktorskog rada.

1.1 Metode praćenja pokreta ljudskog tijela

Područje praćenja pokreta ljudskog tijela usko je povezano s biomehanikom lokomotornog sustava ljudskog tijela, koja se bavi proučavanjem koštanih i mišićnih sustava kao i mehaničkih sustava na kojima se temelji gibanje ljudskog tijela. Ljudski pokreti mogu se opisati zakonima fizike, pri čemu se u analizi lokomotornog sustava čovjeka koristi kinematika kao grana mehanike koja se bavi proučavanjem gibanja tijela, bez obzira na uzročne sile na kojima se temelji gibanje tijela. Kinematički modeli ljudskog tijela služe za kvantitativno modeliranje ljudskog pokreta, što nalazi brojne primjene, poglavito u medicinskoj dijagnostici i rehabilitaciji. Primjerice, u sportu se može primijeniti prilikom prevencije sportskih ozljeda.

Praćenje položaja i pokreta pojedinih dijelova ili cijelog ljudskog tijela može se postići raznim pristupima i tehnologijama. Svaka tehnologija pruža drugačije mogućnosti s obzirom na točnost i ponašanje u dinamičkim uvjetima. Tehnologije praćenja ljudskog pokreta temelje se na mehaničkim, inercijskim, optičkim, magnetskim, ultrazvučnim i radiofrekvencijskim (radarskim) senzorima. Općenito, moderni HMT sustavi mogu se podijeliti u dvije osnovne

kategorije [1]: sustavi temeljeni na računalnom vidu i sustavi temeljeni na nosivim senzorima.

Najtočniji HMT sustavi temelje se na primjeni jedne ili više kamera, koje prate kretanje ispitanika u prostoru, a na kojega je postavljen veći broj markera na karakterističnim točkama ljudskog tijela. Obradom slike dobivaju se informacije o položaju svakog markera u prostoru, dok se povezivanjem markera s odgovarajućim biomehaničkim modelom ljudskog tijela mogu dobiti relativni odnosi između pojedinih dijelova tijela. Nedostatak ovakvih sustava je njihova složenost korištenja, interpretacije rezultata, kao i visoka cijena. Zahtijevaju korištenje specijaliziranih laboratorija, posebne opreme i pripremu ispitanika na kojega se moraju postaviti markeri. U zadnjih nekoliko godina pojavila su se i rješenja temeljena na računalnom vidu koja ne koriste markere, već samo algoritme obrade i analize slike. Posljedično to ih čini jednostavnijim za uporabu i jeftinijim. Primjeri takvih rješenja su sustavi kao Leap Motion* i Microsoft Kinect. Navedeni sustavi se temelje na istovremenoj primjeni višestrukih kamera kako bi se mogla odrediti percepcija dubine. Međutim, iako su takvi sustavi u određenim primjenama prihvatljiviji jer manje ometaju ispitanika prilikom samoga korištenja, takve izvedbe imaju lošije performanse u odnosu na rješenja temeljna na markerima. Prvenstveno u pogledu lošije preciznosti estimacije parametara pokreta, kao i manje robusnosti [2] (npr. npr. Optotrak† i Vicon‡). Svi sustavi temeljeni na metodama računalnog vida dijele i određene zajedničke nedostatke, kao što su potreba za visoko kontroliranim uvjetima, ograničen volumen kojeg prekriva veći broj kamera, problem okluzije, odnosno nemogućnost prepoznavanja pokreta iza prepreka itd. Također, sustavi temeljeni na računalnom vidu zahtijevaju skupu i fiksnu infrastrukturu gdje položaji i usmjerenja kamera moraju ostati nepromijenjeni tijekom mjerenja. Primjenjivost ovakvih sustava u području rutinskih biomehaničkih mjerenja ograničena je jer su takvi sustavi izrazito kompleksni i tipično zahtijevaju specijalizirane laboratorije i stručnjake za provedbu mjerenja [3].

HMT sustavi, temeljeni na nosivim senzorima, postavljaju se na strogo odabrane točke na tijelu ispitanika u svrhu praćenja pokreta. Osnovne prednosti nosivih HMT sustava, u odnosu na rješenja temeljena na računalnom vidu, su neovisnost o fiksnoj infrastrukturi, eliminacija problema okluzije, jednostavnost korištenja sustava, niska cijena itd. Nosivi HMT sustavi tipično koriste inercijske senzore (engl. *inertial measurement unit*, IMU), od kojih su najvažniji akcelerometri i žiroskopi. Inercijski senzori koji se koriste u HMT sustavima postavljaju se na karakteristične točke na udovima s ciljem praćenja pozicije i orijentacije pojedinih udova, kao i kuteva među zglobovima. Akcelerometri i žiroskopi koji se koriste u HMT sustavima najčešće se odabiru tako da omogućavaju mjerenje linearne akceleracije i kutne brzine po tri ortogonalne osi, a obično im se dodaje i troosni magnetometar u svrhu lakše kalibracije sustava za vrijeme rada. Integracijom mjerenja prikupljenih s inercijskih senzora može se doći do kinematičkih

*Leap Motion `www.leapmotion.com/`

†Optotrak `www.ndigital.com/msci/products/`

‡Vicon `www.vicon.com`

vrijednosti uz pomoć mjerenja brzine, položaja, kuta među zglobovima i drugih parametara. Osnovni nedostatak inercijskih senzora su akumulirane pogreške uslijed tehnološki inherentnih nesavršenosti senzora, čiji se utjecaj na točnost i preciznost mjerenja značajno povećava prilikom postupka integracije sirovih rezultata s IMU senzora. Problem akumulirane integracijske pogreške može se značajno umanjiti korištenjem inercijskih senzora s višom klasom točnosti, kao što su npr. XSens [§] i Invensense [¶]. Međutim, za većinu praktičnih rutinskih primjena cijena takvih rješenja je neprihvatljivo visoka. Drugi pristup smanjenju utjecaja pogrešaka inercijskih senzora temeljen je na primjeni naprednih naprednih metoda obrade podataka iz manje kvalitetnih senzora, tipično implementiranih u (engl. *microelectromechanical systems*, MEMS) tehnologiji, korištenjem algoritama senzorske fuzije (engl. *Sensor Fusion*), kao što su Kalmanov i čestični filtar (engl. *Particle Filtering*). Međutim, napredne matematičke metode obrade senzorskih podataka mogu samo do određene mjere ublažiti utjecaj pogrešaka, ali ga ne i u potpunosti ukloniti [2]. Dodatno, većina metoda za kompenzaciju pogrešaka uz akcelerometre i žiroskope koriste magnetometre za kompenzaciju pogrešaka inercijskih mjerenja, koji su sami po sebi osjetljivi na utjecaj lokalne okoline u blizini senzora. Primjerice, korištenje magnetometara u zatvorenim prostorijama može dovesti do nezadovoljavajućih rezultata zbog prisutnosti magnetskih smetnji u obliku stalnih i promjenjivih magnetskih polja koja utječu na prirodno magnetsko polje Zemlje na kojem magnetometar temelji svoju kompenzaciju pogrešaka. Primjerice, slabo magnetsko polje Zemlje mogu narušiti feromagnetski materijali u blizini senzora. Premda se ti utjecaji mogu ukloniti s ponovnom kalibracijom, ta je kompenzacija valjana samo kratko vrijeme i ograničena je na specifičnu lokaciju gdje je sama kalibracija izvršena. Od ostalih nosivih HMT sustava izdvajaju se fleksibilni goniometri, temeljeni na mehaničkim [4], galvanskim [5] i rješenjima koja koriste optička vlakna [6].

U zadnjih nekoliko godina pojavila se nova mogućnost implementacije HMT sustava korištenjem radiofrekvencijskih (RF) sustava za precizno pozicioniranje. Takvi sustavi temelje se na korištenju ultraširokopojasne UWB tehnologije, koja je sazrijela do te mjere da je danas moguće izraditi nosive, baterijski napajane bežične čvorove. Čvorovi omogućuju mjerenja udaljenosti s preciznošću od nekoliko centimetara i dinamičkih promjena u području desetaka, čak i stotina Hz [7]. UWB tehnologija omogućuje određivanje lokacije svakog nosivog čvora u 3D prostoru s centimetarskom preciznošću, na temelju čega se mogu dobiti kinematički parametri lokomotornog sustava ispitanika, bez korištenja sustava temeljenih na računalnom vidu ili inercijskim senzorima. UWB tehnologija također omogućuje specifične prednosti, ali i uspješno rješava mnoge nedostatke svojstvene postojećim HMT sustavima, kao što su problemi okluzije kod optičkih ili klizanja senzorskih očitanja kod IMU senzora. Također imaju mogućnost prodiranja kroz prepreke koje onemogućavaju primjenu sustava temeljenih na računalnom vidu.

[§] Xsens `www.xsens.com`

[¶] InvenSense `www.invensense.com/technology/motion/`

UWB sustavi posebno su imuni na problem refleksija uslijed višestaznog rasprostiranja signala (engl. *multipath propagation*), što inače stvara velike poteškoće kod klasičnih, uskopojasnih radiofrekvencijskih sustava. Premda UWB tehnologija ima svojih specifičnih nedostataka, unatoč tome predstavlja izgledan odabir za rješavanje ranije opisanih poteškoća svojstvenih optičkim i inercijskim HMT sustavima, bilo kao potpuno neovisni sustav ili sustav koji radi kooperativno s postojećim HMT metodama. UWB tehnologija ispunjava nekoliko kritičnih potreba nosivih HMT sustava, kao što su niska cijena, niska potrošnja energije i mogućnost realizacije čvorova malih dimenzija, pogodnih za postavljanje na ljudsko tijelo [8].

1.2 Kinematika pokreta ljudskog tijela

Ljudsko tijelo predstavlja složenu mehaničku strukturu sastavljenu od skupa međusobno povezanih dijelova koji kroz uzajamno međudjelovanje proizvode određeno gibanje. Ljudski kostur sastavljen je od 206 kostiju različitih oblika, a služi kao potporni sustav za skup mišića, tetiva i zglobova koji sudjeluju u procesu gibanja. Zglobovi drže kosti zajedno te pružaju stabilnost i omogućuju pokretljivost ljudskog kostura [9]. Kost predstavlja živo tkivo koje je sastavljeno od većinom anorganskih tvari, temeljenim većim dijelom na kalciju i fosforu. Kako ljudski organizam stari, tako kosti i zglobovi mijenjanju svoju strukturu zbog istrošenosti. Struktura se također može mijenjati i zbog bolesti, kao i uslijed atrofije u slučaju imobilizacije dijela tijela. Kosti mogu i ojačati uzduž linija najvećeg opterećenja ako su izložene konstantnim uzrocima opterećenja.

Kostur se može podijeliti na ukupno 15 zglobova i 14 ekstremiteta koji se mogu pratiti korištenjem HMT sustava [1]. Općenito, zglobovi se mogu podijeliti na tri vrste: vezivne (fibrozne, engl. *fibrous*), hrskavične (kartilaginozne, engl. *cartilaginous*) i pokretne (sinovijalne, engl. *synovial*) [10]. Pokretni zglobovi ključni su za pokretljivost ljudskog tijela, a sastoje se od zglobne plohe podstavljene hrskavicom te zglobne tekućine koja podmazuje kretnje, kako je prikazano na slici 1.1a. Ligamenti učvršćuju i stabiliziraju sam zglob te ujedno ograničavaju smjer i amplitudu kretnje. Prema samom obliku pokretnih zglobova i njihovoj funkciji, može ih se podijeliti u šest grupa: kutni, obrtni (rotacijski), klizni (ravni), jajoliki (elipsoidni), sedlasti i kuglasti. Navedene grupe zglobova s tipičnim primjerima ilustrirani su na slici 1.1b. U tablici 1.1 nalazi se popis zglobova, njihovih mogućih kretnji te primjeri zglobova na ljudskom tijelu vezanih uz određenu vrstu. U tablici 1.1 može se vidjeti da se pokreti glave, ramena, zapešća, trupa, kuka, prsta i gležnjeva mogu pratiti uz pokrete fleksije i ekstenzije. *Fleksija* podrazumijeva promjenu položaja savijanjem, gdje se smanjuje kut promatranog zgloba. S druge strane, *ekstenzija* predstavlja zrcalno gibanje fleksije uda, gdje se kut promatranog zgloba povećava [3].

[‖]Preuzeto s *https://opentextbc.ca/anatomyandphysiology/chapter/9-4-synovial-joints*, Creative Commons At-

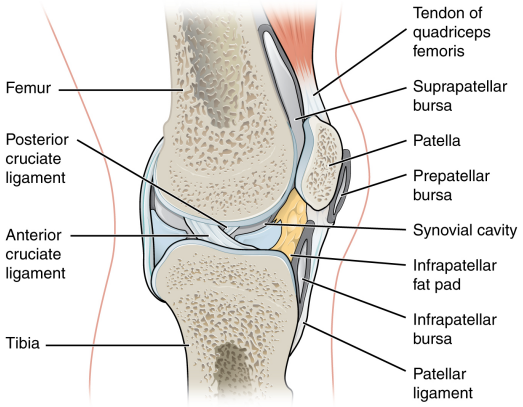

(a)

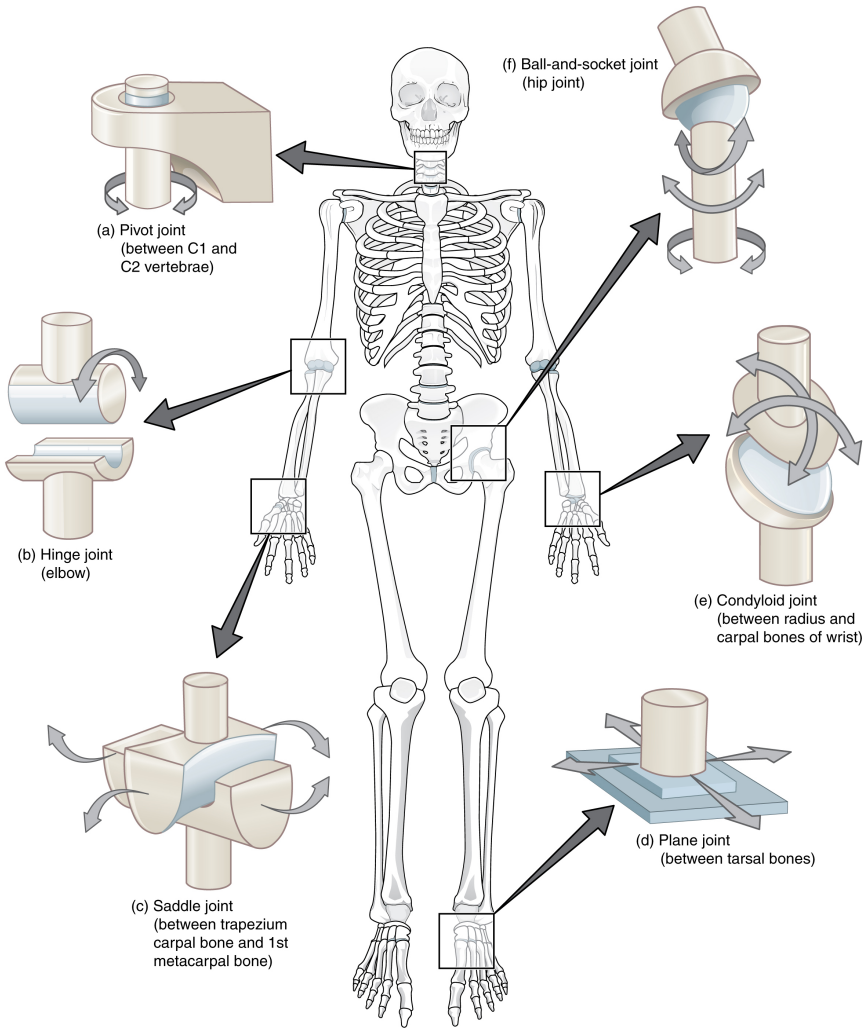

(b)

Slika 1.1: Pokretni (sinovijalni) zglobovi: (a) presjek pokretnog zgloba, (b) tipovi pokretnih zglobova.

Smanjena pokretljivost zglobova može biti uzrokovana starenjem, nedovoljnom fizičkom aktivnošću ili lošom prehranom. HMT sustavi u ovom slučaju mogu pomoći u praćenju ljudske aktivnosti i parametara kinematike zglobova, što se može koristiti u ranoj dijagnostici, tretmanu i rehabilitaciji kod bolesti i poteškoća lokomotornog sustava. Kako bi se mogla napraviti korisna analiza lokomotornog sustava, potrebno je na ispravan način prikupiti parametre na temelju kojih liječnik može donijeti odgovarajuće zaključke i planirati učinkovitu terapiju.

Pokreti zglobova ostvaruju se putem izotoničke kontrakcije mišića i kontrakcijske sile povezane sa promjenom duljine mišića na mjestu zgloba. Za vrijeme kontrakcije, duljina mišića varira za različite kuteve zgloba, pokrete i položaje (posture) tijela. Stoga je primarni fokus kod realizacije sustava za praćenje parametara zglobova omogućiti praćenje aktivnosti na način da se kvantitativno prikupe smisleni podaci za interpretaciju. Primjerice, kao što su kut zgloba, raspon pokretljivosti zgloba, karakteristike pokreta i orijentacija povezanih kostiju, itd. Navedeni parametri mogu pružiti korisnu informaciju za procjenu zdravstvenog stanja zgloba i lokomotornog sustava. Postoje tri ključna parametra koja su važna za dijagnostičke informacije, a to su kut zgloba (engl. *joint angle*), pokret zgloba (engl. *joint motion*) i praćenje kostura (engl. *skeletal tracking*).

Svaki zglob ima optimalni kut za određenu radnju ili pokret. Da bi se postigao optimalni kut, mišić vezan uz zglob mora imati ispravnu duljinu da podnese maksimalno opterećenje. U literaturi postoje preporučene referentne vrijednosti raspona pokretljivosti (kuta) zglobova (engl. *range of motions*, ROM), koje ovise o spolu, dobi, razini fizičke aktivnosti itd. Na temelju praćenja parametra kuta zgloba moguća je rana dijagnoza potencijalnih zdravstvenih problema i praćenje učinkovitosti propisane terapije. Za mjerenje kuta zgloba koriste se različite metode i pristupi [10], od kojih je važno istaknuti mehaničke, elektromehaničke i optičke goniometre, sustave temeljene na IMU senzorima te sustave temeljene na računalnom vidu. Nedostaci mehaničkih i elektromehaničkih goniometara su nefleksibilnost i niska točnost, što uspješno rješavaju optički goniometri temeljeni na optičkim vlaknima. U zadnje vrijeme sustavi za mje-

tribution 4.0 International License

Tablica 1.1: Tipovi pokretnih (sinovijalnih) zglobova

Tip pokretnog zgloba	Pokreti zgloba	Primjer zgloba
obrtni	vrtnja (rotacija)	gornji dio vrata
kutni	fleksija/ekstenzija	lakat, koljeno, gležanj
sedlasti	fleksija/ekstenzija/adukcija/abdukcija/kruženje	palac
klizni	klizanje	zglobovi zapešća
jajoliki	fleksija/ekstenzija/adukcija/abdukcija/kruženje	zapešće
kuglasti	fleksija/ekstenzija/adukcija/abdukcija/rotacija	kuk/rame

renje kuta zgloba temeljeni na IMU senzorima postaju posebno atraktivni zbog kompaktnosti, niske cijene i mogućnosti mjerenja kuteva u tri dimenzije s visokom točnošću i preciznošću.

Pokret zgloba predstavlja opis gibanja zgloba, što uključuje fleksiju (savijanje, engl. *flexion, bending*), ekstenziju (engl. *extension*), adukciju (pokret prema središtu tijela, engl. *adduction*), abdukciju (pokret od središta tijela, engl. *abduction*) i kruženje (engl. *rotation*). ROM parametar za pojedini tip pokreta zgloba može se koristiti kao klinički indikator za procjenu zdravstvenog stanja zgloba uslijed bolesti, ozljeda ili starenja. Mjerenje parametra pokreta zgloba uključuje već ranije spomenuto mjerenje kuta zgloba, ali i orijentacije među povezanim kostima. Za realizaciju mjernih sustava za mjerenje pokreta zgloba koriste se slične metode i pristupi opisani u prethodnom odlomku kao kod opisa parametra kuta zgloba.

Praćenje kostura predstavlja tehniku izgradnje cjelokupnog kinematičkog modela ljudskog kostura povezivanjem informacija o pozicijama i orijentacijama svih zglobova u modelu. Za razliku od dva prethodno spomenuta parametra, praćenje kostura pruža cjelovitu informaciju o stanju lokomotornog sustava ispitanika kao cjeline, koja se promatra pri različitim aktivnostima. Osnovna primjena praćenja kostura je dijagnostika fizičkih ograničenja lokomotornog sustava i analiza uspješnosti rehabilitacijskog procesa preciznim praćenjem posture tijela u različitim uvjetima. U području praćenja kostura prvenstveno se koriste sustavi temeljeni na računalnom vidu, jer je zbog složenosti i velikog broja zglobova na ljudskom tijelu postavljanje IMU senzora za praćenje svih zglobova nepraktično. Ponekad se koriste IMU sustavi kao nadopuna sustavima s kamerama ili za prikupljanje djelomičnih informacija kada je to prikladno.

1.3 Formulacija problema i doprinosi

U ovom doktorskom radu istražena je mogućnost primjene kombinacije ultraširokopojasne tehnologije i inercijskih senzora u svrhu određivanja položaja i pokreta ljudskog tijela. Pod pojmom *položaja* podrazumijevaju se relativni odnosi između dijelova tijela (npr. kutevi i orijentacije zglobova), dok se pod *pokretom* podrazumijevaju kretnje pojedinih dijelova tijela. Praćenje položaja i pokreta važno je u različitim primjenama, od medicinske dijagnostike i rehabilitacije, sporta, interaktivnih sustava i sl.

Kao što je već bilo rečeno, najprecizniji sustavi koji se danas koriste za praćenje položaja i pokreta ljudskog tijela temelje se računalnom vidu i sustavima s više kamera. Takvi sustavi u praktičnim primjenama imaju određene nedostatke, kao što su potreba za kontroliranim laboratorijskim uvjetima, problemi promjenjive osvijetljenosti, opstrukcije vidnog polja, dinamičkih scena u kojima je potrebno istovremeno pratiti više različitih objekata, složenost instalacije sustava, potreba za fiksnom infrastrukturom kao i visoka cijena sustava. Jeftinije i prilagodljivije varijante sustava za praćenje položaja i pokreta ljudskog tijela temelje se na inercijskih senzorima no kod njih najveće probleme izazivaju nesavršenosti jeftinijih MEMS izvedbi IMU

senzora i integracijske pogreške. Alternativno korištenje skupih IMU jedinica u najvećem broju slučajevima nije ekonomski opravdano.

Kako bi se uspješno riješili različiti nedostaci postojećih metoda, u ovoj doktorskoj disertaciji predložen je drugačiji pristup realizaciji HMT sustava temeljen na korištenju nosivih senzora, koji kombiniraju UWB tehnologiju i IMU senzore. Takva kombinacija cjenovno je prihvatljivija od skupih sustava temeljenih na računalnom vidu ili IMU senzorima visoke preciznosti, a dimenzijama, masom i potrošnjom prikladna je za postavljanje na tijelo ispitanika. Osnovna ideja predloženog rješenje je iskoristiti UWB čvorove za precizno mjerenje udaljenosti propagacijom elektromagnetskog vala i ta mjerenja, fuzijom podataka prikupljenih iz inercijskih senzora, koristiti za dobivenje informacije položaju i pokretu zgloba. Slično, može ih se iskoristiti i za kalibraciju IMU senzora za vrijeme rada, bez korištenja magnetometra. Naime, MEMS senzori zbog svojih tehnoloških nesavršenosti zahtijevaju kontinuiranu rekalibraciju za vrijeme rada, a korištenje magnetometra kao pomoćnog senzora uz akcelerometre i žiroskope može biti problematično u situacijama kada postoje magnetske smetnje (izboličenja prirodnog magnetskog polja Zemlje ili prisutstvo feromagnetskog materijala). Predloženo rješenje imuno je na takve probleme.

Za potrebe istraživanja razvijeno je više sklopovskih i programskih implementacija mjernog sustava temeljenog na kombinaciji UWB i IMU senzora. Razvijeni mjerni postav je radi malih dimenzija i mase te niske potrošnje prikladan za ispitivanje predloženih metoda i algoritama u laboratorijskim uvjetima na ljudskom tijelu. Prototipna implementacija senzorskog čvora eksperimentalno je verificirana te je korištena za validaciju predloženog postupka mjerenja i obrade mjernih rezultata.

Razrađen je model za određivanje položaja i pokreta ljudskog tijela iz podataka dobivenih nosivim ultraširokopojasnim lokalizacijskim senzorima i inercijskim senzorima. Proučene su mogućnosti i granice praktične primjenjivosti navedenih tehnologija. Također je razrađen algoritam za određivanje položaja i prepoznavanje pokreta ljudskog tijela primjenom fuzije senzorskih podataka i korištenjem metoda strojnog učenja. Perfomanse algoritma bile su eksperimentalno verificirane kako bi se odredile granice točnosti i primjenjivosti predloženog pristupa.

Ostvareni znanstveni doprinosi ovog doktorskog rada su sljedeći:

- Model za određivanje položaja i pokreta ljudskog tijela iz podataka dobivenih nosivim ultraširokopojasnim lokalizacijskim senzorima i inercijskim senzorima.
- Arhitektura sklopovske i programske izvedbe mjernog postava niske potrošnje za određivanje položaja i pokreta ljudskog tijela.
- Algoritam za određivanje položaja i prepoznavanje pokreta ljudskog tijela primjenom fuzije senzorskih podataka i metoda strojnog učenja.

1.4 Struktura rada

Rad je podijeljen u šest poglavlja u kojima su izloženi motivacija i ciljevi istraživanja, prikazan pregled stanja tehnologije, razrađen novi model određivanja položaja i pokreta ljudskog tijela, prikazana sklopovska i programska arhitektura predloženog rješenja, opisan algoritam analize mjernih rezultata i obrade mjerenje te prezentirani rezultati eksperimentalne evaluacije razvijenog algoritma.

U prvom, uvodnom poglavlju izloženi su kontekst i motivacija istraživanja, pri čemu su prezentirani najvažniji parametri modela ljudskog lokomotornog sustava i postojeće metode za praćenje pokreta i položaja ljudskog tijela. Uspoređene su prednosti i nedostaci postojećih pristupa te je obrazložena motivacija za korištenje ultraširokopojasne tehnologije u kombinaciji s inercijskim senzorima kako bi se dobile bolje karakteristike sustava u odnosi na postojeće metode.

U drugom poglavlju 2 detaljno su opisana načela rada sustava za ultraširokopojasnu (UWB) lokalizaciju i prikazan je pregled stanja tehnologije. Obrazložena su temeljna načela rada sustava za lokalno pozicioniranje, UWB komunikacije, modeli propagacije UWB signala, pristupi mjerenju udaljenosti temeljeni na mjerenju vremena propagacije UWB signala, propisi i standardi za UWB komunikaciju te je prikazan pregled stanja UWB tehnologije. Posebni naglasak je dan na tržišno dostupna tehnološka rješenja za sklopovsku implementaciju sustava za UWB lokalizaciju. Detaljno su izložena načela rada inercijskih (IMU) senzora (akcelerometra i žiroskopa), opisani su izvori pogrešaka kod inercijskih senzora i načini njihove kompenzacije, metode određivanja orijentacije pomoću inercijskih senzora, postupci kalibracije inercijskih senzora i osnovne metode senzorske fuzije podataka prikupljenih iz više izvora.

U trećem poglavlju 3 opisani su i analizirani postojeći biomehanički modeli za opisivanje pokreta i položaja ljudskog tijela te je predložen novi model mjerenja prilagođen za praćenje kuta i orijentacije među zglobovima, koji se temelji na senzorskoj fuziji UWB mjerenja udaljenosti i IMU senzora. Istaknuta je posebnost predloženog modela koji uključuje kompenzaciju nesigurnosti vremenske baze čime je omogućeno preciznije i pouzdanije mjerenje kuta među zglobovima u odnosu na postojeće metode.

U četvrtom poglavlju 4 opisana je sklopovska i programska arhitektura sustava za prikupljanje mjernih podataka izvedena u vidu nosivih bežičnih senzorskih čvorova prikladnih za postavljanje na ljudsko tijelo, a koji imaju mogućnost preciznog mjerenja udaljenosti primjenom UWB tehnologije i orijentacije korištenjem inercijskih senzora (akcelerometar i žiroskop). Opisano je vlastito razvijeno sklopovsko i programsko rješenje te protokol podatkovne komunikacije između čvorova. Razrađeni su i ispitani različiti parametri koji utječu točnost, preciznost i pouzdanost mjerenja.

U petom poglavlju 5 predlažen je algoritam obrade podataka dobivenih iz sustava nosivih

senzorskih čvorova, koji se temelji na fuziji senzorskih podataka prikupljenih UWB mjerenjem udaljenosti i IMU senzorima. Prikazani su postupak i rezultati eksperimentalne provjere točnosti mjerenja kuta u laboratorijskoj okolini u statičkim i dinamičkim uvjetima. Za realizaciju eksperimentalnog postava korišten je referentni mehanički postav temeljen na robotskoj ruci. U okviru eksperimentalog dijela rada prikupljeni su skupovi podataka za odabrane pokrete tijela na skupini ispitanika, a nad prikupljenim podacima ispitane su mogućnosti predloženog algoritma obrade podataka pri čemu je pokazano da je njime moguće izlučivanje značajki u svrhu kvalitetnijeg prepoznavanja pokreta primjenom metoda strojnog učenja.

U Zaključku je izložena rasprava o postignutim rezultatima te su analizirane potencijalne koristi od provedenog istraživanja, uz smjernice za moguća buduća poboljšanja i istraživanja.

Poglavlje 2

Pregled stanja tehnologije sustava za ultraširokopojasnu lokalizaciju i inercijska mjerenja

Tehnologije određivanja položaja objekata nalaze brojne primjene u raznim područja ljudske djelatnosti. Pod pojmom *određivanja položaja* ili *lokalizacije* podrazumijeva se određivanje pozicije objekta u odabranom referentnom koordinantom sustavu. U ovisnosti o primjeni, objekte je potrebno lokalizirati s određenom točnošću, preciznošću i mogućnošću dinamičkog praćenja pozicije, vodeći računa o uvjetima okoline (na otvorenom ili u zatvorenom prostoru), ovisnosti o infrastrukturi (bez posebne infrastrukture, uz korištenje postojeće ili izgradnju nove infrastrukture), energetskoj efikasnosti i potrošnji, sklopovskoj i programskoj složenosti, autonomiji rada, cijeni, masi, dimenzijama i mobilnosti sustava i sl. U ovom poglavlju pružit će se pregled osnovnih pojmova, metoda i tehnologija korištenih za određivanje položaja, kao i trenutno stanje znanstvenog istraživanja s fokusom na određivanje kuta zgloba. Također, u kontekstu ove doktorske disertacije istražena je mogućnost primjene IMU senzora u praćenju ljudske aktivnosti, pod čime se podrazumijeva praćenje položaja, orijentacije i kretanja ljudskog tijela kao cjeline ili njegovih pojedinih dijelova. Isto tako, posebni naglasak dan je na istraživanje primjene UWB tehnologije koja za razliku od uskopojasnih signala s ograničenim rasponom koristi znatno širi frekvencijski opseg što ju čini prikladnom za primjenu prilikom određivanja položaja. Izložene su prednosti kao i nedostatci pojedinih metoda i tehnologija s ciljem opravdanja daljnjih postupaka istraživanja tokom ove disertacije.

2.1 Metode određivanja udaljenosti i položaja

U današnje vrijeme izuzetno veliku važnost u brojnim praktičnim primjenama imaju globalni navigacijski sustavi koji omogućavaju određivanje točne pozicije objekta u globalnom koor-

dinatnom zemljopisnom sustavu. Postoji nekoliko globalnih navigacijskih satelitskih sustava (engl. *global navigation satellite system*, GNSS) koji omogućavaju točnu i preciznu lokalizaciju na otvorenom prostoru gdje je moguće primati signale sa satelita. Najpoznatija i najviše korištena satelitska konstelacija je američki sustav za globalno pozicioniranje (engl. *global positioning system*, GPS), a uz nju su dostupne i druge satelitske konstelcije koje imaju globalnu ili djelomičnu lokalnu pokrivenost (GLONASS, Beido, Galileo, QZSS, IRNSS itd.).

Veliki nedostatak globalnih navigacijskih satelitskih sustava jest da se ne mogu koristiti u zatvorenim prostorima odnosno u područjima gdje je slab prijem satelitskog signala, npr. uslijed djelovanja različitih prirodnih ili umjetnih prepreka koje utječu na propagaciju samog signala sa satelita. U takvim slučajevima potrebno koristiti drugačije pristupe za izvedbu lokalizacije. Uzimajući u obzir dostupnost GNSS signala, metode lokalizacije mogu se podijeliti u dvije kategorije: na metode za lokalizaciju na otvorenom prostoru (engl. *outdoor localization*), koje se tipično oslanjaju na GNSS tehnologije i na metode u zatvorenom prostoru (engl. *indoor localization*), gdje se koriste drugačiji pristupi, od kojih će neki najvažniji biti opisani u nastavku. Zadnji pristup se može koristiti i na otvorenom prostoru kao alternativa GNSS sustavima, a s obzirom da pokrivaju tipično geografski vrlo maleno lokalno područje nazivaju se još i *sustavi za lokalno pozicioniranje* (engl. *local positioning systems*, LPS). Kada se LPS sustavi koriste za praćenje objekata i njihovu lokalizaciju u stvarnom vremenu, za njih se često koristi i termin (engl. *real-time locating systems*, RTLS). U okviru ove disertacije razmatrati će se isključivo LPS sustavi. Neke od primjena LPS sustava su praćenje robe u skladištima, lokalizacija opreme i osoba u radnim prostorima, industriji ili bolnicama, praćenje lokacije vatrogasaca i pripadnika sličnih interventnih službi tijekom intervencija, praćenje dinamike i performansi sportaša, automatska navigacija robota u zatvorenim prostorima i sl. U kontekstu ove doktorske disertacije LPS sustavi biti će korišteni za praćenje i klasifikaciju ljudskog pokreta.

Određivanje položaja ili pozicije nekog objekta u prostoru usko je povezano s mjerenjem *udaljenosti*. Premda postoje metode koje mogu dati razmjerno točnu poziciju kod lokalizacije u zatvorenom prostoru bez mjerenja udaljenosti, većina lokalizacijskih postupaka temelji se na mjerenju parova udaljenosti; između promatranog objekta koji je pokretan odnosno mobilne stanice (engl. *mobile station*, MS) i fiksnih točaka na poznatim koordinatama odnosno baznih stanica (engl. *base station*, BS). Na temelju izmjerene udaljenosti izračunava se nepoznata pozicija promatranog objekta. U nastavku najveća pažnja će se posvetiti metodama mjerenja udaljenosti korištenjem raznih izvedbi LPS sustava. Kako bi se mogli lakše definirati modeli i algoritmi u nastavku disertacije, najprije će se razmotriti temeljne definicije najvažnijih ključnih pojmova vezanih uz sustave lokalnog pozicioniranja.

2.1.1 Osnovne definicije

U različitim primjenama sustava za lokalizaciju koriste se različite metode dolaska do informacije o poziciji promatranog objekta. U ovisnosti o specifičnoj primjeni sama pozicija objekta može se iskazivati na različite načine. Tako se sama lokacija može izraziti kao *fizička*, *simbolička*, *apsolutna* ili *relativna* [11]. *Fizička lokacija* podrazumijeva točku na zemljopisnoj mapi koja se izražava u nekom od uobičajenih koordinatnih zapisa kojima se opisuju geografske koordinate (npr. sustavi DMS (engl. *Degrees/Minutes/Seconds*), UTM (engl *Universal Transverse Mercator*) i sl.). Ako samo želimo saznati lokaciju objekta vezanu uz logički kontekst prikladan opisom, npr. u kojoj se prostoriji nalazi objekt (dnevna soba ili ured na trećem katu), može se koristiti takozvani *simbolički* način zapisivanja lokacije. Takav zapis je izravno u vezi s prirodnim jezikom kao načinom imenovanja simboličkih lokacija. *Apsolutna* lokacija podrazumijeva izražavanje pozicije u koordinatnom sustavu kojeg dijele svi objekti koji sudjeluju u postupku pozicioniranja, što znači da se za promatrano područje definira ishodište i orijentacija koordinatnog sustava (npr. u Kartezijevim koordinatama). Koordinate svih promatranih objekata se tada referiraju prema apsolutno definiranom zajedničkom ishodištu koordinatnog sustava. *Relativna* lokacija odnosi se na izražavanje položaja nekog objekta u odnosu na referentni, pri čemu svaki objekt u sustavu za pozicioniranje može biti referentan u smislu definicije ishodišta relativnog koordinatnog sustava, što se obično veže uz bazne stanice ili druge odabrane referentne točke promatranog područja [11].

Kako bi se ustanovilo je li neki sustav za lokalizaciju prikladan za određenu primjenu te da bi se mogle međusobno kvantitativno usporediti performanse različitih sustava za lokalizaciju, potrebno je definirati metrike za usporedbu najvažnijih značajki sustava za lokalizaciju. Parametri kojima se najčešće izražavaju performanse sustava za lokalizaciju su točnost, preciznost, područje pokrivanja, brzina osvježavanja, složenost, robusnost i cijena [11].

Točnost (engl. *accuracy*) lokalizacijskog sustava definirana se kao razlika između izmjerene i stvarne pozicije objekta. S obzirom da niti jedan mjerni sustav ne daje istu vrijednost nakon svakog provedenog mjerenja, zbog utjecaja mjerne nesigurnosti, potrebno je pojam točnosti promatrati u statističkim okvirima. Tako se za definiciju odstupanja izmjerene od stvarne pozicije objekta tipično koristi srednja Euklidska udaljenost. Točnost sustava može se promatrati kao očekivano statističko odstupanje izmjerene pozicije od stvarne.

Preciznost (engl. *precision*) je veličina koja nam govori o tome koliko se pojedina mjerenja lokacije statistički rasipaju oko srednje vrijednosti mjerenja. Preciznost se veže uz statističku raspodjelu rezultata mjerenja i obično se promatra kumulativna raspodjela vjerojatnosti (engl. *cumulative distribution function*, CDF) gdje se određuju percentili unutar kojih se s određenom vjerojatnošću očekuju rezultati mjerenja. Preciznost mjerenja je to veća što se rezul-

tati manje rasipaju, a u slučaju normalne raspodjele standardna devijacija je najčešće korištena mjera rasipanja mjernih rezultata [12].

Područje pokrivanja (engl. *coverage*) se usko veže uz pojam točnosti i preciznosti sustava i predstavlja površinu (m^2) ili volumen u (m^3) kojeg sustav obuhvaća, u ovisnosti radi li se lokalizacija u dvije ili tri dimenzije. Podrazumijeva se da u tom volumenu ili na toj površini sustav obavlja svoju zadaću u granicama specificirane točnosti i preciznosti. Područje pokrivanja također je povezano i s dometom u slučaju kada se koriste signali za određivanje udaljenosti među točkama.

Brzina osvježavanja lokacije (engl. *refresh rate*) predstavlja učestalost kojom se određuje lokacija promatranog objekta LPS sustavom.

Složenost (engl. *complexity*) sustava odnosi se na složenost sklopovske i programske implementacije, ali i na složenost samog korištenja sustava. Sustavi s većom složenošću tipično imaju negativan utjecaj na druge parametre (potrošnja energije, dimenzije, cijena i sl.), a posebno je kod mobilnih sustava pozicioniranja važno kolika je algoritamska složenost postupaka za određivanje lokacije, jer to u velikoj mjeri utječe i na arhitekturu realizacije stvarnog sustava. Primjerice, ako je potrebno izvoditi složene algoritme, oni se tipično ne mogu izvoditi na mobilnim senzorskim čvorovima niske složenosti i potrošnje, već ih je potrebno izvoditi na centraliziranom računalu. Ta činjenica uvelike utječe na arhitekturu implementacije rješenja.

Robusnost (engl. *robustness*) na kvalitativan način opisuje koliko je sustav otporan na razne nepovoljne utjecaje, poput opstrukcije signala, interferencije s raznim izvorima smetnji, djelomičnog ili povremenog gubitka signala i sl.

Cijena sustava uključuje brojne faktore, koji su povezani s troškom proizvodnje sklopovlja, prostornim zauzećem i masom uređaja, potrošnjom energije, troškovima instalacije, održavanja, edukacije za korištenje sustava i sl. Svi navedeni faktori važni su u procjeni optimalnog rješenja LPS sustava za određenu primjenu.

Vrijeme autonomije je važno napomenuti od dodatnih tehničkih zahtjeva bitnih u praktičnoj implementaciji. Ono nam govori o tome koliko je dugo uređaj sposoban raditi na baterijskom napajanju bez nadopune energije. Ovo se tipično odnosi na MS koji uobičajeno napajaju iz baterijskim izvora napajanja. Što je veća složenost metode određivanja lokacije i samog sklopovlja, to je sumjerljivo veća i potrošnja uređaja poradi veće složenosti obrade podataka. Osim same cijene uređaja, na komercijalnu upotrebu utječe i mogućnost proširivosti sustava, odnosno koliko je jednostavno dodati novog korisnika ili proširiti područje pokrivenosti. Faktor kojega

se također ne smije zanemariti je sigurnost, odnosno privatnost položaja i drugih informacija koje se razmjenjuju u sustavu za lokalizaciju.

Kako je ranije spomenuto, tipični LPS sustav sastoji se od skupa više BS raspoređenih na fiksnim poznatim pozicijama i jedne ili više MS koje se kreću u području pokrivanja LPS sustava. Nepoznata lokacija MS određuje se temeljem mjerenja odabranih parametara MS u odnosu na skup BS na poznatim lokacijama (udaljenosti, kutevi, blizina i sl.). Sam postupak određivanja lokacije temelji se na razmjeni signala koje između sebe šalju MS i BS pa se LPS sustavi s obzirom na funkcionalnost i način međusobne komunikacije između skupova MS i BS mogu podijeliti u tri osnovne kategorije:

- BS šalju signale koje MS osluškuju i na temelju primljenih signala MS izračunavaju svoju poziciju,
- MS šalju signale koje BS osluškuju i izračun pozicija MS obavlja se na BS ili na centraliziranom računalu povezanom s BS,
- BS i MS nemaju unaprijed predefinirane uloge i mogu po potrebi slati i primati signale za pozicioniranje te izračunavati po potrebi poziciju bilo na MS ili na BS.

Prva kategorija LPS sustava podrazumijeva skup BS koje periodički šalju signale koji su svojstveni svakoj pojedinoj BS. MS na temelju primljenih podataka može uz pomoć specifičnih algoritama odrediti svoju vlastitu lokaciju. Naravno, uz pretpostavku da su lokacije BS poznate i nepromijenjene u vremenu trajanja mjerenja. Ovakav sustav inherentno je siguran budući da niti u jednom trenutku MS ne šalje svoje podatke, već *ad-hoc* izračunava svoju lokaciju na temelju podataka primljenih od BS. Područje pokrivanja u ovom slučaju ovisi o položaju BS, a točnost o njihovom broju na jedinici površine. Jedan od važnih nedostataka ovakvog pristupa proizlazi iz činjenice da BS moraju biti postavljenje na točno određene lokacije, što samu instalaciju čini složenom jer zahtijeva prvotno nezavisno mjerenje i razmatranja na koji način optimalno rasporediti BS s gledišta dobre pokrivenosti. Izračunavanje pozicije na MS postavlja veće zahtjeve na složenost sklopovlja i programske potpore MS, a time nepovoljno utječe na parametre potrošnje, autonomije rada, cijene, mobilnosti i dimenzija uređaja vezanih uz MS.

Kako bi se uštedjelo na složenosti i potrošnji MS, a time povoljno utjecalo i na druge parametre LPS rješenja, može se koristiti drugi pristup u kojem MS imaju minimalnu složenost implementacije jer u tom scenariju MS samo šalju informacije važne za njihovo pozicioniranje prema BS, pri čemu se posao izračunavanja lokacije uređaja prepušta centraliziranom računalu. U ovakvoj shemi mogu se postići drastična poboljšanja na MS u smislu veće autonomije rada, niže cijene i bolje mobilnosti, dok BS i centralizirano računalo koja su na stalnom napajanju neće bitnije nepovoljno utjecati na cijenu cjelokupnog rješenja. U ovoj kategoriji LPS rješenja MS u predefiniranim vremenskim intervalima izlazi iz stanja niske potrošnje i šalje signal kojeg primaju okolni BS i na temelju tog signala izračunavaju lokaciju MS. Jedan od važnih

nedostataka ovakve izvedbe sustava je inherentna nesigurnost jer u bilo kojem trenutku postoji mogućnost osluškivanja signala koje šalje MS. Nadalje, izvedba sustava dodatno je otežana zbog mogućnosti interferencije dvaju ili više izvora signala, poglavito u situacijama kada se na istom području pokrivanja nalazi veći broj MS koje šalju svoje signale. Dok je kod prve arhitekture MS trebao samo slušati, u ovom slučaju mora i aktivno pratiti korištenje komunikacijskog kanala kako bi se izbjegle kolizije prilikom slanja podataka. Zato je kod korištenja ovakvog sustava potrebno koristiti ili točno definirani protokol slanja signala ili neke od metoda dijeljenja vremenskog, odnosno frekvencijskog raspona.

Treća kategorija podrazumijeva kooperativne MS i BS čvorove koji međusobno komuniciraju korištenjem jednog ili više kanala i gdje uloge BS ili MS nisu fiksno predefinirane. Premda ovakva konfiguracija načelno pruža najveću fleksibilnost, cijena i složenost ovakvih rješenja raste u odnosu na ranije izložene arhitekture, ali u određenim primjenama donosi potencijal da se učinkovito riješe neki od nedostataka prethodno izloženih arhitektura.

Nadalje, postoje četiri osnovna načela kako se kod LPS sustava može određivati nepoznata pozicija MS:

- triangulacija (engl. *triangulation*) - položaj MS određuje se triangulacijom izmjerenih udaljenosti ili kuteva između MS i skupa BS,
- analiza prostora (engl. *space analysis*) - položaj MS određuje se analizom lokalnih značajki područja pokrivanja LPS sustava pri čemu se lokacija MS određuje na temelju ranije naučenih lokalnih obrazaca u području pokrivanja,
- određivanje lokacije neposrednom blizinom (engl. *proximity detection*) - položaj MS određuje se temeljem detekcije blizine u odnosu na čvorove mreže unaprijed postavljenih senzora u području pokrivanja LPS sustava,
- vizualna lokalizacija (engl. *visual localization*) - lokalizacija korištenjem računalnog vida.

U nastavku će biti ukratko opisano svako od tih načela, s time da će se najveća pažnja posvetiti metodi triangulacije temeljenoj na mjerenju udaljenosti s obzirom da se s njome u praksi mogu postići najbolji rezultati i najveća točnost mjerenja pozicije putem LPS sustava.

2.1.2 Metode određivanja položaja mjerenjem udaljenosti

Položaj objekta može se odrediti mjerenjem njegove udaljenosti od referentnih točaka koje se nalaze na poznatim koordinatama. Mjerenje udaljenosti provodi se slanjem signala između točaka u sustavu za lokalizaciju i mjerenjem parametara na temelju kojih se određuju udaljenosti između parova točaka. Postoji više mogućnosti mjerenja parametara na temelju kojih se mogu odrediti udaljenosti između točaka:

- mjerenje vremena dolaska (engl. *time of arrival*, TOA)
- mjerenje razlike vremena dolaska (engl. *time difference of arrival*, TDOA)
- mjerenje vremena slanja povratne poruke (engl. *roundtrip time of flight*, RTOF)

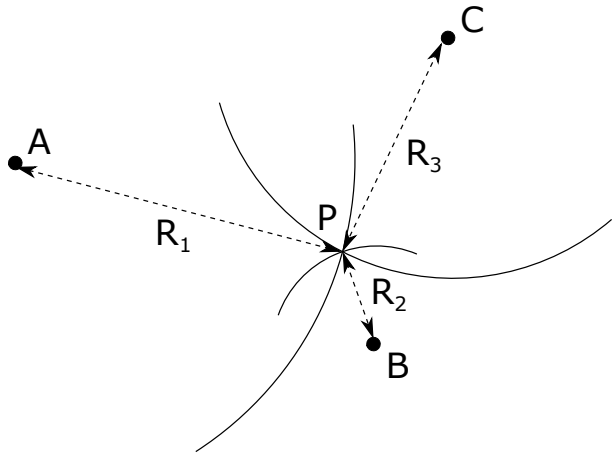

Slika 2.1: Pozicioniranje temeljeno na TOA i RTOF metodama

- mjerenje snage primljenog signala (engl. *received signal strength*, RSS)

Triangulacija koristi geometrijska svojstva trokuta kako bi se iz skupa izmjerenih udaljenosti odredila lokacija. Ako se lokalizacija radi u dvije dimenzije, onda je potrebno provesti mjerenje položaja nepoznatog objekta u odnosu na minimalno tri referentne točke u ravnini. Na taj način dobiva se jednoznačno rješenje kao što je prikazano na slici 2.1. Za jednoznačno rješenje u tri dimenzije potrebne su minimalno četiri referentne točke u prostoru. Ako se u LPS sustavu koristi više od minimalnog broja referentnih točaka, tada će zbog utjecaja mjerne nesigurnosti svaki podskup referentnih točaka triangulacijom dati rješenje koje se malo razlikuje od stvarne vrijednosti. Drugim riječima, dobiti će se onoliko različitih bliskih numeričkih vrijednosti koliko ima minimalnih podskupova referentnih točaka za triangulaciju u odabranoj dimenzionalnosti rješenja problema lokalizacije. U tom slučaju ne traži se egzaktno rješenje sustava linearnih jednaždbi, već rješenje koje minimizira odabranu normu pogreške, tipično najmanje kvadratno odstupanje (engl. *least square solution*, LSS). U tom slučaju odgovarajući sustav jednadžbi za lokalizaciju je predeterminiran, a koristi se pojam *multilateracije* da se naglasi da je broj referentnih točaka već od minimalno potrebnog za triangulaciju.

Važno je istaknuti da je kod mjerenja udaljenosti bitno poznavati model propagacije signala za lokalizaciju (npr. elektromagnetskog ili akustičnog vala) na kojeg mogu utjecati razni efekti, poput višestaznog rasprostiranja (engl. *multipath effects*), uvjeta vidljivosti (engl. *line of sight*, LOS), interferencije s drugim signalima i sl.

Određivanje udaljenosti mjerenjem vremena dolaska (TOA)

TOA metoda temelji se na mjerenju vremena propagacije signala kojeg šalje MS prema BS ili obrnuto. Ako je poznato vrijeme slanja i dolaska signala kao i brzina širenja signala kroz prijenosni medij, do udaljenosti može se doći jednostavnim množenjem vremena putovanja signala (engl. *time of flight*, TOF) i brzine širenja signala. Na slici 2.1 prikazano je načelo lokalizacije TOA metodom. MS smještena u točki *P* šalje signale prema skupu BS smještenih

u točkama A,B,C, pri čemu udaljenosti R_1, R_2 i R_3 predstavljaju TOF između parova točaka (P,A), (P,B) i (P,C). Nepoznata lokacija P u kojoj se nalazi MS traži se kao rješenje problema i predstavlja sjecište triju kružnica radijusa R_1, R_2 i R_3. Njihova središta A, B i C su od prije poznate lokacije, koje predstavljaju sva tri BS (primjer pretpostavlja lokalizaciju u 2D prostoru).

Metoda vremena dolaska signala TOA ima dva važna nedostatka. Prva je činjenica da svi uređaji uključeni u lokalizaciju (MS i BS) moraju imati vrlo točno sinkronizirane interne satove, a druga je da signal kojeg šalje MS mora ili sadržavati zapis kada je signal točno poslan ili koristiti sekundarni kanal za signaliziranje vremena slanja. Uvjet sinkronizacije je u praksi zahtjevno za izvesti, pogotovo na jednostavnijim i jeftinijim MS s ograničenim resursima.

Pretpostavimo da MS smještena u točki P šalje signal s vremenskom oznakom slanja koji se referira na lokalno vrijeme MS. Pretpostavimo da dvije BS (A i B) prime signal (poruku) u vremenskim trenucima t_A i t_B, a u poruci s nalazi vrijeme t_P koje predstavlja trenutak slanja poruke s MS. Ako su interni satovi MS i BS sinkronizirani, tada se mogu odrediti udaljenosti $d(P,A)$ i $d(P,B)$ na jednostavan način:

$$d(P,A) = R_1 = c(t_A - t_P)$$

$$d(P,B) = R_2 = c(t_B - t_P),$$

gdje je c brzina rasprostiranja signala u prijenosnom mediju.

Ako MS nije sinkronizirana s BS i postoji između internih satova u MS i BS vremenski pomak (engl. *offset*) iznosa Δt, tada pomak izravno unosi pogrešku u mjerenje udaljenosti:

$$d(P,A) = R_1' = c(t_A - (t_P + \Delta t))$$

$$d(P,B) = R_2' = c(t_B - (t_P + \Delta t)),$$

pri čemu pogreška već uslijed malene vremenske razlike Δt može postati velika ako je brzina propagacije c velika, što je slučaj kada se koriste elektromagnetski valovi. U praksi je potreba za vrlo točnom sinkronizacijom internih satova na MS sa skupom BS glavni ograničavajući faktor primjene te metode za točnu i preciznu lokalizaciju.

Određivanje udaljenosti mjerenjem razlike vremena dolaska (TDOA)

U cilju uklanjanja potrebe za sinkronizacijom internih satova između MS i BS razvijena je metoda određivanja udaljenosti temeljena na mjerenju razlike vremena dolaska signala TDOA). Metoda ne zahtijeva sinkronizaciju internih satova svih MS i BS u LPS sustavu, već samo međusobnu sinkronizaciju satova svih BS. S gledišta praktične implementacije to je značajno

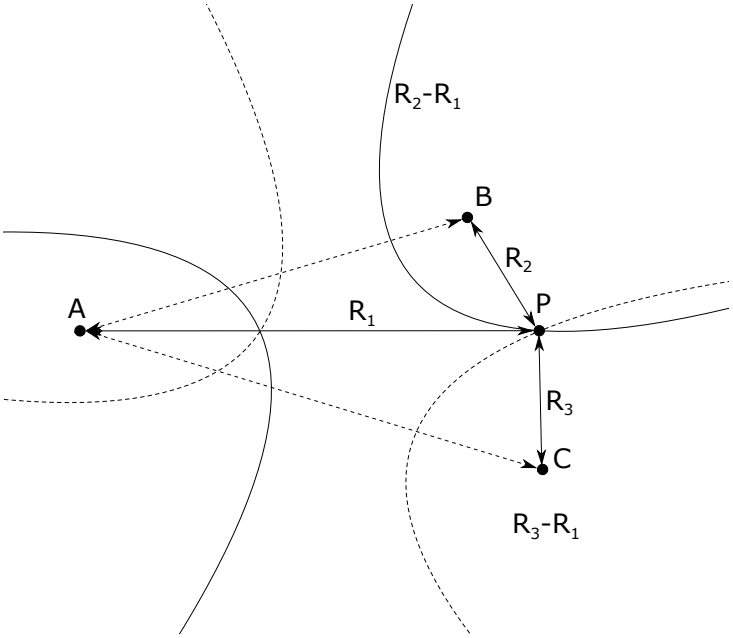

Slika 2.2: Pozicioniranje temeljeno na TDOA metodi

manje zahtjevan izazov u odnosu na zahtjeve za TOA metodu.

Slično kao i kod TOA pristupa, MS šalje signal prema svim BS i u poruci se nalazi vrijeme slanja t_P, koje se referira prema lokalnom satu promatrane MS. Ako se sa Δt označi vremenska razlika između lokalnog vremena MS i vremena na kojega su sinkronizirane sve BS, vrijede sljedeće jednadžbe:

$$d(P,A) = c(t_A - (t_p + \Delta t)) = ct_A - c(t_p + \Delta t)$$

$$d(P,B) = c(t_B - (t_p + \Delta t)) = ct_B - c(t_p + \Delta t),$$

gdje su $d(P,A)$ i $d(P,B)$ stvarne udaljenosti između MS i BS smještenih u A i B, a Δt je nepoznati korekcijski faktor kojeg je potrebno pribrojiti vremenu slanja MS kako bi se lokalno vrijeme MS ispravilo prema vremenski sinkroniziranom skupu BS. Oduzimanjem prethodne dvije jednadžbe dobiva se izraz:

$$d(P,A) - d(P,B) = c(t_A - t_B) = c\tau_{AB}, \tag{2.1}$$

gdje τ_{AB} predstavlja *vremensku razliku* dolaska signala s MS na BS u A i B.

Ako je MS smještena u točki $P(x,y,z)$ i ako su BS smještene u $A(x_1,y_1,z_1)$ i $B(x_2,y_2,z_2)$, jednadžba 2.1 može se zapisati kao:

$$R_{AB} = c\tau_{AB} = \sqrt{(x_1-x)^2 + (y_1-x)^2 + (z_1-x)^2} - \sqrt{(x_2-x)^2 + (y_2-x)^2 + (z_2-x)^2}. \tag{2.2}$$

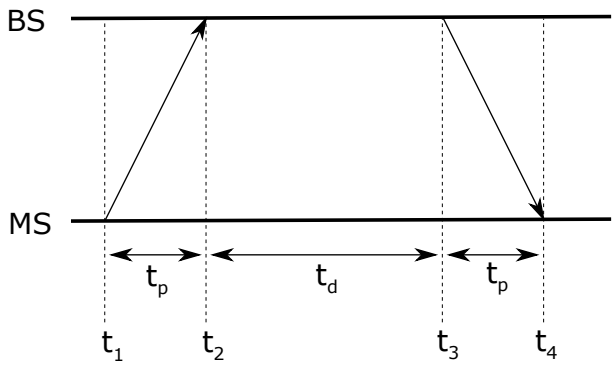

Slika 2.3: Vremenski tijek komunikacije kod RTOF mjerenja (satovi na MS i BS su sinkronizirani)

Relacija 2.2 opisuje hiperboloid na kojem leže sva rješenja za nepoznatu lokaciju $P(x,y,z)$ za koju je izmjerena vremenska razlika dolaska τ_{AB}. Međutim, da bi se dobila lokacija, slično kao i kod TOA metode potrebne su minimalno tri BS za rješavanje dvodimenzijskog problema lokalizacije, odnosno četiri BS za tro-dimenzijski. Jednaždba 2.2 može se zapisati općenitije za sustav od N baznih stanica:

$$R_{ij} = c\tau_{AB} = \sqrt{(x_i-x)^2+(y_i-x)^2+(z_i-x)^2} - \sqrt{(x_j-x)^2+(y_j-x)^2+(z_j-x)^2}, \quad (2.3)$$

gdje (x_i,y_i,z_i) i (x_j,y_j,z_j) predstavljaju par BS za koje se promatra TDOA. Rješavanjem sustava jednadžbi ili nekim od postupaka traženja točke koja minimizira normu pogreške [11] može se doći do nepoznate pozicije MS u (x,y,z). Velika prednost TDOA metode u odnosu na TOA je u tome što nije potrebno sinkronozirati MS prema BS (tj. nije potrebno poznavati Δt), ali dodatno čak nije potrebno niti slati točnu vremenski oznaku t_p s MS, što TDOA metodu čini značajno povoljnijom za praktičnu realizaciju. Načelo traženja rješenja jednadžbe 2.3 prikazano je na slici 2.2.

TDOA metoda pretpostavlja sinkroniziranost satova svih BS i unaprijed poznate pozicije svih BS. U 2D slučaju dovoljna su tri BS čvora i dva TDOA mjerenja za lokalizaciju, a u 3D slučaju četiri BS čvora i tri TDOA mjerenja. U tipičnoj implementaciji prvi BS koji primi signal proglašava se referentnim, a ostale BS mjere vrijeme dolaska signala s obzirom na referentni čvor. Vremenska sinkronizacija MS više nije potrebna, niti slanje vremenskog trenutka u lokalnom vremenu MS. Jedino je potrebno ugraditi u poruku koju šalje svaki MS (u slučaju sustava s više MS) simbolički identifikator MS jer svaki od njih ima drugu vrijednost vremenskog pomaka Δt. Ti pomaci BS moraju se uzeti u obzir prilikom diferenciranja poruka primljenih od svakog MS čvora.

Određivanje udaljenosti mjerenjem vremena slanja povratne poruke (RTOF)

Kako bi se u potpunosti uklonila potreba za međusobnom vremenskom sinkronizacijom između MS i BS može se koristiti metoda mjerenja vremena slanja povratne poruke RTOF). Načelo

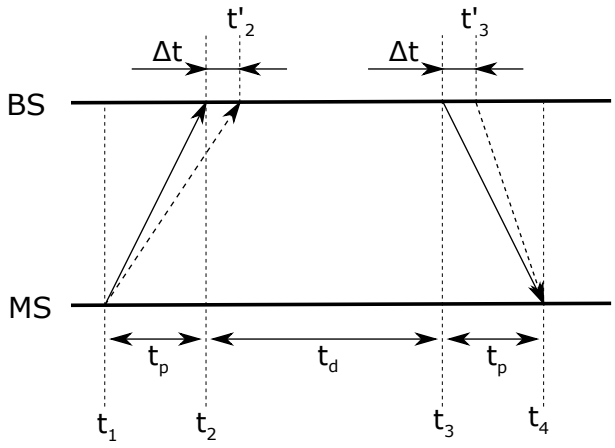

Slika 2.4: Vremenski tijek komunikacije kod RTOF mjerenja (satovi na MS i BS nisu sinkronizirani)

mjerenja udaljenosti kod RTOF metode slično je kao kod TOA pristupa, ali se mjerenje vremena u ovom slučaju odvija u oba smjera.

Na slici 2.3 prikazana je RTOF komunikacija u idealnom slučaju kada su satovi na MS i BS sinkronizirani. Protokol RTOF komunikacije je sljedeći: MS u trenutku t_1 šalje poruku koju BS prima u trenutku t_2. Vrijeme propagacije signala t_p proporcionano je udaljenosti d između MS i BS te brzini propagacije signala c. BS nakon vremena t_d šalje natrag poruku prema MS u trenutku t_3, koju MS prima u trenutku t_4. Uz pretpostavku da su MS i BS za vrijeme razmjene poruka nepomične, udaljenost d između njih može se izračunati na temelju formule:

$$d = \frac{(t_4 - t_1) - (t_3 - t_2)}{2} \cdot c = \frac{2t_p}{2} \cdot c = t_p \cdot c \tag{2.4}$$

Ako MS i BS nemaju satove sinkronizirane međusobno, niti prema stvarnom ili apsolutnom vremenu, tada postoji razlika u mjerenju vremena na MS i BS u odnosu na stvarno vrijeme:

$$t_{MS} = t + \Delta t_{MS}$$

$$t_{BS} = t + \Delta t_{BS}$$

gdje je t_{MS} vrijeme izmjereno na MS i t_{BS} vrijeme izmjereno na BS u trenutku t, a Δt_{MS} i Δt_{BS} su vremenski pomaci satova na MS i BS u odnosu na stvarno vrijeme.

Bez gubitka općenitosti, ako se pretpostavi da je jedan od čvorova za lokalizaciju (npr. MS) sinkroniziran sa stvarnim vremenom, tada se vrijeme koje mjeri nesinkronizirana BS može prikazati preko fiksnog pomaka Δt:

$$t_{MS} = t$$

$$t_{BS} = t + \Delta t$$

Ako se ranije opisani RTOF algoritam primijeni na slučaj kada MS i BS nisu sinkronizirani,

mjeriti će se vremena kako je opisano na slici 2.4. MS u trenutku t_1 šalje poruku, koja nakon vremena t_p stiže na BS u trenutku t_2, ali BS mjeri drugačiju vrijednost vremena $t_2' = t_2 + \Delta t$. Nakon vremena t_d BS šalje poruku u trenutku t_3, ali BS bilježi da je poslao poruku u drugom trenutku prema svojem internom satu $t_3' = t_3 + \Delta t$. Nakon vremena t_p poruka stiže natrag do MS u trenutku t_4. Premda su vremena u kojima je BS primio i poslao poruku na slici 2.4 ista kao i u slučaju prikazanom na slici 2.3, zbog nesinkroniziranog vremena između MS i BS, na BS se mjere pogrešne vrijednosti koje se od vremena na MS razlikuju za konstantu koja predstavlja pomak između satova na MS i BS. U formulu 2.4 potrebno je uvrstiti vremena mjerena satom na BS:

$$\begin{aligned} d &= \frac{(t_4 - t_1) - (t_3' - t_2')}{2} \cdot c = \frac{(t_4 - t_1) - ((t_3 + \Delta t) - (t_2 + \Delta t))}{2} \cdot c = \\ &= \frac{(t_4 - t_1) - (t_3 - t_2)}{2} \cdot c = t_p \cdot c. \end{aligned} \tag{2.5}$$

Iz izraza 2.5 može se zaključiti da za RTOF metodu nije potrebno da satovi na MS i BS budu međusobno sinkronizirani (niti prema stvarnom vremenu) jer se pomaci između satova u 2.5 poništavaju. Također nije potrebno niti poznavati vrijeme t_d na BS između prijema i povratnog slanja poruke. Za razliku od TDOA metode koja zahtijeva sinkronizaciju satova na BS, kod RTOF pristupa nije potrebna nikakva vremenska sinkronizacija.

Ipak, zaključci koji slijede iz jednadžbe 2.5 vrijede uz određene pretpostavke. Pretpostavlja se da je za vrijeme razmjene poruka vremenski pomak Δt među satovima na MS i BS konstantan i da oba sata točno mjere vremenske intervale, tj. da ne postoji nestabilnost ili razlika u frekvenciji same vremenske baze (engl. *clock skew*). Nadalje, mjerenje točnih vremena t_1, t_2', t_3' i t_4 može biti izazovno u ovisnosti o karakteristikama signala korištenog za lokalizaciju i potrebnoj vremenskoj razlučivosti određivanja točnog vremena slanja i prijema. Primjerice, znatno je lakše odrediti navedena vremena ako se za lokalizaciju koriste akustički signali u odnosu na primjene kada se koriste elektromagnetski valovi s puno bržom brzinom propagacije. U procjenu navedenih vremena kod slanja elektromagnetskog vala potrebno je uzeti u obzir i vrijeme propagacije signala kroz signalne vodove, elektroničke sklopove i antenu zbog čega je kod LPS sustava koji rade na malenim udaljenostima obavezno provesti kalibraciju utjecaja navedenih efekata propagacije prije nego signal izađe s odašiljačke antene i dođe s prijemne do sklopovlja za detekciju.

Određivanje udaljenosti mjerenjem snage primljenog signala (RSS)

Ranije opisane metode mjerenja udaljenosti temeljile su se na vremenu mjerenja propagacije, kod kojega najveći izazov predstavlja mjerenje vremena same propagacije signala, što je posebno zahtjevno u slučajevima kada se koriste elektromagnetski valovi. Dodatni problemi kod mjerenja vremena propagacije pojavljuju se u okruženjima gdje postoji izražen utjecaj višes-

taznog rasprostiranja signala pa se može dogoditi da se npr. prilikom opstrukcije puta signala (engl. *non-line of sight*, NLOS) umjesto izravne zrake primi reflektirana, što će izravno uzrokovati pogrešku određivanja udaljenosti.

Probleme s potrebom za visokom razlučivošću mjerenja vremenskih intervala, sinkronizacijom satova i višestaznim rasprostiranjem signala moguće je do određene mjere izbjeći korištenjem drugačijeg pristupa za mjerenje udaljenosti između MS i BS i to mjerenjem snage primljenog signala RSS. RSS pristup temelji se na činjenici da se snaga primljenog signala smanjuje s udaljenošću između odašiljača i prijemnika, što se može analitički iskazati odgovarajućim fizikalnim matematičkim modelima propagacije signala. U slučaju radiofrekvencijskog signala može se koristiti jednostavni model predviđanja gubitaka na putu signala (engl. *path-loss propagation model*) koji opisuje snagu signala koju će mjeriti prijemnik smješten na određenoj udaljenosti:

$$\overline{P}(d) = P_0 - 10n\log_{10}(d/d_0), \tag{2.6}$$

gdje je $\overline{P}(d)$ srednja snaga (u dB) mjerena na udaljenosti d prijemnika od odašiljača, P_0 snaga signala mjerena na referentnoj udaljenosti d_0, a n empirijski koeficijent koji opisuje model gubitaka signala u okruženju u kojem se određuje udaljenost (varira od približno 2 za otvoreni prostor do 4 za zatvorene prostore s preprekama). Udaljenost izmjerena pomoću RSS metode može se koristiti na isti način za lokalizaciju u prostoru metodom triangulacije kako je opisano kod pristupa lokalizacije mjerenjem udaljenosti.

Problem kod određivanja udaljenosti RSS metodom je da procjena dana formulom 2.6 u velikoj mjeri ovisi o empirijskom parametru n koji samo približno opisuje stvarne uvjete, a u stvarnim okružjima zbog prepreka i višestaznog širenja signala taj parametar nije prostorno uniforman. Nadalje, čak i u slučaju kada se n ne mijenja bitnije u promatranom prostoru, snaga koju mjeri prijemnik nije konstantna, kako zbog ranije navedenih efekata, tako i zbog karakteristika samih elektroničkih sklopova koji izvode samo mjerenje. U praksi se snaga primljenog signala može modelirati Gaussovom slučajnom varijablom sa srednjom vrijednošću $\overline{P}(d)$ i varijancom σ_{sh}^2 [13]:

$$10\log_{10}P(d) \sim \mathcal{N}\left(\overline{P}(d), \sigma_{sh}^2\right). \tag{2.7}$$

Može se pokazati da je varijanca nepristranog estimatora $\hat{d}$ udaljenosti d, temeljenog na RSS metodi čija su statistička svojstva opisana formulom 2.7, definirana Cramer-Rao donjom granicom (CRLB) prema izrazu:

$$\sqrt{\mathrm{Var}\left\{\hat{d}\right\}} \geq \frac{\ln 10}{10}\frac{\sigma sh}{n}d. \tag{2.8}$$

Formula 2.8 opisuje koliko je teorijski ostvariva preciznost mjerenja udaljenosti na temelju RSS metode, a s obzirom da je izraz za minimalnu moguću varijancu estimatora $\hat{d}$ proporcionalan s udaljenošću može se zaključiti da će s povećanjem udaljenosti između odašiljača i prijemnika pogreška značajno rasti, što nije slučaj s metodama temeljenima na mjerenju vremena. U prak-

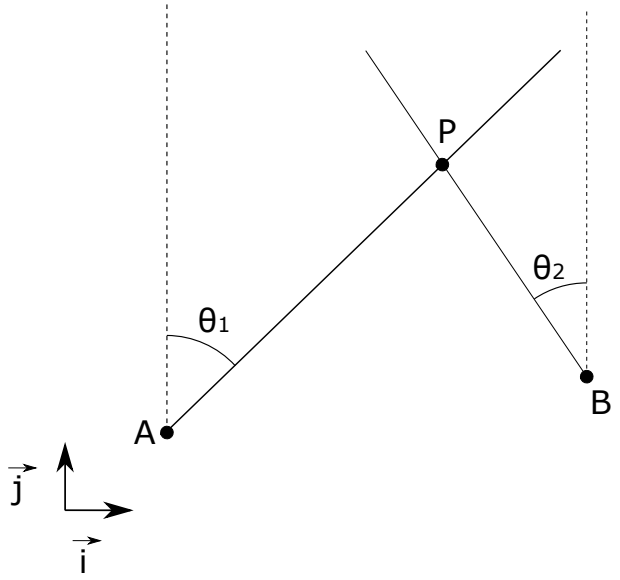

Slika 2.5: Pozicioniranje temeljeno na (engl. *angle of arrival*, AOA) metodi

tičnim aplikacijama pokazuje se da se čak i kod idealnih uvjeta RSS metodom može ostvariti bitno manja točnost i preciznost mjerenja u odnosu na metode koje se zasnivaju na mjerenju vremena, što je još izraženije u prostorima veće nehomogenosti, prepreka i refleksija signala kada jednostavni model 2.6 nije primjenjiv ili mu je teško odrediti odgovarajući parametar n.

2.1.3 Metode određivanja položaja mjerenjem kuta dolaska signala

Kod određivanja nepoznate lokacije MS metodom triangulacije može se osim metoda temeljenih na mjerenju udaljenosti koristiti i pristup temeljen na mjerenju kuta dolaska signala AOA. Načelo određivanja pozicije AOA metodom u dvije dimenzije prikazano je na slici 2.5. Za određivanje lokacije P na kojoj se nalazi MS potrebno je najprije poznavati točne lokacije BS smještenih u točkama A i B. Koordinate P određuju se iz presjecišta pravaca iz kojih signal dolazi od MS do pojedine BS, određenih vektorima u ravnini $\overrightarrow{PA}$ i $\overrightarrow{PB}$. Uz pretpostavku da je za referentni pravac dolaska signala odabran jedinični vektor $\overrightarrow{j}$, tada je potrebno odrediti kuteve θ_1 i θ_2 koje vektori $\overrightarrow{PA}$ i $\overrightarrow{PB}$ zatvaraju s referentnim nultim kutem dolaska signala koji leži na $\overrightarrow{j}$. Za pozicioniranje AOA metodom u tri dimenzije potrebne su svega tri BS, za razliku od pristupa triangulacije mjerenjem udaljenosti kod kojih je potrebna jedna bazna stanica više. Jedna od prednosti AOA metode je također da u odnosu na ranije prikazane metode temeljene na mjerenju udaljenosti nije potrebna nikakva sinkronizacija satova na MS i BS.

Međutim, glavni nedostatak AOA metode je da je potrebno puno složenije sklopovlje za mjerenje kuta dolaska signala, a sama preciznost pozicioniranja počinje se značajno degradirati s povećanjem udaljenosti jer se malene pogreške u mjerenju kuta na BS preslikavaju u velike pogreške u mjerenju pozicije MS kako d između MS i BS raste. Za određivanje kuta dolaska potrebni su usmjereni senzori ili niz antena, u slučaju da se koriste radijski valovi za slanje

signala za pozicioniranje.

2.1.4 Analiza prostora

U određenim primjenama i okruženjima može se primijeniti pristup lokalizaciji temeljen na analizi lokalnih značajki prostora u kojem se obavlja pozicioniranje. Postupak analize prostora (engl. *scene analysis*) temelji se na dva koraka: u prvom se snima raspodjela značajki u području prekrivanja LPS sustava, a drugom se obavlja lokalizacija objekta temeljem povezivanja trenutno mjerenih značajki s ranije izgrađenom mapom. Ova metoda u pravilu se veže uz korištenje radiofrekvencijskih (RF) signala, a najčešće se koristi RSS analiza, tj. promatranje primljene snage signala po pojedinim područjima pokrivanja LPS sustava. Prilikom izgradnje mape značajki, bilježi se primljena snaga signala na skupu unaprijed odabranih koordinata za mjerenje, a na temelju prikupljenih podataka gradi se model za predviđanje raspodjele snage primljenog signala u nekom prostoru. MS na temelju primljenog signala i usporedbe s ranije izgrađenom mapom i modelom nastoji odrediti svoju točnu lokaciju tijekom postupka pozicioniranja.

Metoda je primjenjiva u slučajevima kada postoji odgovarajuća infrastruktura i uvjeti pod kojima se može napraviti dovoljno dobra diskriminacija prostornih značajki mjerenog signala tako da se može odrediti lokacija (npr. ako bi u nekom području mjereni parametar imao uniformnu ili nepredvidljivu raspodjelu, tada se ova metoda ne bi mogla koristiti za pozicioniranje). Jedan od glavnih izazova kod korištenja metode analize prostora je da na primljeni signal prilikom lokalizacije mogu utjecati različiti faktori koji ometaju točnost lokalizacije. Primjerice, kao što su difrakcija, refleksija ili raspršenje signala u zatvorenim prostorima u kojima se obavlja lokalizacija, ali i utjecaj drugih izvora RF signala koji nisu bili prisutni prilikom mapiranja, što može umanjiti i pouzdanost same metode. Kod određivanja lokacije koriste se tipično algoritmi iz područja prepoznavanja uzoraka (engl. *pattern recognition*), u što spadaju probabilistički modeli, neuronske mreže, *k*NN (engl. *k-nearest neighbour*), metoda potpornih vektora (engl. *support vector machine*, SVM) itd. [11].

2.1.5 Određivanje lokacije neposrednom blizinom

Algoritmi za određivanje lokacije neposrednom blizinom (engl. *proximity detection*) temelje se na detekciji prostorne blizine MS nekom od čvorova mreže senzora gusto postavljenih na unaprijed definirane i poznate lokacije u području pokrivanja LPS sustava. Kada se MS nađe u blizini nekog od senzora mreže za lokalizaciju, tada se može odrediti njegova približna lokacija. Određivanje lokacije neposrednom blizinom kao rezultat daje simboličke i relativne lokacije. Glavni nedostatak ove metode je razmjerno niska točnost i preciznost pozicioniranja kao i potreba za izgradnjom infrastrukture gusto postavljenih senzora. Ova metoda lokaliza-

cije razmjerno se jednostavno može implementirati korištenjem RFID (engl. *radio-frequency identification*) tehnologije ili korištenjem infracrvenih senzora.

2.1.6 Vizualna lokalizacija

Lokalizaciju objekta moguće je provesti korištenjem već prije spomenutih metoda računalnog vida (engl. *computer vision*) koje se temelje na računalnoj analizi i obradi slike. Ovakav način lokalizacije razlikuje se od svih do sada opisanih pristupa jer se ne temelji na klasičnim senzorskim sustavima, već prvenstveno na mogućnostima koje nude algoritmi obrade slike, koji se u zadnje vrijeme često temelje i na naprednim algoritmima strojnog učenja. Ovo područje danas je predmetom intenzivnih istraživanja, a ovisno o zahtjevima primjene razvijaju se različite metode i pristupi. To obuhvaća algoritme za analizu scene, kalibraciju prostornih značajki u sceni, algoritme lokalizacije objekata u slici sa ili bez markera za praćenje, dinamičkog praćenja i klasifikacije objekata u slici, stereo vida itd. Prednosti metoda temeljenih na vizualnoj lokalizaciji su da je moguće jednostavno i jeftino izgraditi infrastrukturu LPS sustava korištenjem jeftinih kamera koje mogu prekriti razmjerno veliko područje promatranja i za korisnika je ovakav sustav najjednostavniji i najugodniji za korištenje jer MS na sebi ne moraju nositi nikakve posebne uređaje. Nedostaci sustava vizualne lokalizacije su problemi kod scena koje se mogu dinamički mijenjati, utjecaj raznih parametara koji izravno djeluju na sadržaj same slike (osvjetljenje, vremenski uvjeti i sl.), gubitak informacije o MS u uvjetima prekrivanja drugim objektima, pitanja privatnosti kada se snimaju osobe, visoka računalna složenost izvođenja algoritama (poglavito za sustave koji traže odziv u stvarnom vremenu), pouzdanost i mogućnost korištenja u sigurnosno kritičnim aplikacijama (jer algoritmi strojnog učenja rijetko mogu deterministički garantirati svoje performanse, što je često preduvjet za sigurnosno kritične aplikacije) itd.

2.2 Ultraširokopojasna tehnologija

Prema izvornoj definiciji postavljenoj od strane američke savezne regulatorne agencije za komunikaciju (engl. *Federal Communications Commission*, FCC), pod pojmom ultraširokopojasnog signala UWB podrazumijeva se signal čija je relativna širina frekvencijskog pojasa (engl. *relative or fractional bandwidth*) veća od 20%, odnosno apsolutna širina frekvencijskog pojasa veća od 500 MHz. Temeljna značajka UWB signala je da signal sadrži široki raspon frekvencija, razliku od uskopojasnih signala (engl. *narrowband*) kakvi se tipično koriste u bežičnim komunikacijskim sustavima.

Za UWB signale apsolutna širina frekvencijskog pojasa B definira se kao razlika između gornje f_H i donje f_L frekvencije u spektru signala na kojima je snaga izračenog signala za

10 dB manja od snage izračene na maksimalnoj centralnoj frekvenciji:

$$B = f_h - f_L. \tag{2.9}$$

UWB signali su vrlo kratkog trajanja i lokalizirani na kratke vremenske intervale u vremenskoj domeni, tipično u području nanosekundi (obično se radi o impulsima trajanja nekoliko desetaka pikosekundi). Uskopojasni signali se šalju kontinuirano u vremenskoj domeni na valu nosiocu čija se centralna frekvencija modulira odabranom metodom dok UWB signal koristi cijelu širinu spektra. Za razliku od uskopojasne komunikacije, kod UWB signala nema izraženo i precizno definirane centralne frekvencije signala nosioca. Ipak, kod postupka generiranja UWB signala može se definirati područje frekvencija u kojima će se nalaziti signal i oblikovati spektar. Prethodno odabrani pojas mora zadovoljiti zahtjeve relevantnih normi, pri čemu se maksimum snage spektra mora nalaziti u središnjem području frekvencijskog raspona, kako je prikazano na slici 2.6. Relativna širina pojasa B_{frac} definira se kao:

$$B_{frac} = \frac{B}{f_c}, \tag{2.10}$$

gdje je f_c centralna frekvencija izražena formulom:

$$f_c = \frac{f_H + f_L}{2}. \tag{2.11}$$

Prema FCC regulativi, UWB sustav koji ima $f_c > 2,5$ GHz mora imati $B > 500$ MHz, a UWB sustav s $f_c < 2,5$ GHz mora imati $B_{frac} \geq 0,2$.

2.2.1 Načela ultraširokopojasne komunikacije

UWB sustav tipično odašilje ultrakratke impulse u vremenskoj domeni s malenim radnim omjerom (engl. *duty cycle*). Zato se takvi sustavi još nazivaju i impulsnim radijskim sustavi (engl. *UWB impulse radio*, IR-UWB). Za razliku od uskopojasnih radiokomunikacijskih sustava, IR-UWB informaciju prenosi kodiranjem putem pozicije i polariteta impulsa u paketu, kako je prikazano na slici 2.7. Na slici 2.7 prikazan je primjer izgled UWB paketa u vremenskoj domeni. Svaki UWB impuls nalazi se unutar jednog vremenskog okvira (engl. *frame*), koji ima definirano trajanje T_f. Svaki vremenski okvir podijeljen je u manje intervale tzv. čipove (engl. *chips*), koji imaju definirano trajanje T_c. U primjeru je prikazano slanje informacije duljine tri bita, gdje se svaki bit kodira pomoću dva impulsa, odnosno unutar trajanja dva vremenska okvira T_f. Kodiranje UWB impulsa obavlja se korištenjem sheme s preskakanjem (engl. *time-hopping*, TH) kako bi se smanjila vjerojatnost kolizije impulsa kada se koristi više UWB odašiljača u istom prostoru. TH kod prvog bita prikazan je kombinacijom $\{2,1\}$, zato jer je u prvom okviru prvi

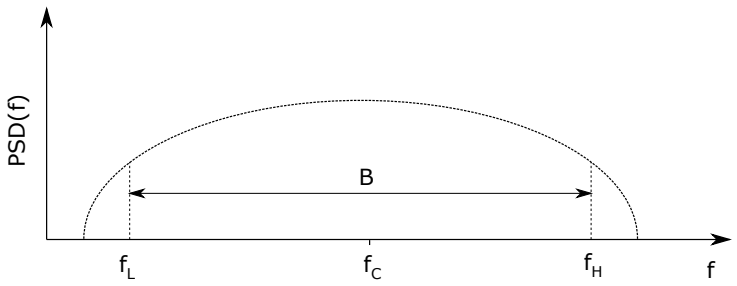

Slika 2.6: Gustoća spektra snage (engl. *power spectral density*, PSD) UWB signala i definicija frekvencija f_L, f_H i f_c

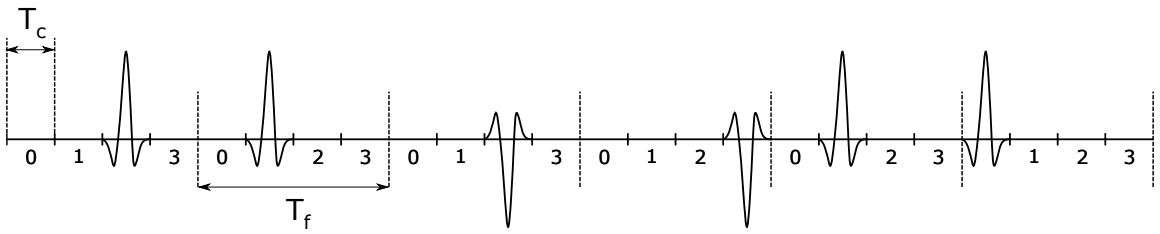

Slika 2.7: Prikaz IR-UWB signala u vremenskoj domeni

impuls pomaknut od početka okvira za $2T_c$, a u drugom okviru je impuls pomaknut za T_c. Uzme li se u obzir da se u prvom i trećem okviru prenose pozitivni impulsi, a u drugom negativni, ukupna informacija koja se na ovakav način šalje putem IR-UWB komunikacijskom kanala je $\{+1,-1,+1\}$.

Impulsi koje šalje IR-UWB odašiljač ne mogu biti proizvoljnog valnog oblika, već moraju zadovoljavati određene uvjete. Naime, iako se UWB tehnologija temelji na radu s kratkim impulsima u vremenskoj domeni koji zauzimaju široko područje u spektralnoj domeni, potrebno je zauzeće spektra i izračenu snagu uskladiti s odgovarajućim normama. Važno je naglasiti da oblik i širina UWB impulsa u vremenu utječe i na širinu frekvencijskog pojasa kao i gustoću spektra snage. Stoga, kvalitetno oblikovanje i generiranje UWB impulsa predstavlja jedan od najvećih izazova u praktičnoj implementaciji UWB tehnologije. Za generiranje UWB impulsa koriste se najčešće druga derivacija Gaussove funkcije, Hermiteovi polinomi ili valići (engl. *wavelets*). Druga derivacija Gaussove funkcije čest je odabir zbog povoljnih svojstava, a vremenski valni oblik može se izraziti sljedećom formulom:

$$\omega(t) = A\left(1 - \frac{4\pi t^2}{\zeta^2}\right)\mathrm{e}^{-2\pi t^2/\zeta^2}, \tag{2.12}$$

gdje parametar A određuje energiju, a parametar ζ širinu impulsa. Na slici 2.8 prikazan je primjer za jediničnu snagu impulsa $A = 1$ i širinu impulsa $\zeta = 0.4$ ns.

U odnosu na uskopojasne bežične komunikacije, UWB zbog specifičnosti signala kojeg šalje (lokaliziranosti impulsa u vremenu) i širokog frekvencijskog raspona, ima brojne važne prednosti:

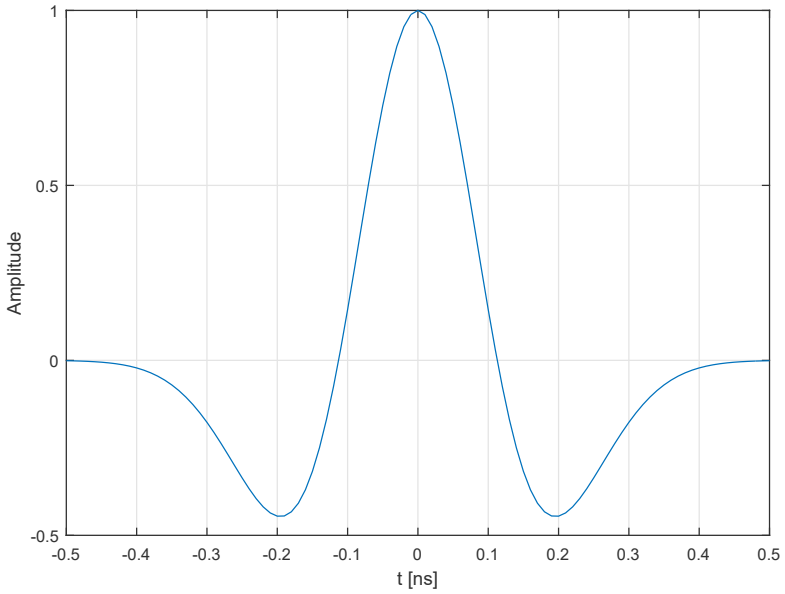

Slika 2.8: Oblik UWB impulsa temeljen na drugoj derivaciji Gaussove funkcije

- bolje prodiranje signala kroz različite prepreke (npr. zidovi u zgradama),
- mogućnost postizanja visoke točnosti i preciznosti radiofrekvencijskog pozicioniranja zbog komunikacije pomoću vrlo uskih impulsa u vremenskoj domeni,
- visoka brzina podatkovne komunikacije,
- niska cijena i potrošnja.

Bolje prodiranje signala kroz prepreke može se zahvaliti činjenici da je u signalu sadržaj veliki raspon spektralnih komponenti, a gušenje je materijalu u frekvencijski ovisno i dominantno je za određeni raspon frekvencija. Upravo iz tog razloga UWB pokazuje bolje svojstva prodiranja signala od klasične uskopojasne komunikacije. Dodatna je prednost što se kod UWB komunikacije ne koristi val nosioc (engl. *carrier*), što sklopovlje za realizaciju primopredajnika UWB sustava čini jednostavnijim.

Osim već spomenutog pristupa IR-UWB, postoje i druge mogućnosti generiranja UWB signala. Jedan od pristupa je *multiband* način rada (engl. *multi-band UWB*, MB-UWB), gdje se podaci multipleksiraju u podnosioce duž cijelog pojasa od 3,1 GHz do 10,6 GHz, odnosno 1,6 GHz do 10,6 GHz GHz ili u nekom njegovom dijelu. U svakom podpojasu podaci se prenose pomoću ortogonale modulacije (engl. *orthogonal frequency division multiplexing*, OFDM) (tzv. OFDM UWB način komunikacije). Također, uz UWB sustave koji rade s malim radnim omjerom (engl. *low duty cycle*), postoje izvedbe UWB sustava s kontinuiranom transmisijom, npr. DS-CDMA.

Nedostatak IR-UWB sustava je pojava većeg broja višestaznih signala koji se pojavljuju u normalnom uredskom, kućnom ili industrijskom okruženju uslijed refleksije i raspršenja UWB signala, tj. prijemnik umjesto jednog impulsa prima veći broj višestaznih komponenti

(engl. *multi-path components*, MPC). Efekti koji se pojavljuju uslijed višestaznog širenja uzrokuje velike probleme prilikom dizajna sklopovlja koje mora biti u stanju ispravno detektirati i dekodirati poslanu poruku, koja uz koristan signal sadrži i veći broj MPC komponenti (ponekad i nekoliko desetaka MPC komponenti). Ipak, s obzirom da se koriste ultrakratki impulsi u vremenskoj domeni, pokazuje se da je u praksi moguće realizirati sklopovlje koje može obaviti učinkovitu filtraciju MPC komponenti u vremenskoj domeni i tako detektirati poruku na ispravan način. Ako je vrijeme između slanja dvaju impulsa veće od širine samog impulsa, efekti preslušavanja između simbola i višestaznih signala se umanjuju ili čak potpunosti uklanjaju.

Glavna prednost MB-UWB sustava je činjenica da je OFDM tehnika prisutna na tržištu već dulje vrijeme te da je dobro provjerena i testirana u realnim okružjima. Dodatno, sama OFDM tehnika posjeduje neka dodatna povoljna svojstva, kao što su visoka spektralna učinkovitost, inherentna otpornost na radio-frekvencijske (RF) smetnje, robusnost na višestazno rasprostiranje signala te sposobnost da se refleksije učinkovito iskoriste. Glavni nedostatak MB-UWB sustava je njihova visoka složenost. Sustav zahtijeva primjenu algoritama brze Fourierove (engl. *Fast Fourier Transform*, FFT) i inverzne FFT Fourierove (engl. *Inverse Fast Fourier Transform*, IFFT) transformacije na odašiljačkoj i prijemnoj strani. Također zahtijeva primjenu sklopovlja za prilagodbu signala visokim ili niskim frekvencijama. Ovaj rad primarno će se fokusirati na IR-UWB sustave zbog sve veće zastupljenosti korištenja IR-UWB tehnologije u područjima komunikacija i lokalizacije u današnjem stanju dostupne tehnologije.

2.2.2 Modeliranje propagacije UWB signala

Za razumijevanje mogućnosti i načina korištenja UWB tehnologije potrebno je dobro razumijeti modele koji opisuju propagaciju UWB signala kao i značajke komunikacijskog kanala. Modeliranje karakteristika komunikacijskog kanala bitno se razlikuje od uskopojasnih tehnologija upravo zbog činjenice da se u signalu nalazi veliki raspon spektralnih komponenti u frekvencijskoj domeni te da su impulsi koji se šalju vrlo kratki u vremenskoj domeni. Primjerice, kod uskopojasnih sustava značajke objekata u komunikacijskom okruženju poput faktora refleksije ili raspršenja mogu se smatrati približno konstantnima s obzirom na frekvenciju jer se radi u dovoljno bliskoj okolini centralne frekvencije vala nosioca. Upravo korišteni široki frekvencijski raspon UWB signala zahtijeva drugačiji pristup analizi načina propagacije UWB signala.

Propagaciju elektromagnetskog vala frekvencije f koji putuje između odašiljača i prijemnika u slobodnom prostoru (bez refleksija, raspršenja i prigušenja), međusobno udaljenih za d, opisuje model koji povezuje snagu signala $P_{rx}(d,f)$. U idealnim uvjetima snaga koju prijemnik prima je:

$$P_{rx}(d,f) = P_{tx}G_{tx}(f)\eta_{tx-ant}(f)G_{rx}(f)\eta_{rx-ant}(f)\left(\frac{c}{4\pi fd}\right)^2, \tag{2.13}$$

gdje je P_{tx} snaga signala na odašiljaču, G_{tx} i G_{rx} pojačanja antena na odašiljaču i prijemniku,

c brzina svjetlosti, a η_{tx-ant} i η_{rx-ant} efikasnosti odašiljačke i prijemne antene. Kao što se može vidjeti iz izraza 2.13, veličine u formuli frekvencijski su ovisne, što je razlog da se kod UWB sustava mora promatrati utjecaj cijelog skupa frekvencija sadržanih u UWB signalu. To je posebno izraženo u dizajnu UWB antena jer je potrebno osigurati male gubitke signala i razmjerno konstante vrijednosti parametara u vrlo širokom frekvencijskom opsegu.

Kod modeliranja komunikacijskog kanala kod uskopojasne komunikacije koristi se parametar faktora gubitaka (engl. *path loss*, PL) koji predstavlja omjer između očekivanja snage P_{rx} primljene na prijemniku i snage signala s odašiljača P_{tx}:

$$\mathrm{PL}(d) = \frac{E\left\{P_{RX}(d, f_c)\right\}}{P_{TX}}, \tag{2.14}$$

gdje je f_c centralna frekvencija uskopojasnog signala, a očekivanje se promatra u dovoljno velikom području da se obuhvate *shadowing* i *small-scale fading* efekti. Zbog širokog spektralnog sastava komponenti, formula 2.14 ne može se izravno primijeniti na UWB sustave, već je potrebno uključiti utjecaj različitih frekvencijskih komponenti koje su sadržane u UWB signalu pa se dobiva izraza za PL ovisan o frekvenciji:

$$\mathrm{PL}(d, f) = E\left\{\int_{f-0.5\Delta f}^{f+0.5\Delta f} \left|H(d, \tilde{f})^2 d\tilde{f}\right|\right\}, \tag{2.15}$$

gdje je $H(d, f)$ transfer funkcija sustava, a Δf dovoljno malo područje oko kojega se parametri materijala i antena mogu smatrati približno konstantnim. Radi jednostavnosti, utjecaj udaljenosti i frekvencije mogu se razmatrati odvojeno pa se formula 2.15 može izraziti kao:

$$\mathrm{PL}(d, f) = \mathrm{PL}(d)\mathrm{PL}(f), \tag{2.16}$$

gdje su $\mathrm{PL}(f) \sim f^{-2\kappa}$ i $\mathrm{PL}(d) \sim d^{-n}$, a parametri κ i n ovisni su o okolini i uključuju utjecaj raznih efekata propagacije signala, koji su u najvećoj mjeri vezani uz LOS i NLOS uvjete. Do vrijednosti parametara tipično se dolazi empirijskim putem. Ovisnost parametra PL o udaljenosti obično se izražava u dB putem formule:

$$\mathrm{PL}(d) = \mathrm{PL}_0 + 10n\log_{10}\left(\frac{d}{d_0}\right), \tag{2.17}$$

gdje je d_0 neka referentna udaljenost na kojoj je izmjerena referentna vrijednost faktora gušenja PL_0.

Jedan od najvažnijih parametara koji opisuje stanje UWB komunikacijskog kanala je profil kašnjenja snage signala (engl. *power delay profile*, PDP), koji daje vremensku ovisnost snage primljenog signala $P(\tau)$, promatranu od trenutka kada prva komponenta signala dođe do prijemnika. Da bi se mogao razumijeti značaj parametra PDP i zašto se modelira na određeni

način, najprije je potrebno razumijeti uzroke pojave višestaznog rasprostiranja UWB signala i kako se ti efekti vide na prijemniku.

U idealnom slučaju homogenog prostora elektromagnetski val širi se izravno od odašiljača do prijemnika, koji prima samo jednu komponentu signala. U slučaju IR-UWB komunikacije to bi značilo da prijemnik prima jedan UWB impuls kojega je poslao odašiljač. U slučaju da se na putu propagacije signala nalaze domene ispunjene različitim materijalima, doći će do efekata poput refleksije (engl. *reflection*), difrakcije (engl. *diffraction*), raspršenja signala (engl. *scattering*), zasjenjenja (engl. *shadowing*) itd. Različiti materijali mogu djelovati na propagaciju materijala zbog npr. zbog promjene u dielektričnosti medija kroz kojega se širi signal, utjecaja metalnih objekata na propagaciju elektromagnetskog vala i sl. Navedeni efekti uzrokuju pojavu novih komponenti (replika) izvornog signala, koji do prijemnika stižu u različitim vremenskim trenucima.

Na slici 2.9 prikazani su jednostavni primjeri kako nastaje višestazno širenje signala kod UWB komunikacije. U primjeru 2.9a prikazana je situacija u kojoj postoji izravna vidljivost između odašiljača TX i prijemnika RX (zadovoljen je LOS uvjet), pri čemu RX prima dvije komponente: izravnu komponentu u trenutku τ_1 te reflektiranu komponentu u kasnijem trenutku τ_2, pri čemu je amplituda reflektirane komponente manja od izravne. U slučaju UWB komunikacije, RX bi trebao temeljem obrade primljenog signala zaključiti da je u trenutku τ_1 primio stvarno odaslanu informaciju, a da je impuls primljen u trenutku τ_2 reflektirana komponenta stvarne poruke koju ne treba uzeti u obzir. Pri tome se ne može koristiti jednostavna pretpostavka da će komponenta s većom amplitudom uvijek biti i izravna komponenta koju je poslao TX. Primjerice, na slici 2.9b prikazana je situacija kada je zadovoljen LOS uvjet, ali je izravna komponenta signala manja od reflektirane: to se može dogoditi iz jednostavnog razloga što antene imaju određenu usmjerenost. Ukoliko je međusobna orijentacija između TX i RX nepovoljna postoji mogućnost da će reflektirana komponenta biti detektirana s većom snagom na RX čak i pod LOS uvjetima. Situacija je još teža u NLOS uvjetima, kako je prikazano na slici 2.9c: prepreka između TX i RX prigušuje snagu signala, a reflektirana komponenta do RX dolazi u kasnijem vremenskom trenutku neprigušena pa ima i veću amplitudu. Iz oba primjera na slikama 2.9b i 2.9c je jasno da se amplituda višestazne komponente ne može koristiti kao mjerodavan parametar detekcije dolaska izravne komponente signala. U slučaju na slici 2.9d prikazana je situacija kada je izravna komponenta prolaskom kroz prepreku dodatno zakasnila pa čak i kada bi se ispravno detektiralo da se radi o izravnoj komponenti vrijeme propagacije signala između TX i RX razlikovalo bi se od vremena propagacije u slobodnom prostoru bez prepreka. Kod primjene UWB tehnologije u području pozicioniranja potrebno je vrlo točno izmjeriti vrijeme dolaska izravne komponente τ_1 kako bi se na temelju toga izmjerila udaljenost. Iz primjera na slici 2.9 vidi se zašto je to problematično u slučaju postojanja višestaznog rasprostiranja signala.

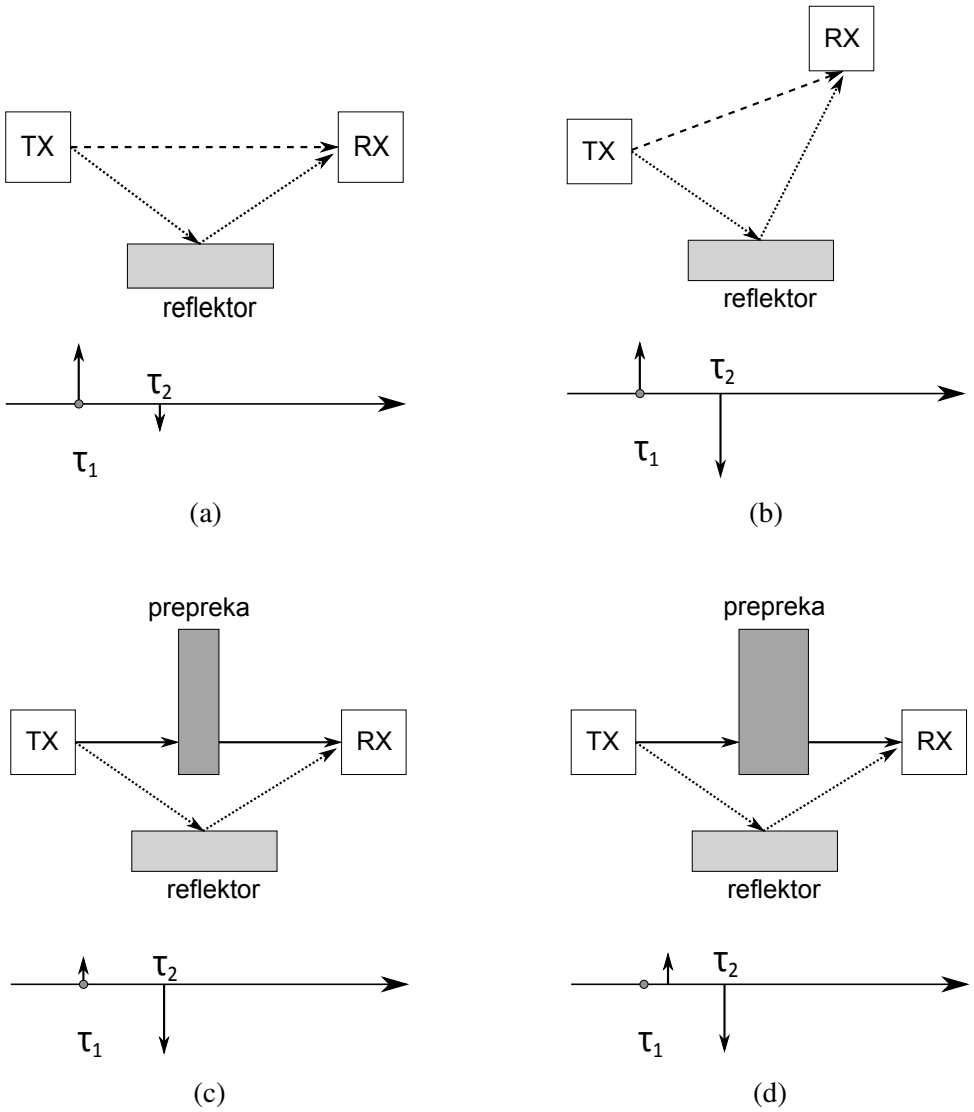

Slika 2.9: Primjeri jednostavnih scenarija nastanka višestaznih komponenti kod LOS i NLOS uvjeta: (a) izravna veza između odašiljača i prijemnika (LOS), (b) izravna veza između odašiljača i prijemnika (LOS), ali na prijemniku postoji atenuacija izravne komponente signala zbog nepovoljne orijentacije antene, (c) izravna komponenta signala prigušena je preprekom (NLOS), (d) izravna komponenta signala prigušena je i zakašnjela djelovanjem prepreka (NLOS)

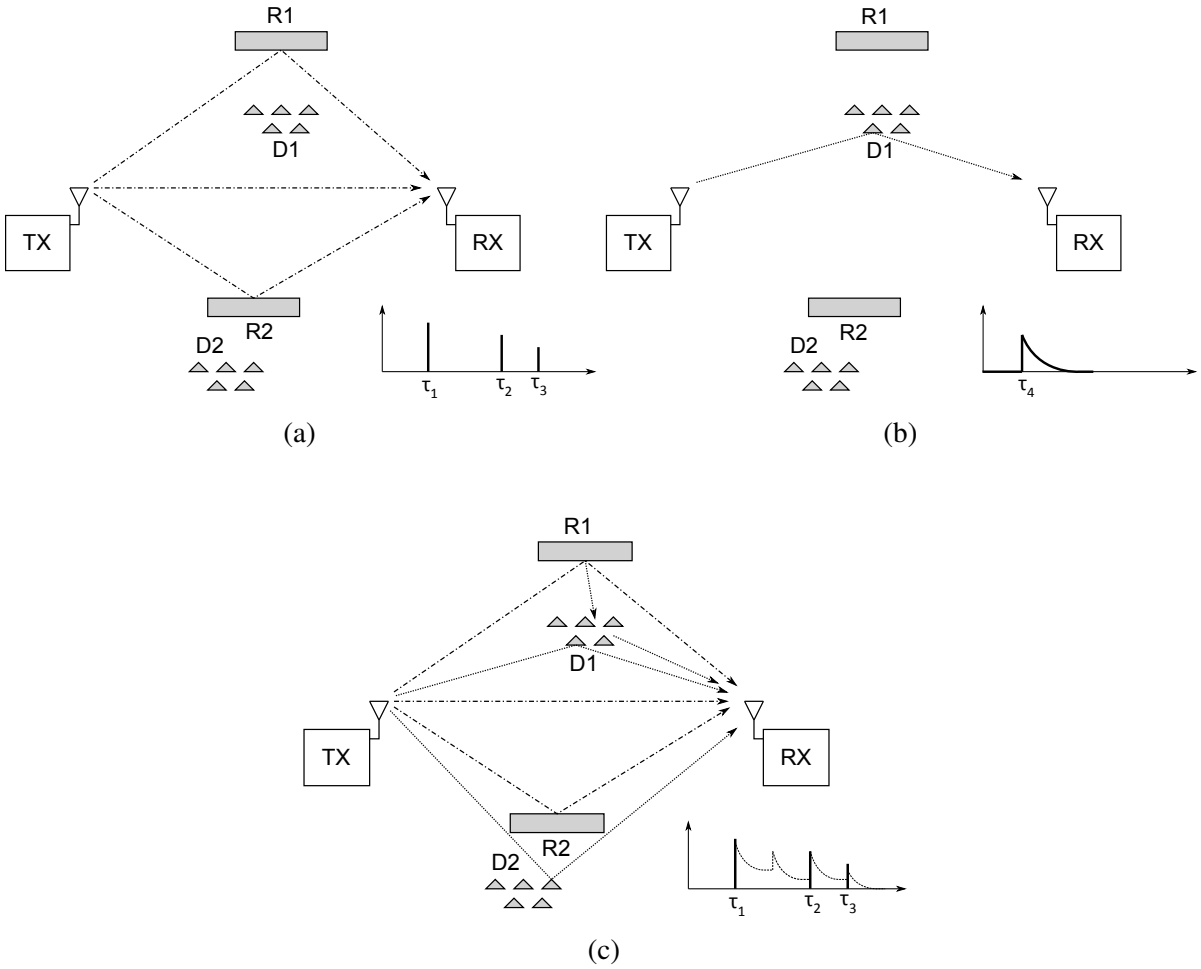

Slika 2.10: Primjer nastanka višestaznog rasprostiranja signala u uvjetima višestrukih refleksija i raspršenja: (a) direktna i spekularne reflektivne MPC komponente, (b) primjer jedne MPC komponente nastale raspršenjem, (c) prikaz svih MPC komponenti signala na RX

Primjer na slici 2.9 prikazuje najjednostavniju situaciju kada postoje samo dvije višestazne (MPC) komponente, ali je situacija u stvarnosti mnogo složenija. Broj MPC komponenti u realnom signalu može se popeti na više desetina, čak i stotina. Stoga je bilo potrebno razviti odgovarajući model višestaznog rasprostiranja UWB signala koji bi bolje opisao očekivano stanje komunikacijskog kanala u realnim uvjetima. Na slici 2.10 prikazan je primjer nešto složenije situacije kod višestaznog rasprostiranja UWB signala, gdje su uz efekte refleksije uzeti u obzir i efekti raspršenja signala. Kod zrcalne ili spekularne refleksije (engl. *specular reflection*) dolazi do odbijanja zrake od reflektora, ali se reflektirana zraka ne dijeli na više zraka. Kod raspršenja ili difuzne refleksije (engl. *scattering*), upadna zraka dijeli se u veći broj reflektiranih zraka, koje se sve ne moraju reflektirati pod istim kutem. Prilikom refleksije mogu biti dodatno unešene promjene u amplitudi, fazi i kašnjenju signala. Efekti raspršenja na određenom materijalu su ovisni o frekvenciji pa će zato posebice kod UWB signala koji sadrži širok raspon frekvencijskih komponenti doći do dijeljenja zrake na veći broj raspršenih komponenti.

U primjeru na slici 2.10 odašiljač TX šalje signal prijemniku RX, pri čemu se u prostoru nalaze dva idealna reflektora $R1$ i $R2$, na kojima se zrake spekularno reflektiraju, te dva difuzora $D1$ i $D2$, na kojima se zrake raspršuju. U primjeru na slici 2.10a prikazane su MPC komponente koje se sastoje od izravne komponente, koja na RX stiže u trenutku τ_1, i od dvije reflektirane komponente, koje na RX stižu u trenucima τ_2 i τ_3. U slučaju kada imamo samo izravnu zraku i spekularne refleksije na prijemniku se primaju tri diskretne zrake, što je prikazano na vremenskom dijagramu na slici 2.10a. Na slici 2.10b prikazana je jedna zraka koja od TX do RX dolazi raspršenjem na difuzoru $D1$. Raspršenje će uzrokovati pojavu većeg broja komponenti koje na RX ne stižu u isto vrijeme jer će efekt raspršenja uzrokovati varijabilno kašnjenje u ovisnosti o frekvenciji i male promjene u kutu refleksije, što utječe na snagu primljenu na RX. Ako bi se samo ova raspršena komponenta promatrala izdvojeno na RX, onda se ne bi dobila jedna diskretna reflektirana zraka kao što je prikazano u vremenskom dijagramu na slici 2.10a, već u vremenu razmazana distribucija kako je prikazano na slici 2.10b. Slična bi se razmazana distribucija primljenog impulsa na RX dobila primjerice kod prigušenja izravne komponente u NLOS uvjetima kada bi zraka prolazila kroz materijal različit od slobodnog prostora propagacije jer će se brzina propagacije signala mijenjati unutar materijala u ovisnosti o frekvenciji što uzrokuje dolazak različitih komponenti signala u različito vrijeme na RX. Više od modelima koji utječu na stvaranje MPC komponenti može se pronaći u [13].

Kroz pojednostavljene primjere prikazane na slikama 2.9 i 2.10 obrazloženo je zašto je kod UWB komunikacije važno razmatranje višestaznog širenja signala i kako MPC komponente utječu na detekciju primljenog signala. Za promatranje višestaznih efekata propagacije signala kod modeliranja bežičnih komunikacijskih kanala koristi se impulsni odziv kanala (engl. *chan-*

nel impulse response, CIR) opisan izrazom:

$$h(t) = \sum_{k=0}^{\infty} h_k \delta(t - \tau_k), \tag{2.18}$$

gdje su h_k i τ_k amplitude i kašnjenja k-te komponente signala uslijed višestaznog rasprostiranja. Model prikazan formulom 2.18 primijenjiv je u slučajevima kada višestazne komponente nastaju uslijed npr. spekularnih refleksija, kod kojih MPC komponente predstavljaju zakašnjelu i amplitudno moduliranu repliku originalnog impulsa. Model 2.18 tipičan je kod uskopojasnih signala jer su svojstva materijala konstantna u uskom pojasu frekvencija oko vala nosioca. Međutim, kod UWB komunikacije zbog vrlo širokog spektralnog sadržaja komponenti u signalu može doći i do raspršenja MPC komponenti u vremenskoj domeni, a ne samo pojave izdvojenih reflektiranih impulsa, jer su karakteristike materijala na putu prolaska elektromagnetskog vala frekvencijske ovisne. Posljedica toga je da MPC komponente kod UWB signala dolaze u *klasterima* (engl. *clusters*), zbog čega se za modeliranje značajki UWB kanala koristi Saleh-Valenzuela (S-V) model koji dobro opisuje takvu situaciju, a za kojega je impulsni odziv kanala prikazan sljedećom formulom:

$$h(t) = \sum_{k=0}^{K} \sum_{l=0}^{L_k} \alpha_{k,l} e^{j\Phi_{k,l}} \delta(t - T_k - \tau_{k,l}), \tag{2.19}$$

gdje je K broj klastera, L_k broj zraka (MPC komponenti) u k-tom klasteru, $\alpha_{k,l}$ koeficijent kanala za l-tu komponentu k-tog klastera, T_k je kašnjenje k-tog klastera, $\tau_{k,l}$ je kašnjenje l-te zrake u odnosu na početak k-tog klastera, a $\Phi_{k,l}$ faza uniformno distribuirana na intervalu $[0, 2\pi]$. Parametar profila kašnjenja snage opisuje razinu snage primljenog signala $P(\tau)$, promatranu od trenutka primitka prve MPC komponente signala u trenutku $\tau = 0$. Promatranjem ovisnosti parametra PDP u vremenu dobiva se informacija o stupnju raspršenja MPC komponenti primljenog signala, a PDP kanala se za kanal s impulsnim odzivom $h(t)$ može izračunati kao lokalna srednja vrijednost $|h(t)|^2$. Kod S-V modela UWB kanala vremena dolaska klastera i pojedinih zraka unutar njih modeliraju se Poissonovom slučajnom varijablom s gustoćama vjerojatnosti:

$$p(T_k | T_{k-1}) = \Lambda \exp\left[-\Lambda \left(T_k - T_{k-1}\right)\right], \quad k > 0, \tag{2.20}$$

$$p(\tau_{k,l} | \tau_{k,l-1}) = \lambda \exp\left[-\lambda \left(\tau_{k,l} - \tau_{k,l-1}\right)\right], \quad l > 0, \tag{2.21}$$

gdje su Λ i λ vremena dolaska klastera i MPC zraka unutar klastera. Uz modeliranje statističkih značajki vremena dolaska klastera i MPC komponenti unutar njih, PDP se modelira eksponencijalnim prigušenjem unutar svakog klastera, a detalji modela mogu se pronaći u [14, 15]. Primjer vremenske ovisnosti PDP za Saleh-Valenzuela model UWB komunikacijskog kanala

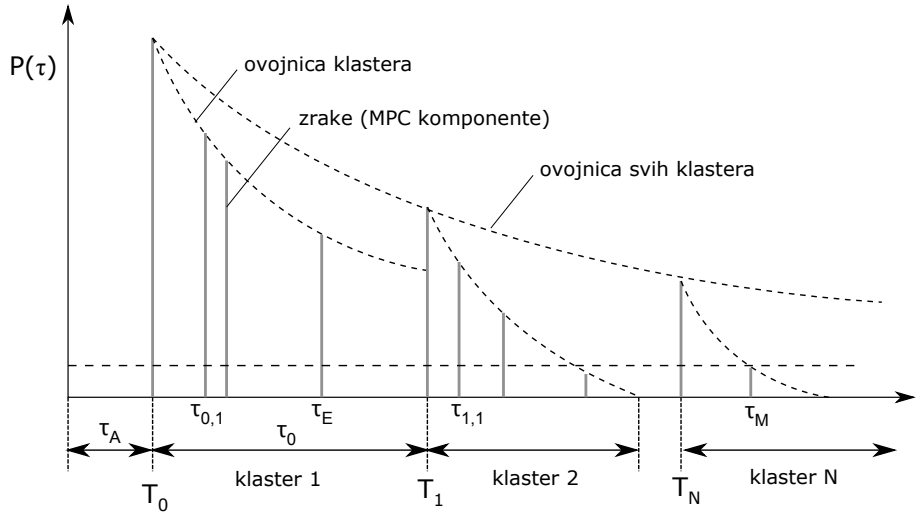

Slika 2.11: Vremenska ovisnost $P(\tau)$ za Saleh-Valenzuela model UWB komunikacijskog kanala

prikazan je na slici 2.11.

Uz Saleh-Valenzuela model kanala definira se nekoliko pomoćnih parametara koji opisuju vremensku raspodjelu profila raspodjele snage (PDP), a prikazani su na slici 2.11. Parametar τ_A predstavlja vrijeme dolaska prve MPC komponente, a prema njemu se relativno određuju sva ostala vremena u vremenskom dijagramu profila raspodjele snage. Točnost procjene parametra τ_A izuzetno je važna kod sustava za pozicioniranje jer točnost pozicioniranja najviše ovisi o kvaliteti procjene tog parametra, a o algoritmima procjene τ_A biti će više riječi nešto kasnije. Prvi i drugi moment profila raspodjele snage $P(\tau)$ definiraju su kao:

$$\tau_E = \frac{\int \tau P(\tau) d\tau}{\int P(\tau) d\tau}, \tag{2.22}$$

$$\tau_{rms} = \left[\frac{\int (\tau - \tau_E)^2 P(\tau) d\tau}{\int P(\tau) d\tau} \right]^{1/2}, \tag{2.23}$$

gdje parametar τ_E predstavlja srednje očekivano kašnjenje MPC odziva (engl. *mean excess delay*), a τ_{rms} RMS snagu vremenskog raspršenja MPC odziva (engl. *RMS delay spread*). Parametar τ_{rms} važan je jer karakterizira vremensku disperziju MPC komponenti impulsnog odziva kanala. Ovi parametri mogu u praksi biti korisni da se na temelju njihove procjene izbjegnu problemi poput npr. interferencije između okvira (engl. *inter-frame interference*, IFI) na način da se procijeni potrebna pauza između impulsa kod slanja signala IR-UWB metodom. Parametar τ_M predstavlja vrijeme nakon kojega snaga primljenog signala $P(\tau)$ pada ispod predefinirane razine (tipično 10 dB ispod maksimalne vrijednosti $P(\tau)$).

2.2.3 Mjerenje udaljenosti temeljeno na mjerenju vremena propagacije ultraširokopojasnog signala

Kod LPS sustava, razmatra se problem određivanja nepoznate pozicije MS u odnosu na skup od N BS, postavljenih na poznate referentne koordinate. Skup izmjerenih udaljenosti $\hat{d}_i$ između MS i svake i-te BS može se opisati formulom:

$$\hat{d}_i = d_i + e_i + n_i = c \cdot t_i, \quad i = 1,2,...,N, \tag{2.24}$$

gdje je t_i vrijeme propagacije signala od i-te MS do MS, c je brzina svjetlosti, d_i je stvarna udaljenost na putu propagacije signala, n_i mjerni šum u komunikacijskom kanalu (tipično modeliran kao aditivni bijeli šum (engl. *Additive White Gaussian Noise*, AWGN) tj. vrijedi $n_i \sim \mathcal{N}(0,\sigma_i^2)$), a e_i je nenegativni pomak u mjerenoj udaljenosti kojeg se unosi u ovisnosti o LOS/NLOS uvjetu, pri čemu vrijedi:

$$e_i = \begin{cases} 0, & \text{ako je } i\text{-to mjerenje obavljeno uz LOS uvjet,} \\ |\tilde{e}_i|, & \text{ako je } i\text{-to mjerenje obavljeno uz NLOS uvjet.} \end{cases} \tag{2.25}$$

Nepoznata pozicija mobilne stanice (x,y,z) određena je sustavom jednadžbi:

$$(x-x_i)^2 + (y-y_i)^2 + (z-z_i)^2 = \hat{d}_i^2, \quad i = 1,2,...,N. \tag{2.26}$$

S obzirom na utjecaj članova n_i i e_i u formuli 2.24, u stvarnim uvjetima tipično nije moguće pronaći jednoznačno rješenje sustava jednadžbi 2.26, već se traži procjena $(\hat{x},\hat{y},\hat{z})$ koja minimizira zadanu normu odstupanja od stvarne vrijednosti pozicije. Postoji mnogo načina kako se može estimirati položaj MS, a jedna od tipično korištenih metoda jest metoda minimalnog kvadratnog odstupanja (LSS) prikazana sljedećom formulom:

$$\begin{aligned} (\hat{x},\hat{y},\hat{z}) &= \arg\min_{(x,y,z)} \left\{ \sum_{i=1}^{N} \zeta_i \left(\hat{d}_i - \sqrt{(x-x_i)^2 + (y-y_i)^2 + (z-z_i)^2} \right)^2 \right\} \\ &= \arg\min_{(x,y,z)} \left\{ \varepsilon_{res}(x,y,z) \right\}, \end{aligned}$$

gdje je $\varepsilon_{res}(x,y,z)$ pogreška ostatka koja prema odabranoj metrici izražava odstupanje od stvarne udaljenosti.

Kao što je već prije rečeno, UWB tehnologija omogućuje slanje vrlo kratkih impulsa u vremenskoj domeni čijim se mjerenjem vremena slanja i dolaska može odrediti udaljenost između odašiljača i prijemnika. Uskopojasnom komunikacijom ne mogu se postići tako kratki impulsi, što UWB metodu čini posebno atraktivnim odabirom za implementaciju LPS sustava temeljenih na mjerenju vremena propagacije elektromagnetskog vala. Pozicioniranje se temelji na

mjerenju udaljenosti preciznim mjerenjem vremena propagacije kratkih UWB impulsa, a takvim sustavom moguće je implementirati ranije opisane pristupe mjerenju udaljenosti temeljene na TOA, TDOA, RTOF i srodnim metodama. S obzirom da se se svi navedeni pristupi u osnovi temelje na mjerenju vremena leta signala (odnosno vremena dolaska, TOA), u nastavku će biti detaljnije opisane mogućnosti i poteškoće kod realizacije TOA metode korištenjem IR-UWB signala.

Ako se pretpostavi da odašiljač šalje signal vremenskog valnog oblika $s(t)$, prijemnik će primiti signal $r(t)$:

$$r(t) = \alpha s(t-\tau) + n(t), \tag{2.27}$$

gdje parametar τ predstavlja kašnjenje signala uslijed propagacije (tj. TOA kojeg se mjeri), α koeficijent djelovanja komunikacijskog kanala na amplitudu signala, a $n(t)$ utjecaj šuma u kanalu (tipično modeliran bijelim Gaussovim šumom). Algoritmi detekcije dolaska signala tipično se temelje na korelaciji primljenog signala s valnim oblikom poznatog signala kojeg se šalje ili na primjeni prilagođenih filtara (engl. *matched filter*) gdje se dolazak signala promatra na temelju maksimalnog izlaza iz filtra. Ovakav pristup primjenjiv je u slučajevima kada nema višestaznog širenja signala, što nije slučaj kod korištenja UWB tehnologije.

Kod UWB pozicioniranja, efekti višestaznog rasprostiranja signala mogu se opisati formulom:

$$r(t) = \sum_{l=1}^{L} \alpha_l s(t-\tau_l) + n(t), \tag{2.28}$$

gdje je $s(t)$ valni oblik signala za pozicioniranje, L je broj višestaznih komponenti na prijemniku, a α_l i τ_l su koeficijenti gušenja i kašnjenja kanala za l-tu MPC komponentu. Signal $s(t)$ u formuli 2.28 može se opisati formulom:

$$s(t) = \sqrt{\frac{E_s}{N_f}} \sum_{j=-\infty}^{\infty} a_j \omega(t - jT_f - c_j T_c), \tag{2.29}$$

gdje E_s predstavlja energiju signala za pozicioniranje, $a_j \in \{\pm 1\}$ polaritet koda, $c_j \in \{0, 1, ..., N_h\}$ TH kod, $\omega(t)$ primljeni UWB impuls s jediničnom energijom, T_f duljinu trajanja okvira, N_f broj impulsa po simbolu za pozicioniranje, T_c trajanje *chip* intervala, a N_h broj čipova po okviru. Svaki simbol za pozicioniranje u signalu 2.29 sastavljen je of N_f UWB impulsa, pri čemu je trajanje simbola za pozicioniranje $T_s = N_f T_f$, a energija UWB impulsa:

$$E_p = \int_{-\infty}^{-\infty} |\omega(t)|^2 dt = 1, \tag{2.30}$$

gdje je jedinična snaga pretpostavljena bez gubitka općenitosti.

Brojni su izvori pogrešaka koji utječu na točnost pozicioniranja UWB sustava kod mjerenja vremena propagacije signala (TOA metoda). Kod slučaja mjerenja udaljenosti bez višes-

taznih efekata, može se pokazati da je Cramer-Rao donja granica (engl. *Cramer-Rao lower bound*, CRLB) varijance procjene vremena TOA određena nejednakošću:

$$\sqrt{\mathrm{Var}(\hat{\tau})} \geq \frac{1}{2\sqrt{2}\sqrt{\mathrm{SNR}}\beta}, \tag{2.31}$$

gdje $\hat{\tau}$ predstavlja nepristranu estimaciju TOA, SNR je odnos signal-šum, a β efektivna širina pojasa signala (engl. *bandwidth*). Iz formule 2.31 vidljivo je da će preciznost mjerenja biti to veća (tj. varijanca TOA što manja) što je bolji odnos signal-šum i što je frekvencijski raspon signala β veći. Sve navedeno čini UWB signala boljim odabirom u odnosu na uskopojasnu komunikaciju zbog svojih specifičnih svojstava. U slučaju višestaznog rasprostiranja signala izraz 2.31 ima drugačiji nešto drugačiji oblik, o čemu se detaljnije može vidjeti u [14].

Osim inherentnog ograničenja na preciznost određivanja vremena propagacije signala već u slučaju dok nema višestaznih efekata, izraženog mjerom CRLB prema 2.31, posebno izazovan problem predstavlja određivanje vremena τ_A prijema direktne MPC komponente u slučaju kada su prisutni efekti višestaznog rasprostiranja. Primjer višestaznih refleksija na signalu na slici 2.12 prikazuje da MPC komponenta s najvećom snagom signala ne mora ujedno odgovarati i direktnoj MPC komponenti koja je relevantna za mjerenje udaljenosti TOA metodom. Problem u slučaju prikazanom na slici 2.12 je da metode digitalne obrade signala koje se mogu uspješno koristiti kod uskopojasne komunikacije mogu dati pogrešne rezultate ako ih se izravno primijeni na UWB signale. Primjerice, maksimum korelacije primljenog signala s predloškom poslanog kod uskopojasne komunikacije bez višestaznih efekata može dobro detektirati direktnu MPC komponentu, ali će u slučaju višestaznog širenja signala na slici 2.12 korelacija u maksimumu detektirati pogrešnu komponentu, jer je direktna MPC komponenta svojom snagom prigušena u odnosu na treću, najjaču MPC komponentu u prikazanom primjeru. To će izravno utjecati na pogrešku prilikom određivanja TOA. Ova pojava posebno je izražena kod NLOS uvjeta propagacije UWB signala. Sljedeći problem kod određivanja vremena dolaska signala je da kod UWB signala postoji efekt razmazivanja MPC komponenti u vremenu uslijed efekata raspršenja signala, što otežava detekciju vršne vrijednosti direktne MPC komponente koja se traži. Zato se za UWB sustave pozicioniranja ne koriste direktno korelacijske metode i prilagođeni filtri kao kod uskopojasne komunikacije, već su razvijene posebne metode obrade signala za detekciju parametra τ_A i direktne MPC komponente, kao što su estimatori maksimalne vjerojatnosti (engl. *maximum likelihood*, ML), razne metode niže kompleksnosti za lakšu sklopovsku implementaciju (npr. *largest-N peak-detection techniques*, *two-step TOA estimators*, *dirty templates*, *threshold-based ranging* itd. [14]).

Sljedeći problem koji otežava detekciju direktne MPC komponente i lokalizaciju su okružja u kojima postoji istovremena komunikacija više čvorova što može dovesti do kolizije između simbola za lokalizaciju (engl. *multiple-access interference*, MAI). Ovi utjecaji se mogu uma-

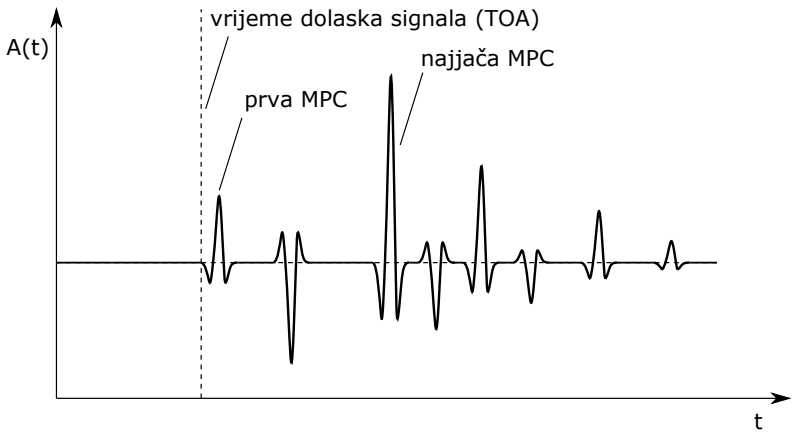

Slika 2.12: Prikaz problema određivanja TOA kod UWB kanala s efektima višestaznog rasprostiranja signala

njiti, no ne i u potpunosti izbjeći, korištenjem ortogonalnog kodiranja signala i algoritama za izbjegavanje kolizije. Također, kod procesiranja primljenog signala korelacijske metode pomažu ne samo u razriješenju problema višestaznog širenja signala, već i problema MAI ako svaki čvor ili dio mreže koristi drugačiji skup simbola, tj. signala koji se šalju za pozicioniranje. Ranije navedeni problem da direktna MPC komponenta može biti prigušena u odnosu na reflektirane kako je prikazano na slici 2.12 može u težim NLOS uvjetima dovesti do situacije da se ona potpuno izgubi iz primljenog signala pa niti napredniji algoritmi obrade signala više ne mogu ispravno odrediti TOA. U tom slučaju pojavljuje se razmjerno veliki pomak mjerenja vremena TOA (opisan parametrom e_i u formuli 2.24), koji je posljedica pogrešne detekcije direktne komponente u nekoj od reflektiranih MPC komponenti.

U praktičnim realizacijama UWB sustava postoje dodatni izvori pogrešaka uzrokovani nesavršenošću vremenske baze satova na MS i BS. Između svih čvorova u mreži za lokalizaciju postoji razlika u fazi satova (pomak ili engl. *clock drift*) i razlika u frekvenciji oscilatora koji definiraju vremenske baze (engl. *clock skew*). Potrebno je voditi računa da pomaci i razlike u frekvenciji satova su vremenski promjenjive veličine, a na njih utječu i drugi parametri, poput temperature i sl. Stoga je u mreži za UWB lokalizaciju od presudne važnosti voditi računa na koji način će se izvršiti kompenzacija nesigurnosti vremenske baze, pri čemu su neke metode inherentno osjetljivije na nesinkronizam vremenskih baza (npr. TOA), dok su druge razmjerno imune na taj problem (npr. RTOF). Međutim, optimalni pristup rješenju ovog problema ovisan je o konkretnoj primjeni i potrebno ga je pažljivo razmotriti u svakoj posebnoj situaciji jer svaki pristup zahtijeva i drugačije komunikacijske protokole između BS i MS u sustavu kojeg je potrebno implementirati.

2.2.4 Propisi i standardi za ultraširokopojasnu komunikaciju

Bilo koji oblik komunikacije korištenjem radiofrekvencijskog spektra podliježe zakonskim propisima koji postavljaju ograničenja na spektralni raspon signala, izračenu snagu, radni omjer i druge parametre komunikacije. Ograničavanje slobodnog pristupa radijskom spektru važno je kako bi se izbjegle kolizije u komunikaciji između različitih uređaja i servisa, a nadležna regulatorna tijela svake države vode brigu o namjenskoj i planskoj dodjeli radijskih frekvencija i kanala. Za razliku od većine radijskih komunikacijskih tehnologija koje rade u uskom i ograničenom području frekvencija, za UWB tehnologiju karakteristično je da pokriva vrlo širok raspon frekvencija, koji se preklapa s većim brojem pojaseva koji se koriste u različite svrhe kod uskopojasne komunikacije pa je stoga posebno izazovan zadatak s gledišta definiranja propisa bio na koji način omogućiti legalno korištenje UWB komunikacije u tako vrlo širokom frekvencijskom području, a da se pritom ne ometaju drugi uređaji i radijske komunikacije.

FCC prva je u svijetu 2002. godine dozvolila legalno korištenje UWB tehnologije na području SAD-a. Problemu širine zauzeća spektralnog pojasa i ometanja drugih uskopojasnih komunikacija pristupilo se na način da se ograniči maksimalna spektralna gustoća snage PSD u cijelom frekvencijskom području UWB signala ispod razine koja će nepovoljno utjecati na druge komunikacijske protokole čiji se pojasevi preklapaju s frekvencijskim rasponom UWB signala (npr. Wi-Fi, Bluetooth i sl.). Za razliku od uskopojasnih komunikacija, kod kojih bi drastično smanjenje snage u uskom spektralnom području značajno otežalo komunikaciju jer se gotovo sva energija komunikacije nalazi u uskom području oko frekvencije vala nosioca, takva ograničenja za UWB tehnologiju su prihvatljiva jer je energija ravnomjerno raspoređena po cijelom širokom spektralnom rasponu. FCC je propisala da spektralna gustoća snage ne smije biti veća od propisane maksimalne referentne vrijednosti $-41{,}3\,\mathrm{dBm/MHz}$ za frekvencijski raspon 3,1–10,6 GHz, a izvan tog raspona mora biti i manja, u ovisnosti o specifičnoj primjeni. Time je ujedno definirano područje rada UWB komunikacije u pojasu širine 7,5 GHz.

Navedena PSD granica od $-41{,}3\,\mathrm{dBm/MHz}$ odnosi se na mjeru ekvivalentne izotropno izračene snage (engl. *equivalent isotropically radiated power*, EIRP). EIRP predstavlja mjeru izračene snage iz idealne izotropne antene u jednom pravcu, pri čemu izotropna antena predstavlja antenu koja zrači istu količinu energije u svim pravcima. Realne antene ne zrače jednako u svim pravcima pa se za definiranje EIRP-a promatra izračena snaga u pravcu najvećeg pojačanja antene. Navedena granica PSD je relativno niska i predstavlja limit kojeg imaju na izračene smetnje u radiofrekvencijskom području uređaji koji nisu namijenjeni za komunikaciju, poput npr. monitora. FCC propisi ne limitiraju izračenu snagu postavljanjem jednostavne ravne granice za cijelo spektralno područje rada UWB komunikacije, već se za različite podpojaseve dozvoljene granice izračene snage definiraju spektralnom maskom, koja se razlikuje za uređaje koji se koriste u zatvorenom (engl. *indoor*) i otvorenom (engl. *outdoor*) prostoru. Na slici 2.13 prikazana je FCC spektralna maska za UWB uređaje koji rade u zatvorenom prostoru,

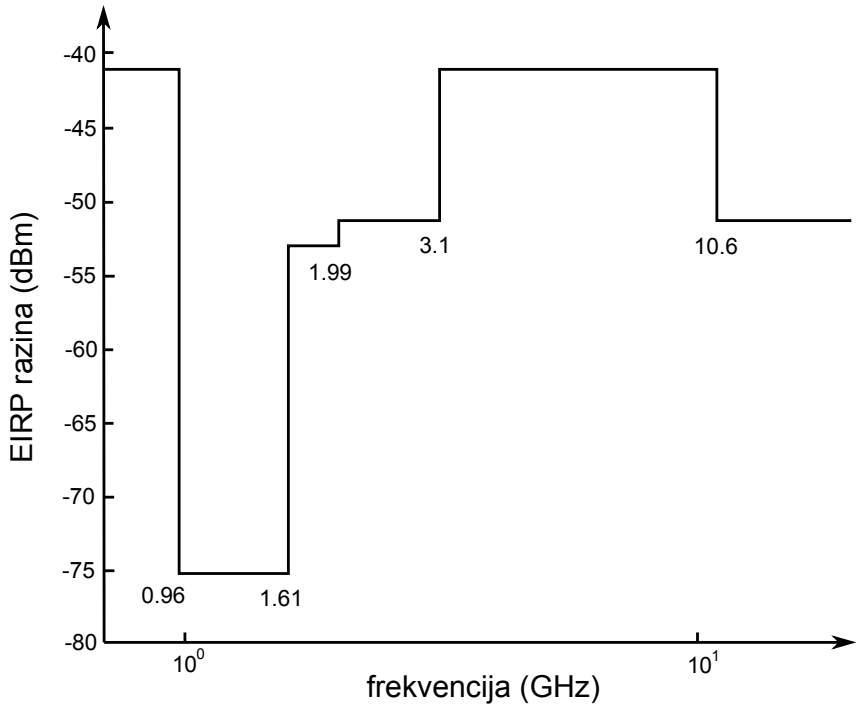

Slika 2.13: FCC spektralna maska za UWB komunikaciju u zatvorenom prostoru

a na slici 2.14 za one na otvorenom. FCC propisi definiraju još neke posebne klase UWB uređaja, kao npr. radare na vozilima (engl. *vehicular radar systems*), sustave za nadzor i inspekciju (npr. *ground penetrating radars* (GPR), medicinske uređaje, nadzorne uređaje i sl.), za koje se definiraju nešto drugačije spektralne maske [14].

Nakon SAD-a i u drugim dijelovima svijeta počeli su se uvoditi propisi koji reguliraju UWB komunikaciju. Europsko nadležno tijelo (engl. *Electronic Communications Committee*, ECC) 2007. donijelo na snagu propise slične američkim, ali s nešto strožim zahtjevima. Za UWB uređaje koji nemaju implementirane odgovarajuće mehanizme izbjegavanja interferencije s drugim uređajima definirana je spektralna maska prikazana slikom 2.15, pri čemu je dozvoljena granica PSD također postavljena na $-41{,}3\,\mathrm{dBm/MHz}$, ali u puno užem području, samo 6,0–8,5 GHz. Za područje 4,2–8,5 GHz ta granica vrijedila je samo do kraja 2010., kada je i za to područje spuštena na $-70\,\mathrm{mdB/MHz}$. Za uređaje koji implementiraju odgovarajuće mehanizme izbjegavanja interferencije s drugim uređajima spektralna maska koja ima nešto blaže zahtjeve prikazana je na slici 2.16. U tim sustavima dozvoljen je PSD od $-41{,}3\,\mathrm{dBm/MHz}$ za pojas 3,4–8,5 GHz, pri čemu se tehnike izbjegavanja interferencije s drugim uređajima temelje na ograničavanju radnog omjera (engl. *duty cycle*) prilikom komunikacije. U Japanu i na drugim područjima također su doneseni posebni propisi vezani uz UWB tehnologiju, a s obzirom da se tehnologija tek nedavno počela komercijalno koristiti, očekuje se da će se ti propisi u budućnosti dalje mijenjati i prilagođavati.

Nakon što su regulatorne agencije počevši s FCC-om zakonski dozvolile korištenje UWB sustava za komunikaciju, međunarodne standardizacijske organizacije započele su s radom na

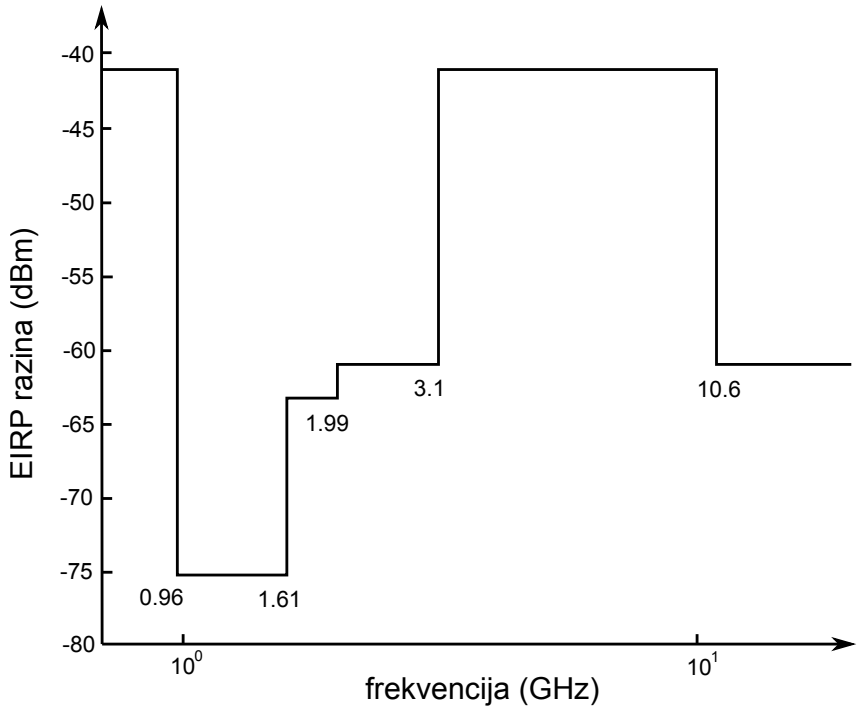

Slika 2.14: FCC spektralna maska za UWB komunikaciju na otvorenom prostoru

standardima za UWB komunikaciju. Prvi koraci u smjeru standardizacije UWB tehnologije napravljeni su od strane *Institute of Electrical and Electronics Engineers* (IEEE), gdje se u okviru IEEE 802.15 standarda nastojao UWB uključiti kao novi fizički (PHY) sloj. IEEE 802.15 je radna grupa koja se bavi standardima u području osobnih bežičnih mreža (engl. *wireless personal area networks*, WPAN), pri čemu su za UWB tehnologiju najvažnije dvije podgrupe, IEEE 802.15.3 (MAC i PHY standardi za brze WPAN mreže, 11–15 Mb/s) i IEEE 802.15.4 (MAC i PHY standardi za spore WPAN mreže, što podržavaju različiti danas često korišteni protokoli, poput ZigBee, Thread, 6LoWPAN, WirelessHART itd.). Standardizacija UWB PHY sloja najprije je krenula u pravcu proširenja IEEE 802.15.3a za brze WPAN mreže, pri čemu se izbor suzio na dvije predložene varijante UWB komunikacije, višepojasni OFDM (engl. *multi-band orthogonal frequency division multiplexing*, MBOFDM) i DS–UWB (engl. *Direct Sequence UWB*). Međutim, radna grupa nije uspjela postići dogovor koji bi se od navedenih prijedloga koristio i u konačnici je 2006. formalno prekinut rad na standardizaciji UWB komunikacije u okviru IEEE 802.15.3 standarda.

UWB komunikacija standardizirana je u okviru nadogradnje izvornog IEEE 802.15.4 standarda inačicom IEEE 802.15.4a, koja predviđa mogućnost dodatnog korištenja alternativnog UWB fizičkog sloja. Ta inačica standarda predviđa uz podatkovnu komunikaciju niske brzine i mogućnost pozicioniranja s vrlo visokom točnošću. IEEE 802.15.4a ujedno je i prvi UWB standard koji predviđa mogućnost bežične lokalizacije, a podržava jednosmjerne i dvosmjerne komunikacijske protokole. Prijedlog standarda IEEE 802.15.4a službeno je odobren 2007. od strane IEEE Standards Association (standard se punim formalnim imenom naziva

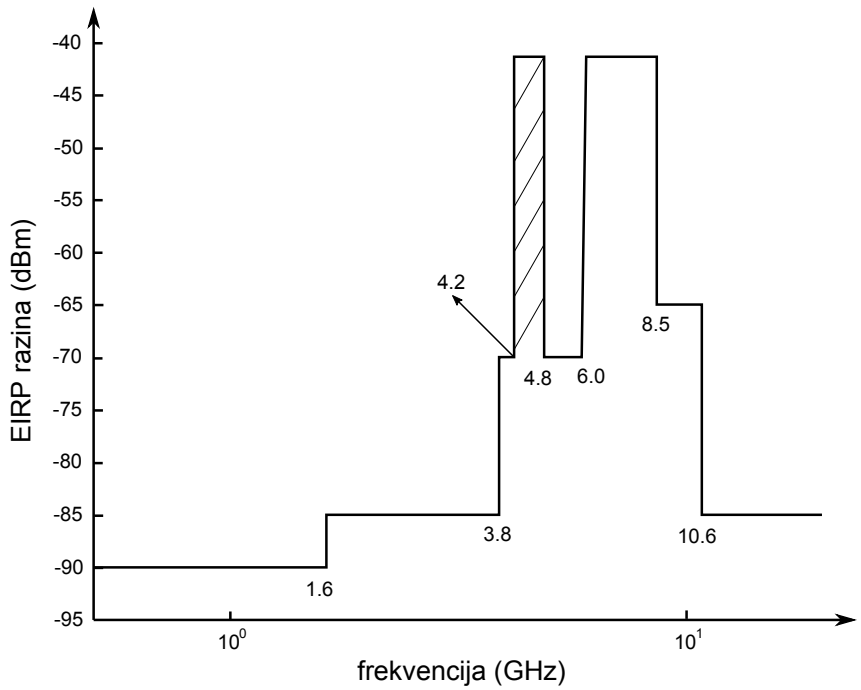

Slika 2.15: ECC spektralna maska za UWB uređaje bez implementiranih mjera za izbjegavanje interferencije

IEEE 802.15.4a-2007). IEEE 802.15.4a standard specificira dvije mogućnosti za generiranje signala za komunikaciju: impulsni IR-UWB i CSS (engl. *chirp spread spectrum*). Oba načina generiranja signala mogu se koristiti za komunikaciju, a IR-UWB i za pozicioniranje. Standard također definira i tri frekvencijska pojasa:

- Sub–GHz: 250–750 MHz
- Low band: 3,244–4,742 GHz
- Hi band: 5,944–10,234 GHz

Za sva tri navedena pojasa, standard definira 16 raspoloživih kanala, jedan u *Sub–GHz* pojasu, četiri u *Low band* pojasu i jedanaest u *High band* pojasu. Frekvencijski raspon kanala je od 499,2 MHz do 1357,97 MHz, a standard također definira koje kanale UWB uređaji koji rade u nekom od navedenih pojaseva obavezno moraju implementirati u komunikaciji, a koje opcionalno. Fizički UWB sloj IEEE 802.15.4a standarda podržava različite predefinirane brzine komunikacije (110 kbps, 850 kbps, 1,7 Mbps, 6,81 Mbps i 27,24 Mbps). Također se definiraju standardizirane vrijednosti frekvencije ponavljanja impulsa kod njihovog slanja u paketu ((engl. *pulse repetition frequency*, PRF)). Definirane su standardizirane vrijednosti PRF od 3,9 MHz, 15,6 MHz i 62,4 MHz. Dodatno, u okviru IEEE 802.15.4a standarda definirani su i standardizirani modeli komunikacijskog kanala koji se koriste kod analize propagacije UWB signala. Za područje frekvencija 2–10 GHz IEEE 802.15.4a standard definira modele kako je prikazano u tablici 2.1, pri čemu se za svaki model kanala navode preporučene vrijednosti parametara modela propagacije UWB signala (za PL, PSD, S-V model impulsnog odziva kanala

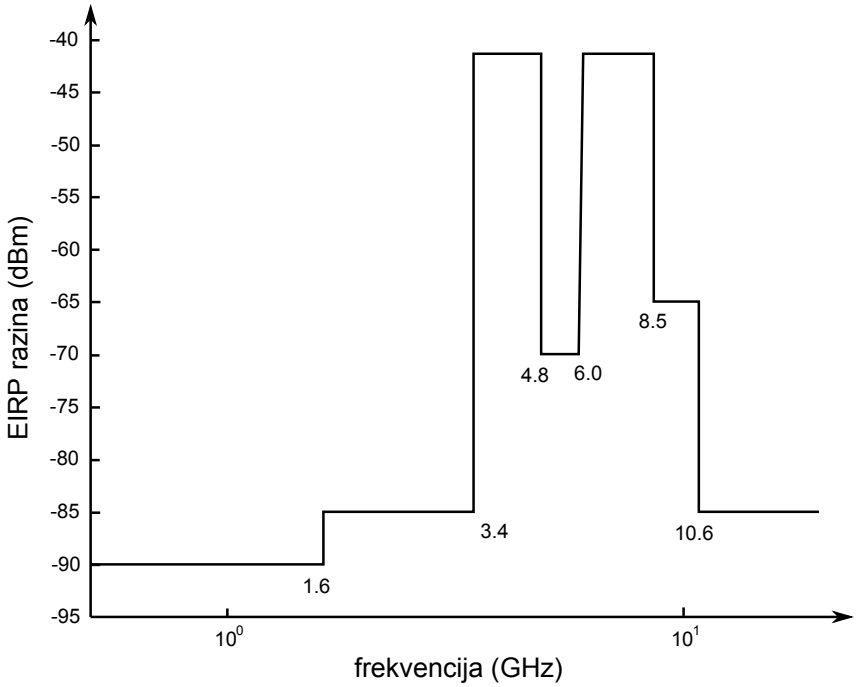

Slika 2.16: ECC spektralna maska za UWB uređaje s implementiranim mjerama za izbjegavanje interferencije

itd., kako je opisano u poglavlju 2.2.2).

Tablica 2.1: Standardizirani modeli komunikacijskih kanala u IEEE 802.15.4a standardu

Naziv modela kanala	**Okruženje za koje se koristi model kanala**
CM-1	LOS uvjet, stambeno okruženje (engl. *Residential LOS*)
CM-2	NLOS uvjet, stambeno okruženje (engl. *Residential NLOS*)
CM-3	LOS uvjet, uredsko okruženje (engl. *Office LOS*)
CM-4	NLOS uvjet, uredsko okruženje (engl. *Office NLOS*)
CM-5	LOS uvjet, vanjsko okruženje (engl. *Outdoor LOS*)
CM-6	NLOS uvjet, vanjsko okruženje (engl. *Outdoor NLOS*)
CM-7	LOS uvjet, industrijsko okruženje (engl. *Industrial LOS*)
CM-8	NLOS uvjet, industrijsko okruženje (engl. *Industrial NLOS*)
CM-9	NLOS uvjet, otvoreno vanjsko okruženje (engl. *Open outdoor environment NLOS*)

2.2.5 Pregled stanja UWB tehnologije

Jedan od osnovnih problema kod svih lokalizacijskih metoda je pitanje ostvarenja optičke vidljivosti (LOS) između baznih i mobilnih stanica, što često nije moguće postići unutar zatvorenih prostora. Nadalje, kod nekih metoda postoji već ranije spomenuti problem višestaznog širenja signala (engl. *multi-path* problem), odnosno refleksija od zidova, predmeta ili osoba u okolici. U takvim uvjetima ne može se samo na temelju primljenog signala biti siguran u njegovo vrijeme propagacije kroz prostor između BS i MS stanice, kao niti u kut ili put dolaska. UWB tehnologija za određivanju položaja objekta predstavlja rješenje koje može na puno bolji način umanjiti probleme kod nedostatka optičke vidljivosti, kao i kod višestaznog širenja signala u primjenama lokalizacije unutar zatvorenih prostora. Također, pokazuje se da se korištenjem UWB tehnologije u zatvorenim prostorima može postići razmjerno visoka točnost pozicioniranja [16]. Spomenute probleme također uspješno rješavaju neke druge metode pozicioniranja (poput analize snage primljenog signala u bežičnim senzorskim mrežama niske potrošnje (RSSI), lokalizacije analizom snage signala u Wi-Fi mrežama itd.), ali te metode ne omogućavaju tako visoku točnost pozicioniranja (u centimetarskom području) koju nudi UWB. Uz prednosti UWB tehnologije, kao što su visoke brzine prijenosa podataka u komunikaciji između čvorova, niska cijena sklopovlja, razmjerno visoka otpornost na pojavu višestaznih signala te sposobnost određivanja položaja i komunikacije u isto vrijeme, UWB tehnologija omogućuje i razmjerno visoku točnost pozicioniranja. Dodatno, UWB signali zbog visokih frekvencijskih komponenti imaju mogućnost prodiranja kroz prepreke kao što su zidovi. LOS u slučaju UWB tehnologije nije nužan uvjet za uspostavu komunikacije ili postupak lokalizacije. Čak i osnovne izvedbe tehnologije postižu točnost od 20 cm, a uz dodatnu obradu signala moguće je dodatno povećanje točnosti, gdje ta tehnologija dostiže čak i sub-milimetarsku točnost [17].

Početna istraživanja UWB tehnologije bila su usredotočena na razna područja, kao npr. dizajn antena, pojačala, optimalni dizajn prijamnika i potrebnih filtara i proces generiranja impulsa [18–23] Istraživale su se mogućnosti nosivih antena (primjerice u tkaninama), unutar i izvan tijela te mogući učinci na ljudsko tijelo [23]. Trenutno UWB tehnologija još uvijek nije zastupljena kao npr. Bluetooth i Wi-Fi, ali to se sve više mijenja. Početni neuspjesi i svojevrsni zastoj u postizanju IEEE standardizacije te naknadno odustajanje od tehnološkog ulaganja od strane industrije rezultirao je time da se UWB tehnologija nije uspjela nametnuti drugim konkurentskim tehnologijama, unatoč određenim tehnološkim prednostima koje nudi. Jedan od razloga takvom razvoju događaja bila je neuspješna IEEE802.15.3a standardizacija pa je UWB tehnologija doživjela veći uspjeh tek u verziji IEEE 802.15.4a standarda koji je omogućio veću preciznost i mogućnost lokalizacije, veći doseg i manju potrošnju energije. IEEE 802.15.4a predviđa primjene gdje su potrebne niske snage odašiljanja i niske brzine prijenosa podataka, ostvarene pomoću DS-UWB. Primarni komercijalni aspekt takvih primjena je u praćenju imovine, senzorskim mrežama i određivanju udaljenosti [24]. Iz tih razloga, sve do prije nekoliko

godina UWB tehnologija bila je rezervirana samo za istraživače koji su imali mogućnost generiranja i detektiranja UWB signala korištenjem skupe laboratorijske opreme. Primjerice, jedna od popularnijih i jeftinijih metoda generiranja UWB signala bila korištenjem SRD (engl. *step recovery diode*) dioda [21]. Sada postoji više proizvođača integriranih sklopovskih rješenja čijim korištenjem korisnici mogu na jednostavan način uključiti UWB tehnologiju u svoje proizvode.

Ubisense je jedna od prvih tvrtki koja je uspješno komercijalizirala UWB tehnologiju za određivanje položaja [25]. Osnovana je 2002. godine u Cambridgeu. U tom razdoblju bili su lideri u rješenjima lokalizacije. Ubisense sustav pozicioniranja sastoji se od mreže senzora koji se instaliraju na fiksnim pozicijama, te UWB oznaka čija se pozicija mora prethodno odrediti. Senzori sadrže niz antena koje su povezane s UWB radio prijemnikom. Senzori izračunavaju položaj oznaka na temelju prijama detektiranih UWB signala koje odašilju Ubisense oznake. Svaki senzor neovisno određuje i kut dolaska (AOA) UWB signala. Podaci o vremenskoj razlici dolaska signala (TDOA) određuju se između para senzora čija su interna vremena sinkronizirana žičanom vezom. Tvrtka ističe da kombinacija AOA i TDOA mjernih tehnika osigurava fleksibilan i robustan sustav određivanja položaja, što omogućuje određivanje precizne lokacije korištenjem samo jednog senzora, kao i precizne 3-D lokacije kada samo dva senzora primaju signal. Tako se integracija AOA i TDOA mjernih metoda može iskoristiti za smanjenje troškova infrastrukture i posljedično instalacije. Uz postavljanje višestrukih senzora može se postići poboljšanje pouzdanosti i robusnosti sustava. Korišteni RF spektar UWB kanala je unutar 6–8 GHz. Postoji dodatni telemetrijski kanal na frekvenciji od 2,4 GHz, koji podržava dvosmjernu komunikaciju radi kontrole sustava i prijenosa telemetrijskih podataka s Ubisense oznaka (primjerice praćenje statusa baterije, gumba, LED dioda itd.) Prema navodima proizvođača, najveći operativni raspon Ubisense senzora veći je od 160 m, dok je maksimalna moguća preciznost bolja od 15 cm u slučaju određivanja položaja u 3-D prostoru. Brzina osvježavanja položaja oznake može se postaviti između 0,1–20 Hz. Komplet sa šest senzora i deset oznaka ima cijenu veću od 20000 eura [26]. Trenutno Ubisense tvrtka prodaje cjelovita rješenja za pametne tvornice i prijevoz.

Slično nestandardno rješenje pruža i tvrtka Humantics (ranije je to bila tvrtka pod nazivom TimeDomain, s *PulsON* serijom uređaja). Tvrtka nudi vlastito rješenje za određivanje položaja i komunikaciju, ali i mogućnost korištenja njihovog uređaja kao UWB radara [27]. Rješenja omogućuju lokalizaciju s točnošću od 1 cm na područjima od 500 m pa sve do milimetarske točnosti u područjima od 20–30 m. Tvrtka se specijalizirala za industrijska rješenja i prikaz promatranih objekata u proizvodnom procesu.

BeSpoon je francuska start-up tvrtka koja je razvila minijaturni IR-UWB sustav [28]. Ta tvrtka je prva pokazala da se UWB tehnologija može uspješno integrirati u pametni telefon. *SpoonPhone* je prototip uređaja koji je prodavan proizvođačima sklopovlja i programerima radi istraživanja i evaluacije. Trenutno su promijenili strategiju i sada se njihovi proizvodi prodaju

se kao modularni setovi opće namjene kako bi korisnici mogli dizajnirati svoja željena rješenja. Moduli nude mogućnosti kao što su preciznost lokalizacije do 10 cm na udaljenostima do 600 m u LOS uvjetima s osjetljivošću prijemnika do -118 dB m. Uređaji koriste UWB kanale od 1 do 4 (3,25–4,75 GHz). Razvojno okružje dostupno je programerima kako bi se u stvarnom vremenu moglo pristupiti podacima o udaljenosti minijaturnih oznaka. Prosječna brzina osvježavanja mjerenja je 2,5 Hz [29].

DW1000 čip, proizvođača DecaWave, usklađen je sa standardom IEEE 802.15.4-2011 i omogućuje mjerenje vremena slanja i primanja UWB signala s razlučivosti od 15,6 ps što znači preciznost od 10 cm u aplikacijama određivanja položaja [30]. Modul istovremeno nudi mogućnost visoke brzine prijenosa podataka (do 6,8 Mb/s) koja se postiže se kombinacijom BPM (engl. *Burst Position odulation*) i BPSK (engl. *Binary Phase Shift Keying*) modulacije, s deklariranim rasponom od 290 m u LOS uvjetima. Visoka otpornost na problem višestaznog prostiranja signala čini ovu platformu idealnom za industrijska i druga okruženja gdje se RF signal reflektira na metalnim površinama. Prema specifikacijama proizvođača, moguće je ažuriranje položaja do 3,5 Hz za jednu pokretnu oznaku (frekvencija ažuriranja se smanjuje u slučaju većeg broja oznaka jer je kanal vremenski multipleksiran). Ono što čini ovog proizvođača dodatno aktraktivnim za budući fokus istraživanja i dizajniranja proizvoda jest njihova velika lista referenci i partnera *.

Slično IC rješenje pruža tvrtka Blinksight sa sličnom preciznošću od 10 cm i nešto manjim dometom od 200 m. Prednost ovog rješenja jest podrška AOA metode određivanja položaja. [31].

U dostupnoj literaturi [26, 29] provedena je evaluacija Ubisense, BeSpoon i DecaWave sustava u NLOS okruženju, kao što je primjerice industrijsko skladište s raznovrsnom opremom koja ometa širenje UWB signala. Pokazalo se da su u takvim uvjetima, performanse DecaWave sustava nešto bolje od BeSpoon sustava i znatno pouzdanije, s obzirom na točnost, od Ubisense sustava. Isto tako, DecaWave sustav se pokazao točnijim od BeSpoon sustava LOS uvjetima, kao i slučajevima kada je UWB signal morao proći kroz prepreke kao što su zidovi u zatvorenom stambenom prostoru. DecaWave koristi napredniji antenski sustav od BeSpoon sustava. Rezultati performansi za Ubisense opremu su niži od DecaWave i BeSpoon sustava bez obzira na dodatnu prednost AOA metode. Broj neispravnih mjerenja otežava dobivanje pouzdane procjene položaja u navedenim uvjetima ispitivanja. Treba uzeti u obzir da Ubisense sustav datira od 2009, dok su BeSpoon i DecaWave rješenja dostupna na tržištu od 2015, odnosno 2016 godine.

*Decawave Partners `https://www.decawave.com/partners/`

2.3 Inercijski senzori

Pod pojmom *inercijskog senzora* podrazumijeva se senzor koji mjeri poziciju, orijentaciju ili kretanje nekog objekta, pri čemu se mjerenja obavljaju s obzirom na vlastiti referentni koordinatni sustav senzora. Tipični predstavnici inercijskih senzora su akcelerometar (engl. *accelerometer*) i žiroskop (engl. *gyroscope*). Akcelerometar mjeri specifičnu silu, odnosno linearnu akceleraciju promatranog objekta, dok žiroskop mjeri kutnu brzinu. Inercijski senzori nalaze svoju primjenu u brojnim područjima, kao što su navigacija, dinamičko upravljanje vozilima, robotika, biomehanika, nadzor ljudske aktivnosti i sl.

Povijesno gledajući, inercijski senzori svoju primjenu najprije su pronašli u navigacijskim sustavima raznih vozila sačinjavajući zajedno s odgovarajućim inercijskim navigacijskim algoritmima *inercijske navigacijske sustave* (engl. *inertial navigation system*, INS). Akcelerometri i žiroskopi tipično se realiziraju tako da se u istom kućištu senzora nalaze tri linearno nezavisno orijentirane senzorske jedinice koje istodobno mjere odgovarajuće parametre. U praktičnim primjenama obično je potrebno prikupljati informacije o poziciji, orijentaciji ili kretanju objekta u tri dimenzije istovremeno. Najčešće su tri senzora orijentirana po ortogonalnim osima, iako postoje i izvedbe koje nisu ortogonalne. Kombiniranjem akcelerometra i žiroskopa u istom kućištu dobivaju se uređaji koji se nazivaju *inercijske mjerne jedinice* IMU, koje obično sadrže troosne akcelerometre i žiroskope integrirane u istom kućištu s unaprijed definiranim i fiksnim međusobnim orijentacijama. Takvi IMU sustav nazivaju se i 6-(engl. *deegres of freedom*, DOF) senzori DOF jer prikupljaju istovremeno tri komponente vektora specifične sile (linearne akceleracije) i tri komponente vektora kutne brzine. S obzirom da se inercijski senzori referiraju prema vlastitom koordinantnom sustavu, jedan od tipičnih problema je kalibracija IMU jedinica kako bi se odredio odnos između unutarnjeg referentnog koordinatnog sustava senzora u kojemu se obavljaju inercijska mjerenja i vanjskog koordinatnog sustava u kojem se promatrani objekt kreće. Naime, kod primjene u navigaciji informacija od interesa je kretanje objekta u vanjskom referentnom koordinatnom sustavu zbog čega je očitanja mjerenja inercijskih senzora potrebno povezati s vanjskim koordinatnim sustavom, što nije trivijalan zadatak.

Kako bi se u praktičnim primjenama olakšao postupak kalibracije senzora, akcelerometrima i žiroskopima često se dodaje i treći senzor, a to je troosni magnetometar. Magnetometar je senzor osjetljiv na jakost magnetskog polja i služi za mjerenje triju komponenti vektora magnetskog polja Zemlje u promatranoj točki. Kombiniranjem izmjerenih vrijednosti iz akcelerometra, žiroskopa i magnetometra moguće je lakše doći do informacije o poziciji, orijentaciji i kretanju objekta u koordinatama vanjskog koordinatnog sustava. Taj isti vanjski koordinatni sustav se tada može povezati s globalnim geografskim koordinatnim sustavom. IMU jedinice koje imaju i dodatni troosni magnetometar nazivaju se još i 9-DOF senzori, zbog dodatna tri stupnja slobode mjerenja komponenti vektora magnetskog polja Zemlje.

U zadnjih nekoliko godina tržište nosivih uređaja (engl. *wearable devices*) ostvarilo je strelovit rast zahvaljujući raspoloživosti i niskoj cijeni IMU senzora u MEMS tehnologiji. Praćenje ljudske aktivnosti inercijskim senzorima interesantno je u brojnim područjima i primjenama, kao primjerice u medicini (npr. praćenje parametara lokomotornog sustava (engl. *gait analysis*), detekcija pada starijih osoba, praćenje kvalitete spavanja itd.), sportu (praćenje aktivnosti tijeka treninga, stanja fizičke spremnosti sportaša, prikupljanje indikacija za predikciju vjerojatnosti nastanka ozljeda i sl.), sučeljima čovjek-računalo (razne napredne izvedbe sustava za upravljanje putem gestura) itd. Sustavi temeljeni na jeftinim i kompaktnim MEMS izvedbama IMU senzora najprikladnija su tehnologija za dinamičko mjerenje parametara i stanja lokomotornog sustava u trodimenzionalnom prostoru u raznim primjenama. Pomoću njih moguće je realizirati malene i lagane senzorske jedinice koje minimalno ometaju normalno funkcioniranje pacijenta, ispitanika ili korisnika sustava.

U nastavku će biti prikazan pregled osnovnih tipova IMU senzora, načela njihovog rada, postupaka kalibracije sustava te izvora pogrešaka. Premda MEMS senzori nude brojne praktične prednosti i čine praćenje ljudske aktivnosti mogućom (za razliku od tradicionalnih IMU jedinica koje se koriste za precizne INS sustave u vozilima te koji svojim dimenzijama, masom i cijenom nisu prikladni za ove primjene), uz njihovu primjenu vezane su i brojne poteškoće. Njihovo korištenje je izazovno i iz tih razloga potrebno je razmotriti integraciju s dodatnim senzorima druge vrste, kojima se mogu otkloniti inherentni nedostaci IMU senzora. Pod time se prvenstveno smatra njihova dugotrajna osjetljivost na klizanje izmjerenih vrijednosti. Kod klasičnih navigacijskih sustava, IMU senzori tipično se kombiniraju s GNSS sustavima, dok će se u kontekstu ovog rada koristiti pristup integracije s UWB sustavima za lokalno precizno pozicioniranje. Kroz opis poteškoća koje donosi korištenje MEMS IMU senzora ujedno će biti prikazana i motivaciju za integraciju IMU senzora s LPS sustavima temeljenima na UWB tehnologiji. Ta će integracija, kako će se kasnije pokazati, biti nužna kako bi se omogućila kvalitetnija detekcija i klasifikacija ljudskog pokreta kroz poboljšanu metodu određivanja orijentacije senzora. Na taj način uz korištenje algoritama i metoda obrade podataka izdvojile su značajke koje opisuju pojedine aktivnosti korisnika primjenom metoda strojnog učenja.

2.3.1 Izvedbe inercijskih senzora

Akcelerometri

Na slici 2.17 prikazano je načelo rada akcelerometra. Unutar tijela senzora nalazi se referentna masa (engl. *proof mass*), koja se može gibati u smjeru osjetljive osi akcelerometra, ali čiji je hod ograničen elastičnim oprugama spojenima na tijelo senzora. Kada dođe do ubrzavanja tijela senzora, referentna masa inicijalno se nastavlja gibati svojom prethodnom brzinom, dok se kućište senzora kreće relativno u odnosu na referentnu masu. To dovodi do stezanja i rastezanja

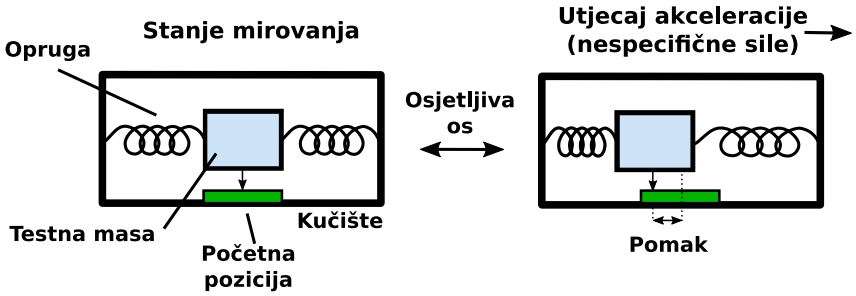

Slika 2.17: Načelo rada akcelerometra

opruga na koje je pričvršćena referentna masa. Gibanje traje sve dok se akceleracija referentne mase ne izjednači s akceleracijom kućišta senzora, uzrokovane vanjskom specifičnom silom. Rezultirajući relativni položaj referentne mase u odnosu na kućište senzora proporcionalan je akceleraciji tijela senzora, a može se izravno mjeriti očitavanjem otklona referentne mase od ravnotežne pozicije.

Za razliku od vanjske primijenjene sile koja uzrokuje ubrzanje kućišta akcelerometra u odnosu na okolišni inercijski sustav u mirovanju, isto tako gravitacijska sila jednako utječe i na kućište senzora. Referentna masa u tom slučaju se ne kreće relativno u odnosu na kućište senzora. Sila koja uzrokuje pomak referentne mase u odnosu na kućište senzora naziva se *specifična sila* (engl. *specific force*) i to je sila koju mjeri akcelerometar. Specifična sila koju mjeri akcelerometar odnosi se na specifičnu silu na kućište akcelerometra u inercijskom koordinatnom sustavu koji miruje u odnosu na okolinu, a u odnosu na kojega se senzor giba.

Za potrebe jasnijeg izlaganja i analize načela rada inercijskih senzora, potrebno je najprije definirati neke važne referentne koordinatne sustave i odgovarajuće notacije koje će se koristiti u razmatranjima koja slijede:

- **koordinatni sustav tijela senzora** (engl. *body frame*, oznaka $\boldsymbol{b}$) predstavlja vlastiti koordinatni sustav samog IMU senzora, s ishodištem u sjecištu triju osjetljivih osi u slučaju inercijskih senzora s tri stupnja slobode. Sva inercijska mjerenja referiraju se prema ovom koordinatnom sustavu.
- **navigacijski koordinatni sustav** (engl. *navigation frame*, oznaka $\boldsymbol{n}$) predstavlja lokalni koordinatni sustav okoline unutar koje se inercijski senzor giba. Kod navigacije potrebno je odrediti odnos između b-sustava u odnosu na okolinu opisanu n-sustavom jer se tipično određuje položaj, brzina, ubrzanje, orijentacija i sl. senzora u n-sustavu. U većini slučajeva može se pretpostaviti da n-sustav miruje u odnosu na Zemlju. U slučaju da senzor prevaljuje velike udaljenosti, tada je n-sustav potrebno translatirati i rotirati u odnosu na globalni koordinatni sustav Zemlje.
- **inercijski koordinatni sustav** (engl. *inertial frame*, oznaka $\boldsymbol{i}$) je stacionarni koordinatni sustav koji se miruje u odnosu na svemir. IMU senzori mjere linearnu akceleraciju i kutnu brzinu u odnosu na i-sustav. Za ishodište i-sustava obično se uzima središte Zemlje.

- **koordinatni sustav Zemlje** (engl. *earth frame*, oznaka $\boldsymbol{e}$) sličan je i-sustavu, ali s tom razlikom da rotira zajedno s planetom Zemljom, tj. nije stacionaran u odnosu na ostatak svemira, već na geografski koordinatni sustav Zemlje.

S obzirom da su jedinični vektori jednaki u sva četiri koordinatna sustava, transformacije koordinata između sustava obavlja se uz pomoću rotacije vektora u tri dimenzije. Neka je npr. $\mathbf{x}^b$ vektor u b-sustavu. Rotacijska matrica $\boldsymbol{R}^{nb}$ tada rotira vektor iz b-sustava u n-sustav, dok se rotacija u suprotnom smjeru obavlja rotacijska matrica $\boldsymbol{R}^{bn} = (\boldsymbol{R}^{nb})^T$. Pretvorba koordinata iz između sustava radi se putem izraza:

$$\mathbf{x}^n = \boldsymbol{R}^{nb}\mathbf{x}^b \tag{2.32}$$

$$\mathbf{x}^b = (\boldsymbol{R}^{nb})^T\mathbf{x}^n = \boldsymbol{R}^{bn}\mathbf{x}^n. \tag{2.33}$$

Akcelerometar mjeri specifičnu silu u vlastitom koordinatnom b-sustavu, što se može izraziti izrazom:

$$\mathbf{f}^b = \boldsymbol{R}^{bn}(\mathbf{a}_{ii}^n - \mathbf{g}^n), \tag{2.34}$$

gdje $\mathbf{g}^n$ označava vektor gravitacije u n-sustavu, a $\mathbf{a}_{ii}^n$ vektor linearne akceleracije u n-sustavu.

Prikaz na slici 2.17 predstavlja jednu od mogućih načelnih izvedbi akcelerometara. Prve izvedbe akcelerometara bile su u potpunosti mehaničke, dok u današnje vrijeme u najvećem broju slučajeva koriste se MEMS izvedbe. Premda se mehaničke izvedbe i dalje koriste u navigacijskim primjenama gdje je potrebno postići visoke performanse IMU jedinica. Praktične izvedbe akcelerometara temelje se uglavnom na jednom od dva načela: mjerenju pomaka referentne mase ili principu vibrirajuće grede [32]. Akcelerometri visokih performansi potrebnih za preciznu navigaciju temeljeni na pomaku referentne mase i dalje se izvode mehanički. Dimenzije, masa i cijena takvih senzora čine ih prikladnima za primjenu npr. kao navigacijskih jedinica u zrakoplovima, ali ne i nosivih senzora za praćenje ljudske aktivnosti. Postoji i treća vrsta akcelerometara koja je danas još uvijek u fazi istraživanja, a to su atomski interferometrijski akcelerometri (engl. *cold-atom intereferometry*) [32], koji mogu pružiti značajno veću preciznost od uobičajenih izvedbi akcelerometara, no zbog svojih specifičnosti i cijene prikladni samo u posebnim primjenama, kao npr. za navigaciju velikih brodova, podmornica ili zrakoplova.

Razvojem MEMS tehnologije akcelerometri se počinju intenzivno koristiti u području praćenja ljudske aktivnosti, ali i mnogim drugim primjenama gdje je potrebno imati kompaktne i jeftine senzore niske potrošnje. Postoji više izvedbi MEMS akcelerometara, a najčešće se koriste piezoelektrički, piezootpornički, kapacitivni i servo upravljani [33], [32]. Svaka od MEMS tehnologija ima svoje specifične prednosti i nedostatke. Primjerice, piezoelektrički akcelerometri imaju razmjerno visoku gornju graničnu frekvenciju i visoki temperaturni raspon, ali nisu pogodni za istosmjerna mjerenja. Piezootpornički s druge strane mogu mjeriti istosmjernu komponentu, imaju izrazito malene dimenzije, malenu nelinearnost, posmak nule i histerezu, ali i

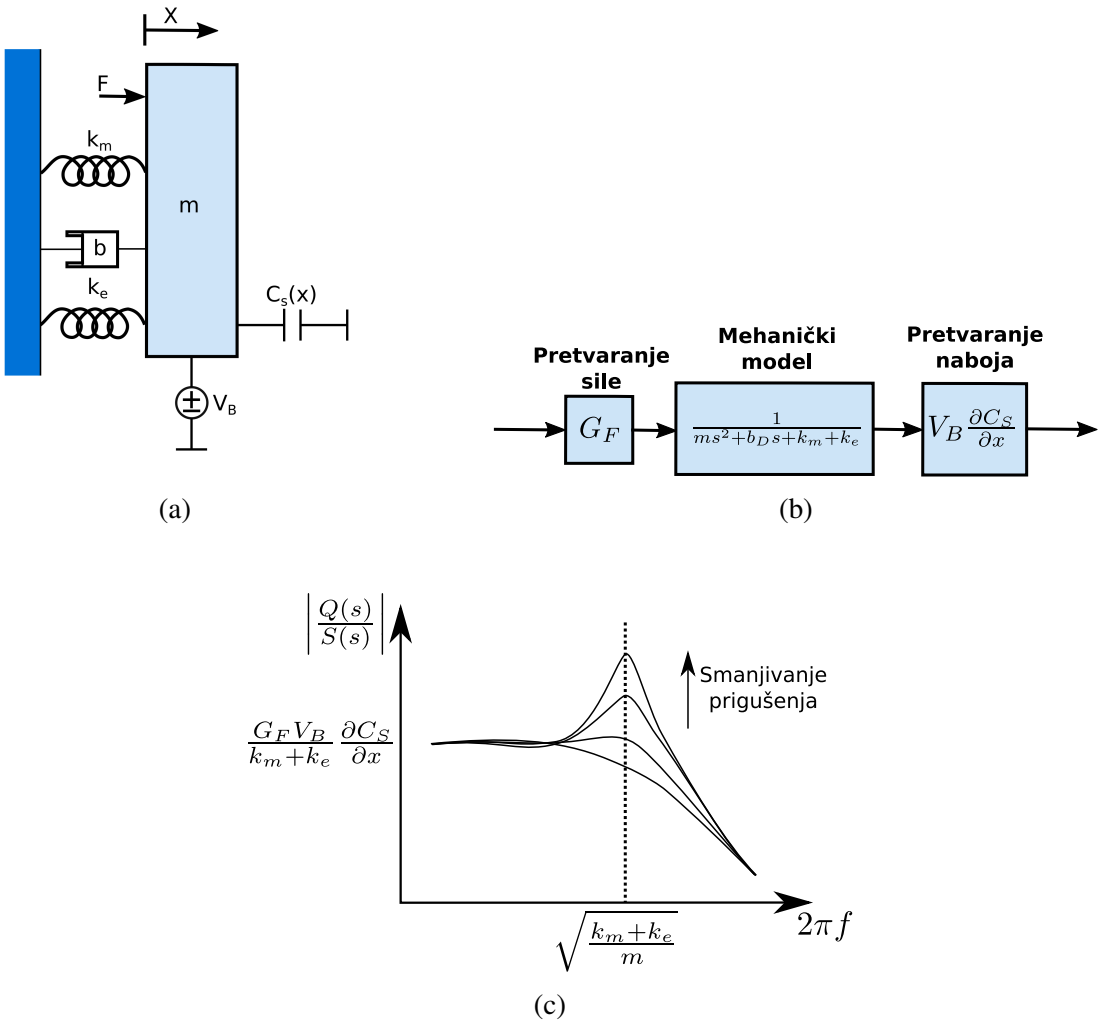

Slika 2.18: Kanonski prikaz IMU senzora kao elektromehaničkog sustava (a) shematski prikaz, (b) ekvivalentni dinamički model sustava drugog reda i (c) frekvencijska karakteristika.

maleni dinamički opseg i visoku osjetljivost na udarce. Kapacitivni akcelerometri također omogućuju istosmjerna mjerenja i jeftini su za izvedbu, ali imaju izraženu temperaturnu osjetljivost te nelinearnost. Servo akcelerometri omogućuju najpreciznija mjerenja i visok mjerni opseg, ali imaju razmjerno veliku masu i dimenzije u odnosu na druge izvedbe akcelerometara.

Koncept i načela rada MEMS IMU senzora mogu se modelirati kanonskim elektromehaničkim sustavom [33] kako je prikazano na slici 2.18. Na shematskom prikazu na slici 2.18a može se vidjeti da je referentna masa m povezana s kućištem senzora preko opruge s konstantnom elastičnosti k_m, a svoj referentni položaj x u odnosu na kućište senzora mijenja pod utjecajem sile F, čije se djelovanje izravno mjeri inercijskim senzorom. Pomak x uzrokovan je linearnom akceleracijom u slučaju akcelerometara, a Coriolisovom akceleracijom kod žiroskopa, pri čemu se za obje vrste inercijskih senzora može koristiti isti referentni model prikazan na slici 2.18. Referentna masa m također je pod utjecajem sile mehaničkog prigušenja sustava vrijednosti proporcionalne brzini mase m, što je na slici 2.18a označeno koeficijentom prigušenja b. Pri-

kazani model može se formalno analizirati kao ekvivalentni dinamički model sustava drugog reda, kako je prikazano na slici 2.18b. Frekvencijska karakteristika tipičnog IMU senzora prikazana je na slici 2.18c, gdje se može uočiti da inercijski senzori, kao sustavi drugog reda imaju rezonantnu frekvenciju, dok se u praksi mjerenja obavljaju u području dovoljno udaljenom od rezonantne frekvencije. U ovisnosti o izvedbi, akcelerometri mogu imati mogućnost istosmjernog mjerenja akceleracije, što znači da mogu mjeriti vrlo spore promjene kretanja u blizini 0 Hz.

Mjerenje pomaka x u MEMS izvedbama akcelerometara najčešće se provodi mjerenjem promjene kapaciteta C između dviju elektroda, od kojih je jedna na referentnoj masi m, a druga na kućištu senzora. Kapacitet mijenja vrijednost u ovisnosti o pomaku x, što je na slici 2.18a naznačeno veličinom $C_s(x)$. Primjerice, ako se na kondenzator dovede fiksna vrijednost napona U_b, promjena naboja uslijed pomaka x može se izraziti izrazom:

$$\Delta Q(\Delta x) = \frac{\partial C_s(x)}{\partial x} U_b \Delta x. \tag{2.35}$$

Ako se izravno mjeri kapacitet, tada se promjena kapaciteta može izraziti preko izraza:

$$C_s(x) = \varepsilon_0 \varepsilon_r \cdot \frac{A}{d+x}, \tag{2.36}$$

gdje je A efektivna površina između elektroda, d razmak elektroda u mirovanju, a ε_0 i ε_r apsolutna i relativna dielektrička konstanta materijala. U slučaju diferencijalne izvedbe kapacitivnog akcelerometra, može se geometrijom senzora postići da se izvedu dva kapaciteta C_1 i C_2, pri čemu iznos jednoga pada, a drugoga raste s pomakom x:

$$C_1(x) = \varepsilon_0 \varepsilon_r \cdot \frac{A}{d+x}, \qquad C_2(x) = \varepsilon_0 \varepsilon_r \cdot \frac{A}{d-x} \tag{2.37}$$

$$\Delta C = \varepsilon_0 \varepsilon_r \cdot \frac{x \cdot A}{d \cdot (d-x)}, \tag{2.38}$$

iz čega slijedi da se pomak x može mjeriti izravno iz razlike kapaciteta ΔC. Kod kapacitivnih MEMS akcelerometara koriste se dvije tipične načelne izvedbe prikazane na slici 2.19: izvedba s paralelnim elektrodama i češljasta izvedba. Kod izvedbe s paralelnim elektrodama promjena kapaciteta posljedica je promjene razmaka među elektrodama, dok se kod češljastih izvedbi koriste elektrode složenijeg oblika s više međusobno isprepletenih segmenata, gdje se uz isti pomak može dobiti značajno veća promjena kapaciteta, a time i osjetljivost senzora.

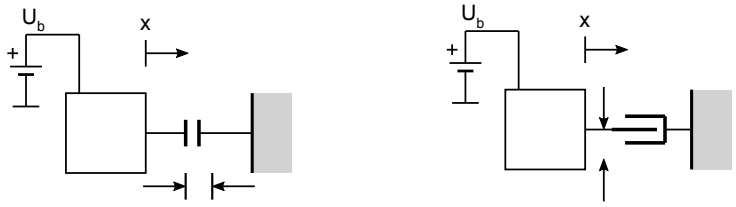

(a) (b)

Slika 2.19: Načelne izvedbe kapacitivnih akcelerometara: (a) izvedba s paralelnim elektrodama, (b) češljasta izvedba.

Žiroskopi

Kod gibanja tijela po zakrivljenoj putanji odstupanje od pravocrtnog gibanja može se aproksimirati, promatrajući ga na dovoljno malenim odsječcima, rotacijskim gibanjem po kružnici radijusa zakrivljenosti r [34], kako je prikazano na slici 2.20. Promjena kuta θ na promatranom radijusu zakrivljenosti gibanja r u nekoj točki putanje u vremenu t označava kutnu brzinu:

$$\omega(t) = \frac{d\theta(t)}{dt}. \tag{2.39}$$

U svakom trenutku kod kružnog gibanja po radijusu zakrivljenosti $r(t)$ obodna brzina gibanja $v(t)$ tangencijalna je na kružnicu koja predstavlja aproksimaciju zakrivljene putanje:

$$v(t) = \omega(t) \cdot r(t). \tag{2.40}$$

Promjena kutne brzine u vremenu opisuje se kutnom akceleracijom:

$$\alpha = \frac{d\omega}{dt} = \frac{d^2\theta}{dt^2}. \tag{2.41}$$

Kod kružnog gibanja konstantnom kružnom brzinom ω obodna brzina v se ne mijenja po iznosu, ali se u svakom trenutku mijenja po smjeru kako bi se zadržalo gibanje po kružnici. Ta se promjena vektora smjera brzine, uz nepromijenjen modul vektora brzine $\mathbf{v}$, može opisati centripetalnom akceleracijom:

$$a = \frac{v^2}{r}, \tag{2.42}$$

gdje a predstavlja akceleraciju konstantnog iznosa čiji vektor pokazuje prema središtu zakrivljenosti kružnog gibanja.

U navigacijskim primjenama mjerenje kutne brzine izuzetno je važno jer se na temelju poznavanja vremenske ovisnosti kutne brzine može pratiti odstupanje objekta od pravocrtnog gibanja kao i njegovo kretanje po proizvoljnoj putanji. S obzirom da se gibanje po proizvoljnoj putanji može rastaviti na aproksimacije kružnog gibanja po odsječcima, mjerenjem kutne brzine u svakom trenutku može se doći do informacije o poziciji objekta korištenjem odgovarajućih

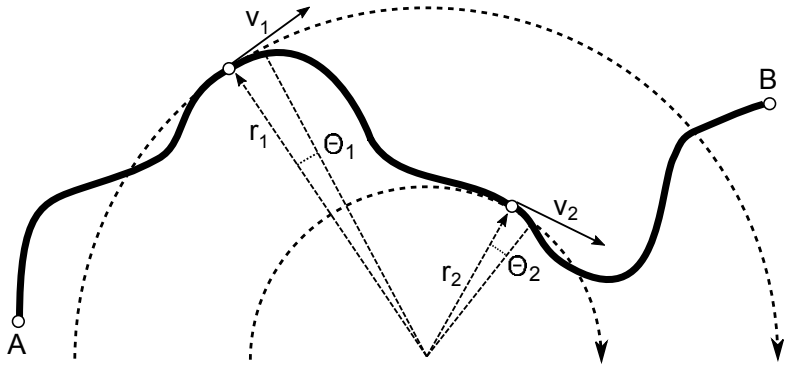

Slika 2.20: Opisivanje gibanja objekta po proizvoljnoj zakrivljenoj putanji po odsječcima kružnim gibanjem

navigacijskih algoritama. Stoga se žiroskop kao instrument koji može direktno mjeriti kutnu brzinu koristi kao jedna od najvažnijih komponenti navigacijskih sustava.

Žiroskopi su po svojoj konstrukciji i izvedbama značajno složeniji od akcelerometara, a služe za izravno mjerenje kutne brzine (u $^\circ\,\mathrm{s}^{-1}$ ili $\mathrm{rad\,s}^{-1}$). Prvu izvedbu žiroskopa temeljenu na sustavu masivnih rotirajućih kugli izradio je Johann Bohnenberger 1817. godine dok je godine 1832. Walter R. Johnson razvio je žiroskop temeljen na rotirajućim diskovima. Mehaničke izvedbe žiroskopa s rotirajućom masom temelje se na zakonu očuvanja kutne količine gibanja, pri čemu rotirajuća masa žiroskopa zadržava nepromijenjen vektor rotacije u odnosu na *i*-sustav, bez obzira na promjenu smjera kretanja ili orijentacije tijela žiroskopa u koordinatnom navigacijskom *n*-sustavu. To vrijedi uz pretpostavku da na rotirajuću masu ne djeluju dodatne sile. Moderne izvedbe žiroskopa ne temelje se uglavnom više na rotirajućoj masi, već na vibracijskim i optičkim izvedbama [32].

Vibracijske izvedbe žiroskopa temelje se na mjerenju Coriolisove sile, koja nastaje kada se objekt kreće brzinom $\mathbf{v}'$ unutar samog rotacijskog referentnog koordinatnog sustava (npr. u odnosu na *b*-sustav samog žiroskopa). Coriolisova akceleracija $\mathbf{a}_c$ računa se preko vektorskog produkta između vektora brzine $\mathbf{v}'$ i kutne brzine $\boldsymbol{\Omega}$:

$$\mathbf{a_c} = -2\boldsymbol{\Omega} \times \mathbf{v}', \tag{2.43}$$

pri čemu je modul vektora $\boldsymbol{\Omega}$ jednak vrijednosti kutne brzine ω i orijentiran uzduž osi rotacije. Coriolisova sila $\mathbf{F}_c$ koja djeluje na objekt mase m koji se kreće unutar *b*-sustava računa se putem izraza:

$$\mathbf{F_c} = -2m(\boldsymbol{\Omega} \times \mathbf{v}'). \tag{2.44}$$

Vibracijske izvedbe žiroskopa koriste vibrirajuću referentnu masu postavljenu unutar tijela žiroskopa, koja se uslijed vibracija kreće brzinom $\mathbf{v}'(t)$ u odnosu na referentni *b*-sustav žiroskopa. Kada je kutna brzina tijela žiroskopa promatrana u *i*-sustavu $\omega \neq 0$, javlja se Coriolisova sila koja djeluje na referentnu masu m, proporcionalna kutnoj brzini ω koja se mjeri. Vibracijske

izvedbe žiroskopa razlikuju se prema načelu na koji se proizvode prisilne vibracije referentne mase, a tipične izvedbe su žiroskop s vibrirajućom vilicom (engl. *tuning-fork*), s vibrirajućim diskom (engl. *vibrating-wheel*) i vibrirajućim prstenom (engl. *vibrating-ring*). Vibracijske izvedbe žiroskopa pogodne su za izvedbu u MEMS tehnologiji, čime je moguće izvesti jeftine i kompaktne žiroskopske senzore niske potrošnje, što ih čini popularnim odabirom u brojnim primjenama, pogotovo za praćenje ljudske aktivnosti. Glavni nedostatak u primjeni MEMS tehnologije za realizaciju IMU senzora su izvori pogrešaka jer je teško postići dobar odnos signal-šum zbog izrazito niskih razina korisnog signala generiranih pomoću MEMS senzora. Primjerice, tipična promjena kapaciteta kod MEMS žiroskopa iznosi nekoliko aF za 1 dps kutne brzine [33], što čini zadržavanje dobrog SNR-a (engl. *signal-to-noise ratio*) tehnološki izazovnim zadatkom. Stoga je kod korištenja MEMS izvedbi inercijskih senzora posebnu pažnju posvetiti izvorima pogrešaka te algoritmima i načinu minimizacije njihovog utjecaja, o čemu će biti nešto više riječi u nastavku.

U navigaciji gdje su potrebni žiroskopi visokih performansi danas se koriste većinom optičke izvedbe žiroskopa koji pružaju najbolje karakteristike. Postoje dvije osnovne izvedbe optičkih žiroskopa: RLG (engl. *ring laser gyro*) i IFOG (engl. *interferometric fiber-optic gyro*) [32]. Takvi tipovi žiroskopa koriste se primjerice u zrakoplovima, projektilima, podmornicama i drugim primjenama gdje su potrebne visoke performanse koje se ne mogu postići MEMS izvedbama. Optički žiroskopi temelje se na načelu odašiljanja svjetlosti unutar rotirajućeg svjetlovoda gdje se put kojega svjetlost treba prijeći mijenja ako sustav rotira. Različitim metodama detekcije promjene duljine puta svjetlosti u ovisnosti o kutnoj brzini može se vrlo precizno izmjeriti kutna brzina rotacije.

2.3.2 Izvori pogrešaka kod inercijskih senzora

Inercijski navigacijski sustavi (INS) koriste IMU senzore kako bi iz mjerenja akceleracije i kutne brzine pomoću akcelerometra i žiroskopa pratili poziciju i orijentaciju objekta u prostoru, poznajući njegovu početnu poziciju, orijentaciju i brzinu [35]. IMU jedinice najčešće sadrže troosne akcelerometre i žiroskope, čije su osjetljive osi pojedinih komponenata mjerenja postavljene ortogonalno. Obradom senzorskih podataka korištenjem navigacijskih algoritama može se pratiti pozicija i orijentacija objekta u navigacijskom n-koordinatnom sustavu. Premda su se INS sustavi inicijalno koristili prvenstveno u području navigacije vozila, pojavom kompaktnih MEMS inercijskih senzora danas se sve više koriste u nosivim uređajima za praćenje ljudske aktivnosti, pri čemu koriste slične algoritme kao i klasični INS sustavi.

Iako su MEMS senzori omogućili korištenje IMU sustava u raznim područjima gdje je važno imati jeftine i kompaktne inercijske senzore, zbog specifičnosti tehnološke izvedbe imaju značajno lošije performanse od klasičnih IMU uređaja koji se koriste u navigaciji. Za njihovu uspješnu primjenu posebno važno dobro poznavati izvore mjernih pogrešaka i načine na koje

se mogu kompenzirati. Također je važno poznavati i postupke kalibracije inercijskih senzora, s obzirom da je za interpretaciju mjernih rezultata potrebno povezati mjerenja koja očitavaju IMU senzori u vlastitom *b*-koordinatnom sustavu s navigacijskim *n*-sustavom u kojem se promatraju i interpretiraju rezultati mjerenja.

Za bolje razumijevanje izvora pogrešaka kod inercijskih senzora važno je također poznavati i dvije osnovne konfiguracije IMU uređaja koje se koriste kod inercijskih navigacijskih sustava. Prva konfiguracija je *sustav sa stabilnom platformom* (engl. *stable platform system*), kod kojeg je inercijski senzor postavljen na platformu koja ga izolira od utjecaja rotacije objekta s obzirom na vanjski navigacijski *n*-sustav. To se postiže korištenjem mehaničkog žiroskopa i gimbala, pri čemu žiroskop služi za stabilizaciju orijentacije platforme u odnosu na vanjski *n*-sustav. Gimbali omogućuju rotaciju platforme oko tri ortogonalne osi, uz zanemarivo trenje. Na taj način IMU jedinica ostaje uvijek poravnata s referentnim vanjskim *n*-sustavom, bez obzira na promjenu prostorne orijentacije objekta čije se kretanje prati. Druga konfiguracija je *sustav bez stabilne platforme* (engl. *strapdown system*), kod kojega IMU senzor prati promjene orijentacije objekta na kojega je ugrađen i nije stabiliziran u odnosu na vanjski referentni *n*-sustav.

Algoritam određivanja orijentacije i pozicije objekta kojega prati IMU senzor u sustavu sa stabilnom platformom prikazan je na slici 2.21a. Preduvjet za primjenu tog algoritma je korištenje klasičnog mehaničkog žiroskopa koji stabilizira platformu, a koji može izravno mjeriti kut rotacije $\theta(t)$ u tri osi na temelju detekcije pomaka osi gimbala uslijed rotacije objekta relativno prema vanjskom *n*-sustavu. Naime, samo se mehaničkim žiroskopom može izravno mjeriti kut orijentacije, dok moderne vibracijske i optičke izvedbe žiroskopa ne mogu izravno mjeriti kut $\theta(t)$, već isključivo kutnu brzinu $\omega(t)$. Kod vibracijskih žiroskopa kutna brzina mjeri se posredno mjerenjem Coriolisove sile pa stoga nije moguće izravno mjerenje orijentacije $\theta(t)$ bez korištenja gimbala i mehaničkog žiroskopa. U slučaju ovakve konfiguracije mjerenje orijentacije je trivijalno jer žiroskop izravno daje $\theta(t)$. Pozicija objekta određuje se iz akceleracije, pri čemu akcelerometar mjeri akceleraciju $\mathbf{a}_b(t)$ u svojem vlastitom *b*-koordinatnom sustavu, ali koji je zbog stabilizirane platforme već poravnat s navigacijskim *n*-sustavom. Od akceleracije koju mjeri akcelerometar potrebno je oduzeti vektor gravitacijske komponente akceleracije kako bi se dobila specifična akceleracija $\mathbf{a}(t)$ koja je mjerodavna za određivanje pozicije u *n*-sustavu. Korekciju gravitacijske komponente jednostavno je napraviti jer su mjerenja IMU senzorom zbog stabilizacije već poravnata s *n*-sustavom. Dvostrukom integracijom korigirane akceleracije dobiva se pozicija objekta.

U praksi se IMU sustavi sa stabilnom platformom ne mogu koristiti kod nosivih senzora, već isključivo prilikom navigacije vozila. Za stabilne platforme potreban je složen, precizan, masivan, velik i skup mehanički postav za stabilizaciju orijentacije IMU senzora. Stoga u slučajevima kada nije moguće koristiti stabilne platforme IMU senzor postavljen na objekt prati njegovu orijentaciju i vlastiti *b*-koordinatni sustav nije poravnat s navigacijskim *n*-sustavom. U tim

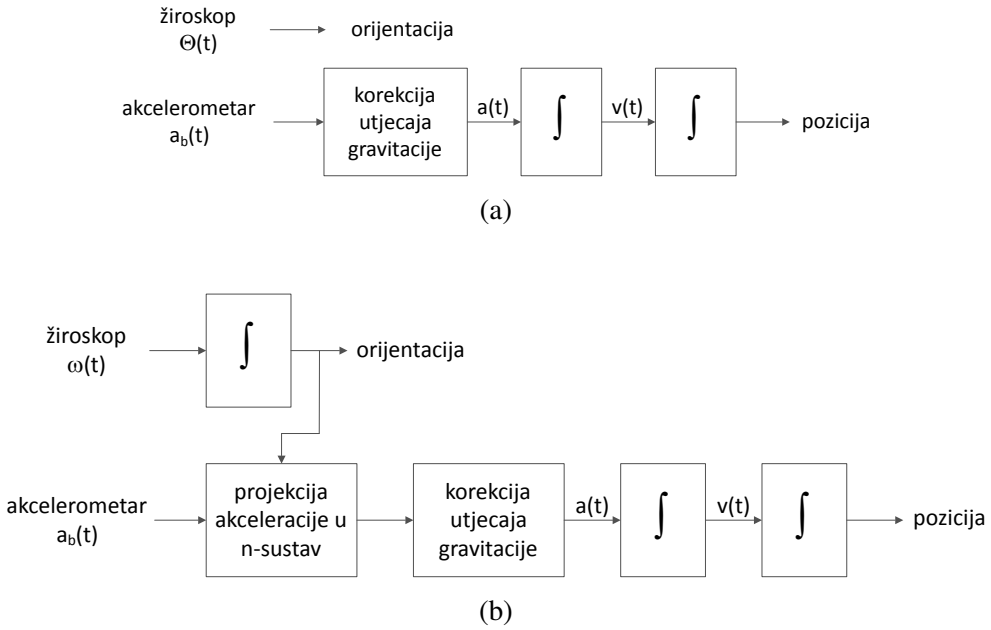

Slika 2.21: Načelni blok dijagrami za navigacijske algoritme za (a) IMU jedinice sa stabiliziranom platformom, (b) IMU jedinice bez stabilizirane platforme.

slučajevima koristi se drugačiji navigacijski algoritam za sustave bez stabilne platforme, kako je to prikazano na slici 2.21b. Bitna razlika u tom algoritmu je da se orijentacija IMU senzora ne može dobiti izravnim mjerenjem kuta $\Theta(t)$, već se mora izračunati integracijom mjerenja kutne brzine $\omega(t)$. Nadalje, akcelerometar mjeri akceleraciju $\mathbf{a}_b$ u vlastitom b-koordinatnom sustavu, pri čemu se orijentacija vektora sile teže $\mathbf{g}_b$ promatrana u tom sustavu mijenja s orijentacijom senzora u vanjskom n-sustavu. Da bi se mogao ukloniti utjecaj gravitacije, potrebno je napraviti projekciju izmjerene akceleraciju na osi n-sustava. Kako bi se to postiglo potrebno poznavati orijentaciju senzora $\theta(t)$ u n-sustavu, što se dobiva integracijom izmjerene kutne brzine $\omega(t)$. Za razliku od sustava sa stabilnom platformom, potreba za integracijom kutne brzine dovodi do propagacije malih mjernih pogrešaka u izračunatom kutu s vremenom, a nesigurnost u određivanju točne orijentacije dodatno nepovoljno utječe na dodavanje parazitskih komponenti nekompenziranog dijela vektora gravitacije izmjerenoj specifičnoj akceleraciji koja je mjerodavna za određivanje pozicije. Dvostruka integracija potrebna za izračun pozicije još u većoj mjeri utječe na propagaciju pogrešaka u konačnom rezultatu pa su mjerenja s IMU senzorima bez stabilne platforme podložna brzom klizanju rezultata u vremenu i visokim mjernim pogreškama kao što je prikazano na slici 2.22b.

Glavni izvori mjernih pogrešaka kod inercijskih senzora su posmak nule, temperaturno klizanje, termomehanički bijeli šum, $1/f$ šum i kalibracijske pogreške.

Posmak nule predstavlja srednju vrijednost izlaza senzora kada je ulazna veličina jednaka nuli. Kod MEMS akcelerometara posmak nule ε_a tipično se izražava u tisućinkama g (mg), a kod žiroskopa ε_g se izražava u mdps. Kod žiroskopa prilikom jednostruke integracije kutne

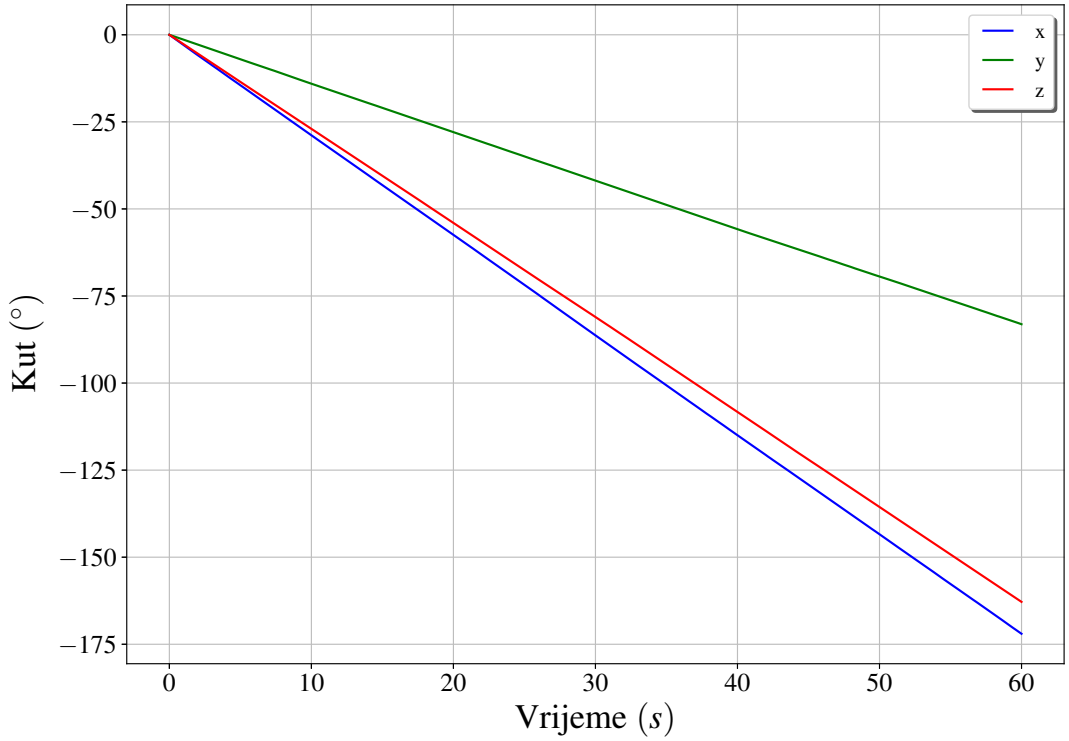

(a)

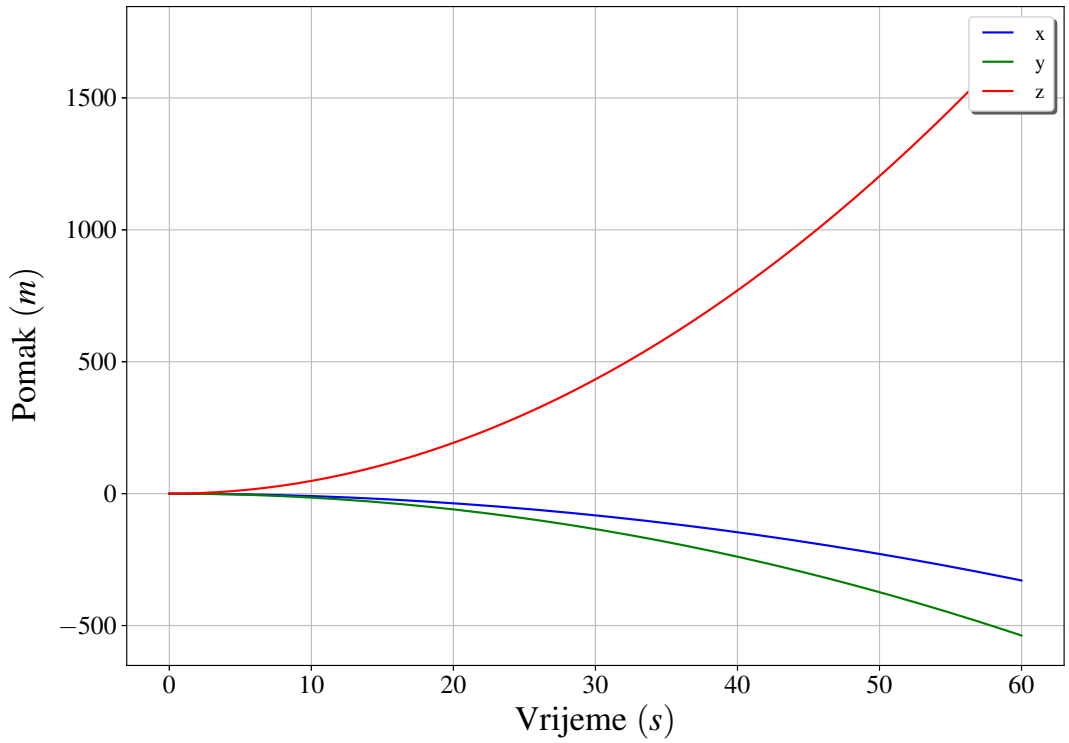

(b)

Slika 2.22: Prikaz integracijske pogreške za (a) troosni žiroskop, (b) troosni akcelerometar LMS9DS0

brzine radi dobivanja kuta orijentacije posmak nule uzrokuje linearni porast pogreške estimacije kuta $\theta(t)$ s vremenom:

$$\theta(t) = \varepsilon_g \cdot t. \tag{2.45}$$

Kod akcelerometara zbog dvostruke integracije akceleracije radi dobivanja pozicije pogreška estimacije pozicije raste kvadratno s vremenom:

$$s(t) = \varepsilon_a \cdot \frac{t^2}{2}. \tag{2.46}$$

Posmak nule kod inercijskih senzora može se smatrati konstantom, iako postoje manje statističke fluktuacije vrijednosti posmaka nule u vremenu. Kod žiroksopa se razmjerno jednostavno može smanjiti pogreška $\theta(t)$ uslijed posmaka nule oduzimanjem vrijednosti posmaka izmjerenog usrednjavanjem kroz određeni vremenski period dok je kutna brzina $\omega = 0$. Međutim, kod akcelerometra je puno teže kalibracijom ukloniti utjecaj posmaka nule jer je potrebno savršeno poravnati osi senzora tako da se može kompenzirati utjecaj vektora gravitacije. Svako odstupanje od savršeno poravnatih ortogonalnih osi uzrokovati će utjecaj vektora gravitacije na kalibrirani posmak nule, što može dovesti do velikih pogrešaka kod dvostruke integracije. Stoga je posmak nule akcelerometra jedan od dominantnih izvora pogrešaka kod IMU senzora. Na slici 2.22 prikazan je primjer vremenskog porasta pogreške integracije kuta i pozicije za nekompenzirani posmak nule žiroskopa i akcelerometra. Na slici se može zorno vidjeti da je svega desetak sekundi dovoljno da pogreška pozicije dvostrukom integracijom izmjerene akceleracije naraste na više od nekoliko metara.

Temperaturno klizanje predstavlja ovisnost mjerene veličine o utjecaju vanjske temperature. Kod inercijskih senzora temperatura utječe na posmak nule senzora i osjetljivost, odnosno koeficijent pretvorbe neelektričke mjerene veličine u električku. Važno je naglasiti da je utjecaj temperature na MEMS inercijske senzore najčešće nelinearan.

Termomehanički bijeli šum uzrokuje stohastičku promjenu sa srednjom vrijednošću nula izlaza iz MEMS inercijskih senzora oko stvarne vrijednosti. Dok se kod senzora koji izravno mjere neku veličinu utjecaj bijelog šuma može značajno umanjiti jednostavnim usrednjavanjem ili niskopropusnim filtriranjem, kod inercijskih senzora bijeli šum izravno utječe na kut i poziciju koji se dobivaju iz inercijskih mjerenja postupcima jednostruke i dvostruke integracije. Utjecaj bijelog šuma na navigacijske veličine može se analizirati sljedećim razmatranjem. Neka je σ standardna devijacija bijelog šuma u izmjerenim vrijednostima kutne brzine ω koju mjeri žiroskop i neka je T_s vrijeme između dva uzroka dobivena iz žiroskopa. Može se pokazati [35] da standardna devijacija kuta σ_θ dobivenog integracijom kutne brzine raste s vremenom prema

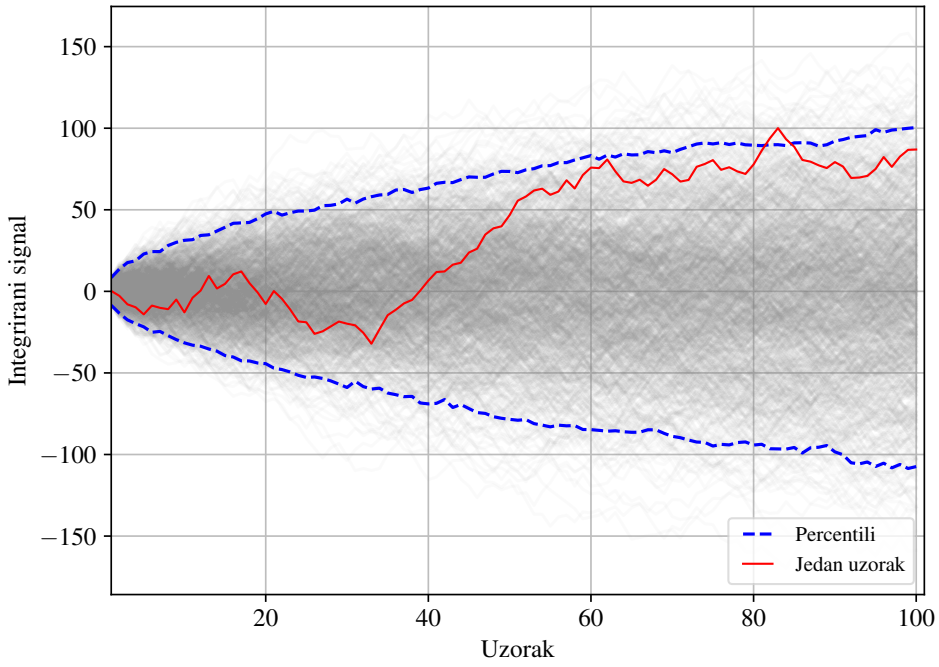

Slika 2.23: Ilustracija vremenske ovisnosti pogreške uslijed jedne integracije bijelog šuma promatrano na 100 realizacija slučajnog procesa opisanog Gaussovom distribucijom $\mathcal{N}(0,1)$ (crveno je označena jedna od realizacija slučajnog procesa)

sljedećem izrazu:

$$\sigma_\theta(t) = \sigma \cdot \sqrt{T_s \cdot t}. \tag{2.47}$$

U slučaju akcelerometra može se pokazati da standardna devijacija pozicije σ_s dobivene dvostrukom integracijom akceleracije raste još brže:

$$\sigma_s(t) \approx \sigma \cdot t^{3/2} \cdot \sqrt{\frac{T_s}{3}}, \tag{2.48}$$

pri čemu veličina σ u 2.48 predstavlja standardnu devijaciju mjerenih uzoraka akceleracije. Na slici 2.22 ilustriran je utjecaj integracijske pogreške bijelog šuma koji se javlja kod inercijskih senzora. Za ilustraciju je uzeto stotinu realizacija jednostruke integracije slučajnog procesa $y(t) \sim \mathcal{N}(0,1)$ gdje se može vidjeti da će statistički očekivana srednja vrijednost svih realizacija slučajnog procesa biti jednaka nuli, ali da će svaka od realizacija bez obzira na to potencijalno odvesti rezultat u neželjenom smjeru od stvarne vrijednosti nula (jedan primjer istaknut je crvenom bojom), pri čemu će se pogreška pogoršavati s vremenom. Formula 2.47 pokazuje da će standardna devijacija rasti s vremenom, premda će statistički očekivana srednja vrijednost promatrana preko svih realizacija slučajnog procesa biti nula. Situacija je još jače izražena kod dvostruke integracije tako da se na temelju prikaza na slikama 2.22 i 2.23 može zaključiti da klizanje vrijednosti u vremenu kod inercijskih senzora nastaje i zbog nekompenzirane vrijednosti posmaka nule i zbog bijelog šuma.

Utjecaj $1/f$ šuma (engl. *flicker noise*) odnosi se na spore slučajne promjene posmaka nule senzora. Ovaj tip šuma karakterizira porast spektralne gustoće snage šuma na niskim frekvencijama i tpično se javlja u raznim elektroničkim sklopovima pa time i u MEMS senzorima. Modelira se slučajnim hodom (engl. *random walk*), ali uz ograničeni raspon unutar kojega su dozvoljene promjene posmaka nule. U kalibracijske pogreške spadaju sve tehnološke, mehaničke i električne nesavršenosti u realizaciji IMU senzora. To se odnosi primjerice na nesavršnosti poravnavanja osjetljivih osi senzora, nelinearnost prijenosne karakteristike senzora i sl., a koje se mogu uočiti samo za vrijeme dok je senzor podvrgnut vanjskom inercijskom djelovanju, kutnoj brzini u slučaju žiroskopa i akceleraciji kod akcelerometra.

2.3.3 Određivanje orijentacije inercijskih senzora

Određivanje orijentacije pomoću žiroskopa

Inercijski senzori mjerenja referenciraju prema vlastitom b-koordinatnom sustavu dok se rezultati interpretiraju u navigacijskom n-sustavu. Prilikom praćenja orijentacije i položaja ljudskog tijela ili njegovih dijelova, tipično se na osobi nalazi više nosivih inercijskih senzora. Za dobivanje uvida u cjelokupnu informaciju o orijentaciji i položaju potrebno je sve rezultate prevesti iz svakog b_k-sustava u zajednički n-sustav, pri čemu b_k označava da svaki k-ti inercijski senzor postavljen na ljudsko tijelo ima neovisnu orijentaciju koordinatnih osi promatranih u vanjskom n-sustavu.

Rotacijske matrice operacijom matričnog množenja rotiraju vektor u prostoru, pri čemu se njegova duljina ne mijenja. Specijalnu ortogonalnu grupu 3×3 rotacijskih matrica $SO(3)$ čine matrice za koje vrijedi:

$$SO(3) = \left\{ \mathbf{R} \in \mathbb{R}^{3\times 3} : \mathbf{R}\mathbf{R}^T = \mathbf{I}, \det(\mathbf{R}) = +1 \right\}. \tag{2.49}$$

Ako je neki vektor $\mathbf{a}^b$ izražen u vlastitom b-koordinatnorm sustavu IMU senzora, tada se njegova reprezentacija u navigacijskom n-sustavu $\mathbf{a}^n$ može dobiti korištenjem rotacijske matrice $\mathbf{R}$:

$$\mathbf{a}^n = \mathbf{R}\mathbf{a}^b. \tag{2.50}$$

Obrnuta transformacija dobiva se putem izraza:

$$\mathbf{a}^b = \mathbf{R}^T\mathbf{a}^n. \tag{2.51}$$

Kod reprezentacije rotacijskih matrica mogu se koristiti različite notacije. Često korištena notacija temelji se na kosinusima kuteva između koordinatnih osi (engl. *direction cosine*), a odgovarajuća rotacijska matrica koja koristi tu notaciju $\mathbf{R}$ u literaturi naziva se (engl. *direc-*

tion cosine matrix, DCM). Elementi DCM matrice su kosinusi pozitivnih kuteva između parova koordinatnih osi. Ako imamo dva koordinatna sustava (x,y,z) i (x',y',z') i kuteve između pojedinih osi označimo s $\theta_{a',b}$, tada DCM rotacijska matrica ima sljedeći oblik:

$$R = \begin{bmatrix} \cos\theta_{x',x} & \cos\theta_{x',y} & \cos\theta_{x',z} \\ \cos\theta_{y',x} & \cos\theta_{y',y} & \cos\theta_{y',z} \\ \cos\theta_{z',x} & \cos\theta_{z',y} & \cos\theta_{z',z} \end{bmatrix}. \tag{2.52}$$

Iz zapisa 2.52 proizlazi da rotacije oko pojedinih osi mogu zapisati kao:

$$R_x = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\alpha & \sin\alpha \\ 0 & -\sin\alpha & \cos\alpha \end{bmatrix} \tag{2.53}$$

$$R_y = \begin{bmatrix} \cos\alpha & 0 & -\sin\alpha \\ 0 & 1 & 0 \\ \sin\alpha & 0 & \cos\alpha \end{bmatrix} \tag{2.54}$$

$$R_z = \begin{bmatrix} \cos\alpha & \sin\alpha & 0 \\ -\sin\alpha & \cos\alpha & 0 \\ 0 & 0 & 1 \end{bmatrix} \tag{2.55}$$

Rotacijska matrica također se može izraziti putem Eulerovih kuteva propinjanja (engl. *pitch*), valjanja (engl. *roll*) i skretanja (engl. *yaw*). Vektor Eulerovih kuteva se tada može zapisati kao:

$$\mathbf{u} := [\phi, \theta, \psi]^T. \tag{2.56}$$

Definicije pojednih kuteva orijentacije prikazane su na slici 2.24, dok su nazivi su povezani s tradicionalnom primjenom u navigaciji zrakoplova. Tada se ukupna rotacijska matrica R_{xyz} može izraziti kao umnožak rotacijskih matrica oko pojedinih osi:

$$R_{xyz}(\phi,\theta,\psi) := R_x(\phi)R_y(\theta)R_z(\psi). \tag{2.57}$$

Postoje 12 različitih sekvenci umnožaka pojedinih rotacijskih matrica od kojih je slijed $z-$

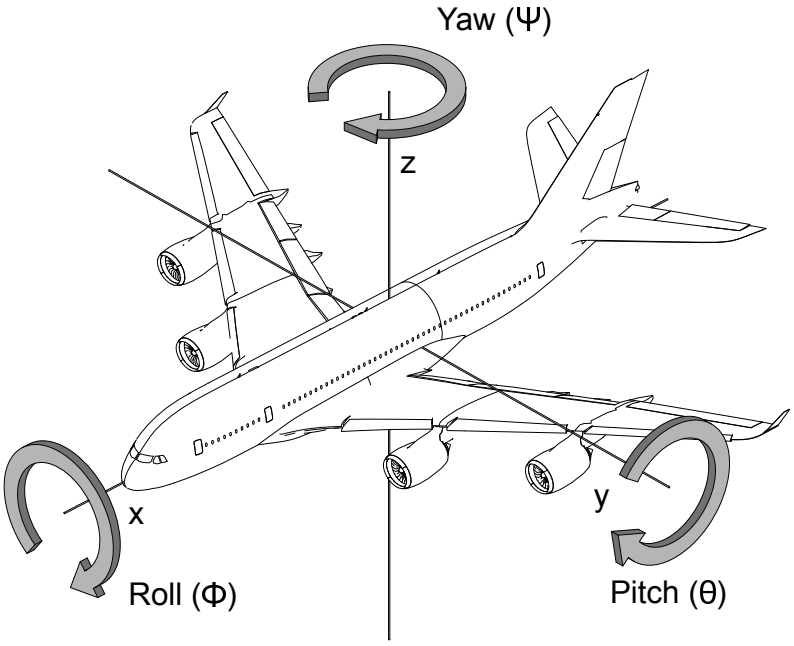

Slika 2.24: Definicija kuteva valjanja (*roll*), propinjanja (*pitch*) i skretanja (*yaw*)

$x-y$ korišten u ovom radu. Problem koji se javlja kod rotacije korištenjem Eulerovih kuteva jest u jednoznačnosti rješenja jer postoje konfiguracije orijentacija kod kojih se može izgubiti informacija o orijentaciji jedne od osi (engl. *gimbal lock*). Dodatno, ova interpretacija koristiti trigonometrijske funkcije koje u nekim određenim kombinacijama orijentacija mogu postati numerički nestabilne te davati netočne estimacije.

Za razliku od Eulerovih kuteva, notacija temeljena na kvaternionima nema problema sa singularnostima i jednostavnija je za implementaciju. Ipak, činjenica je da se kod kvaterniona koristi reprezentacija s kompleksnim brojevima. Matematički zapis kvaterniona nastao je kao algebarska ekstenzija kompleksnih brojeva:

$$\mathbf{q} = q_0 + q_1 i + q_2 j + q_3 k, \tag{2.58}$$

gdje su q_0, q_1, q_2, q_3 realni brojevi. S ovakvim zapisom, tri uzastopne rotacije mogu biti zapisane kao rotacija oko jednog vektora definiranog uz pomoć 2.58. Uzmemo li neku rotaciju θ oko osi definirane s DCM matricom s kutevima $\cos(\alpha), \cos(\beta), \cos(\gamma)$, tada rotaciju vektora $\mathbf{a}$ možemo izraziti kao:

$$\mathbf{a}^n = \mathbf{q} \otimes \mathbf{a}^b \otimes \mathbf{q}^*, \tag{2.59}$$

gdje $\mathbf{q}^*$ predstavlja kompleksnu konjugaciju vektora $\mathbf{q}$ koji je oblika:

$$\mathbf{q} = \cos\frac{\theta}{2} + \sin\frac{\theta}{2}(\cos\alpha i + \cos\beta j + \cos\gamma k), \tag{2.60}$$

dok $\otimes$ predstavlja funkciju umnoška dvaju kvaterniona. Važno je za napomenuti da umnožak

nije komutativan. Ovaj pristup se općenito koristiti prilikom izračunavanja orijentacije jer je u usporedbi s Eulerovim kutevima efektivan na cijelom prostoru vrijednosti. Dodatno, rotacije isključuju korištenje trigonometrijskih funkcija te je zbog toga efikasniji za izvođenje na platformama s ograničenim resursima. Više o pojedinim zapisima i transformacijama između njih može se pronaći u [36].

Određivanje orijentacije pomoću žiroskopa

Za određivanje orijentacije senzora u *n*-sustavu potrebno je provesti vremensku integraciju komponenti kutne brzine mjerenih troosnim žiroskopom, pri čemu se očitanja sa senzora $\omega_b(t) = [\omega_{bx}(t)\omega_{by}(t)\omega_{bz}(t)]^T$ dobivaju u vlastitom koordinatnom sustavu žiroskopa. Zatim je potrebno ta očitanja transformirati u navigacijski *n*-sustav, pri čemu se za transformaciju orijentacije vektora između različitih koordinatnih sustava koriste rotacijske matrice.

Za određivanje orijentacije senzora u prostoru integracijom mjerene kutne brzine potrebno je pratiti rotacijsku matricu $\mathbf{R}(t)$ koja se mijenja u vremenu s promjenom orijentacije senzora. Ako $\mathbf{R}(t)$ opisuje orijentaciju senzora u trenutku t, tada se vremenska derivacija promjene orijentacije može zapisati kao:

$$\dot{\mathbf{R}}(t) = \lim_{\delta t \to 0} \frac{\mathbf{R}(t+\delta t) - \mathbf{R}(t)}{\delta t}. \tag{2.61}$$

Element $\mathbf{R}(t+\delta t)$ u formuli 2.61 može se zapisati kao umnožak dviju matrica:

$$\mathbf{R}(t+\delta t) = \mathbf{R}(t) \cdot \mathbf{A}(t), \tag{2.62}$$

gdje je $\mathbf{A}(t)$ rotacijska matrica koja povezuje rotacijske matrice senzora u vremenu t i $(t+\delta t)$. Neka vektor $[\delta\phi \ \ \delta\theta \ \ \delta\psi]^T$ opisuje relativnu rotaciju koordinatnih osi *b*-sustava u odnosu na *n*-sustav u vremenu od t do $(t+\delta t)$. Tada se matrica $\mathbf{A}(t)$ može zapisati kao:

$$\mathbf{A}(t) = \mathbf{I} + \delta\Psi, \tag{2.63}$$

gdje je

$$\Psi = \begin{bmatrix} 0 & -\delta\psi & \delta\theta \\ \delta\psi & 0 & -\delta\phi \\ -\delta\theta & \delta\phi & 0 \end{bmatrix}. \tag{2.64}$$

Uvrštavanjem u 2.61 dobiva se:

$$\dot{\mathbf{R}}(t) = \mathbf{R}(t) \lim_{\delta t \to 0} \frac{\delta\Psi}{\delta t}. \tag{2.65}$$

Kada $\delta \to 0$ za aproksimaciju kod malih kuteva vrijedi da je:

$$\lim_{\delta t \to 0} \frac{\delta \Psi}{\delta t} = \Omega(t), \tag{2.66}$$

gdje je $\Omega(t)$ izražen formulom:

$$\Psi(t) = \begin{bmatrix} 0 & -\omega_{bz}(t) & \omega_{by}(t) \\ \omega_{bz}(t) & 0 & -\omega_{bx}(t) \\ -\omega_{by}(t) & \omega_{bx}(t) & 0 \end{bmatrix}, \tag{2.67}$$

gdje su elementi matrice $\omega_{bx}(t)$, $\omega_{by}(t)$ i $\omega_{bz}(t)$ komponente kutne brzine $\omega(t)$ koju troosni žiroskop mjeri u vlastitom b-sustavu u trenutku t. Algoritam za praćenje orijentacije mora riješiti sljedeću diferencijalnu jednaždbu:

$$\dot{\mathbf{R}}(t) = \mathbf{R}(t)\Omega(t), \tag{2.68}$$

čije se rješenje dobiva integracijom:

$$\mathbf{R}(t) = \mathbf{R}(0) \cdot \exp\left(\int_0^t \Omega(\tau) d\tau\right). \tag{2.69}$$

Matrica $\mathbf{R}(0)$ predstavlja početnu rotacija senzora u trenutku $t = 0$.

Određivanje orijentacije pomoću akcelerometra i magnetometra

Kada je inercijski senzor nepokretan i na njega ne djeluje neka vanjska sila, njegova orijentacija može se odrediti uz pomoć specifičnog vektora gravitacije Zemlje. Korištenjem Eulerovih kuteva i rotacijskih matrica možemo doći do sljedećih izraza za kut skretanja i valjanja:

$$\hat{\theta} = \arctan\left(\frac{a_x}{\sqrt{(a_y)^2 + (a_z)^2}}\right), \tag{2.70}$$

$$\hat{\phi} = \arctan_2\left(\frac{-a_y}{-a_z}\right), \tag{2.71}$$

pri čemu a_x, a_y, a_z predstavljaju mjerenja akcelerometra u pojedinim osima. Važno je primijetiti da se za kut valjanja mora koristiti $\arctan_2$ funkcija. Točnost određivanja orijentacije u ovom slučaju je određena s mjernom pogreškom samog akcelerometra. Kratkotrajni pomaci i mehaničke vibracije mogu se ukloniti s jednostavnim usrednjavanjem mjerenja u nekom vremenskom prozoru.

S obzirom da se kut propinjanja ψ ne može jednoznačno odrediti iz akcelerometarskih mjerenja, potrebna su dodatna mjerenja magnetometra kako bi se mogao on mogao estimirati. Korištenjem magnetometarskih mjerenja u trima osima m_x, m_y, m_z te sa prije određenim kutevima skretanja i valjanja, možemo doći do sljedećih izraza za kut propinjanja:

$$\hat{\psi} = \arctan_2 \begin{pmatrix} -m_y \cos\hat{\phi} + m_y \sin\hat{\phi}, \\ m_x \cos\hat{\theta} + m_y \sin\hat{\theta} + m_z \cos\hat{\phi} \sin\hat{\theta} \end{pmatrix} \pm D, \tag{2.72}$$

gdje je D kut otklona magnetskog od geografskog sjevernog pola. Globalni modeli koji pružaju vrijednost magnetskog otklona D kao što su IGRF (engl. *International Geomagnetic Reference Field*) i WMM (engl. *US/UK World Magnetic Model*) ažuriraju se svakih 5 godina i općenito imaju grešku od 0,5° pa sve nekoliko stupnjeva u nekim područjima [32].

Važno je za napomenuti MEMS magnetometri ne mjere samo Zemljino polje već i sve druge izvore magnetskih polja u neposrednoj blizini senzora. Ti izvori magnetskih polja, kao što su metalna kućišta mjernog uređaja, metalne noge od namještaja ili izvori napajanja u blizini, mogu unijeti po nekoliko stupnjeva pogreške prilikom određivanja kuta orijentacije IMU senzora. Općenito se problemi ovakve vrste uklanjaju prepoznavanjem i izbacivanjem prepoznatih anomalija ili pak kalibracijom s obzirom na mjesto korištenja samog senzora. Prva metoda ne jamči detekciju i uklanjanje svih anomalija, dok druga limitira korištenje IMU senzora na određeno područje gdje su izvori smetnji bili prethodno uzeti u obzir s kalibracijom.

Metode senzorske fuzije

Kako bi se što bolje estimirala orijentacija, može se koristiti i pristup senzorske fuzije. Ovaj pristup kombinira različite izvore mjerenja s ciljem smanjivanja nesigurnosti krajnje estimacije. Primjerice, istovremenim korištenjem orijentacija dobivenih korištenjem žiroskopa, akcelerometra, i magnetometra možemo umanjiti utjecaj grešaka pomaka i raznih izvora šuma. Izvori mjerenja mogu se koristiti direktno (engl. *tightly*) ili indirektno (engl. *loosely*) prilikom fuzije. Indirektni pristup podrazumijeva korištenje podataka koji su, prije samog korištenja izračuna krajnje estimacije, bili prethodno obrađeni. Suprotno tome, direktni pristup podrazumijeva korištenje podataka izravno iz senzora prilikom procesa fuzije. Ako je funkcija gustoće vjerojatnosti estimirane vrijednosti poznata, i jedan i drugi pristup daju slične rezultate [37]. U praksi, funkciju gustoće vjerojatnosti nije uvijek moguće odrediti te je moguć gubitak informacija prilikom korištenja indirektne metode fuzije senzorskih podataka. Odabir metode zavisi o primjeni i estimiranoj mjernoj veličini.

Najjednostavniji oblike fuzije informacija dobivenih orijentacija pomoću modela opisanih s 2.69, 2.71, 2.70 i 2.72 je putem njihovog omjera. Ako izrazimo orijentaciju dobivenu praćenjem

promjene kuta žiroskopom u obliku kvaterniona q_g i orijentaciju dobivenu akcelerometrom i magnetometrom kao $q_{a/m}$ tada se fuzija informacija može izraziti kao:

$$q(k) = \gamma \cdot q_g(k) + (1-\gamma) \cdot q_{a/m}(k), \tag{2.73}$$

gdje je γ težina čija se optimalna vrijednost određuje u ovisnosti o primjeni, dok su q_g i $q_{a/m}$ prethodno određene orijentacije IMU senzora korištenjem žiroskopa odnosno akcelerometra i magnetometra [38] ili tokom dizajna komplementarnog filtra [38–40]. Zapis orijentacija u jednadžbi 2.73 je izveden u obliku kvaterniona.

Od složenijih metoda senzorske fuzije izdvajaju se prošireni Kalmanov filtar (engl. *extended Kalman filter*, EKF) kao i komplementarni filtar (engl. *Complementary Filter*) te različite metode optimizacija. Kalmanov filtar (KF) koristi se kod linearnih sustava i temelji se na statističkim metodama gdje se stanje sustava modelira uz pomoć Gaussove raspodjele i najraširenija je pristup za kompenzaciju pomaka mjerenja [1]. Estimator se temelji na Bayesovoj metodi, gdje se uz set inicijalnih pretpostavki o stanju sustavu rekurzivno izračunava estimacija s obzirom na prethodna i trenutna mjerenja. EKF predstavlja nadogradnju na osnovni oblik Kalmanovog filtra u slučaju kada je promatrani sustav nelinearan, odnosno kada su izrazi koji opisuju ponašanje cjelokupnog sustava nelinearnog oblika. Cijeli sustav filtriranja se može opisati kao:

$$x_{t+1} = f_t(x_t, u_t, w_t) \tag{2.74}$$

$$y_t = h_t(x_t) + e_t, \tag{2.75}$$

gdje su $w_t \sim \mathcal{N}(0,Q)$ i $e_t \sim \mathcal{N}(0,R)$ izvori šuma procesa i mjerenja s konstantnim kovarijancama. Estimacija se tada rekurzivno određuje u dva koraka. U prvom koraku određuje se predikcija stanja na temelju jednadžbi stanja:

$$\bar{x}_{t+1|t} = f(\bar{x}_{t|t}, u_t) \tag{2.76}$$

$$P_{t+1|t} = F_t P_{t|t} F_t^T + G_t Q G_t^T, \tag{2.77}$$

gdje su:

$$F_t = \left.\frac{\partial f_t(x_t, u_t, w_t)}{\partial x_t}\right|_{\substack{w_t=0 \\ x_t=\bar{x}_{t|t}}}, \quad G_t = \left.\frac{\partial f_t(x_t, u_t, w_t)}{\partial v_t}\right|_{\substack{w_t=0 \\ x_t=\bar{x}_{t|t}}}, \tag{2.78}$$

parcijalne derivacije funkcija promjena stanja, odnosno Jakobijani. S matricom P označavamo ukupnu kovarijancu sustava. Funkcija promjene stanja sustava označena je s $f(\bar{x}_{t|t}, u_t)$, mjerna funkcija je označena s $h_t(x_t)$, dok u_t predstavlja vektor ulaza u estimator. Oznake $t+1|t$ označavaju da se te vrijednosti estimiraju za trenutak $t+1$ i uključuju mjerenja sve do trenutka t.

Slično, oznake $t|t$ označavaju estimaciju stanja sustava u trenutku t i uključuju sva mjerenja do trenutka t. Iza predikcije slijedi korak korekcije stanja sustava na temelju novih mjerenja y_t:

$$\bar{x}_{t|t} = \bar{x}_{t|t-1} + K_t \varepsilon_t, \tag{2.79}$$

$$P_{t|t} = P_{t|t-1} - K_t S_t K_t^T, \tag{2.80}$$

pri čemu su K_t Kalmanovo pojačanje, S_t označava nesigurnost sustava a y_t označava ostatak odnosno razliku između trenutnog mjerenja i predikcije. Matematički varijable se izražavaju kao:

$$\begin{aligned} y &\triangleq z_t - \bar{z}_{t|t-1} \\ \bar{z}_{t|t-1} &= h(\bar{x}_{t|t-1}) \end{aligned} \tag{2.81}$$

$$\begin{aligned} S_t &\triangleq H_t P_{t|t-1} H_t^T + R \\ H_t &= \left.\frac{\partial h_t(x_t)}{\partial x_t}\right|_{x_t = \bar{x}_{t|t-1}} \end{aligned} \tag{2.82}$$

$$K_t \triangleq P_{t|t-1} H_t^T S_t^{-1} \tag{2.83}$$

Razlike između linearnog i proširenog Kalmanovog filtra u vektorskoj formi se mogu sumirati sljedećim jednadžbama:

	linearni Kalman filter	prošireni Kalman filter
korak predikcije		$\mathbf{F} = \left.\frac{\partial f(\mathbf{x}_t, \mathbf{u}_t)}{\partial \mathbf{x}}\right\|_{\mathbf{x}_t, \mathbf{u}_t}$
	$\bar{\mathbf{x}} = \mathbf{F}\mathbf{x} + \mathbf{B}\mathbf{u}$	$\bar{\mathbf{x}} = f(\mathbf{x}, \mathbf{u})$
	$\bar{\mathbf{P}} = \mathbf{F}\mathbf{P}\mathbf{F}^\mathsf{T} + \mathbf{Q}$	$\bar{\mathbf{P}} = \mathbf{F}\mathbf{P}\mathbf{F}^\mathsf{T} + \mathbf{Q}$
korak korekcije		$\mathbf{H} = \left.\frac{\partial h(\bar{\mathbf{x}}_t)}{\partial \bar{\mathbf{x}}}\right\|_{\bar{\mathbf{x}}_t}$
	$\mathbf{y} = \mathbf{z} - \mathbf{H}\bar{\mathbf{x}}$	$\mathbf{y} = \mathbf{z} - h(\bar{x})$
	$\mathbf{K} = \bar{\mathbf{P}}\mathbf{H}^\mathsf{T}(\mathbf{H}\bar{\mathbf{P}}\mathbf{H}^\mathsf{T} + \mathbf{R})^{-1}$	$\mathbf{K} = \bar{\mathbf{P}}\mathbf{H}^\mathsf{T}(\mathbf{H}\bar{\mathbf{P}}\mathbf{H}^\mathsf{T} + \mathbf{R})^{-1}$
	$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{K}\mathbf{y}$	$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{K}\mathbf{y}$
	$\mathbf{P} = (\mathbf{I} - \mathbf{K}\mathbf{H})\bar{\mathbf{P}}$	$\mathbf{P} = (\mathbf{I} - \mathbf{K}\mathbf{H})\bar{\mathbf{P}}$

(2.84)

Više o samoj implementaciji matrica, odnosno funkcija F_t, G_t i H_t uz pomoć kvaterninona, kao i algoritmu može se pronaći u [40, 41]. Prema izloženom, metoda je matematički zahtjevnija za izvođenje i stoga se kod rada u stvarnom vremenu, pogotovo na ograničenim ugradbenim računalnim sustavima, preferiraju algoritmi temeljeni na komplementarnom filtru zbog manjih zahtjeva za izračune. Primjerice u [40] usporedbom vlastite implementacije komplementarnog filtra temeljenog na kvaternionima s EKF metodom može se primijetiti razlika od 6 ms u vremenu potrebnom za izračunavanje orijentacije na računalu opće namjene. Iako su komplementarni filtri jednostavniji za izračun, po performansama usporedivi su s EKF filtrom [42].

Također, često korištena implementacija filtra za određivanje orijentacije temelji se na Mahonyevom algoritmu [39]. Njihovo rješenje se temelji na analizi Lie grupa i nelinearnoj reprezentaciji promatrača u SO(3) grupi. Kroz analizu SO(3) grupa dolaze do definicija direktnog (engl. *Direct Complementary Filter*) i pasivnog (engl. *Passive Complementary Filter*) komplementarnog filtra čiju krajnju implementacija zovu eksplicitnim komplementarnim filtrom (engl. *Explicit Complementary Filter*) koji koristi direktna mjerenja usmjerenja gravitacijskog i magnetnog polja. Za pravilno funkcioniranje algoritma potrebno je znati inicijalnu poziciju, dok se nakon svakog koraka trenutna orijentacija ažurira s obzirom na prethodnu uz pomoć akcelerometarskih i magnetometarskih mjerenja. Žiroskopska mjerenja se koriste za korekciju orijentacije uz pomoć korištenja proporcionalnog integratora. Sama implementacija je pogodna za implementaciju u sustavima s ograničenim resursima kao što su mikrokontroleri. Ipak, metoda ima svojih nedostataka kada se IMU senzor nalazi u okružju s promjenjivim magnetskim poljem, kao i prilikom estimacije pomaka žiroskopskih mjerenja kada se vrijednosti orijentacija kvaterniona približavaju $\pm\pi$ rad.

Druga često korištena implementacija algoritma za određivanje orijentacije, koja je relativno nezahtjevna za izvođenje, temelji se Madgwick algoritmu [43]. Za razliku od prethodnog rješenja [39] gdje su se žiroskopska mjerenja koristila za kompenzaciju mjerenja, u ovom pristupu akcelerometarska i magnetometarska mjerenja koriste se za kompenzaciju. Orijentacija promatranog objekta se određuje u dva koraka. Prvo se trenutna orijentacija, izražena uz pomoć kvaterniona, određuje uz pomoć integracije žiroskopskih mjerenja s ciljem minimizacije utjecaja pomaka i šuma s obzirom na prethodnu orijentaciju. Korištenjem fuzije akcelerometra i magnetometra određuje se prilagodni faktor za kompenzaciju uz pomoć algoritma postupnog opadanja (engl. *Gradient Descent*). Metoda daje sumjerljive rezultate kao i složenije implementacije dok u isto vrijeme osigurava jednostavnost izvođenja. Također, metoda uzima u obzir lokalne promjene u magnetskom polju, koje kada se pojave, utječu na sve estimirane kuteve (skretanja, valjanja i propinjanja), čime se minimizira utjecaj smetnje. Greška se ograničava samo na kut skretanja na taj način. Više o raznim implementacija algoritama za određivanje rotacije može se pronaći u [40]

Određivanje kuta između dva inercijska senzora

Kod korištenja parova inercijskih senzora, prilikom primjerice praćenje orijentacije dijelova ljudskog tijela, korisno je poznavati kut između njih. Neka su **a** i **b** dva vektora, a α kuta među njima. Neka vektori **a** i **b** predstavljaju dva očitanja s akcelerometra u mirovanju ili u gibanju senzora bez djelovanja vanjske sile (akceleracije), pri čemu se njihove komponente mogu zapisati kao:

$$\mathbf{a} = \begin{pmatrix} a_x \\ a_y \\ a_z \end{pmatrix}, \mathbf{b} = \begin{pmatrix} b_x \\ b_y \\ b_z \end{pmatrix}. \tag{2.85}$$

U tom slučaju vektori $[a_x\ a_y\ a_z]^T$ i $[b_x\ b_y\ b_z]^T$ predstavljaju projekcije vektora gravitacije na osi vlastitog b-koordinatnog sustava akcelerometra. Kut između vektora **a** i **b** može se odrediti iz skalarnog produkta kao:

$$\mathbf{a} \cdot \mathbf{b} = \begin{pmatrix} a_x \\ a_y \\ a_z \end{pmatrix} \cdot \begin{pmatrix} b_x \\ b_y \\ b_z \end{pmatrix} = a_x b_x + a_y b_y + a_z b_z = |\mathbf{a}||\mathbf{b}| \cos\alpha, \tag{2.86}$$

$$\Rightarrow \alpha = \arccos \frac{a_x b_x + a_y b_y + a_z b_z}{\sqrt{a_x^2 + a_y^2 + a_z^2}\sqrt{b_x^2 + b_y^2 + b_z^2}}. \tag{2.87}$$

Vektor normale $\hat{\mathbf{n}}$ na površinu koju razapinju vektori **a** i **b** može se odrediti iz vektorskog produkta:

$$\mathbf{a} \times \mathbf{b} = \begin{pmatrix} a_x \\ a_y \\ a_z \end{pmatrix} \times \begin{pmatrix} b_x \\ b_y \\ b_z \end{pmatrix} = \begin{vmatrix} \hat{i} & \hat{j} & \hat{k} \\ a_x & a_y & a_z \\ b_x & b_y & b_z \end{vmatrix} = |\mathbf{a}||\mathbf{b}|\hat{\mathbf{n}} \sin\alpha, \tag{2.88}$$

$$\Rightarrow \alpha = \arcsin \frac{1}{\sqrt{a_x^2 + a_y^2 + a_z^2}} \frac{1}{\sqrt{b_x^2 + b_y^2 + b_z^2}} \begin{vmatrix} a_y b_z - a_z b_y \\ a_z b_x - a_x b_z \\ a_x b_y - a_y b_x \end{vmatrix}. \tag{2.89}$$

Predložena metoda, određivanja kuta između dva vektora korištenjem dva akcelerometra, posebno je korisna u primjeni određivanja kuta između zglobova na ljudskom tijelu, o čemu će biti više riječi kasnije. Važno je napomenuti da se kut α određuje u koordinatnom sustavu Zem-

lje te kao takav ne predstavlja kut promatranog zgloba, nego neku njegovu određenu projekciju. Korištenjem skalarnog ili vektorskog produkta može se čak i rudimentarno odrediti orijentacija senzora usporedbom trenutnog i prijašnjeg usrednjenog mjerenja [44]. Kako akcelerometri ne mjere samo komponentu gravitacije, već ukupnu akceleraciju koja djeluje na senzor, svako odstupanje od pretpostavke statičkih uvjeta (mirovanja ili gibanja s konstantnom brzinom) utjecat će na rezultat. Bez obzira na utjecaj dodatne akceleracije, u najvećem broju primjena gravitacijska komponenta značajno je većeg iznosa u odnosu na sile koje nastaju ljudskim pokretom te se te promjene mogu smatrati kao izvori smetnji i pogrešaka prilikom određivanja kuta α. Prednost korištenja para senzora jest činjenica da se bilo koji pokreti nastali trzajem ili sličnim brzim pokretima međusobno poništavaju. Slično, s korištenjem jednadžbi 2.87 i 2.89 može se odrediti kut između dvaju žiroskopskih mjerenja, ali naravno uz prethodno objašnjenu integraciju mjerenja, primjerice kako je napravljeno u [45]. Doduše, postav senzora u ovom primjeru ograničavao je određivanja brzine orijentacije samo u x i y osi, a zahtijevao je i početno umjeravanje.

2.3.4 Kalibracija inercijskih senzora

Kalibracija je postupak u kojem se obavlja korekcija parametara mjernog uređaja usporedbom dobivenih očitanja s poznatim referentnim vrijednostima kako bi se naknadna mjerenja dobivena uređajem slagala sa stvarnim vrijednostima. Kod inercijskih senzora potrebno je kalibracijom minimizirati sustavne izvore pogrešaka, koje se prvenstveno odnose na posmak nule i mjernu skalu. Kod skupljih mehaničkih i optičkih izvedbi inercijskih senzora (poput npr. [46]) sustavne pogreške značajno su manje nego kod jeftinijih MEMS izvedbi senzora. Bez odgovarajuće kalibracije takvi senzori mogu unijeti veliku grešku u mjernim rezultatima. Kalibracijski podaci koje daju proizvođači MEMS senzora ograničeno se mogu koristiti za kompenzaciju jer ne mogu obuhvatiti mnoge važne izvore sustavnih pogrešaka, kao što su npr. tolerancije orijentacije montaže senzora na tiskanu pločicu, utjecaj naprezanja u materijalu kao posljedica termičkih naprezanja na tiskanoj pločici prilikom lemljenja, utjecaj vanjskih metalnih objekata na magnetsko polje koje mjeri magnetometar itd.

Za inercijske senzore može se koristiti postupak kalibracije u šest mjerenja s različitim referentnim orijentacijama [15], pri čemu se IMU senzor montira na posebno postolje te se koristi procedura kalibracije koja omogućuje određivanje svih posmaka nule i faktora skale inercijskog senzora, u sve tri osi. Međutim, takav postupak pogodan je prvenstveno za kvalitetnije skuplje mehaničke i optičke izvedbe senzora, ali ne i za MEMS senzore zbog značajno niže točnosti, stabilnosti i kvalitete mjerenja. U nastavku će biti opisane i neke kalibracijske metode koje su pogodne za primjenu s manje kvalitetnim IMU senzorima temeljenima na MEMS tehnologiji, pri čemu se kalibracija može izvesti prije korištenja uređaja ili tijekom njegovog rada kroz proces samokalibracije.

Pri tome je važno naglasiti da se najveći problemi u praksi pojavljuju kod korištenja magnetometra jer niti jedna metoda umjeravanja ne može uzeti u obzir užu i širu okolicu uređaja tijekom rada. Naime, okolina može sadržavati feromagnetske materijale (poput npr. željeza), koji mogu imati privremeno ili trajno magnetsko polje koje utječe na mjerenja magnetometra. Izvori magnetskog polja također mogu biti i vodljivi likovi na tiskanoj pločici koji uslijed protjecanja struje mogu stvarati stalno ili promjenjivo magnetsko polje, čiji se utjecaj ne može ukloniti kalibracijom.

Kalibracija akcelerometra i magnetometra

Najjednostavnija metoda za kalibraciju IMU senzora koja se često koristi, pogotovo kod kvalitetnijih senzora, temelji se na postavljanju inercijskih senzora u šest referentnih orijentacija na posebnom postolju. Kod svakog mjerenja orijentacija senzora je takva da se osjetljiva os senzora poklapa sa smjerom vektora gravitacije. Primjerice, u jednoj orijentaciji $+x$ os senzora mjeri $+g$ vrijednost gravitacije, dok u suprotnoj orijentaciji mjeri vrijednost $-g$, pri čemu je djelovanje gravitacije na ortogonalne osi senzora jednako nuli. U tom slučaju dva mjerenja u jednoj osi senzora mogu se zapisati kao:

$$a_{+g} = b + (g \cdot \Delta), \tag{2.90}$$

$$a_{-g} = b - (g \cdot \Delta), \tag{2.91}$$

gdje a_{+g} i a_{-g} predstavljaju očitanja senzora uzduž osjetljive osi poravnate s vektorom gravitacije, g iznos vektora gravitacije, b posmak nule, a Δ faktor skaliranja mjernih rezultata. Na temelju dva mjerenja po svakoj od tri osi mogu se za svaku os odrediti parametri b i Δ prema sljedećim formulama:

$$b = 0.5 \cdot (a_{+g} + a_{-g}), \tag{2.92}$$

$$\Delta = 0.5 \cdot \left(\frac{a_{+g} - a_{-g}}{g} \right). \tag{2.93}$$

Ova vrsta kalibracije također pomaže umanjiti efekte koji se mogu pojaviti uslijed djelovanja gravitacije po ortogonalnim osima jer bi kod ovakve kalibracije ortogonalne osi u idealnom slučaju trebale mjeriti akceleraciju od 0 g. Kako bi se dobilo mjerenje senzora kalibrirano s obzirom na b i Δ, potrebno je izmjerenu vrijednost podijeliti s faktorom skaliranja Δ i oduzeti izmjereni posmak nule b:

$$\hat{a} = \frac{a - b}{\Delta}. \tag{2.94}$$

Nažalost, prethodno opisana jednostavna metoda kalibracije ne daje dobre rezultate kod

jeftinijih MEMS IMU senzora jer su sustavne pogreške, nestabilnost i šum senzora kod mjerenja akceleracije i kutne brzine preveliki. Problem kod MEMS senzora je što ih je potrebno kontinuirano rekalibrirati što nije moguće prethodno opisanom metodom, pri čemu u stvarnim primjenama nije prihvatljivo, a često niti moguće, koristiti poseban kalibracijski postav putem kojega se inercijski senzor postavlja u predefinirane orijentacije za kalibraciju. Zato je potrebno koristiti drugačije metode i pristupe, koji omogućavaju jednostavniji postupak kalibracije, ali uz znatno složeniju matematičku obradu izmjerenih podataka. Jedna od najčešćih metoda koja se uspješno koristi za kalibraciju MEMS senzora je višepozicijska metoda kalibracije (engl. *multi-position calibration method*, MPCM) [15]. Glavna prednost ove metode u odnosu na prethodno opisanu je to što se može koristiti za samokalibraciju za vrijeme rada uređaja te što ne zahtijeva nikakav dodatni instrument ili mehanički postav za poravnavanje IMU senzora u postupku kalibracije. Jedino što MPCM zahtijeva je da tijekom kalibracije na inercijski senzor ne djeluje vanjska sila, odnosno akceleracija, osim sile teže.

MPCM metoda koristi kalibracijski model mjernih pogrešaka akcelerometra koji se može izraziti sljedećom izrazom:

$$f = a_x^2 + a_y^2 + a_z^2 - ||g||^2 = 0. \tag{2.95}$$

Model pretpostavlja da ako akcelerometar mjeri samo utjecaj sile teže da tada vektor $[a_x\ a_y\ a_z]^T$ predstavlja projekciju vektora gravitacije na osjetljive osi troosnog akcelerometra, pri čemu modul projekcije po iznosu mora biti jedan vrijednosti akceleracije uslijed sile teže iznosa g. Mjerenje po jednoj osjetljivoj osi akcelerometra (npr. po x-osi senzora) može se zapisati kao:

$$y_{f,x} = b_{f,x} + (1 + \Delta_x) + \eta_{f,x}, \tag{2.96}$$

gdje $y_{f,x}$ predstavlja sirovu vrijednost akceleracije izmjerene senzorom po osjetljivoj osi x, $b_{f,x}$ je nepoznati posmak nule po osi x, Δ_x je nepoznati faktor skaliranja očitanja akceleracije po osi x i $\eta_{f,x}$ je stohastički mjerni šum. Uvrštavanjem formule 2.96 u 2.95 dobiva se izraz:

$$f = \left(\frac{y_{f,x} - b_{f,x}}{1 + \Delta_x}\right)^2 + \left(\frac{y_{f,y} - b_{f,y}}{1 + \Delta_y}\right)^2 + \left(\frac{y_{f,z} - b_{f,z}}{1 + \Delta_z}\right)^2 - ||g||^2 = 0. \tag{2.97}$$

Nepoznati parametri u izrazu 2.97 mogu se estimirati metodom najmanjih kvadrata iterativnim postupkom opisanim u [15]. Pri tome je važno radi izbjegavanja singulariteta u rješenju tako da se IMU senzor postavi u minimalno šest različitih orijentacija kako bi sustav jednaždbi opisan izrazom 2.97 bio rješiv.

U [47], [48] opisana je kalibracijska metoda za akcelerometre i magnetometre temeljena na estimaciji nepoznatih parametara pristupom rješavanja problema prilagođavanja točaka 3D elipsoidu (engl. *3D-ellipsoid fitting problem*). Takav pristup posebno je pogodan u sustavima

u kojima je važna brza rekalibracija senzora u stvarnom vremenu uz minimalno vrijeme proračuna. Kao i kod ranije opisanih kalibracijskih metoda, i ovdje se pretpostavlja da se kalibracija akcelerometra odvija u statičkim uvjetima u kojima je utjecaj dodatne akceleracije zanemariv u odnosu na djelovanje sile teže. Izlaz iz kalibriranog senzora $\hat{\mathbf{y}}^b$ promatran u vlastitom b-koordinatnom sustavu može se opisati putem formule:

$$\hat{\mathbf{y}}^b = \boldsymbol{V}(\mathbf{y}_f^b - \mathbf{b}^b) = \boldsymbol{V}\mathbf{y}_f^b - \boldsymbol{V}\mathbf{b}^b, \tag{2.98}$$

gdje $\boldsymbol{V} = \text{diag}\{\Delta_x\ \Delta_y\ \Delta_y\}$ predstavlja dijagonalnu matricu faktora skaliranja mjernih rezultata po svakoj osjetljivoj osi, a $\mathbf{b}^b = [b_x\ b_y\ b_z]^T$ vektor posmaka nule po svakoj osi. Cilj kalibracijskog postupka je izračunati matricu $\boldsymbol{V}$ i vektor $\mathbf{b}^b$ tako da se elipsoid prikaže jediničnom sferom sa središtem u ishodištu, što se može izraziti putem formule:

$$1 = \hat{\mathbf{y}}^{b^T}\hat{\mathbf{y}}^b = \mathbf{y}_f^{b^T}\boldsymbol{V}^2\mathbf{y}_f^b + \mathbf{b}^{b^T}\boldsymbol{V}^2\mathbf{b}^b - 2\mathbf{y}_f^{b^T}\boldsymbol{V}^2\mathbf{b}^b. \tag{2.99}$$

Uz uvođenje nadomjesnih varijabli:

$$d = 1 - \mathbf{b}^{b^T}\boldsymbol{V}^2\mathbf{b}^b, \tag{2.100}$$

$$\bar{\boldsymbol{V}} = (1/d)\boldsymbol{V}^2 = \text{diag}\{\bar{\Delta}_x, \bar{\Delta}_y, \bar{\Delta}_z\}, \tag{2.101}$$

$$\mathbf{c} = (1/d)\boldsymbol{V}^2\mathbf{b}^b = \bar{\boldsymbol{V}}\mathbf{b}^b, \tag{2.102}$$

model 2.98 može se zapisati u obliku pogodnom za estimaciju:

$$1 = \begin{bmatrix} y_{f,x}^2 & y_{f,y}^2 & y_{f,z}^2 & -2y_{f,x} & -2y_{f,y} & -2y_{f,z} \end{bmatrix} \begin{bmatrix} \bar{\Delta}_x \\ \bar{\Delta}_y \\ \bar{\Delta}_z \\ \mathbf{c} \end{bmatrix}. \tag{2.103}$$

Izraz 2.103 može se zapisati kao linearni sustav jednaždbi za kojega se nepoznati parametri modela mogu estimirati metodom najmanjih kvadrata.

Svi do sada prikazani modeli kalibracije uzimali su faktor skaliranja samo po jednoj osi, pretpostavljajući da nema međusobnog djelovanja između ortogonalnih osi. Međutim, zbog načina tehnološke izvedbe MEMS senzora postoji mogućnost da pojedine mjerne osi utječu jedna na drugu mimo inercijskih veličina koje mjere, npr. uslijed kapacitivnog preslušavanja i sl. To znači da u stvarnosti mjerenje akceleracije po jednoj osjetljivoj osi akcelerometra može utjecati na drugu osjetljivu os zbog načina izvedbe senzora, što zahtijeva da se za potpuni model

kalibracije koristi izraz oblika:

$$\boldsymbol{Y} = \begin{pmatrix} y_x \\ y_y \\ y_z \end{pmatrix} = \boldsymbol{V}\boldsymbol{Y}_f + \boldsymbol{B} = \begin{pmatrix} \Delta_{xx} & \Delta_{xy} & \Delta_{xz} \\ \Delta_{yx} & \Delta_{yy} & \Delta_{yz} \\ \Delta_{zx} & \Delta_{zy} & \Delta_{zz} \end{pmatrix} \begin{pmatrix} y_{f,x} \\ y_{f,y} \\ y_{f,z} \end{pmatrix} + \begin{pmatrix} b_x \\ b_y \\ b_z \end{pmatrix}. \tag{2.104}$$

U ovom slučaju matrica $\boldsymbol{V}$ sadrži devet neovisnih elemenata koji opisuju faktore skaliranja i proširuje kalibracijske modele opisane s 2.95 i 2.98 tako što uključuje i faktore skaliranja između pojedinih parova koordinatnih osi. Pri tome vektor $\boldsymbol{Y}$ predstavlja poznate iznose gravitacije kod pojedinih orijentacija senzora. Orijentacije senzora mogu biti istovjetne kao i u jednostavnom modelu kalibracije. U [49] navedene su posebne referentne rotacije koje maksimiziraju razlike u izmjernim vrijednostima gravitacije po osima. Model opisan izrazom 2.104 također se može estimirati korištenjem metode najmanjih kvadrata, kao i prethodno opisani kalibracijski modeli.

Odabir metode kalibracije ovisi o mjernom senzoru, njegovim karakteristikama i ciljnoj primjeni, pri čemu se može odabrati jedna ili više metoda za potrebe kalibracije. Pri tome je potrebno uzeti u obzir računalnu složenost implementacije kalibracijske metode, memorijske i procesorske zahtjeve za izvođenje (posebno ako se implementacija radi na ugradbenom računalu s ograničenim resursima), zahtjeve na rad u stvarnom vremenu te ograničenja na provedbu samog kalibracijskog postupka, pri čemu je važno znati može li se ili ne koristiti referentni postav za definiranje kalibracijskih orijentacija senzora te je li potrebno kalibraciju izvršavati prije mjerenja ili se mora raditi kontinuirano i za vrijeme samog mjerenja.

Kalibracija žiroskopa

Pogreške posmaka kod žiroskopa imaju izuzetno velik utjecaj na točnost mjerenja inercijskog sustava, posebno zbog činjenice da se kut orijentacije iz žiroskopa dobiva jednostrukom integracijom mjerene kutne brzine. Ako se posmak nule žiroskopa ne kompenzira kalibracijom, pogreška orijentacije raste linearno s vremenom, kako je prikazano na slici 2.22a. U statičkim uvjetima žiroskop se može modelirati sljedećim izrazom:

$$\omega = \omega_x^2 + \omega_y^2 + \omega_z^2 - ||\omega_e||^2 = 0, \tag{2.105}$$

gdje ω predstavlja kutnu brzinu žiroskopa, $\{\omega_x,\ \omega_y,\ \omega_z\}$ komponente mjerene po tri osjetljive osi žiroskopa, a ω_e kutnu brzinu rotacije Zemlje oko svoje osi. S obzirom da senzori temeljeni na MEMS tehnologiji nisu dovoljno osjetljivi da bi mogli detektirati ω_e, model 2.105 može se aproksimirati formulom:

$$\omega = \omega_x^2 + \omega_y^2 + \omega_z^2 \approx 0. \tag{2.106}$$

Posmak nule žiroskopa može se jednostavno odrediti kao srednja vrijednost svih mjerenja dok je senzor nepomičan. U slučaju da imamo N mjerenja, posmak nule za primjerice x-os može se izraziti kao:

$$\hat{b}_{\omega,x} = \frac{1}{N}\sum_{i=1}^{N} \omega_{i,x}. \tag{2.107}$$

Važno je naglasiti da ova jednostavna metoda određivanja posmaka nule žiroskopa ne uzima u obzira $1/f$ šum, koji je karakterističan za MEMS žiroskope i koji se može modelirati slučajnim hodom (engl. *random walk*), a manifestira se u nestabilnosti posmaka s promjenama u niskom frekvencijskom području. Ti efekti mogu se opisati kroz karakterizaciju šuma senzora, o čemu se više informacija može pronaći u [15].

Faktori skaliranja žiroskopa mogu se odrediti uz primjenu poznate konstantne brzine rotacije oko svake osjetljive osi. Kao i u slučaju određivanja faktora skaliranja akcelerometra, nepoznati parametri se mogu estimirati metodom najmanjih kvadrata. Kalibracijski model ima sličan zapis kao i model 2.97 u slučaju akcelerometra:

$$\omega = \left(\frac{y_{\omega,x} - \hat{b}_{\omega,x}}{1+\Delta_x}\right)^2 + \left(\frac{y_{\omega,y} - \hat{b}_{\omega,y}}{1+\Delta_y}\right)^2 + \left(\frac{y_{\omega,z} - \hat{b}_{\omega,z}}{1+\Delta_z}\right)^2 = 0, \tag{2.108}$$

gdje su $\{y_{\omega,x},\, y_{\omega,y},\, y_{\omega,z}\}$ mjerenja prikupljena žiroskopom sa sve tri osjetljive osi, $\{\Delta_x,\, \Delta_y,\, \Delta_z\}$ nepoznati faktori skaliranja, a $\{\hat{b}_{\omega,x},\, \hat{b}_{\omega,y},\, \hat{b}_{\omega,z}\}$ vrijednosti posmaka nule ranije procjenjene korištenjem izraza 2.107.

Allanova varijanca

Perfomanse IMU senzora, s obzirom na izvore šuma, tipično se izražavaju se uz pomoć Allanove devijacije, odnosno varijance [37, 50–52]. Ova statistička mjera opisuje ponašanje izvora šuma tijekom vremena u mjernom procesu. Pravilnom analizom mjernog procesa možemo umanjiti utjecaj šuma u mjernom signalu dodatnom obradom. Navedena metoda često se koristi kako bi se kvantificirali izvori šuma kod oscilatora ili izvora takta. U slučaju IMU senzora pomaže odrediti optimalni broj uzoraka za usrednjavanje kako bi se minimizirali utjecaji raznih izvora šuma. Isto tako, analizom izvora pogrešaka može se ispravno modelirati proces estimacije i povećati preciznost procjene.

Uzme li se niz od K neprekinutih mjerenja $y_{1:K} = y_{k\,k=1}^{K}$ s vremenom uzrokovanja T, on se može podijeliti u skupine od n mjerenja $\overline{y}_{1:L}(n) = y_{l\,l=1}^{L}$, gdje je $L = \lfloor \frac{K}{n} \rfloor$. Trajanje jedne skupine je tada $T_c = nT$, dok $\overline{y}_l$ predstavlja srednju vrijednost koja se može definirati kao:

$$\overline{y}_l = \frac{1}{n}\sum_{k=1}^{n} y_{(l-1)n+k}. \tag{2.109}$$

U tom slučaju Allanova varijanca se može izraziti kao:

$$\bar{y}_l = \frac{1}{2(L-1)} \sum_{l=1}^{L-1} (\bar{y}_{l+1} - \bar{y}_l)^2. \tag{2.110}$$

Allanova varijanca se izražava kao kvadratna razlika srednjih vrijednosti pojedinih skupina mjerenja. Spektralna gustoća snage S s obzirom na mjerenja y se tada može izraziti kao:

$$\sigma^2(T_c) = 4 \int_0^\infty \frac{\sin^4(\pi f T_c)}{(\pi f T_c)^2} S(f)\, df. \tag{2.111}$$

Rezultati se obično prikazuju korištenjem logaritamske skale, kao što prikazuju slike 2.25 i 2.26, koje su bile generirane korištenjem mjerenja IMU senzora LSM9DS0 tijekom 2 sata. Na prikazanim krivuljama mogu se primijetiti zajedničke značajke koje karakteriziraju mjerenja na pojedinim osima. Prva izračunata vrijednost σ_{oa}, odnosno početak krivulje, određuje varijancu jednog uzorka, odnosno jedne izmjerene vrijednosti. Zatim slijedi pad krivulje s koeficijentom od $-0,5$, koja definira utjecaj bijelog šuma na mjerenje. Što je dulje usrednjavanje, to se može utjecati da je sve manji utjecaj bijelog šuma na mjerenja. Prestanak utjecaja bijelog šuma definiran je u vremenu $T_k = 1$. S obzirom na promatrano gibanje, vrijeme usrednjavanja mjerenja može se odabrati na ovom odsječku krivulje. Primjerice, u slučaju prikaza Allanove varijance za žiroskopska mjerenja na slici 2.25 može se primijetiti prethodni rast utjecaja bijelog šuma prije pada. S druge strane, s usrednjavanjem od samo 38 uzoraka može se ostvariti smanjenje utjecaja bijelog šuma od 2 do 4 puta, ovisno o osi uz smanjivanje granične frekvencije otipkavanja na 10 Hz.

Drugi važni parametar kojeg se može očitati s krivulja jest minimalna vrijednost. U ovom području stabilnosti, najveći utjecaj pogreške stvaraju već prije spomenuti efekti klizanja vrijednosti mjerenja u vremenu. Ova točka predstavlja najbolji mogući slučaj prilikom korištenja pojedinog senzora i koristiti se za usporedbu različitih proizvođača s gledišta kvalitete. Iza miniminalne točke, u slučaju analize žiroskopskih mjerenja, može se primijetiti rast varijance. Općenito, uzorci rasta su promjene posmaka, klizanja ili utjecaji temperature.

2.4 Stanje tehnologije u određivanju položaja i orijentacije ljudskog tijela

2.4.1 Stanje inercijske tehnologije u određivanju kuta zgloba

IMU uređaji su tipično sastavljeni od tri senzora, akcelerometra, žiroskopa i magnetometra. Svaki od navedenih senzora mjeri svoje zasebne vektore akceleracije, kutne brzine i magnetskog polja kako bi odredili svoju poziciju, kao i orijentaciju u prostoru. Tipično, tri odvojena

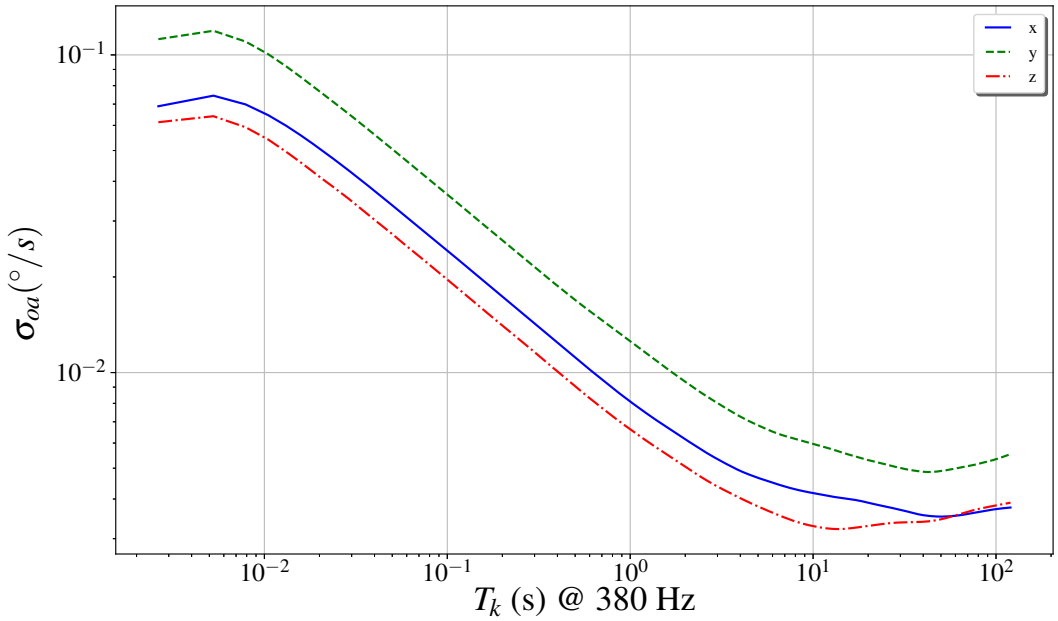

Slika 2.25: Prikaz Allanove devijacije za žiroskopska mjerenja IMU uređaja LSM9DS0

senzora čine jedan uređaj koji predstavlja zajednički koordinatni sustav poravnat s vlastitim kućištem. Većina razvijenih sustava koristi par IMU uređaja postavljenih oko promatranog zgloba, kako bi izmjerili promjenu kuta [45, 53–56]. Uspoređujući međusobna mjerenja s parom IMU senzora mogu se pratiti promjene kuta. Neka od komercijalno dostupnih rješenje, kao što je [46], imaju već ugrađene algoritme koji kao rezultat daju orijentaciju senzora u nekom globalno definiranom koordinatnom sustavu. Orijentacija može biti izražena u obliku rotacijskih matrica, Eulerovih kuteva ili putem kvaterniona. Ipak, takvo rješenje dolazi i s visokom cijenom senzora po uređaju.

Kako bi točno odredili kut zgloba korištenjem para senzora, potrebno je rješiti problem međusobnog poravnanja IMU senzora, kao i poravnanja s obzirom na koordinatni sustav tijela. U [45] problem je riješen uz pomoć prije definiranih kalibracijskih pokreta koji su se koristili za poravnanje IMU senzora. U tom istraživanju IMU senzori su bili postavljenih na bedro i gležanj te se tako uspjela odrediti razlika u snimljenom pokretu koja je odgovarala kutu koljena. Korištenjem fuzije podataka iz akcelerometra i žiroskopa uspješno je određena promjena kuta koljena u 3D prostoru. Usporedbom s refretnim mjernim sustavom temeljenom na magnetnoj indukciji, dosegnuta je točnost (preciznost) od 1°(1°) u slučaju fleksije/ekstenzije, 0°(0,6°) u slučaju adukcije/abdukcije i 1,6°(0,5°) u slučaju rotacije. Ista grupa autora je godinu kasnije uspjela razviti algoritam za poravnanje samo uz korištenje izmjerenih podataka prilikom kretanja i mirovanja te validirati sustav s referetnim optičkim sustavom [57] gdje je točnost bila manja od 1°. Sličan sustav bio je izveden i u [54], gdje je dodatno bio korišten i magnetometar. Snimanjem pokreta validacijom uz pomoć infracrvenog sustava i reflektivnih markera doseg-

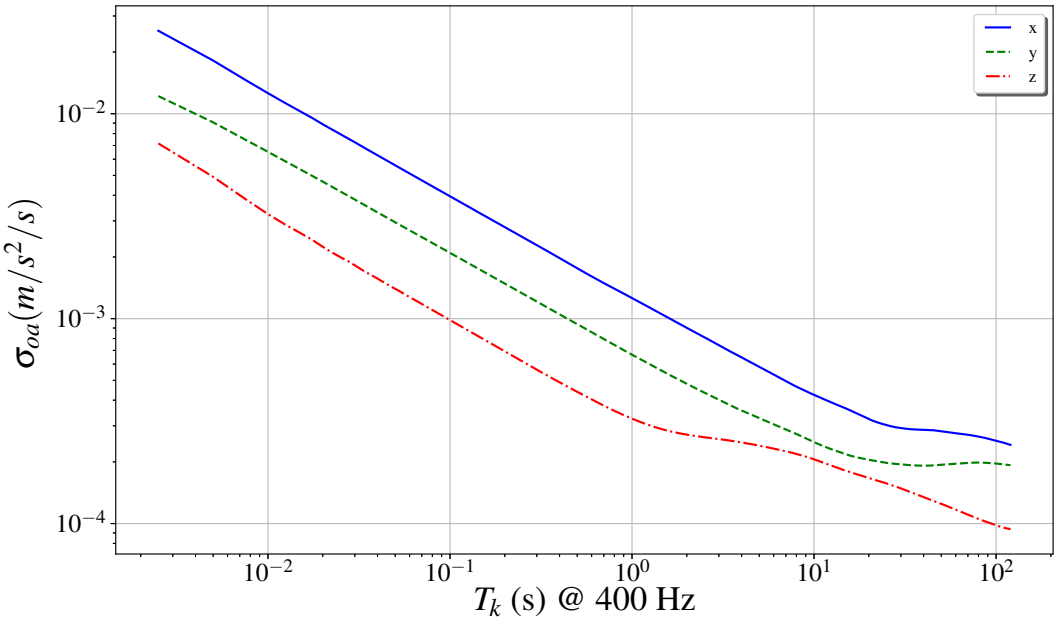

Slika 2.26: Prikaz Allanove devijacije za akcelerometarska mjerenja IMU uređaja LSM9DS0

nuta je standardna devijacija određivanja kuta koljena u rasponu od 0,08° do 3,06°, ovisno o vrsti mjerenja. Cijeli sustav je imao cijenu od 400$ dok su se mjerenja prenosila na računalo uz pomoć *Bluetooth* komunikacije. U [55] se razvijen je kalibracijski protokol poravnanja uz korištenje četiri IMU senzora postavljenih na kuk, iznad i ispod koljena te na stopalo. Metoda zahtijeva pet sekundi mirovanja u stojećem položaju kako bi se mogao odrediti anatomski koordinatni sustav uz pomoć vektora gravitacije. Orijentacija zapisana u formatu kvaterniona se zatim koristi kako bi se odredili kutevi zglobova. U usporedbi s referentnim mjerenjem izvedenim uz pomoć goniometra, ustanovljena je točnost metode od 0,93° do 15,61°, ovisno o promatranom zglobu. Također, metoda je više griješila u slučajevima većih kuteva zglobova, nego u manjim.

Zanimljiv pristup rješenja problema poravnanja dan je u [53], gdje je cilj bio odrediti zajednički koordinatni sustav parova IMU senzora tako da je poravnat s osima kretanja promatranog zgloba, odnosno da je u ravnini udova. Zbog već prije spomenute činjenice da mjerenja magnetskog polja mogu biti narušena u zatvorenim prostorima, autori su odlučili odrediti poravnanje samo uz korištenje žiroskopskih podataka [53, 58]. Njihov pristup ne zahtijeva od ranije definirane kalibracijske kretnje te je sposoban odrediti poravnanje tijekom rada samog uređaja uz korištenje iterativne metode. S preciznom kalibracijom i poravnanjem uspjeli su povećati točnost mjerenja kuta koljena na protezi i zdravoj nozi. Sustav je bio validiran uz pomoć optičkog sustava te je dosegao grešku manju od 0,6° na protezi i manju od 4,0° na zdravoj nozi sa standardnom devijacijom manjom od 1°. Tokom implementacije rješenja [53], o kojem će biti nešto više riječi kasnije, primjećena je nestabilnost metode prilikom određivanja vektora

poravnanja na većem broju mjerenja. Isto je primijećeno i u [59], gdje se problem nastojao riješiti uz pomoć primjene proširenog Kalmanovog filtra uz korištenje istih ograničenja. Rezultati su bili sumjerljivi [53] prilikom usporedbe s potenciometrom na egzoskeletu. Algoritam je bio implementiran na ugradbenom računalu i testiran pri raznim brzinama kretanja čovjeka. U [60] ustanovljeno je da je iterativna metoda korištena za pronalazak vektora uspješnija ako se pogreška izračunava uz pomoć apsolutne razlike vrijednosti, a ne kao Euklidska norma. U ranijem radu [61] iz 2015. godine bila su istražena ograničenja kalibracijske metode iz [53] te je s obzirom na provedenu analizu predložena nova auto-kalibracijska metoda. Uz pomoć analize temeljene na Fischerovoj informacijskoj matrici (engl. *Fischer information matrix*, FIM) ustanovila su se tri nedostatka, koja su riješena uvođenjem dodatnog IMU čvora postavljenog na kuk. Ovisno o tipu kretnje, nova metoda daje veću točnost određivanja kuta promatranog zgloba, ali i veću brzinu konvergencije prilikom određivanja koordinatnog sustava zgloba. Iako rad nije u potpunosti povezan s problemom određivanja kuta zgloba, u [62] nadograđen je algoritam iz [53] uključivanjem ograničenja rotacijskih komponenti akceleracije s obzirom na kutne zglobove, kao što su koljeno ili lakat.

Iako su u većini istraživanja bili korišteni parovi IMU senzora, moguće je koristiti i samo jedan. U [63] uz pomoć jednog senzora, postavljenog na nogu, estimirani su kutevi zglobova uz pomoć metode najmanjih kvadrata. Promjena kuteva zglobova, aproksimirana Taylorovim redom, određivala se uz pomoć modela kinematičkog lanca u 4 točke. Međusobne udaljenosti točaka nužno je izmjeriti prije korištenja predloženog algoritma i odrediti ih palpitacijom određenih referenci na ljudskom kosturu. Kao referentni sustav koristila se stereofotogrametrijska kamera te je metoda ostvarivala prosječnu točnost od 3,2° s 1,2° standardne devijacije. Uz nužna mjerenja duljina pojedinih segmenata kostura, metoda zahtijeva da je zdjelica nepomična tokom mjerenja. Slično prijašnjem radu, s prije izmjerenim udaljenostima između senzora u [64] određivao se položaj zgloba koljena i gležnja. Iz usporedbe tih dvaju položaja moguće je odrediti njihove kuteve. Korištena metoda svodila se na korake predikcije i korekcije prema modeliranim ograničenjima kretanja i implememententirana je uz pomoć Kalmanovog filtra. S tri IMU senzora postavljenih visoko na bedro, ispod koljena i na stopalo ostvarena je greška od 2° u usporedbi s optičkim sustavom.

Drugi značajan problem je već ranije spomenuti posmak nule prilikom mjerenja koji nastaje tijekom vremena zbog prije opisanih nesavršenosti senzora. Akumulacija tih pomaka uzrokuje sve manju točnost estimacije tijekom vremena. Iz tog razloga u [65] predložen je kinematski model s ciljem minimiziranja utjecaja pomaka uz uvođenje ograničenja gibanja s obzirom na dob, spol i strukturu kostiju. U radu je modeliran pomak kao slučajni proces i korištena metoda osvježavanja u razdobljima mirovanja kada se podatci nisu mijenjali, odnosno kada je brzina kretanja bila jednaka 0. Kako bi se izbjegli složeni linearizacijski procesi EKF-a, primijenjen je *unscented* oblik Kalmanovog filtra. S validacijom uz korištenje optičkih sustava i industrijske

ruke, ustanovljeno je da je pogreška točnosti manja od 6,5° prilikom raznih vrsta gibanja.

2.4.2 Stanje UWB tehnologije u određivanju položaja i kuta zgloba

UWB tehnologija za određivanja položaja promatranog objekta može se koristiti na dva načina. Prvi način je da se analiziraju promjene u UWB kanalu kako bi se detektirala prisutnost [20, 66], pratilo kretanje [20, 67–71] ili čak klasificirala aktivnost čovjeka [72, 73] u zatvorenom prostoru ili iza prepreka kao što su zidovi [74–76]. Primjerice, korištenjem radarske UWB metode i praćenjem odayiva u UWB kanalu moguće je čak i detektirati ravnotežu čovjeka, promjenu posture, odnosno njihanje dok stoji [77]. Slično, osobe se mogu lokalizirati u prostoru bez korištenja mobilnih stanica korištenjem UWB tehnologije kao detektora disanja, odnosno pomaka grudnog koša. Korištenjem UWB signala u 5 GHz području, moguće je detektirati ponavljajuće frekvencijske komponente u rasponu 0,2–0,7 Hz koje odgovaraju frekvenciji disanja čovjeka. Lokalizacija je moguća čak i iza zidova do debljine 55 cm cm uz točnost od 1,13 cm cm na udaljenosti od 46 m [78]. Usporedbom refleksija UWB signala moguće je čak i prepoznati osobu prema njihovom stasu i hodu [79]. Također, simulacije pokazuju da je moguće s više statičkih antena odrediti udaljenost i smjer gibanja čovjeka s maksimalnom točnošću od 0,5 m [80].

Dok su primjene radarskog načina raznovrsne, drugi način korištenja UWB se primarno odnosi na određivanja vremena dolaska signala (TOA), odnosno pozicioniranje UWB primopredajnika korištenjem fiksne infrastrukture [1, 8, 18, 41, 81–91] ili postavljanjem na pojedinim dijelovima tijela radi određivanja relativnih udaljenosti između antena [3, 68, 92–94]. Većina novijih istraživanja koriste već prije navedeno rješenje tvrtke Decawave. U [7] pokazano je da je integrirani sklop DW1000 moguće koristiti prilikom mjerenja brzih promjena udaljenosti. Istraživanje je bilo provedeno s ciljem kako bi se odredio optimalni broj uzoraka prilikom usrednjavanja mjerenja, pri tome uzimajući u obzir različite brzine gibanja. Odabrane brzine referentnog mjernog sustava, temeljenog na preciznom elektro-pneumatskom aktuatoru, bile su odabrane kako bi se simuliralo brzo ($2{,}0\,\mathrm{m\,s^{-1}}$) i sporo ($0{,}5\,\mathrm{m\,s^{-1}}$) gibanje ljudske ruke. U istraživanju se može primijetiti da je za brza gibanja potrebno puno manje uzoraka za usrednjavanje nego pri sporijem gibanju, ako je frekvencija osvježavanja mjerenja 283 Hz. Slično istraživanje primjene UWB tehnologije provedeno je i u [95], gdje se nastojalo odrediti da li je rješenje temeljeno na DW1000 pogodno za korištenje prilikom sportskih aktivnosti. Analizirali su se pojedine pozicije čvorova na ljudskom tijelu prilikom raznih aktivnosti s obzirom na kretnje i točnost određivanja pozicije. Također, analizirali se primjena lokalizacijskih metoda s obzirom na različite optimizacije, kao što su uklanjanje posmaka nule, detektiranje NLOS uvjeta ili određivanje putanje. Pošto su kretnje sportaša često složene i nepredvidive po prirodi, uz odabir prave metode točnost određivanja pozicije može se poboljšati za 30 %. Važno je razumjeti da mjerni sustav pokazuje drugačije ponašanje u slučajevima kada osoba trči ili hoda, odnosno u situacijama više i niže fizičke aktivnosti, što je moguće obuhvatiti odgovarajućim kinematičkim

modelima [89].

U većini slučajeva prilikom određivanja pozicije poboljšanje rezultata i performansi mogu se postići kombiniranjem UWB tehnologije s inercijskim i drugim senzorima. Upravo iz tih razloga koristi se već prije spomenuti pristup fuzije senzora. Uz pomoć metoda senzorske fuzije, prikupljeni podatci iz višestrukih senzora se zajednički interpretiraju kako bi se iskoristile prednosti pojedinih izvora informacije. Mjerenja udaljenosti, a s time i lokalizacija, može se modelirati kao Gaussov proces. Pogreška prilikom određivanja udaljenosti s prijašnjom pretpostavkom ponašanja procesa se u tom slučaju može značajno smanjiti (u slučaju korištenja DW1000 čipa) [96]. Primjerice, uz definiranje pravilnih modela propagacije UWB signala moguće je čak i provesti lokalizaciju samo uz korištenje informacija o refleksijama iz CIR-a i jedne BS do 0,5 m točnosti [97, 98]. Zbog navedene pretpostavke o ponašanju pogreške mjerenja, proces fuzije višestrukih izvora informacija najčešće se ostvaruje uz korištenje Kalmanovih filtera, odnosno njihovih nelinearnih oblika, proširenog i *unscented* Kalmanovog filtra. Jednostavna dostupnost UWB tehnologije za potrebe istraživanja dovodi do raznih novih metoda kompenzacija mjerenja u raznim uvjetima. Korištenjem iterativnog proširenog Kalmanovog filtra (engl. *iterative extended Kalman filter*, IEKF) i s fuzijom inercijskih mjerenja moguće je ukloniti pogreške uzrokovane NLOS uvjetima prilikom lokalizacije s TOA mjerenjima [99] i TDOA [100] metodama. U slučaju industrijskih okružja, koja su prepuna izvora refleksija i NLOS uvjeta, može se primijeniti GMCKF algoritam (engl. *Generalized Maximum Correntropy Kalman Filter*) gdje metoda maksimizira sličnost između izmjerenog signala i trenutnog stanja sustava. U slučaju rijetkih nelinearnih pojava, Kalmanov filtar neće uspjeti kompenzirati promjene uzrokovane NLOS uvjetima pa je potrebna ovakva metoda.

Korištenjem laboratorijske opreme za generiranje i analizu UWB signala u [18] i [84] razvili su se sustavi s pogreškom lokalizacije u rasponu od 1 do 3 cm. Važno je za napomenuti da su se u [84] koristile dvije različite procedure određivanja dolaska vremena paketa u NLOS i LOS uvjetima kako bi se smanjio utjecaj prepreka i povećala točnost određivanja položaja ruke ili prsa u prostoru. U ostalim istraživanjima istih autora [82, 83] ustanovilo se da i položaj BS-a značajno utječe na točnost lokalizacije ovisno o promatranim točkama na ljudskom tijelu.

U osnovnoj izvedba sustava za nadziranje ljudskog hoda, [91] UWB čvor s DW1000 integriranim sklopom postavljen je na stopalo ispitanika. Subjektu se pratila 3D pozicija stopala uz pomoć četiri BS dok je hodao na pokretnoj traci. Ustanovljeno je da ovaj jednostavni sustav daje zadovoljavajuću točnost u smjeru hoda za analizu hoda u prostornoj i vremenskoj dimenziji. Pogreška u smjeru hodanja koordinata je između 19 mm i 23,14 mm. Za razliku od ostalih skupljih sustava, za ovaj podstav nije potrebna kalibracija ili višestruki broj čvorova postavljen na čovjeku te ga čini dobrim kandidatom za klinička ispitivanja hoda. Sličan sustav predložen je i u [86], gdje se proširio s korištenjem IMU senzora. U navedenom radu, IMU senzor se koristio za zasebno računanje pozicije stopala u prostoru kao i UWB. Pokazuje se da predloženo

rješenje nije ispunilo zadovoljavajuću razinu točnosti, što dodatno opravdava pristup senzorske fuzije. Pristup je opravdan na sličnom istraživanju u [92] gdje se udaljenost određivala određivanjem duljine hoda uz pomoć IMU senzora, kao i UWB čvorova postavljenih na svako stopalo. Mjereći udaljenost između koraka te koristeći EKF fuziju dviju metoda ustanovila se pogreška između prehodane i stvarne vrijednosti od 0,2 do 1,5 %.

Od naprednijih metoda određivanja pozicije bez korištenja senzorske fuzije, izdvajaju se istraživanja istih autora [8] i [87]. Postavljanjem BS na trup ljudskog tijela i MS na udove te uz ML estimacije određivala se pozicija ruke, odnosno njezin pokret. U kasnijem istraživanju [87] korišteni su Taylorovi redovi s ciljem povećanja točnosti estimacije. Zanimljivo je primijetiti da je u modelima uračunata estimacija odmaka udaljenosti uzrokovana vremenskom nesinkronizacijom BS i MS. Isto tako, u navedenom istraživanju koristila se laboratorijska oprema, a na integrirana rješenja poput npr. DW1000. S obzirom na topologiju antena koje tvore BS i MS, pogreška lokalizacije se kreće između 0,17 i 4,10 cm.

Korištenjem EKF metode u [41, 85] razvijen je sustav koji koristi TOA UWB mjerenja, kao i inercijska mjerenja, s ciljem određivanja pozicije u prostoru. S obzirom da TOA mjerenja zahtijevaju vremenski sinkronizirane BS postavljene na točno određene fiksne pozicije, kako bi se pojednostavila procedura postavljanja infrastrukture razvijena je automatska kalibracijska metoda. Metodom se određuju pozicije, kao i vremenski odmaci pojedinih izvora vremena. Dvostrukim integriranjem akceleracije i oduzimanjem gravitacije određuje se promjena pozicije uz pomoć inercijskih mjerenja. Fuzijom senzora i usporedbom s optičkim referentnim sustavom pogreška pozicije nije bila veća od 3 cm u pojedinim osima. Slično u [88–90] razvijena je metoda za 3D praćenje donjih ekstremiteta prilikom hodanja ili čak skakanja. Rješenje se sastoji od dva Kalmanova filtra gdje se jedan specifično koristi za određivanje orijentacije, dok drugi služi za određivanje pozicije u prostoru. Korištenjem UWB mjerenja i biomehaničkog modela kretanja donjih ekstremiteta razvijen je sustav za praćenje kretanja, koji ne ovisi o magnetometarskim mjerenjima. Pogreška sustava prilikom određivanja pozicije pojedinih točaka na ljudksom tijelu, u usporedbi s optičkim sustavom, iznosi 4,5 cm. Za razliku od ostalih sustava, gdje su se koristila rješenja bazirana na DW1000 ili laboratorijskoj opremi, u ovim istraživanjima koristila se oprema bazirana na Ubisense modulima.

Sva dosad iznesena istraživanja, osim [41], podrazumijevaju fiksnu infrastrukturu koja je nepromjenjiva u svojim pozicijama te vremenski sinkronizirana. Istraživanje [94] je prvo uzelo u obzir utjecaj položaj BS, kao i pogreške TOA metode i IMU senzora. Korištenjem Cramér–Rao mjere, odnosno CRLB i *posterior* CRLB mjera, mogu se odrediti teoretske granice varijance prilikom određivanja pozicije u prostornoj i vremenskoj domeni. Usporedbom simulacijskih rezultata može se doći do sljedećih zaključaka:

- što je međusobni položaj i raspored BS bliži kvadratnom obliku, pozicioniranje će biti točnije.

- što je veći broj BS, to će određivanje pozicije biti točnije, ali broj BS nema toliki utjecaj na pogrešku kao njihov raspored.
- fuzija IMU/TOA metoda daje puno bolje rezultate, nego što bi mogle dati svaka metoda odvojeno, makar postoje mjesta za dodatnim poboljšanjem.

Sa saznanjima iz [94] ista grupa autora uspjela je razviti sustav bez fiksne infrastrukture [1]. Slično kao i u slučaju [8], BS su bile postavljene na relativno nepromjenjiva mjesta na ljudskom tijelu, kao što su kuk ili prsa. Na taj način sustav ne zahtijeva fiksnu infrastrukturu.

U [3] predložena je metoda određivanja kuta zgloba korištenjem nosivih UWB antena na segmentima ispod i iznad promatranog zgloba. Mjerenjem udaljenosti između antena te korištenjem trigonometrijskih formula moguće je odrediti kut zgloba uz poznavanje udaljenosti antena od zgloba. Metoda je bila validirana uz pomoć fleksibilnog goniometra prilikom različitih brzina gibanja. Pogreška navedene metode iznosila je od 0,8° za sporija kretanja, do 2,8° za brža kretanja ruke sa standardnom devijacijom mjerenja do 4,2°. Rezultati čine ovaj sustav pogodnim za korištenje u kliničkim mjerenjima, primjerice u rehabilitaciji.

Poglavlje 3

Model za određivanje položaja i pokreta ljudskog tijela

Kao što je bilo spomenuto u poglavlju 2.4, u prethodnim istraživanjima postoje nedostatci kod primjene UWB tehnologije u praćenju kretnji čovjeka. Sva dostupna postojeća istraživanja temelje se na potrebi dobivanja pozicije iz UWB sustava u svojim modelima, odnosno koordinata u referentnom koordinatnom sustavu. Iako takav pristup daje zadovoljavajuće rezultate u navedenim primjenama, ujedno predstavlja i važno praktično ograničenje. Dobivanje pozicije od UWB sustava podrazumijeva neku vrstu fiksne infrastrukture, kao i prethodne kalibracije da bi se uhodao sustav za pozicioniranje na određenom području. Iako postoje automatizirani pristupi kalibraciji sustava za UWB pozicioniranje, kao što je primjerice izloženo u [8], takav pristup i dalje zahtijeva neki oblik dodatne infrastrukture oko promatranog čovjeka. U slučaju kada bi se UWB tehnologija koristila bez infrastrukture, odnosno kada su se mjerile samo međusobne udaljenosti između čvorova, primijećeno je da se u pronađenim istraživanjima koristila isključivo visoko precizna i sofisticirana laboratorijska oprema, a ne jeftini moduli nižeg stupnja preciznosti. Iz tih razloga provedeno je istraživanje i predložen model mjerenja udaljenosti s kompenzacijom vremenske baze mobilnih čvorova kako bi se primjenjivost ovog pristupa proširila i na jeftinije sustave, bez potrebe za korištenjem skupe laboratorijske opreme. Pokazuje se da je uz ovakav pristup moguće ostvariti sustav za mjerenje udaljenosti bez potrebe za fiksnom infrastrukturom ili laboratorijskom opremom sa visoko stabilnim izvorom vremenske baze.

Dodatno, kako bi se povećala točnost i brzina odziva predloženog sustava, odlučeno je provesti istraživanje mogućnosti fuzije inercijskih podataka s UWB mjerenjima. Iz provedenog istraživanja iznesenog u poglavlju 2.4 pokazano da je to moguće. Isto tako izvučen je i zaključak da se prilikom fuzije, odnosno prilikom estimacije orijentacije senzora, izbjegava korištenje magnetometar . Kako bi se ipak mogli riješiti problemi poravnanja IMU senzora s ljudskim tijelom, kao i korištenje sustava bez prethodno potrebne kalibracije, implementirano je i nadograđeno pronađeno rješenje opisano u [58]. Dodatno, navedeno rješenje odabrano je

jer komplementira mjerenja dobivena s UWB sustavom prilikom fuzije senzora.

3.1 Modeliranje mjerenja udaljenosti korištenjem ultraširokopojasnih senzora

Rezultati dobiveni u [3] pokazuju da je moguće koristiti UWB tehnologiju za mjerenje udaljenosti kako bi se odredio kut promatranih zglobova. Općenito, kut se može dobiti iz udaljenosti izmjerene između dvaju čvora postavljenih na suprotnim stranama zgloba, kako je prikazano na slici 3.1. Na sličan način može se odrediti kut koljena. Ako se udaljenosti d_1 i d_2 odrede prije samog mjerenja, iz udaljenosti između čvorova d može se odrediti kut uz korištenje trigonometrijskog izraza:

$$\cos\alpha = \frac{d_1^2 + d_2^2 - d^2}{2d_1 d_2}. \tag{3.1}$$

Udaljenost između dva UWB čvora se općenito određuje uz pomoć TOA metode. Za vremenski nesinkronizirane čvorove, primjenjuje se već prije spomenuta RTOF metoda. Tijekom komunikacije bilježe se četiri vremena od T_1 do T_4. Iz razlike tih vremena dobiva se vrijeme τ_{ij} koje je elektromagnetskom valu potrebno da propagira od jednog do drugog čvora te se iz toga može odrediti udaljenost:

$$\hat{d} = c \times \tau_{ij} = c \times \frac{(T_4 - T_1) - (T_3 - T_2)}{2}, \tag{3.2}$$

gdje je c brzina propagacije elektromagnetskog vala. RTOF, odnosno dvostrana metoda određivanja udaljenosti (engl. *two way ranging*, TWR), svojim pristupom uklanja potrebu za žičnom ili bežičnom sinkronizacijom, tako da se razlikom uklanjaju poznati ili nepoznati izvori vremenskih kašnjenja, kao i vremenska odstupanja čvora. Jednadžba 3.2 je najjednostavnija od svih TWR metoda i poznata je pod imenom jednostrana TWR metoda (engl. *single-sided*

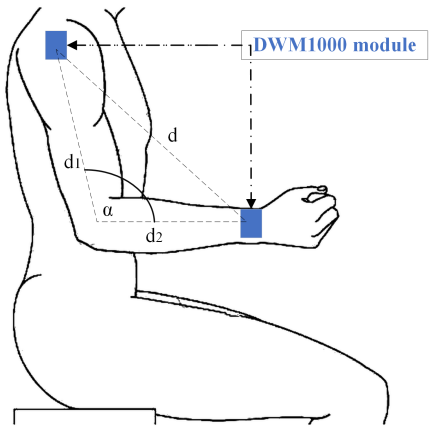

Slika 3.1: Određivanje kuta zgloba korištenjem pristupa mjerenja udaljenosti

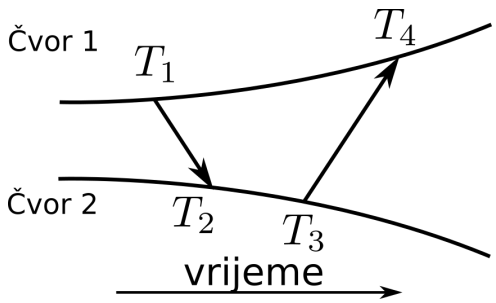

Slika 3.2: Simbolički prikaz tijeka komunikacije prilikom RTOF mjerenja u slučaju nesavršenosti oscilatora

two way ranging, SS-TWR). Dodatne varijacije postoje u obliku simetrične dvostrane metode (engl. *symmetric double-sided TWR*, SDS-TWR), alternativne dvostrane TWR metode (engl. *alternative double-sided TWR*, AS-TWR), asimetrične dvostrane TWR metode (engl. (engl. *asymmetric double-sided TWR*, ASDS-TWR) itd. U svim navedenim varijacijama zanošenje izvora vremena, odnosno *drift* izvora takta, uz pomoć kojega se određuje vrijeme dolaska paketa, predstavlja glavni izvor pogreške tijekom određivanja udaljenosti te su upravo taj parametar primarno analizira i modelira [101]. Primjerice, odstupanje od svega 1 ns može prouzročiti pogrešku od 30 cm prilikom određivanja udaljenosti uz pomoć jednadžbe 3.2. U većini prijašnih istraživanja podrazumijeva se da su čvorovi statični u vremenu sa stabilnim izvorima takta, općenito ili barem u vremenu tijekom određivanja udaljenosti. Međutim, ta pretpostavka opravdana je samo u idealnim uvjetima gdje zasebni oscilatori na čvorovima ne odstupaju zbog utjecaja temperature, odnosno njezine razlike ili nedostataka prilikom izrade samih čvorova. Ovo simbolično prikazuje slika 3.2, gdje su kao i na slici 2.3 prikazana dva nezavisna oscilatora, ali u realnim uvjetima gdje se s vremenom razilaze. Navedni utjecaji su nelinearne prirode i predstavljaju sustavnu pogrešku prilikom određivanja udaljenosti. Bez obzira na to, TWR metode su široko korištene pod pretpostavkom da je trajanje između poslanog i primljenog paketa dovoljno kratko tako da odstupanja nezavisnih izvora vremena čine zanemariv utjecaj na sam izračun udaljenosti. Ovaj pristup je odgovarajući u slučajevima kada se UWB koristi u fuziji s IMU mjerenjem kao svojevrsna nadopuna, odnosno korekcija prije spomenutih nesavršenosti inercijskih senzora [1, 85, 93]. Također, navedeni pristup ima smisla ako se koristi precizna laboratorijska oprema za generiranje i primanje UWB signala [3, 8]. U slučajevima gdje se koriste mobilni čvorovi od kojih svaki ima svoj zasebni izvor takta potreban je drugačiji pristup.

Prema [3] dva su glavna izvora pogrešaka prilikom određivanja kuta zgloba, a to su položaji antena na rukama i sama greška mjerenja udaljenosti pomoću UWB-a. Postavljanjem ruke na fiksnu poziciju može se izračunati utjecaj pogreške na estimaciju kuta tako da se uključi u udaljenost d. Primjerice, postavi li se ruka na 90° i uračuna li se standardna devijacija od 10 cm, dobiva se pogreška od gotovo 60° prilikom estimacije.

Iz svega navedenog može se zaključiti da nije moguće koristiti samo TWR metodu uz ko-

rištenje DW1000 kao mjernog sustava. Kako bi se pružila dovoljna preciznost prilikom estimacije kuta zgloba, potrebno je razviti model koji će osim određivanja udaljenosti estimirati i ponašanje oscilatora tokom izvođenja mjerenja.

3.1.1 Kompenzacija vremenske baze

Lokalni unutarnji satovi svakog od čvorova i u lokalnom vremenu t_i mogu se opisati kao:

$$t_i = \omega t + \phi_i \quad \Leftrightarrow \quad \mathscr{C}_i(t_i) \triangleq t = \alpha_i t_i + \beta_i, \tag{3.3}$$

gdje t predstavlja vrijeme *idealnog* sata. Zanošenje sata (engl. *skew*) označeno je s $\omega_i \in \mathbb{R}_+$, dok je odmak od početka praćenja vremena idealnog sata (engl. *offset*) označen s $\phi_i \in \mathbb{R}$. $\mathscr{C}_i(t_i)$ označava transformaciju lokalnog vremena t_i u *idealno* vrijeme t. Za dva čvora koja sudjeluju u TWR metodi određivanja udaljenosti, kao što je opisano jednadžbom 3.2, postoji 5 nepoznatih parametara: dva nepoznata *offset*-a, dva nepoznata *skew* parametra i sama udaljenost između čvorova. Prema [102] nemoguće je odrediti svih 5 parametara koliko god izmjenenih poruka ili vremenskih oznaka iskoristili tokom estimacije. Kako bi se parametri ipak mogli estimirati, uobičajeno je da se jedan od čvorova proglasi referetnim, uz ograničenja $\alpha_i = 1$ and $\beta_i = 0$. Čak i s ovim pretpostavkama postoje različiti pristupi prilikom estimiranja ostalih parametara. Kako je već prije bilo spomenuto, jedan od pristupa podrazumijeva potpuno zanemarivanje promjena koje utječu na mjerenje vremena. Kako je već analiza pokazala, to nije primjenjivo u slučaju ovo istraživanja gdje se koriste mobilni čvorovi sa zasebnim izvorima takta čije pogreške eksponencijalno utječu na estimaciju kuta zgloba.

U literaturi opisano je nekoliko različitih pristupa estimiranja nepoznatih parametara [8, 103, 104], od korištenja procijenjene maksimalne vjerojatnosti (ML) koja istovremeno estimira pozicije i odstupanja u mjerenjima, do rješenja dobivenih metodom najmanjih kvadrata (LSS) gdje je model opisan jednadžbom 3.3 proširen kvadratnim parametrom koji opisuje zanošenje frekvencije samog oscilatora. *Skew* parametar se čak može estimirati tijekom izvršenja TWR metode pomoću linearne estimacije vremenskih oznaka (engl. *timestamps*) [105]. Niti jedna od prije spomenutih metoda ne estimira parametre satova, kao i promjenu udaljenosti, istovremeno.

U ovom doktorskom radu predlaže se zajedničko estimiranje udaljenosti između para čvorova, kao i parametari njihovih internih satova, prema modelu koji je predložen u [106]. Predloženi estimator se izvorno koristio u distribuiranim bežičnim mrežama u statičnim i dinamičnim situacijama gdje su udaljenosti, odnosno kašnjenja između pojedinih čvorova, nepoznata. Nepoznata kašnjenja, odnosno udaljenosti, aproksimiraju se Taylorovim redom određenog reda s ciljem organizacije komunikacije bežične mreže. U tom kratkom vremenskom prozoru prilikom odvijanja mjerenja vremenske oznake se kompenziraju s parametrima modela sata prvog reda opisanog jednadžbom 3.3. Korištenjem predloženog modela i estimatora može se pove-

ćati preciznost određivanja udaljenosti u slučajevima nestabilnih parametara satova. Kako bi se estimator mogao koristiti u stvarnom vremenu i u dinamičkim uvjetima, prilikom kontinuiranog gibanja potrebno je optimirati parametre Taylorovog reda s brojem korištenih uzoraka. Iz tih razloga bilo je potrebno razviti algoritamsko proširenje estimatora iz [106] radi određivanja optimalnih parametara Taylorovog reda i broja uzoraka korištenih prilikom estimacije. Detaljan raspis metode iz [106] nalazi se u poglavlju 5 gdje je i u nastavku dan prijedlog proširenja algoritma.

3.2 Modeliranje mjerenja korištenjem inercijskih senzora

Kao što je već prije bilo spomenuto, IMU senzori koriste se za određivanje pokreta dijelova ljudskog tijela zbog svoje pristupačne cijene i veličine. Prvenstveno se koriste troosni akcelerometri i žiroskopi kako bi izmjerili promjenu akceleracije i brzine rotiranja. Dvostrukom, odnosno jednostrukom integracijom tih dviju izmjerenih veličina mogu se estimirati promjena orijentacije i relativni pomak u prostoru. Zbog postupka integracije, estimirane vrijednosti tipično su valjane samo u kratkom vremenu mjerenja zbog pojave integracijske pogreške. Kako bi se smanjio utjecaj pogreške, primijenjuju se različite tehnike kompenzacije. Primjerice, mjerenje orijentacije može se izvoditi u statičnim uvjetima kada nema utjecaja vanjske sile na akcelerometar. Također, mogu se koristiti senzori i sustavi koji nisu pod utjecajem sustavnih grešaka kao što su magnetometri ili LPS sustavi za lokalno ili globalno pozicioniranje. Ipak, uvođenjem dodatnih rješenja cijeli mjerni sustav se ili poskupljuje ili mu se smanjuje opseg moguće primjene zbog uvođenja dodatnih ograničenja. Iz tih razloga prilikom mjerenja ljudskog pokreta s IMU senzorima uzimaju se u obzir kinematički modeli kretanja čovjeka, odnosno kinematički lanci (engl. *kinematic chains*) koji opisuju kretanja segmenata povezanih sa zglobovima s više stupnjeva slobode. Korištenjem ove informacije modeli kretanja pojedinih segmenata mogu se redefinirati, pojednostaviti ili čak postaviti tako da uključuju korištenje višestrukih izvora informacija, odnosno korištenje parova IMU senzora u slučaju ovog istraživanja. Generalizirani model kretanja često se opisuje s Denavit–Hartenbe (D-H) jednadžbama koje koriste parametre udaljenosti između zglobova, kao i njihove kuteve [1]. Ipak, za parove IMU senzora, koje je ionako potrebno koristiti za određivanje udaljenosti uz pomoć UWB-a, može se koristiti pojednostavljeni model kinematičkog lanca opisan u [58].

3.2.1 Generalizirani model kinematskog lanca s dva segmenta

Uzme li se da su L_1 i L_2 lokalni kooordinatni sustavi dvaju IMU senzora, postavljenih na ljudskoj ruci kao što je prikazano na slici 3.3, tada u globalnom Zemljinom koordinatnom sustavu

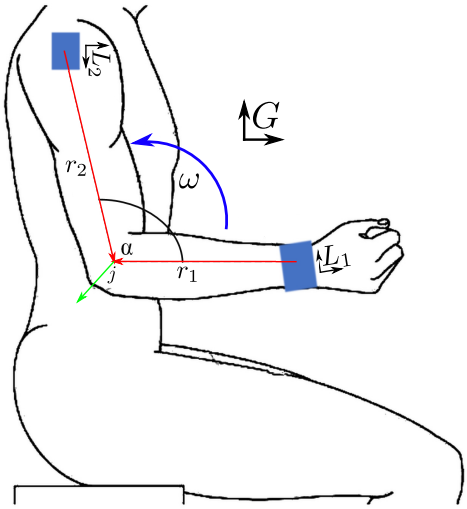

Slika 3.3: Određivanje kuta zgloba korištenjem IMU senzora

G može se izraziti izmjerena akceleracija a_i oba senzora kao:

$$a_i^{L_i} = a_0^{L_i} + \omega_i^{L_i} \times \left(\omega_i^{L_i} \times r_i^{L_i}\right) + \dot{\omega}_i^{L_i} \times r_i^{L_i} \qquad i \in 1,2\,, \tag{3.4}$$

gdje je $a_0^{L_i}$ akceleracija centra rotacije, dok su $\omega_i^{L_i}$ i $\dot{\omega}_i^{L_i}$ kutna brzina i kutna akceleracija izražene u koordinatnom sustavu senzora. Veličina r_i predstavlja poziciju IMU senzora s obzirom na promatrani zglob. U daljnjem tekstu smatra se da su sve mjerene veličine iskazane u lokalnom koordinatnom sustavu senzora kako bi se povećala preglednost izraza i smanjila potreba za posebnim notacijama. Korištenjem sljedećeg identiteta:

$$[a]_\times \equiv \begin{bmatrix} 0 & -a_z & a_y \\ a_z & 0 & -a_x \\ -a_y & a_x & 0 \end{bmatrix}, \tag{3.5}$$

jednadžbe 3.4 mogu se zapisati kao:

$$a_i = a_0^{L_i} + K(\omega_i, \dot{\omega}_i) r_i, \tag{3.6}$$

gdje je matrica $K(\omega_i, \dot{\omega}_i)$ oblika:

$$K(\omega_i, \dot{\omega}_i) = \begin{bmatrix} -\omega_y^2 - \omega_z^2 & \omega_x\omega_y - \dot{\omega}_z & \omega_x\omega_z + \dot{\omega}_y \\ \omega_x\omega_y + \dot{\omega}_z & -\omega_x^2 - \omega_z^2 & \omega_y\omega_z + \dot{\omega}_x \\ \omega_x\omega_z - \dot{\omega}_y & \omega_y\omega_z + \dot{\omega}_x & -\omega_z^2 - \omega_y^2 \end{bmatrix}. \tag{3.7}$$

Kako bi se povećala preglednost izraza, matrica $K(\omega_i, \dot{\omega}_i)$ označavat će se kao K_i u daljnjem tekstu. Važno je napomenuti da se akceleracije kutne brzine $\dot{\omega}_i$ dobivaju iz mjerenih veličina ω_i korištenjem simetrične derivacije drugog reda:

$$\dot{\omega}(k) \approx y_{\dot{\omega}}(k) = \frac{y_\omega(k+1) - y_\omega(k-1)}{2h}, \tag{3.8}$$

gdje je h vrijeme uzrokovanja. Dakako, i viši redovi derivacije mogu biti korišteni prilikom estimacije akceleracije kutne brzine [60].

Veličine dobivene s 3.4 izražene su u koordinatnim sustavima pojedinih IMU senzora. Ako su poznate orijentacije senzora s obzirom na koordinatni sustav Zemlje G, jednadžbe 3.4 mogu se izraziti kao:

$$a_0^G = R_1^{GL_1} a_0^{L_1} = R_2^{GL_2} a_0^{L_2}, \tag{3.9}$$

gdje je $R_i = R_i^{GL_i}$ rotacijska matrica veličine 3×3 koja definira translaciju veličine iz koordinatnog sustava IMU senzora u koordinatni sustav Zemlje. Njihova razlika se tada može izraziti kao:

$$R_1^{GL_1} a_0^{L_1} - R_2^{GL_2} a_0^{L_2} = a_0^G - a_0^G + R_1^{GL_1} K_1 r_1 - R_2^{GL_2} K_2 r_2 = R_1^{GL_1} K_1 r_1 - R_1^{GL_2} K_1 r_1, \tag{3.10}$$

što tvori linearni sustav jednadžbi koji ovise o vektoru $r = [r_1\ r_2]^T$. Sustav za N mjerenja može se raspisati kao:

$$\tilde{K} r = \tilde{a} \tag{3.11}$$

$$\tilde{K} = \begin{bmatrix} \tilde{K}(1) \\ \tilde{K}(2) \\ \vdots \\ \tilde{K}(N) \end{bmatrix} = \begin{bmatrix} R_1(1)K_1(1) & -R_2(1)K_2(1) \\ R_1(2)K_1(2) & -R_2(2)K_2(2) \\ \vdots & \\ R_1(N)K_1(N) & -R_2(N)K_2(N) \end{bmatrix}, \tag{3.12}$$

$$\tilde{a} = \begin{bmatrix} \tilde{a}(1) \\ \tilde{a}(2) \\ \vdots \\ \tilde{a}(N) \end{bmatrix} = \begin{bmatrix} R_1(1)a_1(1) - R_2(1)a_2(1) \\ R_1(2)a_1(2) - R_2(2)a_2(2) \\ \vdots \\ R_1(N)a_1(N) - R_2(N)a_2(N) \end{bmatrix}. \tag{3.13}$$

Rješenje se može dobiti metodom najmanjih kvadrata () tako da se minimizira razlika kvadrata pogrešaka:

$$\hat{r}_{LS} = \text{argmin} \sum_{k=1}^{N} \left|\left|\tilde{K}r - \tilde{a}\right|\right|_2^2, \tag{3.14}$$

$$\hat{r}_L S = \tilde{K}^{\dagger}\tilde{a}, \tag{3.15}$$

gdje $\tilde{K}^{\dagger}$ predstavlja Moore-Penrose pseudo inverz. Iako se ovom metodom izravno dobiva rješenje, ona zahtijeva ponovnu estimaciju orijentacijskih matrica R_1 i R_2 s obzirom na koordinatni sustav Zemlje, što uvodi nesigurnost u mjerenje, pogotovo jer razne metode određivanja orijentacije IMU senzora zahtijevaju magnetometre, razdoblja mirovanja ili posebne metode inicijalizacije koje se nastoje izbjeći.

U [58] predloženo je korištenjem L^2-norme i iterativnih metoda optimizacije odrediti r u trenutku k bez određivanja orijentacija IMU senzora korištenjem izraza:

$$\hat{r}_{GN} = \text{argmin} \sum_{k=1}^{N} e(k,r)^2 = \text{argmin} \sum_{k=1}^{N} \left(||a_1(k) - K_1(k)r_1||_2 - ||a_2(k) - K_2(k)r_2||_2\right)^2. \tag{3.16}$$

Prilikom korištenja L^2-norme, gravitacijske komponente a_0 se međusobno poništavaju jer za njih vrijedi $||a_0^{L_1}||_2 = ||a_0^{L_2}||_2$. Pod iterativnim metodama smatra se Gauss-Newtonova optimizacija koja zahtijeva određivanje Jakobijana funkcije greške. Parcijalne derivacije $e(k,r)$ po r_1 i r_2 tada imaju oblike:

$$J = \frac{\partial e(k,r)}{\partial r_i} = (-1)^i \frac{K_i(k)^T e_i(k,r)}{||e_i(k,r)||_2} \qquad i \in 1,2, \tag{3.17}$$

gdje je:

$$e_i(k,r_i) = a_i(k) - K_i(k)r_i \qquad i \in 1,2. \tag{3.18}$$

Važno je napomenuti da niti jedna od navedenih metoda ne daje jednoznačno rješenje. U slučaju pojave smetnji u mjerenjima moguć je lokalni minimum u kojem će estimacija imati netočan rezultat [60]. Također, kao i u [59], prilikom implementacije 3.16 primijećeno je da metoda postaje nestabilna nakon korištenja više od desetak uzoraka. Kao i slučaju estimacije kuta ko-

rištenjem UWB tehnologije, u ovom radu predlaže se segmetirano estimiranje koje uzima u obzir zaključke dobivene analizom Allanove varijance žiroskopskih i akcelerometarskih mjerenja kako bi se minimizirao utjecaj s usrednjavanjem rezultata.

Uzroci nestabilnosti optimizacije mogu se odrediti uz pomoć analize Fischerove informacijske matrice (FIM), kako je i učinjeno u [61]. Pošto se FIM može izraziti za neki proces s kovarijancijskom matricom W kao:

$$\text{FIM} = J^T W^{-1} J, \tag{3.19}$$

analiza se svodi na proučavanje situacija kada matrica J ima nepun rang. Prema [61] postoje tri situacije u kojima se to događa:

- kada ne postoji rotacija u barem dva stupnja slobode kretanja zgloba. Primjerice, ako su komponente $\omega_x = \omega_y = 0$, posljedično i $\dot{\omega}_x = \dot{\omega}_y = 0$, tada je cijeli jedan stupac matrice J jednak 0, što reducira rang matrice. Ovo je situacija kada se mjerenja izvode na zglobovima kao što su lakat ili koljeno, koji imaju slobodu kretanja samo u jednom smjeru.
- kada postoji jednoliki iznos rotacije u svim trima stupnjevima slobode. Primjerice, ako su $\omega_x = \omega_y = \omega_z$, posljedično $\dot{\omega}_x = \dot{\omega}_y = \dot{\omega}_z$, tada je zbroj svih stupaca pojedinog IMU senzora jednak 0.
- kada par IMU senzora ima slične rotacijske brzine u svim stupnjevima slobode. Tada je zajednički zbroj stupaca IMU senzora jednak 0.

Uvođenjem dodatnog čvora kao u [61] ili degeneracijom funkcije pogreške 3.16 kao u [58, 62] mogu se minimizirati navedeni uzroci singularnosti matrice J. Naravno, moguće je i rješenje temeljeno na logici odlučivanja zadovoljava li navedeni izmjereni uzorak prijašnje spomenute uvjete.

3.2.2 Model kinematskog lanca s dva segmenta za kutni zglob

U slučaju kutnog zgloba, odvojeni segmenti mogu se rotirati samo oko jednog stupnja slobode. Ako se uzme vektor j koji opisuje vektor normale zgloba s obzirom na smjer kretnje, tada vrijedi:

$$R_1 j_1 = R_2 j_2, \tag{3.20}$$

gdje su j_1 i j_2 vektori normale izraženi u koordinatnim sustavima pojedinih IMU senzora L_1 i L_2. U tom slučaju, kutnu brzinu može se razdijeliti na komponentu koja je paralelna i kompo-

nentu ortogonalnu s obzirom na os zgloba:

$$\begin{aligned} \omega_i &= \omega_{j_i||} + \omega_{j_1\perp} \\ \omega_{j_i\perp} &= \omega_i - \omega_{j_1||} \\ \omega_{j_i\perp} &= \omega_i - j_i^T \omega_i j_i \\ \omega_{j_i\perp} &= ||\omega_i \times j_i|| \,. \end{aligned} \tag{3.21}$$

Za ortogonalne komponente kutne brzine tada vrijedi:

$$\begin{aligned} \left|\left|\omega_{j_1\perp}\right|\right| &= \left|\left|\omega_{j_2\perp}\right|\right| \\ ||\omega_1 \times j_1|| &= ||\omega_2 \times j_2|| \end{aligned} \tag{3.22}$$

bez obzira na koordinatni sustav IMU senzora. Izraz 3.22 predstavlja ograničenje kutne brzine s obzirom na gibanje segmenata povezanih s kutnim zglobom. Iterativnim metodama optimizacije može se odrediti j u trenutku k minimizacijom pogreške:

$$\hat{j}_{GN} = \text{argmin} \sum_{k=1}^{N} e(k,j)^2 = \text{argmin} \sum_{k=1}^{N} \left(||\omega_1 \times j_1|| - ||\omega_2 \times j_2||\right)^2 . \tag{3.23}$$

Jakobijan pogreške izraza 3.23 tada je:

$$J_j = \frac{\partial e(k,j)}{\partial j_i} = \frac{(\omega_i \times j_i)^T}{||\omega_i \times j_i||} \cdot [g_i]_\times \,. \tag{3.24}$$

Na sličan način mogu se razmatrati i projekcije pojedinih akceleracija s obzirom na os zgloba kao i u [62] te dobiti:

$$j_1^T a_1 - j_2^T a_2 \approx 0. \tag{3.25}$$

Ipak, ovaj uvjet podrazumijeva da su radijalne i tangencijalne komponente akceleracije u smjeru osi zanemarive, odnosno da vrijedi $j_i K_i r_i \approx 0, \forall i$.

Poglavlje 4

Arhitektura i implementacija sustava za prikupljanje mjernih podataka

Za praktičnu evaluaciju modela predloženog u poglavlju 3, bilo je potrebno razviti arhitekturu i implementaciju sustava za prikupljanje mjernih podataka u obliku nosivih bežičnih senzorskih čvorova niske potrošnje. Čvorovi su bili razvijeni s ciljem da budu postavljeni na ljudsko tijelo te da imaju mogućnost mjerenja udaljenosti korištenjem UWB tehnologije i da sadrže ugrađene IMU senzore. U svrhu sklopovske realizacije sustava razvijeno je više inačica sklopovlja temeljenih na korištenju integriranog sklopa DW1000. Postojeći komercijalno dostupni razvojni sustavi nisu sadržavali sve potrebne sklopovske komponente nužne za provedbu i obradu mjerenja, a programske biblioteke proizvođača integriranog sklopa trebale su biti nadograđene novim mogućnostima s obzirom da postojeća programska potpora nije pružala svu potrebnu funkcionalnost. Rješenje temeljeno na DW1000 je također bilo evaluirano kako bi se dokazalo da je funkcionalno ispravno te da ne unosi sustavne pogreške. Također, ispitali su se različiti izvori pogrešaka koji mogu utjecati na točnost i preciznost mjerenja. Najveća pažnja posvetila se utjecaju uskopojasnih komunikacija, čiji se spektar preklapa s frekvencijskim područjem rada UWB komunikacijskog sustava, kao i utjecaju refleksija u okruženjima s višestaznim rasprostiranjem.

U ovom poglavlju će biti izložena sklopovska arhitektura i pojedine varijante implementacije rješenja, s pregledom najvažnijih mogućnosti integriranog sklopa DW1000. Potom će biti prikazana arhitektura programske potpore bežičnih senzorskih čvorova, s naglaskom na način strukturiranja programske potpore u višezadaćnom okruženju za rad u stvarnom vremenu korištenjem operacijskog sustava za rad u stvarnom vremenu (*FreeRTOS*). Na kraju poglavlja bit će prikazani rezultati eksperimentalnog ispitivanja različitih izvora smetnji na točnost i preciznost pozicioniranja pomoću UWB sustava temeljenog na integriranom sklopu DW1000.

4.1 Sklopovska arhitektura i izvedbe senzorskog čvora

Na slici 4.1a prikazana je blok shema sklopovske arhitekture prve verzije bežičnog senzorskog čvora, dok je na slici 4.1b prikazan izgled realizirane tiskane pločice. Prva inačica poslužila je za upoznavanje s mogućnostima Decawave DW1000 integriranog sklopa za UWB komunikaciju i uhodavanje inicijalne programske potpore za upravljanje UWB primopredajnikom. Sklop je razvijen sa ciljem da pruži:

- evaluacijsko okruženje za ispitivanje mogućnosti integriranog sklopa DW1000,
- razvoj programske potpore za mikrokontroler temeljen na ARM Cortex-M4 jezgri visokih performansi za izvođenje algoritama digitalne obrade signala i estimacije u stvarnom vremenu,
- mogućnost baterijskog ili neovisnog vanjskog napajanja,
- komunikaciju s računalom putem USART porta,
- komunikaciju s vanjskom periferijom putem SPI i GPIO sučelja,
- pohranu podataka na SD karticu,
- malene dimenzije i masu radi mogućnosti realizacije nosivog senzorskog čvora.

DW1000 je integrirani sklop razvijen od strane tvrtke Decawave Ltd. koji predstavlja potpuno integrirani UWB primopredajnik s podrškom za IEEE 802.15.4-2011 standard. Od najvažnijih mogućnosti integriranog sklopa važno je istaknuti sljedeće:

- mogućnost određivanja udaljenosti s točnošću od $\pm 10\,\text{cm}$,
- podrška za 6 kanala u frekvencijskom području 3,5 6 5 (podržani UWB kanali prikazani su u tablici 4.1),
- mogućnost podatkovne komunikacije pri brzinama od 110 kbps, 850 kbps i 6,8 Mbps, kako bi se minimiziralo vrijeme slanja poruka i omogućila postizanje niske potrošnje,
- mogućnost robusnog rada u uvjetima višestaznih refleksija korištenjem posebnih metoda analize višestaznih komponentni primljenog signala u sklopovlju u stvarnom vremenu,
- programabilna izlazna snaga odašiljača,
- sukladnost sa spektralnim maskama propisanim FCC i ETSI normama.

Najvažniji dio DW1000 primopredajnika, koji omogućuje precizno mjerenje udaljenosti TOA metodom, je vremensko-digitalni pretvornik (engl. *time-to-digital converter*, TDC) koji omogućuje postavljanje vremenskih oznaka uz podatkovne pakete s razlučljivošću od 15,6 ps. UWB modul ima mogućnost rada do udaljenosti od 70 m u LOS uvjetima i do 30 m u NLOS uvjetima. Prema podacima proizvođača, standarda devijacija mjerenja udaljenosti pomoću DW1000 primopredajnika iznosi 10 cm, što je ujedno mjera koja opisuje preciznost, ali točnost može varirati i u širim granicama, ovisno o nizu faktora (npr. radi li se u LOS i NLOS uvjetima, koristi li se izravno RTOF mjerenje ili dodatni estimator i sl.).

Sljedeći vrlo važan implementacijski detalj DW1000 primopredajnika je mogućnost oči-

tanja stanja komnikacijskog kanala u vidu prikupljanja impulsnog odziva (CIR). Korištenjem CIR-a DW1000 primopredajnik određuje udaljenost praćenjem dolazaka višestaznih komponenti impulsa prema modelima UWB propagacije ranije opisanima u poglavlju 2.2. Na temelju analize CIR-a može se utvrditi radi li se o lokaciji u kojoj postoji veći broj refleksija, je li nepovoljan odnos signal-šum i sl. Akumulator CIR-a predstavlja sumu svih dolaznih UWB impulsa tijekom trajanja preambule UWB podatkovnog paketa. Pri tome višestazne komponente primljenog signala mogu biti atenuirane, pomaknute u vremenu ili oboje, zbog utjecaja izvora refleksija i raspršenja, kako je bilo opisano u poglavlju 2.2. Uz pomoć patentiranih algoritama [107] DW1000 određuje trenutak dolaska prvog UWB impulsa, čije je trajanje povezano sa širinom spektra signala jednadžbom:

$$T_f = \frac{1}{B}, \tag{4.1}$$

gdje je T_f trajanje impulsa, a B širina frekvencijskog pojasa. Jednadžba 4.1 upućuje na to da što je frekvencijski raspon signala širi, to je trajanje UWB impulsa kraće, i obrnuto. U praktičnim mjerenjima je pokazano da što je veći šum prisutan u CIR-u, to će ugrađenim algoritmima na razini integriranog sklopa biti teže odrediti stvarno i točno vrijeme dolaska prvog UWB impulsa. Stoga se CIR koristio tijekom provedenih eksperimenata kao dodatna metrika usporedbe provedenih mjerenja, kako bi se vjerodostojnije karakteriziralo ukupno stanje kanala i njegov utjecaj na određivanje same udaljenosti između UWB modula. Sam CIR akumulator DW1000 primopredajnika sadrži 4065 okteta podataka o stanju kanala te se zapisuje prilikom primitka svake nove poruke (točnije, ovisno o postavkama programske potpore). Akumulator se sastoji od 992, odnosno 1016 uzoraka, ovisno o tome je li frekvencija ponavljanja impulsa (PRF) tijekom komunikacije postavljena na 16 ili na 64 MHz. Svaki od uzoraka CIR-a predstavljen je kompleksnim brojem sa 16-bitnom realnom vrijednošću a_k i 16-bitnom imaginarnom vrijednošću b_k. CIR se može izraziti kao:

$$h = \sum_{k=1}^{N} a_k + jb_k = \sum_{k=1}^{N} A_k e^{j\theta_k}, \tag{4.2}$$

gdje $A_k = \sqrt{a_k^2 + b_k^2}$ predstavlja amplitudu, a $\theta = \arctan b_k/a_k$ fazu signala. Akumulator DW1000 integriranog sklopa predstavlja zapis trajanja od približno 1 ns.

Prva prototipna verzija nosivog bežičnog senzorskog čvora, uz DW1000 primopredajnik, sadrži i druge dijelove važne za potrebe ispitivanja. Primjerice, mikrokontroler koji izvodi specifično razvijenu programsku potporu za upravljanje DW1000 integriranim sklopom i protokole za određivanje udaljenosti među čvorovima. Zatim je implementirano napajanje s mogućnošću rada s ulaznim naponima od 1,8 V do 5,5 V (projektirano za upotrebu s različitim vrstama baterija), podrška za komunikaciju preko konektora za proširenje (GPIO, UART, SPI), kao i sučelje SD kartice za pohranu podataka prikupljenih tijekom ispitivanja. Dostupno je i sučelje za pro-

Tablica 4.1: UWB kanali koje podržava DW1000 primopredajnik

Broj UWB kanala	Centralna frekvencija (MHz)	Pojas (MHz)	Širina frekvencijskog pojasa (MHz)
1	3494,6	3244,8 - 3744	499,2
2	3993,6	3774 - 4243,2	499,2
3	4492,8	4243,2 - 4742,4	499,2
4	3993,6	3328 - 4659,2	1331,2*
5	6489,6	6240 - 6739,2	499,2
7	6489,6	5980,3 - 6998,9	1081,6*

*DW1000 podržava maksimalnu širinu frekvencijskog pojasa od 900 MHz

gramiranje i uklanjanje pogrešaka (engl. *debug interface*). Korišten je mikrokontroler temeljen na ARM Cortex-M4 arhitekturi (STM32F401), koji radi na frekvenciji do 84 MHz i sadrži dodatne resurse, poput jedinice za računanje s pomičnim zarezom (engl. *floating point unit*, FPU). Navedena jedinica je važna za samu implementaciju algoritama za određivanje položaja. Na samoj pločici nije korišten izravno integrirani sklop DW1000, već DWM1000 modul, koji je izveden u obliku kompaktne tiskane pločice na kojoj se nalaze DW1000 primopredajnik, UWB antena i lokalni oscilator. Mikrokontroler upravlja DW1000 primopredajnikom putem SPI sučelja. Mikrokontroler i DWM1000 modul rade s napajanjem od 3,3 V, tipičnom potrošnjom struje u mirovanju od 42 µA, odnosno 2 µA. Dimenzije projektirane tiskane pločice su 60 $\times$ 25 mm, što uključuje 10 mm razmaka potrebnog za ugrađenu UWB antenu.

Nakon početnog upoznavanja s mogućnostima UWB primopredajnika i razvoja osnovne programske potpore za određivanje udaljenosti između senzorskih čvorova, provedena je nadogranja postojeće sklopovske platforme dodavanjem inercijskih senzora. Utvrđeno je da će za potrebe nastavka istraživanja biti potrebno koristiti akcelerometar i žiroskop za senzorsku fuziju s podsustavom za UWB određivanje udaljenosti. Blok shema druge inačice bežičnog senzorskog čvora prikazana je na slici 4.2a, a izvedba same tiskane pločice na slici 4.2b. Glavna razlika u odnosu na prvu inačicu senzorskog čvora je dodavanje senzora LSM9DSO, koji sadrži troosni akcelerometar, žiroskop i magnetometar, a koji s mikrokontrolerom komunicira putem SPI sučelja. Senzor omogućuje mjerenje akceleracije u rasponima $\pm 2g/\pm 4g/\pm 6g/\pm 8g/\pm 16g$, promjene magnetskog polja od $\pm 2/\pm 4/\pm 8/\pm 12$ Gs i brzinu rotacije od $\pm 245/\pm 500/\pm 2000$ dps. Dodatno, cijelo sklopovlje bilo je prilagođeno za strojnu serijsku montažu radi lakše izrade većeg broja jedinica.

Treća inačica sklopovlja senzorskog čvora razvijena je kako bi se popravili neki od uočenih implementacijskih nedostataka u prve dvije prototipne verzije i pružile određene dodatne mogućnosti za praktično korištenje razvijenog prototipa za potrebe budućih istraživanja [108] . Na

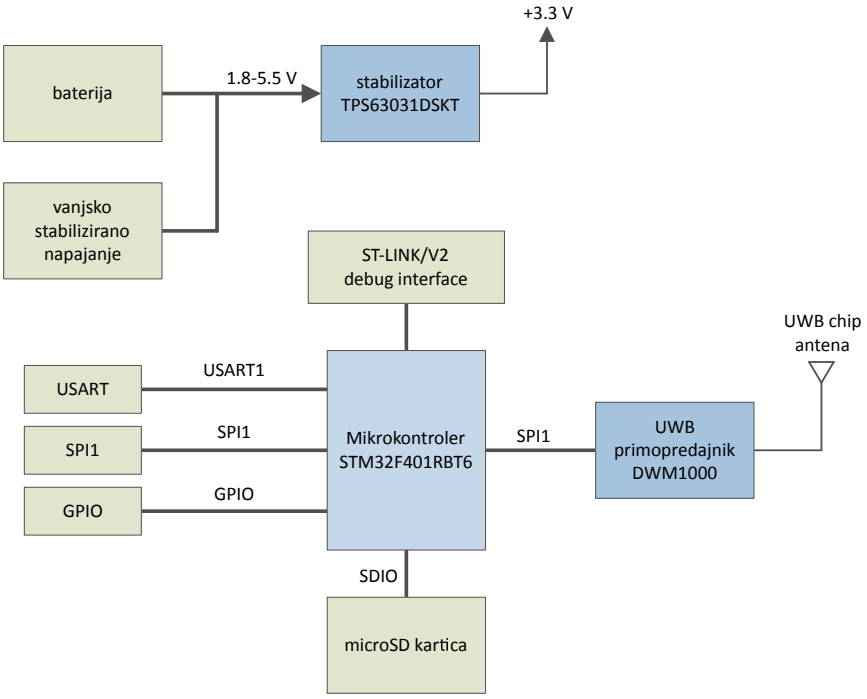

(a)

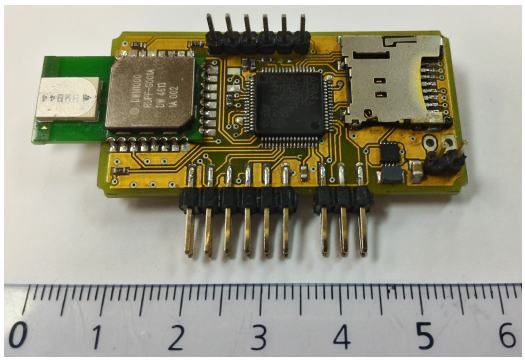

(b)

Slika 4.1: Prva inačica implementacije bežičnog senzorskog čvora

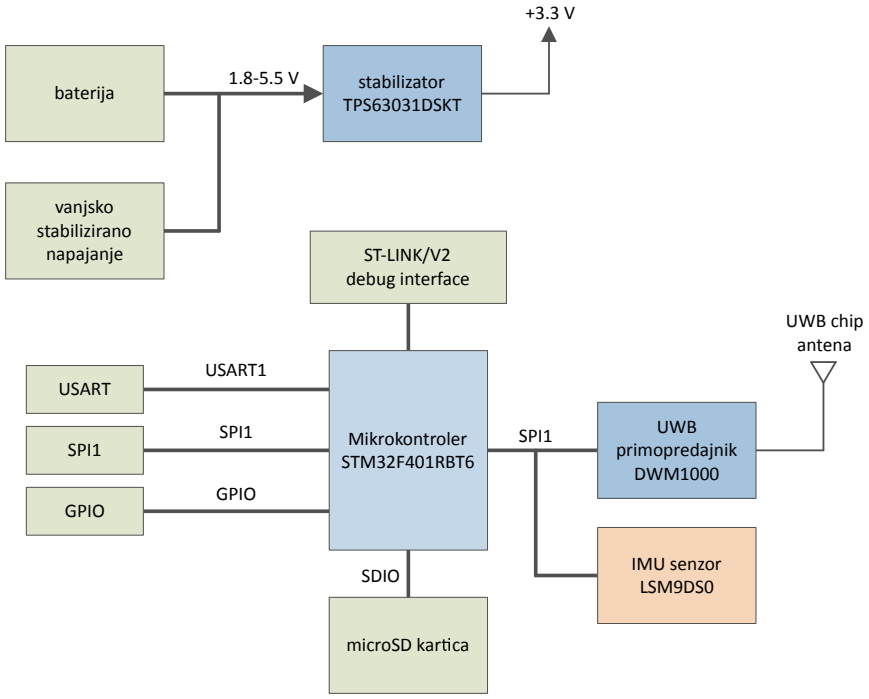

(a)

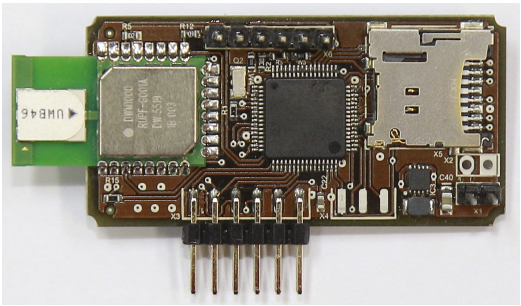

(b)

Slika 4.2: Druga inačica implementacije bežičnog senzorskog čvora

slici 4.3a prikazan je blok dijagram senzorskog čvora, a na slici 4.3b njegova izvedba. Odabran je mikrokontroler nRF52840 tvrtke Nordic Semiconductor, koji se također temelji na ARM Cortex-M4F jezgri s FPU podrškom, a dodatno podržava cijeli niz komunikacijskih protokola koji se koriste za bežične senzorske mreže niske potrošnje (802.15.4, Bluetooth Low Energy (BLE), ANT, Thread, Zigbee, s predkompajliranim izvršnim datotekama, tzv. Nordic *Soft Devices*). Odabrani mikrokontroler karakterizira izrazito niska potrošnja, uz glavni takt procesora do 64 MHz, 256 kB RAM-a, 1 MB Flash memorije, 48 ulazno-izlaznih priključaka opće namjene te raspon napajanja od 1,7 do 5,5 V. Mikrokontroler na samom integriranom sklopu sadrži prilagodni krug za spajanje vanjske BLE antene, što olakšava dizajn sklopovlja. Senzorski čvor sadrži LIS2DH12 troosni MEMS akcelerometar, kojeg karakterizira izrazito niska potrošnja, raspon mjerenja akceleracije od $\pm 2g, \pm 4g, \pm 8g, \pm 16g$, I2C i SPI sučelje te dvije prekidne linije za komunikaciju s mikrokontrolerom. Omogućeno je napajanje putem USB priključka ili baterije, s time da je na pločicu ugrađen punjač Li-Ion/Li-Po baterija MCP73831 kako bi se olakšao rad s nadopunjivim baterijama. Za dobivanje potrebnih napona napajanja od 3,3 V u 1,8 V korišteni su stabilizatori TPS63031 i LP5910. Ova inačica senzorskog čvora također ima mogućnost pohrane podataka na SD karticu. Za UWB komunikaciju koristi se drugačija izvedba u odnosu na prve dvije verzije jer se umjesto DWM1000 modula koristi DW1000 integrirani sklop ugrađen na tiskanu pločicu, zajedno s pratećim pasivnim komponentama i lokalnim oscilatorom. Razlog tome je da je na tiskanu pločicu dodan konektor za vanjsku UWB antenu kako bi se mogla provesti ispitivanja s različitim UWB antenama, što nije moguće s DWM1000 modulom kod kojega je na tiskanu pločicu fiksno ugrađena čip antena. Oblik tiskane pločice kompatibilan je s *Mini PCI Express Full-Mini-Type-F1* standardom kako bi se tiskana pločica mogla po potrebi lakše ugraditi u prijenosno računalo. Od poboljšanja u odnosu na prethodne inačice sklopovlja važno je istaknuti sljedeće:

- mogućnost Bluetooth komunikacije,
- priključak za vanjsku UWB antenu za fleksibilnija testiranja i buduća istraživanja,
- USB priključak (napajanje i komunikacija),
- 3,3 V naponski regulator (DC-DC pretvornik u *buck-boost* topologiji),
- 1,8 V linearni LDO naponski regulator,
- temperaturno kompenzirani 38,4 MHz oscilator (eng. TCXO) za DW1000, radi bolje stabilnosti vremenske baze za generiranje vremenskih oznaka i preciznijeg mjerenja udaljenosti,
- 32 MHz i 32,768 kHz oscilatori za mikrokontroler.

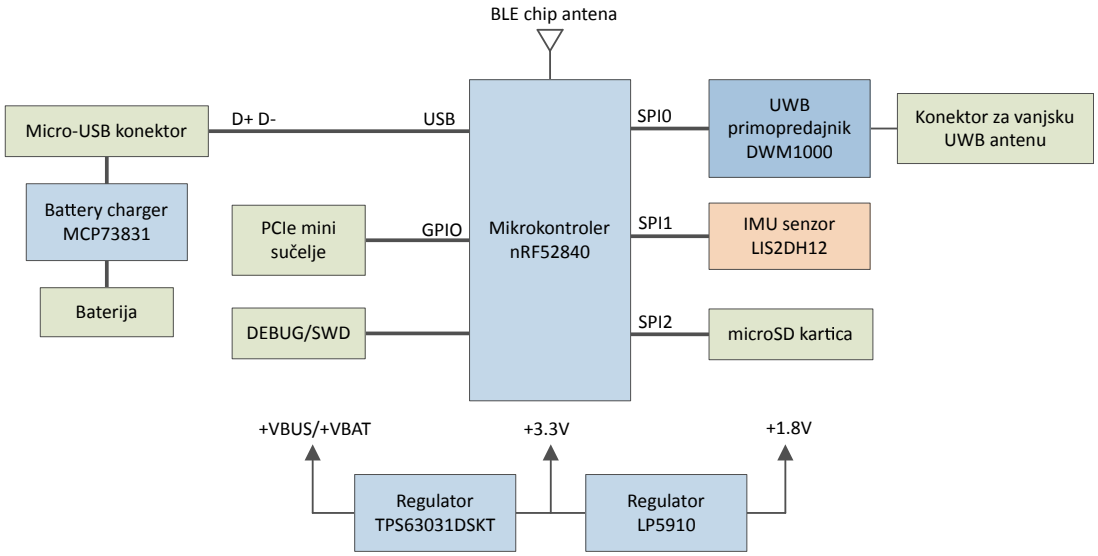

(a)

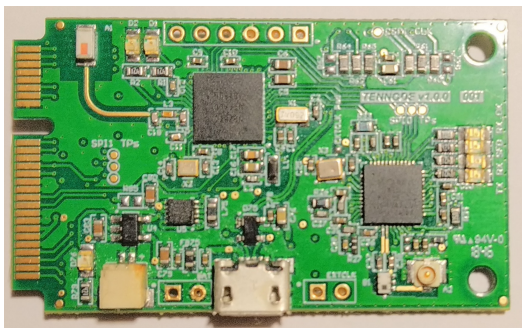

(b)

Slika 4.3: Treća inačica implementacije bežičnog senzorskog čvora

4.2 Arhitektura programske potpore senzorskog čvora

Za potrebe istraživanja mogućnosti primjene UWB tehnologije za preciznu lokalizaciju bilo je potrebno razviti odgovarajuću programsku potporu za bežični senzorski čvor. Programska potpora razvijena je za Cortex-M4 porodicu mikrokontrolera u programskom jeziku *C*, a strukturirana je tako da se omogući jednostavna prenosivost između različitih mikrokontrolerskih platformi. Najvažniji dio programske potpore je dio koji služi za upravljanje i nadzor DW1000 primopredajnika. Korištena je biblioteka programskih upravljačkih rutina koje nudi proizvođač, uz nadogradnju aplikacijskog koda prilagođenu potrebama istraživanja kako bi se mogli na fleksibilan način mogli implementirati algoritmi za određivanje udaljenosti korištenjem UWB primopredajnika, opisani u poglavlju 2.2.

Na slici 4.4 prikazani su glavni programski moduli i najvažnije vanjske programske biblioteke korištene za implementaciju programske potpore senzorskog čvora. Programska potpora razvijena je za STM32F4xx porodicu mikrokontrolera, pri čemu je korištena biblioteka *STM32F4 Standard Peripheral Library* sa skupom gotovih upravljačkih funkcija niske razine za komunikaciju s periferijskim jedinicama. Za upravljanje primopredajnikom korištena je programska biblioteka *decadriver*, koja sadrži niz funkcija niske razine za upravljanje i komunikaciju s DW1000 sklopom, što uključuje konfiguriranje sklopa, dohvaćanje stanja, slanje i primanje paketa i sl. Međutim, iako biblioteka *decadriver* nudi široku funkcionalnost i brojne mogućnosti upravljanja integriranim sklopom, nema implementirane više razine funkcionalnosti, kao što su MAC (*media access layer*) sloj, komunikacijski protokoli za razmjenu poruka, protokoli i algoritmi za mjerenje udaljenosti i pozicioniranje, algoritmi za bežičnu kompenzaciju nesigurnosti vremenske baze čvorova, estimatori položaja i sl. Sve te funkcionalnosti mora implementirati korisnik biblioteke, koja je dodatno razvijena za potrebe istraživanja. S obzirom da DW1000 primopredajnik implementira funkcionalnost razmjene poruka u vidu razmjerno složenog automata s konačnim brojem stanja (engl. *finite state machine*, FSM) i kroz sustav upravljan događajima (*event-driven system*), bilo je potrebno odabrati odgovarajući programski okvir koji olakšava razvoj paralelnih zadataka i reakcija na događaje u stvarnom vremenu. Iz toga razloga odlučeno da se koristi operacijski sustav za rad u stvarnom vremenu. Korišten je operacijski sustav *FreeRTOS*, jer nudi širok raspon mogućnosti, jednostavnu integraciju i prenosivost na veliki broj različitih ugradbenih računalnih platformi. Za potrebe pohrane veće količine podataka tijekom testiranja korištena je SD kartica, a mikrokontroleru je bilo potrebno dodati podršku za datotečni sustav za pohranu podataka u datoteku, za što je korištena *FatFs* biblioteka otvorenog koda.

Vlastito razvijeni aplikacijski sloj podijeljen je na četiri glavna modula: *main*, *mac*, *comm* i *cli*. U modulu *main* implementiran je glavni dio aplikacijskog sloja programske potpore na način da se omogući jednostavno konfiguriranje i dodavanje novih testnih scenarija za pro-

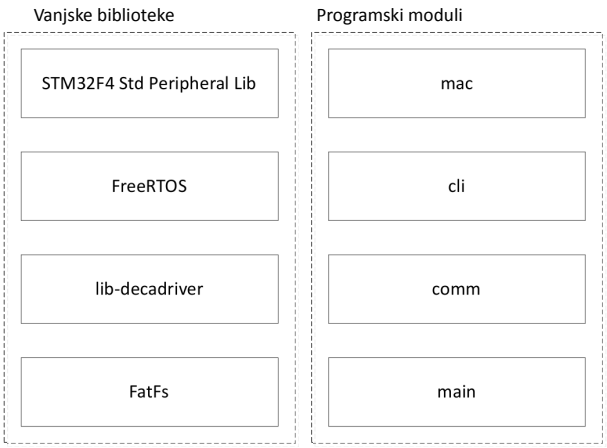

Slika 4.4: Moduli i vanjske biblioteke korištene za implementaciju programske potpore senzorskog čvora

vedbu različitih eksperimenata i prikupljanje mjernih rezultata. U tom modulu se obavljaju sve potrebne inicijalizacije prilikom pokretanja programske potpore, a u ovisnosti o konfiguraciji testa pokreću se odgovarajući *FreeRTOS* zadaci i konfiguriraju globalni resursi (npr. semafori, redovi poruka i sl.). U modulu *mac* implementirani su dijelovi MAC komunikacijskog sloja 802.15.4-2011 standarda, koji su bili nužni za razvoj vlastitog komunikacijskog protokola razmjene poruka u svrhu određivanja udaljenosti između bežičnih čvorova. U modulu *comm* nalazi se implementacija osnovih funkcija i programskih gradivnih blokova koje koriste algoritmi za određivanje udaljenosti među čvorovima i njihovo pozicioniranje, kao što su funkcije za slanje i prijem paketa, precizno zadavanje i čitanje vremenskih oznaka (*timestamps*) prilikom njihovog slanja i prijema, funkcije za postavljanje adresa, filtriranje paketa, upravljanje zadacima i redovima koji služe za slanje i primanje poruka itd. Modul *cli* (skr. od *command-line interface*) implementira naredbeni redak putem USART serijskog sučelja koji omogućuje lakše upravljanje i nadzor sustava putem terminala s osobnog računala, što je bilo osobito važno tijekom različitih scenarija testiranja. Takva arhitektura sustava omogućila je brojne prednosti, ne samo u vidu lakše implementacije različtih testnih scenarija, već i boljih performansi jer je primjerice postignuta veća brzina mjerenja udaljenosti između dva čvora od programske biblioteke koju nudi sam proizvođač. Korištenje *FreeRTOS* cirkularnih međuspremnika (redova, *queue*) omogućilo je jednostavniju implementaciju zadataka i olakšalo zahtjeve na latenciju odziva u stvarnom vremenu za obradu poruka koje kontinuirano stižu ili se šalju drugim čvorovima.

Aplikacijski sloj podijeljen je u skup zadataka, koji su prikazani na slici 4.5. Dekompozicijom programske potpore u zadatke koji se paralelno izvode značajno je pojednostavljena implementacija različitih testnih scenarija i povećana robusnost izvođenja programske potpore u stvarnom vremenu. Na slici su navedene dvije skupine zadataka: *glavni zadaci*, koji se nalaze u svakoj inačici programske potpore i sadrže ključnu zajedničku funkcionalnost, i *pomoćni zadaci*, koji se koriste kod realizacije specifičnih testnih uvjeta. Gotovo identična programska

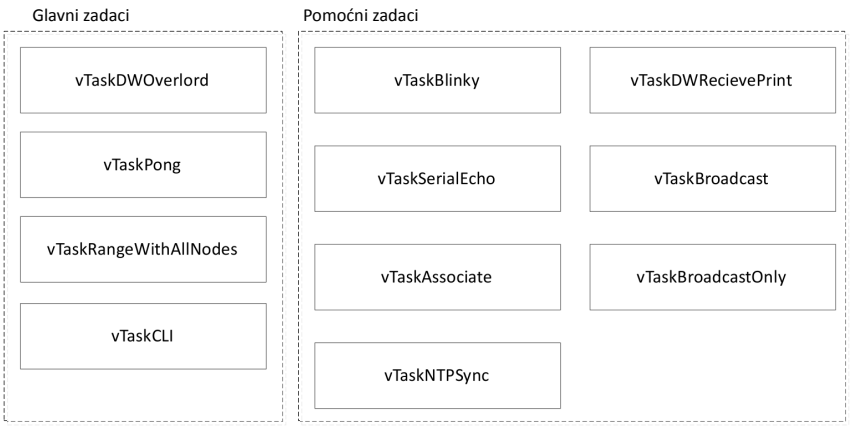

Slika 4.5: Zadaci implementirani u okviru aplikacijskog sloja programske potpore

potpora koristi se i za mobilnu (MS) i za baznu stanicu (BS), uz manje izmjene u konfiguraciji i zadacima koje obavlja čvor u različitim ulogama. Glavni zadaci imaju sljedeću funkcionalnost:

- *vTaskDWOverlord* - najvažniji zadatak koji upravlja protokolom slanja i primanja poruka, vremenskim oznakama i sl. (izvodi se i na MS i na BS čvoru),
- *vTaskPong* - zadatak koji vraća primljenu poruku, zajedno s vremenskim oznakama prijema i slanja poruke, kod protokola mjerenja udaljenosti RTOF metodom (izvodi se na MS čvoru),
- *vTaskRangeWithAllNodes* - zadatak koji komunicira sa svim drugim čvorovima u dometu radi određivanja svih parova udaljenosti (izvodi se na BS čvoru),
- *vTaskCLI* - zadatak koji implementira naredbeni redak za upravljanje i nadzor sustava preko serijske konzole i računala.

Ostali pomoćni zadaci služe za implementaciju jednostavnijih provjera ili specifičnih mogućnosti koje se koriste u pojedinim testovima, kao što su:

- *vTaskBlinky* - osnovni test funkcionalnosti naizmjeničnim paljenjem LED indikatora,
- *vTaskSerialEcho* - slanje dijagnostičkih poruka na serijsku konzolu,
- *vTaskBroadcast*, *vTaskBroadcastOnly* - testiranje *broadcast* komunikacije,
- *vTaskAssociate* - asociranje čvorova u mrežu (kod *broadcast* komunikacije),
- *vTaskNTPSync* - sinkronizacija vremena na čvoru,
- *vTaskDWRecievePrint* - pomoćni ispisi primljenih poruka.

U nastavku će nešto detaljnije biti opisani najvažniji zadaci, a to su *vTaskDWOverlord*, *vTaskPong* i *vTaskRangeWithAllNodes*.

Prije samog pokretanja *FreeRTOS* zadataka, potrebno je inicijalizirati sustav, kako je prikazano na slici 4.6. Prilikom poziva funkcije *main()*, najprije se inicijaliziraju periferijske jedinice mikrokontrolera (Reset and Clock Control (RCC), General Purpose Input-Ouput (GPIO), SYSTICK, Nested Vector Interrupt Controller (NVIC), Universal Synchronous and Asynchronous Receiver Transmitter (USART), Serial Peripheral Interface (SPI), Real-Time Clock (RTC), Di-

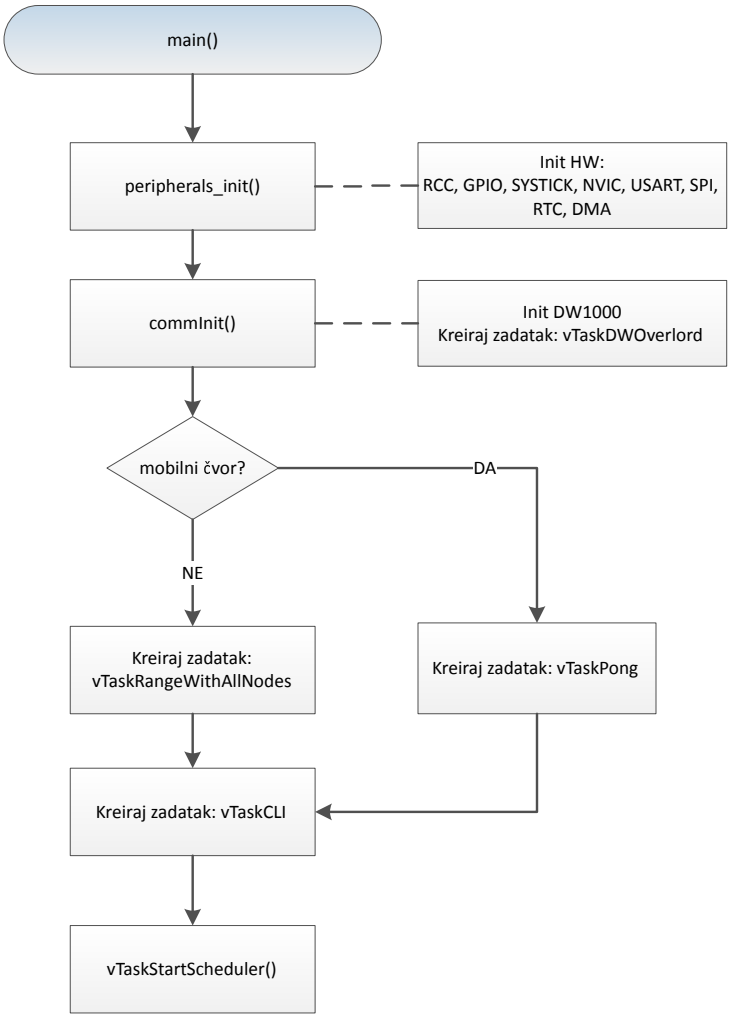

Slika 4.6: Inicijalizacijski dio programske potpore

rect Memory Access (DMA)). Potom slijedi inicijalizacija DW1000 primopredajnika pozivom funkcije *commInit()*, nakon čega se kreira zadatak *vTaskDWOverlord*, koji služi za upravljanje slanjem i prijemom poruka. U slučaju da se radi o programskoj potpori za BS, kreira se zadatak *vTaskRangeWithAllNodes*, a u slučaju da se radi o MS kreira se zadatak *vTaskPong*. Zadatak *vTaskCLI* kreira se za obje vrste uređaja radi lakšeg testiranja.

Sam postupak inicijalizacije DW1000 primopredajnika u funkciji *commInit()* prikazan je na slici 4.7. Najprije je potrebno resetirati DW1000 sklop i inicijalizirati SPI sučelje za komunikaciju prema njemu. U sljedećem koraku poziva se funkcija *dwt_initialise()* iz biblioteke *decadriver*, s parametrom *DWT_LOADUCODE*, koja obavlja složeni postupak dovođenja primopredajnika u poznato definirano početno stanje s podrškom za određivanje vremena dolaska paketa. Nakon toga potrebno je pozivom odgovarajućih API funkcije iz biblioteke *decadriver* konfigurirati kašnjenje antene, koje se mjeri posebnim postupkom propisanim od strane proizvođača, a koje uključuje sva kašnjenja signala na tiskanoj pločici i na samoj anteni. Kada se ne bi napravila ispravno kompenzacija vrijednosti kašnjenja antene, to bi se na mjerenjima udaljenosti vidjelo kao fiksna pogreška reda veličine više metara. Nakon toga potrebno je definirati

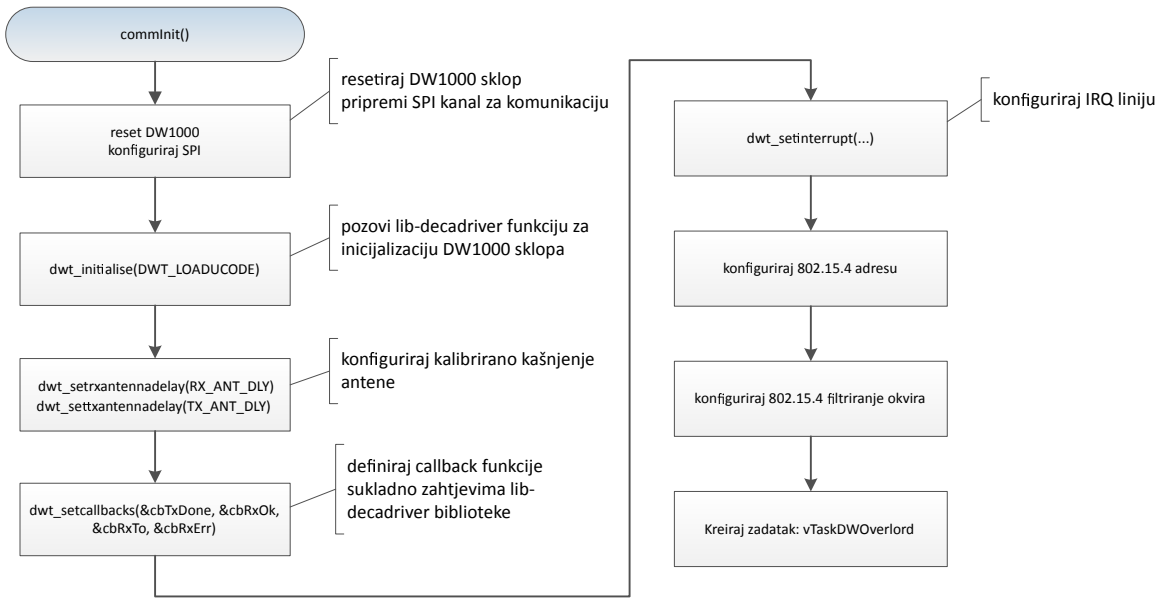

Slika 4.7: Inicijalizacija DW1000 primopredajnika

callback funkcije koje *decadriver* automatski poziva kada se dogode određeni događaji:

- *cbTxDone* - funkcija koja se poziva nakon što je poruka uspješno poslana,
- *cbRxOk* - funkcija koja se poziva nakon što je poruka uspješno primljena,
- *cbRxTo* - funkcija koja se poziva ako poruka nije uspješno primljena u predefiniranom vremenskom periodu (*timeout*),
- *cbRxErr* - funkcija koja se poziva ako je došlo do pogreške u komunikaciji.

Navedene *callback* funkcije bit će pozvane od strane *decadriver* biblioteke, a kod u njima služi za povezivanje s vlastitim rješenjem aplikacijskog sloja, koje se temelji na *FreeRTOS* zadacima. Nakon toga potrebno je konfigurirati prekide, odnosno definirati uvjete pod kojima će DW1000 automatski preko IRQ linije mikrokontroleru signalizirati zahtjev za prekidom. Nakon toga se definiraju postavke vezane uz 802.15.4-2011 protokol (adresa čvora, postavke filtriranja paketa i sl.) te se kreira *vTaskDWOverlord* koji će služiti za obradu poslanih i primljenih poruka.

Na slici 4.8 prikazan je pojednostavljeni dijagram tijeka najvažnijih zadaća koje obavlja zadatak *vTaskOverlord*. S obzirom da taj zadatak služi za upravljanje cjelokupnim postupkom slanja i primanja poruka te njihovom razmjenom između različitih zadataka korištenjem *FreeRTOS* redova, na samom početku alocira sve redove koji se koriste za razmjenu poruka među zadacima:

- *DWTxMAC* - red u kojeg se upisuju poruke za slanje,
- *broadcast_QUEUE* - red u kojeg se pohranjuju primljene *broadcast* poruke,
- *command_QUEUE* - red u kojeg se pohranjuju primljene *command* poruke,
- *range_QUEUE* - red u kojeg se pohranjuju primljene *range* poruke,
- *DWSentTimestampQueue* - red u kojeg se pohranjuju poslane vremenske oznake.

Korištenje redova je važno kako bi se smanjili zahtjevi na latenciju kod komunikacije s DW1000

sklopom prilikom slanja i prijema poruka. Koristeći takav pristup nije nužno izravno pozivati funkcije iz *decadriver* biblioteke u trenutku kada se želi poslati poruka ili kada dođe zahtjev za prekidom od primopredajnika da je poruka stigla. Prethodno pripremljena poruka za slanje može postaviti u red kako bi bila poslana u najpogodnijem trenutku s obzirom na izvođenje drugih funkcionalnosti programa, odnosno da se odgodi obrada IRQ zahtjeva s DW1000 sklopa za trenutak kada je najpogodnije pročitati novu poruku putem SPI sučelja. Sve poruke za slanje upisuju se u red *DWTxMAC* i šalju iz zadatka *vTaskOverlord*, koji je jedini zadužen za izravnu komunikaciju s DW1000 sklopom putem SPI sučelja. Ako neki drugi zadatak želi poslati poruku, neće je slati tako da je izravno upisuje u DW1000 sklop, već će poruku postaviti u red *DWTxMAC* i poslati notifikaciju zadatku *vTaskOverlord* putem *FreeRTOS* funkcije *xTaskNotifyWait* da ga obavijesti da ima poruku na čekanju. Zadatak *vTaskOverlord* primit će po jednu notifikaciju za svaku postavljenu poruku, a ako želi istovremeno i sam poslati više poruka, treba poslati notifikacije samome sebi da ne propusti poslati istim mehanizmom ostale poruke nakon što pošalje prvu. Također, odmah po slanju poruke iz DW1000 primopredajnika zadatak *vTaskOverlord* može po potrebi pročitati točnu vremensku oznaku slanja poruke i pohraniti je u red *DWSentTimestampQueue*, što se koristi kod RTOF algoritma. Preostala tri reda (*broadcast_QUEUE*, *command_QUEUE* i *range_QUEUE*) sadrže primljene poruke, koje se odmah razdvajaju po tipu poruke i pohranjuju u odvojene redove.

Odmah po kreiranju redova, zadatak konfigurira DW1000 primopredajnik i zadaje postavke UWB komunikacije. Nakon toga ulazi u blokirajući poziv čekajući na sljedeći događaj. U aktivno stanje doći će kada putem *FreeRTOS*-a od nekog drugog zadatka ili prekida dobije notifikaciju da se dogodio određeni događaj. Događaji mogu biti sljedeći:

- *TX* - događaj koji označava da je postavljena nova poruka u red *DWTxMAC* i da je poruku potrebno poslati,
- *RX* - događaj koji označava da je uspješno primljena nova poruka,
- *ERR* - događaj koji označava da je došlo do pogreške u komunikaciji koju je potrebno obraditi i signalizirati pojavu pogreške putem serijskog terminala.

Ranije je već opisan postupak slanja poruke koji se pokreće kada dođe notifikacija tipa *TX*. Notifikaciju *RX* tipa zadatak *vTaskOverlord* dobit će tipično iz *callback* funkcije *cbRxOk*, koja će se pokrenuti po uspješnom primitku poruke s DW1000 primopredajnika, kako je implementirano u biblioteci *decadriver*. Poruke *broadcast* tipa koriste BS za slanje informacija prema svim MS, a poruke *command* tipa služe za pokretanje određenih akcija na čvorovima koji ih prime. Poruka tipa *range* sadrži u sebi podatke s vremenskim oznakama potrebnima za RTOF algoritam određivanja udaljenosti između dva bežična čvora. Notifikacija *ERR* dobiva se u slučaju da se poruka ne primi u definiranom vremenskom intervalu (tipično ju šalje *callback* funkcija *cbRxTo*) ili ako je došlo do neke druge pogreške u komunikaciji (tipično ju šalje *callback* funkcija *cbRxErr*).

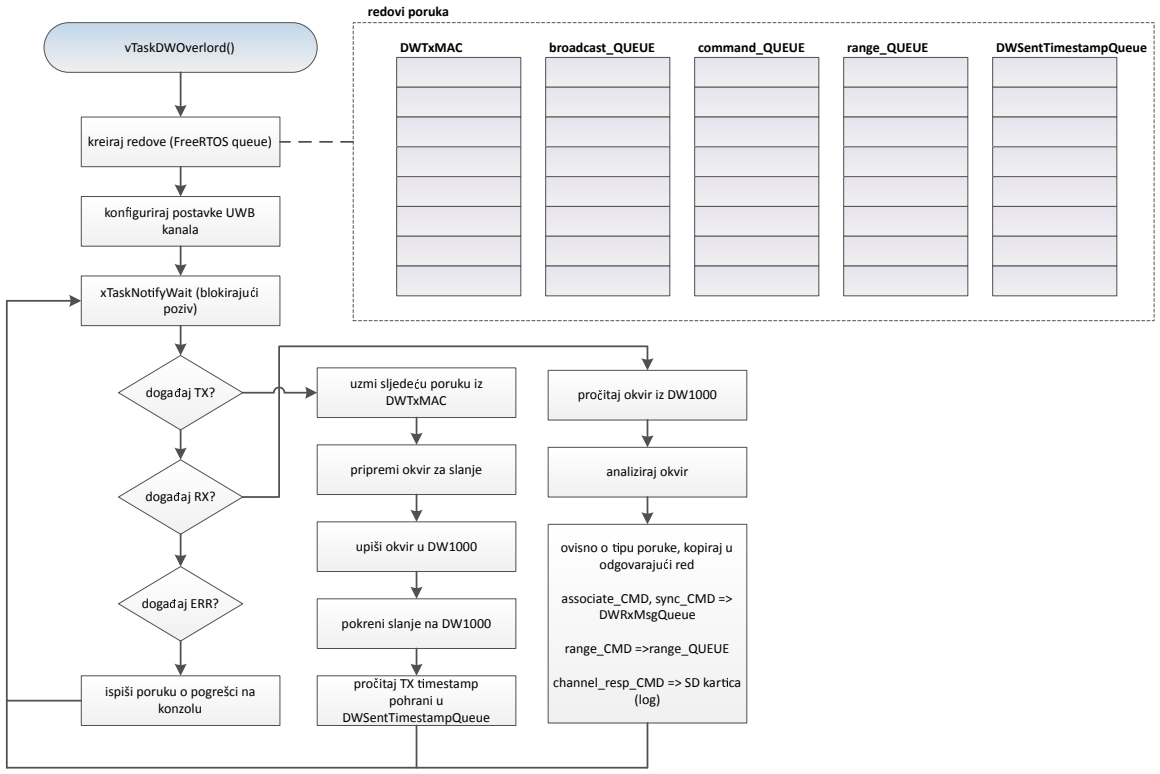

Slika 4.8: Dijagram tijeka izvođenja zadataka *vTaskOverlord*

Slika 4.9 prikazuje dijagram tijeka izvođenja zadatka *vTaskPong*. Taj zadatak igra vrlo važnu ulogu kod pozicioniranja RTOF algoritmom jer služi za primanje *range* poruka na MS i slanje odgovora prema BS u kojem se nalaze odgovarajuće vremenske oznake (*timestamps*) na temelju kojih BS može temeljem izmjerenog vremena propagacije izračunati udaljenost između MS i BS. Zadatak najprije u blokiranom stanju čeka na primitak nove *range* poruke u red *range_QUEUE* koju šalje BS, pri čemu bilježi vrijeme primitka poruke (*RX timestamp*). Potom šalje poruku natrag prema BS u kojoj se nalazi zabilježena vrijednost *RX timestamp*, no BS nema informaciju kada je ta povratna poruka točno poslana. Po slanju prve poruke zadatak čita točnu vremensku oznaku *TX timestamp* kada je prva poruka poslana prema BS i tu informaciju prema BS šalje u drugoj poruci. Zadatak *vTaskPong* ne šalje poruke izravno prema DW1000 primopredajniku, već stavlja poruke u red *DWTxMAC* i notificira zadatak *vTaskOverlord* da ima spremne poruke za slanje.

Na slici 4.10 prikazan je dijagram tijeka zadatka *vTaskRangeWithAllNodes*. To je zadatak koji se izvodi na BS i služi za prikupljanje informacija o međusobnim udaljenostima između BS i svih MS u dometu. Ako se u dometu neke promatrane BS nalazi n MS čvorova, za svaki od njih ponavlja se postupak određivanja udaljenosti tako da BS komunicira s MS čvorom koji ima drugačiju adresu ADDRn, sukladno adresiranju definiranom 802.15.4-2011 standardom kojeg podržava DW1000 primopredajnik. Sam postupak određivanja udaljenosti između BS i MS(ADDRn) opisan je na dijagramu tijeka u proceduri *range()*. Ponavlja se $Nrepeat$ mjerenja udaljenosti (npr. 10 puta) i izračunava se srednja vrijednost kako bi se smanjilo rasipanje

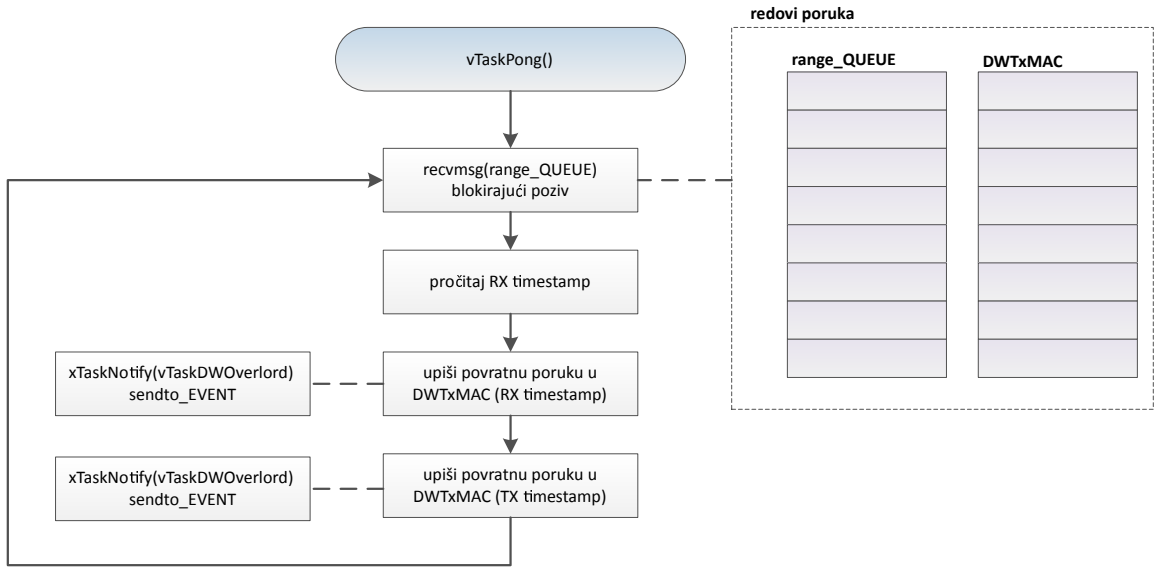

Slika 4.9: Dijagram tijeka izvođenja zadataka *vTaskPong*

mjerenja. Kod slanja poruka koristi se monotono rastući sekvencijski broj *seqNum* kako bi se kod razmjene poruka moglo identificirati kojoj iteraciji mjerenja udaljenosti pripadaju pojedine poruke. RTOF algoritam koristi sljedeća izmjerena vremena:

- *localSent* - vremenski trenutak u kojem je BS čvor poslao *range* poruku za pozicioniranje,
- *remoteRecv* - vremenski trenutak u kojem je MS(ADDRn) čvor primio *range* poruku od BS,
- *remoteSent* - vremenski trenutak u kojem je MS(ADDRn) poslao povratnu *range* poruku prema BS,
- *localRecv* - vremenski trenutak u kojem je BS primio *range* poruku od MS(ADDRn).

Na temelju skupa izmjerenih parametara {*localSent*, *remoteRecv*, *remoteSent*, *localRecv*} izračunava se pseudoudaljenost u vidu vremena propagacije između BS i MS(ADDRn). Pseudoudaljenost je potrebno transformacijskom formulom pretvoriti u udaljenost koja se dalje obrađuje prema potrebi i konkretnoj primjeni. Iz skupa udaljenosti moguće je odrediti poziciju MS u koordinantnom sustavu korištenjem odgovarajućih algoritama koji kombiniraju skup svih parova udaljenosti izmjerenih između MS i BS koji pripadaju sustavu za lokalno pozicioniranje.

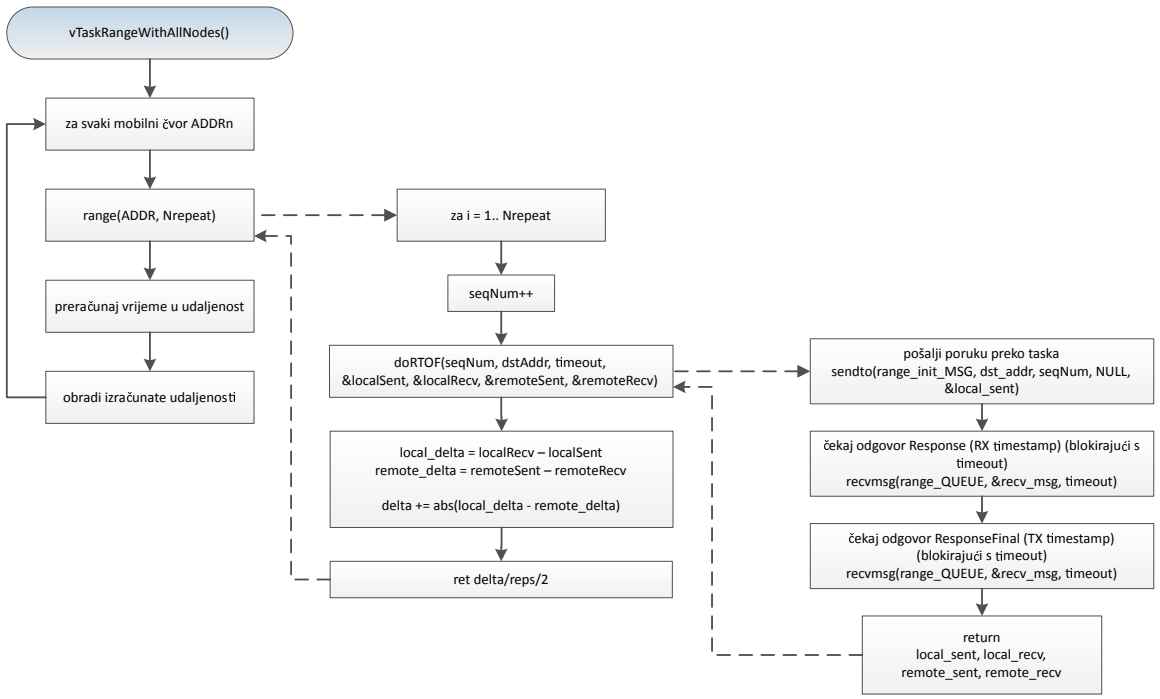

Slika 4.10: Dijagram tijeka izvođenja zadataka *vTaskRangeWithAllNodes*

4.3 Inicijalna validacija prototipnog senzorskog čvora

Prvi prototip senzorskog čvora prikazan na slici 4.1b poslužio je za početnu validaciju sustava za određivanje položaja korištenjem UWB tehnologije. U postupku validacije korištena je prilagođena inačica programske potpore dostupna od strane proizvođača DW1000 sklopa, u okviru dijela preliminarnog istraživanja opisanog u [109]. Mjerni postav za validaciju temeljio se na tri bazne stanice (BS) i jednom mobilnom čvoru (MS). Takav postav omogućio je jednostavno određivanje pozicije MS u dvodimenzionalnom koordinatnom sustavu. Mobilni čvor sekvencijalno je određivao svoju udaljenost u odnosu na stacionarne bazne stanice postavljene na unaprijed poznatim pozicijama. Protokol mjerenja udaljenosti temeljio se na SS-TWR metodi određivanja udaljenosti, koji se izvodio u 16 iteracija u kojima su dobivene ukupno 64 vrijednosti izmjerene udaljenosti. Standardna devijacija izmjerene srednje vrijednosti bila je 5 cm. Tijekom inicijalne validacije sustava korištenjem prilagođene programske potpore tvrtke Decawave Ltd. uočen je nedostatak u vidu razmjerno dugog vremena potrebnog za provedbu mjerenja jer je za izvođenje navedenog mjernog protokola bilo potrebno nešto manje od jedne sekunde (za svega 3 iteracije s ukupno 16 mjerenja bilo je potrebno 250 ms). Iz tog razloga započet je razvoj vlastite programske potpore kako bi se omogućila veća fleksibilnost u provedbi mjerenja, ali i brže vrijeme osvježavanja udaljenosti između čvorova. Arhitektura razvijenog i unaprijeđenog programskog rješenja opisana je u poglavlju 4.2.

U postupku validacije čvorovi su bili međusobno umjereni prema uputama proizvođača, a rezultat umjeravanja prikazan je u tablici 4.2. Fizička udaljenost između čvorova tijekom

kalibracije bila je 1290,0 cm, a postupkom kalibracije određena je srednja vrijednost udaljenosti koju mjeri UWB sustav u iznosu $\mu = 1293,4$ cm, uz standardnu devijaciju od $\delta = 2,3$ cm. Ti kalibracijski parametri poslužili su za kompenzaciju vremena propagacije signala na tiskanoj pločici i anteni kako bi se izmjerena vremena mogla ispravno pretvoriti u fizičke udaljenosti. Mjerenja udaljenosti provodila su se u laboratorijskim uvjetima na površini približnih dimenzija 150 $\times$ 150 cm. Bazne stanice bile su postavljene na koordinatama $(0,0)$, $(120,0)$ i $(60,65)$ (izraženo u cm). Rezultati mjerenja udaljenosti između UWB čvorova prikazani su u tablici 4.3, pri čemu d_1, d_2 i d_3 označavaju udaljenosti MS od prve, druge i treće BS. Oznake μ_{d_1}, μ_{d_2} i μ_{d_3} odnose se na usrednjene vrijednosti izmjerenih udaljenosti. Pozicija MS(x,y) izračunavala se rješavanjem sustava jednadžbi koje opisuju tri kružnice radijusa d_1, d_2 i d_3, gdje njihovo zajedničko presjecište predstavlja traženu točku MS(x,y) u dvodimenzionalnom prostoru:

$$d_1^2 = (x-x_1)^2 + (y-y_1)^2, \tag{4.3}$$

$$d_2^2 = (x-x_2)^2 + (y-y_2)^2, \tag{4.4}$$

$$d_3^2 = (x-x_3)^2 + (y-y_3)^2. \tag{4.5}$$

Sjecište triju kružnica može se odrediti rješavanjem sustava jednadžbi:

$$x = \frac{v_1 - y(y_3-y_2)}{x_3-x_2}, \tag{4.6}$$

$$y = \frac{v_2(x_3-x_2) - v_1(x_1-x_2)}{(y_1-y_2)(x_3-x_2) - (y_3-y_2)(x_1-x_2)} \tag{4.7}$$

gdje su

$$v_1 = \frac{(d_2^2-d_3^2) - (x_2^2-x_3^2) - (y_2^2-y_3^2)}{2}, \tag{4.8}$$

$$v_2 = \frac{(d_2^2-d_1^2) - (x_2^2-x_1^2) - (y_2^2-y_1^2)}{2}. \tag{4.9}$$

Usrednjene vrijednosti MS(x,y) prikazane su veličinama (μ_x, μ_y), a standardne devijacije izračunate pozicije po koordinatnim osima veličinama δ_x i δ_y.

Tablica 4.2: Umjeravanje prototipnog sustava [109]

Kalibracijska udaljenost [cm]	μ [cm]	δ [cm]
1290,0	1293,4	2,3

Tablica 4.3: Validacijska mjerenja prve verzije prototipa za mjerenje udaljenosti UWB metodom promatrano u tri različite pozicije MS [109]

Točka (x,y) [cm]	μ_{d_1} [cm]	μ_{d_2} [cm]	μ_{d_3} [cm]	μ_x [cm]	μ_y [cm]	δ_x [cm]	δ_y [cm]
(5,4)	1,45	133,52	99,74	-3,57	3,35	2,30	3,26
(60,33)	73,23	81,26	35,86	60,23	40,72	1,44	1,48
(115,62)	142,29	75,54	70,13	120,93	62,31	2,64	2,82

Tijekom provedbe eksperimentalne validacije sustava u mjernim rezultatima nisu uočena značajnija odstupanja pojedinih uzoraka mjerenja udaljenosti od srednje vrijednosti (μ_x, μ_y). U tablici 4.3 može se uočiti da su vrijednosti standardnih devijacija srednje vrijednosti po koordinatnim osima u približnom rasponu od 1 do 3 cm. U [109] je napomenuto da je uočena dodatna sustavna pogreška mjerenja koja ovisi o promjeni temperature u iznosu od 2,15 mm/°C te promjeni napona napajanja u iznosu od 5,35 cm/V.

Dobiveni rezultati inicijalne validacije poslužili su kao smjernice za poboljšanja sljedećih inačica sklopovlja senzorskog čvora. Veća pažnja posvećena je boljoj stabilizaciji napona napajanja kako bi se minimizirao njegov utjecaj na točnost mjerenja udaljenosti. Također se dodatno posvetila pažnja arhitekturi programske potpore i samom komunikacijskom protokolu kako bi se minimizirala potrošnja, a time i zagrijavanje integriranog sklopa, zbog ovisnosti točnosti mjerenja udaljenosti o temperaturi. Kasnija eksperimentalna ispitivanja utvrdila su da pogreške mjerenja udaljenosti ipak najviše ovise o stanju komunikacijskog kanala, zbog čega je provedeno dodatno ekstenzivno istraživanje utjecaja stanja kanala na točnost pozicioniranja u kontroliranim uvjetima.

4.4 Eksperimentalno ispitivanje utjecaja stanja kanala na mjerenje udaljenosti

Premda je eksperimentalna validacija potvrdila ispravnu funkcionalnost vlastito razvijenog prototipa UWB bežičnog čvora, pokazalo se da na točnost mjerenja udaljenosti utječu različiti parametri, kao što su temperatura, napon napajanja i stanje komunikacijskog kanala, koje obuhvaća stanje propagacijskog medija, višestazno širenje signala, utjecaj drugih komunikacijskih sustava itd. Kako bi se u potpunosti otklonili mogući utjecaji u nesavršenosti izvedbe vlastite sklopovske i programske platforme na eksperimentalno istraživanje utjecaja stanja komunikacijskog kanala na točnost mjerenja udaljenosti UWB sustavom, mjerenja su provedena korištenjem razvojnog sustava DWM1001 proizvođača Decawave Ltd., koji je prošao odgovarajuća testiranja i ispitivanja te se može smatrati pouzdanom i provjerenom platformom za potrebe ispitivanja ovakvog tipa. Razvojni sustav na sebi sadrži DWM1001 modul, koji se od DWM1000 modula razlikuje po tome što sadrži nRF52832 mikrokontroler i dodatno Bluetooth komunikaciju.

Cilj ovog dijela eksperimentalnog istraživanja bio je ustanoviti na koji način različiti efekti koji djeluju na stanje komunikacijskog kanala unose pogrešku u mjerenje udaljenosti. Ispitivani utjecaji podijeljeni su na statičke i dinamičke. Pod statičkim utjecajima podrazumijeva se konfiguracija prostora u kojem se UWB komunikacija odvija, što se ponaprije odnosi na izvore refleksija i raspršenja koji uzrokuju višestazne efekte propagacije signala (npr. raspored zidova, metalnih objekata, armature, namještaja i sl. unutar zatvorenog prostora). Dinamički utjecaji podrazumijevaju izvore smetnji od drugih radiokomunikacijskih uređaja čiji se spektar preklapa s područjem rada UWB bežičnih čvorova. Mjerenja statičkih i dinamičkih utjecaja provedena su u zatvorenom prostoru, u dvije referentne radne okoline: uredska okolina (prostorije unutar Fakulteta elektrotehnike i računarstva) i kontrolirana okolina bez elektromagnetskih smetnji (engl. *electromagnetic compatibility*, EMC) i refleksija (komora u akreditiranom Laboratoriju za elektromagnetsku kompatibilnost (EMC) i sigurnost, Končar Institut za elektrotehniku d.d.*). Uredska okolina obuhvaća očekivane radne uvjete u kojima je moguća pojava višestaznih efekata propagacije signala, ali i prisutstvo smetnji uslijed drugih komunikacijskih uređaja (Wi-Fi, Bluetooth, mobilne mreže i sl.). Mjerenja u EMC komori provedena su da se provjeri da uočeni efekti nisu posljedica utjecaja karakteristika samog prostora ili drugih komunikacijskih uređaja. Kako bi se osigurala ponovljivost smetnji uslijed drugih komunikacijskih uređaja u obje ispitne okoline, za ispitivanje utjecaja smetnji provedeno je generiranje smetnji korištenjem Bluetooth i Wi-Fi komunikacijske opreme. Rezultati provedenih testiranja bit će opisani u nastavku, a detaljno su izloženi u radu [110].

Postav mjernog sustava u EMC laboratoriju može se vidjeti na slici 4.11. Svaki od DWM1001 razvojnih sustava bili su postavljeni na drvenim gredama, kako bi se minimizirao utjecaj bli-

*Končar Institut za elektrotehniku `https://www.koncar-institut.hr/`

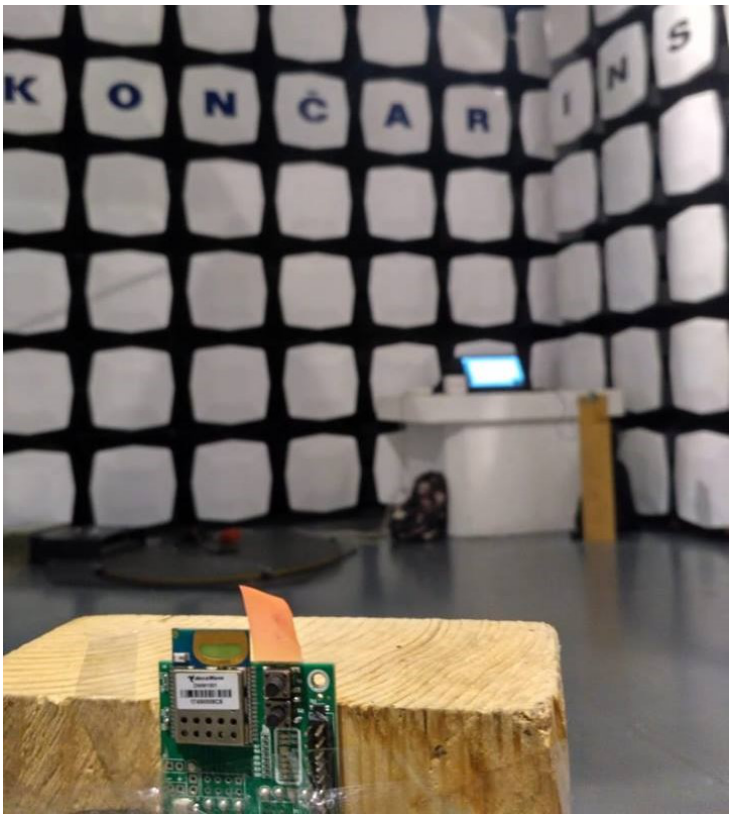

Slika 4.11: Ispitni postav UWB bežičnih čvorova u EMC laboratoriju [110]

skih metalnih objekata na UWB komunikaciju. Udaljenost između greda bila je stalna prilikom mjerenja i iznosila je 5 m. Razvojni sustavi bili su postavljeni na određenu visinu od metalnog poda kako bi se minimizirao utjecaj refleksije signala od poda. Sva mjerenja bila su izvedena u LOS uvjetima. Prilikom mjerenja utjecaja Wi-Fi komunikacije na određivanje udaljenosti, IEEE 802.11a/b uređaj bio je postavljen relativno blizu UWB senzorskom čvoru, kako je prikazano na slici 4.12.

Smetnje za UWB komunikaciju za potrebe ispitivanja proizvodile su se korištenjem Bluetooth i Wi-Fi komunikacijskih uređaja. S obzirom da DWM1001 razvojni sustav osim UWB podržava i Bluetooth komunikaciju, za potrebe mjerenja ostvarena je *point-to-point* kontinuirana Bluetooth komunikacija u kojoj je jedan čvor neprestano slao poruke drugome odmah nakon inicijalizacije. Za generiranje ometajuće Wi-Fi komunikacije korišten je *TP-Link Dual Band Gigabit* bežični usmjerivač koji podržava IEEE 802.11ac/n/a 5 GHz i IEEE 802.11b/g/n 2,4 GHz tehnologiju. U slučaju 5 GHz spektra korišteni su samo kanali 36, 40, 44, 48 s obzirom da su samo oni dozvoljeni u Republici Hrvatskoj. Iako usmjerivač podržava 14 kanala IEEE 802.11b standarda, samo su se koristi kanali 1, 6 i 11 koji se preklapaju s područjem spektra UWB komunikacije.

Svako mjerenje udaljenosti uključivalo je razmjenu 150 paketa. Svi paketi, odnosno stanja kanala, prikazani su grupno na grafovima. Neuspjele komunikacije označene su crvenom bojom. UWB komunikacija bila je namještena na srednju brzinu (850 kbps). Preambula poruke

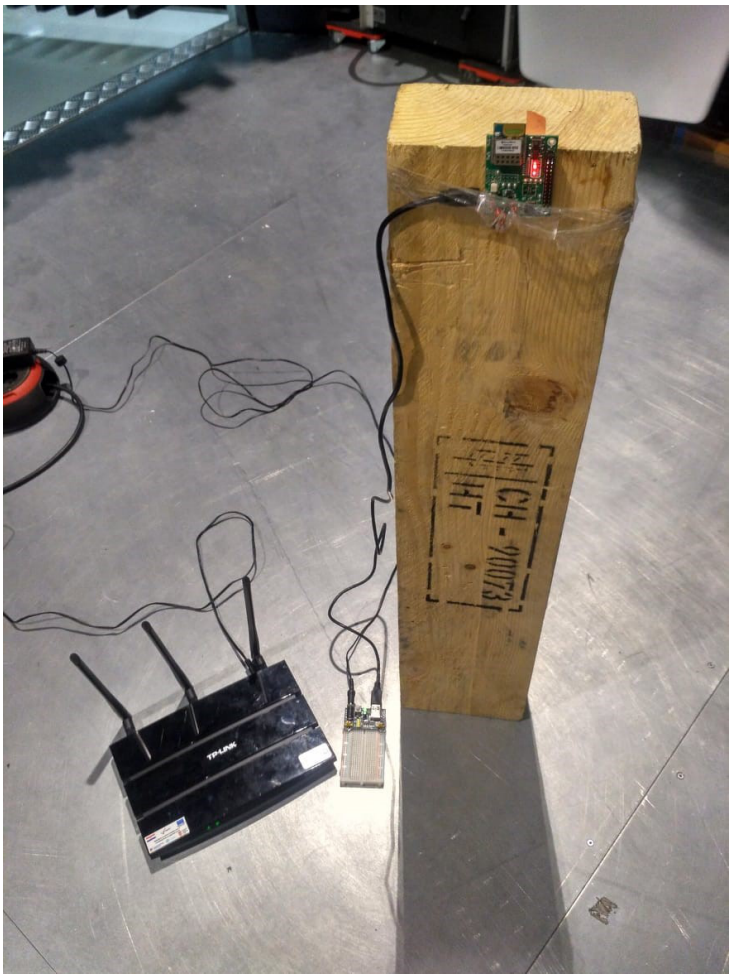

Slika 4.12: Ispitni postav UWB bežičnog čvora u EMC laboratoriju s Wi-Fi izvorom smetnji [110]

bila je namještena na duljinu od 1024 simbola, dok je frekvencija ponavljanja impulsa (PRF) iznosila 64 MHz. Iako DW1000 primopredajnik podržava šest različitih kanala, jedino mjerenja za kanal 5 su dolazila u obzir prilikom analize jer je antena DWM1001 modula projektirana upravo za frekvencijski opseg tog kanala. U pojedinim slučajevima mjerenja su napravljena i za druge kanale, radi usporedbe ponašanja sustava u različitim scenarijima.

4.4.1 Referentna mjerenja u EMC komori bez višestaznih refleksija

Kako bi se ustanovilo ponašanje sustava u idealnim uvjetima, prva mjerenja bila su izvedena u EMC komori u kojoj su minimizirani utjecaji višestaznih efekata bez generiranja smetnji. Rezultati su prikazani u tablici 4.4 i na slikama 4.13 i 4.14. U tablici 4.4 svaki redak predstavlja izmjerene rezultate na odabranim UWB kanalima, uz napomenu da je antena na razvojnom sustavu DWM1001 optimirana na CH5 i na tom kanalu očekuju se optimalni rezultati. Svaki ciklus mjerenja obuhvatio je slanje 150 paketa za mjerenje udaljenosti, pri čemu stupac μ u tablici predstavlja srednju vrijednost izmjerene udaljenosti, a δ standardnu devijaciju. Bolji uvid u raspodjelu izmjerenih udaljenosti može se vidjeti u histogramskom prikazu na slici 4.14, gdje

Tablica 4.4: Referentna mjerenja - EMC laboratorij (bez smetnji)

UWB kanal	*mjerenje 1*		*mjerenje 2*		*mjerenje 3*		*mjerenje 4*	
udaljenost [m]	μ	δ	μ	δ	μ	δ	μ	δ
CH 1	5,5	0,024	5,47	0,025	5,47	0,024	5,47	0,024
CH 2	5,42	0,054	5,35	0,03	5,27	0,026	5,27	0,029
CH 3	5,17	0,024	5,15	0,028	5,20	0,03	5,17	0,021
CH 4	5,03	0,028	5,01	0,022	5,04	0,025	5,02	0,022
CH 5	5,02	0,022	5,03	0,028	5,02	0,023	5,03	0,023
CH 7	4,68	0,024	4,68	0,025	4,68	0,02	4,68	0,023

je za svaki interval vrijednosti zabilježeno koliko je puta očitana određena udaljenost. Posebno je zanimljivo proučiti prikaz CIR-a na slici 4.13. CIR predstavlja stanje akumulatora impulsnog odziva koji se sastoji od 1016 uzoraka, koji predstavljaju vremenski prozor od otprilike 1 ns, a vizualizira višestazne komponente primljenog UWB impulsa za kojeg se određuje glavna komponente kako bi se na temelju nje mogla točno izmjeriti udaljenost. Što je veći šum u CIR-u, to će ugrađenim algoritmima biti teže odraditi glavnu višestaznu komponentu, odnosno doći će do većih pogrešaka mjerenja udaljenosti. Vizualizacija na slici 4.13 prikazuje iscrtano 150 CIR odziva istovremeno za sve primljene pakete u jednom ciklusu mjerenja. U idealnom slučaju, svi CIR odzivi trebali bi se preklopiti jedan preko drugoga, ako nema nikakvih promjena u stanju signala i komunikacijskog kanala. U realnom okruženju postoje određena rasipanja valnog oblika CIR-a, a što su ta rasipanja manja, to će mjerenje udaljenosti biti točnije. Prikaz na slici 4.13 na kvalitativan način opisuje koliko je rasipanje CIR-a u primljenom signalu. Na osi apscise nalazi se redni broj uzorka u CIR akumulatoru DW1000 primopredajnika, a na ordinati amplituda očitana iz CIR akumulatora.

U rezultatima prikazanima u tablici 4.4 može se primijetiti odstupanje točnosti mjerenja u slučaju kanala 1, 2, 3, i 7 u iznosu od $\pm$0,5 m. Takvi rezultati posljedica su činjenice da je antena DWM1001 modula projektirana za kanal 5, što se navodi u dokumentaciji i zbog čega su rezultati na tom kanalu puno bolji od ostalih. Ako se samo promatraju mjerenja na kanalu 5, može se ustanoviti da točnost ne odstupa značajno u odnosu na ranija mjerenja prikazana u tablici4.3. Također, može se primijetiti da izmjerena udaljenost odstupa samo za 0,02 m od postavljene. Razlog tome vidljiv je iz reprezentacije CIR-a za peti kanal na slici 4.13, gdje se može primijetiti usko grupiranje prvog dolaska impulsa oko jedne vrijednosti. Također, nakon 770-tog uzorka nisu vidljivi utjecaji dodatnih višestaznih komponenti impulsa ili refleksija. Na histogramu mjerenja udaljenosti prikazanom slikom 4.14 može se primijetiti zvonolika razdioba mjerenja na kojoj udaljenosti odstupaju do oko 10 cm između minimalne i maksimalne

Tablica 4.5: Referentna mjerenja - EMC laboratorij (Bluetooth komunikacija)

UWB kanal	*mjerenje 1*		*mjerenje 2*	
udaljenost [m]	μ	δ	μ	δ
CH 1	5,51	0,027	5,47	0,024
CH 2	5,27	0,026	5,26	0,028
CH 3	5,20	0,03	5,17	0,021
CH 4	5,04	0,025	5,02	0,025
CH 5	5,03	0,021	5,03	0,019
CH 7	4,68	0,02	4,68	0,023

Tablica 4.6: Referentna mjerenja - EMC laboratorij (IEEE 802.11b komunikacija)

Wi-Fi Kanal	*1*				*6*				*11*			
mjerenje	mjerenje 1		mjerenje 2		mjerenje 1		mjerenje 2		mjerenje 1		mjerenje 2	
udaljenost [m]	μ	δ	μ	δ	μ	δ	μ	δ	μ	δ	μ	δ
UWB CH5	5,04	0,019	5,03	0,019	5,03	0,022	5,03	0,018	5,04	0,02	5,04	0,023

izmjerene udaljenosti.

Opisana mjerenja su zatim ponovljena uz generiranu smetnju Bluetooth komunikacije. Cilj mjerenja bio je ustanoviti ima li kontinuirana Bluetooth komunikacija utjecaj na UWB mjerenja udaljenosti. Prema mjerenjima u tablici 4.5 može se zaključiti da ne postoje značajne razlike s obzirom na mjerenja prikazana u tablici 4.4, što upućuje na zaključak da kontinuirana Bluetooth komunikacija nema značajan utjecaj na mjerenje udaljenosti UWB metodom. Rezultate dodatno potvrđuju prikaz CIR-a i histogram mjerenja udaljenosti, prikazani na slikama 4.15 i 4.16. S obzirom da je u tablici 4.4 pokazano da ne postoje veće razlike za više ponovljenih ciklusa mjerenja (4 u tom slučaju), u nastavku eksperimentalnog istraživanja smanjen je broj ciklusa mjerenja (na 2 u tablici 4.5 i drugim mjerenjima koja su uslijedila).

Zadnje mjerenje u EMC komori provedeno je uz unošenje smetnje Wi-Fi komunikacije, prvo uz korištenje 2,4 GHz, a zatim 5 GHz tehnologije. Posebno je zanimljiv IEEE 802.11a standard jer upada u frekvencijski spektar UWB komunikacije. Tablice 4.6 i 4.7 prikazuju rezultate tih mjerenja. Kao i u prethodnom slučaju s Bluetooth komunikacijom, ne mogu se primijetiti značajnija odstupanja od referentnih mjerenja. To dodatno dokazuju i prikazi stanja kanala (CIR) na slici 4.17 za 2,4 GHz i slici 4.19 za 5 GHz tehnologiju, kao i histogrami na slikama 4.18 i 4.20. Iz svega navedenog može se zaključiti da u idealnim uvjetima bez utjecaja višestazne propagacije signala Bluetooth i Wi-Fi komunikacija nemaju utjecaj na pogrešku prilikom određivanja udaljenosti uz pomoć UWB tehnologije.

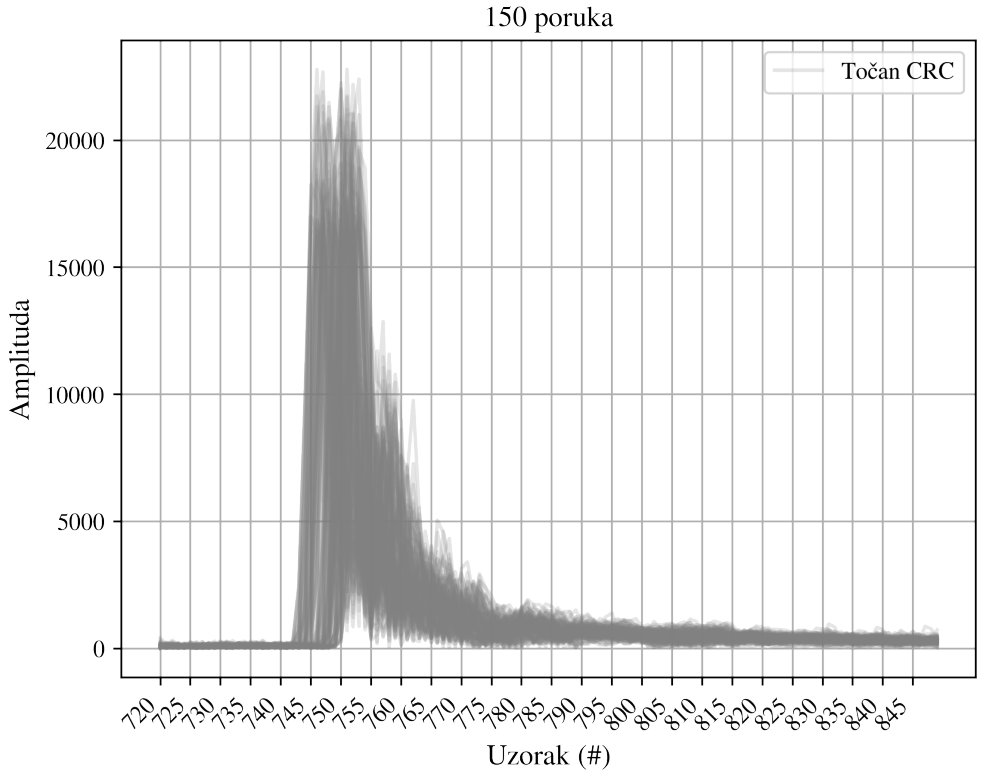

Slika 4.13: CIR bez utjecaja smetnji (izmjereno u EMC komori)

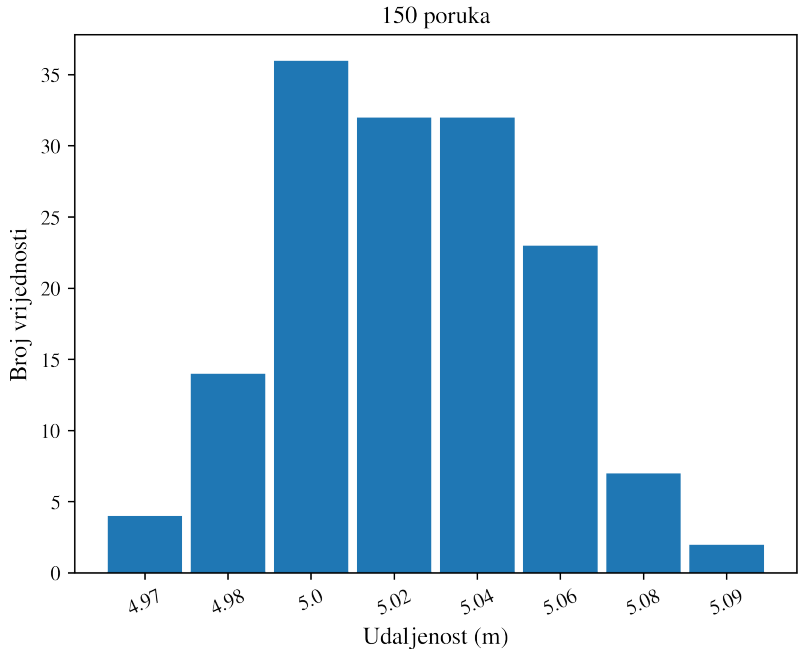

Slika 4.14: Histogram izmjerenih udaljenosti (bez utjecaja smetnji, izmjereno u EMC komori)

Tablica 4.7: Referentna mjerenja - EMC laboratorij (IEEE 802.11a komunikacija)

Wi-Fi Kanal	*36*				*40*				*44*				*48*			
mjerenje	mjerenje 1		mjerenje 2		mjerenje 1		mjerenje 2		mjerenje 1		mjerenje 2		mjerenje 1		mjerenje 2	
distance [m]	μ	δ	μ	δ	μ	δ	μ	δ	μ	δ	μ	δ	μ	δ	μ	δ
UWB CH5	5,04	0,018	5,03	0,018	5,04	0,02	5,04	0,02	5,03	0,02	5,03	0,022	5,04	0,021	5,04	0,021

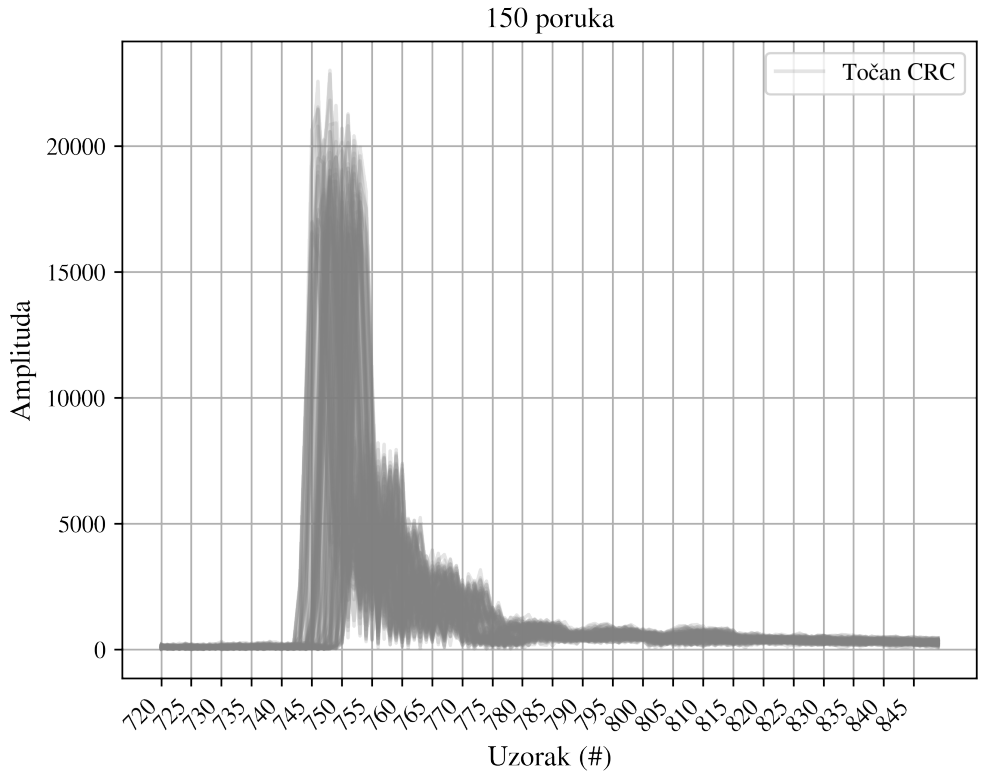

Slika 4.15: CIR uz Bluetooth komunikaciju (izmjereno u EMC komori)

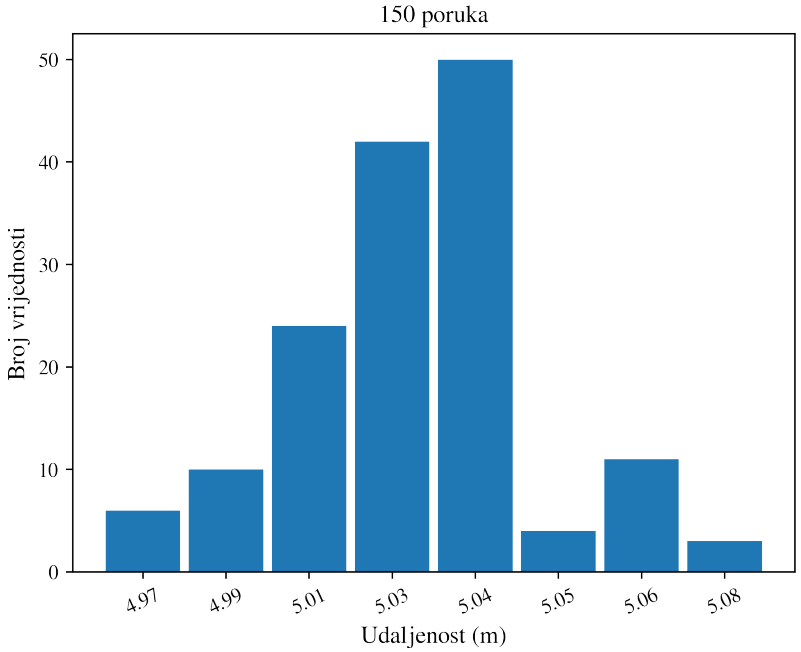

Slika 4.16: Histogram izmjerenih udaljenosti (uz Bluetooth komunikaciju, izmjereno u EMC komori)

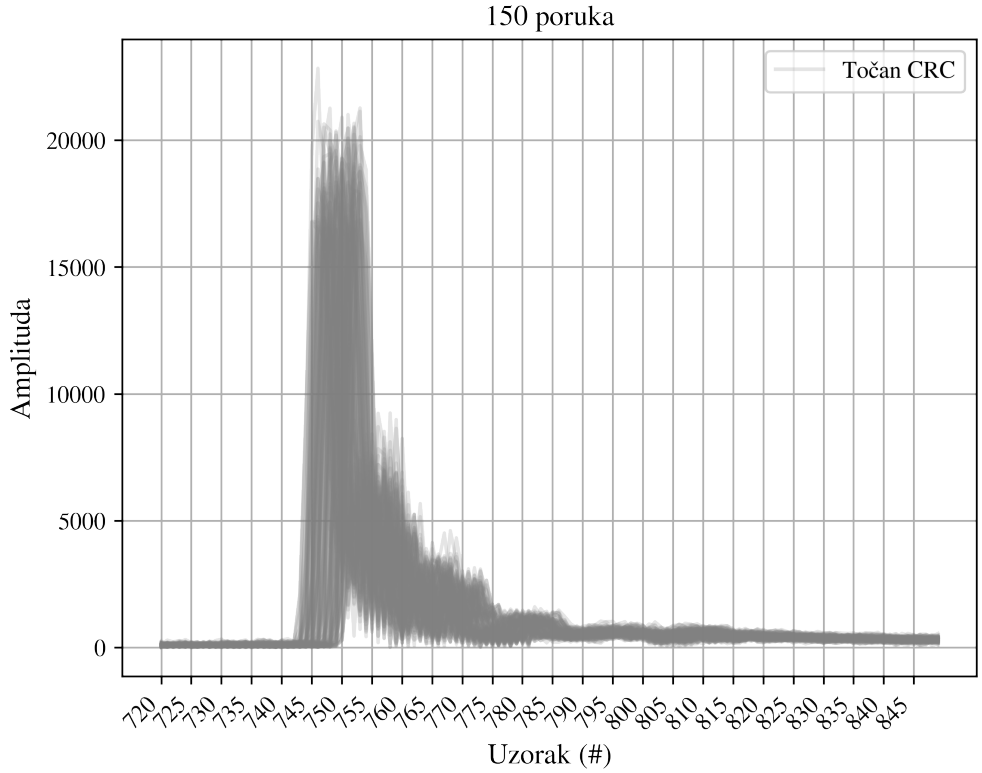

Slika 4.17: CIR uz IEEE 802.11b komunikaciju (izmjereno u EMC komori)

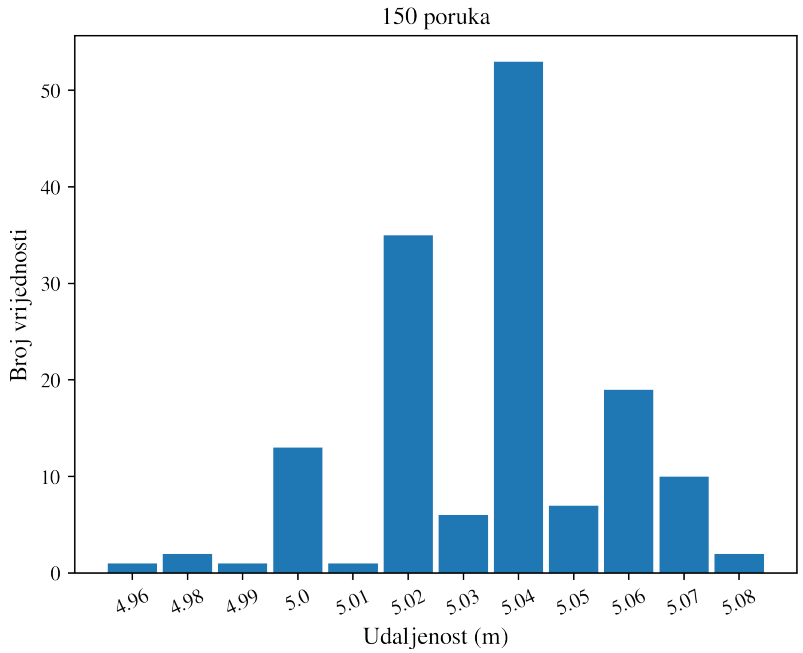

Slika 4.18: Histogram izmjerenih udaljenosti (uz IEEE 802.11b komunikaciju, izmjereno u EMC komori)

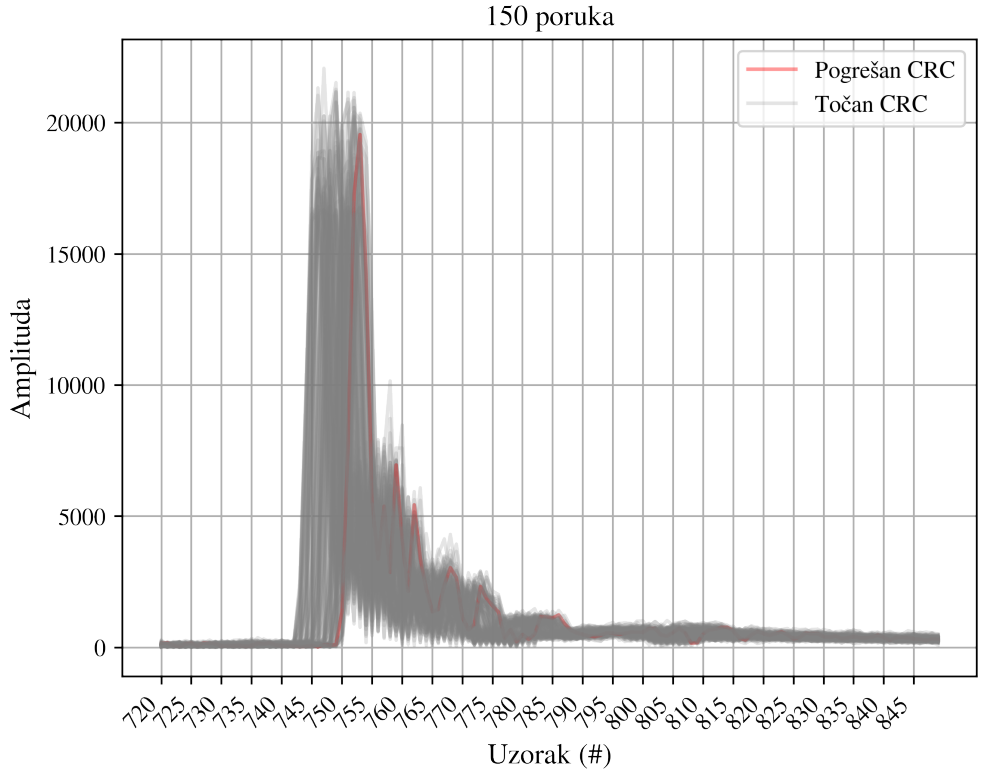

Slika 4.19: CIR uz IEEE 802.11a komunikaciju (izmjereno u EMC komori)

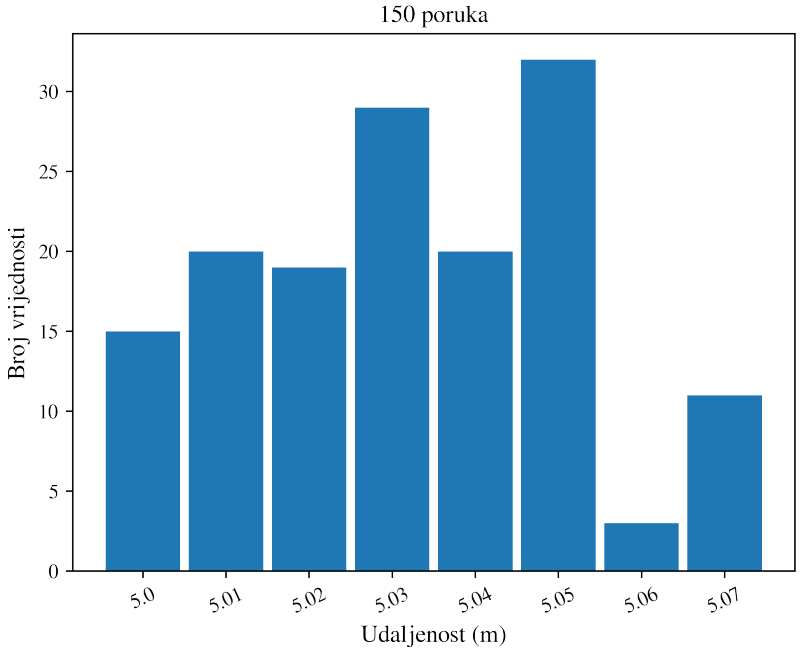

Slika 4.20: Histogram izmjerenih udaljenosti (uz IEEE 802.11a komunikaciju, izmjereno u EMC komori)

Tablica 4.8: Mjerenje u okolini s višestaznom propagacijom signala (prostorija na fakultetu, bez generiranih smetnji)

UWB kanal	*mjerenje 1*		*mjerenje 2*		*mjerenje 3*	
udaljenost [m]	μ	σ	μ	σ	μ	σ
CH 1	5,91	0,068	5,86	0,047	5,84	0,045
CH 2	5,64	0,055	5,6	0,04	5,61	0,04
CH 3	5,46	0,033	5,44	0,031	5,44	0,035
CH 4	5,37	0,034	5,31	0,03	5,33	0,03
CH 5	5,29	0,027	5,29	0,021	5,3	0,024
CH 7	4,97	0,024	4,98	0,022	4,98	0,02

4.4.2 Mjerenja u prostoriji s višestaznim izvorima refleksija

S obzirom da su mjerenja u EMC komori pokazala da Bluetooth i Wi-Fi komunikacija u uvjetima bez višestaznog rasprostiranja signala ne utječu značajnije na mjerenje udaljenosti UWB metodom, u nastavku eksperimentalnog istraživanja ispitan je utjecaj okoline s višestaznim rasprostiranjem signala na ranije uočena fiksna konstantna odstupanja u mjerenju udaljenosti koja su prikazana u tablici 4.3. Mjerenja su ponovljena uz postavljanje razvojnih sustava na udaljenost od 5 m, ali ovaj put u prostoriji na fakultetu u kojoj se očekuju utjecaji višestazne propagacije signala, ali i drugih komunikacijskih uređaja.

Mjerenja su provedena na svim kanalima koje podržava DW1000 primopredajnik, a prema rezultatima prikazanima u tablici 4.8 može se uočiti konstantan pomak u mjerenju udaljenosti u odnosu na referentna mjerenja provedena u EMC komori i prikazana u tablici 4.4. Taj pomak izražen je čak i na kanalu 5 za kojega je predviđena antena na razvojnom sustavu i on iznosi 0,28 m. Zanimljivo je primijetiti da je standardna devijacija ostala ista samo za kanale 5 i 7, dok je za druge porasla i do tri puta. Takvi rezultati upućuju na zaključak da se u okolini u kojoj postoje višestazni efekti mogu očekivati konstantni pomaci u mjerenoj udaljenosti. Pomaci su uzrokovani rasporedom objekata koji izazivaju višestazne efekte jer mijenjaju impulsni odziv kanala (CIR). Zbog toga se prva višestazna komponenta ne detektira ispravno, što se izravno reflektira na sustavnu pogrešku mjerenja na pojedinima lokacijama unutar zatvorenog prostora. Rezultate prikazane u tablici 4.8 dodatno potkrijepljuje izgled impulsnog odziva kanala (CIR) prikazan na slici 4.21 gdje se može uočiti veći broj višestaznih komponenti, utjecaj refleksija i veće statističko rasipanje u vremenima dolazaka prvog impulsa promatrano na 150 paketa.

Mjerenja u uredskom okruženju prostorije na fakultetu bila su ponovljena uz namjerno unošenje dodatne smetnje Bluetooth komunikacije. Rezultati se nisu bitnije razlikovali od mjerenja u tablici 4.8 kada nije bila uključena Bluetooth komunikacija. Na temelju tog eksperimenta

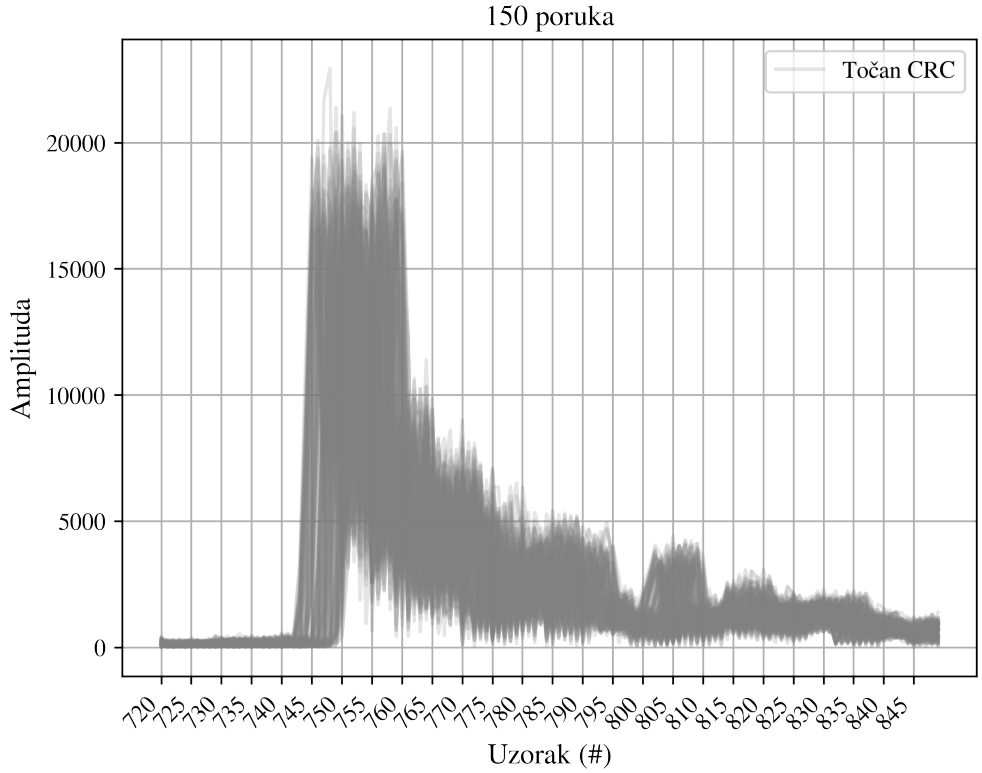

Slika 4.21: CIR bez generiranih smetnji (izmjereno u prostoriji na fakultetu)

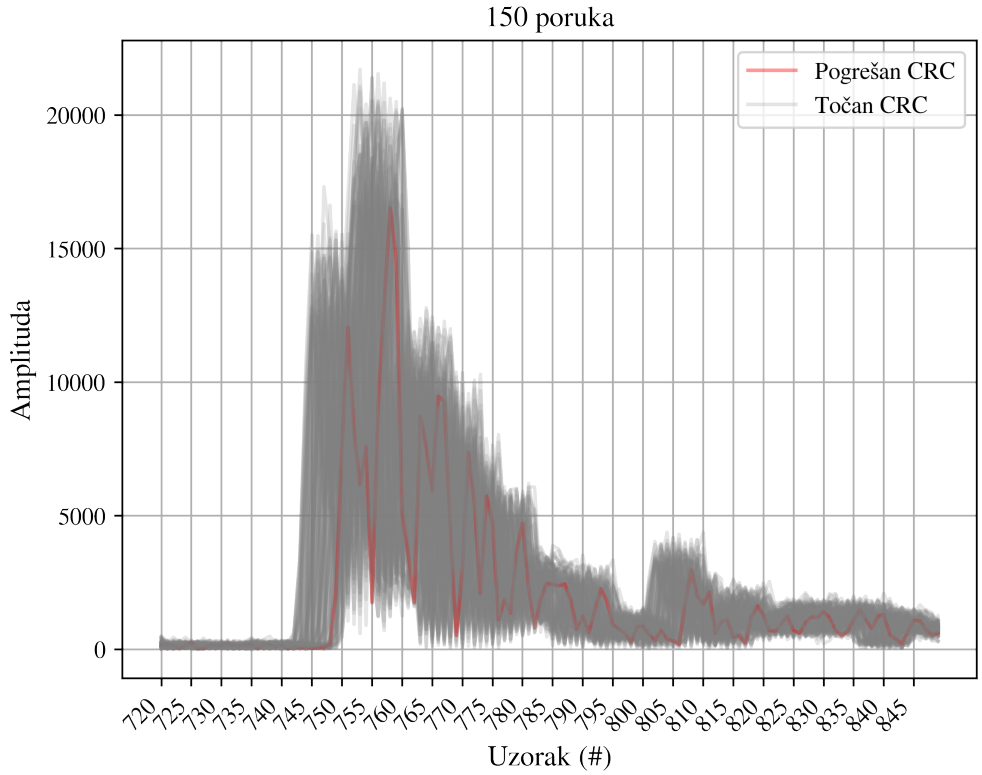

Slika 4.22: CIR uz uključenu Bluetooth komunikaciju (izmjereno u prostoriji na fakultetu)

može se zaključiti da sama Bluetooth komunikacija ne utječe značajnije na mjerenje udaljenosti UWB metodom. Ipak, zanimljivo je primijetiti da se utjecaj Bluetooth komunikacije može uočiti u CIR-u prikazanom na slici 4.22. Uočena su dva šiljka na početku CIR-a, gdje je drugi istaknutiji po snazi od prvoga, ali preciznost određivanja udaljenosti nije narušena jer postojanje tih šiljaka u CIR-u nije utjecalo na detekciju glavne višestazne komponente UWB signala i time na samo mjerenje udaljenosti.

Zadnji skup mjerenja u prostoriji na fakultetu proveden je uz unošenje smetnje uslijed Wi-Fi komunikacije u UWB kanal, postavljanjem bežičnog Wi-Fi usmjerivača u blisku okolinu UWB čvora. U tablici 4.9 prikazan je utjecaj 2,4 GHz, u tablici 4.10 5 GHz tehnologije. U obje tablice može se primijetiti da je došlo do dodatnog pomaka u srednjoj pogrešci mjerenja udaljenosti od 10 cm, u odnosu na tablicu 4.8. Time je eksperimentalno i empirijski potvrđeno da Wi-Fi komunikacija ipak ima utjecaj na točnost određivanja udaljenosti UWB metodom. Razlozi zašto taj utjecaj nije uočen u EMC komori, ali je u prostoriji na fakultetu, mogu se analizirati promatranjem impulsnog odziva kanala (CIR) prikazanog na slikama 4.23 i 4.24 snimljenog u prostoriji s efektima višestaznog rasprostiranja signala, uz usporedbu s CIR-om snimljenim pod istim uvjetima bez uključenih izvora smetnji, kako je prikazano na slici 4.21. U svim slučajevima primjećuje se puno veća razmazanost snimljenog CIR-a uslijed višestaznih efekata što detekciju glavne višestazne komponente čini težom i osjetljivijom na smetnje drugih komunikacijskih uređaja.

Nakon provedenih eksperimenata može se zaključiti da Bluetooth i Wi-Fi komunikacija neće utjecati značajnije na CIR i mjerenje udaljenosti ako je on dovoljno kvalitetan zbog postojanja samo jedne izravne (LOS) komponente, ali da će u slučaju višestaznog širenja signala i razmazanosti CIR-a na algoritme prepoznavanja glavne višestazne komponente dodatno utjecati smetnje uslijed Wi-Fi komunikacije dok uslijed Bluetootha neće. Pri tome je teško izvesti analitičku i determinističku ovisnost koja opisuje pogrešku mjerenja udaljenosti jer nije jednostavno modelirati različite realne okoline u kojima se događaju višestazni efekti, niti je poznata točna implementacija patentiranog algoritma ugrađenog u DW1000 primopredajnik koji na temelju CIR-a određuje glavnu višestaznu komponentu. Važno je napomenuti da su ovo zaključci preliminarnih ispitivanja i da se u slučaju mjerenja u prostorijama fakulteta nisu mogli postići tako dobro kontrolirani uvjeti kao u EMC komori. Drugim riječima, mjerenja koja su označena kao mjerenja bez utjecaja vanjskih smetnji treba uzeti kao približnu aproksimaciju jer je sasvim sigurno postojala Wi-Fi komunikacija unutar prostora (zbog pokrivenosti prostora Wi-Fi signalom), ali je taj signal bio puno manje razine nego u slučaju kada je namjerno uključen Wi-Fi usmjerivač postavljen blizu UWB čvora. Uvjeti pod kojima se mjerilo u fakultetskim prostorijama mogli su biti ponovljivi samo kvalitativno jer nije bilo moguće utjecati na to kakva će prilikom ponovljenih eksperimenata biti točno Wi-Fi i druga komunikacija u pozadini. Unatoč tim ograničenjima, rezultati ipak imaju važan praktični značaj jer upućuju na zaključke što sve

može biti uzrokom pogreške mjerenja udaljenosti kada se provode mjerenja u stvarnim primjenama u zatvorenim prostorima s višestaznim širenjem signala i pokrivenošću s Wi-Fi signalom.

Tablica 4.9: Mjerenje u okolini s višestaznom propagacijom signala (prostorija na fakultetu, uz uključenu IEEE 802.11b komunikaciju)

Wi-Fi kanal	*1*				*6*				*11*			
mjerenje	mjerenje 1		mjerenje 2		mjerenje 1		mjerenje 2		mjerenje 1		mjerenje 2	
udaljenost [m]	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
UWB CH 5	5,4	0,044	5,4	0,038	5,37	0,022	5,38	0,022	5,42	0,045	5.43	0,044

Tablica 4.10: Mjerenje u okolini s višestaznom propagacijom signala (prostorija na fakultetu, uz uključenu IEEE 802.11a komunikaciju)

Wi-Fi kanal	*36*		*40*		*44*		*48*	
udaljenost [m]	μ	σ	μ	σ	μ	σ	μ	σ
UWB CH 5	5,38	0,021	5,38	0,022	5,39	0,022	5,39	0,025

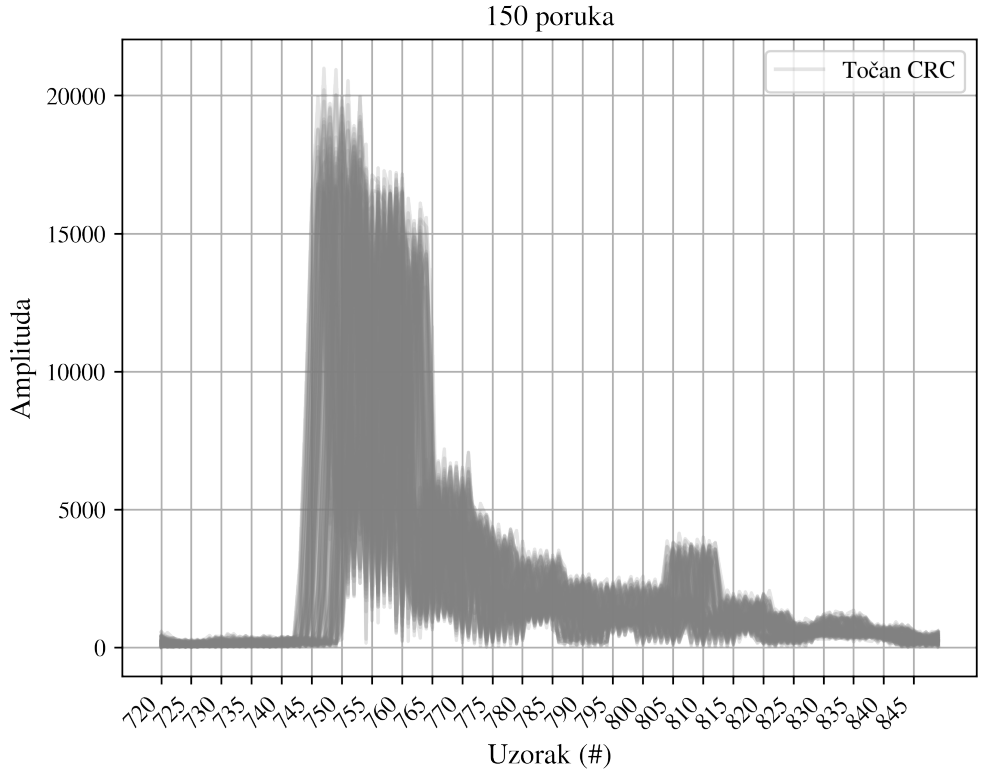

Slika 4.23: CIR uz uključenu IEEE 802.11b komunikaciju (izmjereno u prostoriji na fakultetu)

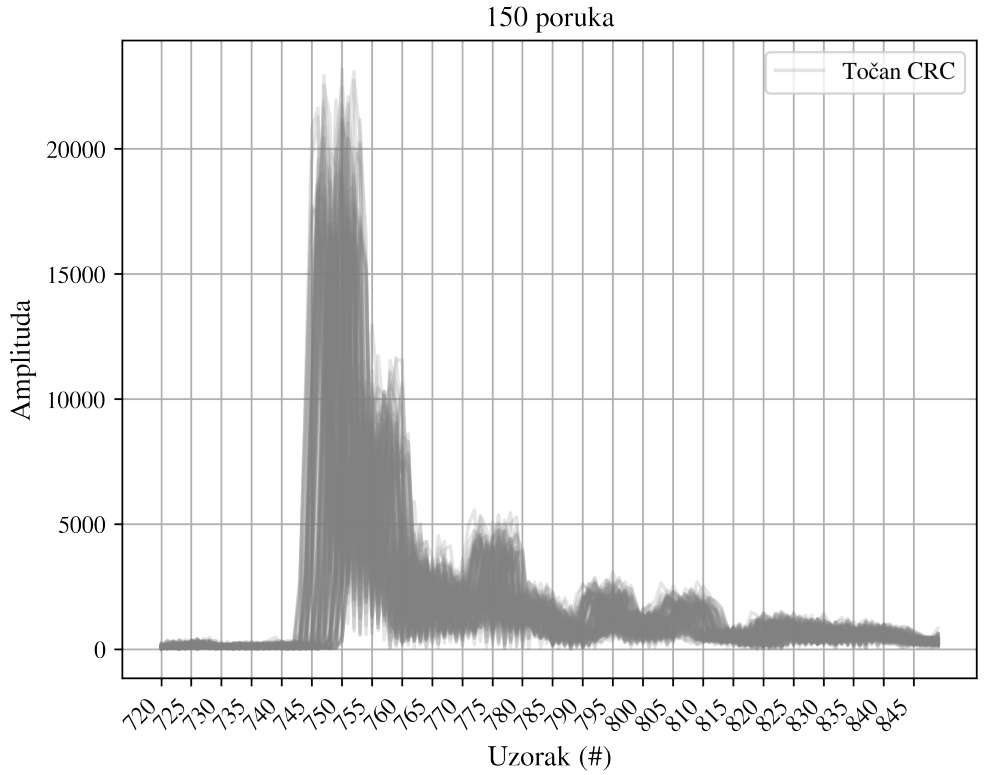

Slika 4.24: CIR uz uključenu IEEE 802.11a komunikaciju (izmjereno u prostoriji na fakultetu)

Poglavlje 5

Metoda određivanja položaja i prepoznavanja pokreta ljudskog tijela

U ovom poglavlju dani su rezultati mjerenja cjelokupnog sustava, kao i prethodno obavljena istraživanja kako bi se validirale pojedine metode. Objašnjena je metoda kompenzacije vremenske baze prilikom određivanja udaljenosti te su pruženi validacijski rezultati dobiveni na referentnom mjernom sustavu. Eksperimentalno su utvrđeni potrebni parametri za estimaciju gibanja, odnosno određivanje kuta zgloba, uz pomoć algoritamske ekspanzije modela predloženog u [106]. Ponašanje cjelokupnog sustava validirano je u statičkim i dinamičkim uvjetima gdje se utvrdilo da je ponašanje sustava u granicama ostalih istraživanja iznesenih u poglavlju 2. Dodatno, kako bi se iskoristile informacije iz IMU senzora, predložen je postupak senzorske fuzije temeljen na Kalmanovom filtru. Kut zgloba pomoću IMU senzora dobiven je uz pomoć metode iz [58] kako bi se uklonila potreba za prethodnom kalibracijom položaja modula s obzirom na ljudski kostur. Na kraju, obavljena su mjerenja u svrhu prepoznavanja pokreta te se pokazalo da se uz predložene metode može značajno povećati točnost klasifikacije pojedinih gibanja.

5.1 Predloženi algoritam estimacije udaljenosti

Kako bi se objasnio predloženi algoritam, potrebno je najprije ukratko pojasniti estimator iz [106], koji se temelji na modelu opisanom jednadžbom 3.3. Jednadžba 3.3 definira pretvaranje lokalnog vremena t_i u *idealno* vrijeme t gdje su $[\alpha_i, \beta_i] \triangleq [\omega_i^{-1}, -\phi\,\omega_i^{-1}]$ kalibracijski parametri koje je potrebno odrediti za korekciju sata na čvorovima.

Općenito, udaljenost d_{ij} između dva čvora i i j izražava se kao konstanta i može se odrediti mjerenjem vremena propagacije τ_{ij} korištenjem RTOF metode. Tada se udaljenost može izraziti kao $\tau_{ij} = c^{-1} d_{ij}$. U našem slučaju pretpostavka je da su čvorovi u neprestanom gibanju. Kako nemamo niti jednu informaciju o prirodi tog nelinearnog gibanja, promjenu udaljenosti

možemo aproksimirati Taylorovim redom u malom vremenskom prozoru $\Delta T = T_{ij,K} - T_{ij,1}$. U tom slučaju, aproksimacija za τ_{ij} izgleda:

$$\tau_{ij}(t_i) \approx c^{-1}\left(\gamma_{ij}^{(0)} + \gamma_{ij}^{(1)}t + \gamma_{ij}^{(2)}t^2 + \cdots + \gamma^{(L-1)}t^{(L-1)}\right), \tag{5.1}$$

gdje su koeficijenti $\gamma_{ij} = [\gamma_{ij}^{(0)}, \gamma_{ij}^{(1)}, \gamma_{ij}^{(2)}, \cdots, \gamma_{ij}^{(L-1)}]^T \in \mathbb{R}^{L\times 1}$ vremenski pretvoreni parametri Taylorovog reda u kontekstu *idealnog* vremena t. Broj koeficijenata u razvoju Taylorovog reda L može se odrediti eksperimentalno ili estimirati iz izmjerenih podataka. Kako bi se istovremeno estimirali parametri nestabilnog sata i koeficijenti reda označeni s $\theta = [\alpha, \beta, \gamma]^T$, mora se primijeniti metoda TWR mjerenja gdje se sve vremenske oznake u kontekstu *idealnog* vremena t mogu izraziti kao:

$$T_{ji,k} = T_{ij,k} + c^{-1}E_{ij,k}d_{ij,k} \text{ za } i \rightleftarrows j \tag{5.2}$$

gdje $T_{ij,k}$ predstavlja vremensku oznaku u trenutku k kada čvor i komunicira s čvorom j. Slično tome, $T_{ji,k}$ predstavlja vrijeme kada čvor j šalje poruku čvoru i u trenutku k. Smjer poruke u jednadžbi predstavlja izraz $E_{ij,k}$, gdje pozitivna vrijednost $+1$ označava komunikaciju od čvora i prema j, dok negativna vrijednost od -1 označava komunikaciju od čvora j prema i. Pošto su sve vrijednosti vremenskih oznaka zapisane uz pomoć lokalnih satova koji se nalaze na mobilnim čvorovima, one moraju biti pretvorene u kontekst *idealnog* vremena. Iz tog razloga jednadžba 5.2 se transformira u sljedeći izraz:

$$\eta_{ij,k} = \alpha_i T_{ij,k} - \alpha_i T_{ji,k} + \beta_i - \beta_j + E_{ij}\left(\gamma_{ij}^{(0)} + \gamma_{ij}^{(1)}t + \gamma_{ij}^{(2)}t^2 + \cdots + \gamma^{(L-1)}t^{(L-1)}\right), \tag{5.3}$$

gdje su utjecaji nestabilnosti lokalnih oscilatora, odnosno izvora vremena, uključeni u obzir. Dodatno, u obzir se mora uzeti i šum mjerenja, odnosno šum ukupnog procesa koji nastaje prilikom određivanja vremenskih oznaka, pošto jedino u idealnim uvjetima jednadžba 5.2 ima sumu jednaku 0. U tom slučaju, $\eta_{ij,k}$ predstavlja zajednički utjecaj svih izvora pogrešaka u mjernom procesu.

Konačno, koristeći model opisan jednadžbom 5.3, može se zapisati u matričnom obliku za

$(L-1)$ red za par čvorova koji sudjeluju u RTOF komunikaciji:

$$\begin{bmatrix} A_{ij,1} & A_{ij,2} \end{bmatrix} \begin{bmatrix} \alpha_i \\ \alpha_j \\ \beta_i \\ \beta_j \\ \gamma_{ij}^{(0)} \\ \gamma_{ij}^{(1)} \\ \gamma_{ij}^{(2)} \\ \vdots \\ \gamma^{(L-1)} \end{bmatrix} = \eta_{ij}, \tag{5.4}$$

gdje su:

$$A_{ij,1} = \begin{bmatrix} t_{ij} & t_{ji} & 1_K & -1_K \end{bmatrix}, \tag{5.5a}$$

$$A_{ij,2} = E_{ij} V_{ij} \tag{5.5b}$$

$$V_{ij} = \begin{bmatrix} t_{ij}^{\odot 0} & t_{ij}^{\odot 1} & \cdots & t_{ij}^{\odot L-1} \end{bmatrix}, \tag{5.5c}$$

dok je:

$$t_{ij} = \begin{bmatrix} T_{ij,1} & T_{ij,2} & \cdots & T_{ij,K} \end{bmatrix}^T \in \mathbb{R}^{K\times 1}, \tag{5.6a}$$

$$E_{ij} = \text{diag}\,(e_{ij}) \in \mathbb{R}^{K\times K} \tag{5.6b}$$

$$e_{ij} = \begin{bmatrix} E_{ij,1} & E_{ij,2} & \cdots & E_{ij,K} \end{bmatrix}^T \in \mathbb{R}^{K\times 1}. \tag{5.6c}$$

Oznaka $(\cdot)^{\odot}$ označava operaciju potenciranja, ali za svaki element posebno unutar matrice. Vektori t_{ij} i t_{ji} označavaju vremenske oznake s čvorova i i j, dok vektor e_{ji} je sastavljen od vrijednosti koje određuju smjer komunikacije. Vektor pogrešaka definiran je kao:

$$\eta_{ij} = \begin{bmatrix} \eta_{ij,1} & \eta_{ij,2} & \cdots & \eta_{ij,K} \end{bmatrix}^T \in \mathbb{R}^{K\times 1}. \tag{5.7}$$

Pošto je rang matrice $A_{ij,1}$ manjkav, jedinstveno rješenje modela 5.4 može se dobiti jedino

ako se primijene već prije spomenute restrikcije nad modelom gdje će se jedan od čvorova prozvati referentnim. U tom slučaju model opisan s 5.4 poprima sljedeći oblik:

$$A_{ij}\theta_{ij} = b_{ij} + \eta_{ij}, \tag{5.8}$$

gdje su:

$$A_{ij,1} = \begin{bmatrix} -t_{ji} & -1_K & A_{ij,2} \end{bmatrix} \in \mathbb{R}^{K\times(L+2)}, \tag{5.9a}$$

$$\theta_{ij} = \begin{bmatrix} \alpha_j & \beta_j & \gamma_{ij}^T \end{bmatrix}^T \in \mathbb{R}^{(L+2)\times 1}, \tag{5.9b}$$

$$b_{ij} = -t_{ij}. \tag{5.9c}$$

Primjenom metode najmanjih kvadrata minimiziranjem modela 5.8 prema L^2-normi možemo dobiti jedinstveno rješenje:

$$\hat{\theta}_{ij} = \arg\min ||A_{ij}\theta_{ij} - b_{ij}||_2^2 = \left(A_{ij}^T A_{ij}\right)^{-1} A_{ij}^T b_{ij} = A^{\dagger} b_{ij}, \tag{5.10}$$

gdje je $\hat{\theta}_{ij} = \begin{bmatrix} \hat{\alpha}_j \hat{\beta}_{ij} \hat{\gamma}_{ij}^T \end{bmatrix}^T$ estimirani vektor vrijednosti θ. Ako je matrica A_{ij} singularna, $A^{\dagger}$ predstavlja Moore–Penrose inverz. Parametri $\begin{bmatrix} \hat{\omega}_j \hat{\phi}_{ij} \hat{r}_{ij}^T \end{bmatrix}^T$ mogu biti dobiveni ponovnom primjenom transformacije s relacijom 3.3. Udaljenost u svakom trenutku k može se dobiti s rješenjem:

$$\hat{d}_{ij} = cV_{ij}\hat{\gamma}_{ij} \tag{5.11}$$

Idealno, rješenje 5.11 moglo bi se primijeniti nad cijelim zabilježenim gibanjem, što nije moguće jer estimator podrazumijeva mali vremenski prozor ΔT u kojem se mjerenje izvodi. Dodatno, u slučaju da se želi opisati umjereno složeno gibanje, morao bi se koristiti puno veći red aproksimacije L, što bi značajno povećalo vrijeme izvođenje, kao i memorijske zahtjeve. Također, s povećanjem broja elemenata u aproksimaciji s Taylorovim redom stvara se veća vjerojatnost da sam estimator postane nestabilan.

Predloženo rješenje u ovom doktorskom radu, zapisano u pseudo kodu 1, je da se gibanje estimira po odsječcima te da se naknadno spoje pojedine estimacije odsječaka kako bi se dobila cjelokupna slika gibanja. Metoda je bila inspirirana sa segmetiranim problemom najmanjih kvadrata s područja dinamičkog programiranja. Samu metodu nije moguće izravno primijeniti na ovom problemu pošto se ona može koristiti samo za skup točaka $P = \{x_1, y_1\}, \{x_2, y_2\} \cdots \{x_n, y_n\}$, gdje vrijedi da je $x_1 \leq x_2 \leq \cdots \leq x_n$ na području cijelog mjerenja. Predloženo rješenje u ovom doktorskom radu podrazumijeva dijeljenje vektora t_{ij} and t_{ji} na jednake duljine, gdje su vrijednosti normalizirane s obzirom na prijašnji dio. Svaki od dijelova se zatim odvojeno provodi kroz estimator opisan s 5.11. Na kraju, svaki od zasebnih estimira-

Algoritam 1 Algoritam za segmetirano estimiranje pokreta

procedure SEGMETIRANA ESTIMACIJA
    definiraj maksimalni stupanj L Taylorovog reda
    generiraj vektore T_{ij} T_{ji} vremenskih oznaka
    for $i \leftarrow 1, len(T_{ij})$ **do**
        $(s_{ij}, s_{ji}) \leftarrow$ izrezani (T_{ij}, T_{ji}) na i jednakih duljina
        for $j \leftarrow 2$, maksimalni(L) **do**
            for (dio_{ij}, dio_{ji}) in (s_{ij}, s_{ji}) **do**
                $\hat{d}_{ij} = cV_{ij}\hat{\gamma}_{ij}$
            $d_{ij} \leftarrow [dio_1 \cdots dio_n]$ gdje je $n = i * \text{len}(s_{ij})$
        $e_{ij} \leftarrow (d_{ij} - \hat{d}_{ij})$
    $(duljina\ segmenta, L) \leftarrow min(e_{ij})$

nih dijelova se naknadno povezuju kako bi stvorili kontinuirani signal, odnosno u ovom slučaju gibanje. Algoritam 1 trebao bi biti izveden nad već unaprijed snimljenim gibanjima pošto njegovo izvođenje zahtijeva povećane računalne resurse te ovisi o nezavisno snimljenom gibanju d_{ij}, kako bi se mogla izračunati pogreška prilikom estimacije. Ipak, algoritam se može koristiti za potrebe optimizacije izvedbe procesa u realnom vremenu kako bi se mogli odabrati najbolji parametri s obzirom na vrijeme izvođenja i količinu slobodnih resursa.

5.2 Validacija modela s kompenzacijom izvora vremena

Za validaciju modela opisanog u poglavlju 3.1.1 korišten je postav temeljen na JACO robotskoj ruci*. KINOVA JACO robotska ruka, prikazana na na slici 5.1, je manipulator lakog dizajna sa šest međusobno povezanih segmenata. Može se kontrolirati uz pomoć komandne palice ili uz pomoć računala i prateće programske podrške. Ruka sa svojom hvataljkom ima mogućnost pomicanja u trodimenzionalnom prostoru. Za potrebe validacije modela korišten je samo *Aktuator 3*, koji je temeljen na pokretaču K-75+ od istog proizvođača kao i robotska ruka. Apsolutna preciznost upravljača prilikom korištenja ruke iznosi 1,5°†. Korištenjem programske podrške, brzina upravljača može se postaviti u rasponu od 0 do 60° po sekundi. Za potrebe istraživanja napisan je kratki upravljački program za inicijalizaciju ruke, programiranje putanje kretanja, kao i brzine. Dodatno, program je zapisivao trenutni kut zgloba svakih 5 ms te vrijeme zapisa u *Unix* formatu kako bi se mjerenja mogla sinkronizirati s onima koja pružaju UWB čvorovi. Za validaciju modela koristila se druga verzija razvijenog prototipnog modula. Čvorovi su se postavljali na JACO robotsku ruku što je moguće dalje od zgloba, kako je predloženo u [3] prema tamo provedenoj analizi pogrešaka. Sam položaj čvorova i njihovih baterijskih napaja-

*KINOVA JACO Arm Guide `https://www.kinovarobotics.com/sites/default/files/UG-007_KINOVA_Jaco_\Assistive_robot_User_guide_EN_R02.pdf`

†KINOVA Actuator Guide `https://www.kinovarobotics.com/`

Slika 5.1: Mjerni postav temeljen na JACO robotskoj ruci i DW1000 prototipnim modulima

nja prikazan je na slici 5.1. Kako bi se testirao predloženi model, ruka je bila postavljena u tri statična položaja gdje je *Aktuator 3* bio namješten na vrijednosti od 30° do 180° s korakom od 30°. Ove vrijednosti su odabrane zbog lakše kalibracije i mjerenja udaljenosti od zgloba d_1 i d_2 prikazanih na slici 3.1. Udaljenosti su iznosile otprilike 30 cm. UWB čvorovi bili su prethodno kalibrirani prema preporukama proizvođača. Mjerenje udaljenosti izvodilo se s vremenom osvježavanja od 20 Hz korištenjem RTOF metode. Mjerenje u statičnim položajima izvodilo se otprilike 30 s.

Kako bi se testirale dinamičke karakteristike predloženog estimatora, robotska ruka izvodila je kontinuirano gibanje. *Aktuator 3* kretao se od početne pozicije (30°) pa sve do krajnje (180°) i natrag. Gibanje je bilo snimljeno korištenjem tri različite brzine, 10°/s, 30°/s i 60°/s. Svi zapisi kuteva zgloba pretvoreni su u udaljenosti uz pomoć jednadžbe 3.1 kako bi se vrijednosti mogle analizirati. Nakon početne vremenske sinkronizacije, čvorovi su pratili svoja mjerenja udaljenosti s dodavanjem trenutnog vremena u *Unix* formatu na početak svakog zapisa. Zbog činjenice da su sva mjerenja vremenski sinkronizirana, mogla se primijeniti kvantitativna metrika usporedbe, kao što je Sprague i Geer usporedba [111]. Ova usporedna metrika bila je odabrana zbog mogućnosti da se dva signala mogu usporediti u fazi i magnitudi te izraziti kao mjera pogreške e_{ij} u predloženom algoritmu za kontinuiranu estimaciju 1. S ovom mjerom pogreške algoritam 1 može se iskoristiti za pronalazak najbolje kombinacije stupnja Taylorovog reda L i duljine segmenata korištenih u estimaciji. Pogreška magnitude može se izračunati kao:

$$M_{S\&G} = \sqrt{\frac{\sum_{i=1}^{N} p_i^2}{\sum_{i=1}^{N} m_i^2}} - 1, \tag{5.12}$$

gdje m predstavlja cijeli skup podataka estimiranog signala, dok p predstavlja referentni signal dobiven praćenjem kuta zgloba JACO robotske ruke. Broj uzoraka označen je s N. Slično, pogreška u fazi između signala može se izračunati kao:

$$P_{S\&G} = \frac{1}{\pi} \cos^{-1} \frac{\sum_{i=1}^{N} p_i m_i}{\sqrt{\sum_{i=1}^{N} m_i^2 \sum_{i=1}^{N} p_i^2}}. \tag{5.13}$$

Na kraju, ukupni iznos pogreške između dva signala može se izraziti kao:

$$C_{S\&G} = \sqrt{M_{S\&G}^2 + P_{S\&G}^2}. \tag{5.14}$$

5.2.1 Ponašanje u statičnim uvjetima

Rezultati ponašanja estimatora 5.11 u statičnim uvjetima prikazani su na slici 5.2. Na slici su prikazana referentna mjerenja dobivena od *Aktuatora 3*, estimirane vrijednosti i izmjerena udaljenost uz pomoć TWR metode. Može se primijetiti da estimirana vrijednost puno bolje prati referentne vrijednosti od mjerenja koja su dobivena samo s TWR metodom. Veća greška točnosti estimirane vrijednosti nastaje nakon 100-tog stupnja. Najvjerojatniji uzrok su neprecizno izmjerene udaljenosti d_1 i d_2, kao i postupak umjeravanja čvorova. Prema preporukama proizvođača, umjeravanje modula izvodi se TWR metodom. U kasnijem istraživanju proučit će se mogućnost korištenja estimatora 5.11 prilikom umjeravanja. Između 30° i 90° najveća pogreška točnosti iznosi 6.67°, što je sumjerljivo rezultatima iz [3]. Korištenjem 100 RTOF mjerenja dobivena je standardna devijacija TWR metode od 45,8 mm, dok je za isti broj mjerenja preciznost estimatora 5.11 procijenjena standardnom devijacijom 8,7 mm. To znači da pomoću estimatora standardna devijacija mjerenja smanjila pet puta u najgorem slučaju.

5.2.2 Ponašanje u dinamičkim uvjetima

Najbolji rezultati estimatora 5.11 u dinamičkim uvjetima, prema algoritmu 1, prikazani su na slikama 5.3b, 5.4b i 5.5b. Estimacija gibanja od 10°/s na slici 5.3b provedena je uz odabir petog stupnja Taylorovog reda ($L = 5$) i s duljinom segmenta estimacije od 288 uzoraka. Za gibanje od 30°/s odabrana je duljina segmenta od 312 uzoraka i četvrti red ($L = 4$). Za zadnju brzinu od 60°/s također je odabrana duljina segmenta od 312 uzoraka, ali sa šestim redom ($L = 6$). Treba napomenuti da je broj uzoraka uvijek djeljiv s 2 pošto se vektori T_{ij} i T_{ji} generiraju od vremenskih oznaka nastalih tijekom TWR mjerenja, kako je prikazano na slici 2.3. Primjerice, ako se kaže da je estimator koristio 264 uzoraka, to znači da je provedeno 132 TWR mjerenja.

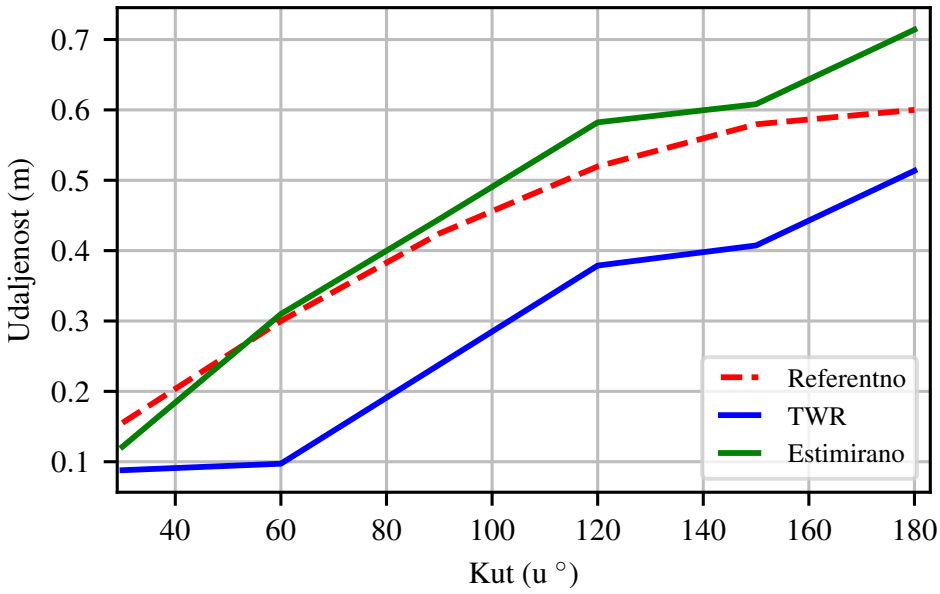

Slika 5.2: Usporedba mjerenja udaljenosti u statičnim uvjetima

Kvalitativno se može primijetiti da estimacija u potpunosti prati referentno mjerenje, makar u nekim slučajevima postoje odstupanja koja mogu biti predmet kasnijih istraživanja. Zanimljivo je primijetiti da je za brže gibanje od 60°/s odabrana ista duljina segmenta kao i za sporije od 30°/s, a jedina razlika je u stupnju Taylorovog reda. To pokazuje da metrika usporedbe 5.14 u potpunosti odgovara predloženoj primjeni jer s istim brojem uzoraka se dobiva zadovoljavajuće ponašanje estimatora. Amplitudna i fazna ovisnost estimatora za pojedina gibanja može se vidjeti na slikama 5.3a, 5.4a i 5.5a, gdje se mogu primijetiti otoci stabilnosti za pojedine kombinacije broja uzoraka i stupnja Taylorovog reda. Također mogu se primijetiti povećane amplitudne i fazne pogreške nakon što se poveća stupanj Taylorovog reda prilikom estimacije.

Ako se ignoriraju točke u kojima je vrijednost arccos nedefinirana prilikom izračunavanja kuta zgloba *Aktuatora 3*, na slici 5.3b srednja pogreška točnosti estimacije iznosi 1,2° dok je standardna devijacija mjerenja 6,3°. Za gibanje od 30°/s srednja odstupanje točnosti je 0,8° sa standardnom devijacijom mjerenja od 9,1°. Za najbrže gibanje od 60°/s odstupanje je 7° sa standardnom devijacijom od 15,7°. Iako nešto lošiji, rezultati su sumjerljivi onima iz [3]. Veći iznos standardne devijacije u zadnjem slučaju mogao bi se rješiti većom frekvencijom osvježavanja kako bi se smanjio stupanj Taylorovog reda korišten prilikom estimacije, kao i broj korištenih uzoraka. Ipak, to dovodi do povećanja radne temperature sklopa u DW1000 zbog učestalijeg uzorkovanja što posljedično uslijed temperaturnog klizanja dovodi do većih pogrešaka točnosti prilikom određivanja udaljenosti, kako je već bilo napomenuto u [109]. Cilj kasnijeg istraživanja je uvesti temperaturnu kompenzaciju kod mjerenja udaljenosti kako bi se umanjio taj problem. Mogući uzroci dobivenih iznosa standardne devijacije leže i u metodi spajanja pojedinih segmenata estimacije gdje npr. nisu uračunati nagli skokovi od jednog prema drugom segmentu.

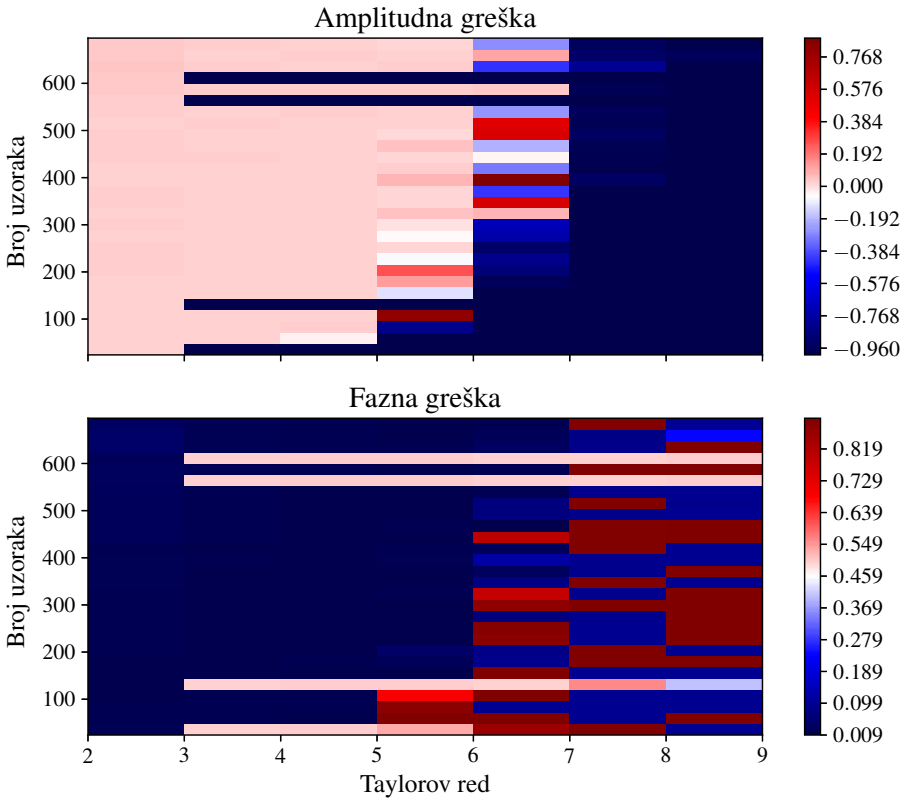

(a) Prikaz pogreške s obzirom na broj uzoraka i stupanj Taylorovog reda

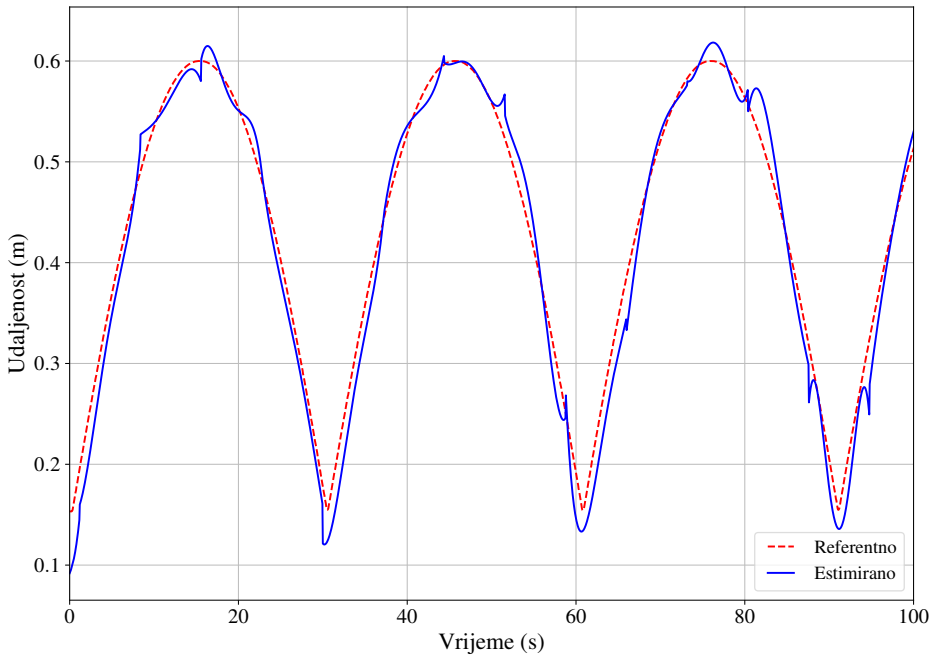

(b) Usporedba estimacije gibanja za najbolji slučaj s referentnim mjerenjem

Slika 5.3: Prikaz pogreške i estimiranog gibanja za brzinu od 10°/s

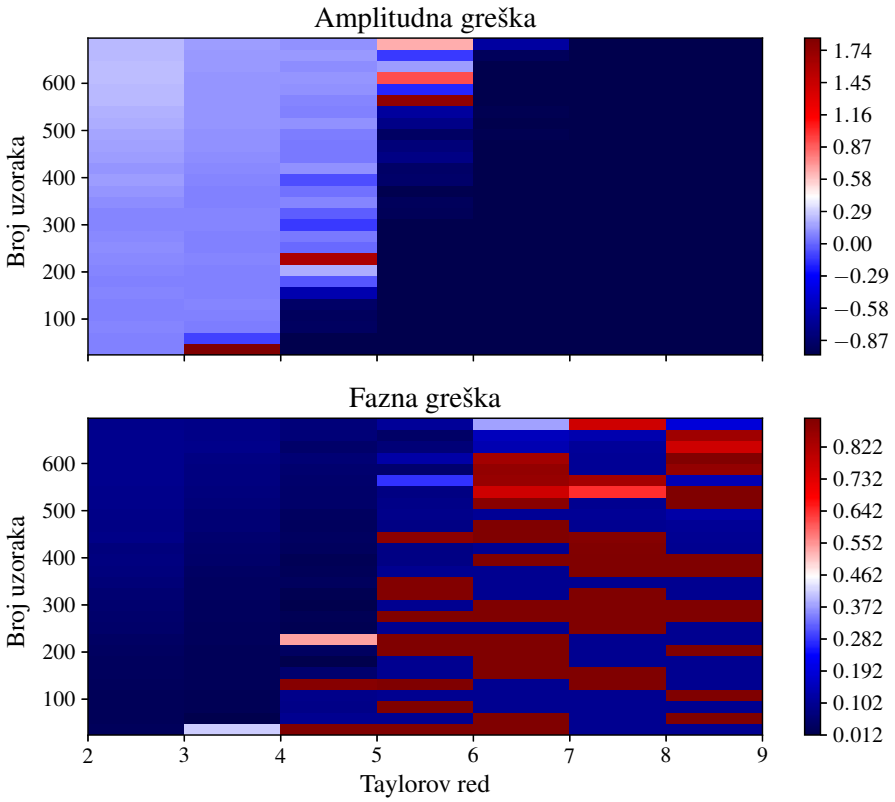

(a) Prikaz pogreške s obzirom na broj uzoraka i stupanj Taylorovog reda

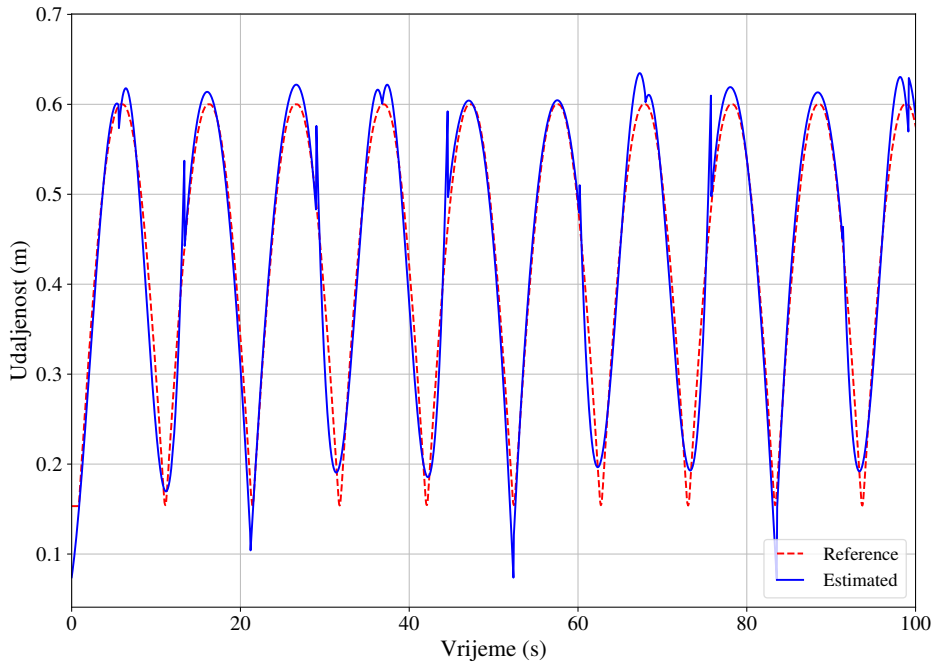

(b) Usporedba estimacije gibanja za najbolji slučaj s referentnim mjerenjem

Slika 5.4: Prikaz pogreške i estimiranog gibanja za brzinu od 30°/s

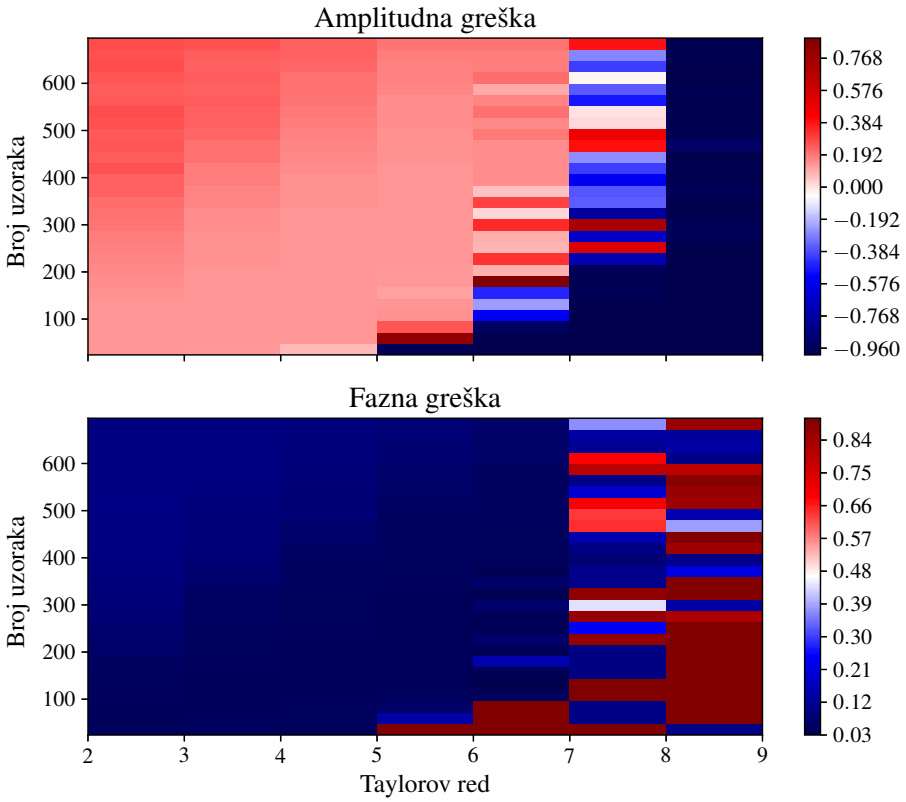

(a) Prikaz pogreške s obzirom na broj uzoraka i stupanj Taylorovog reda

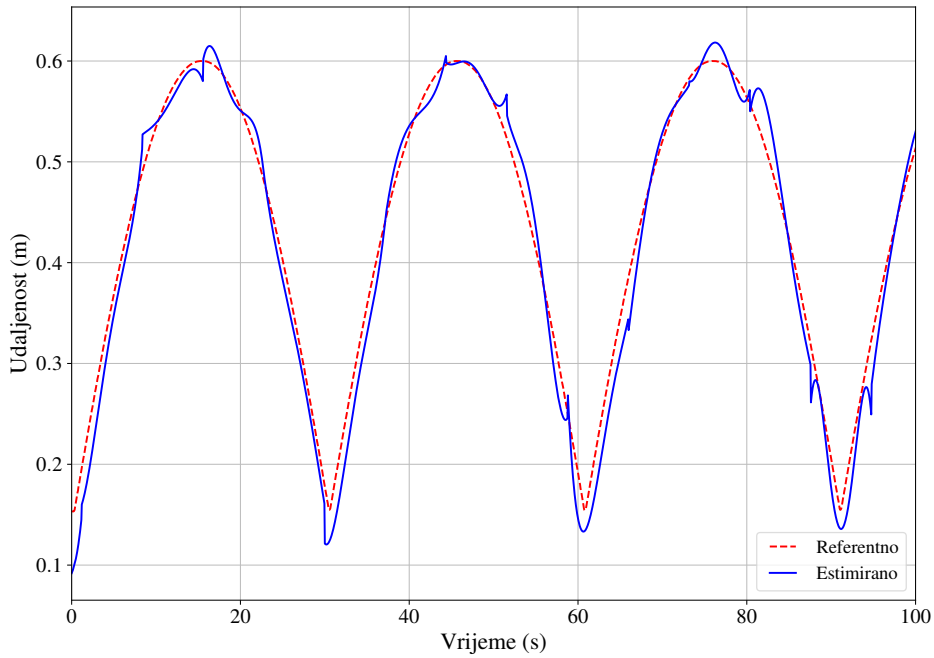

(b) Usporedba estimacije gibanja za najbolji slučaj s referentnim mjerenjem

Slika 5.5: Prikaz pogreške i estimiranog gibanja za brzinu od 60°/s

5.3 Određivanje kuta uz pomoć IMU senzora

Kako bi se mogao odrediti kut između dva IMU senzora, potrebno je prvo pronaći specifične vektore koji opisuju promatrani zglob. Metodama minimizacije i uz pomoć izraza koji su bili izloženi u poglavlju 3.2:

$$e(k,r)^2 = ||a_1(k) - K_1(k)r_1||_2 - ||a_2(k) - K_2(k)r_2||_2\,, \tag{5.15}$$

i

$$e(k,j)^2 = ||\omega_1 \times j_1|| - ||\omega_2 \times j_2||\,, \tag{5.16}$$

mogu se odrediti vektori r_i i j_i koji opisuju položaj zgloba. Važno je napomenuti da vektori j_i ovise samo o položaju postava IMU senzora na zglobovima i opisuju njihove vektore normale. Isto vrijedi i za vektore r_i, koji opisuju položaj centra zgloba u lokalnim koordinatnim sustavima L_i. Ako se označi estimacijski vektor kao $x = [r_1\ r_2]^T$, odnosno $x = [j_1\ j_2]^T$, tada se može iskoristiti Gauss-Newtonova procedura za pronalazak vrijednosti na sljedeći način:

1. izračunati vektor pogreške $e \in \mathbb{R}^{N\times 1}$ za N uzoraka uz pomoć 5.16, odnosno 5.15.
2. izračunati Jakobijane $\frac{\partial e(k,x)}{\partial x}$, kao i njihov Moore-Penrose pseudo-inverz $\left(\frac{\partial e(k,x)}{\partial x}\right)^{\dagger}$
3. osvježiti estimacijski vektor $x = x - \left(\frac{\partial e(k,x)}{\partial x}\right)^{\dagger}$ te krenuti od točke 1. sve dok se ne ostvari uvjet konvergencije

Korištenjem estimiranih vektora zgloba $\hat{j}_i$ može se odrediti kutna brzina u smjeru kretanja zgloba:

$$\omega = \omega_1 \cdot \hat{j}_1 - \omega_2 \cdot \hat{j}_2, \tag{5.17}$$

odnosno sam kut:

$$\theta_\omega(t) = \int_0^t (\omega_1 \cdot \hat{j}_1 - \omega_2 \cdot \hat{j}_2) d\tau. \tag{5.18}$$

Prikaz estimacije kuta, dobiven uz prethodne analize, može se vidjeti na slici 5.6. Ako se pobliže pogleda estimacija, može se primijetiti i utjecaj pozitivnog pomaka žiroskopskih mjerenja, kao i činjenica da početni kut nije poznat.

Kut zgloba također se može odrediti i korištenjem parova akcelerometarskih mjerenja, ali pri tome estimirane vektore $\hat{r}_i$, koji opisuju položaj centra zgloba, mogu se nalaziti bilo gdje na osi kretnje zgloba. Potrebno ih je pomaknuti što bliže odredištima IMU senzora uz pomoć projekcije:

$$r_1 = \hat{r}_1 - j_1 \frac{\hat{r_1} \cdot j_1 + \hat{r_2} \cdot j_2}{2}, \qquad r_2 = \hat{r}_2 - j_2 \frac{\hat{r_1} \cdot j_1 + \hat{r_2} \cdot j_2}{2}. \tag{5.19}$$

Korištenjem ovih novoodređenih vektora mogu se izračunati akceleracije u centru zgloba korištenjem jednadžbi 3.4 te dobiti $\tilde{a}_1$ i $\tilde{a}_2$. Tada uz odabir proizvoljnog vektora $c \neq j_i$ može se

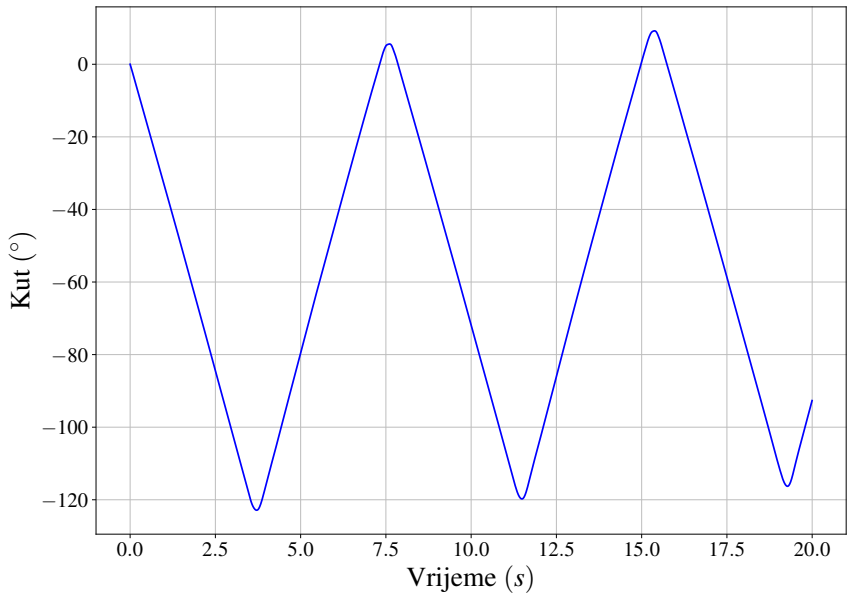

Slika 5.6: Prikaz određivanja kuta uz pomoć žiroskopskih mjerenja na JACO robotskoj ruci

napraviti projekcija akceleracije na os promatranog zgloba pomoću izraza:

$$x_1 = j_1 \times c, \quad y_1 = j_1 \times x_1, \quad x_2 = j_2 \times c, \quad y_2 = j_2 \times x_2, \quad c \nparallel j_1, j_2, \tag{5.20}$$

gdje su x_i i y_i osi u kojima se promatrani zglob nalazi. Tada se projekcije izmjerenih vrijednosti akceleracije mogu izraziti u obliku dvodimenzionalnog vektora:

$$\alpha = \left(\begin{bmatrix} \tilde{a}_1 \cdot x_1 \\ \\ \tilde{a}_1 \cdot y_1 \end{bmatrix}, \begin{bmatrix} \tilde{a}_2 \cdot x_2 \\ \\ \tilde{a}_2 \cdot y_2 \end{bmatrix} \right), \tag{5.21}$$

dok se θ_α može odrediti vektorskim produktom. Kao što je napomenuto u [53], određivanje kuta uz pomoć akcelerometarskih mjerenja posebno je osjetljivo na pogreške ako su vektori $\tilde{a}_i$ kolinearni s vektorima zgloba j_i. Također, metoda postaje nestabilna u situacijama kada na kretnju promatranog zgloba djeluju lateralne akceleracije od smjera kretanja zgloba. U većini slučajeva te su situacije rijetke i uglavnom je vektor gravitacije najizraženija komponenta u mjerenjima akceleracije. Nažalost, ovaj dio metode nije mogao biti validiran na trenutnom mjernom postavu zbog već ranije spomenutih ograničenja opisanih u poglavlju 3.2.1.

5.4 Fuzija višestrukih izvora informacija

Kao što je bilo izloženo u poglavlju 2.3.3, Kalmanov filtar je u većini situacija najbolja metoda za fuziju višestrukih izvora informacija. U ovom slučaju potrebno je, već prije linearizirane mjerne veličine, iskoristiti kako bi se dobila što bolja estimacija kuta zgloba u vremenu. U ovom slučaju postoje tri izvora informacija:

- trenutni kut zgloba dobiven iz UWB mjerenja korištenjem kompenzirane vremenske baze
- trenutni kut zgloba u smjeru kretanja zgloba uz pomoć akcelerometarskih mjerenja
- kutna brzina u smjeru kretanja zgloba dobivena iz žiroskopskih mjerenja; važno je napomenuti da je ova veličina opterećena s konstantnim pomakom u vremenu zbog nesavršenosti senzora

U tom slučaju predloženo je korištenje linearnog Kalmanovog filtra drugog reda s konstantnom akceleracijom kutne brzine:

$$\begin{aligned} x_t &= x_{t-1} + v_{t-1}\Delta t + \frac{1}{2}a_{t-1}\Delta t^2 \\ v_t &= v_{t-1} + a_{t-1}\Delta t \\ a_t &= a_{t-1}. \end{aligned} \tag{5.22}$$

U ovom slučaju, pošto se prati kretanje kuta zgloba, proces dobiva sljedeći oblik:

$$\begin{aligned} \theta_t &= \theta_{t-1} + \dot{\theta}_{t-1}\Delta t + \frac{1}{2}\ddot{\theta}_{t-1}\Delta t^2 \\ \dot{\theta}_t &= \dot{\theta}_{t-1} + \ddot{\theta}_{t-1}\Delta t \\ \ddot{\theta}_t &= \ddot{\theta}_{t-1}. \end{aligned} \tag{5.23}$$

Dodatno, u procesni model moraju se uračunati još dvije veličine: pomak mjerenja kutne brzine θ_b tijekom vremena uzrokovan nesavršenostima žiroskopskih mjerenja te početni kut θ_0. U tom slučaju model poprima sljedeći oblik:

$$\begin{aligned} \theta_t &= \theta_{t-1} + \dot{\theta}_{t-1}\Delta t + \frac{1}{2}\ddot{\theta}_{t-1}\Delta t^2 + \theta_0 \\ \dot{\theta}_t &= \dot{\theta}_{t-1} + \ddot{\theta}_{t-1}\Delta t + \theta_b \\ \ddot{\theta}_t &= \ddot{\theta}_{t-1}. \end{aligned} \tag{5.24}$$

Iz modela procesa opisanog jednadžbama 5.24 dolazi se do vektora estimacija **x**:

$$\mathbf{x} = \begin{bmatrix} \theta \\ \dot{\theta} \\ \ddot{\theta} \\ \theta_0 \\ \theta_b \end{bmatrix}, \tag{5.25}$$

kao i procesne matrice **F**:

$$\mathbf{F} = \begin{bmatrix} 1 & \Delta t & \frac{1}{2}\Delta t^2 & 1 & 0 \\ 0 & 1 & \Delta t & 0 & 1 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix} \tag{5.26}$$

Matrica kovarijance procesa **Q** dizajnirana je korištenjem standardnih devijacija IMU i UWB mjerenja te pogreške procesa opisanog jednadžbama 5.24. Za veličine θ_b i θ_0 uzeto je da je njihova standardna devijacija jednaka nuli.

Kao što je već prije bilo rečeno, postoje tri mjerne veličine pa vektor mjerenja **z** poprima sljedeći oblik:

$$\mathbf{z} = \begin{bmatrix} \theta_{\text{UWB}} \\ \theta_\alpha \\ \dot{\theta}_\omega \end{bmatrix}. \tag{5.27}$$

Posljedično, matrica mjerenja **H** poprima oblik:

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix}. \tag{5.28}$$

Matrica kovarijance mjerenja **R** dizajnirana je korištenjem standardnih varijanca IMU i UWB mjerenja.

5.5 Klasifikacija i prepoznavanje pokreta

Prepoznavanje pokreta svodi se na prepoznavanje ponavljajućih obrazaca u podatcima. Ako korisnik izvodi predefinirani set pokreta A on se može izraziti kao:

$$A = \{A_i\}_{i=1}^{m}, \tag{5.29}$$

gdje m predstavlja broj pokreta. S obzirom na skup podataka sa senzora $\mathbf{s}$, koji se može izraziti kao:

$$\mathbf{s} = \{d_1, d_2, \cdots, d_t, \cdots, d_n\}, \tag{5.30}$$

gdje d_t predstavlja vrijednost snimljenu u trenutku t, potrebno je razviti model $\mathscr{F}$ koji će predvidjeti pokret:

$$\hat{A} = \{\hat{A}_j\}_{i=1}^{n} = \mathscr{F}(\mathbf{s}), \qquad \hat{A}_j \in A. \tag{5.31}$$

Cilj prepoznavanja pokreta pomoću modela $\mathscr{F}$ je da se minimizira pogreška između prepoznate aktivnosti $\hat{A}$ i stvarne aktivnosti A^*, koja se može izraziti kao:

$$A^* = \{A_j^*\}_{i=1}^{n}, \qquad A_j^* \in A, \tag{5.32}$$

gdje n predstavlja duljinu signala $\mathbf{s}$ i mora vrijediti $n \geq m$. Model prepoznavanja općenito ne uzima direktno signal $\mathbf{s}$ kao ulazni parameter, nego njegove značajke $\Phi(d_i) \in \mathscr{R}^d$ dobivene projekcijskom funkcijom Φ. Funkcija određivanja značajki Φ pretvara senzorska očitanja $d_i \in \mathbf{s}$ u d-dimenzionalni vektor značajki koji se zatim koristi prilikom minimizacije funkcije gubitka $\mathscr{L}(\mathscr{F}(\Phi(d_i), A^*, A))$.

Većina korištenih metoda za prepoznavanje pokreta temelji se na ručno određenim specifičnim značajkama podataka (engl. *feature extraction*) te iz tog razloga pojedine metode prepoznavanja obrazaca ne daju zadovoljavajuće rezultate nad skupovima podataka koji su prikupljeni u stvarnim situacijama prilikom korištenja samo IMU senzora [112]. Iz tih razloga metode temeljene na dubokom učenju (engl. *deep learning*) daju bolje rezultate jer ne ovise o prije odabranim svojstvima signala koji se koriste prilikom određivanja pokreta. Ipak, osim korištenja naprednih metoda klasifikacija i prepoznavanja obrazaca, pokazuje se da se uz predobradbu *sirovih* podataka s IMU senzora, koja uzima u obzir kinematiku kretanja ljudskog tijela, mogu značajno poboljšati rezultati. U [113] napravljena je usporedba korištenja neobrađenih i obrađenih podataka, gdje su se određivali kutevi pojedinih zglobova uz pomoć 5 IMU senzora. Određivanjem kuta zgloba povećana je točnost klasifikacije korištenjem istih metoda strojnog učenja kao i slučaju neobrađenih podataka. Metode mogu biti temeljene na statistici (*Gaussian naive Bayes*, *linear discriminant analysis*), *kernel* funkcijama (*stochastic gradient descent*, *support vector machine*), stablima odluke (*classification and regression trees*), na udaljenostima

između pojedinih značajki (*k-nearest neighbors*), dubokom učenju itd.

Općenito postupak određivanja značajki signala svodi se na postupaka redukcije signala A na diskretne vrijednosti $\mathscr{X}_i$ koje opisuju neku od aktivnosti, odnosno pokreta, što se može formalno izraziti kao:

$$\mathscr{X}_i = \Phi(L, w_i), \tag{5.33}$$

gdje je w_i segment signala L koji sadrži aktivnosti y_i. Značajke neobrađenog signala svode se na određivanje aritmetičke sredine, standardne devijacija, minimalne i maksimalne vrijednosti, spektralnih komponenta itd. Odabir vremenskih značajki signala značajno ovisi o *a priori* znanju o promatranom procesu. Primjerice, praćenjem ukupne snage može se razlikovati mirovanje od skakanja, ali ne i tipkanje na mobitelu ili laptopu [114]. Važno je za napomenuti da se specifične značajke signala određuju na nekom manjem segmentu signala, a ne na cijeloj duljini. Što je širi prozor nad kojim se određuju značajke, to su one više izraženije, ali isto tako smanjuje se broj kategorija koje se mogu razlikovati. U literaturi se koriste prozori u trajanju od 0,08 s pa sve do 30 s, pri čemu se pojedini segmenti preklapaju ili su u potpunosti odvojeni [115].

Prepoznavanje pokreta i ljudske aktivnosti uz pomoć akcelerometara koristi se već 15 godina, ali isto tako u tom istom vremenu nije bilo značajnih pomaka u povećanju kompleksnosti klasifikacijskih grupa [114]. Prepoznavanje pokreta korištenjem samo IMU senzora je u svojevrsnoj stagnaciji ako se izuzmu najnovija istraživanja s novijim modelima strojnog učenja, kao što su metode dubokog učenja, konvolucijske neuronske mreže (engl. *convolutional neural networks*) itd. [112, 116–118]. Drugim riječima, iako su metode prepoznavanje postale složenije, klasifikacijske grupe su dalje vrlo jednostavne i mogu jedino odrediti razliku između aktivnosti, kao što su primjerice "sjedenje" ili "trčanje" [119]. U [114] napominje se kako to nije problem količine podataka, već njihove kvalitete. Upravo iz tog razloga prethodno spomenuti rad predlaže korištenje senzora koji imaju veći modalitet, za razliku od akcelerometara koji su dobri za klasifikaciju ponavljajućih radnja u kratkim vremenski prozorima. Iz tih razloga potrebno je kombinirati višestruke izvore informacija, primjerice akcelerometra, žiroskopa i magnetometra, kako bi se postigli bolji rezultati prilikom klasifikacije [120].

Kako bi se demonstrirao navedeni problem određivanja značajki prilikom estimacije, napravljeno je mjerenje na subjektima gdje su se na zapešće i ruci ispod ramena postavili moduli, kako je prikazano na slici 5.1. Subjekte se zamolilo da ispred sebe u zraku ispisuju slova "A", "B" i "C" bez pauzi u trajanju od 30 s po svakom od pokreta. Rezultati IMU mjerenja na jednom subjektu mogu se vidjeti na slici 5.7. Prikazana mjerenja dobivena su nakon što su bila prethodno obrađena uz pomoć zaključaka iz poglavlja 2.3.4 gdje se odabrao preklapajući prozor od 20 mjerenja kako bi se smanjio utjecaj šuma. Ipak, može se primijetiti da bez obzira na odabranu os mjerenja ili slovo koje je ispisano, mjerenja kvalitativno izgledaju slično. Kvantitativno njihova sličnost je prikazana na slici 5.8. Osim ispisivanja slova "C", gdje se vidi očigledni šiljak u broju mjerenja, ostatak mjerenja ima podjednak broj mjerenja sličnih vrijed-

nosti. Važno je napomenuti da histogram prikazuje rezultate u prozoru od 15 s, gdje prema [115] se može očekivati najveći broj specifičnih značajki pojedinih kretnji.

Na slici 5.9 mogu se vidjeti estimirane vrijednosti kuta lakta za iste pokrete kao i na slici 5.7. Ono što se može odmah primijetiti je kvalitativna razlika između pojedinih snimki. Promjene kutova, odnosno samo gibanje, bilo je estimirano uz pomoć metode fuzije senzora opisane u poglavlju 5.4, gdje su mjerenja udaljenosti bila kompenzirana s parametrom $L = 4$ uz korištenje 288 RTOF mjerenja. Parametri su bili odabrani s obzirom na provedenu validaciju najsporijeg gibanja JACO robotske ruke, kako je bilo opisano u poglavlju 5.1. Isto kao i za prošla mjerenja, kvantitativna razlika prikazana je na slici 5.10 uz pomoć histograma pojedinih pokreta. Prepoznavanje u ovom slučaju može se izvesti uz pomoć jednostavnog uvjeta bez primjene generalizirane metode prepoznavanja $\mathscr{F}$ pošto se snimke pokreta u potpunosti razlikuju u rasponu minimalne i maksimalne vrijednosti estimiranog kuta, kao i u broju pojedinih vrijednosti. Ovim rezultatima potvrđuje se zaključak iz [114] pošto je klasifikacija postala jednostavnija uz povećanje modaliteta informacije uz pomoć fuzije višestrukih izvora informacija te njihovom interpretacijom s obzirom na ljudsko gibanje, odnosno promjenu kuta zgloba.

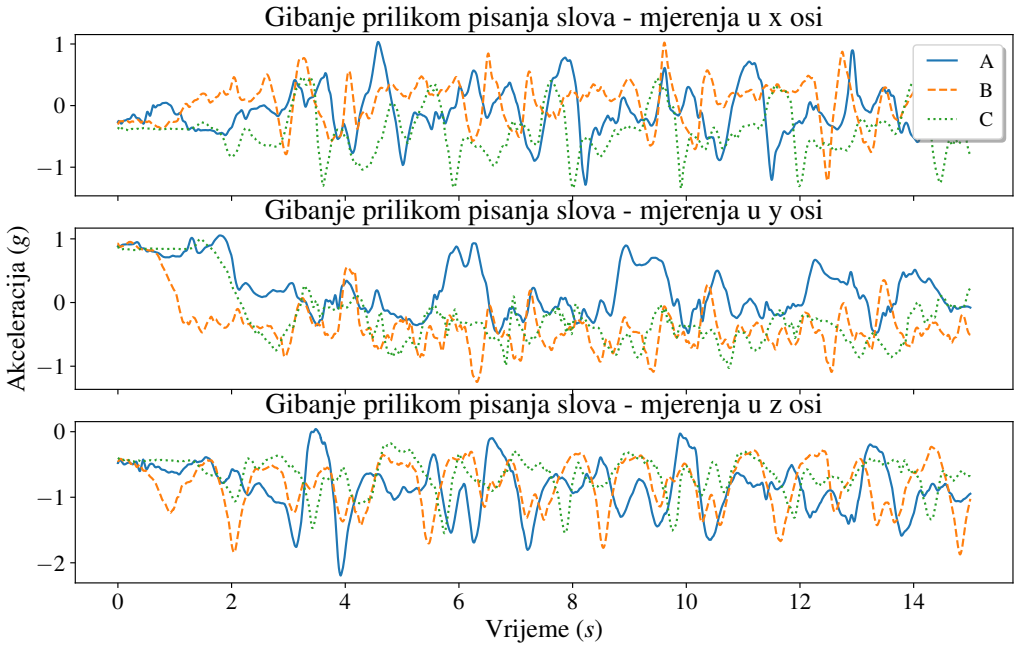

Slika 5.7: IMU mjerenja prilikom ispisivanja slova u zraku

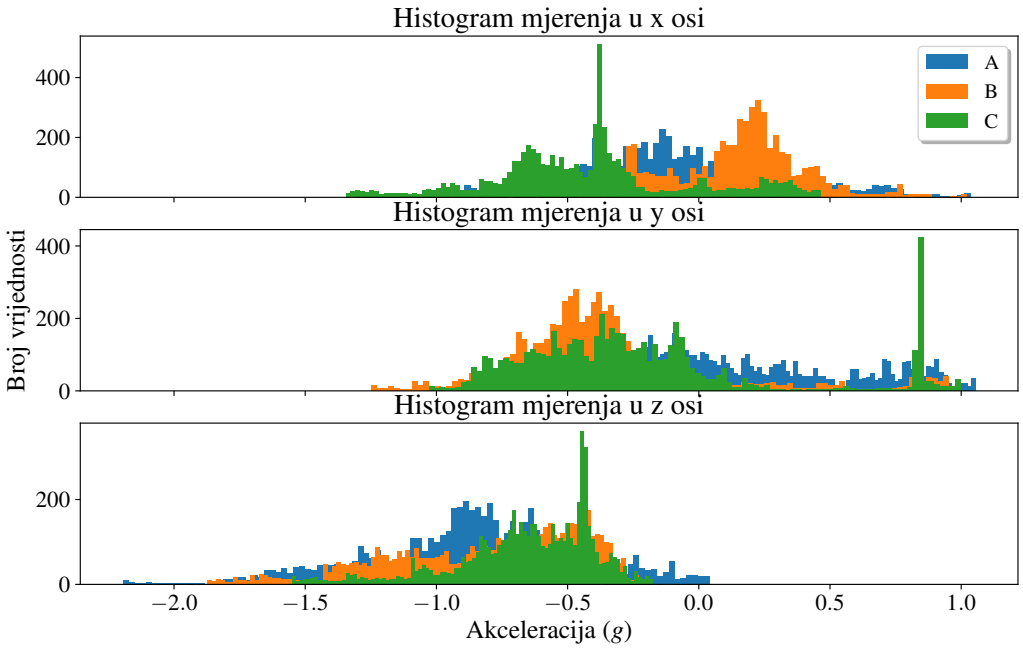

Slika 5.8: Histogram IMU mjerenja prilikom ispisivanja slova u zraku

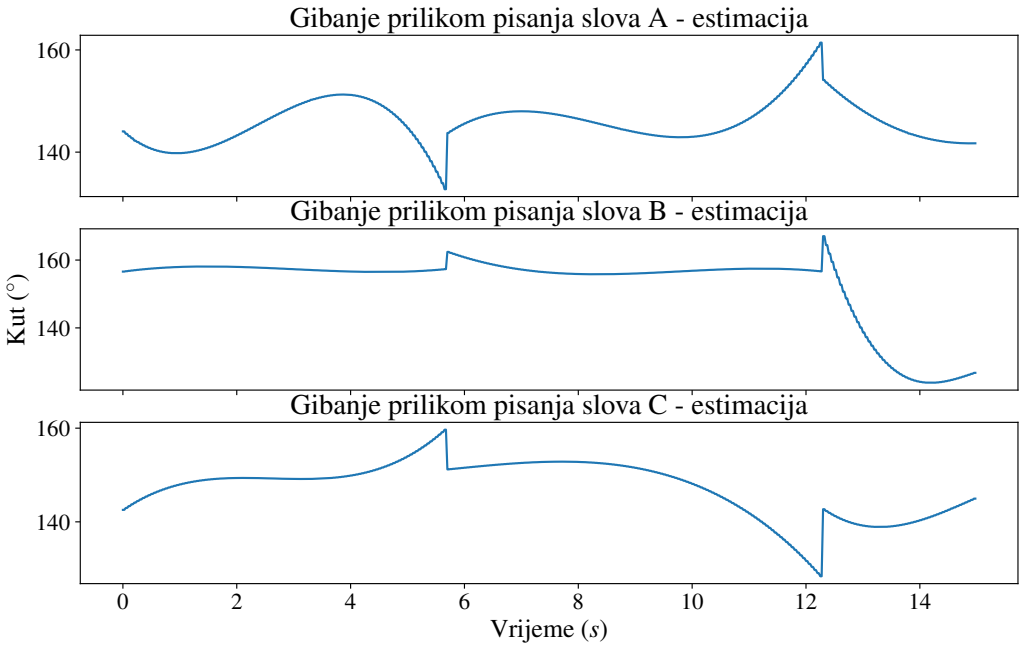

Slika 5.9: Estimacija kuta lakta prilikom ispisivanja slova u zraku

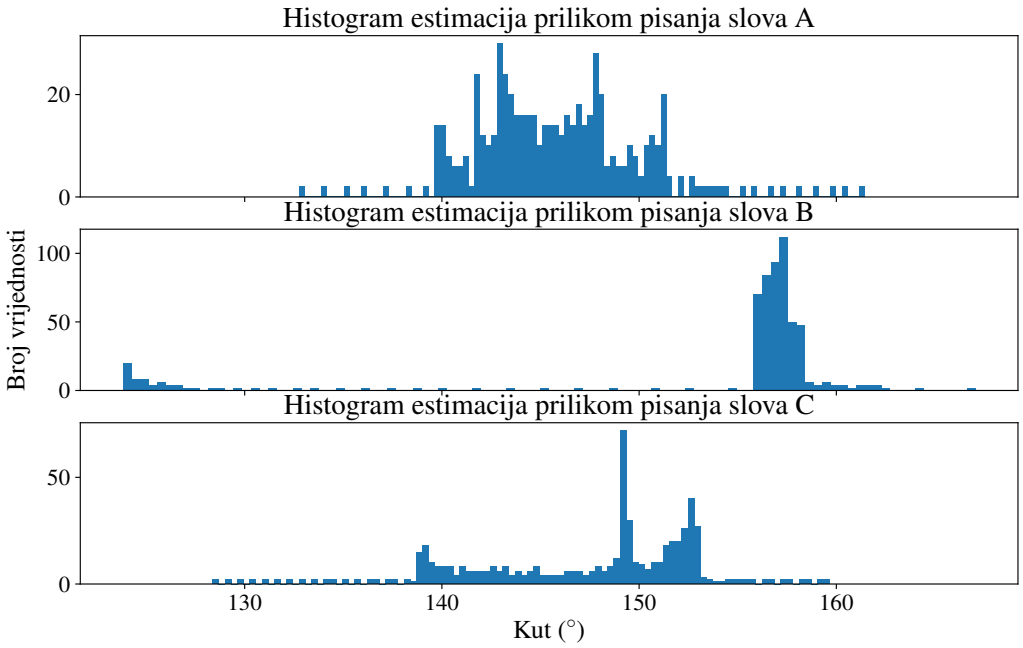

Slika 5.10: Histogram estimacije kuta lakta prilikom ispisivanja slova u zraku

Poglavlje 6

Zaključak

UWB tehnologija predstavlja brzorastuće područje s nizom novih mogućnosti i primjena. Metode, algoritmi i sklopovska rješenja koja to omogućuju predmet su intenzivnih istraživanja. Navedeni sustavi usavršavaju se s ciljem postizanja što boljih performansi i niže cijene. U okviru ove doktorske disertacije istražena je mogućnost uporabe UWB tehnologije, kombinirane s IMU senzorima, u svrhu praćenja i klasifikacije ljudskoga pokreta. Kako bi se proučile granice praktične primjenjivosti tehnologije, razvile su se potrebne metode za interpretacije senzorskih podataka, kao i prototipno rješenje sustava za mjerenje udaljenosti uz pomoć UWB tehnologije. Isto tako, razvila se i potrebna programska potpora za pravovremeno i pouzdano prikupljanje mjernih podataka s IMU senzora. Kako bi se povećala preciznost određivanja udaljenosti, razvila se metoda za optimiranje estimacije gibanja, kao i fuzija višestrukih izvora informacija. Postav se validirao u laboratorijskim uvjetima te su se odredile točnost i preciznost za pojedine brzine gibanja. Na kraju ju pokazano da je metoda primjenjiva za izlučivanje boljih značajki za klasifikaciju pokreta kod mjerenja na čovjeku.

Jedan od osnovnih problema kod lokalizacijskih metoda je ostvarenje optičke vidljivosti (LOS) između baznih i mobilnih stanica, što nije uvijek moguće postići unutar zatvorenih prostora. Nadalje, postoji problem višestaznog širenja signala, odnosno refleksija od okolnih objekata. U takvim uvjetima ne možemo samo na temelju primljenog signala biti sigurni u vrijeme propagacije i kut njegovog dolaska. Za modeliranje problema određivanja udaljenosti UWB tehnologijom bilo je potrebno analizirati propagaciju signala u prijenosnom mediju. Analiza ponašanja UWB sustava razlikuje se od široko rasprostranjenih modela koji vrijede za uskopojasne bežične kanale i ti modeli ne mogu se najčešće izravno primijeniti za analizu UWB prijenosnog kanala. Jedna od fundamentalnih razlika odnosi se na analizu širenja UWB signala kod slučaja višestaznih refleksija. Potrebno je uzeti u obzir da prijenosna funkcija kanala ovisi o frekvencijama koje kanal reflektira ili apsorbira. Ako se te činjenice povežu s analizom ponašanja UWB kanala u blizini tijela osobe, čiji se pokreti određuju, važno je uzeti u obzir utjecaj čovjeka i strukture prostorije na prijenosni kanal, jer je već pokazano da sama prisut-

nost prepreka ili aktivnost čovjeka mijenja njegova svojstva. S obzirom na područje i ciljeve istraživanja, analizirali su se odgovarajući modeli koji opisuju ponašanje jednog takvog sustava u uvjetima ciljne praktične primjene detekcije pokreta i gesti. Korištenjem referentnog postava propagacijski kanal se eksperimentalno analizirao kako bi se ustanovili izvori pogreška u mjernom procesu. Bez obzira na navedene probleme, ultraširokopojasna tehnologija predstavlja obećavajuće rješenje za određivanje udaljenosti i, posljedično, lokacije objekta. Također, pokazuje se da se korištenjem UWB tehnologije u zatvorenim prostorima može postići razmjerno visoka točnost pozicioniranja. Dodatne prednosti UWB tehnologije su visoka brzine prijenosa podataka, niska cijena, otpornost na višestazne signale te sposobnost istodobne lokalizacije i komunikacije. Dodatno, UWB signal ima mogućnost prodiranja kroz prepreke (npr. zidove), zbog širokog frekvencijskog pojasa, pa LOS nije nužan uvjet za uspostavu komunikacije. Osnovne izvedbe UWB sustava postižu točnost od 20 cm, a uz dodatnu obradu mjerenja mogući su i bolji rezultati. UWB tehnologija za nadzor ljudske aktivnosti može se koristiti na dva načina. Prvi je da se koristi svojstvo UWB kanala i radarska primjena kako bi se detektirala, pratila i klasificirala aktivnost čovjeka u zatvorenom prostoru ili čak iza prepreka kao što su zidovi. Drugi način je koristiti svojstvo određivanja vremena dolaska signala te pozicionirati UWB primopredajnike na promatranim objektima ili dijelovima tijela za potrebe praćenja pokreta.

Model fuzije podataka iz više senzora može dodatno poboljšati svojstva određivanja parametara ljudskog pokreta te istovremeno minimizirati pogreške koje mogu unijeti dodatni senzori. Modelom se nadalje mogu odbaciti vrijednosti za koje se zna da objekt nije sposoban postići. Poboljšanje interpretacije rezultata i izlučivanja značajki promatranih pokreta postiglo se s kombiniranjem UWB tehnologije i inercijskih senzora. Inercijske senzore čine akcelerometar, žiroskop i magnetometar, tipično smješteni u istom kućištu. Za procjenu položaja i orijentacije, dobivena mjerenja potrebno je integrirati po vremenu, ali s povećanjem trajanja mjernog intervala utjecaji intergracijske pogreške, smetnji i šuma postaju sve značajniji i uzrokuje nepoželjne pogreške. Proces fuzije najčešće se ostvaruje uz korištenje Kalmanovih ili proširenih Kalmanovih filtara. Nadalje, inercijski senzori mogu se kombinirati s drugim modelima, npr. s kinematičkim modelima kretanja čovjeka, u svrhu boljeg određivanja smjera i brzine kretanja. Od svih kombinacija inercijskih i radijskih sustava, u području lokalizacije, pokazuje se da je korištenjem UWB tehnologije moguće postići rezultate sumjerljive sustavima za praćenje pokreta temeljenim na računalnom vidu. Pregledom postojeće literature došlo se do zaključka da postoji prostor za daljnja istraživanja u području fuzije lokalizacijskih senzora i inercijskih senzora. Ranija istraživanja u području praćenja pokreta i nadzora aktivnosti čovjeka pokazala su opravdanost ovakvog pristupa. Još uvijek je nedovoljno istražena mogućnost primjene navedenog pristupa u interakciji čovjeka s računalom, pomoću nosivih, energetski učinkovitih sustava za lokalizaciju. Dok se metode strojnog učenja uglavnom primjenjuju na estimaciju stanja UWB kanala, područje klasifikacije pokreta nedovoljno istraženo.

Za potrebe istraživanja bilo je potrebno razviti sklopovsku izvedbu malenog, kompaktnog, baterijski napajanog i energetski učinkovitog čvora za mjerenje udaljenosti i detekciju pokreta i gesti, pogodnog za nošenje. Razvijena je prilagodljiva arhitektura programske potpore raspodijeljenog sustava koja je omogućila potrebnu funkcionalnost za eksperimentalna istraživanja, prikupljanje senzorskih podataka za daljnju obradbu te validaciju i verifikaciju razvijenih modela i metoda. Programska potpora omogućila je jednostavnu konfiguraciju sustava, podatkovnu komunikaciju između čvorova, vremensku sinkronizaciju, prikupljanje podataka za analizu algoritama za određivanja udaljenosti iz vremena slanja i primanja UWB signala, prikupljanje podataka iz inercijskih senzora, pohranu, kao i slanje prikupljenih podataka na centralnu jedinicu za obradu. Korištenjem prikupljenih podataka razvijena je metoda vremenske kompenzacije bežičnih UWB čvorova za određivanje udaljenosti radi dobivanja što veće točnosti i preciznosti prilikom izračuna udaljenosti između njih. Proučeni su različiti pristupi lokalizaciji (kao što su: TOA, TDOA, RTOF itd.), kao i odgovarajući algoritmi obrade signala i podataka u svrhu optimiranja performansi odabranog estimatora. Pomoću eksperimentalnog postava ustanovile su se granice točnosti i primjenjivosti sustava i ranije navedenih metoda i algoritama obrade podataka, a dobiveni rezultati usporedili su se s referentnim postojećim sustavom slične namjene.

Općenito cilj doktorske disertacije bio je istražiti mogućnosti primjene fuzije UWB lokalizacije i inercijskih senzora u području prepoznavanja pokreta, pri čemu se nastojalo odrediti praktične granice točnosti i primjenjivosti takvog pristupa, kao i razraditi metode izlučivanja značajki za potrebu klasifikacije pokreta iz senzorskih podataka. Osnovna hipoteza prilikom izrade rada bila je pretpostavka da se iz senzorskih podataka može prikupiti reprezentativna informacija za klasifikaciju pokreta. Obrana navedene hipoteze izložena je u pet poglavlja.

U uvodu je prikazan pregled motivacije istraživanja u području praćenja pokreta ljudskog tijela koje je tijekom proteklog desetljeća privuklo veliku pozornost u znanstvenoj i inženjerskoj zajednici. Općenito, sustavi za praćenje ljudskog pokreta prikupljaju kinetičke i kinematičke informacije o kretanju tijela ili njegovih pojedinih dijelova, u svrhu kvantitativne analize parametara koji se odnose na njihove relativne međusobne položaje. Posebni naglasak bio je na analizi ljudskog lokomotornog sustava, kao i na prikazu trenutnog presjeka metoda i tehnologija koje se koriste prilikom praćenja pokreta.

Pregled tehnologija za određivanje položaja objekata dan je u sljedećem poglavlju, i to u ovisnosti o primjeni, točnosti, preciznosti, mogućnosti dinamičkog praćenja pozicije, o uvjetima okoline, ovisnosti o infrastrukturi, energetskoj efikasnosti i potrošnji, sklopovskoj i programskoj složenosti, autonomiji rada, cijeni, masi, dimenzijama, mobilnosti sustava i sl. Za potrebe analize postojećih sustava i tehnologija za određivanje položaja napravljen je pregled osnovnih pojmova i metoda. Izloženo je trenutno stanje znanstvenog istraživanja s fokusom na određivanje kuta ljudskog zgloba. Također, u kontekstu ovog poglavlja izložene su primjene IMU senzora u praćenju ljudske aktivnosti, pod čime se podrazumijeva praćenje položaja, ori-

jentacije i kretanja ljudskog tijela kao cjeline ili njegovih pojedinih dijelova. Isto tako, posebni naglasak dan je na istraživanje primjene UWB tehnologije. Izložene su prednosti i nedostatci pojedinih metoda i tehnologija s ciljem opravdanja daljnjih postupaka istraživanja. U prethodno obavljenim istraživanjima uočeni su nedostatci prilikom primjene UWB tehnologije u praćenju kretnji čovjeka. Primijetilo se da se sva dostupna istraživanja temelje na modelima koje koriste pozicije dobivene pomoću UWB sustava, odnosno koordinata u referentnom koordinatnom sustavu. Iako takav pristup daje zadovoljavajuće rezultate, ujedno predstavlja i važno praktično ograničenje. Dobivanje pozicije od UWB sustava podrazumijeva neku vrstu fiksne infrastrukture, kao i prethodne kalibracije da bi se uhodao sustav za pozicioniranje na određenom području. Iako postoje automatizirani pristupi kalibraciji sustava za UWB pozicioniranje, navedeni pristup i dalje zahtijeva neki oblik dodatne infrastrukture oko promatranog čovjeka. U slučaju kada se UWB tehnologija koristila bez infrastrukture, odnosno kada su se mjerile samo međusobne udaljenosti između čvorova, primijećeno je da se u pronađenim istraživanjima koristila isključivo visoko precizna i sofisticirana laboratorijska oprema, a ne jeftini moduli nižeg stupnja preciznosti.

Upravo iz prije navedenih razloga razvijen je model mjerenja udaljenosti s kompenzacijom vremenske baze mobilnih čvorova u sljedećem poglavlju. Ovakav pristup odabran je kako bi se primjenjivost mjerenja udaljenosti uz pomoć UWB tehnologije mogla proširiti i na jeftinije sustave, bez potrebe za korištenjem skupe laboratorijske opremom s visoko stabilnim izvorom vremenske baze. Na isti način uklonila se potreba za korištenjem fiksne infrastrukture. U navedeni model bili su uključeni i IMU senzori koji su se koristili za određivanje pokreta dijelova ljudskog tijela zbog svoje pristupačne cijene i veličine. Dodatno, prilikom mjerenja ljudskog pokreta s IMU senzorima uzimao se u obzir kinematički model kretanja čovjeka, specifično kinematički lanac koji opisuje kretanje segmenata povezanih sa zglobovima s više stupnjeva slobode. Model kretanja pojedinih segmenata se na ovaj način redefinirao i pojednostavio uz korištenje višestrukih izvora informacija, odnosno korištenjem parova IMU senzora. Isto tako, prilikom predthodnog istraživanja izvučen je i zaključak da se prilikom fuzije, odnosno prilikom estimacije orijentacije IMU senzora, izbjegava korištenje magnetometra.

Iako su se *modelom za određivanje položaja i pokreta ljudskog tijela iz podataka dobivenih nosivim ultraširokopojasnim lokalizacijskim senzorima i inercijskim senzorima* obuhvatili višestruki izvori informacija, kao i uključili kinematički lanci kretanja čovjeka, postoje pravci za poboljšanje tog modela. U području određivanja udaljenosti i dalje je potrebno napraviti prethodna mjerenja duljine pojedinih segmenata koji sudjeluju u gibanju zgloba. Točnost mjerenja duljine segmenata izravno utječe na pogrešku mjerenja kuta zgloba. Zbog prirode trigonometrijskih funkcija, pogreška mjerenja manja je pri manjim kutevima zgloba, a veća pri većim iznosima. Dodatno, iako nam modeli kinematsog lanca omogućuju korištenje IMU senzora bez prethodnih kalibracijskih pokreta ili mjerenja, pokazalo se da je Gauss-Newtonova metoda

nestabilna prilikom većeg broja uzoraka. Za stabilno korištenje navedenih modela potrebno je napraviti dodatnu analizu i istraživanje funkcija pogrešaka. Buduća istraživanja trebala bi uključiti istraživanje mogućnosti korištenja kalibracijskih pokreta IMU senzora s ciljem određivanja specifičnih vektora od postavljenih senzora do centra rotacije zgloba. Modul, odnosno duljina tog vektora bi se zatim mogla koristiti prilikom izračunavanja udaljenosti UWB tehnologijom.

Za praktičnu evaluaciju modela predloženog u prijašnjem poglavlju, bilo je potrebno razviti arhitekturu i implementaciju sustava za prikupljanje mjernih podataka u obliku nosivih bežičnih senzorskih čvorova niske potrošnje. Izvedba čvorova koji su bili razvijeni s ciljem postavljanja na ljudsko tijelo opisana je u četvrtom poglavlju. Razvijeni čvorovi imaju mogućnost mjerenja udaljenosti korištenjem UWB tehnologije te akceleracije i kutne brzine uz pomoć ugrađenog IMU senzora. U svrhu sklopovske realizacije sustava razvijeno je više inačica sklopovlja temeljenih na korištenju integriranog sklopa DW1000. Postojeći komercijalno dostupni razvojni sustavi nisu sadržavali sve potrebne sklopovske komponente nužne za provedbu i obradu mjerenja. Također, programske biblioteke proizvođača integriranog sklopa trebale su biti nadograđene novim mogućnostima s obzirom da postojeća programska potpora nije pružala svu potrebnu funkcionalnost. Rješenje temeljno na DW1000 integriranom sklopu također je bilo potrebno testirati kako bi se dokazalo da je funkcionalno ispravno te da ne unosi sustavne pogreške prilikom mjerenja. Također, ispitali su se različiti izvori pogrešaka koji mogu utjecati na točnost i preciznost mjerenja. Najveća pažnja posvetila se utjecaju uskopojasnih komunikacija, čiji se spektar preklapa s frekvencijskim područjem rada UWB komunikacijskog sustava, kao i utjecaju refleksija u okruženjima s višestaznim rasprostiranjem.

Korištenjem *arhitekture sklopovske i programske izvedbe mjernog postava niske potrošnje za određivanje položaja i pokreta ljudskog tijela* dobiveni su prvi rezultati za validaciju prethodno opisanog modela. Iako je sklopovska arhitektura bila dizajnirana s ciljem što manje potrošnje, nisu se odredile krajne granice korištenja ovakvog tipa sustava, kao niti vrijeme autonomije rada, što je od posebne važnosti u HMT sustavima. Dodatno, prilikom analize ponašanja cjelokupnog sustava uočena je potreba za dodatnim istraživanjem izvora sustavnih pogrešaka koje se pojavljuju tokom korištenja IEEE 802.11b/g/n bežičnih mreža. Trenutno, zaključak je jedino da odmak u mjerenjima udaljenosti u različitim okružjima postoji, ali nije određen izravni uzrok, niti detaljnije razrađen postupak mitigacije takvih izvora pogrešaka. Dodatno, bile su razvijene tri varijante prototipnog modula, od kojih zadnja nije bila u potpunosti funkcionalna sve do kraja izrade ovog doktorskog rada. Ono što ju čini različitom od prijašnje dvije je uključenje TCXO oscilatora radi povećanja točnosti lokalnog izvora takta za DW1000 integrirani sklop. Cilj budućeg istraživanja je odrediti povećanje točnosti predloženog modela u slučaju povećanja stabilnosti sata DW1000 čipa koji se koristi prilikom mjerenja vremena propagacije UWB signala.

U zadnjem poglavlju prikazani su rezultati mjerenja cjelokupnog sustava, kao i prethodno

obavljena istraživanja kako bi se validirale pojedine metode. Objašnjena je metoda kompenzacije vremenske baze prilikom određivanja udaljenosti čiji su parametri bili eksperimentalno utvrđeni uz pomoć referentnog sustava temeljenog na robotskoj ruci. Validacija cjelokupnog sustava napravljena je u statičkim i dinamičkim uvjetima gdje se utvrdilo da je ponašanje sustava u granicama ostalih istraživanja. Dodatno, kako bi se iskoristile informacije iz IMU senzora, predložen je postupak senzorske fuzije temeljen na Kalmanovom filtru. Strojno učenje predstavlja skup tehnika i algoritama koji na temelju proučavanja statističkih zakonitosti u podacima mogu izgraditi model te pomoću njega donositi odluke i zaključke nad novo prikupljenim podatcima. Mjerenja na subjektima pokazala su da se uz predložene metode može značajno povećati točnost klasifikacije pojedinih gibanja.

Uz korištenje predloženog *algoritma za određivanje položaja i prepoznavanje pokreta ljudskog tijela primjenom fuzije senzorskih podataka i metoda strojnog učenja* pokazuje se da je moguće smanjiti standardnu devijaciju mjerenja udaljenosti uz pomoć UWB tehnologije. Ipak, ako se pobliže razmotre eksperimentalno dobivene vrijednosti stupnja Taylorovog reda i broja korištenih uzoraka može se primijetiti da predložena metoda nije pogodna za rad u stvarnom vremenu, već samo za naknadnu obradu podataka. Pretpostavka je da se navedeni problem može riješiti uz povećanje frekvencije RTOF mjerenja, ali to dovodi do drugog skupa problema, koji uključuje temperaturnu kompenzaciju samog DW1000 integriranog sklopa. Drugi način rješavanja problema je namjerni odabir manjeg broja korištenih mjerenja prilikom estimacije što bi naknadno povećalo standardnu devijaciju udaljenosti. Upravo iz tog razloga potrebno je napraviti ponovljena mjerenja na prototipnoj verziji koja uključuje temperaturno kompenzirani oscilator (TCXO) radi dobivanja stabilnijeg izvora vremena. Trenutna implementacija metode također podrazumijeva linerizirani model fuzije višestrukih izvora informacija, što možda i nije najbolji postupak senzorske fuzije za navedeni model. Naime, korištenjem prije linerizirani estimacija gubi se skrivena statistička informacija mjernog procesa koja može poslužiti kao dodatan izvor informacije prilikom implementacije Kalmanovog filtra. Kasnija istraživanja metode trebala bi se fokusirati na implementaciju senzorske fuzije koja uključuje potpuni opis modela u implementaciji Kalmanovog filtra (drugim riječima, implementaciju *tightly*, a ne *loosely* Kalmanovog filtra). Na kraju, iako je pokazano da navedena metoda poboljšava izlučivanje značajki signala prilikom različitih ljudskih pokreta, navedena metoda nije bila testirana na dovoljnom velikom ili raznolikom skupu osoba, kao niti validarana krajnjom implementacijom metoda strojnog učenja. Za navedeno potrebna su dodatna istraživanja i razmatranja kako bi se mogao unaprijediti eksperimentalni postav za validaciju različitih pokreta koji ne uključuju samo jednostavne kategorije pronađene u dosadašnjim istraživanjima.

Tijekom rada na ovoj doktorskoj disertaciji ispunili su se početno određeni znanstveni doprinosi, ali evidentno je da postoje brojne mogućnosti za nastavak istraživanja u područjima modeliranja, algoritama i implementacije sklopovske i programske arhitekture. Kako bi se

u potpunosti obranio pristup korištenja UWB tehnologije prilikom praćenja ljudskog pokreta, potrebna su dodatna istraživanja ne samo u implementaciji, nego i u postavu referentnih validacijskih modela i mjernih sustava (primjerice, temeljenih na preciznim optičkim sustavima) jer navedena tehnologija otvara primjene koje dosad nisu bile istražene. Dodatno, kako bi predloženi model bio koristan za praktične aplikacije, nužno je razmotriti implementaciju kako bi se uspješno mogla prilagoditi za izvođenje u stvarnom vremenu. Sve navedeno predstavlja daljni izazov znanstvenog istraživanja i budući rad u području koje je otvoreno ovim radom.

Literatura

[1] Xu, C., He, J., Zhang, X., Zhou, X., Duan, S., "Towards Human Motion Tracking: Multi-Sensory IMU/TOA Fusion Method and Fundamental Limits", Electronics, Vol. 8, No. 2, Jan. 2019, str. 142, dostupno na: http://www.mdpi.com/2079-9292/8/2/142

[2] Wong, C., Zhang, Z., Lo, B., Yang, G., "Wearable Sensing for Solid Biomechanics: A Review", IEEE Sensors Journal, Vol. 15, No. 5, May 2015, str. 2747–2760.

[3] Qi, Y., Soh, C. B., Gunawan, E., Low, K., Maskooki, A., "A Novel Approach to Joint Flexion/Extension Angles Measurement Based on Wearable UWB Radios", IEEE Journal of Biomedical and Health Informatics, Vol. 18, No. 1, Jan. 2014, str. 300–308.

[4] Lee, S. I., Daneault, J., Weydert, L., Bonato, P., "A novel flexible wearable sensor for estimating joint-angles", in 2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN), Jun. 2016, str. 377–382.

[5] Chen, X. M., Barma, S., Pun, S. H., Vai, M. I., Mak, P. U., "Direct Measurement of Elbow Joint Angle Using Galvanic Couple System", IEEE Transactions on Instrumentation and Measurement, Vol. 66, No. 4, Apr. 2017, str. 757–766, dostupno na: http://ieeexplore.ieee.org/document/7847304/

[6] Stupar, D. Z., Bajic, J. S., Manojlovic, L. M., Slankamenac, M. P., Joza, A. V., Zivanov, M. B., "Wearable Low-Cost System for Human Joint Movements Monitoring Based on Fiber-Optic Curvature Sensor", IEEE Sensors Journal, Vol. 12, No. 12, Dec. 2012, str. 3424–3431.

[7] Risset, T., Goursaud, C., Brun, X., Marquet, K., Meyer, F., "UWB Ranging for Rapid Movements", in 2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN), Sep. 2018, str. 1–8.

[8] Mekonnen, Z. W., Slottke, E., Luecken, H., Steiner, C., Wittneben, A., "Constrained maximum likelihood positioning for UWB based human motion tracking", in 2010 International Conference on Indoor Positioning and Indoor Navigation, Sep. 2010, str. 1–10.

[9] Standring, S., Gray's Anatomy: the Anatomical Basis of Clinical Practice. London: Elsevier Health Sciences UK, 2008, oCLC: 861539176, dostupno na: http://site.ebrary.com/id/10859982

[10] Faisal, A. I., Majumder, S., Mondal, T., Cowan, D., Naseh, S., Deen, M. J.,

"Monitoring Methods of Human Body Joints: State-of-the-Art and Research Challenges", Sensors, Vol. 19, No. 11, Jun. 2019, str. 2629, dostupno na: https://www.mdpi.com/1424-8220/19/11/2629

[11] Liu, H., Darabi, H., Banerjee, P., Liu, J., "Survey of Wireless Indoor Positioning Techniques and Systems", IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, Vol. 37, No. 6, Nov. 2007, str. 1067 –1080.

[12] Gu, Y., Lo, A., Niemegeers, I., "A survey of indoor positioning systems for wireless personal networks", IEEE Communications Surveys & Tutorials, Vol. 11, No. 1, 2009, str. 13–32, dostupno na: http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4796924

[13] Sahinoglu, Z., Gezici, S., Guvenc, I., Ultra-wideband Positioning Systems: Theoretical Limits, Ranging Algorithms, and Protocols. Cambridge: Cambridge University Press, 2008, dostupno na: http://ebooks.cambridge.org/ref/id/CBO9780511541056

[14] Guvenc, I., Gezici, S., Sahinoglu, Z., "Ultra-wideband range estimation: Theoretical limits and practical algorithms", in IEEE International Conference on Ultra-Wideband, 2008. ICUWB 2008, Vol. 3, Sep. 2008, str. 93 –96.

[15] Zekavat, S., Buehrer, R. M., "Handbook of Position Location", Wiley, 2019, str. 1376.

[16] Meissner, P., Leitinger, E., Witrisal, K., "UWB for Robust Indoor Tracking: Weighting of Multipath Components for Efficient Estimation", IEEE Wireless Communications Letters, Vol. 3, No. 5, Oct. 2014, str. 501–504.

[17] Mahfouz, M., Kuhn, M., Wang, Y., Turnmire, J., Fathy, A., "Towards sub-millimeter accuracy in UWB positioning for indoor medical environments", in 2011 IEEE Topical Conference on Biomedical Wireless Technologies, Networks, and Sensing Systems (BioWireleSS), Jan. 2011, str. 83 –86.

[18] Sharma, M., Parini, C., Alomainy, A., "Experimental investigation of 3D localisation of an on-body UWB antenna using several base stations", in Antennas and Propagation Conference (LAPC), 2014 Loughborough, Nov. 2014, str. 173–177.

[19] Park, P., Kim, S., Woo, S., Kim, C., "A Centimeter Resolution, 10 m Range CMOS Impulse Radio Radar for Human Motion Monitoring", IEEE Journal of Solid-State Circuits, Vol. 49, No. 5, May 2014, str. 1125–1134.

[20] Chang, S., Chu, T.-S., Roderick, J., Du, C., Mercer, T., Burdick, J., Hashemi, H., "UWB human detection radar system: A RF CMOS chip and algorithm integrated sensor", in 2011 IEEE International Conference on Ultra-Wideband (ICUWB), Sep. 2011, str. 355–359.

[21] Prakash, T., Ghosh, D., "Review of the ultra wideband pulse generation", in 2015 International Conference on Microwave, Optical and Communication Engineering (ICMOCE), Dec. 2015, str. 310–313.

[22] Yassin, A., Nasser, Y., Awad, M., Al-Dubai, A., Liu, R., Yuen, C., Raulefs, R., Aboutanios, E., "Recent Advances in Indoor Localization: A Survey on Theoretical Approaches and Applications", IEEE Communications Surveys Tutorials, Vol. 19, No. 2, 2017, str. 1327–1346.

[23] Zito, D., Morche, D., "UWB Radios—The maturity age?", in New Circuits and Systems Conference (NEWCAS), 2016 14th IEEE International. IEEE, 2016, str. 1–4, dostupno na: http://ieeexplore.ieee.org/abstract/document/7604843/

[24] Catherwood, P. A., Scanlon, W. G., "Ultrawideband Communications #x2014;An Idea Whose Time has Still Yet to Come? [Wireless Corner]", IEEE Antennas and Propagation Magazine, Vol. 57, No. 2, Apr. 2015, str. 38–43.

[25] "Ubisense", dostupno na: https://www.ubisense.net/node/1

[26] Jiménez, A. R., Seco, F., "Comparing Decawave and Bespoon UWB location systems: Indoor/outdoor performance analysis", in Indoor Positioning and Indoor Navigation (IPIN), 2016 International Conference on. IEEE, 2016, str. 1–8, dostupno na: http://ieeexplore.ieee.org/abstract/document/7743686/

[27] "Humatics", dostupno na: https://www.humatics.com/

[28] "BeSpoon", dostupno na: http://bespoon.com/

[29] Jimenez Ruiz, A. R., Seco Granja, F., "Comparing Ubisense, BeSpoon, and DecaWave UWB Location Systems: Indoor Performance Analysis", IEEE Transactions on Instrumentation and Measurement, Vol. 66, No. 8, Aug. 2017, str. 2106–2117, dostupno na: http://ieeexplore.ieee.org/document/7891540/

[30] "Decawave", dostupno na: https://www.decawave.com/

[31] "Blinksight", dostupno na: https://www.blinksight.com/

[32] Groves, P. D., "Navigation using inertial sensors [Tutorial]", IEEE Aerospace and Electronic Systems Magazine, Vol. 30, No. 2, Feb. 2015, str. 42–69, dostupno na: http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7081494

[33] Shaeffer, D., "MEMS inertial sensors: A tutorial overview", IEEE Communications Magazine, Vol. 51, No. 4, Apr. 2013, str. 100–109.

[34] Fraden, J., Handbook of modern sensors: physics, designs, and applications, 5th ed. Cham Heidelberg New York Dordrecht London: Springer, 2016, oCLC: 930757614.

[35] Woodman, O. J., "An introduction to inertial navigation", str. 37.

[36] Diebel, J., "Representing Attitude: Euler Angles, Unit Quaternions, and Rotation Vectors", str. 35.

[37] Hol, J., "Sensor fusion and calibration of inertial sensors, vision, ultra-wideband and GPS", Doktorski rad, Department of Electrical Engineering, Linköping University, Linköping, 2011, oCLC: 938872957.

[38] Diaz, E. M., de Ponte Muller, F., Jimenez, A. R., Zampella, F., "Evaluation of AHRS

algorithms for inertial personal localization in industrial environments", in 2015 IEEE International Conference on Industrial Technology (ICIT). Seville: IEEE, Mar. 2015, str. 3412–3417, dostupno na: http://ieeexplore.ieee.org/document/7125605/

[39] Mahony, R., Hamel, T., Pflimlin, J.-M., "Nonlinear Complementary Filters on the Special Orthogonal Group", IEEE Transactions on Automatic Control, Vol. 53, No. 5, Jun. 2008, str. 1203–1218, dostupno na: http://ieeexplore.ieee.org/document/4608934/

[40] Valenti, R., Dryanovski, I., Xiao, J., "Keeping a Good Attitude: A Quaternion-Based Orientation Filter for IMUs and MARGs", Sensors, Vol. 15, No. 8, Aug. 2015, str. 19 302–19 330, dostupno na: http://www.mdpi.com/1424-8220/15/8/19302

[41] Kok, M., Hol, J. D., Schön, T. B., "Using Inertial Sensors for Position and Orientation Estimation", Foundations and Trends® in Signal Processing, Vol. 11, No. 1-2, 2017, str. 1–153, arXiv: 1704.06053, dostupno na: http://arxiv.org/abs/1704.06053

[42] Fakhri, A., "A Comparative Analysis of Orientation Estimation Filters using MEMS based IMU", in 2nd International Conference on Research in Science, Engineering and Technology (ICRSET'2014), March 21-22, 2014 Dubai (UAE). International Institute of Engineers, Mar. 2014, dostupno na: http://iieng.org/siteadmin/upload/7697E0314552.pdf

[43] Madgwick, S. O. H., Harrison, A. J. L., Vaidyanathan, R., "Estimation of IMU and MARG orientation using a gradient descent algorithm", in 2011 IEEE International Conference on Rehabilitation Robotics. Zurich: IEEE, Jun. 2011, str. 1–7, dostupno na: http://ieeexplore.ieee.org/document/5975346/

[44] Mizell, D., "Using gravity to estimate accelerometer orientation", in Seventh IEEE International Symposium on Wearable Computers, 2003. Proceedings. White Plains, NY, USA: IEEE, 2003, str. 252–253, dostupno na: http://ieeexplore.ieee.org/document/1241424/

[45] Favre, J., Jolles, B. M., Aissaoui, R., Aminian, K., "Ambulatory measurement of 3D knee joint angle", Journal of Biomechanics, Vol. 41, No. 5, Jan. 2008, str. 1029–1035, dostupno na: http://www.sciencedirect.com/science/article/pii/S0021929007005350

[46] "Xsens", dostupno na: https://www.xsens.com/functions/3d-character-animation/

[47] Gietzelt, M., Wolf, K.-H., Marschollek, M., Haux, R., "Performance comparison of accelerometer calibration algorithms based on 3D-ellipsoid fitting methods", Computer Methods and Programs in Biomedicine, Vol. 111, No. 1, Jul. 2013, str. 62–71, dostupno na: https://linkinghub.elsevier.com/retrieve/pii/S0169260713000825

[48] Cirillo, A., Cirillo, P., Maria, G. D., Natale, C., Pirozzi, S., "A comparison of multisensor attitude estimation algorithms", str. 24.

[49] Pedley, M., "High-Precision Calibration of a Three-Axis Accelerometer", str. 35.

[50] Allan, D. W., "Time and Frequency (Time-Domain) Characterization, Estimation, and

Prediction of Precision Clocks and Oscillators", IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, Vol. 34, No. 6, Nov. 1987, str. 647–654.

[51] "Allan Variance: Noise Analysis for Gyroscopes", str. 9.

[52] Vagner, M., "MEMS GYROSCOPE PERFORMANCE COMPARISON USING ALLAN VARIANCE METHOD", str. 5.

[53] Seel, T., Raisch, J., Schauer, T., "IMU-Based Joint Angle Measurement for Gait Analysis", Sensors, Vol. 14, No. 4, Apr. 2014, str. 6891–6909, dostupno na: http://www.mdpi.com/1424-8220/14/4/6891

[54] Bakhshi, S., Mahoor, M. H., Davidson, B. S., "Development of a body joint angle measurement system using IMU sensors", in 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Aug. 2011, str. 6923–6926.

[55] Vargas-Valencia, L., Elias, A., Rocon, E., Bastos-Filho, T., Frizera, A., "An IMU-to-Body Alignment Method Applied to Human Gait Analysis", Sensors, Vol. 16, No. 12, Dec. 2016, str. 2090, dostupno na: http://www.mdpi.com/1424-8220/16/12/2090

[56] Castañeda, J. J., Ruiz-Olaya, A. F., Lara-Herrera, C. N., Roldán, F. Z., "Knee Joint Angle Monitoring System Based on Inertial Measurement Units for Human Gait Analysis", in VII Latin American Congress on Biomedical Engineering CLAIB 2016, Bucaramanga, Santander, Colombia, October 26th -28th, 2016, ser. IFMBE Proceedings, Torres, I., Bustamante, J., Sierra, D. A., (ur.). Springer Singapore, 2017, str. 690–693.

[57] Favre, J., Aissaoui, R., Jolles, B. M., de Guise, J. A., Aminian, K., "Functional calibration procedure for 3D knee joint angle description using inertial sensors", Journal of Biomechanics, Vol. 42, No. 14, Oct. 2009, str. 2330–2335, dostupno na: http://www.sciencedirect.com/science/article/pii/S0021929009003649

[58] Seel, T., Schauer, T., Raisch, J., "Joint axis and position estimation from inertial measurement data by exploiting kinematic constraints", in 2012 IEEE International Conference on Control Applications. Dubrovnik, Croatia: IEEE, Oct. 2012, str. 45–49, dostupno na: http://ieeexplore.ieee.org/document/6402423/

[59] Hidalgo, A. F., Lora-Millán, J. S., Rocon, E., "IMU-Based Knee Angle Estimation using an Extended Kalman Filter", in 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Jul. 2019, str. 570–573, iSSN: 1557-170X.

[60] Olsson, F., Halvorsen, K., "Experimental evaluation of joint position estimation using inertial sensors", in 2017 20th International Conference on Information Fusion (Fusion), Jul. 2017, str. 1–8, iSSN: null.

[61] Salehi, S., Bleser, G., Reiss, A., Stricker, D., "Body-IMU autocalibration for inertial hip and knee joint tracking", in Proceedings of the 10th EAI International

Conference on Body Area Networks. Sydney, Australia: ICST, 2015, dostupno na: http://eudl.eu/doi/10.4108/eai.28-9-2015.2261522

[62] Olsson, F., Seel, T., Lehmann, D., Halvorsen, K., "Joint axis estimation for fast and slow movements using weighted gyroscope and acceleration constraints", arXiv:1903.07353 [cs], Mar. 2019, arXiv: 1903.07353, dostupno na: http://arxiv.org/abs/1903.07353

[63] Bonnet, V., Joukov, V., Kulic, D., Fraisse, P., Ramdani, N., Venture, G., "Monitoring of Hip and Knee Joint Angles Using a Single Inertial Measurement Unit During Lower Limb Rehabilitation", IEEE Sensors Journal, Vol. 16, No. 6, Mar. 2016, str. 1557–1564, dostupno na: http://ieeexplore.ieee.org/document/7352303/

[64] Roetenberg, D., Schipper, L., Garofalo, P., Cutti, A., Luinge, H., "Joint Angles And Segment Length Estimation Using Inertial Sensors", 2010, str. 5.

[65] El-Gohary, M., Pearson, S., McNames, J., "Joint angle tracking with inertial sensors", in 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Aug. 2008, str. 1068–1071.

[66] Chiang, Y. Y., Hsu, W. H., Yeh, S. C., Li, Y. C., Wu, J. S., "Fuzzy support vector machines for device-free localization", in Instrumentation and Measurement Technology Conference (I2MTC), 2012 IEEE International, 2012, str. 2169–2172, dostupno na: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6229338

[67] Park, J., Cho, S. H., "IR-UWB Radar Sensor for Human Gesture Recognition by Using Machine Learning", in 2016 IEEE 18th International Conference on High Performance Computing and Communications; IEEE 14th International Conference on Smart City; IEEE 2nd International Conference on Data Science and Systems (HPCC/SmartCity/DSS), Dec. 2016, str. 1246–1249.

[68] Qi, Y., Soh, C. B., Gunawan, E., Low, K.-S., Maskooki, A., "Using wearable UWB radios to measure foot clearance during walking", in 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Jul. 2013, str. 5199–5202.

[69] Dai, X., Zhou, Z., Zhang, J., Davidson, B., "Ultra-wideband radar based human body landmark detection and tracking with biomedical constraints for human motion measuring", in 2014 48th Asilomar Conference on Signals, Systems and Computers, Nov. 2014, str. 1752–1756.

[70] Dai, X., Zhou, Z., Zhang, J. J., Davidson, B., "Ultra-wideband radar-based accurate motion measuring: human body landmark detection and tracking with biomechanical constraints", Sonar Navigation IET Radar, Vol. 9, No. 2, 2015, str. 154–163.

[71] Chang, S., Wolf, M., Burdick, J., "Human detection and tracking via Ultra-Wideband (UWB) radar", in 2010 IEEE International Conference on Robotics and Automation (ICRA), May 2010, str. 452–457.

[72] Bryan, J., Kim, Y., “Classification of human activities on UWB radar using a support vector machine”, in 2010 IEEE Antennas and Propagation Society International Symposium (APSURSI), Jul. 2010, str. 1–4.

[73] Bryan, J., Kwon, J., Lee, N., Kim, Y., “Application of ultra-wide band radar for classification of human activities”, IET Radar, Sonar Navigation, Vol. 6, No. 3, Mar. 2012, str. 172–179.

[74] Hu, J., Zhu, G., Jin, T., Zhou, Z., “Adaptive Through-Wall Indication of Human Target with Different Motions”, IEEE Geoscience and Remote Sensing Letters, Vol. 11, No. 5, May 2014, str. 911–915.

[75] Li, J., Zeng, Z., Sun, J., Liu, F., “Through-Wall Detection of Human Being’s Movement by UWB Radar”, IEEE Geoscience and Remote Sensing Letters, Vol. 9, No. 6, Nov. 2012, str. 1079–1083.

[76] Lu, Q., Liu, C., Zeng, Z., Li, J., Zhang, X., “Detection of human’s motions through a wall using UWB radar”, in 2016 16th International Conference on Ground Penetrating Radar (GPR), Jun. 2016, str. 1–4.

[77] Joshi, V., Knoefel, F., Goubran, R., El-Tanany, M., “Measurement of spontaneous body sway during quiet stand using UWB sensor”, in Biomedical & Health Informatics (BHI), 2017 IEEE EMBS International Conference on. IEEE, 2017, str. 281–284, dostupno na: http://ieeexplore.ieee.org/abstract/document/7897260/

[78] Novák, D., Kocur, D., Demčák, J., “Static person detection and localization with estimation of person’s breathing rate using single multistatic UWB radar”, in Applied Machine Intelligence and Informatics (SAMI), 2017 IEEE 15th International Symposium on. IEEE, 2017, str. 000 143–000 148, dostupno na: http://ieeexplore.ieee.org/abstract/document/7880291/

[79] Mokhtari, G., Zhang, Q., Hargrave, C. O., Ralsthon, J. C., “Non-wearable UWB Sensor for Human Identification in Smart Home”, IEEE Sensors Journal, 2017, str. 1–1, dostupno na: http://ieeexplore.ieee.org/document/7902163/

[80] Nakamura, R., Hadama, H., “Target localization using multi-static UWB sensor for indoor monitoring system”, in Wireless Sensors and Sensor Networks (WiSNet), 2017 IEEE Topical Conference on. IEEE, 2017, str. 37–40, dostupno na: http://ieeexplore.ieee.org/abstract/document/7878750/

[81] Bharadwaj, R., Parini, C., Alomainy, A., “Indoor tracking of human movements using UWB technology for motion capture”, in The 8th European Conference on Antennas and Propagation (EuCAP 2014), Apr. 2014, str. 2097–2099.

[82] Bharadwaj, R., Swaisaenyakorn, S., Parini, C. G., Batchelor, J., Alomainy, A., “Localization of Wearable Ultrawideband Antennas for Motion Capture Applications”, IEEE Antennas and Wireless Propagation Letters, Vol. 13, 2014, str. 507–510.

[83] Bharadwaj, R., Parini, C., Alomainy, A., "Ultrawideband-Based 3-D Localization Using Compact Base-Station Configurations", IEEE Antennas and Wireless Propagation Letters, Vol. 13, 2014, str. 221–224, dostupno na: http://ieeexplore.ieee.org/document/6717005/

[84] Bharadwaj, R., Parini, C., Alomainy, A., "Experimental Investigation of 3-D Human Body Localization Using Wearable Ultra-Wideband Antennas", IEEE Transactions on Antennas and Propagation, Vol. 63, No. 11, Nov. 2015, str. 5035–5044, dostupno na: http://ieeexplore.ieee.org/document/7265001/

[85] Kok, M., Hol, J. D., Schön, T. B., "Indoor Positioning Using Ultrawideband and Inertial Measurements", IEEE Transactions on Vehicular Technology, Vol. 64, No. 4, Apr. 2015, str. 1293–1303.

[86] Persson, A., Platform development of body area network for gait symmetry analysis using IMU and UWB technology, 2018, dostupno na: http://urn.kb.se/resolve?urn=urn:nbn:se:mdh:diva-39498

[87] Mekonnen, Z. W., Wittneben, A., "Localization via Taylor series approximation for UWB based human motion tracking", in Navigation and Communication 2011 8th Workshop on Positioning, Apr. 2011, str. 77–82.

[88] Zihajehzadeh, S., Yoon, P. K., Kang, B.-S., Park, E. J., "UWB-Aided Inertial Motion Capture for Lower Body 3-D Dynamic Activity and Trajectory Tracking", IEEE Transactions on Instrumentation and Measurement, Vol. 64, No. 12, Dec. 2015, str. 3577–3587, dostupno na: http://ieeexplore.ieee.org/document/7182775/

[89] Yoon, P. K., Zihajehzadeh, S., Kang, B.-S., Park, E. J., "Robust Biomechanical Model-Based 3-D Indoor Localization and Tracking Method Using UWB and IMU", IEEE Sensors Journal, Vol. 17, No. 4, Feb. 2017, str. 1084–1096, dostupno na: http://ieeexplore.ieee.org/document/7782717/

[90] Zihajehzadeh, S., Park, E. J., "A Novel Biomechanical Model-Aided IMU/UWB Fusion for Magnetometer-Free Lower Body Motion Capture", IEEE Transactions on Systems, Man, and Cybernetics: Systems, Vol. 47, No. 6, Jun. 2017, str. 927–938.

[91] Ashhar, K., Soh, C. B., Kong, K. H., "Wireless Ultrawideband Sensor Network for Gait Analysis in Rehabilitation Clinics", in 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Oct. 2018, str. 1524–1529.

[92] Zeng, Z., Liu, S., Wang, W., Wang, L., "Infrastructure-free indoor pedestrian tracking based on foot mounted UWB/IMU sensor fusion", in 2017 11th International Conference on Signal Processing and Communication Systems (ICSPCS), Dec. 2017, str. 1–7.

[93] Xu, C., He, J., Zhang, X., Yao, C., Tseng, P.-H., "Geometrical kinematic modeling on human motion using method of multi-sensor fusion", Information Fusion, Vol. 41,

May 2018, str. 243–254, dostupno na: https://linkinghub.elsevier.com/retrieve/pii/S1566253517300301

[94] Xu, C., He, J., Zhang, X., Duan, S., Yao, C., "3D Localization Performance Evaluation using IMU/TOA Fusion Methods", International Journal of Wireless Information Networks, Vol. 26, No. 2, Jun. 2019, str. 67–79, dostupno na: http://link.springer.com/10.1007/s10776-019-00426-x

[95] Ridolfi, M., Vandermeeren, S., Defraye, J., Steendam, H., Gerlo, J., De Clercq, D., Hoebeke, J., De Poorter, E., "Experimental Evaluation of UWB Indoor Positioning for Sport Postures", Sensors, Vol. 18, No. 2, Jan. 2018, str. 168, dostupno na: http://www.mdpi.com/1424-8220/18/1/168

[96] Ledergerber, A., D'Andrea, R., "Ultra-wideband range measurement model with Gaussian processes", in 2017 IEEE Conference on Control Technology and Applications (CCTA), Aug. 2017, str. 1929–1934.

[97] Kulmer, J., Hinteregger, S., Großwindhager, B., Rath, M., Bakr, M. S., Leitinger, E., Witrisal, K., "Using DecaWave UWB transceivers for high-accuracy multipath-assisted indoor positioning", in 2017 IEEE International Conference on Communications Workshops (ICC Workshops), May 2017, str. 1239–1245.

[98] Kulmer, J., Leitinger, E., Grebien, S., Witrisal, K., "Anchorless Cooperative Tracking Using Multipath Channel Information", IEEE Transactions on Wireless Communications, Vol. 17, No. 4, Apr. 2018, str. 2262–2275.

[99] Zeng, Z., Liu, S., Wang, L., "UWB/IMU integration approach with NLOS identification and mitigation", in 2018 52nd Annual Conference on Information Sciences and Systems (CISS), Mar. 2018, str. 1–6.

[100] Zeng, Z., Liu, S., Wang, L., "A novel NLOS mitigation approach for TDOA based on IMU measurements", in 2018 IEEE Wireless Communications and Networking Conference (WCNC), Apr. 2018, str. 1–6.

[101] Lian Sang, C., Adams, M., Hörmann, T., Hesse, M., Porrmann, M., Rückert, U., "Numerical and Experimental Evaluation of Error Estimation for Two-Way Ranging Methods", Sensors, Vol. 19, No. 3, Feb. 2019, str. 616, dostupno na: http://www.mdpi.com/1424-8220/19/3/616

[102] Freris, N. M., Graham, S. R., Kumar, P. R., "Fundamental Limits on Synchronizing Clocks Over Networks", IEEE Transactions on Automatic Control, Vol. 56, No. 6, Jun. 2011, str. 1352–1364.

[103] Xie, Y., Janssen, G. J. M., Veen, A. v. d., "A practical clock synchronization algorithm for UWB positioning systems", in 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Mar. 2016, str. 3891–3895.

[104] Tomic, S., Beko, M., "Exact Robust Solution to TW-ToA-Based Target Localization

Problem With Clock Imperfections", IEEE Signal Processing Letters, Vol. 25, No. 4, Apr. 2018, str. 531–535.

[105] Sidorenkoab, J., Schatza, V., Scherer-Negenborna, N., Arensa, M., Hugentobler, U., "Decawave UWB clock drift correction and powerself-calibration", arXiv:1902.11085 [eess], Feb. 2019, arXiv: 1902.11085, dostupno na: http://arxiv.org/abs/1902.11085

[106] Rajan, R. T., Veen, A. v. d., "Joint Ranging and Synchronization for an Anchorless Network of Mobile Nodes", IEEE Transactions on Signal Processing, Vol. 63, No. 8, Apr. 2015, str. 1925–1940.

[107] Pennington, A., Myers, J. V., "(74) Attorney, Agent, or Firm — Hunt Pennington Kumar", str. 24.

[108] Stanić, M., "Komunikacijski čvor za UWB lokalizaciju temeljen na integriranom sklopu DW1000", Master's thesis, University of Zagreb. Faculty of Electrical Engineering and Computing., Sep. 2018, dostupno na: https://urn.nsk.hr/urn:nbn:hr:168:496458

[109] Hölbling, Z., "Određivanje relativnog položaja objekta UWB senzorom", Master's thesis, University of Zagreb. Faculty of Electrical Engineering and Computing., Jul. 2015, dostupno na: https://urn.nsk.hr/urn:nbn:hr:168:167656

[110] Ovčarik, M., "Analiza utjecaja Wi-Fi i BLE komunikacije na performanse ultraširokopojasne lokalizacije", Master's thesis, University of Zagreb. Faculty of Electrical Engineering and Computing., Jul. 2018, dostupno na: https://urn.nsk.hr/urn:nbn:hr:168:453440

[111] Kat, C.-J., Els, P. S., "Validation metric based on relative error", str. 32.

[112] Wang, J., Chen, Y., Hao, S., Peng, X., Hu, L., "Deep Learning for Sensor-based Activity Recognition: A Survey", Pattern Recognition Letters, Vol. 119, Mar. 2019, str. 3–11, arXiv: 1707.03502, dostupno na: http://arxiv.org/abs/1707.03502

[113] Lopez-Nava, I. H., Muñoz-Meléndez, A., "Human action recognition based on low- and high-level data from wearable inertial sensors", International Journal of Distributed Sensor Networks, Vol. 15, No. 12, Dec. 2019, str. 155014771989453, dostupno na: http://journals.sagepub.com/doi/10.1177/1550147719894532

[114] Tong, C., Tailor, S. A., Lane, N. D., "Are Accelerometers for Activity Recognition a Dead-end?", in Proceedings of the 21st International Workshop on Mobile Computing Systems and Applications. Austin TX USA: ACM, Mar. 2020, str. 39–44, dostupno na: https://dl.acm.org/doi/10.1145/3376897.3377867

[115] Elhoushi, M., Georgy, J., Noureldin, A., Korenberg, M. J., "A Survey on Approaches of Motion Mode Recognition Using Sensors", IEEE Trans. Intell. Transport. Syst., Vol. 18, No. 7, Jul. 2017, str. 1662–1686, dostupno na: http://ieeexplore.ieee.org/document/7726001/

[116] Hassan, M. M., Uddin, M. Z., Mohamed, A., Almogren, A., "A robust human

activity recognition system using smartphone sensors and deep learning", Future Generation Computer Systems, Vol. 81, Apr. 2018, str. 307–313, dostupno na: http://www.sciencedirect.com/science/article/pii/S0167739X17317351

[117] Ronao, C. A., Cho, S.-B., "Human activity recognition with smartphone sensors using deep learning neural networks", Expert Systems with Applications, Vol. 59, Oct. 2016, str. 235–244, dostupno na: http://www.sciencedirect.com/science/article/pii/S0957417416302056

[118] Ignatov, A., "Real-time human activity recognition from accelerometer data using Convolutional Neural Networks", Applied Soft Computing, Vol. 62, Jan. 2018, str. 915–922, dostupno na: http://www.sciencedirect.com/science/article/pii/S1568494617305665

[119] Twomey, N., Diethe, T., Fafoutis, X., Elsts, A., McConville, R., Flach, P., Craddock, I., "A Comprehensive Study of Activity Recognition Using Accelerometers", Informatics, Vol. 5, No. 2, May 2018, str. 27, dostupno na: http://www.mdpi.com/2227-9709/5/2/27

[120] Jain, A., Kanhangad, V., "Human Activity Classification in Smartphones Using Accelerometer and Gyroscope Sensors", IEEE Sensors J., Vol. 18, No. 3, Feb. 2018, str. 1169–1177, dostupno na: http://ieeexplore.ieee.org/document/8186158/

Kazalo pojmova

AOA	angle of arrival
AS-TWR	alternative double-sided TWR
ASDS-TWR	asymmetric double-sided TWR
AWGN	Additive White Gaussian Noise
BS	base station
CDF	cumulative distribution function
CIR	channel impulse response
CRLB	Cramer-Rao lower bound
DCM	direction cosine matrix
DOF	deegres of freedom
ECC	Electronic Communications Committee
EIRP	equivalent isotropically radiated power
EKF	extended Kalman filter
EMC	electromagnetic compatibility
FCC	Federal Communications Commission
FIM	Fischer information matrix
FPU	floating point unit

FSM	finite state machine
GNSS	global navigation satellite system
GPS	global positioning system
HMT	human motion tracking
IEKF	iterative extended Kalman filter
IFI	inter-frame interference
IMU	inertial measurement unit
INS	inertial navigation system
IR-UWB	UWB impulse radio
LOS	line of sight
LPS	local positioning systems
LSS	least square solution
MAI	multiple-access interference
MB-UWB	multi-band UWB
MBOFDM	multi-band orthogonal frequency division multiplexing
MEMS	microelectromechanical systems
ML	maximum likelihood
MPC	multi-path components
MPCM	multiposition calibration method
MS	mobile station
NLOS	non-line of sight
OFDM	orthogonal frequency division multiplexing

PDP	power delay profile
PL	path loss
PRF	pulse repetition frequency
PSD	power spectral density
ROM	range of motions
RSS	received signal strength
RTLS	real-time locating systems
RTOF	roundtrip time of flight
SDS-TWR	symmetric double-sided TWR
SS-TWR	single-sided two way ranging
SVM	support vector machine
TDC	time-to-digital converter
TDOA	time difference of arrival
TH	time-hopping
TOA	time of arrival
TOF	time of flight
TWR	two way ranging
UWB	ultra-wideband
WPAN	wireless personal area networks

Popis slika

1.1. Pokretni (sinovijalni) zglobovi: (a) presjek pokretnog zgloba, (b) tipovi pokretnih zglobova.* 5

2.1. Pozicioniranje temeljeno na TOA i RTOF metodama 17
2.2. Pozicioniranje temeljeno na TDOA metodi 19
2.3. Vremenski tijek komunikacije kod RTOF mjerenja (satovi na MS i BS su sinkronizirani) 20
2.4. Vremenski tijek komunikacije kod RTOF mjerenja (satovi na MS i BS nisu sinkronizirani) 21
2.5. Pozicioniranje temeljeno na AOA metodi 24
2.6. Gustoća spektra snage PSD UWB signala i definicija frekvencija f_L, f_H i f_c . . 28
2.7. Prikaz IR-UWB signala u vremenskoj domeni 28
2.8. Oblik UWB impulsa temeljen na drugoj derivaciji Gaussove funkcije 29
2.9. Primjeri jednostavnih scenarija nastanka višestaznih komponenti kod LOS i NLOS uvjeta: (a) izravna veza između odašiljača i prijemnika (LOS), (b) izravna veza između odašiljača i prijemnika (LOS), ali na prijemniku postoji atenuacija izravne komponente signala zbog nepovoljne orijentacije antene, (c) izravna komponenta signala prigušena je preprekom (NLOS), (d) izravna komponenta signala prigušena je i zakašnjela djelovanjem prepreka (NLOS) 33
2.10. Primjer nastanka višestaznog rasprostiranja signala u uvjetima višestrukih refleksija i raspršenja: (a) direktna i spekularne reflektivne MPC komponente, (b) primjer jedne MPC komponente nastale raspršenjem, (c) prikaz svih MPC komponenti signala na RX 34
2.11. Vremenska ovisnost $P(\tau)$ za Saleh-Valenzuela model UWB komunikacijskog kanala 37
2.12. Prikaz problema određivanja TOA kod UWB kanala s efektima višestaznog rasprostiranja signala 41
2.13. FCC spektralna maska za UWB komunikaciju u zatvorenom prostoru 43
2.14. FCC spektralna maska za UWB komunikaciju na otvorenom prostoru 44

2.15. ECC spektralna maska za UWB uređaje bez implementiranih mjera za izbjegavanje interferencije . . . 45
2.16. ECC spektralna maska za UWB uređaje s implementiranim mjerama za izbjegavanje interferencije . . . 46
2.17. Načelo rada akcelerometra . . . 52
2.18. Kanonski prikaz IMU senzora kao elektromehaničkog sustava (a) shematski prikaz, (b) ekvivalentni dinamički model sustava drugog reda i (c) frekvencijska karakteristika. . . . 54
2.19. Načelne izvedbe kapacitivnih akcelerometara: (a) izvedba s paralelnim elektrodama, (b) češljasta izvedba. . . . 56
2.20. Opisivanje gibanja objekta po proizvoljnoj zakrivljenoj putanji po odsječcima kružnim gibanjem . . . 57
2.21. Načelni blok dijagrami za navigacijske algoritme za (a) IMU jedinice sa stabiliziranom platformom, (b) IMU jedinice bez stabilizirane platforme. . . . 60
2.22. Prikaz integracijske pogreške za (a) troosni žiroskop, (b) troosni akcelerometar LMS9DS0. . . . 61
2.23. Ilustracija vremenske ovisnosti pogreške uslijed jedne integracije bijelog šuma promatrano na 100 realizacija slučajnog procesa opisanog Gaussovom distribucijom $\mathcal{N}(0,1)$ (crveno je označena jedna od realizacija slučajnog procesa) . . . 63
2.24. Definicija kuteva valjanja (*roll*), propinjanja (*pitch*) i skretanja (*yaw*) . . . 66
2.25. Prikaz Allanove devijacije za žiroskopska mjerenja IMU uređaja LSM9DS0 . . 81
2.26. Prikaz Allanove devijacije za akcelerometarska mjerenja IMU uređaja LSM9DS0 82

3.1. Određivanje kuta zgloba korištenjem pristupa mjerenja udaljenosti . . . 89
3.2. Simbolički prikaz tijeka komunikacije prilikom RTOF mjerenja u slučaju nesavršenosti oscilatora . . . 90
3.3. Određivanje kuta zgloba korištenjem IMU senzora . . . 93

4.1. Prva inačica implementacije bežičnog senzorskog čvora . . . 102
4.2. Druga inačica implementacije bežičnog senzorskog čvora . . . 103
4.3. Treća inačica implementacije bežičnog senzorskog čvora . . . 105
4.4. Moduli i vanjske biblioteke korištene za implementaciju programske potpore senzorskog čvora . . . 107
4.5. Zadaci implementirani u okviru aplikacijskog sloja programske potpore . . . 108
4.6. Inicijalizacijski dio programske potpore . . . 109
4.7. Inicijalizacija DW1000 primopredajnika . . . 110
4.8. Dijagram tijeka izvođenja zadataka *vTaskOverlord* . . . 112
4.9. Dijagram tijeka izvođenja zadataka *vTaskPong* . . . 113

4.10. Dijagram tijeka izvođenja zadataka *vTaskRangeWithAllNodes* 114
4.11. Ispitni postav UWB bežičnih čvorova u EMC laboratoriju [110] 118
4.12. Ispitni postav UWB bežičnog čvora u EMC laboratoriju s Wi-Fi izvorom smetnji [110] 119
4.13. CIR bez utjecaja smetnji (izmjereno u EMC komori) 122
4.14. Histogram izmjerenih udaljenosti (bez utjecaja smetnji, izmjereno u EMC komori) 122
4.15. CIR uz Bluetooth komunikaciju (izmjereno u EMC komori) 123
4.16. Histogram izmjerenih udaljenosti (uz Bluetooth komunikaciju, izmjereno u EMC komori) 123
4.17. CIR uz IEEE 802.11b komunikaciju (izmjereno u EMC komori) 124
4.18. Histogram izmjerenih udaljenosti (uz IEEE 802.11b komunikaciju, izmjereno u EMC komori) 124
4.19. CIR uz IEEE 802.11a komunikaciju (izmjereno u EMC komori) 125
4.20. Histogram izmjerenih udaljenosti (uz IEEE 802.11a komunikaciju, izmjereno u EMC komori) 125
4.21. CIR bez generiranih smetnji (izmjereno u prostoriji na fakultetu) 127
4.22. CIR uz uključenu Bluetooth komunikaciju (izmjereno u prostoriji na fakultetu) 127
4.23. CIR uz uključenu IEEE 802.11b komunikaciju (izmjereno u prostoriji na fakultetu) 130
4.24. CIR uz uključenu IEEE 802.11a komunikaciju (izmjereno u prostoriji na fakultetu) 130

5.1. Mjerni postav temeljen na JACO robotskoj ruci i DW1000 prototipnim modulima 136
5.2. Usporedba mjerenja udaljenosti u statičnim uvjetima 138
5.3. Prikaz pogreške i estimiranog gibanja za brzinu od 10°/s 139
5.4. Prikaz pogreške i estimiranog gibanja za brzinu od 30°/s 140
5.5. Prikaz pogreške i estimiranog gibanja za brzinu od 60°/s 141
5.6. Prikaz određivanja kuta uz pomoć žiroskopskih mjerenja na JACO robotskoj ruci 143
5.7. IMU mjerenja prilikom ispisivanja slova u zraku 148
5.8. Histogram IMU mjerenja prilikom ispisivanja slova u zraku 149
5.9. Estimacija kuta lakta prilikom ispisivanja slova u zraku 149
5.10. Histogram estimacije kuta lakta prilikom ispisivanja slova u zraku 150

Popis tablica

1.1. Tipovi pokretnih (sinovijalnih) zglobova 6

2.1. Standardizirani modeli komunikacijskih kanala u IEEE 802.15.4a standardu . . 46

4.1. UWB kanali koje podržava DW1000 primopredajnik 101
4.2. Umjeravanje prototipnog sustava [109] 115
4.3. Validacijska mjerenja prve verzije prototipa za mjerenje udaljenosti UWB metodom promatrano u tri različite pozicije MS [109] 116
4.4. Referentna mjerenja - EMC laboratorij (bez smetnji) 120
4.5. Referentna mjerenja - EMC laboratorij (Bluetooth komunikacija) 121
4.6. Referentna mjerenja - EMC laboratorij (IEEE 802.11b komunikacija) 121
4.7. Referentna mjerenja - EMC laboratorij (IEEE 802.11a komunikacija) 122
4.8. Mjerenje u okolini s višestaznom propagacijom signala (prostorija na fakultetu, bez generiranih smetnji) 126
4.9. Mjerenje u okolini s višestaznom propagacijom signala (prostorija na fakultetu, uz uključenu IEEE 802.11b komunikaciju) 129
4.10. Mjerenje u okolini s višestaznom propagacijom signala (prostorija na fakultetu, uz uključenu IEEE 802.11a komunikaciju) 129

Životopis

HRVOJE MIHALDINEC je rođen 1987 u Zagrebu dok je zvanje diplomiranog inženjera elektrotehnike stekao 2010. godine na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu.

Nakon završetka studija 2011. godine zapošljava se u tvrtki Abit d.o.o. gdje radi kao vanjski suradnik na međunarodnom projektu tvrtke Nokia Siemens Networks. Projekt je uključivao istraživanje, razvoj i projektiranje novih generacija baznih stanica baziranih na Linux operacijskom sustavu. Od 2014. godine radi u tvrtki Tieto d.o.o. na istom projektu koji od tada uključivao i rad na CRTM i U-Boot podršci za navedene platforme.

Na FER-u se zapošljava se 2014. godine kao zavodski suradnik na Zavodu za elektroničke sustave i obradbu informacija u sklopu ICTGEN (Information and communication technology for generic and energy-efficient communication solutions with application in e-/m-health) projekta gdje radi na istraživanju primjene bežičnih senzorskih mreža za praćenje parametara okoline. Nakon kraja ICTGEN projekta, radio je na istraživačko-razvojnom projektu SafeTram (System for increased driving safety in public urban rail traffic) na razvoju sustava baziranim na Linux operacijskog sustavu s ciljem povećanja sigurnosti u prometu. U sklopu doktorskog rada sudjelovao je na SafeLOG (Safe human-robot interaction in logistic applications for highly flexible warehouses) projektu s ciljem razvoja sustava baziranim na ultraširokopojasnoj tehnologiji za sigurnu interakciju ljudi u blizini automatiziranih robotskih platformi.

Popis objavljenih djela

Rad u časopisima

1. Mihaldinec H. i Dzapo H., „Method for joint flexion angle estimation using UWB ranging with clock model compensation“, Automatika, sv. 61, izd. 1, str. 132–140, sij. 2020, doi: 10.1080/00051144.2019.1690290.
2. Čuljak, I., Mihaldinec, H., Kovačić, Z., Cifrek, M., Džapo, H., “UWB Platform for Vital Signs Detection and Monitoring”, World Congress on Medical Physics and Biomedical Engineering 2018, ser. IFMBE Proceedings, Lhotska, L., Sukupova, L., Lacković, I., Ibbott, G. S., (ur.). Springer Singapore, 2019, str. 33–37.

3. Hölbling, Z., Mihaldinec, H., Ambruš, D., Džapo, H., Bilas, V.,Vasić, D., “UWB localization for discrimination-enabled metal detectors in humanitarian demining”, 2017 IEEE Sensors Applications Symposium (SAS), Ožujak 2017, str. 1–4.
4. Tepić, S., Pejić, P., Domšić, J., Mihaldinec, H., Džapo, H., “IBMS - Intelligent Building Management System Framework”, 2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), Svibanj 2015, str. 143–148.

Biography

HRVOJE MIHALDINEC was born in Zagreb, Croatia in 1987 while he received his degree of M.Sc. in Electrical Engineering at University of Zagreb, Faculty of Electrical Engineering and Computing (FER), Zagreb, Croatia in 2010.

After end of his studies in 2011 he was with Abit d.o.o. where he worked as consultant in Nokia Siemens Networks on an international project. Project included research, development and design of new generation base stations based on Linux operating system. Since 2014 he continued working on the same project in Tieto d.o.o. which included additional development on CRTM and U-Boot support on before mentioned platforms.

In 2014 he joined FER as a Research Associate at Department of Electronic Systems and Information Processing working on ICTGEN (Information and communication technology for generic and energy-efficient communication solutions with application in e-/m-health) with research goal of wireless sensor networks application for tracking environmental parameters. After end of ICTGEN project, he worked on SafeTram (System for increased driving safety in public urban rail traffic) project on Linux based systems with goal of increasing safety in traffic. While working on his PhD thesis, he was involved in SafeLOG (Safe human-robot interaction in logistic applications for highly flexible warehouses) project where goal was to increase safety in human to machine interaction with ultra-wideband technology.