

# Utjecaj individualnih prijenosnih funkcija glave na kvalitetu binauralne sinteze uz praćenje položaja glave

---

Planinec, Vedran

Doctoral thesis / Disertacija

2024

*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:168:627770>

*Rights / Prava:* [In copyright](#) / [Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2025-03-26**



*Repository / Repozitorij:*

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repository](#)





Sveučilište u Zagrebu  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Vedran Planinec

**UTJECAJ INDIVIDUALNIH PRIJENOSNIH  
FUNKCIJA GLAVE NA KVALITETU BINAURALNE  
SINTEZE UZ PRAĆENJE POLOŽAJA GLAVE**

DOKTORSKI RAD

Zagreb, 2024.





Sveučilište u Zagrebu  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Vedran Planinec

**UTJECAJ INDIVIDUALNIH PRIJENOSNIH  
FUNKCIJA GLAVE NA KVALITETU BINAURALNE  
SINTEZE UZ PRAĆENJE POLOŽAJA GLAVE**

DOKTORSKI RAD

Mentor: Prof. dr. sc. Kristian Jambrošić

Zagreb, 2024.



University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Vedran Planinec

**THE INFLUENCE OF INDIVIDUAL HEAD-RELATED  
TRANSFER FUNCTIONS ON THE QUALITY OF  
BINAURAL SYNTHESIS WITH HEAD TRACKING**

DOCTORAL THESIS

Supervisor: Professor Kristian Jambrošić, PhD

Zagreb, 2024

Doktorski rad izrađen je na Sveučilištu u Zagrebu, na Fakultetu elektrotehnike i računarstva, na Zavodu za elektroakustiku.

Mentor: prof. dr. sc. Kristian Jambrošić

Doktorski rad ima: 114 stranica

Doktorski rad br.: \_\_\_\_\_

## O mentoru

Kristian Jambrošić je redoviti profesor u trajnom izboru i voditelj Auralizacijskog laboratorija na Zavodu za elektroakustiku Sveučilišta u Zagrebu Fakulteta elektrotehnike i računarstva (FER). Diplomirao je 1996., magistrirao 2000. te doktorirao 2004. godine na FER-u u polju elektrotehnike. Od 1997. zaposlen je na Zavodu za elektroakustiku FER-a, najprije kao doktorand i istraživač, a od 2006. u znanstveno-nastavnim zvanjima.

Od početka rada na Zavodu za elektroakustiku intenzivno je uključen u nastavne aktivnosti, najprije kao asistent, a potom kao nastavnik. Predaje cijeli niz predmeta na prijediplomskom, diplomskom i doktorskom studiju po FER1, FER2 i FER3 programu. Bio je mentorom na više od 100 završnih i diplomskih radova, te na tri doktorske disertacije. Sudjeluje u uvođenju nastavnog modula „Tonski majstor“ s tri kolegija na Muzičkoj akademiji Sveučilišta u Zagrebu te studijskog programa „Glazba i mediji“ s četiri kolegija na Sveučilištu Sjever. Suautor je sveučilišnog udžbenika „Prijenos zvuka“.

Aktivno se bavi znanstveno-istraživačkim radom, te je kao rezultat svog rada kao autor ili suautor objavio više od 30 znanstvenih radova u znanstvenim časopisima te više od 150 radova u zbornicima međunarodnih znanstvenih konferencija. Glavna područja istraživanja su mu prostorna akustika, auralizacija, audiotehnologije i VR sustavi, zvučni okoliši, percepcija zvuka i zaštita od buke.

Kao glavni istraživač, vodio je istraživački projekt Ministarstva znanosti i obrazovanja, projekt Provjere inovativnog koncepta HAMAG-BICRO, te dva projekta Hrvatske zaklade za znanost, a kao istraživač sudjeluje na većem broju domaćih projekata te na međunarodnim istraživačkim projektima iz grupe COST, bilateralni hrvatsko-kineski projekti, Erasmus+, te H2020.

Aktivno je sudjelovao u organizaciji 40 međunarodnih znanstvenih konferencija kao član organizacijskog, programskog ili znanstvenog odbora, te je bio urednikom osam zbornika radova s međunarodnih konferencija. Također je sudjelovao u izradi više od 200 stručnih projekata, elaborata, ekspertiza i mjernih izvješća iz područja svog istraživanja.

U dva mandata (2007.-2013.) sudjeluje u radu odbora Europske Akustičke Asocijacije (EAA) kao glavni tajnik, a od 2013. do 2023. sudjeluje u izvršnom odboru EAA kao urednik mjesečnika Nuntius. Od 2021. postaje član upravnog odbora strukovne udruge International Institute of Noise Control Engineering (I-INCE), a od 2022. preuzima dužnost glavnog tajnika. Član je nekoliko profesionalnih organizacija i udruženja: Audio Engineering Society, Acoustical Society of America, Hrvatsko ergonomsko društvo te Hrvatsko akustičko društvo u kojemu je od 1998. do 2015. obnašao dužnost blagajnika, od 2015. do 2019. predsjednika, a od 2019. tajnika. Obnaša dužnost predstojnika Zavoda za elektroakustiku u mandatu 2018./2019. – 2020./2021. te 2024./2025. – 2026./2027.

---

## About the Supervisor

Kristian Jambrošić is a full professor and the head of the Auralization Laboratory at the Department of Electroacoustics, University of Zagreb Faculty of Electrical Engineering and Computing (FER). He graduated in 1996, earned his master's degree in 2000, and completed his PhD in 2004 at FER in the field of electrical engineering. He has been employed at the Department of Electroacoustics, FER since 1997, initially as a doctoral candidate and researcher, and since 2006 in teaching positions.

Since starting at the Department of Electroacoustics, he has been intensively involved in teaching activities, first as an assistant and later as a lecturer. He teaches a wide range of courses at the undergraduate, graduate, and doctoral levels under the FER1, FER2, and FER3 programs. He has supervised over 100 bachelor's and master's theses, as well as three doctoral dissertations. He has contributed to the introduction of the "Sound Engineer" teaching module with three courses at the Academy of Music, University of Zagreb, and the study program "Music and Media" with four courses at the University North. He is a co-author of the university textbook "Sound Transmission."

He is actively engaged in scientific research and, as a result, has published over 30 scientific papers in journals and more than 150 papers in the proceedings of international scientific conferences as an author or co-author. His main research areas include spatial acoustics, auralization, audio technologies and VR systems, sound environments, sound perception, and noise protection.

As the principal investigator, he has led a research project for the Ministry of Science and Education, a Proof-of-Concept project for HAMAG-BICRO, and two projects for the Croatian Science Foundation. He also participates as a researcher in several domestic projects and international research projects from the COST group, bilateral Croatian-Chinese projects, Erasmus+, and H2020.

He has actively participated in the organization of 40 international scientific conferences as a member of the organizing, program, or scientific committee and has edited eight proceedings from international conferences. Additionally, he has contributed to over 200 professional projects, reports, expert opinions, and measurement reports in his field of research.

During two terms (2007-2013), he served on the board of the European Acoustics Association (EAA) as the General Secretary, and from 2013 to 2023, he was on the EAA executive board as the editor of the monthly newsletter Nuntius. Since 2021, he has been a member of the board of the International Institute of Noise Control Engineering (I-INCE), and since 2022, he has taken on the role of Secretary General. He is a member of several professional organizations and associations: Audio Engineering Society, Acoustical Society of America, Croatian Ergonomics Society, and Croatian Acoustical Society, where he served as Treasurer from 1998

---

to 2015, President from 2015 to 2019, and Secretary since 2019. He held the position of Head of the Department of Electroacoustics for the terms 2018/2019 – 2020/2021 and 2024/2025 – 2026/2027.

*Na samom početku, želim iskreno zahvaliti svojoj obitelji i prijateljima, koji su mi bili neizostavna podrška kroz cijelo moje obrazovanje.*

*Posebnu zahvalu dugujem svom mentoru, profesoru Kristianu Jambrošiću, čije je mentorstvo bilo ne samo stručno, već i nadahnjujuće. Njegovo vodstvo kroz ovaj doktorat bilo je izuzetno, i teško bih mogao zamisliti boljeg mentora.*

*Također, zahvaljujem svim zaposlenicima Zavoda za elektroakustiku, a posebno profesoru Marku Horvatu, uz čiju sam pomoć stekao vrijedna znanja i s lakoćom savladao izazove na putu do završetka ovog rada.*

*Zahvaljujem i svim kolegama s Fakulteta elektrotehnike i računarstva koji su mi nesebično pružali podršku kada je bilo najpotrebnije.*

*Na kraju, najveću zahvalu upućujem svojoj zaručnici Ivani, koja je bila moj najvažniji oslonac i neiscrpni izvor motivacije, te je bila uz mene kroz svaki izazov i svaki uspjeh.*

## Sažetak

Korištenje audio sustava koji koriste binauralnu sintezu s praćenjem položaja glave postalo je sve popularnije na današnjem tržištu, osobito u sustavima virtualne stvarnosti. Proces binauralne sinteze koristi prijenosne funkcije glave (HRTF, engl. Head-Related Transfer Functions) kao ulazni podatak potreban za vjerni doživljaj zvučnih izvora iz svih mogućih smjerova dolaska u virtualnim okruženjima. Kako bi se ovaj postupak prilagodio svim potencijalnim slušateljima, često se koriste generički HRTF skupovi.

Istraživanja kvalitete lokalizacije virtualnih zvučnih izvora često variraju u metodama i zaključcima, posebno u vezi poboljšanja rezultata korištenjem vlastitih individualnih HRTF skupova. Zbog kompleksnosti mjerenja individualnih HRTF skupova, prethodna istraživanja često uključuju mali broj ispitanika. Ova disertacija istražuje cijeli sustav binauralne sinteze, počevši s uređajima za praćenje položaja glave. Statička mjerenja uključuju pohranu podataka s nepomičnih uređaja nekoliko sati za analizu senzorskih odstupanja, dok dinamička mjerenja koriste motorizirane platforme i njihalo za preciznija mjerenja uređaja u pokretu. Preliminarno ispitivanje kvalitete binauralne sinteze bez individualnih HRTF skupova ispituje promjene ostalih parametara binauralnog sustava, dok glavno ispitivanje uključuje mjerenje individualnih HRTF skupova metodom *Earfish* u gluhoj komori, te ispitivanje točnosti lokalizacije i subjektivnog vrednovanja prirodности i eksternalizacije virtualnih zvučnih izvora.

Koristeći nove metode, istraživanja u doktorskoj disertaciji pokazat će da korištenje individualnih HRTF skupova povećava ukupnu točnost lokalizacije, te poboljšava percepciju prirodности i eksternalizacije zvučnog polja dobivenog binauralnom sintezom, što rezultira zvučnim doživljajem najbližim slušanju stvarnih zvučnih izvora.

**Ključne riječi:** binauralna sinteza, praćenje položaja glave, HRTF funkcija, IMU senzor, virtualni zvučni izvor, 3D audio sustav, virtualna i proširena stvarnost



# **The influence of individual head-related transfer functions on the quality of binaural synthesis with head tracking**

## **Introduction**

The field of audio reproduction has been dominated by stereo sound for decades. Despite advancements in multichannel audio systems, stereo remains the standard for most users due to its simplicity, affordability, and compatibility with various devices. However, the demand for more immersive audio experiences has been growing, particularly with the rise of virtual reality (VR) and augmented reality (AR) technologies. This demand has given rise to the potential for binaural audio systems, which can create three-dimensional audio experiences that go beyond the capabilities of stereo.

Binaural audio systems aim to replicate the natural hearing experience by simulating the way sound interacts with the head, ears, and torso before reaching the inner ear. This is achieved through Head-Related Transfer Functions (HRTFs), which describe how sound is filtered based on the listener's anatomy. Combined with head-tracking technologies, binaural synthesis enables a dynamic and immersive sound field that adjusts as the listener moves their head, offering a compelling alternative to traditional stereo.

## **Research Focus and Motivation**

The main focus of this doctoral dissertation is to investigate the impact of using individualized HRTFs on the quality of binaural audio synthesis in virtual environments where head tracking is employed. While generic HRTFs are widely used due to their ease of application, they may not provide the same level of spatial accuracy and realism as individualized HRTFs, which are tailored to the unique anatomical features of each listener. This research seeks to determine the conditions under which individualized HRTFs significantly improve the accuracy of sound localization, the sense of externalization, and the overall naturalness of the listening experience.

---

## Objectives and Contributions

The dissertation presents several key scientific contributions to the field of binaural audio synthesis:

1. Evaluation method was developed to assess the localization accuracy of dynamic, binaurally synthesized sound sources using head tracking. This approach allows for precise measurements of how well listeners can identify the direction and movement of sound sources in virtual environments.
2. A subjective evaluation method was proposed to assess listeners' perceptions of naturalness and the externalization of virtual sound sources. This method considers various factors, such as head movement and the effects of different HRTF sets.
3. A core aspect of this study is the direct comparison between using generic and person's own individualized HRTF sets. The results highlight the scenarios where individualized HRTFs offer significant improvements in audio quality, providing a clearer understanding of their benefits and limitations.

## Research Methodology

The methodology involves a systematic evaluation of the entire binaural synthesis process, starting with the role of head-tracking devices. These devices utilize IMU (Inertial Measurement Unit) sensors to monitor the orientation of the listener's head, providing real-time data that informs the audio processing system.

**Static IMU Measurements:** For static evaluations, data was collected over extended periods to detect sensor drift, which refers to gradual errors that can accumulate in IMU sensor readings. The Allan variance method was applied to quantify these errors and ensure that the selected devices maintain stability over time.

**Dynamic IMU Measurements:** Dynamic tests were conducted using motorized rotational platforms and large-radius pendulums, simulating controlled head movements. These tests aimed to replicate realistic listening scenarios where users move their heads while interacting with virtual audio environments. The pendulum method was particularly useful for reducing magnetic interference, which had been an issue with the rotational platform method.

**Preliminary Binaural Synthesis Quality Study:** An initial study was carried out using only generic HRTF sets to establish a baseline for the system's performance. By varying parameters like the choice of head-tracking device, binaural decoder, and the amount of reverberation,

---

the study examined how these factors influenced the accuracy of sound localization and the perception of externalization.

**Main Binaural Synthesis Quality Study:** The core of the research involved measuring individualized HRTFs for participants using the Earfish method in an anechoic chamber, providing a controlled acoustic environment. Participants' localization accuracy and subjective perceptions of sound were evaluated using both their personalized HRTFs and generic ones, allowing for a direct comparison of the two approaches.

## Key Findings

The results indicate that individualized HRTFs generally lead to better localization accuracy, particularly when the sound sources are positioned in front of the listener. This improvement is especially noticeable in dynamic scenarios where the listener's head movement is significant, such as when tracking a moving sound source in a virtual reality application. The sense of externalization—where sound sources are perceived as originating from outside the head—was also enhanced with individualized HRTFs.

However, the study found that the advantages of individualized HRTFs are not uniform across all conditions. For simpler audio environments or scenarios with minimal head movement, the difference between generic and individualized HRTFs was less pronounced. This suggests that while individualized HRTFs offer benefits, their necessity depends on the complexity of the listening environment and the degree of immersion required by the application.

## Implications for Audio and VR/AR Industries

These findings have practical implications for the audio industry, particularly for developers of VR and AR applications. The research demonstrates that binaural audio systems with head tracking and individualized HRTFs can provide a more realistic and immersive audio experience, potentially setting a new standard for spatial audio in interactive environments. However, the adoption of individualized HRTFs in consumer products faces challenges due to the time-consuming nature of HRTF measurement and the need for specialized equipment.

The dissertation also emphasizes the importance of standardized evaluation methods for testing binaural synthesis systems. Current research often suffers from inconsistent methodologies and small sample sizes, making it difficult to draw definitive conclusions. By proposing a more rigorous approach to testing, this work aims to establish a framework that can guide future studies and help manufacturers integrate personalized audio solutions more effectively.

---

## Structure of the Dissertation

Chapter 1 presents an introduction to the topics of this dissertation.

Chapter 2 introduces the fundamental concepts related to binaural synthesis. Subchapter 2.1 provides basic information on binaural hearing and describes the phenomena on which sound source localization is based.

Subchapter 2.2 introduces the concept of HRTF functions and HRTF sets, describes individual HRTF functions and their advantages, and presents a selection of currently available methods for measuring individual HRTF sets.

Devices for head tracking are described in subchapter 2.3, with the introduction of concepts such as degrees of freedom and embedded systems, along with basic information about IMU sensors.

Subchapter 2.4 describes the process of binaural synthesis, from the appropriate data transfer protocols, through audio formats that include sound content and information on the direction of the sound source (necessary for virtual and augmented reality systems), to examples of successfully integrated binaural systems with head tracking using publicly available VST plugins, and introduces the concept of signal latency in these systems.

Subchapter 2.5 showcases commercial products that use binaural synthesis and are currently available on the market, as well as describes the application of binaural systems in the music and other industries.

Chapter 3 presents the implementation and results of three different tests of IMU sensor performance, i.e., devices with embedded IMU sensors. Devices from the group of embedded systems and smartphones were tested. Subchapter 3.1 describes the measurement of static performance of IMU sensors in the tested devices, using Allan variance to determine static sensor drift (*drift*).

In subchapter 3.2, the main focus of the research was testing the dynamic performance of devices with embedded IMU sensors, specifically finding and implementing an appropriate method for conducting dynamic measurements. A method for measuring with a motorized rotational platform is presented, along with the challenges encountered during its implementation, and the results of the conducted measurements.

Subchapter 3.3 describes an improved method for measuring the dynamic performance of devices with embedded IMU sensors, which significantly reduces the influence of magnetic interference on the tests. The implementation of a method for processing raw IMU sensor data is shown, as well as the results of the measurements and discussion of the results.

Chapter 4 presents the implementation and results of a preliminary evaluation of binaural synthesis quality, which includes testing the accuracy of localization of virtual sound sources and assessing the effect of reverberation on the perception of externalization of virtual sound so-

---

urces. In these tests, specific parameters of the binaural synthesis system were varied to assess their impact on the synthesis process. Subchapter 4.1 describes the setup of the binaural synthesis system and the physical setup of the tests for participants. A total of fifteen participants took part in the study. Subchapter 4.2 presents the results of localization accuracy testing and the perception of externalization of the virtual sound source, as well as the statistical analysis of the obtained results.

Chapter 5 details the implementation and results of the main evaluation of binaural synthesis quality. Subchapter 5.1 presents a method for measuring individual HRTF sets developed for use without the need for an anechoic chamber, using cost-effective equipment and significantly reducing the time required for measuring individual sets compared to standard methods described in subchapter 2.2. Subchapter 5.2 describes the process of measuring audio signal latency of the binaural system used for the main evaluation of binaural synthesis quality.

Subchapter 5.3 contains the description of the method, setup, and implementation of the localization accuracy test for virtual sound sources using both individual and generic HRTF sets in the binaural synthesis of these sources. Subchapter 5.4 includes a description of the method, setup, and execution of the subjective evaluation of naturalness and externalization of virtual sound sources synthesized using binaural synthesis with the use of participants' individual HRTF sets and individual HRTF sets of other individuals. Subchapter 5.5 presents the results of the localization accuracy testing and the subjective evaluation of the naturalness and externalization of virtual sound sources, along with a detailed statistical analysis of the results. The discussion of the results is presented in subchapter 5.6.

Chapter 6 presents the conclusions of this doctoral dissertation.

Appendix 7 contains a list of abbreviations common in the included scientific and engineering fields (subchapter 7.1). In addition to the list of abbreviations, the appendix includes tables with the results of the preliminary localization accuracy and externalization perception tests of virtual sound sources (subchapter 7.2), R code for calculating the analysis of variance for repeated measures (subchapter 7.3), and tables with the results of the main localization accuracy tests for virtual sound sources (subchapter 7.4).

## **Conclusion**

This dissertation advances the understanding of how individualized HRTFs can enhance the quality of binaural audio experiences. It provides evidence that personalized audio processing can significantly improve spatial accuracy and listener immersion in certain contexts, making it a valuable consideration for next-generation audio technologies. The work offers a foundation for further research into making personalized HRTFs more accessible and integrating them into consumer audio products, paving the way for a more immersive and lifelike auditory experience

---

in both entertainment and professional applications.

**Keywords:** binaural synthesis, head tracking, HRTF functions, IMU sensors, virtual sound source, 3D audio systems, virtual and augmented reality

# Sadržaj

|                                                                                      |           |
|--------------------------------------------------------------------------------------|-----------|
| <b>1. Uvod</b>                                                                       | <b>1</b>  |
| 1.1. Motivacija                                                                      | .1        |
| 1.2. Doprinos                                                                        | .2        |
| 1.3. Metodologija istraživanja                                                       | .2        |
| 1.4. Struktura disertacije                                                           | .4        |
| <b>2. Binauralna sinteza uz praćenje položaja glave</b>                              | <b>6</b>  |
| 2.1. Binauralni sluh                                                                 | .6        |
| 2.2. Prijenosne funkcije glave (HRTF)                                                | .9        |
| 2.2.1. Proces mjerenja individualnih HRTF skupova                                    | .12       |
| 2.3. Uređaji za praćenje položaja glave                                              | .12       |
| 2.3.1. IMU senzori                                                                   | .13       |
| 2.3.2. Primjeri uređaja za praćenje položaja glave                                   | .15       |
| 2.4. Proces binauralne sinteze                                                       | .19       |
| 2.4.1. Prijenos podataka - OSC protokol                                              | .19       |
| 2.4.2. Ambisonics                                                                    | .20       |
| 2.4.3. Primjer povezivanja kompletnog binauralnog sustava uz praćenje položaja glave | .21       |
| 2.4.4. Kašnjenje signala u sustavu binauralne sinteze                                | .24       |
| 2.5. Primjena u industriji i proizvodi na tržištu                                    | .25       |
| <b>3. Ispitivanje performansi IMU senzora</b>                                        | <b>27</b> |
| 3.1. Preliminarna mjerenja statičkih performansi IMU senzora                         | .27       |
| 3.2. Metoda mjerenja dinamičkih performansi IMU senzora rotacijskom platformom       | 30        |
| 3.2.1. Izazovi pri provedbi mjerenja                                                 | .32       |
| 3.2.2. Rezultati mjerenja                                                            | .37       |
| 3.3. Metoda mjerenja performansi IMU senzora njihovom                                | .40       |
| 3.3.1. Postava mjerenja i izbor testnih uređaja                                      | .41       |
| 3.3.2. Obrada podataka s IMU senzora i izračun položaja                              | .43       |

|                   |                                                                                                         |            |
|-------------------|---------------------------------------------------------------------------------------------------------|------------|
| 3.3.3.            | Rezultati mjerenja . . . . .                                                                            | .45        |
| 3.3.4.            | Diskusija rezultata . . . . .                                                                           | .48        |
| <b>4.</b>         | <b>Preliminarno ispitivanje kvalitete binauralne sinteze . . . . .</b>                                  | <b>50</b>  |
| 4.1.              | Metoda mjerenja i postava ispitivanja . . . . .                                                         | .50        |
| 4.2.              | Statistička analiza i rezultati . . . . .                                                               | .55        |
| 4.2.1.            | Rezultati ispitivanja točnosti lokalizacije izvora zvuka . . . . .                                      | .55        |
| 4.2.2.            | Rezultati ispitivanja percepcije eksternaliziranosti izvora zvuka . . . . .                             | .59        |
| <b>5.</b>         | <b>Glavno ispitivanje kvalitete binauralne sinteze . . . . .</b>                                        | <b>60</b>  |
| 5.1.              | Mjerenje individualnih HRTF skupova . . . . .                                                           | .60        |
| 5.2.              | Mjerenje kašnjenja audio signala binauralnog sustava . . . . .                                          | .63        |
| 5.3.              | Metoda mjerenja točnosti lokalizacije . . . . .                                                         | .66        |
| 5.3.1.            | Postava i izvođenje ispitivanja . . . . .                                                               | .66        |
| 5.4.              | Metoda subjektivnog vrednovanja prirodnosti i eksternalizacije virtualnog zvučnog izvora . . . . .      | .69        |
| 5.4.1.            | Postava i izvođenje ispitivanja . . . . .                                                               | .69        |
| 5.5.              | Statistička analiza i rezultati ispitivanja . . . . .                                                   | .70        |
| 5.5.1.            | Ispitivanje točnosti lokalizacije . . . . .                                                             | .71        |
| 5.5.2.            | Ispitivanje subjektivnog vrednovanja prirodnosti i eksternalizacije virtualnog zvučnog izvora . . . . . | .76        |
| 5.6.              | Diskusija rezultata . . . . .                                                                           | .77        |
| <b>6.</b>         | <b>Zaključak . . . . .</b>                                                                              | <b>80</b>  |
| <b>7.</b>         | <b>Dodatak . . . . .</b>                                                                                | <b>82</b>  |
| 7.1.              | Popis kratica . . . . .                                                                                 | .82        |
| 7.2.              | Tablice rezultata preliminarnog ispitivanja kvalitete binauralne sinteze . . . . .                      | .84        |
| 7.3.              | R kod za izračun rezultata ANOVA ponovljenih mjerenja . . . . .                                         | .86        |
| 7.4.              | Tablice rezultata glavnog ispitivanja točnosti lokalizacije virtualnog zvučnog izvora . . . . .         | .88        |
| 7.5.              | Grafovi prosječnih vrijednosti rezultata ispitanika glavnog ispitivanja točnosti lokalizacije . . . . . | .92        |
| <b>Literatura</b> | <b>. . . . .</b>                                                                                        | <b>96</b>  |
| <b>Životopis</b>  | <b>. . . . .</b>                                                                                        | <b>112</b> |
| <b>Biography</b>  | <b>. . . . .</b>                                                                                        | <b>114</b> |



# Poglavlje 1

## Uvod

### 1.1 Motivacija

Stereo zvuk već je desetljećima standard u audio industriji kao glavni format za reprodukciju glazbenih sadržaja i reprodukciju zvuka iz videozapisa. S razvojem novih tehnologija te potrebom za višekanalnim audio zapisima (na primjer, u filmskoj industriji), postavljaju se pitanja o potencijalnoj zamjeni stereo zvuka kao standarda, te o mogućnostima novih sustava koji bi ga mogli zamijeniti. Iako napredak u filmskoj industriji donosi značajne inovacije u višekanalnim zvučnim zapisima [1], takvi standardi nisu nužno zamjena za stereo zvuk u kontekstu prosječnog korisnika audio zapisa, s obzirom na visoku cijenu takvih sustava, složenu i skupu instalaciju, nemogućnost jednostavnog prijenosa sustava za korištenje u drugim prostorijama, te druge faktore koji čine ovakav sustav nepristupačnim većini korisnika. Razvojem binauralnih audio sustava uz praćenje položaja glave, pojavilo se potencijalno rješenje za zamjenu stereo zvuka kao standarda u audio industriji. Rezultat dobiven takvim sustavima je prostorni zvuk (engl. *Spatial Audio*), pojam koji se sve češće spominje u profesionalnoj audio industriji [2].

Binauralni audio sustavi uz praćenje položaja glave koriste se za stvaranje realističnog iskustva slušanja, pružajući slušateljima osjećaj prostornosti virtualnog zvučnog okruženja i prirodne usmjerenosti virtualnih zvučnih izvora. S porastom interesa i razvoja tehnologija virtualne i proširene stvarnosti (VR, engl. *Virtual Reality*; AR, engl. *Augmented Reality*), binauralni audio sustavi postali su još značajniji jer imaju ključnu ulogu u stvaranju uvjerljivog osjetilnog iskustva, te pokušavaju replicirati iskustvo slušanja realnih zvučnih izvora [3]. Binauralna sinteza koristi prijenosne funkcije glave (HRTF, engl. *Head Related Transfer Function*), koje su ključne za lokaliziranje virtualnih zvučnih izvora u virtualnom prostoru i stvaranje realističnog osjećaja prostornosti. U virtualnoj i proširenoj stvarnosti, binauralni audio sustavi koriste se za stvaranje realističnog zvučnog polja koje odgovara korisnikovom vizualnom okruženju, pružajući uronjenije i privlačnije iskustvo u usporedbi s korištenjem samo vizualnih znakova [4]. Od računalnih igara i zabave [5], medicine [6, 7], do obrazovanja i profesionalne obuke [8, 9],

binauralni audio sustavi i prostorni zvuk jako su bitan faktor interakcije unutar virtualnih i proširenih okruženja. Dok su generički HRTF skupovi naširoko korišteni u području prostornog zvuka za stvaranje prirodnijeg i točnijeg VR/AR iskustva [10], individualni ili osobni HRTF skupovi imaju potencijal još više personalizirati cjelokupno iskustvo. Nadalje, korištenje generičkog HRTF skupa može potencijalno dovesti do ograničenja percepcije trodimenzionalnog zvuka (3D, engl. *Three-Dimensional*) u virtualnoj stvarnosti [11]. Jedna od potencijalnih prednosti korištenja individualnog HRTF skupa za razliku od generičkog je superiorna lokalizacija izvora zvuka unutar frontalne hemisfere, što može rezultirati višim stupnjem preciznosti kada se koristi individualni HRTF skup koji je posebno izmjeren za određenog slušatelja [12].

Trenutna istraživanja u području kvalitete lokalizacije virtualnih zvučnih izvora uz uporabu vlastitih individualnih skupova HRTF funkcija pri binauralnoj sintezi često prikazuju kontradiktorne rezultate. Iako postoje istraživanja koja su pokazala statistički značajna poboljšanja uz uporabu vlastitih individualnih HRTF skupova pri binauralnoj sintezi [13, 14, 15], neka druga istraživanja dovela su do zaključka da je korištenje generičkog HRTF skupa dovoljno kvalitetno i da nema nužne potrebe za mjerenjem i korištenjem individualnih HRTF skupova u binauralnoj sintezi [16]. Razlike u ishodima navedenih istraživanja ukazuju da su potrebna dodatna istraživanja uz preciznije metode ispitivanja točnosti lokalizacije virtualnih zvučnih izvora kako bi se pokazalo u kojim uvjetima i u kojim primjenama upotreba individualnih vlastitih HRTF skupova dovodi do značajnih poboljšanja vezanih uz točnost lokalizacije zvučnog izvora, i time opravdava mjerenje i korištenje tih skupova.

## 1.2 Doprinosa

Ova doktorska disertacija sadrži sljedeći znanstveni doprinos:

1. Metoda ispitivanja točnosti lokalizacije binauralno sintetiziranih zvučnih izvora promjenjivog smjera kretanja uz praćenje položaja glave
2. Metoda subjektivnog vrednovanja prirodnosti i eksternalizacije zvučnih izvora u binauralno sintetiziranom zvučnom polju uz praćenje položaja glave
3. Povećanje točnosti lokalizacije binauralno sintetiziranih zvučnih izvora promjenjivog smjera kretanja uz praćenje položaja glave implementacijom individualnih umjesto generičkih prijenosnih funkcija glave

## 1.3 Metodologija istraživanja

Iako postoje istraživanja koja se fokusiraju na točnost lokalizacije i ostale parametre kvalitete virtualnih zvučnih izvora koristeći binauralnu sintezu u VR/AR sustavima, metode ispitivanja kvalitete nisu široko univerzalno prihvaćene (metode se značajno razlikuju), te dolaze do

znatno drugačijih zaključaka kada je u pitanju korištenje individualnih HRTF skupova u navedenim sustavima. Također, zbog često kompleksnog postupka mjerenja individualnih HRTF skupova, trenutno dostupna istraživanja baziraju se na manjem broju ispitanika (često manje od deset ispitanika po istraživanju). S malim brojem ispitanika, teško je dobiti statistički značajne rezultate kako bi se donijeli relevantni zaključci za cijelu populaciju.

Jedan od ciljeva ove doktorske disertacije je ispitati cjelokupni sustav za binauralnu sintezu, počevši sa vrlo bitnim dijelom u postupku implementacije sustava: uređajima za praćenje položaja glave, to jest, uređajima koji sadrže IMU (engl. Inertial Measurement Unit) senzore za detekciju orijentacije korisnikove glave. Kako bi se adekvatno ispitala kvaliteta uređaja za praćenje položaja glave, bilo je potrebno koristiti različite dostupne uređaje, te ispitati statičke i dinamičke performanse uređaja s ugrađenim IMU sensorima. Za potrebe statičkih mjerenja, podatke s uređaja bilo je potrebno pohranjivati u periodu od nekoliko sati, uz onemogućavanje pomicanja uređaja kako bi bilo moguće uočiti senzorska klizanja (engl. *drift*). Za određivanje pouzdanosti senzora bilo je potrebno koristiti Allanovu varijancu, mjeru klizanja parametara senzora u frekvencijski stabilnom signalu. Dinamička mjerenja podrazumijevaju korištenje ponovljivog kontroliranog gibanja, kako bi bila moguća usporedba podataka dobivenih pomoću različitih mjerenih uređaja. U ovoj doktorskoj disertaciji predložene su i implementirane dvije različite metode mjerenja dinamičkih performansi uređaja s ugrađenim IMU sensorima, prvo korištenjem dvije različite motorizirane rotacijske platforme, te naknadno korištenjem njihala velikog polumjera. Korištenje njihala osmišljeno je kao odgovor na probleme uočene pri mjerenjima uređaja na rotacijskim motoriziranim platformama, tijekom kojih su detektirane magnetske smetnje, te je iz tog razloga magnetometar zapisivao netočne podatke koji nisu mogli biti upotrijebljeni za izračunavanje orijentacije.

Uz potvrdu zadovoljavajuće kvalitete uređaja s ugrađenim IMU sensorima u svrhu nastavka istraživanja, izvedeno je preliminarno ispitivanje kvalitete binauralne sinteze uz uporabu samo generičkih HRTF skupova, a ne i individualnih, kako bi naglasak ispitivanja bio na variranju drugih parametara sustava binauralne sinteze, kao što su uređaj za praćenje položaja glave, binauralni dekodir i količina odjeka dodanog virtualnom zvučnom izvoru. Promjenom navedenih parametara bilo je moguće ispitati točnost lokalizacije, te eksternaliziranost virtualnog zvučnog izvora sustava za binauralnu sintezu.

Glavno ispitivanje fokusirano je na ispitivanje kvalitete binauralne sinteze uz korištenje individualnih HRTF skupova. Za potrebe ovog ispitivanja, svim sudionicima morao je biti izmjeren njihov vlastiti individualni HRTF skup *Earfish* metodom mjerenja HRTF skupova, te su sva mjerenja odrađena u gluhoj komori Zavoda za elektroakustiku na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu, kao akustički kontroliranom prostoru. Točnost lokalizacije ispitana je korištenjem binauralno sintetiziranih zvučnih izvora promjenljivog smjera kretanja i brzine, a subjektivno vrednovanje prirodosti i eksternalizacije korištenjem virtualnog zvučnog

izvora na fiksnoj poziciji unutar virtualne zvučne okolice pri binauralnoj sintezi. Korišteno je više različitih individualnih HRTF skupova, među kojima su primarno bili korišteni ispitanikov vlastiti individualni HRTF skup, individualni HRTF skup druge osobe koja nije ispitanik, te generički HRTF skup.

## 1.4 Struktura disertacije

Poglavlje 2 uvodi osnovne pojmove vezane uz binauralnu sintezu. Potpoglavlje 2.1 pruža osnovne informacije o binauralnom sluhu, te opisuje fenomene na kojima se temelji lokalizacija zvučnih izvora. Potpoglavlje 2.2 uvodi pojam HRTF funkcije i HRTF skupa, opisuje individualne HRTF funkcije i njihove prednosti, te prikazuje izbor trenutno dostupnih metoda mjerenja individualnih HRTF skupova. Uređaji za praćenje položaja glave opisani su u potpoglavlju 2.3, uz uvođenje pojmova kao što su stupnjevi slobode i ugradbeni sustavi, te pruža osnovne informacije o IMU sensorima. Potpoglavlje 2.4 opisuje proces binauralne sinteze, od adekvatnog protokola za slanje podataka, preko audio formata koji uz zvučni sadržaj sadrži i informaciju o smjeru u kojem se nalazi izvor zvuka (nužno za sustave virtualne i proširene stvarnosti), do primjera uspješno povezanog binauralnog sustava s praćenjem položaja glave koji se služi javno dostupnim VST dodacima, te se uvodi pojam kašnjenja signala u navedenim sustavima. Potpoglavlje 2.5 prikazuje komercijalne proizvode koji koriste binauralnu sintezu i trenutno su dostupni na tržištu, te opisuje primjenu binauralnih sustava u glazbenoj i ostalim industrijama.

Poglavlje 3 prikazuje provedbu i rezultate tri različita ispitivanja performansi IMU senzora, tj. uređaja s ugrađenim IMU sensorima. Ispitani su uređaji iz skupine ugradbenih sustava i pametnih telefona. Potpoglavlje 3.1 opisuje mjerenje statičkih performansi IMU senzora u mjerenim uređajima, koristeći Allanovu varijancu za određivanje statičkog senzorskog klizanja (engl. *drift*). U potpoglavlju 3.2, glavni fokus istraživanja bio je ispitivanje dinamičkih performansi uređaja s ugrađenim IMU sensorima, točnije, pronalaženje i realizacija adekvatne metode za izvođenje dinamičkih mjerenja. Prezentirana je metoda mjerenja motoriziranom rotacijskom platformom, i opisani su izazovi uočeni pri implementaciji metode, te rezultati provedenih mjerenja. Potpoglavlje 3.3 opisuje poboljšanu metodu mjerenja dinamičkih performansi uređaja s ugrađenim IMU sensorima, koja značajno smanjuje utjecaj magnetskih smetnji na ispitivanja. Prikazana je implementacija metode obrade sirovih podataka s IMU senzora, te rezultati izvedenih mjerenja i diskusija rezultata.

Poglavlje 4 prikazuje način provedbe i rezultate preliminarnog ispitivanja kvalitete binauralne sinteze, što uključuje ispitivanje točnosti lokalizacije virtualnih zvučnih izvora, te ispitivanje utjecaja količine odjeka na percepciju eksternaliziranosti virtualnih zvučnih izvora. U navedenim su ispitivanja mijenjani određeni parametri sustava za binauralnu sintezu u svrhu procjene njihovog utjecaja na proces binauralne sinteze. U potpoglavlju 4.1, opisana je postava

sustava za binauralnu sintezu, te fizička postava ispitivanja za sudionike ispitivanja. Ukupno petnaest ispitanika sudjelovalo je u ispitivanju. Potpoglavlje 4.2 predstavlja rezultate ispitivanja točnosti lokalizacije i percepcije eksternaliziranosti virtualnog izvora zvuka, te statističku analizu navedenih rezultata.

Poglavlje 5 predstavlja postupak provedbe i rezultate glavnog ispitivanja kvalitete binauralne sinteze. U potpoglavlju 5.1 prikazana je metoda mjerenja individualnih HRTF skupova razvijena za korištenje bez potrebe za gluhom komorom, uz cjenovno pristupačnu opremu, te uz znatno kraće vremensko trajanje mjerenja individualnih skupova nego standardnim metodama opisanim u potpoglavlju 2.2. Potpoglavlje 5.2 opisuje postupak mjerenja kašnjenja signala binauralnog sustava korištenog za glavno ispitivanje kvalitete binauralne sinteze. Potpoglavlje 5.3 sadrži opis metode, postave i provedbe ispitivanja točnosti lokalizacije virtualnih zvučnih izvora uz uporabu individualnih i generičkih HRTF skupova pri binauralnoj sintezi navedenih izvora. Potpoglavlje 5.4 sadrži opis metode, postave i izvođenje subjektivnog vrednovanja prirodnosti i eksternalizacije virtualnih zvučnih izvora sintetiziranim binauralnom sintezom uz uporabu individualnih vlastitih HRTF skupova i individualnih HRTF skupova drugih osoba. Potpoglavlje 5.5 predstavlja rezultate ispitivanja točnosti lokalizacije i subjektivnog vrednovanja prirodnosti i eksternalizacije virtualnih zvučnih izvora, te detaljnu statističku analizu navedenih rezultata. Diskusija rezultata predstavljena je u potpoglavlju 5.6.

Poglavlje 6 prezentira zaključke ove doktorske disertacije.

Dodatak 7 sadrži popis kratica koje su uobičajene u obuhvaćenim znanstvenim i inženjerskim područjima (potpoglavlje 7.1). Uz popis kratica, u dodatku se nalaze tablice s rezultatima preliminarnog ispitivanja točnosti lokalizacije i percepcije eksternalizacije virtualnog zvučnog izvora (potpoglavlje 7.2), R kod za izračun analize varijance ponovljenih mjerenja (potpoglavlje 7.3), te tablice s rezultatima glavnog ispitivanja točnosti lokalizacije virtualnog zvučnog izvora (potpoglavlje 7.4).


## Poglavlje 2

# Binauralna sinteza uz praćenje položaja glave

### 2.1 Binauralni sluh

Ljudski sluh predstavlja izuzetan biomehanički sustav koji ljudi koriste za detekciju zvuka [17]. Evolucija je značajno utjecala na razvoj sluha, prilagođavajući se uvjetima ljudskog života, pri čemu je primarna svrha sluha bila detekcija opasnosti u okolini (što je vidljivo i kod različitih životinjskih vrsta). Od početaka ljudske civilizacije, ljudski sluh je postupno usavršavan na svim frekvencijskim područjima [18].

Uz vid, okus, miris i dodir, osjet sluha pripada skupini pet glavnih osjeta. Uho je organ sluha i ravnoteže, a sastavljen je od tri anatomska dijela: vanjsko uho, srednje uho i unutarnje uho (slika 2.1) [19].




**Slika 2.1:** Vizualni prikaz dijelova uha [20].

Za detaljno razumijevanje sluha, te potencijalnih problema sa sluhom kao što su šum ili

tinitus [21], važno je poznavati anatomiju i fiziologiju uha, te cijeli slušni put [20].

Frekvencijski raspon ljudskog sluha definiran je u frekvencijskom području od 20 do 20000 Hz, pri čemu je uho najosjetljivije u području frekvencija između 2000 i 5000 Hz (gdje je potreban najmanji intenzitet zvuka kako bi se došlo do praga čujnosti) [22]. Frekvencijski raspon sluha se značajno sužava s godinama, uz značajnije smanjenje gornje granice frekvencijskog raspona [23, 24] (slika 2.2. Gubitak sluha utječe na sposobnost razumijevanja govora, posebno u bučnim okolinama, te na smanjenu sposobnost lokalizacije zvučnih izvora [25].




**Slika 2.2:** Prosječni audiogram dobiven audiometrijom pomoću čistih tonova za različite dobne skupine po desetljećima života kod muškaraca (a) i žena (b) [24].

Danas se slušanje prvenstveno koristi za komunikaciju, dok se binauralna svojstva sluha koriste za lokalizaciju zvučnih izvora i orijentaciju u prostoru. Sposobnost lokalizacije zvučnog izvora slušanjem pomoću dva uha naziva se binauralni sluh [18].

Za razliku od slušanja jednim uhom, slušanje s oba uha omogućuje preciznu lokalizaciju izvora zvuka i bolju percepciju prostornosti zvučnog okruženja. Lokalizacija zvučnog izvora dijelom se ostvaruje razlikama u vremenu dolaska zvuka od zvučnog izvora do svakog uha koje se nazivaju interauralne vremenske razlike (ITD, engl. *interaural time difference*), a dijelom razlikama u intenzitetu zvuka pristiglog na svako uho koje nazivamo interauralnim intenzitetnim razlikama (ILD, engl. *interaural level difference*) (slika 2.3.), što pomaže osobi da odredi smjer i udaljenost zvučnog izvora. Također, binauralno slušanje poboljšava sposobnost razlikovanja zvukova u bučnim okolinama.

Za potrebe lokalizacije zvučnih izvora u trodimenzionalnom prostoru, interauralne vremenske i intenzitetne razlike nisu dovoljne. Kao dodatni faktor, oblik ušne školjke čovjeka ponaša se kao filtar audio signala, te ga mijenja ovisno o upadnom kutu zvuka na uho [26]. Zahvaljujući tomu moguće je, na primjer, lokalizirati zvučni izvor koji se nalazi točno ispred, iznad ili iza čovjeka, iako ni u jednom od tih slučajeva ne postoje interauralne razlike. Interauralne vremenske razlike pružaju informacije za lokalizaciju primarno za zvukove niskih frekvencija



**Slika 2.3:** Lokalizacija zvučnog izvora pomoću interauralnih vremenskih i intenzitetnih razlika.

(manje od 1500 Hz), gdje je valna duljina dolaznog zvuka velika u odnosu na promjer glave, što omogućava jasnu razliku u fazi između zvukova koji stižu do oba uha [27]. Međutim, druga istraživanja pokazuju da slušatelji mogu detektirati interauralna kašnjenja kod zvukova visokih frekvencija [28]. Kod zvukova niskih frekvencija s valnim duljinama većim od promjera glave pojavljuje se difrakcija, odnosno savijanje zvučnih valova oko glave kako bi stigli do suprotnog uha. Stoga su interauralne intenzitetne razlike za zvukove niskih frekvencija obično neznatne, iako u nekim slučajevima mogu doseći i do 5 decibela [29]. Za frekvencije iznad 1500 Hz, gdje su dimenzije glave veće od valne duljine, zvučni valovi su premali da bi se savijali oko glave, te glava predstavlja zasjenu. To rezultira jasnim interauralnim intenzitetnim razlikama, osobito za bočno smještene izvore zvuka [30].

Jedan od mogućih načina reprodukcije binauralnog zvuka je da se zvučna okolina snimi umjetnom glavom (slika 2.4), te reproducira stereo slušalicama bez pomicanja glave slušatelja. Snimanje zvuka umjetnom glavom podrazumijeva snimanje pomoću para mikrofona koji se nalaze na mjestu bubnjića umjetne glave, te takav način snimanja oponaša sluh jer uključuje realna zasjenjenja i filtriranja zbog oblika i dimenzija glave i ušiju [31]. Zapisi se zatim slušaju isključivo putem slušalica, omogućujući slušatelju da čuje zvučno polje iz perspektive umjetne glave u trenutku snimanja. Kako bi snimke bile prilagođene velikom broju ljudi, oblik umjetne glave i ušiju definiran je prema prosječnim antropometrijskim podacima dobivenim na velikom



uzorku ljudske populacije.




**Slika 2.4:** Bruel & Kjaer umjetna glava i torzo tip 4128C [32].

U prethodno navedenom načinu reprodukcije nakon snimanja umjetnom glavom, slušatelj bi morao držati svoju glavu potpuno mirno tijekom reprodukcije. U navedenim uvjetima, pojavljuje se problem pogreške određivanja smjera zvuka, koji se naziva stožac zbunjenosti (engl. *Cone of Confusion*) [33]. Čovjek malim pomacima glave smanjuje bazu tog stošca i time bolje lokalizira zvuk. Zbog toga je takva statična reprodukcija binauralnog signala na slušalice neadekvatna za upotrebu.

## 2.2 Prijenosne funkcije glave (HRTF)

Prethodno spomenuti fenomen filtriranja zvuka ovisno o smjeru dolaska uzrokovan veličinom i oblikom ušne školjke, glave i torza opisuje se prijenosnim funkcijama glave (engl. Head-Related Transfer Functions). Definira se kao impulsni odziv na mjestu bubnjića za određeni smjer izvora zvuka, odnosno u frekvencijskoj domeni, to je razlika spektra zvuka snimljenog mikrofonom na mjestu bubnjića u odnosu na spektar zvuka snimljen istom mjestu kad nema slušatelja (ili umjetne glave). HRTF funkcija opisuje akustičku prijenosnu funkciju između


točkastog izvora u slobodnom prostoru (bez informacija o prostoru) i određene pozicije u slušateljevom ušnom kanalu [34]. Ulazni zvučni val dolazi do ušne školjke, a zatim oblik ušne školjke proizvodi mikro refleksije (jako mala kašnjenja) koje se na ulazu u ušni kanal "zbrajaju" u signal, te dolaze do bubnjića. Taj signal ljudski mozak procesira i, dodatno koristeći interauralne vremenske i intenzitetne razlike, izračunava informaciju o smjeru dolaska zvuka koji se širi od nekog zvučnog izvora [35]. Ako je izvor zvuka udaljen više od jednog metra od slušatelja, HRTF funkcija postaje asimptotski neovisna o udaljenosti i kategorizira se kao HRTF funkcija dalekog polja (engl. *far-field HRTF*), dok se za zvučne izvore udaljene manje od jednog metra od slušatelja koriste HRTF funkcije bliskog polja (engl. *near-field HRTF*) [36] (slika 2.5).



**Slika 2.5:** Vizualni prikaz razlike između HRTF funkcija bliskog (plava isprekidana crta) i dalekog polja (crvena crta) [35].


Za adekvatnu binauralnu sintezu nekog virtualnog izvora zvuka potrebno je pravilno primijeniti skup HRTF funkcija bliskog ili dalekog polja ovisno o željenoj udaljenosti tog izvora od slušatelja. HRTF funkcije ključni su ulazni podaci za pravilnu binauralnu sintezu (slika 2.6).

Impulsni odziv vezan uz orijentaciju glave u odnosu na izvor zvuka (HRIR, engl. *Head-Related Impulse Response*) je reprezentacija HRTF funkcije u vremenskoj domeni. Budući da su sve relevantne akustičke značajke za lokalizaciju stvarnih izvora zvuka sadržane u HRTF funkcijama, tj. interauralne vremenske i intenzitetne razlike i monauralne spektralne značajke [27], HRTF funkcije se primjenjuju za sintetiziranje virtualnih zvučnih polja reproduciranih preko slušalica ili zvučnika (binauralna ili transauralna reprodukcija) [38, 39]. Iako postoje generičke HRTF funkcije koje su dobivene mjerenjem umjetne glave ili prosječnim mjerenjima HRTF funkcija velikog broja ljudi, te se koriste u današnjim sustavima virtualne stvarnosti i općenito u područjima gdje je potrebna binauralna sinteza, individualne HRTF funkcije jedins-



**Slika 2.6:** Grafovi razlike magnituda (za iznos azimuta  $0^\circ$ , tj. zvučni izvor direktno ispred slušatelja) u ovisnosti o frekvenciji za različite vrijednosti elevacije zvučnog izvora [37]

tvne su za svaku osobu jer ovise o antropometrijskim karakteristikama tijela osobe i opisuju djelovanje tijela osobe na zvuk na njegovom putu od određenog zvučnog izvora do bubnjića osobe. Neke od navedenih karakteristika uključuju prethodno spomenuti oblik ušne školjke, te oblik glave i torza osobe. Primjer razlike između individualnih i generičkih HRTF funkcija vidljiv je na slici 2.7.



**Slika 2.7:** Frekvencijski odzivi generičkih i individualnih HRTF funkcija izjednačeni prema difuznom polju, izmjereni na lijevom uhu uz smjer dolaska zvuka određen azimutom od  $0^\circ$  i elevacijom od  $40^\circ$  [40].

### 2.2.1 Proces mjerenja individualnih HRTF skupova

Kako bi se što bolje opisao način na koji se za sasvim određenu osobu događa promjena frekventijskog sadržaja zvuka u ovisnosti o smjeru dolaska zvuka, potrebno je izmjeriti HRTF funkcije za što veći broj mogućih smjerova dolaska zvuka i ujediniti ih u individualni HRTF skup jedinstven upravo za tu osobu. Mjerenje takvog individualnog HRTF skupa za određenu osobu (vlastiti individualni HRTF skup) mora se izvesti pomoću jedne od mnogih dostupnih mjernih metoda i sustava [41]. Za mjerenje individualnog HRTF skupa obično se koristi višestruki eksponencijalni klizajući sinus, koji se reproducira na segmentu kružnog luka koji se sastoji od velikog broja zvučnika smještenih u gluhoj komori. Luk se može zakretati oko fiksne središnje točke u kojoj se nalazi glava slušatelja za kojega se provodi mjerenje HRTF funkcija. Slušatelj nosi par mikrofona u ušima, i mjeri individualne HRTF funkcije koristeći prethodno objašnjenu mjernu postavu [42, 43, 44, 45] (slika 2.8). Iako je opisana konvencionalna metoda mjerenja vlastitih individualnih HRTF funkcija još uvijek prevladavajuća, posljednjih godina razvijene su nove mjerne metode koje omogućuju mjerenje individualnih HRTF skupova za širi raspon korisnika bez potrebe za složenim mjernim sustavima ili gluhom komorom. Ove nove metode uključuju tehnike kao što su trodimenzionalno skeniranje i modeliranje uha pojedinaca strukturiranim svjetlom/3D skenerima, ili pomoću slika/videosnimki visoke rezolucije [45, 47, 48]. Druga skupina metoda koristi sustav s jednim zvučnikom smješten u običnoj prostoriji (koja ne mora imati zadovoljene uvjete gluhe komore), a ispitanik nosi uređaj za praćenje položaja glave opremljen IMU senzorima, pri čemu taj uređaj može biti implementiran kao specijalizirana namjenska jedinica za praćenje položaja glave, ili se čak može koristiti pametni telefon [49, 50, 51]. Suvremene sustavi za mjerenje HRTF skupova uglavnom se koriste za mjerenje individualnih HRTF skupova za jednu, točno određenu udaljenost izvora zvuka od slušatelja. S povećanim interesom za binauralne aplikacije sa šest stupnjeva slobode, treba razmotriti nove pristupe mjerenju individualnih HRTF skupova s visokom prostornom gustoćom funkcija i na različitim udaljenostima (HRTF funkcije bliskog polja).

## 2.3 Uređaji za praćenje položaja glave

Kako bi bila postignuta pravilna simulacija zvučne okoline, sinteza binauralnog signala mora uzeti u obzir i orijentaciju slušateljeve glave u odnosu na zvučni izvor [52, 53]. Ako postoji virtualni akustički prostor u kojem postoji virtualni zvučni izvor, promjenom položaja korisnikove glave mijenja se i smjer zvučnog izvora u ovisnosti o položaju korisnika. Za navedeno praćenje položaja glave potreban je uređaj koji uzima podatke sa senzora, računa položaj glave i šalje podatke o položaju potrebne za binauralnu sintezu [54].



**Slika 2.8:** Prikaz mjerenja individualnih HRTF funkcija umjetne glave [46].

### 2.3.1 IMU senzori

Najčešće korišteni senzori potrebni za praćenje položaja glave su akcelerometar, žiroskop i magnetometar, i nazivaju se IMU senzori (engl. *Inertial Measurement Unit*). Pomoću podataka dobivenih s navedenih senzora, moguće je izračunati podatke o orijentaciji: azimut ili skretanje (engl. *Azimuth*), nagib ili propinjanje (engl. *Elevation*), i valjanje (engl. *Roll*). Najčešće korištena tehnologija za proizvodnju IMU senzora naziva se MEMS (engl. *microelectromechanical system*) tehnologija, koja je trenutno i najnaprednija javno dostupna tehnologija. Iako je moguće postići praćenje orijentacije bez magnetometra, zbog činjenice da je magnetometar ključan za održavanje referentne orijentacije sustava, moguć je pomak izračunate orijentacije tijekom vremena zbog povremenih pogreški u dobivenim podacima senzora (engl. *sensor drift*). Pomak može biti veoma značajan [55] i uvelike utjecati na kvalitetu binauralne sinteze,

i time negativno utjecati na percepciju prirodnosti virtualne zvučne okoline. Ovisno o cijeni i implementaciji IMU senzora, za što preciznije praćenje položaja glave potrebno je izmjeriti te izračunati moguće pogreške senzora [56] i implementirati algoritam za kalibraciju IMU senzora [57].


Nisu svi tipovi senzora i sustavi jednako prikladni za slušnu binauralnu reprodukciju, budući da bi kašnjenje sustava za praćenje položaja glave trebalo biti što je manje moguće. Prijenos i obrada podataka o orijentaciji moraju biti dovoljno brzi kako ne bi stvarala primjetna kašnjenja koja remete percepciju, transparentnost i glatkoću promjene binauralne slike za slušatelje koji pri slušanju pomiču glavu. Brzina samih senzora može se unaprijediti fuzijom senzora ili naprednim filtriranjem. Uz primjenu algoritama dubokog učenja, moguće je optimizirati stvarno vrijeme detekcije promjene orijentacije glave, ili detektirati položaj cijelog tijela pomoću više IMU senzora, gdje je dodatno moguće uključiti refleksije torza u izračun individualnih HRTF skupova. Specijalizirani komercijalni binauralni sustavi s praćenjem položaja glave još uvijek su prilično skupi, jer se ne proizvode u velikim količinama, te zahtijevaju nekoliko senzora i računalo koja se koristi isključivo za obavljanje te zadaće. U idealnom slučaju, kada se prethodno opisani uređaji koriste za praćenje položaja i orijentacije glave u binauralnim sustavima, uređaji su pričvršćeni na korisnikovu glavu, što osigurava potpunu sinkronizaciju pokreta glave i uređaja. Za postizanje toga, uređaj za praćenje mora se pričvrstiti na glavu na jednostavan i učinkovit način, obično kao dio slušalica ili kao dio kućišta sustava virtualne stvarnosti [58].

### Stupnjevi slobode

Stupnjevi slobode (DoF, engl. *degrees of freedom*) u sustavima definiraju se kao broj neovisnih osi u kojima se korisnik sustava može pomicati [59]. Prvi stupanj slobode je azimut, drugi stupanj je propinjanje, a treći stupanj je valjanje. Ova tri stupnja slobode odnose se na pomak glave u ovim trima osima u smislu promjene orijentacije glave, ali bez gibanja u prostoru. Dodavanjem tri dodatne koordinate pomaka u kartezijevom koordinatnom sustavu kojima se opisuje gibanje glave korisnika u prostoru, dobiva se sustav sa šest stupnjeva slobode (slika 2.9.). Za postizanje šest stupnjeva slobode na otvorenim prostorima, podatke o gibanju u prostoru moguće je dobiti uporabom GPS uređaja koji mjeri podatke (engl. *global positioning system*) o geografskoj širini, dužini i visini.

Barem tri stupnja slobode koja se odnose na orijentaciju glave na fiksnoj poziciji u prostoru potrebna su za vjerni prikaz virtualne zvučne okoline. Međutim, položaj ljudske glave nije fiksna, nego se ona u pravilu konstantno giba u prostoru, pa zbog toga šest stupnjeva slobode omogućuje najkvalitetniji doživljaj virtualnog prostora i virtualnog zvučnog polja, uz dovoljnu preciznost praćenja položaja glave.






Slika 2.9: Stupnjevi slobode sustava virtualne stvarnosti [60].

### 2.3.2 Primjeri uređaja za praćenje položaja glave

#### Ugradbeni sustav/mikrokontroler

U sustavima za praćenje položaja glave koji koriste ugradbeni sustav/mikrokontroler, nalaze se IMU senzori akcelerometar, žiroskop i magnetometar, koji su svojom širokom uporabom postali standardni za korištenje u sustavima za praćenje položaja s tri stupnja slobode. Ugradbeni sustavi moraju se programirati kako bi računali i prenosili informacije potrebne za binauralnu sintezu. Prednost ovakvih sustava je specijaliziranost za izvođenje samo jednog postupka (u ovom slučaju, praćenje položaja glave). Uređaji za praćenje položaja glave i binauralne audio sinteze u navedenoj kategoriji najčešće koriste komercijalne ugradbene sustave ili FPGA (engl. *Field Programmable Gate Array*) sustave [61]. Kao primjer ugradbenog sustava za praćenje položaja glave slušatelja, vrijedno je istaknuti Arduino Nano sustav (slika 2.10), zbog njegovih kompaktnih dimenzija koje ne opterećuju glavu slušatelja prilikom ugradnje na slušalice, te sposobnosti direktnog prijenosa podataka o položaju glave na računalo putem USB kabela. Direktan prijenos podataka ključan je u kontekstu binauralne sinteze kako bi se smanjilo kašnjenje, što je jedan od bitnih parametara za percepciju binauralnog zvuka kao zvuka koji ljudi doživljavaju u stvarnom prostoru. Dodatni uvid u kašnjenje signala prezentiran je u potpoglavlju 5.2.

Alternativno, moguće je koristiti i bežični prijenos podataka putem *Bluetooth* protokola (BLE, engl. *Bluetooth Low Energy*), što omogućuje veću slobodu kretanja, uz uvjet da je kašnjenje signala dovoljno malog iznosa kako ne bi utjecalo na percepciju prirodnosti virtualne zvučne okoline dobivene binauralnom sintezom. Za stabilniji bežični prijenos podataka, dos-



**Slika 2.10:** Arduino Nano ugradbeni sustav [62].

tupna je opcija korištenja *Arduino Uno Rev2 Wi-Fi* ugradbenog sustava [63], koji uz funkcionalnost jednaku onoj *Arduino Nano* sustava, također nudi mogućnost Wi-Fi prijenosa podataka.

### Pametni telefon

Većina ljudi danas posjeduje pametni telefon. Osim za komunikaciju, fotografije ili pregledavanje interneta, pametni telefoni mogu se koristiti i kao uređaj za praćenje položaja glave. U pametne telefone standardno se ugrađuju IMU senzori i GPS moduli pomoću kojih je moguće postići praćenje položaja glave sa šest stupnjeva slobode. Cijena pametnog telefona direktno utječe na kvalitetu senzora, pa je preciznost podataka IMU senzora i izračun praćenja položaja glave češće bolji na skupljim uređajima [64]. Velika prednost korištenja pametnog telefona kao uređaja za praćenje položaja glave je činjenica da nije potrebno kupovati poseban sustav za praćenje položaja, nego se koristi uređaj koji osoba već posjeduje, a daje iskoristive rezultate. Kao i kod ugradbenih sustava, optimalno je slati podatke preko USB kabela na računalo zbog smanjenja kašnjenja, ali moguće je koristiti bežični prijenos preko *Bluetooth* protokola na manje udaljenosti, ili putem Wi-Fi mreže, što u određenim situacijama daje bitno veću slobodu kretanja. Kako bi pametni telefon mogao slati podatke o položaju glave, potrebno je odrediti način komunikacije između pametnog telefona i sustava za binauralnu sintezu. Jedna od jednostavnijih metoda je koristiti aplikaciju za prikupljanje podataka s IMU senzora pametnog telefona. Kao primjer, moguće je instalirati aplikaciju *TouchOSC Mk1* (slika 2.11), koja se koristi kao modularna OSC i MIDI platforma za kontroliranje i slanje podataka. Pomoću navedene aplikacije moguće je čitati podatke sa senzora, te ih pomoću OSC protokola (opisanog u potpoglavlju 2.4.1) poslati na računalo radi daljnje obrade podataka.





**Slika 2.11:** Primjeri korisničkog sučelja aplikacije *TouchOSC Mk1* [65].

### Sustav za virtualnu/proširenu stvarnost


U navedenim sustavima osoba koristi uređaj s posebno dizajniranim lećama i monitorima koji u potpunosti prekriva oči i stvara vizualni doživljaj kao da se korisnik nalazi u drugom prostoru ili okolini. Okretom glave korisnika mijenja se i virtualni prostor u skladu s promjenom položaja glave, kako bi percepcija virtualnog prostora bila realistična. Korisnik uređaja za virtualnu stvarnost može doživjeti mučninu ako sustav nije pravilno implementiran, na primjer, zbog sporog video uzorkovanja, lošeg izračuna položaja korisnikove glave ili loše skaliranih pomaka u virtualnom okruženju [66]. Probleme s korisničkim doživljajem može uzrokovati i audiosustav unutar sustava virtualne stvarnosti. Neadekvatnom binauralnom sintezom doživljaj virtualnog okruženja nije potpun. Prednost navedenih sustava je kvaliteta senzora za praćenje položaja glave, jer su sustavi za virtualnu stvarnost specijalizirani za takvo praćenje, te omogućavaju praćenje položaja glave sa šest stupnjeva slobode (većina današnjih modela). Primjer sustava virtualne stvarnosti je Meta Quest 3 (slika 2.12).



**Slika 2.12:** Sustav za virtualnu i proširenu stvarnost Meta Quest 3 [67].

Za pristup podacima potrebnim za prikaz vizualne i zvučne VR/AR stvarnosti putem računala, te za uspostavljanje komunikacije između računala i VR/AR sustava, potrebno je omogućiti razvojni način rada (engl. *developer mode*) na uređaju. Primjer takve podrške jest razvojna okolina namijenjena igrama, koja omogućuje integraciju sustava virtualne stvarnosti s računalom. Dvije vodeće razvojne platforme za navedeni primjer uređaja su *Unity* [68] i *Unreal Engine* [69]. Iako obje platforme omogućuju praćenje položaja korisnikove glave, Unity ne pruža opciju slanja sirovih podataka s IMU senzora. U slučaju da korisnik želi implementirati vlastiti algoritam praćenja položaja glave ne oslanjajući se na unaprijed definirane funkcionalnosti VR/AR sustava, sirovi podaci postaju neophodni. Nasuprot tome, razvojno okruženje Unreal Engine omogućuje slanje sirovih podataka s IMU senzora, te nudi gotovo rješenje ispisivanja navedenih podataka putem grafičkog programiranja.

Osim uređaja koji koriste IMU senzore kao metodu praćenja položaja glave, moguće je koristiti i uređaje s optičkim sensorima, tj. kamere [70]. Za praćenje položaja glave ovom metodom potrebno je koristiti detekciju i prepoznavanje ljudskog lica i praćenje položaja lica pomoću umjetne inteligencije [71]. Problem navedene metode pojavljuje se pri okretu glave dovoljno velikom da lice slušatelja više nije u kadru kamere, tj. da sustav za prepoznavanje lica nema dovoljno vizualnih markera lica za određivanje rotacije glave. U tom trenutku prestaje praćenje položaja glave do povratka lica slušatelja u kadar (slika 2.13).



**Slika 2.13:** Primjer mjerenja rotacije položaja glave slušatelja za tri sustava (ugradbeni sustav Arduino, sustav za virtualnu stvarnost HTC Vive [72] i sustav s kamerom) [70].

## 2.4 Proces binauralne sinteze

### 2.4.1 Prijenos podataka - OSC protokol

OSC (engl. *Open Sound Control*) je protokol za upravljanje instrumenata, uređaja i aplikacija putem UDP/IP mreže [73]. OSC poruke obično se prenose unutar kućnih i studijskih računalnih mreža, ali mogu prenositi podatke i putem interneta. OSC pruža glazbenicima i programerima veću fleksibilnost u izboru vrste podataka koje mogu slati, omogućujući nove aplikacije koje mogu međusobno komunicirati uz pouzdano slanje podataka velikom brzinom [74]. Jedinica prijenosa OSC protokola je OSC paket. Aplikacija koja šalje OSC pakete naziva se OSC klijent (engl. *client*), a aplikacija koja prima OSC pakete naziva se OSC poslužitelj (engl. *server*). Veličina OSC paketa je uvijek četiri bajta (32 bita). Skripta zadužena za slanje/primanje OSC podataka s određene pristupne točke u sustavu prema drugoj pristupnoj točki šalje/prima podatke o položaju glave putem UDP (engl. *User Datagram Protocol*) paketa. OSC se također može koristiti preko TCP/IP mreže za situacije gdje je potrebna veća pouzdanost umjesto brzine, iako je UDP češći izbor zbog niskog kašnjenja. U jednoj poruci sadržana su sva tri smjera pokreta: rotacija, valjanje i propinjanje. Nakon slanja, svaka se poruka zasebno dekodira, te zatim šalje kao ulazni podatak o orijentaciji za binauralnu sintezu putem OSC protokola. Dok je na ugradbenim sustavima potrebno programirati njihovu funkcionalnost za omogućavanje

slanja podataka pomoću OSC protokola, na mobilnim telefonima postoje aplikacije kojima se mogu koristiti kontrolne informacije za upravljanje podacima koji se šalju OSC protokolom.

### 2.4.2 Ambisonics

Ambisonics je sustav koji omogućuje snimanje i reprodukciju prostornog zvuka sa zadržanim informacijama o smjeru dolaska zvuka iz izvora koji se nalaze u prostoru oko referentne točke snimanja/slušanja. Potpuni 3D doživljaj dobiva se reprodukcijom zvuka pomoću sustava zvučnika postavljenog u konfiguraciju u kojoj su zvučnici jednoliko raspoređeni po cijeloj površini sfere čije je središte u točki slušanja (slika 2.15 [75]). 3D zvučno polje snima se pomoću posebno dizajniranog Ambisonics mikrofona (slika 2.14).



**Slika 2.14:** ZYLIA ZM-1 Ambisonics mikrofon uz Ambisonics snimač [76].

Navedeni format snima zvučno polje sa zadržanim smjerovima zvučnih izvora u odnosu na točku snimanja. Što je viši red Ambisonics formata, zapis sadrži preciznije prostorne informacije o smjerovima zvučnih izvora.

Ambisonics se danas često koristi za reprodukciju zvuka pri slušnim ispitivanjima u sustavima virtualne stvarnosti. Negativna strana je da Ambisonics sustav (u originalnoj višezvučnoj konfiguraciji) zahtijeva skupu i kompleksnu opremu za reprodukciju, proces kalibracije je kompleksan, mora postojati specijalizirana prostorija za postavljanje sustava, te su datoteke Ambisonics formata puno veće nego uobičajeni audio formati. Moguće je korištenje Ambisonics formata za binauralne sustave uz praćenje položaja glave, čime se zanemaruje navedeni nedostatak u vidu potrebe za specijaliziranom opremom i prostorom. Uz korištenje binauralnog sustava uz praćenje položaja glave, Ambisonics format može se koristiti za poboljšanje kvalitete binauralne sinteze [78].

Primjer projekta koji koristi Ambisonics format kako bi spojio fizički svijet s mogućnostima Ambisonics virtualne prostornosti signala je "*Ambisonic Guitar System GASP: Guitars with*





Slika 2.15: Ambisonics postava u TGM (*The school of technology*) u Beču, Austrija [77].

*Ambisonic Spatial Performance*" [79].

### 2.4.3 Primjer povezivanja kompletnog binauralnog sustava uz praćenje položaja glave

Zbog današnjeg razvoja tehnologije vezane uz binauralne sustave uz praćenje položaja glave, otvorila se mogućnost izrade vlastitog sustava za binauralnu reprodukciju, zasnovanog na osobnom računalu te lako dobavljivim elektroničkim uređajima i programskoj podršci. U ovom potpoglavlju, naveden je primjer takvog sustava uz detaljno objašnjen način povezivanja svih komponenti, te je upravo takav sustav korišten za daljnja mjerenja navedena u idućim poglavljima.

Prvi bitan podatak kod implementacije binauralnog sustava uz praćenje položaja glave je položaj glave. Jedan od prethodno navedenih sustava za praćenje položaja glave potrebno je fiksno pričvrstiti na korisnika sustava, na primjer, na korištene okoušne (engl. *over-ear*) slušalice koje se pomiču na isti način kao i korisnikova glava (slika 2.16).

Takvi uređaji, koji se postavljaju fiksno na korisnikovu glavu, najčešće koriste IMU senzore za određivanje položaja glave. Te informacije potrebno je poslati na uređaj koji koristi položaj glave za daljnje računanje binauralnog signala, te je za potrebu slanja potrebno odrediti način zapisa informacija, pri čemu se najčešće koriste kvaternioni. Kvaternioni su matematički koncept korišten u različitim područjima poput računalne grafike, robotike i fizike. Kvaternioni proširuju ideju kompleksnih brojeva koristeći četiri dimenzije za njihov zapis, te je njihova česta primjena zapis podataka o rotaciji u prostoru [81]. Mogu se koristiti zajedno s drugim me-



**Slika 2.16:** Waves NX [80] uređaj za praćenje položaja glave postavljen na slušalice binauralnog sustava.

todama rotacije, poput Eulerovih kutova i rotacijskih matrica, ili kao alternativa njima, ovisno o primjeni. Bilo koja proizvoljna orijentacija u trodimenzionalnom prostoru okvira A u odnosu na okvir B može se predstaviti jediničnim kvaternionom  ${}^B_Aq$  definiranim na sljedeći način:

$${}^B_Aq = \begin{bmatrix} q_0 & q_1 & q_2 & q_3 \end{bmatrix}^T = \begin{bmatrix} \cos \frac{\alpha}{2} & e_x \sin \frac{\alpha}{2} & e_y \sin \frac{\alpha}{2} & e_z \sin \frac{\alpha}{2} \end{bmatrix}^T \quad (2.1)$$

gdje je " $\alpha$ " kut rotacije, a " $e$ " je jedinični vektor koji predstavlja os rotacije. Konjugat kvaterniona, uz pretpostavku jedinične norme, ekvivalentan je inverznom kvaternionu  ${}^B_Aq^*$  i opisuje inverznu rotaciju. Stoga se konjugirani kvaternion može koristiti za prikazivanje orijentacije okvira B u odnosu na okvir A:


$${}^B_Aq^* = {}^A_Bq = \begin{bmatrix} q_0 & -q_1 & -q_2 & -q_3 \end{bmatrix}^T \quad (2.2)$$

Za slanje zapisa o orijentaciji, potrebno je definirati protokol kojim će te informacije biti poslane u lanac binauralnog sustava. Prethodno opisani OSC protokol idealan je za takav zadatak, te je često korišten i preporučan za osobne sustave binauralne sinteze. Uređaj za praćenje položaja glave šalje podatke žičnom ili bežičnom komunikacijom na računalu na kojem se odvija postupak binauralne sinteze. Na računalu je potrebno osigurati programsko rješenje koje prima, te prosljeđuje informacije o položaju u digitalnu audio radnu stanicu (DAW, engl. *Digital Audio Workstation*).

U izabranom DAW programu, potrebno je izraditi Ambisonics predložak projekta višeg reda


(HOA, engl. *Higher Order Ambisonics*), uz povezivanje izvora i kanala (engl. *routing*) pogodno za binauralnu reprodukciju putem slušalica [82].

U navedenom predlošku postavlja se VST dodatak (engl. *Virtual Studio Technology*) koji prima informacije o položaju korisnikove glave putem OSC protokola, te primljene podatke o smjeru glave dinamički i u stvarnom vremenu koristi za binauralnu sintezu svih zvučnih izvora (slika 2.17).



**Slika 2.17:** Primjer VST dodatka za rotaciju zvučnog polja - IEM Suite Scene Rotator [83].

Uz VST dodatak za uključivanje podataka o položaju glave u binauralnu sintezu, za preciznu i prirodnu lokalizaciju zvučnih izvora potrebno je uključiti VST dodatak za binauralno dekodiranje (slika 2.18), pomoću kojeg se na ukupno 3D zvučno polje primjenjuje HRTF skup (generički ili po izboru korisnika), te ekvalizacija slušalica.



**Slika 2.18:** Primjer VST dodatka za binauralno dekodiranje - IEM Suite Binaural Decoder [83].

## Binauralno sintetizirani zvučni izvori

Kako bi se određeni zvučni izvor reproducirao na binauralnom sustavu, potrebno ga je postaviti u prethodno navedeni predložak u DAW programu, te na njega primijeniti VST dodatke koji će definirati točan smjer binauralno sintetiziranog zvučnog izvora u 3D virtualnom prostoru oko korisnikove glave. Zvučni izvor ne mora biti fiksiran, te je moguće automatizirati varijablu smjera da se stvori virtualni pomak izvora pomoću programiranja promjene vrijednosti parametara azimuta, nagiba ili valjanja. U tu svrhu, potrebno je koristiti binauralni stereo koder (slika 2.19).



**Slika 2.19:** Primjer VST dodatka za binauralno stereo kodiranje - IEM Suite Stereo Encoder [83].

Nakon navedenog koraka, DAW program šalje binauralno sintetiziranu zvučnu okolinu na uređaj za reprodukciju zvuka, tj. na slušalice.

### 2.4.4 Kašnjenje signala u sustavu binauralne sinteze

Kašnjenje signala smatra se jednim od ključnih problema u virtualnim sustavima [84]. Vremensko kašnjenje između pokreta korisnikove glave i odgovarajuće vizualne i zvučne reprodukcije sustava virtualne stvarnosti može rezultirati nepovoljnim učincima poput smanjene percepcije prisutnosti u virtualnom prostoru ili mučninu sličnu bolesti kretanja u vožnji [85, 86]. Dok je vizualno kašnjenje fokusirano na kinematičke ulaze i vizualne izlaze, kašnjenje audiosustava može se definirati kao vremenska razlika između generiranja i reprodukcije zvučnih signala u sustavu [87]. Budući da se nekim VR/AR aplikacijama pokušava postići uobičajena ljudska komunikacija, kašnjenje zvuka od jednog do drugog kraja prijenosnog lanca (engl. *end-to-end*) češća je u dijeljenim virtualnim okruženjima koja korisnicima mogu predstavljati izazov u do-



bivanju pravovremenog povratnog zvučnog signala od drugih. Stoga, dugo vrijeme kašnjenja audio signala također je značajan problem pri dizajniranju realističnih komunikacija u VR/AR sustavima. Iako su istraživanja vezana za kašnjenje i mjerenje kašnjenja u VR/AR sustavima većinski fokusirano na područje vizualnog kašnjenja [88, 89, 90, 91, 92], također postoje i istraživanja koja se fokusiraju na detekciju, percepciju i mjerenje kašnjenja audio signala u binauralnim sustavima [93, 94].

## 2.5 Primjena u industriji i proizvodi na tržištu

Razvojem binauralnih audiosustava s praćenjem položaja glave, na tržištu su se počeli pojavljivati proizvodi i programska podrška koja implementira binauralnu sintezu i praćenje orijentacije korisnikove glave. Apple [95] i Samsung [96] koriste novu generaciju slušalica s ugrađenim IMU senzorima kako bi ostvarili reprodukciju binauralnog prostornog zvuka. Apple omogućava integraciju novog sustava Dolby Atmos [97] koji je proizišao iz kino sustava, ali je dodatnom integracijom povećao tržišni značaj svoje tehnologije i izvan kino industrije.

Zbog sve većeg interesa krajnjih korisnika za virtualni prostorni zvuk i virtualnu stvarnost određene društvene mreže i internetske stranice s video i audio sadržajem također su omogućile objavu sadržaja virtualne i proširene stvarnosti (na primjer, YoutubeVR [98] i GoogleVR [99]).

Jedna od najvećih industrija koja ima potencijal proširiti uporabu audiosustava s praćenjem položaja glave je profesionalna glazbena industrija. Osim uređivanja Ambisonics sadržaja i prostornog zvuka na digitalnim audio radnim stanicama kao što su Reaper [100], Nuendo [101] ili Adobe [102], virtualna akustička okruženja otvaraju mogućnost replikacije profesionalnih studijskih uvjeta koristeći samo slušalice i uređaj za praćenje položaja glave. Takvu aplikaciju razvila je tvrtka Waves [80], zajedno s uređajem za praćenje položaja glave koji se montira na slušalice (slika 2.20). Uz Waves, postoje i drugi programski paketi koji repliciraju tonske studije, kao što je dearVR [103].

Jedno od područja industrije koje je pokrenulo dodatni razvoj i korištenje VR/AR tehnologije i sustava uz praćenje položaja glave u glazbenoj industriji je koncertna industrija. Koncertna industrija suočena je s pandemijom Covid-19 virusa 2020. godine [104], ali pandemija je posljedično potaknula razvoj VR aplikacija koje omogućuju korisnicima virtualno praćenje koncerta. Na primjer, MelodyVR [105] omogućava korisnicima virtualno praćenje koncerata pomoću pametnog telefona ili uređaja virtualne stvarnosti.

Zylia, tvrtka koja proizvodi audio uređaje za 3D audio snimanje i procesiranje, izradila je aplikaciju virtualne stvarnosti "Zylia Concert Hall 6DoF" [106], gdje korisnici mogu virtualno prošetati orkestrom i slušati kako se zvuk mijenja u ovisnosti o položaju korisnika (slika 2.21.). Navedena VR aplikacija je među prvim aplikacijama koja koristi šest stupnjeva slobode i integraciju kompleksnog skupa zvučnih izvora kao što je orkestar.



Slika 2.20: Waves NX programski paket i uređaj za praćenje položaja glave [80].



Slika 2.21: Virtualno okruženje orkestra u koncertnoj dvorani u aplikaciji "Zylia Concert Hall 6DoF" [106] .

## Poglavlje 3

# Ispitivanje performansi IMU senzora

Ovo poglavlje preuzeto je iz znanstvenih radova objavljenih u sklopu doktorskog istraživanja [64, 107], uz manje prilagodbe.

### 3.1 Preliminarna mjerenja statičkih performansi IMU senzora

Teško je procijeniti ukupnu kvalitetu IMU senzora temeljenu na dinamičkim mjerenjima koja traju samo nekoliko sekundi. Takva mjerenja nisu dovoljno duga da bi otkrila senzorsko klizanje koje se može pojaviti tijekom korištenja senzora. Senzorsko klizanje (engl. *sensor drift*) definira se kao postupna promjena ili devijacija izlaznih podataka senzora tijekom vremena, čak i kada ulazni uvjeti ostaju konstantni, to jest, kada su senzori nepomični [108]. Ovo odstupanje može nastati zbog različitih čimbenika kao što su promjene temperature, vlage, mehaničkog stresa unutar senzora, magnetskih smetnji ili starenja komponenti senzora. Senzorsko klizanje može utjecati na točnost i pouzdanost mjerenja koja se provode pomoću tih senzora, što može dovesti do pogrešnih rezultata (bez adekvatne kompenzacije odstupanja). Kako bi se otkrili potencijalni problemi sa senzorskim klizanjem, pogotovo na sensorima niske kvalitete [109, 110], potrebno je provesti dugotrajna statička mjerenja na IMU sensorima na različitim hardverskim platformama, uz onemogućavanje gibanja senzora. Takva mjerenja uobičajeno se provode u vremenskom periodu od nekoliko minuta pa čak do nekoliko sati. Allanova varijanca dokazani je alat za određivanje pouzdanosti senzora, pogotovo kada se uzme u obzir senzorsko klizanje [111]. Allanova varijanca je mjera klizanja parametara senzora u frekvencijski stabilnom konstantnom signalu (bez vanjske pobude). Koristi se u analizi stabilnosti frekvencijskih standarda i uređaja koji generiraju frekvencijski stabilne signale, poput oscilatora i atomskih satova. Allanova varijanca definira se kao srednja vrijednost kvadrata razlike između uzastopnih razlika u frekvenciji signala, uzimajući u obzir različite vremenske intervale. Matematički, za niz

uzastopnih mjerenja  $\tau$ , Allanova varijanca  $\sigma^2(\tau)$  izračunava se kao:

$$\sigma^2(\tau) = \frac{1}{2(N-1)} \sum_{i=1}^{N-1} (y_{i+1} - y_i)^2 \quad (3.1)$$

gdje je:


- $N$ : broj uzastopnih mjerenja,
- $y_i$ : mjerenje u vremenskom koraku  $i$ ,
- $\tau$ : vremenski interval između mjerenja.

Allanova varijanca se koristi kako bi se procijenila stabilnost signala, što omogućuje analizu različitih vrsta smetnji i njihov utjecaj na stabilnost signala.

Korjenovanjem Allanove varijance dobiva se Allanova devijacija, koja služi za određivanje nagiba linearnih dijelova grafa Allanove varijance u vremenu (oba parametra u grafu su prezentirana u logaritamskoj ljestvici). Pomoću navedenog nagiba, moguće je zaključiti o kojem tipu senzorskog klizanja na IMU sensorima se radi (slika 3.1), pri čemu su izdvojene relevantne vrijednosti za preliminarna statička mjerenja:

- -1, kvantizacijski šum,
- -1/2, 0 i +1/2, ostale vrijednosti,
- +1, nagib senzorskog klizanja.


Osim toga, rezultati analiza putem Allanove varijance počinju davati vrlo slične rezultate koji brzo konvergiraju prema određenoj prosječnoj vrijednosti nakon što se frekvencija uzorkovanja senzora poveća iznad 50 Hz [112].




**Slika 3.1:** Označene tipične vrijednosti nagiba Allanove varijance [113].

U prethodnom istraživanju [55], istražene su statičke performanse IMU senzora ugrađenih u Arduino ugradbene sustave i pametne telefone na odabranoj grupi uređaja mjerenjem Alla-

nove varijance za sve dostupne troosne IMU senzore. Dobiveni histogram izmjerenih podataka isčitanih s IMU senzora već može biti indikator potencijalnih problema s određenim IMU senzorima. Očekivana distribucija podataka trebala bi biti ona tipa Gaussove krivulje, kako je prikazano na slici 3.2a. Svaka asimetrija u distribuciji ukazuje na nepravilno ponašanje senzora tijekom razdoblja mjerenja. Narančasta isprekidana krivulja s normalnom Gaussovom distribucijom dodana je radi usporedbe, otkrivajući asimetriju izmjerenih vrijednosti ubrzanja (slika 3.2b).



**Slika 3.2:** (a) Histogram kutne brzine rotacije oko X osi izmjerene pomoću IMU senzora u pametnom telefonu; (b) Histogram ubrzanja duž Z osi izmjerenog pomoću IMU senzora u istom pametnom telefonu.



**Slika 3.3:** (a) Graf Allanove varijance u vremenu za podatke o kutnoj brzini, dobivene s IMU senzora pametnog telefona; (b) Graf Allanove varijance u vremenu za podatke o ubrzanju dobivene s IMU senzora istog pametnog telefona.

Još konkretniji zaključci mogu se utvrditi generiranjem grafa logaritma Allanove varijance i u ovisnosti o logaritmu proteklog vremena mjerenja, kako je prikazano na slici 3.3 za određeni pametni telefon koji je jedan od uređaja u daljnjem istraživanju. Graf na slici 3.3a pokazuje da

nema senzorskog klizanja pri mjerenju kutne brzine tijekom cijelog razdoblja mjerenja, budući da vrijednost Allanove varijance kontinuirano pada s vremenom. S druge strane, graf na slici 3.3b pokazuje lokalni minimum Allanove varijance za izmjereno ubrzanje u X i Y osi, koji se pojavljuje u određenom vremenskom trenutku nakon početka mjerenja. Povećanje iznosa Allanove varijance s vremenom u nastavku mjerenja jasan je pokazatelj senzorskog klizanja.

### **3.2 Metoda mjerenja dinamičkih performansi IMU senzora rotacijskom platformom**


Kao preliminarni korak za izvođenje dinamičkih mjerenja na ugradbenim sustavima i pametnim telefonima, bilo je potrebno koristiti sustav pomaka koji precizno izvodi definirane pokrete potrebne za mjerenje performansi sustava. Kontrolirana dinamička mjerenja IMU senzora već su provedena korištenjem robotske ruke [56], fiksnih pozicija s poznatim kutnim razlikama [114], konstrukcijom na bazi klackalice [115], te gimbal sustava [116]. Ljudski pokreti također su korišteni, u obliku pomicanja ruke s postavljenim uređajima za praćenje položaja ruke [117], i pomicanja cijele osobe s postavljenim uređajima za praćenje položaja noge [108]. U svrhu predloženih mjerenja, metoda mjerenja morala je biti precizno definirana. Drugim riječima, pokreti mjernog uređaja moraju biti ponovljivi i isti svaki put kako bi se olakšala usporedba različitih ispitivanih uređaja (DUT, engl. *Device Under Test*) koji sadrže IMU senzore.

Za dobivanje pomaka, korištene su motorizirane rotacijske platforme kako bi se osiguralo ravnomjerno i jednakomjerno kretanje svih ispitivanih uređaja. Korištenje rotacijskih platformi također je omogućilo i predvidljivo kretanje, kako bi se podaci dobiveni iz različitih uređaja mogli usporediti. Glavni zahtjev za rotacijsku platformu bio je konstantna i stabilna brzina rotacije.

Korištene su dvije platforme: prva je Bruel & Kjaer rotacijska platforma (tip 9640) s konstantnom brzinom rotacije iznosa jedan okretaj u 80 sekundi, odnosno 0.75 okretaja u minuti (engl. *Rounds Per Minute*), a druga je motorizirana DJ kontrolna jedinica *Rane Twelve MKII* čija je brzina rotacije prilagođena vinil pločama, to jest, 33 ili 45 okretaja u minuti. Za potrebe navedene metode mjerenja korištena je konstantna brzina rotacije iznosa 33 okretaja u minuti. Shema mjerenja i obje platforme vidljive su na slici 3.4.


Za testiranje njihovih IMU senzora u kontroliranim dinamičkim mjerenjima ispitano je pet pametnih telefona (Samsung Galaxy A50, iPhone 12 Pro, LG G6, Samsung Galaxy S10+, Xiaomi Redmi 5) i pet Arduino ugradbenih sustava (Arduino Uno Wifi Rev2 - dva uređaja, Arduino Nano 33 BLE - tri uređaja). Pametni telefoni su morali biti postavljeni u konfiguraciju nalik krugu kako bi se smanjio utjecaj stvarne pozicije IMU senzora u pametnom telefonu. U takvoj konfiguraciji, svi uređaji su se mogli istovremeno postaviti na motorizirane platforme. Za Arduino ugradbene sustave, bilo je potrebno izvršiti individualna mjerenja za svaku konfi-





**Slika 3.4:** Shema dinamičkog mjerenja uređaja s IMU senzorima na rotacijskoj platformi (a); B&K rotacijska platforma za mjerenje brzinom 0.75 okretaja u minuti (b); RANE motorizirani DJ kontroler koji se koristi kao rotacijska platforma za mjerenje brzinom 33 okretaja u minuti (c).

guraciju. Razlog takvoj konfiguraciji je potreba za USB vezom između prijenosnog računala i Arduino ugradbenog sustava kako bi se napajala konfiguracija Arduina i postizanje optimalne (najbrže) veze prijenosa podataka s IMU senzora. Iako je razmatrana mogućnost bežičnog prijenosa podataka, dostupna brzina prijenosa bežičnih podataka bila bi nedostatna za potrebe mjerne metode. Nadalje, kako bi se izbjeglo zapetljavanje USB kabela, prijenosno računalo također je moralo biti postavljeno i fiksirano na rotacijsku platformu (slika 3.5).



**Slika 3.5:** Mjerenje Arduino ugradbenog sustava na rotacijskoj platformi.

### 3.2.1 Izazovi pri provedbi mjerenja

Dinamička mjerenja IMU senzora popraćena su brojnim izazovima koje je potrebno prevladati, pri čemu je najveći od njih prikupljanje rezultata mjerenja i izračun orijentacije mjerenih uređaja. Budući da su postupci mjerenja koji se koriste na pametnim telefonima i ugradbenim sustavima djelomično različiti, glavni izazovi opisani su za različite uređaje u zasebnim odjeljcima.

#### Mjerenje pametnih telefona


Za prikupljanje sirovih podataka s IMU senzora pametnih telefona (akcelerometar - troosno ubrzanje, žiroskop - troosna kutna brzina i magnetometar - troosno magnetsko polje) i već izračunate orijentacije (azimut, propinjanje i valjanje) korištena je aplikacija *Matlab Mobile* [118]. Aplikacija omogućuje prikupljanje podataka s proizvoljnom frekvencijom uzorkovanja do 100 Hz. Početna frekvencija uzorkovanja postavljena je na 100 Hz za svih pet telefona u aplikaciji. Aplikacija *Matlab Mobile* bilježi izmjerene podatke u tablicu s jedinstvenom vremenskom oznakom za svaki mjereni parametar (jedna vremenska oznaka za jedan mjereni senzor, postavljena za sve tri osi). Iako aplikacija *Matlab Mobile* automatski izračunava orijentaciju uređaja, korištenjem prikupljenih neobrađenih podataka i specijaliziranih funkcija u Matlabu [119], moguće je izračunati orijentaciju u fazi obrade podataka, što je korisno za usporedbu različitih metoda izračuna orijentacije i korištenih mjernih parametara.

Nakon provedenih mjerenja na pet pametnih telefona, uočeni su problemi koji znatno utječu na točnost podataka dobivenih iz senzora, te su opisani u sljedećim paragrafima.

**Frekvencija uzorkovanja:** Iako se očekivalo da će pametni telefoni imati konstantnu frekvenciju uzorkovanja podataka dobivenih iz IMU senzora, kod jednog uređaja frekvencija je varirala značajno. Pojedinačni uzorci uzimani su s vremenskim korakom od 7 umjesto 10 milisekundi što odgovara nominalnoj frekvenciji uzorkovanja od 100 Hz, kako bi sugerirala frekvencija uzorkovanja postavljena na 100 Hz, čime se dobiva stvarna frekvencija uzorkovanja u iznosu oko 142 Hz. Iako navedena frekvencija predstavlja veliko odstupanje, ona je detektirana u slučaju samo jednog pametnog telefona, no ni većina ostalih telefona nije imala stalnu frekvenciju uzorkovanja od 100 Hz. Na slici 3.6 vidljiv je primjer odstupanja broja uzoraka tijekom 70 sekundi uzorkovanja.

Slijedom toga, utvrđena su dva izvora nesigurnosti: nejedinstvena vremenska oznaka za svako mjerenje IMU senzora i neujednačena frekvencija uzorkovanja tijekom prikupljanja podataka. Budući da je korišten unaprijed programirani mjerni sustav, bez mogućnosti izravnog pristupa podacima senzora, ta su se ograničenja morala uzeti u obzir pri procjeni preciznosti i kvalitete podataka o položaju.





**Slika 3.6:** Primjer varijacije frekvencije uzorkovanja tijekom testnog mjerenja IMU senzora pametnog telefona.


Kao što je već spomenuto, *Matlab Mobile* zapisuje jedinstvenu vremensku oznaku za svaki uzorak dobiven preko IMU senzora pametnog telefona. Vremenska oznaka može se koristiti za određivanje stvarne frekvencije uzorkovanja, a podaci dobiveni s različitih uređaja mogu se sinkronizirati. Na jednom od pametnih telefona došlo je do nepodudarnosti vremenske baze u odnosu na preostale uređaje toga tipa. Iako je uređaj prošao točno određen broj rotacija zajedno sa svim ostalim uređajima, njegovi spremljeni podaci nisu odgovarali stvarnom broju rotacija. Pregledom podataka potvrđeno je da je aplikacija *Matlab Mobile* pogrešno zapisala vremensku oznaku, a ukupno zapisano vrijeme mjerenja bilo je kraće od stvarnog trajanja mjerenja, što ukazuje na problem s frekvencijom takta, tj. problem s oscilatorom koji se koristi u tu svrhu na pametnom telefonu.

Kako bi se riješio problem različitih frekvencija uzorkovanja pametnih telefona, razvijen je postupak sinkronizacije za dobivanje usporedivih podataka sa svih uređaja. Za pametne telefone koji imaju jedinstvene vremenske oznake dodane svojim mjernim podacima, svi su podaci ponovno uzorkovani uz frekvenciju uzorkovanja iznosa 200 Hz, a za izračunavanje podataka za nove intervale korištena je linearna interpolacijska funkcija. Slijedom toga, neobrađeni podaci dobiveni od svih senzora i izračunati podaci o orijentaciji postali su izravno usporedivi zbog zajedničke vremenske oznake utvrđene za sve uređaje. Novom, jednako raspoređenom vremenskom osi s koracima od 5 milisekundi također je riješena neusklađenost frekvencije uzorkovanja koja je uzrokovala poteškoće u izravnoj usporedbi prikupljenih podataka. Također,

nakon testnih mjerenja utvrđeno je da je u nekim slučajevima magnetometar na određenim uređajima imao različitu, nižu frekvenciju uzorkovanja od akcelerometra i žiroskopa. Za izračun orijentacije pomoću Matlab-a, podatke iz magnetometra trebalo je uzorkovati uz istu frekvenciju uzorkovanja kao i za podatke dobivene na ostalim sensorima.

**Magnetske smetnje:** Orijentaciju uređaja moguće je prikazati relativno od početnog trenutka, ili relativno iz referentnog položaja nakon kalibracije uređaja. Za apsolutnu orijentaciju uređaja, magnetsko polje Zemlje ključno je za pronalaženje odgovarajuće orijentacije pomoću referentnog usmjerenja sjever-jug. Bez magnetskog polja kao reference, kretanje poput rotacije platformi može se opisati samo u odnosu na poznatu početnu referentnu orijentaciju, ali ne i u apsolutnom smislu. Više informacija može se prikupiti ako je dostupan i položaj pametnog telefona, ali to zahtijeva dodatne informacije s GPS senzora pametnog telefona.


Zbog rada motora rotacijske platforme, u podacima dobivenim iz magnetometra dolazi do nagle promjene vrijednosti magnetskog polja pri paljenju motora. Zbog konstantnog magnetskog polja tijekom mjerenja, magnetsko polje motora zbraja se s magnetskim poljem Zemlje, te je rezultirajuće magnetsko polje vidljivo u podacima magnetometra kao stalni pomak odgovarajućih izmjerenih vrijednosti nastao zbog utjecaja rada motora (slika 3.7).



**Slika 3.7:** Troosni podaci o magnetskom polju neposredno prije i poslije uključivanja rotacijske platforme (vidljiva nagla, impulsna promjena magnetskog polja pri paljenju motora).

Uklanjanjem podataka dobivenih iz magnetometra iz izračuna orijentacije, čime u izračun ulaze samo podaci s akcelerometra i žiroskopa [120], izračun orijentacije postaje znatno precizniji za pametne telefone. Kako bi se odredio utjecaj magnetskog polja, moguće je prikazati izračunatu orijentaciju sa i bez podataka magnetometra uključenih u izračun. Na slici 3.8 prikazana je usporedba vrijednosti orijentacije izravno izmjerene pomoću aplikacije *Matlab Mobile*

instalirane na pametnom telefonu, podataka izračunatih iz svih dostupnih podataka IMU senzora, te podataka izračunatih samo iz podataka akcelerometra i žiroskopa.



**Slika 3.8:** Azimut pametnog telefona izračunat: (a) ugrađenom funkcijom u aplikaciji *Matlab Mobile*; (b) pomoću Matlab skripte na temelju podataka sa svih senzora; (c) na temelju podataka dobivenih samo iz akcelerometra i žiroskopa (bez podataka iz magnetometra).

### Mjerenje ugradbenih sustava

Ugradbeni sustavi, uz izazove vezane za magnetske smetnje slične onima uočenim kod pametnih telefona, donose i nove izazove vezane uz postupak uzorkovanja. Važno je primijetiti da odabrani ugradbeni sustavi nisu nužno opremljeni istim sensorima. Svi odabrani ispitivani uređaji posjeduju troosni akcelerometar i žiroskop, ali samo neki od njih imaju troosni magnetometar. Proizvođači ugradbenih sustava u dokumentaciji navode podatke o frekvenciji uzorkovanja IMU komponenti. Magnetometar uobičajeno ima nižu frekvenciju uzorkovanja u usporedbi s druga dva senzora, slično kao i kod pametnih telefona. Na primjer, Arduino Nano 33 BLE omogućuje maksimalnu frekvenciju uzorkovanja za akcelerometar i žiroskop iznosa 104 Hz, a za magnetometar je frekvencija uzorkovanja 20 Hz, što predstavlja značajnu razliku.


U usporedbi s pametnim telefonima, stopa prikupljanja podataka za Arduino platforme definirana je memorijskim međuspremnikom ugradbenog sustava, u kojem se pohranjuju vrijednosti iščitane u traženom trenutku. Ako se vrijednosti iz senzora uzimaju brže nego što se memorijski međuspremnik ažurira, numerička vrijednost zapisana u prethodnom trenutku bit će ponovljena. Stoga se stvarna frekvencija uzorkovanja ugradbenog sustava može samo pretpostaviti. Za razliku od pametnih telefona, Arduino ugradbeni sustavi mjere vrijeme od početka postupka prikupljanja podataka i zapisuju zajedničku relativnu vremensku oznaku za sve izmjerene podatke (slika 3.9).

Podaci iz ugradbenih sustava prikupljeni su serijskom žičnom vezom, spremljeni lokalno na računalo, a zatim obrađeni pomoću odgovarajućih Matlab funkcija. Pojedinačni broj uzoraka u

|   | Time       | 1<br>AxN1 | 2<br>AyN1 | 3<br>AzN1 | 4<br>GxN1 | 5<br>GyN1 | 6<br>GzN1 | 7<br>MxN1 | 8<br>MyN1 | 9<br>MzN1 |
|---|------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| 1 | 142 sec    | -0.0500   | 0.1200    | 0.9900    | 5.3700    | 4.6400    | -172.9700 | 6.3000    | 67.4200   | -39.6900  |
| 2 | 142.01 sec | -0.0500   | 0.1200    | 0.9900    | 5.3700    | 4.7600    | -173.1000 | 6.3000    | 67.4200   | -39.6900  |
| 3 | 142.02 sec | -0.0500   | 0.1200    | 0.9900    | 5.3700    | 4.7600    | -173.0300 | 3.8000    | 67.9400   | -41.3100  |
| 4 | 142.03 sec | -0.0500   | 0.1200    | 0.9900    | 5.5500    | 4.6400    | -173.0300 | 3.8000    | 67.9400   | -41.3100  |
| 5 | 142.04 sec | -0.0500   | 0.1200    | 1         | 5.4300    | 4.8800    | -173.1000 | 3.8000    | 67.9400   | -41.3100  |
| 6 | 142.04 sec | -0.0500   | 0.1200    | 0.9900    | 5.6200    | 4.7000    | -173.2200 | 3.8000    | 67.9400   | -41.3100  |
| 7 | 142.05 sec | -0.0500   | 0.1200    | 0.9900    | 5.5500    | 4.5200    | -173.2200 | 3.8000    | 67.9400   | -41.3100  |
| 8 | 142.06 sec | -0.0500   | 0.1200    | 0.9900    | 5.6800    | 4.6400    | -173.1600 | 3.8000    | 67.9400   | -41.3100  |

**Slika 3.9:** Primjer svih izmjerenih podataka sa IMU senzora za Arduino Nano 33 ugradbeni sustav (A - ubrzanje, G - kutna brzina, M - magnetsko polje).

svakoj sekundi mjerenja može odstupati od konstantnog broja kao što je odstupao i kod mjerenja na pametnim telefonima (slika 3.10). Stoga nesigurnost izračuna orijentacije zbog neujednačene frekvencije uzorkovanja predstavlja izazov i na ugradbenim sustavima.



**Slika 3.10:** Primjer varijacije frekvencije uzorkovanja ugradbenog sustava Arduino Nano 33.


Budući da Arduino ugradbeni sustavi nemaju točno određenu frekvenciju uzorkovanja, svi su podaci ponovno uzorkovani na jedinstvenu frekvenciju uzorkovanja iznosa 100 Hz, što je rezultiralo stabilnim vremenskim korakom osvježavanja podataka od 10 milisekundi. I za ugradbene je sustave primijenjen isti postupak linearne interpolacije između izmjerenih vrijednosti, kao i onaj koji se koristio za pametne telefone, u svrhu ponovnog izračuna podataka koje daju senzori u ugradbenim sustavima.

### 3.2.2 Rezultati mjerenja

Budući da su korištene rotacijske platforme mijenjale samo azimut ispitanih uređaja za  $360^\circ$  u jednom ili više punih okreta, najjednostavniji način usporedbe svih uređaja je upravo međusobna usporedba izmjerenih, tj. izračunatih azimuta.

#### Rezultati mjerenja pametnih telefona


S obzirom na to da Bruel & Kjaer rotacijska platforma ima malu brzinu rotacije, pretpostavljeno je da će se izračunati podaci o azimutu odlikovati visokom točnošću. Nakon izračuna rezultata, ustanovljeno je da je samo jedan pametni telefon uspio adekvatno potisnuti smetnje magnetskog polja pri izračunu orijentacije, te osigurao prikaz ispravnih podataka o azimutu. Čak i uz algoritam koji koristi samo podatke akcelerometra i žiroskopa u izračunu, samo su dva pametna telefona uspjela proizvesti podatke o orijentaciji zadovoljavajuće točnosti (slika 3.11).



**Slika 3.11:** Usporedba izračunatog azimuta pametnih telefona na rotacijskoj platformi brzine vrtnje  $0,75$  okretaja u minuti, uz korištenje direktnih podataka s IMU senzora, bez korištenja podataka s magnetometra (A - Samsung Galaxy A50, I - iPhone 12 Pro, L - LG G6, S - Samsung Galaxy S10+, X - Xiaomi Redmi 5).


Za DJ rotacijsku platformu, izmjereni azimuti značajno bolje su se podudarali sa stvarnim vrijednostima nego što je to slučaj kod Bruel & Kjaer rotacijske platforme. Razlike se mogu primijetiti kada se koristi ugrađeni direktni postupak za izračunavanje azimuta zbog značajnog vremenskog odstupanja za jedan od pametnih telefona, dok za neke modele azimut ne slijedi ravnu liniju koja pokazuje stvarne vrijednosti (engl. *ground truth*) (slika 3.12).

Azimut koji je izračunat pomoću vlastite skripte u Matlabu iz podataka sa sva tri IMU



**Slika 3.12:** Usporedba izračunatog azimuta pametnih telefona na rotacijskoj platformi brzine 33 okretaja u minuti, uz *Matlab Mobile* direktni izračun azimuta.


senzora značajno je precizniji, kao što je prikazano na slici 3.13a. U skladu s očekivanjima, najbolji rezultati dobiveni su kada se podaci iz magnetometra izostave iz izračuna azimuta. Izračunate vrijednosti azimuta vrlo su bliske stvarnima, uz minimalno međusobno odstupanje izračunatih podataka dobivenih za različite pametne telefone (slika 3.13b).



**Slika 3.13:** (a) Usporedba izračunatog azimuta pametnih telefona na rotacijskoj platformi brzine 33 okretaja u minuti, uz korištenje direktnih podataka sa svih IMU senzora; (b) Usporedba izračunatog azimuta pametnih telefona na rotacijskoj platformi brzine 33 okretaja u minuti, uz korištenje direktnih podataka s IMU senzora, bez podataka s magnetometra.


## Rezultati mjerenja ugradbenih sustava

Izračun azimuta za Arduino ugradbene sustave postavljene na Bruel & Kjaer rotacijsku platformu pokazuje probleme jednake onima uočenim kod pametnih telefona. Točniji rezultati dobiveni su izračunima koji ne uključuju podatke iz magnetometra, iako je izostavljanjem magnetometra iz izračuna za neke uređaje dobivena velika pogreška u smislu odstupanja od očekivane linearne promjene azimuta u ovisnosti o vremenu (slika 3.14). Za brzu rotacijsku platformu, smisleni rezultati dobivaju se samo s podacima iz sva tri IMU senzora, pa je usporedba načinjena samo za ona tri uređaja koja sadrže sve tri vrste IMU senzora. Budući da jedan od uređaja pokazuje pogrešku u vremenskoj oznaci, rezultati pokazuju značajno odstupanje od samog početka mjerenja (slika 3.15).



**Slika 3.14:** Usporedba izračunatog azimuta Arduino ugradbenih sustava na rotacijskoj platformi brzine 0,75 okretaja u minuti, uz korištenje direktnih podataka s IMU senzora, bez podataka s magnetometra (U1, U2 - Arduino Uno Wifi Rev2; N1, N2, N3 - Arduino Nano 33 BLE).

Iako je problem utjecaja magnetskog polja rotacijskih mjernih uređaja na preciznost izračuna orijentacije moguće riješiti uklanjanjem podataka s magnetometra iz izračuna, podaci s magnetometra su važni za smanjenje senzorskog klizanja uređaja za praćenje položaja glave. Zbog navedenog razloga, bilo je potrebno osmisliti dodatnu metodu mjerenja navedenih sustava, koja je opisana u potpoglavlju 3.3.



**Slika 3.15:** Usporedba izračunatog azimuta Arduino ugradbenih sustava na rotacijskoj platformi brzine 33 okretaja u minuti, uz *Matlab Mobile* direktni izračun azimuta.

### 3.3 Metoda mjerenja performansi IMU senzora njihovom

Poboljšana metoda mjerenja performansi IMU senzora (u usporedbi s metodom predstavljenom u potpoglavlju 3.2) trebala bi omogućiti provedbu dinamičkih mjerenja s promjenjivom kutnom brzinom koja se mogu primijeniti na različite ispitivane uređaje, te otkloniti potencijalne smetnje i probleme uočene pri provedbi mjerenja prethodno opisanom metodom. Kako bi se osigurala maksimalna točnost i minimizirale pogreške u mjerenju, bilo je potrebno obratiti posebnu pažnju na sljedeće zahtjeve:


- Značajan zahtjev ovog mjerenja je da rezultati mjerenja budu usporedivi. Stoga, mjerenja su se morala provoditi istovremeno za sve mjerene uređaje. Nadalje, uređaji trebaju biti postavljeni na način koji će osigurati da njihovi izlazni podaci s IMU senzora zadovolje kriterij izravne usporedbe rezultata.
- Postava mjerenja trebala je omogućiti istovremeno postavljanje različitih DUT uređaja na mjerni sustav.
- Različiti uređaji koji se mjere u isto vrijeme predstavljaju dodatni problem vremenske sinkronizacije svih prikupljenih podataka. Dok neki od mjerenih uređaja imaju mogućnost pružanja informacija o svjetskom vremenu (GMT, engl. *Greenwich Mean Time*) ili koordiniranom univerzalnom vremenu (UTC, *Coordinated Universal Time*), čime se izbjegava potreba za sinkronizacijom, drugi uređaji nemaju tu funkcionalnost. Općenito, unutarnji satovi ispitivanih uređaja nisu sinkronizirani, zbog čega je bilo potrebno osmisliti i primijeniti mehanizam sinkronizacije.



- Za prikupljanje podataka o orijentaciji u stvarnom vremenu, prijenos podataka treba biti robustan i stabilan. Bežični prijenos ne udovoljava ovom zahtjevu i uvodi kašnjenje signala u prijenos podataka. Prijenos podataka pomoću kabela je optimalna opcija, posebno jer se koristi i za napajanje ispitivanih uređaja.
- Osim podataka iz akcelerometra i žiroskopa, podaci dobiveni iz magnetometra povećavaju točnost sustava. Kako bi se izbjegao utjecaj parazitnih magnetskih polja koji bi utjecali na podatke sa magnetometra, trebalo je potpuno izbjeći korištenje elektromehaničkih motora i bežičnih uređaja, to jest, bilo je potrebno osigurati da se ispitivani uređaji nalaze što dalje od potencijalnih izvora magnetskog polja u laboratoriju.

### 3.3.1 Postava mjerenja i izbor testnih uređaja

Rješenje koje udovoljava ovim posebnim zahtjevima je postava koja koristi jednostavno matematičko (gravitacijsko) njihalo (slika 3.16). Slična rješenja su implementirana u drugim istraživanjima [121, 122].



**Slika 3.16:** Idealno gravitacijsko njihalo [123].

Iako se uređaji i u njih ugrađeni senzori nisu mogli postaviti na način da zauzimaju istu poziciju u prostoru, bilo ih je moguće postaviti na način da se izbjegne utjecaj razlika u pozicioniranju uređaja na izmjerene podatke. Bilo je potrebno konstruirati postavu u kojoj se svi uređaji mogu pozicionirati na njihalo, tako da se prikupljeni podaci istovremeno bilježe za sve uređaje tijekom istog mjerenja. Sinkronizacija vremena postiže se generiranjem snažnog mehaničkog podražaja (udarac njihala čvrstim predmetom) koji se bilježi na svim sensorima


prije i poslije svakog mjerenja. Budući da se željeno kretanje ostvaruje djelovanjem gravitacije Zemlje, nisu potrebni motori koji bi potencijalno bili izvori magnetskih smetnji. Njihalo je bilo smješteno u okruženje bez izvora magnetskog polja kako bi se minimizirale moguće magnetske smetnje iz drugih izvora. Mali, jasno definirani raspon pokreta njihala i njegov dizajn općenito omogućuju upotrebu žičanih veza do ispitivanih uređaja.

Postava mjerenja sastavljena je uporabom stropnih nosača kao točke ovjesa njihala (načinjenih pomoću 3D pisača), dugi aluminijski štap, drvenu platformu na kraju štapa na koju su postavljeni ispitivani uređaji, te dodatan uteg postavljen neposredno ispod drvene platforme, u svrhu stabilizacije njihanja i manju ovisnost njihanja o broju postavljenih uređaja na njihalo. Računalo s odgovarajućim žičnim vezama koristilo se za prijenos podataka s uređaja i za njihovo napajanje. Plastični stropni nosači postavljeni su na strop laboratorija na visini od 3,2 metra. Metalna osovina koja se proteže između dva nosača prisiljava njihalo na kretanje u samo jednoj ravnini. Rotacijsko trenje koje se pojavljuje tijekom kretanja njihala i osovine smanjeno je korištenjem para kugličnih ležajeva visoke klase na krajevima osovine. Aluminijski štap izrađen je od 3 metra dugog komada aluminijskog profila tankog presjeka u obliku slova "U". Ovaj oblik korišten je kako bi se osigurala jednostavna i laka instalacija žičnih veza uz održavanje krutosti štapa. Drvena platforma bila je pričvršćena na štap pomoću plastičnog spojnog elementa načinjenog pomoću 3D pisača. Platforma je morala biti okomita na štap kako bi polumjer rotacije bio isti za sve ispitivane uređaje koji su na nju postavljeni. Budući da je masa drvenog nosača mala, ispod nje je dodan čelični uteg kako bi se povećala pokretna masa njihala i spustio centar mase cijelog njihala. Veća masa uzrokuje veću kinetičku energiju njihala, što rezultira ujednačenim pokretima njihala. Osim toga, dodana masa omogućava dulje trajanje mjerenja, jer omogućuje njihalu da se kreće dulje i načini veći broj titraja prije nego što se zaustavi. Postava mjerenja prikazana je na slici 3.17, na kojoj su označeni krajnji položaji njihala na obje strane i ravnotežni položaj u sredini.

U dva krajnja položaja njihala, ubrzanje pokretne mase ima svoj maksimum, a kutna brzina je iznosa nula. U ravnotežnom položaju, pokretna masa je na svojoj najnižoj točki, kutna brzina je na svojem maksimumu, a ubrzanje je iznosa nula. Važno je napomenuti da su svi zvučnici vidljivi u pozadini pomaknuti dovoljno daleko od mjerne postave kako bi se minimizirao utjecaj njihovog magnetskog polja.

Izvršena mjerenja u sklopu ovog doktorskog istraživanja, uz uporabu opisane mjerne postave, usredotočena su na dvije danas često korištene vrste uređaja s mogućnošću praćenja položaja:

- Pet ispitivanih uređaja s IMU sensorima. Tri su ugradbeni sustavi temeljeni na Arduino platformama s vanjskim čipom IMU senzora, a dva su Arduino ugradbeni sustavi s već ugrađenim IMU čipom. Mikrokontroleri i senzori označeni su kako slijedi: LSM6DS3 (vanjski senzorski modul), NanoInt (unutarnji), UnoInt (unutarnji), ICM40608 (vanjski), i



**Slika 3.17:** Mjerna postava temeljena na gravitacijskom njihalu, postavljena u slušaonici Zavoda za elektroakustiku na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu.

DOFv2 (vanjski). Oznake odgovaraju njihovom čipu IMU senzora, redom: LSM6DS3, LSM9DS1, LSM6DS3, ICM-20600 i MPU-9250.

- Pet pametnih telefona različitih proizvođača i u različitom cjenovnom rangu. Korišteni modeli su bili Samsung S21, LG G6, Apple iPhone 12 Pro, Xiaomi POCOx3NFC i Samsung A50, te su označeni kao S21, G6, iPhone, POCO i A50.

U znanstvenom radu objavljenog u sklopu doktorskog istraživanja [107], bio je izmjeren i jedan sustav za virtualnu stvarnost, s omogućenim pristupom sirovim IMU podacima. Navedeni sustav nije korišten kao dio istraživanja u Poglavljima 4 i 5, te zbog toga rezultati navedenog sustava neće biti predstavljeni u ovoj disertaciji.


### 3.3.2 Obrada podataka s IMU senzora i izračun položaja

Frekvencija uzorkovanja ovisi o vrsti mjerenih parametara i o vrsti ispitivanih uređaja. Ugrađeni sustavi imali su frekvenciju uzorkovanja za podatke o akceleraciji i žiroskopu u rasponu od 70 do 150 Hz, a za pametne telefone je frekvencija uzorkovanja bila oko 100 Hz.

U ispitivanju su se koristili uređaji koji nemaju jedinstveni i uniformni format izlaznih podataka. Na primjer, kutna brzina mogla je biti izražena u stupnjevima po sekundi, ali i u radijanima po sekundi, dok se ubrzanje moglo biti izraženo u  $m/s^2$ , ali i u  $g$ . Svi ispitivani uređaji imali su podatke o ubrzanju koji koriste gravitacijsko ubrzanje Zemlje. Položaj i orijentaciju IMU senzora unutar uređaja u odnosu na orijentaciju njegovog kućišta nije bilo jednostavno odrediti, zbog nedostatka tehničkih informacija i dokumentacije o uređajima. Zbog toga, bilo je potrebno odrediti referentni koordinatni sustav za svaki uređaj prije početka ispitivanja, te uniformirati izlazne podatke sa svih uređaja kako bi bili pogodni za izravne usporedbe i za naknadne izračune orijentacije. Drugim riječima, očitavanja senzora dobivena s različitih uređaja trebala su biti

usporediva. Da bi se to postiglo, ispitivani uređaji postavljeni su u statičkim uvjetima, pri čemu je prisutna samo gravitacija Zemlje kao izvor stalnog ubrzanja. Za svaki uređaj proveden je skup mjerenja, a orijentacija uređaja mijenjala se od mjerenja do mjerenja, pri čemu se pazilo na usmjerenje sustava za mjerenje u sve tri osi. Faktori korekcije magnituda izračunavati su iz dobivenih podataka za sve tri osi svakog uređaja. U konačnoj fazi obrade sirovih podataka, odgovarajući korekcijski faktori primijenjeni su na sirove podatke dobivene iz svakog senzora, čime je omogućena izravna usporedba sirovih podataka dobivenih iz različitih uređaja, kao i izravna usporedba izračunatih vrijednosti parametara orijentacije.

Kako bi se riješio problem usklađivanja svih podataka u vremenu, svi su uređaji vremenski usklađeni korištenjem snažnog mehaničkog impulsa na početku i na kraju svakog mjerenja. Učinak takve sinkronizacije vidljiv je na primjeru grafičkog prikaza izmjerenih podataka. Bez navedene sinkronizacije, ne bi bilo moguće odrediti zajedničku vremensku bazu za sve izmjerene podatke, čime rezultati ne bi bili izravno usporedivi. Razlika između nesinkroniziranih i sinkroniziranih podataka dobivenih iz akcelorometara ispitivanih uređaja za os X koja odgovara smjeru gibanja (navesti kojem) prikazana je na slici 3.18a.



**Slika 3.18:** Usporedba sirovih podataka akcelorometra izmjerenih u osi elevacije prije i poslije obrade: (a) sinkronizacija i (b) normalizacija.

Postupak normalizacije drugi je dio faze obradbe podataka, a cilj je uskladiti amplitudu sirovih IMU podataka dobivenih iz različitih uređaja (slika 3.18b). Opisana obrada primijenjena na IMU podatke olakšava izravnu usporedbu različitih uređaja i čini sve kasnije izračune znatno jednostavnijima. Neovisno o obrađenim podacima, svi sirovi podaci s IMU senzora prikupljeni tijekom mjerenja spremljeni su u jedinstvenoj bazi podataka u njihovom izvornom obliku.

Za olakšavanje izravne usporedbe sirovih IMU podataka dobivenih iz uređaja i izračunatih

podataka orijentacije, uređaji pri mjerenju su postavljeni na ispitnu platformu njihala na točno određen način. Konkretno, IMU senzori u tim uređajima poravnati su uz liniju koja je okomita na ravninu u kojoj se njihalo kreće. Takvo postavljanje osigurava da svi senzori pokazuju isti raspon kutnog pomaka. Osim toga, fizička orijentacija senzora u uređajima treba biti usklađena u sve tri osi, što bi osiguralo usklađenost koordinatnih sustava svih senzora. U stvarnosti, položaj i orijentacija IMU senzora unutar uređaja u koje su ugrađeni (pametni telefoni) obično su nepoznati. Čak i kada je orijentacija senzora dobro dokumentirana i poznata, izuzetno je teško postaviti i orijentirati uređaje u skladu s prethodno navedenim zahtjevima, te postoji vjerojatna mogućnost odstupanja od navedenog pri postavljanju ispitivanog uređaja, tj. IMU senzora unutar uređaja.


Umjesto sirovih IMU podataka, kontrolni podatak potreban za binauralnu sintezu je orijentacija uređaja/IMU senzora. U ovom ispitivanju, orijentacija uređaja izračunata iz sirovih IMU podataka dobivena je koristeći specijaliziranu MATLAB funkciju [120]. Usporedba izračunate orijentacije omogućila je otkrivanje potencijalnih razlika u položaju i/ili orijentaciji senzora kao posljedice odstupanja pri postavljanju uređaja na platformu njihala za potrebe mjerenja. Kako bi se izbjegao dugotrajan i vremenski zahtjevan proces korekcije i usklađivanja položaja i/ili orijentacije uređaja na platformi njihala, odlučeno je da se početna orijentacija izračunata za svaki uređaj na početnoj točki njihala uzme kao njegova individualna referenca. Relativna orijentacija dobivena na taj način za sve uređaje potom je uspoređena kako bi se utvrdilo postoje li stvarne razlike između uređaja, te je potvrđeno da su te razlike zanemarive.

### 3.3.3 Rezultati mjerenja

Ovo potpoglavlje predstavlja rezultate ispitivanja dobivene korištenjem predložene metode mjerenja. Uspoređeni su uređaji iste vrste, te je napravljena usporedba različitih vrsta ispitivanih uređaja. Prvo su prikazani rezultati dobiveni s ugradbenim sustavima, zatim rezultati dobiveni za pametne telefone. Na kraju je prikazana usporedba rezultata ugradbenih sustava i pametnih telefona. Za svako mjerenje su spremljeni sirovi podaci, a orijentacija je izračunata u postupku naknadne obrade korištenjem posebne MATLAB funkcije (kao što je opisano u prethodnom potpoglavlju), kako bi se omogućila izravna usporedba svih vrsta i kombinacija uređaja. Mjereni podaci uključuju interno vrijeme svakog uređaja, podatke s akcelerometra i podatke sa žiroskopa. Svaki uređaj prilagođen je samo za prikupljanje i slanje sirovih IMU podataka bez obavljanja dodatnih računalnih operacija, ako je to bilo moguće.

Slika 3.19 prikazuje sirove podatke izmjerene pomoću ugradbenih sustava za cijelo trajanje mjerenja.

Grafovi u gornjem redu slike 3.19 prikazuju sirove podatke akceleracije uređaja. Smjerovi osi odgovaraju koordinatnom sustavu prikazanom na slici 3.20b. Kao što je bilo očekivano, najveće amplitude nalaze se u smjeru Z osi, dok su vrijednosti akceleracije u smjeru ostale



**Slika 3.19:** Sirovi podaci akcelerometra i žiroskopa u smjeru sve tri osi, izmjereni pomoću ugradbenih sustava.


dvije osi znatno niže, ali ne i zanemarive. Podaci o kutnoj brzini dobiveni sa žiroskopa mjereni su istovremeno kada i akceleracija. Maksimalna amplituda kutne brzine očekivano se dobiva za rotaciju oko X osi. Donji red slike 3.19 prikazuje sirove podatke dobivene sa žiroskopa za sve tri osi. Dodatnom analizom akceleracije u smjeru X osi otkriva se da su podaci izmjereni pomoću ugradbenih sustava NanoInt i LSM6DS3 zapravo izvan faze u usporedbi s podacima dobivenim s ugradbenih sustava DOFv2, ICMak i UnoInt, kao što je prikazano na slici 3.20a. Razlog navedene razlike u fazi je torzijsko titranje platforme na kojoj su uređaji postavljeni tijekom mjerenja, što je označeno zelenim strelicama na fotografiji prikazanoj na slici 3.20b. Ključni podatak za razumijevanje dobivenih rezultata je da su ugradbeni sustavi NanoInt i LSM6DS3 postavljeni na lijevoj strani platforme, dok su preostala tri DUT uređaja postavljena na desnoj strani. Ista razlika primijećena je u podacima akceleracije za ostale dvije osi. S druge strane, torzijsko kretanje drvenog nosača nije utjecalo na očitavanja podataka sa žiroskopa, gdje očitavanje nije bilo izvan faze, te su sve rotacije bile u istom smjeru, kako se i očekivalo.

Izmjereni podaci potvrđuju očekivanje da su akceleracija u smjeru Z osi i kutna brzina u smjeru rotacije oko X osi najrelevantniji za opisivanje gibanja njihala korištenog u postavi ispitivanja. Slika 3.21 prikazuje usporedbu ovih dvaju parametara i izračunate orijentacije za pet mjerenih pametnih telefona.


Dodatno, slika 3.21 prikazuje prisutnost grešaka u obliku šiljaka koje su unijeli mjereni pametni telefoni u podatke s akcelerometra. Podaci sa žiroskopa su znatno ujednačeniji, ali A50 pametni telefon ima vremensko kašnjenje iznosa 500 milisekundi u usporedbi s ostalim uređajima. Navedeno kašnjenje odražava se u izračunatoj orijentaciji.

Za usporedbu performansi ugradbenih sustava, promatran je jedan period njihala i odgovarajuće vrijednosti izračunate orijentacije uređaja u obliku elevacije. Izračunata elevacija prikazana





(a)



(b)


**Slika 3.20:** (a) Graf akceleracije s protufaznim vrijednostima dobivenim u smjeru X osi s nekih uređaja u odnosu na preostale. (b) Smjer osi u mjernom sustavu i torzijske sile koje djeluju na drveni nosač uređaja.

je na slici 3.22.


Moguće se primijetiti da je izračunata elevacija za svih pet DUT uređaja sinkronizirana, te je vidljivo samo neznatno kašnjenje. Amplituda elevacije za NanoInt ugradbeni sustav je manja nego za ostala četiri sustava, dok UnoInt sustav prikazuje mali vremenski odmak u odnosu na ostala četiri ugradbena sustava.

Za usporedbu podataka o elevaciji izračunatih za pametne telefone, podaci sa žiroskopa dobiveni od A50 pametnog telefona morali su biti vremenski prilagođeni u fazi post-procesiranja. Elevacija izračunata za svih pet pametnih telefona nakon navedenog prilagođavanja prikazana je na slici 3.23.

U slučaju pametnih telefona, izračunata elevacija imala je manje odstupanje po amplitudi i vremenu nego je to bio slučaj kod ugradbenih sustava, te je samo pametni telefon A50 pokazivao odstupanje u amplitudi u odnosu na sve ostale pametne telefone.



**Slika 3.21:** Akceleracija u smjeru Z osi (lijevo), kutna brzina u smjeru rotacije X osi (sredina) i orijentacija u elevacijskoj osi (desno) dobiveni za pet testiranih pametnih telefona.




**Slika 3.22:** Elevacija izračunata za jedan titraj njihala za svih pet ugradbenih sustava.

Kako se ni duljina šipke niti ukupna masa sustava nije mijenjala tijekom mjerenja, stvarni period titranja njihala je konstantan, te je iz tog razloga korišten kao referentni period njihanja za sve uređaje. Srednja vrijednost izračunata je iz deset uzastopnih perioda u jednom mjerenju. Na slici 3.24 prikazano je deset uzastopnih perioda izračunate elevacije za pet pametnih telefona, te su minimumi elevacije, koji odgovaraju jednoj od točaka maksimalnog otklona njihala, označeni crvenim točkama.


### 3.3.4 Diskusija rezultata

Mjereni uređaji omogućili su pristup sirovim IMU podacima s minimalnim kašnjenjem. Među ugradbenim sustavima temeljenima na Arduino platformi, uređaj DOFv2 imao je najveće kašnjenje, iako je istovremeno demonstrirao i najveću kvantizacijsku razlučivost među svim ugradbenim sustavima. To čini sustav DOFv2 posebno prikladnim za primjene koje zahtijevaju precizno otkrivanje malih promjena orijentacije. S druge strane, ugradbeni sustav ICMak pokazao se najprikladnijim za primjene koje zahtijevaju brzo otkrivanje promjena orijentacije. Frekvencija uzorkovanja u ugradbenim sustavima bila je praktički konstantna, s tek manjim odstupa-





**Slika 3.23:** Elevacija izračunata za jedan titraj njihala za svih pet pametnih telefona.



**Slika 3.24:** Elevacija izračunata za deset titraja njihala za svih pet pametnih telefona.

njima.

Mjerenja provedena na pametnim telefonima ukazuju na to da su ovi uređaji prikladni za prikupljanje podataka s ugrađenih žiroskopa i akcelerometara. Na današnjem tržištu već postoji nekoliko proizvoda koji omogućuju montiranje pametnih telefona na korisnikovu glavu za potrebe binauralne sinteze u aplikacijama virtualne stvarnosti. U takvim slučajevima, IMU senzori u pametnim telefonima imaju ključnu ulogu u stvaranju uranjajućih (imersivnih) virtualnih okolina. Mjerenja su pokazala da većina pametnih telefona daje podatke o orijentaciji uređaja zadovoljavajuće tačnosti uz zanemarivo kašnjenje, ispunjavajući osnovni zahtjev za njihovu uporabu u sustavima virtualnih zvučnih okolina. Međutim, primijećeno je da je najjeftiniji pametni telefon u ispitnoj grupi pokazao najmanju tačnost. Detaljna statistička analiza rezultata dostupna je u radu na kojem se temelji trenutno potpoglavlje [107].

Na temelju predstavljenih rezultata ispitivanja uređaja s ugrađenim IMU sensorima, za preliminarno ispitivanje opisano u poglavlju 4 zaključeno je da je za praćenje položaja glave moguće koristiti kvalitetni uređaj baziran na ugradbenom sustavu, ali i pametni telefon. Stoga, u preliminarnom ispitivanju korištena su oba uređaja kako bi se dodatno ispitalo postoji li statistički značajna razlika između navedena dva uređaja vezano uz praćenje položaja glave.

## Poglavlje 4

# Preliminarno ispitivanje kvalitete binauralne sinteze


Ovo poglavlje preuzeto je iz znanstvenog rada objavljenog u sklopu doktorskog istraživanja [124], uz manje prilagodbe.

Za bolje razumijevanje što čini percepciju virtualnih zvučnih izvora realističnom i koji parametri značajno utječu na točnost lokalizacije navedenih izvora, osmišljeno je preliminarno ispitivanje u kojem su mijenjani različiti hardverski i softverski parametri binauralnog sustava kako bi se utvrdilo dovode li unesene promjene do statistički značajnog povećanja točnosti lokalizacije binauralno sintetiziranih zvučnih izvora. Eksternalizacija virtualnog zvučnog izvora važna je za prirodni osjećaj uronjenosti slušatelja u zvučno polje [125], jer se postizanjem realističnog osjećaja eksternalizacije zvučnog izvora pokušava oponašati realno zvučno polje. Pretpostavka je da odječnost prostorije karakterizirana vremenom odjeka može znatno utjecati na percepciju eksternaliziranosti virtualnog zvučnog izvora.

### 4.1 Metoda mjerenja i postava ispitivanja

Za postavljanje binauralnog sustava uz praćenje položaja glave u svrhu provođenja preliminar-  
nog ispitivanja, korištena je sljedeća oprema i softver: Reaper DAW, IEM Suite Scene Rotator, IEM Suite Stereo Encoder, IEM Suite Binaural Decoder, Ho-DirAC Binaural VST dodatak, Ambisonics odjek, slušalice, te dva uređaja za praćenje položaja glave. Korišten je IEM Suite predložak za kodiranje uzoraka zvuka u Ambisonics formatu petog reda, kao nužan pripremni korak za binauralnu sintezu (slika 4.1). Funkcionalnost svih dijelova binauralnog sustava opisana je u potpoglavlju 2.4, te u nastavku trenutnog potpoglavlja.

Prvi faktor čiji je utjecaj na točnost lokalizacije ispitan provedbom ovog ispitivanja je uređaj za praćenje položaja glave. Korištena su dva različita uređaja za praćenje položaja glave: komercijalni uređaj Waves NX, te pametni telefon iPhone 12 Pro. Pametni telefon izabran je




Slika 4.1: Računalni program preliminarnog ispitivanja u Reaper DAW-u.

na temelju rezultata izvedenih mjerenja opisanih u Poglavlju 3. Drugi faktor čiji je utjecaj ispitivan je binauralni dekodera i njemu pridružen generički skup HRTF funkcija. Korištena su dva različita binauralna dekodera, te je svaki bio opremljen različitim generičkim HRTF skupom. Prvi dekodera je IEM Suite Binaural Decoder VST dodatak koji koristi metodu binauralne sinteze najmanjih kvadrata amplituda (engl. *Magnitude Least Squares*) [126] te koristi generički HRTF skup izmjeren na umjetnoj glavi Neumann KU 100. Drugi dekodera je HO-DirAC Binaural VST dodatak [127], koji se temelji na metodi usmjerenog audio kodiranja višeg reda (HO-DirAC, engl. *Higher-Order Directional Audio Coding*) [128], te koristi generički HRTF skup izmjeren na umjetnoj glavi Gras 45BB KEMAR s normalnom ušnom školjkom. Ove dvije postavke odabrane su zbog primjene u prethodnim istraživanjima binauralne sinteze uz praćenje položaja glave. Azimut virtualnog izvora zvuka definiran je pomoću IEM Suite Stereo Encoder VST dodatka. IEM Scene Rotator VST dodatak prima podatke o rotaciji glave putem OSC protokola te kontrolira rotaciju cijelog DAW projekta, tj. skupnu rotaciju svih izvora virtualne zvučne okoline. Kako bi se ostvario prijenos podataka o orijentaciji glave, bio je potreban dodatan softver (Nxosc MacOS aplikacija za Waves NX uređaj [129], te iOS aplikacija GyrOSC za iPhone pametni telefon [130])(slika 4.2). IEM Suite Reverb korišten je kao dodatak za generiranje Ambisonics odjeka virtualnog zvučnog izvora. Dijagram toka preliminarnog ispitivanja prikazan je na slici 4.3.


Ispitivanje je podijeljeno u dva dijela, te je u oba dijela ispitivanja sudjelovalo ukupno petnaest ispitanika, od kojih pet žena i desetorica muškaraca. Dob ispitanika kretala se u rasponu od 21 do 58 godina. Ispitanici su u ispitivanju sudjelovali individualno. Bili su smješteni u prostoriji u kojoj se održavalo ispitivanje i sve su im upute pročitane unutar te prostorije. Na taj su način mogli doživjeti odjek u prostoriji kao potencijalni utjecajni faktor u dijelu ispitivanja eksternalizacije virtualnog zvučnog izvora, uz reprodukciju putem slušalica otvorenog tipa.

U prvom dijelu ispitivanja ispitana je točnost lokalizacije virtualnog zvučnog izvora za sve četiri moguće kombinacije uređaja za praćenje položaja glave i binauralnih dekodera, te je taj dio ispitivanja proveden u dvije faze. Postava prvog dijela ispitivanja vidljiva je na slici 4.4.

Na glavu ispitanika stavljene su slušalice s nosačem za uređaj za praćenje položaja glave. Za lokalizaciju virtualnog izvora zvuka i određivanje njegove orijentacije (azimuta), ispitanici su




(a)



(b)

**Slika 4.2:** (a) Nxosc MacOS aplikacija; (b) GyrOSC iOS aplikacija.

koristili papirnatu traku raširenu simetrično duž kružnog luka s kutom od  $240^\circ$  oko položaja za slušanje, s oznakama kuta azimuta iscrtanim u razlučivosti od jednog stupnja. Zbog navedene simetrije, azimut od  $120^\circ$  je dodijeljen frontalnom smjeru. Uređaj za praćenje položaja glave kalibriran je više puta tijekom ispitivanja, a kalibracija je provjeravana reproduciranjem zvuka kuckanja po drvu iz frontalnog smjera. Ispitanici su zatim zamoljeni da potvrde da zaista čuju zvuk, te da ga čuju iz navedenog frontalnog smjera. Za određivanje smjera dolaska zvuka,



**Slika 4.3:** Dijagram toka preliminarnog ispitivanja kvalitete binauralne sinteze.

ispitanici su sjedili na okretnom barskom stolcu i bili su u mogućnosti okretati se na njemu, to jest, pomicati i tijelo i glavu u tri stupnja slobode. Prva faza ispitivanja točnosti lokalizacije bila je fokusirana na statičku lokalizaciju. Zvuk kuckanja po drvu trajao je 10 sekundi i reproduciran je iz odabranih 5 fiksnih smjerova azimuta. Po završetku reprodukcije svakog uzorka, ispitanici bi na glas izgovorili iznos azimuta koji označava smjer iz kojeg smatraju da je došao zvuk. Kako bi se provjerila dosljednost odgovora, 2 od 5 fiksnih smjerova azimuta imali su jednaku vrijednost, slučajno izabranu za svaki uzorak zvuka tijekom ispitivanja. Druga faza ispitivanja točnosti lokalizacije usmjerena je na dinamičku lokalizaciju. Zadatak zadan ispitanicima bio je odrediti konačan azimut virtualnog izvora zvuka koji se kretao u horizontalnoj ravnini oko slušatelja. Korišten je isti uzorak zvuka kao i prije, ali mu je trajanje skraćeno na 6 sekundi. Smjer dolaska zvuka mijenjao se od početne do krajnje vrijednosti kuta azimuta konstantnom kutnom brzinom. Definirana su tri scenarija, od kojih svaki scenarij ima različitu vrijednost kuta između početnog i konačnog smjera, što rezultira različitim kutnim brzinama za tri slučaja. Kada bi svaka reprodukcija zvuka završila, ispitanici su na glas izgovorili smjer azimuta iz kojeg smatraju da je zvuk stigao na samom završetku reprodukcije.

Drugi dio ispitivanja osmišljen je kako bi se testirao utjecaj odjeka i metode binauralnog dekodiranja na percepciju eksternalizacije virtualnog zvučnog izvora. Stoga su mijenjana dva parametra: binauralni dekodir i vrijeme odjeka. Pretpostavljeno je da će varijacija uređaja za praćenje položaja glave biti zanemariva za drugi dio ispitivanja, što je na koncu potvrđeno rezultatima prvog dijela ispitivanja. Uzorci zvuka korišteni u ovom dijelu ispitivanja sadržavali su snimljeni govor. Umjetna glava postavljena je ispred slušatelja kao vizualni podražaj koji oponaša ljudskog govornika (slika 4.5).

Umjetna glava postavljena je na stol točno iza ispitanika, tj. izravno nasuprot direktne frontalne pozicije korištene u ispitivanju točnosti lokalizacije. Na taj su način sudionici samo trebali napraviti poluokret od 180 stupnjeva na rotirajućem stolcu i bili su spremni za drugi dio ispiti-





(a)



(b)

**Slika 4.4:** Postava preliminarnog ispitivanja u Auralizacijskom laboratoriju FER-a: (a) udaljena perspektiva; (b) bliža perspektiva.

vanja. Osim toga, na taj način nisu mogli vidjeti mjerni postav iz prvog dijela ispitivanja, te im on na taj način nije predstavljao moguću vizualnu smetnju. Tri zvučna uzorka napravljena su iz izvorne neuređene audio snimke govora, razlikujući se samo u količini dodanog odjeka. Konkretno, odabrana su vremena odjeka od 0, 0,4 i 0,8 sekundi. Binauralno dekodiranje Ambisonics signala ostvareno je korištenjem ista dva dekodera kao i u ispitivanju točnosti lokalizacije. Uzorci su reproducirani ispitanicima, a oni su trebali ocijeniti razinu eksternalizacije zvuka na skali koja se kretala od 1 ("Zvuk je u mojoj glavi") do 9 ("Zvuk dolazi iz usta umjetne glave").



**Slika 4.5:** Umjetna glava postavljena ispred slušatelja kao vizualni stimulus tijekom ispitivanja.


Iako bi logični zaključak bio postaviti vrijeme odjeka približno jednako kao u prostoriji u kojoj se osoba nalazi, pretpostavka je da bi veće vrijeme odjeka primijenjeno na virtualni zvučni izvor moglo stvoriti snažniju percepciju eksternaliziranosti izvora.

## 4.2 Statistička analiza i rezultati

Rezultati ispitivanja obrađeni su te zatim statistički analizirani pomoću dijagrama pravokutnika (engl. *box-plot with whiskers*), te dvosmjerne analize varijance (ANOVA, engl. *Analysis of Variance*)[131] u Excel aplikaciji [132]. Provjerena je i potvrđena normalna distribucija (slika 4.6).

### 4.2.1 Rezultati ispitivanja točnosti lokalizacije izvora zvuka

Kako bi se procijenila točnost lokalizacije virtualnog zvučnog izvora ovisno o korištenim uređajima za praćenje položaja glave i binauralnim dekoderima u ispitnom sustavu, sirovi rezultati pretvoreni su u prikladniji oblik za statističku analizu. Konkretno, smjerovi azimuta izrečeni od strane ispitanika, tj. percipirani smjerovi virtualnog izvora zvuka uspoređeni su sa zadanim




**Slika 4.6:** Distribucija rezultata ispitivanja točnosti lokalizacije virtualnog zvučnog izvora.

smjerovima virtualnog izvora zvuka definiranim u IEM *Stereo Encoder*-u. Zatim je izračunana apsolutna vrijednost odstupanja percipiranog smjera (azimuta) od programski zadanog smjera. Budući da je svaki slušatelj bio neovisni sudionik ispitivanja, za svakoga od njih je iz pojedinačnih opažanja (odstupanja od zadanog smjera zvuka) izračunata srednja vrijednost i standardna devijacija apsolutnog odstupanja, posebno za statičku i dinamičku lokalizaciju, i to za svaku od četiri moguće kombinacije uređaja za praćenje položaja glave i binauralnog dekodera. Na taj je način za svaku kombinaciju uređaja za praćenje položaja glave i binauralnog dekodera dobiveno 15 srednjih vrijednosti i standardnih devijacija za statističku analizu (slika 4.7), te su cjelokupni rezultati dostupni u tablicama u dodatku 7.2. Rezultati prikazani u obliku dijagrama pravokutnika mogu se vidjeti na slici 4.8.


Očekivani položaj interkvartilnog raspona dijagrama pravokutnika za točnost statičke lokalizacije bio je ispod 10 stupnjeva apsolutne devijacije od programski zadanog smjera virtualnog zvučnog izvora, dok je za točnost dinamičke lokalizacije očekivani položaj interkvartilnog raspona dijagrama pravokutnika bio ispod 15 stupnjeva za isti parametar.

Dvosmjerna ANOVA korištena je kako bi se analizirali dobiveni prilagođeni podaci, te kako bi se ispitao utjecaj odabira uređaja za praćenje položaja glave i binauralnog dekodera kao neovisnih faktora na točnost lokalizacije virtualnih zvučnih izvora. Dobivene p-vrijednosti veće su vrijednosti od odabrane razine značajnosti 0,05 za oba faktora i njihovu interakciju, kako za statičku, tako i za dinamičku točnost lokalizacije. Točnije, p-vrijednosti za točnost statičke lokalizacije su 0,43 i 0,93 za izbor uređaja za praćenje položaja glave i binauralnog dekodera, redom, te 0,13 za njihovu interakciju. P-vrijednosti za točnost dinamičke lokalizacije su 0,69 i 0,09 za izbor uređaja za praćenje položaja glave i binauralnog dekodera, redom, te 0,36 za






(a)




(b)

**Slika 4.7:** Prikaz prosječnih vrijednosti rezultata ispitanika za sve kombinacije variranih parametara, uz vidljive trake pogreške, za: (a) statički, (b) dinamički virtualni izvor zvuka.

njihovu interakciju. Stoga, hipoteza dvosmjernog ANOVA testa da odabir uređaja za praćenje položaja glave i binauralnog dekodera nema utjecaja na točnost statičke i dinamičke lokalizacije ne može se odbaciti, barem ne za sustave korištene u ovom ispitivanju. Navedeni rezultati ukazuju da je razlika u performansama između komercijalnog uređaja za praćenje položaja glave i pametnog telefona korištenog u istu svrhu zanemariva, iako se očekivala određena razlika vezano točnost dinamičke lokalizacije, s obzirom na to da Waves NX uređaj koristi *Bluetooth* vezu za prijenos podataka, dok pametni telefon iPhone 12 Pro koristi *Wi-Fi* vezu za slanje podataka o položaju glave putem *OSC* protokola, koja bi trebala biti sporija od *Bluetooth* veze.



(a)




(b)

**Slika 4.8:** Dijagrami pravokutnika za apsolutnu vrijednost odstupanja percipiranog smjera (azimuta) virtualnog izvora zvuka od stvarnog (programski zadanog), prikazani za različite kombinacije uređaja za praćenje položaja glave i binauralnog dekodera za statičku lokalizaciju (a) i dinamičku lokalizaciju (b).

#### 4.2.2 Rezultati ispitivanja percepcije eksternaliziranosti izvora zvuka

Na temelju podataka dobivenih dvosmjernim ANOVA testom za ispitivanje točnosti lokalizacije virtualnih zvučnih izvora koji su pokazali da nema značajne razlike između korištenih uređaja za praćenje položaja glave, u svrhu ispitivanja utjecaja različitih parametara postavki binauralnog sustava na percepciju eksternaliziranosti virtualnog zvučnog izvora, zaključeno je da je odabir uređaja za praćenje položaja zanemariv faktor. Stoga su kao faktori utjecaja ispitani odabir binauralnog dekodera i vrijeme odjeka. Budući da su rezultati dvosmjernog ANOVA testa ispitivanja točnosti lokalizacije pokazali da i odabir binauralnog dekodera nema značajan utjecaj na binauralnu sintezu, izrađen je samo dijagram pravokutnika rezultata količine eksternalizacije virtualnog zvučnog izvora uz varijaciju vremena odjeka u sustavu (slika 4.9).



**Slika 4.9:** Dijagram pravokutnika za percepciju eksternaliziranosti binauralno sintetiziranog virtualnog zvučnog izvora u ovisnosti o vremenu odjeka dodanom pri sintezi virtualne zvučne okoline.

Dvosmjerni ANOVA proveden na dobivenim obrađenim podacima daje p-vrijednosti od 0,39 za izbor binauralnog dekodera, i otprilike  $10^{-18}$  za izbor vremena odjeka kao dvaju neovisnih faktora, te 0,58 za njihovu interakciju. Ovim rezultatima pokazano je da je izbor vremena odjeka glavni parametar koji utječe na percepciju eksternaliziranosti virtualnog zvučnog izvora, u smislu da dodatak odjeka "suhom" virtualnom zvuku značajno pojačava tu percepciju. Rezultati potvrđuju pretpostavku da veća količina odjeka u reproduciranom zvuku izvora dovodi do snažnije percepcije eksternaliziranosti izvora. Nadalje, budući da zbog trajanja ispitivanja nisu ispitana vremena odjeka veća od 0,8 sekundi, to je prepoznato ograničenje predstavljenog ispitivanja.

## Poglavlje 5

# Glavno ispitivanje kvalitete binauralne sinteze

U ovom poglavlju predstavljeni su rezultati glavnog ispitivanja cjelokupnog doktorskog istraživanja. Ovo poglavlje preuzeto je iz znanstvenog rada objavljenog u sklopu doktorskog istraživanja [133], uz manje prilagodbe.

### 5.1 Mjerenje individualnih HRTF skupova

Za potrebe ove doktorske disertacije korištena je metoda mjerenja opisana u [49, 134] za dobivanje vlastitih individualnih HRTF skupova za ispitanike koji su sudjelovali u ispitivanju, s iznimkom da su mjerenja obavljena u akustički izoliranoj maloj gluhoj komori, što je još i bolje od uvjeta za koje su metode zamišljene i razvijene. Prije početka mjerenja, bilo je potrebno osigurati opremu za izvođenje mjerenja individualnih HRTF skupova (slika 5.1).



**Slika 5.1:** Oprema za izvođenje mjerenja individualnih HRTF skupova [134].


Oprema potrebna za izvođenje mjerenja bila je sljedeća:

- SparkFun Openlog Artemis uređaj za praćenje položaja glave [135]: Navedeni uređaj izabran je zbog odličnih performansi praćenja položaja glave, te zbog žičnog povezivanja sa ostatkom sustava. Uređaj se koristi uz tri stupnja slobode za potrebe mjerenja HRTF skupova i za potrebe glavnog ispitivanja.
- Axagon ADA-17 USB - HQ MINI audio sučelje [136]: Za audio sučelje bilo je potrebno zadovoljiti uvjet male veličine i mase sučelja (zbog jednostavnog postavljanja na glavu ispitanika), te je povezivost napajanja sučelja i prijenos podataka trebala biti izvedena pomoću jedne žičane veze zbog smanjenja broja spojnih kabela između računala i sustava postavljenog na glavu ispitanika.
- USB kabele za povezivanje uređaja za praćenje položaja glave i audio sučelja.
- Par kondenzatorskih oblikovno prilagodljivih (engl. *in-ear*) mikrofona.
- Elastični držač uređaja za praćenje položaja glave.


Prije početka mjerenja u gluhoj komori, ispitanicima je usmeno pojašnjen koncept HRTF funkcija i proces mjerenja njihovih vlastitih individualnih HRTF skupova. Ispitanici su zatim sjeli na stolicu s mogućnošću rotacije, koja se nalazila u gluhoj komori. Točna pozicija je odabrana kako bi se osiguralo da se ispitanikova glava nalazi u osi zvučnog sustava s jednim zvučnikom na udaljenosti od 1,5 metar od zvučnika. Na čelo sudionika postavljen je uređaj za praćenje položaja glave kako bi se podaci o orijentaciji sudionikove glave mogli koristiti za mjerenje HRTF funkcija. Oblikovno prilagodljivi mikrofoni za uši umetnuti su u ušne kanale ispitanika kako bi se snimili eksponencijalni klizajući sinusi koje generira zvučnički sustav tijekom mjerenja. Prije početka procesa mjerenja HRTF skupa, bilo je potrebno provjeriti digitalno podešivu razinu zvučnog tlaka mjernog zvučnog sustava i ulazne razine signala oba mikrofona postupkom ugrađenim u računalnu aplikaciju (slika 5.2). U aplikaciji je zatim vidljiva tekstualna potvrda da su razine signala zadovoljavajuće za provedbu mjerenja.

Za razliku od standardnog mjerenja HRTF skupa gdje je ispitanik obavezan ostati nepomičan, ispitanici su morali okretati svoju glavu, pa i cijelo tijelo, kako bi time kontinuirano mijenjali orijentaciju glave u odnosu na zvučnički sustav, čime je omogućeno mjerenje HRTF funkcija za sve smjerove dolaska zvuka, gledano iz pozicije ispitanika. U stvari, ispitanicima je rečeno da uzorkuju smjerove dolaska zvuka u cijelom prostornom kutu od  $4\pi$  za vrijeme trajanja mjerenja od 15 minuta, sa što manje praznina u prostoru oko glave. Kako bi to bilo postignuto, ispitanicima je dopušteno da rotiraju cijelo tijelo oko centralne osi dok sjede na stolici tako da se smjerovi izvora zvuka s boka i straga također mogu snimiti. Kako bi pratili svoj napredak, ispitanicima su prikazane vizualne povratne informacije o smjerovima koji su već izmjereni u obliku točaka na sferi oko njihove glave (slika 5.3).

Također, ispitanicima je prikazano preostalo vrijeme do kraja mjerenja. Sve navedene povratne informacije su prikazane na dva različita računalna monitora postavljena jedan nasuprot



**Slika 5.2:** Provjera razina za mjerenje HRTF skupova [134].



**Slika 5.3:** Programsko sučelje aplikacije za mjerenje HRTF skupova [134].

drugome kako bi one bile dostupne ispitanicima tijekom punog okreta na okretnoj stolici (slika 5.4). Ovdje primijenjeno predstavlja poboljšanje u odnosu na izvorno rješenje koje se uobičajeno primjenjuje pri mjerenju HRTF skupova metodom *Earfish*, a koje podrazumijeva držanje prijenosnog računala u krilu ispitanika kako bi mu gore navedene informacije bile dostupne. Rješenje je primijenjeno uz pretpostavku da će uklanjanje prijenosnog računala kao stranog tijela iz blizine ispitanika rezultirati većom točnošću izmjerenih HRTF skupova. Nakon mjerenja, izvršeno je dodatno kalibracijsko mjerenje sustava. Na temelju izmjerenih IMU podataka, sirovih audio podataka i kalibracijskih podataka, u fazi naknadne obrade navedenih podataka iz-

računat je vlastiti individualni HRTF skup svakog sudionika i pohranjen u SOFA formatu (engl. *Spatially Oriented Format for Acoustics*) [137].

## 5.2 Mjerenje kašnjenja audio signala binauralnog sustava

Glavni preduvjet prije ispitivanja točnosti lokalizacije je da je kašnjenje signala binauralnog audio sustava dovoljno nisko. Jedan od ključnih parametara bilo je korištenje sustava s direktnim žičnim prijenosom podataka, budući da performanse samog uređaja za praćenje položaja glave imaju utjecaj na kvalitetu binauralne sinteze zbog razlika u točnosti i preciznosti rada IMU senzora. Istraživanja u kojima se koriste binauralni audio sustavi zahtijevaju da je kašnjenje sustava što niže za dobivanje kvalitetnih i relevantnih rezultata, optimalno ispod 75 milisekundi (prag detekcije kašnjenja)[138]. Iako se teoretska vrijednost kašnjenja signala može procijeniti, korišten je eksperimentalni pristup kako bi se odredila stvarna vrijednost.

Binauralni audio sustav bio je postavljen na umjetnu glavu, zajedno s jednostavnim električnim krugom za detekciju svjetla, sastavljenim od 9-voltne baterije, svijetleće diode i visokokvalitetnog fotootpornika (slika 5.5).

Specijalizirana SOFA datoteka implementirana je u binauralni audio sustav, u kojoj su za frontalne smjerove (s korakom 6 stupnjeva između susjednih smjerova) HRTF funkcije postavljene kao *Dirac* impuls s amplitudom 0,5, dok su ostali smjerovi definirani kao HRTF funkcija vrijednosti 0. Virtualno ispred umjetne glave postavljen je zvučni izvor koji je emitirao konstantni sinusni ton frekvencije 10 kHz, s umjetnom glavom pozicioniranom u frontalnom smjeru (gdje je sinusni ton bio čujan). Laserski pokazivač bio je usmjeren prema fotootporniku, što je smanjilo otpor elementa, uzrokujući porast napona na fotootporniku. Uz nagli trzaj umjetne glave, laserska zraka više nije bila usmjerena prema fotootporniku, što je rezultiralo padom napona na elementu. Istovremeno, sustav za praćenje položaja glave detektirao je promjenu orijentacije umjetne glave u odnosu na izvor zvuka u položaj izvan definiranog frontalnog smjera, uzrokujući promjenu azimuta zvučnog izvora u odnosu na umjetnu glavu, i samim time, promjenu HRTF funkcije iz one definirane Diracovim impulsom amplitude 0,5 u onu stalne vrijednosti (što znači da zvuk virtualnog izvora više nije čujan). Kašnjenje sustava je potom izračunato kao razlika u vremenu između točnog trenutka početka promjene napona na fotootporniku i trenutka kada je audio izlaz binauralnog sustava prešao iz čujnog u nečujni.

Korištena je zvučna kartica s dva ulaza kako bi se snimio audio izlaz binauralnog sustava i promjena napona na fotootporniku. Moderne zvučne kartice uobičajeno imaju kondenzator u seriji s audio ulazom kako bi blokirali istosmjerne napone (DC, engl. *direct current*) od ulaska u zvučnu karticu. Iz tog razloga, za snimljenu promjenu AC napona (engl. *alternating current*) na kondenzatoru bitan je samo početni trenutak promjene stanja, tj. prijelazne pojave za određivanje kašnjenja signala (slika 5.6). Kako bi promjena napona bila dovoljno izražena za






(a)



(b)

**Slika 5.4:** Mjerenje HRTF skupova u gluhoj komori: (a) pogled straga na ispitanika; (b) pogled sprijeda na ispitanika.





**Slika 5.5:** Postava jednostavnog električnog kruga na umjetnoj glavi za mjerenje kašnjenja signala binauralnog sustava.

određivanje kašnjenja signala, mjerenje je provedeno u kontroliranom okruženju bez vanjskih izvora svjetlosti.

Provedeno je deset mjerenja kašnjenja signala na postavljenom binauralnom sustavu dizajniranom za testiranje točnosti lokalizacije. Dobivene vrijednosti kašnjenja kretale su se od 69 do 78 milisekundi, s prosječnim rezultatom iznosa 73 milisekunde. U glavnom ispitivanju točnosti lokalizacije koristi se tranzijentni signal kucanja o drvo, koji je korišten i u preliminarnom ispitivanju. S obzirom na to da je vremenski interval između dva uzastopna udara zvučnog podražaja u ispitivanju bio 283 milisekunde, a da je kašnjenje signala bilo gotovo četiri puta kraće od navedenog intervala, zaključeno je da je izmjereno kašnjenje sustava dovoljno nisko za nesmetano izvođenje ispitivanja točnosti lokalizacije.

Uz izračunato kašnjenje, bilo je potrebno dodatno izmjeriti i kašnjenje sustava primijenjenog pri ispitivanju percepcije prirodnosti virtualne zvučne okoline i percepcije eksternaliziranosti virtualnog zvučnog izvora, jer je za potrebe tog ispitivanja implementirana jednostavnija postava binauralnog sustava. Kašnjenje signala u tom sustavu izmjereno je u iznosu od 35 milisekundi, te je i ovdje zaključeno da je ono dovoljno nisko za uspješnu provedbu ispitivanja.




Slika 5.6: Mjerenje kašnjenja signala binauralnog sustava u Reaper DAW-u.


## 5.3 Metoda mjerenja točnosti lokalizacije

### 5.3.1 Postava i izvođenje ispitivanja

Za postavljanje binauralnog sustava uz praćenje položaja glave u svrhu provođenja glavnog ispitivanja, korištena je sljedeća oprema i softver: Reaper DAW (verzija 6,75), IEM Suite Scene Rotator, Sparta Binauralizer VST dodatak [139, 140] (slika 5.7), IEM Ambisonics odjek, kvalitetne otvorene slušalice, te uređaj za praćenje položaja glave (koji je korišten u mjerenju HRTF skupova) s računalnom aplikacijom za slanje podataka praćenja putem OSC protokola (slika 5.8). Kao i u preliminarnom ispitivanju, korišten je IEM Suite predložak za stvaranje virtualne zvučne okoline kodirane u Ambisonics formatu petog reda. Dijagram toka ispitivanja jednak je kao i u preliminarnom ispitivanju (slika 4.3).



Slika 5.7: Programsko sučelje VST dodatka Sparta Binauralizer [140].



**Slika 5.8:** Aplikacija za primanje i slanje podataka praćenja položaja glave [134].

Mjerenjem individualnih HRTF skupova, dobiveni su podaci nužni za provedbu ispitivanja točnosti lokalizacije virtualnog zvučnog izvora. U ispitivanju je sudjelovalo ukupno 25 osoba starosti od 19 do 58 godina, od kojih su pet bile žene, a dvadeset muškarci. Prije sudjelovanja u ispitivanju, ispitanici su pročitali i potpisali suglasnost o sudjelovanju, te pročitali upute o ispitivanju. Zatim su na ispitanikovu glavu postavljene slušalice i uređaj za praćenje položaja glave. Za potrebe određivanja smjera dolaska zvuka, ispitanici su sjeli na okretnu stolicu zahvaljujući kojoj su mogli slobodno okretati svoja tijela i glave. Kako bi lokalizirali izvor zvuka i utvrdili njegov azimut i nagib, bilo je potrebno ispitanicima omogućiti vizualni indikator za određivanje smjera dolaska zvuka. U tu svrhu, dvije papirnate trake bile su rastegnute simetrično na luk od 180 stupnjeva oko položaja za slušanje u horizontalnoj i vertikalnoj (medijalnoj) ravnini, s kutnim oznakama azimuta i nagiba u rezoluciji od 1 stupanj (slika 5.9).

Kako bi se izbjegle negativne vrijednosti azimuta i nagiba, frontalnom smjeru dodijeljena je vrijednost azimuta i nagiba od 90 stupnjeva, čime se dobiva raspon od 0 do 180 stupnjeva za oba parametra. Na taj način, izbjegnuto je korištenje negativnih vrijednosti kuta, te je ispitanicima olakšano snalaženje po vrijednostima azimuta i nagiba. Ispitanici su imali zadatak odrediti početni i konačni azimut (ili nagib) virtualnog izvora zvuka koji se kreće u horizontalnoj (ili vertikalnoj) ravnini unutar odabranog raspona kutova azimuta ili nagiba. Zvuk korišten u ovom ispitivanju bio je ponavljajuće kuckanje po komadu drveta. Kutna brzina virtualnog izvora zvuka mogla se nasumično mijenjati (ne više od 3 stupnja po sekundi od početne kutne brzine) kako bi se izbjeglo automatizirano okretanje glave ispitanika nakon prilagodbe na konstantnu





(a)



(b)

**Slika 5.9:** Konstrukcija s papirnatom trakom za određivanje smjera virtualnog zvučnog izvora: (a) prednji pogled; (b) bočni pogled.

brzinu izvora zvuka (u slučaju konstantne kutne brzine). Kao dodatna mjera za izbjegavanje navedenog automatskog okretanja glave, implementirana je mogućnost neočekivane promjene smjera kretanja virtualnog izvora zvuka, to jest, zvuk se mogao kretati do određenog azimuta u jednom smjeru, te nakon toga promijeniti smjer kretanja (početi se vraćati prema početnoj točki). Kretanje izvora testirano je neovisno u dvije navedene ravnine, a ispitanicima je rečeno na koju papirnatu traku se trebaju usredotočiti prije svakog pojedinačnog mjerenja. Ispitanicima je zadan zadatak da izgovore početni smjer virtualnog izvora zvuka u obliku brojčane vrijednosti azimuta ili nagiba čim ga lokaliziraju, te da na jednak način izgovore i konačni smjer iz kojeg su percipirali zvuk nakon završetka reprodukcije zvučnog signala. Prije početka ispitivanja, svakom su ispitaniku bila prezentirana dva primjera kako bi se provjerila funkcionalnost binauralnog sustava i osiguralo da ispitanici razumiju postupak ispitivanja. Svaki ispitanik je slušao više ispitnih slučajeva i neposredno procijenio točnost lokalizacije virtualnog zvučnog izvora dobivenog binauralnom sintezom uz uporabu triju različitih HRTF skupova. Tri HRTF skupa u ispitivanju bila su: vlastiti individualni HRTF skup sudionika, generički HRTF skup dobiven mjerenjem na umjetnoj glavi Neumann KU100 i individualni HRTF skup druge osobe, dobiven od jednog ispitanika koji je sudjelovao u mjerenju individualnih HRTF skupova, ali nije sudjelovao u ispitivanju točnosti lokalizacije virtualnog zvučnog izvora. Kako bi se smanjila mogućnost pojave pristranosti, ispitivanja u horizontalnoj i vertikalnoj ravnini sustavno su bila izmjenjivana svaka tri mjerenja. Nadalje, kako bi se ublažili potencijalni učinci umora na rezultate, tri HRTF skupa su nakon svakog segmenta od tri ispitivanja bila ponovno nasumično raspoređena.

## **5.4 Metoda subjektivnog vrednovanja prirodnosti i ekster-nalizacije virtualnog zvučnog izvora**

### **5.4.1 Postava i izvođenje ispitivanja**

Sljedeće ispitivanje koje je dio glavnog ispitivanja uključivalo je slušanje različitih HRTF skupova primijenjenih na virtualne zvučne izvore, te je ispitanicima zadatak bio pronaći i odabrati vlastiti individualni HRTF skup iz skupine od četiri različita HRTF skupa slušajući zvučne uzorke koji su bili binauralno kodirani uz uporabu tih HRTF skupova. Navedeno ispitivanje služilo je kao vježba za ispitanike za ispitivanje točnosti lokalizacije, s ciljem upoznavanja s virtualnim zvukom i zvučnom okolinom pomoću praćenja pokreta glave. Uz navedeni primarni cilj, ispitivanje je kao dodatni cilj služilo za pokazivanje potencijalne prednosti uporabe individualnih HRTF skupova pri binauralnoj sintezi virtualnih zvučnih okolina. Stoga je navedeno ispitivanje provedeno prije ispitivanja točnosti lokalizacije. Postava ispitivanja uključivala je smještaj ispitanika ispred računala te postavljanje slušalica i uređaja za praćenje položaja glave

na glavu ispitanika. Ispitivanje je provedeno koristeći programski jezik C++, uz korištenje programskog alata *3DTI-toolkit* [141]. Prije početka ispitivanja, bilo je potrebno precizno kalibrirati orijentaciju uređaja za praćenje položaja glave u odnosu na magnetsko polje Zemlje postavljanjem zahtjeva ispitanicima da kimaju i odmahuju glavom, oponašajući time pokrete koji se poistovjećuju s potvrdom, odnosno nijekanjem. Procedura ispitivanja sastojala se od ukupno 10 pokušaja, pri čemu je virtualni zvučni izvor bio postavljen izravno ispred ispitanika, a njegov je položaj stabiliziran i ažuriran u stvarnom vremenu na temelju podataka o praćenju položaja glave. U svakom zasebnom ispitivanju je postojala mogućnost odabira između četiri slučajno raspoređena HRTF skupa pritiskom na odgovarajući broj na tipkovnici, čime je pri binauralnoj sintezi zvučnog izvora primijenjen odabrani HRTF skup. Ispitanici su imali mogućnost promijeniti i poslušati različite HRTF skupove koliko god puta su to željeli i smatrali potrebnim. Ispitanicima je rečeno da odaberu preferirani HRTF skup prema sljedećem kriteriju: "Odaberite HRTF skup za koji mislite da je vaš, uzimajući u obzir percepciju prirodnosti virtualne zvučne okoline i percepciju eksternaliziranosti zvučnog izvora. Dojam bi trebao biti kao da slušate svojim vlastitim ušima, a ne tuđim". Iste zvučne datoteke ponavljane su tijekom cijelog ispitivanja, a prebacivanje HRTF skupova događalo se trenutačno na naredbu sudionika zadanu putem tipkovnice. Ispitni slučaj je završen kada je sudionik putem tipkovnice označio i potvrdio HRTF skup koji je smatrao odgovarajućim prema navedenim kriterijima. Ispitanici su slušali dva različita uzorka zvuka, koji su se izmjenjivali između uzastopnih pokušaja:

- Žena koja čita tehnički tekst na engleskom jeziku.
- Pjesma Ozarka Henryja.

Skup od četiri slučajno raspoređena individualna HRTF skupa korišten je u svakom pokušaju. Skup se sastojao od vlastitog individualnog HRTF skupa ispitanika i individualnih HRTF skupova tri druge osobe koje nisu sudjelovale u navedenom ispitivanju subjektivnog vrednovanja prirodnosti i eksternalizacije virtualnog zvučnog izvora. Tri HRTF skupa drugih osoba bila su identična za sve ispitanike.

## 5.5 Statistička analiza i rezultati ispitivanja

U ovom potpoglavlju predstavljani su rezultati statističkih analiza provedenih na sirovim podacima prikupljenim tijekom ispitivanja, te na prilagođenim sirovim podacima u svrhu izračuna statističkih podataka potrebnih za korištene statističke analize. U statističkoj analizi sve odluke o statističkoj značajnosti donesene su na razini značajnosti 0,05. Statističke analize izvedene su u programskom paketu R [142].

### 5.5.1 Ispitivanje točnosti lokalizacije

Statistička analiza temelji se na analizi varijance (ANOVA) ponovljenih mjerenja [143, 144] i izvedena je prema uputama na stranici *Finnstats* [145], uz prilagodbu koda za ovu doktorsku disertaciju (kod je dostupan u dodatku 7.3).

Budući da je bilo 25 neovisnih sudionika s višestrukim mjerenim podacima, njihovi rezultati s istim parametrima (HRTF skup, vertikalna ili horizontalna ravnina, početni ili završni kut) bili su upotrijebljeni kao neovisna zapažanja. Nakon 2 probna slučaja i 18 ispitnih mjerenja, od svakog sudionika slijedilo je ukupno 12 neovisnih opažanja za konačnu analizu. Za svaki od tri HRTF skupa, postojala je početna i završna numerička vrijednost koja je predstavljala apsolutnu devijaciju od točnog azimuta (ili elevacije) početnog i završnog smjera virtualnog izvora zvuka. U rijetkim slučajevima nepostojanja podataka (engl. *missing data*) zbog nesigurnosti sudionika pri procjeni položaja virtualnog izvora zvuka, prosječna apsolutna devijacija izračunata je bez nedostajuće vrijednosti korištenjem drugih dostupnih podataka o devijaciji za konkretni ispitni slučaj. Uvijek je postojao barem jedan rezultat ispitivanja za svako neovisno zapažanje za svakog sudionika, što je rezultiralo time da nema nedostajućih podataka za neovisna zapažanja za sve sudionike. To je važan uvjet pravilne uporabe ANOVA ponovljenih mjerenja. Tablice i grafovi pojedinačnih rezultata ispitnika dostupni su u dodacima 7.4 i 7.5.

Budući da je postojao mali broj ekstremnih vrijednosti (engl. *outlier*) (maksimalno dvije ekstremne vrijednosti za svaki skup od 25 podataka), bilo je potrebno zamijeniti te vrijednosti prikladnom metodom zamjene. Primijenjena je tehnika umetanja vrijednosti medijana umjesto ekstremnih vrijednosti (engl. *median imputation*) [146], budući da je to prva pretpostavka za mogućnost pravilnog korištenja ANOVA analize ponovljenih mjerenja.

Druga pretpostavka za potrebnu ANOVA analizu bio je test normalnosti distribucije vrijednosti. U statistici, testovi normalnosti koriste se kako bi se utvrdilo je li skup podataka modeliran prema normalnoj distribuciji i kako bi se izračunala vjerojatnost da je slučajna varijabla koja je dio osnovnog skupa podataka normalno distribuirana. Drugim riječima, test normalnosti koristi se kako bi se utvrdilo je li uzorak podataka izvučen iz normalno distribuirane populacije (unutar određene tolerancije). Za korištenje ANOVA ponovljenih mjerenja, zahtjev normalno distribuirane populacije uzoraka mora biti zadovoljen. Shapiro-Wilk test [147] testira nultu hipotezu da je uzorak  $x_1, \dots, x_n$  došao iz normalno distribuirane populacije:

$$W = \frac{(\sum_{i=1}^n a_i x_{(i)})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (5.1)$$

gdje su:

- $x_{(i)}$ :  $i$ -ti redni statistik, to jest,  $i$ -ti najmanji broj u uzorku.
- $\bar{x} = (x_1 + \dots + x_n) / n$ : srednja vrijednost uzorka.



Koeficijent  $a_i$  definiran je kao:

$$(a_1, \dots, a_n) = \frac{m^\top V^{-1}}{C} \quad (5.2)$$

gdje je  $C$  vektorska norma:

$$C = \|V^{-1}m\| = \left(m^\top V^{-1}V^{-1}m\right)^{1/2} \quad (5.3)$$

i vektor  $m$ ,

$$m = (m_1, \dots, m_n)^\top \quad (5.4)$$

koji se sastoji od očekivanih vrijednosti rednih statistika nezavisnih i identično distribuiranih slučajnih varijabli uzorkovanih iz standardne normalne distribucije, a  $V$  je matrica kovarijance tih normalnih rednih statistika. Granične vrijednosti za statistike izračunate su pomoću Monte Carlo simulacija. Kao što je navedeno, nulta hipoteza ovog testa je da je populacija normalno distribuirana. Dakle, ako je p-vrijednost manja od odabrane razine značajnosti, tada se odbacuje nulta hipoteza i postoji dokaz da testirani podaci nisu normalno distribuirani. S druge strane, ako je p-vrijednost veća od odabrane razine značajnosti, tada se nulta hipoteza (da podaci potječu iz populacije normalne distribucije) ne može odbaciti. Test normalnosti korištenjem Shapiro-Wilk testa proveden je na svim skupovima podataka, pokazujući da su podaci normalno distribuirani (p-vrijednost je veća od 0,05).


Treća pretpostavka za pravilno korištenje ANOVA ponovljenih mjerenja je test sferičnosti. Mauchly-ev test sferičnosti [148] koristi se kako bi se provjerilo je li pretpostavka sferičnosti ispunjena, te je li ispunjena nulta hipoteza o jednakim varijancama razlika. Ako navedena nulta hipoteza nije ispunjena, tada se F-omjer efektivno povećava i rezultati analize varijance s ponovljenim mjerenjima postaju nepouzdana. Primjenom Mauchly-evog testa sferičnosti na korištene skupove podataka, potvrđeno je da je pretpostavka sferičnosti ispunjena, te da su podaci ANOVA ponovljenih mjerenja pouzdani.

Nakon potvrde svih pretpostavki, generirani su dijagrami pravokutnika za apsolutnu devijaciju od stvarnih horizontalnih i vertikalnih početnih i završnih točaka (slika 5.10).

ANOVA rezultati bili su sljedeći:

- Za horizontalni početni kut:  $F(48, 2) = 7,052, p = 0,002$ .
- Za horizontalni završni kut:  $F(48, 2) = 3,223, p = 0,049$ .
- Za vertikalni početni kut:  $F(48, 2) = 10,113, p = 0,000216$ .
- Za vertikalni završni kut:  $F(48, 2) = 4,542, p = 0,016$ .

Podaci dobiveni iz ispitivanja ukazuju na postojanje statistički značajnih razlika za sva četiri slučaja, s obzirom na HRTF skup koji je korišten. Kako bi se dodatno procijenila učinkovitost vlastitog individualnog HRTF skupa u usporedbi s drugim HRTF skupovima, izvršena je analiza parova (engl. *pair-wise comparison*) [149] uz prilagodbu p-vrijednosti Bonferroni-jevom



**Slika 5.10:** Dijagrami pravokutnika apsolutnog odstupanja od programiranih kutova za početne i završne točke u obje ravnine: (a) horizontalni početni kut; (b) horizontalni završni kut; (c) vertikalni početni kut; i (d) vertikalni završni kut.

korekcijom [150], metodom koja rješava problem višestrukih usporedbi [151, 152]. U statistici, stopa pogreške cijelog skupa (FWER, engl. *family-wise error rate*) je vjerojatnost da će se napraviti jedno ili više lažnih otkrića, odnosno tip *I* pogrešaka prilikom izvođenja višestrukih testova hipoteza. Bonferroni korekcija odbacuje nultu hipotezu za svaki  $p_i \leq \frac{\alpha}{m}$ , čime se provjerava FWER na  $\leq \alpha$ . Dokaz ove provjere slijedi iz Boole-ove nejednakosti:

$$\text{FWER} = P \left\{ \bigcup_{i=1}^{m_0} \left( p_i \leq \frac{\alpha}{m} \right) \right\} \leq \sum_{i=1}^{m_0} \left\{ P \left( p_i \leq \frac{\alpha}{m} \right) \right\} = m_0 \frac{\alpha}{m} \leq \alpha, \quad (5.5)$$

gdje je  $H_1, \dots, H_m$  skup nultih hipoteza,  $p_1, \dots, p_m$  su njihove odgovarajuće p-vrijednosti,  $m$  ukupan broj nultih hipoteza, a  $m_0$  broj istinitih nultih hipoteza. Ova provjera ne zahtijeva pretpostavke o ovisnosti između p-vrijednosti ili o tome koliko je nultih hipoteza istinito. Rezultati

analize parova prikazani su u Tablici 5.1.

**Tablica 5.1:** Rezultati post-hoc testa usporedbe parova provedenog za tri korištena skupa HRTF funkcija.

|                          | Generički HRTF skup i individualni HRTF skup druge osobe <sup>1</sup> |                     | Vlastiti individualni HRTF skup i generički HRTF skup <sup>2</sup> |                     | Vlastiti individualni HRTF skup i individualni HRTF skup druge osobe <sup>3</sup> |                     |
|--------------------------|-----------------------------------------------------------------------|---------------------|--------------------------------------------------------------------|---------------------|-----------------------------------------------------------------------------------|---------------------|
|                          | p <sup>4</sup>                                                        | p-Bonf <sup>5</sup> | p <sup>4</sup>                                                     | p-Bonf <sup>5</sup> | p <sup>4</sup>                                                                    | p-Bonf <sup>5</sup> |
| Horizontalni početni kut | 0.002                                                                 | 0.006               | 0.005                                                              | 0.015               | 0.894                                                                             | 1.000               |
| Horizontalni završni kut | 0.031                                                                 | 0.094               | 0.086                                                              | 0.256               | 0.623                                                                             | 1.000               |
| Vertikalni početni kut   | 0.214                                                                 | 0.642               | 0.002                                                              | 0.007               | 0.001                                                                             | 0.002               |
| Vertikalni završni kut   | 0.674                                                                 | 1.000               | 0.007                                                              | 0.022               | 0.016                                                                             | 0.050               |

<sup>1</sup>Usporedba između generičkog HRTF skupa i individualnog HRTF skupa druge osobe.

<sup>2</sup>Usporedba između vlastitog individualnog HRTF skupa i generičkog HRTF skupa.

<sup>3</sup>Usporedba između vlastitog individualnog HRTF skupa i individualnog HRTF skupa druge osobe.

<sup>4</sup>p-vrijednost.

<sup>5</sup>p-vrijednost prilagođena Bonferroni korekcijom.

Rezultati koji se odnose na horizontalni početni kut ukazuju da nema statistički značajne razlike u apsolutnom odstupanju od programski zadanog kuta između vlastitog individualnog HRTF skupa i individualnog HRTF skupa druge osobe. Međutim, primjećuje se statistički značajna razlika između korištenja oba navedena skupa i korištenja generičkog HRTF skupa, čijim korištenjem su dobiveni lošiji rezultati od oba individualna skupa. Za horizontalni završni kut nije bilo statistički značajne razlike između HRTF skupova. Rezultati dobiveni iz analize parova ukazuju na značajno manje apsolutno odstupanje od programski zadanih vertikalnih početnih i završnih kutova kada se koristi vlastiti individualni HRTF skup, u usporedbi s ostala dva HRTF skupa. Dodatno, dobiveni rezultati mjerenja od strane ispitanika analizirani su radi podatka o percepciji smjera kojim se virtualni zvučni izvor kretao. Ako je brojeva vrijednost završnog kuta veća od početnog, smjeru je dodijeljena vrijednost "1", a ako je brojeva vrijednost završnog kuta manja od početnog, smjeru je dodijeljena vrijednost "0". Ovo je provedeno i za programirane vrijednosti kako bi se odredio ispravan smjer kretanja, i za rezultate mjerenja. Rezultati su prikazani u Tablici 5.2.

Iako podaci koji nedostaju nisu utjecali na izračune apsolutnog odstupanja zbog usrednjavanja neovisnih podataka, treba ih uzeti u obzir prilikom ispravnog određivanja smjera kretanja. Kada se pojavi slučaj nepostojanja podataka, postoje dva moguća načina postupanja: konstatacija da je smjer kretanja izvora neispravno određen ili isključivanje takvih podataka iz daljnje analize. U slučaju da sudionik nije bio siguran gdje je zvučni izvor započeo ili završio (zbog

**Tablica 5.2:** Točnost određivanja smjera kretanja virtualnog zvučnog izvora (u postocima).

|                             | Generički HRTF skup | Vlastiti individualni HRTF skup | Individualni HRTF skup druge osobe |
|-----------------------------|---------------------|---------------------------------|------------------------------------|
| Horizontalna os             | 98.67%              | 98.67%                          | 100%                               |
| Vertikalna os <sup>1</sup>  | 40%                 | 81.33%                          | 50.67%                             |
| Vertikalna os* <sup>2</sup> | 44.12%              | 83.56%                          | 55.07%                             |

<sup>1</sup>Rezultati uz podatke koji nedostaju pripisane neispravno određenom smjeru kretanja.

<sup>2</sup>Rezultati uz isključivanje podataka koji nedostaju iz rezultata ispitivanja određivanja smjera kretanja.

čega odgovarajući podaci i nedostaju), smjer nije mogao biti definiran s apsolutnom sigurnošću. Iz tog razloga, isključenje podataka koji nedostaju je relevantniji pristup. U dijelu ispitivanja koji ispituje percepciju kretanja izvora u horizontalnoj ravnini nije zabilježen ijedan ovakav slučaj.

Hi-kvadrat ( $\chi^2$ ) test [153, 154] često se koristi kada je potrebno utvrditi jesu li dobivene (opažene) frekvencije određenih ishoda odstupale od frekvencija očekivanih uz postavljenu hipotezu, te u slučaju navedenog ispitivanja,  $\chi^2$  test idealno je rješenje za provjeru postojanja mogućih statistički značajnih razlika između rezultata dobivenih za ispravno i neispravno određivanje smjera kretanja u vertikalnoj ravnini u odnosu na očekivane vrijednosti koje se odnose na potpuno slučajno pogađanje smjera kretanja virtualnog zvučnog izvora (pogotovo kod rezultata s generičkim HRTF skupom, jer je postotak ispravnog određivanja smjera bio ispod 50 posto).  $\chi^2$  test najčešće se upotrebljava u sljedećim slučajevima:

- Kada je potrebno odrediti odstupaju li frekvencije ispitivanog uzorka od očekivanih frekvencija uz neku hipotezu (relevantni slučaj za navedeno ispitivanje).
- Kada postoje frekvencije dva ili više nezavisnih uzoraka, te je potrebno odrediti razlikuju li se uzorci u opaženim svojstvima.
- Kad postoje frekvencije dva zavisna uzorka, koji imaju dihotomna svojstva, te je potrebno odrediti razlikuju li se uzorci u mjerenim svojstvima, to jest, je li došlo do promjene.

U većini slučajeva, parametar  $\chi^2$  izračunava se na jednak način, prema formuli:

$$\chi^2 = \sum \frac{(f_0 - f_t)^2}{f_t} \quad (5.6)$$

pri čemu su  $f_0$  opažene frekvencije, a  $f_t$  očekivane (teoretske) frekvencije, to jest, očekivane frekvencije definirane za određenu hipotezu.

Rezultati  $\chi^2$  testa (p-vrijednost jednaka 0,08 za određivanje smjera uz uključivanje nedostajućih podataka, te p-vrijednost jednaka 0,33 za isključivanje nedostajućih podataka iz neisprav-

nih određivanja smjera) impliciraju da u ovom slučaju ne postoji statistički značajna razlika između određivanja smjera s generičkim HRTF skupom i slučajnog odabira, odnosno, određivanje smjera u vertikalnoj ravnini uz uporabu generičkih HRTF skupova u biti se svodi na pogađanje. Također je proveden binomni test (detaljnije opisan u potpoglavlju 5.5.2), koji potvrđuje rezultate  $\chi^2$  testa ( $p$ -vrijednost jednaka 0,3961). Predstavljeni rezultati pokazuju da korištenje vlastitog individualnog HRTF skupa u binauralnoj sintezi dovodi do značajno veće točnosti pri određivanju smjera kretanja virtualnog zvučnog izvora u vertikalnoj ravnini.

### 5.5.2 Ispitivanje subjektivnog vrednovanja prirodnosti i eksternalizacije virtualnog zvučnog izvora

Za dobivanje rezultata ispitivanja, potrebno je koristiti binomni test [155, 156], točni test statističke značajnosti odstupanja od teorijski očekivane distribucije odabira određenog parametra (u trenutnom ispitivanju: skupova) u dvije kategorije koristeći uzorak podataka. Binomni test koristan je za testiranje hipoteza o vjerojatnosti uspjeha ( $\pi$ ):

$$H_0 : \pi = \pi_0 \quad (5.7)$$

gdje je  $\pi_0$  korisnički definirana vrijednost između 0 i 1. Ako u broju nezavisnih izvođenja istog pokusa  $n$ , sa samo dva moguća ishoda (uspjeh i neuspjeh), imamo  $k$  uspjeha, pri čemu se u svakom izvođenju uspjeh ostvaruje s vjerojatnošću  $p$ , formula binomne distribucije daje vjerojatnost pronalaženja te vrijednosti:

$$P(k) = \binom{n}{k} p^k (1-p)^{n-k} \quad (5.8)$$

Ako je nulta hipoteza  $H_0$  točna, tada bi očekivani broj uspjeha bio  $n\pi_0$ . Za odabrani test,  $p$ -vrijednost dobiva se razmatranjem vjerojatnosti ishoda koji je jednak navedenoj vrijednosti, ili ekstremniji. Na primjer, ako je potrebno testirati hipotezu  $\pi < \pi_0$ ,  $p$ -vrijednost bi bila:

$$p = \sum_{i=0}^k P(i) = \sum_{i=0}^k \binom{n}{i} \pi_0^i (1-\pi_0)^{n-i} \quad (5.9)$$

Broj pokušaja u kojima su sudionici ispitivanja uspješno odabrali vlastiti individualni HRTF skup uz dodatna tri individualna HRTF skupa drugih osoba zbrojen je za svakog od 25 sudionika. Zatim je proveden binomni test kako bi se ispitalo je li taj broj značajno veći od očekivane vrijednosti od 2,5 za 10 pokušaja. Navedeni broj pokušaja odgovara slučajnom odabiru.

Spajanjem podataka o uspješnosti ispitanika, ukupno su ispitanici točno prepoznali vlastiti individualni HRTF skup 87 puta od 250 pokušaja. Kao rezultat toga, vjerojatnost da će sudionici odabrati vlastiti HRTF skup bila je značajno veća od slučajnog odabira ( $p$ -vrijednost manja od 0,001).

## 5.6 Diskusija rezultata

Rezultati statističke analize potvrđuju hipotezu da korištenje vlastitog individualnog HRTF skupa rezultira povećanjem točnosti lokalizacije virtualnih izvora zvuka u vertikalnoj ravnini, to jest, u elevaciji zvučnog izvora. To je posebno vidljivo u točnosti određivanja početnog kuta virtualnog zvučnog izvora u navedenoj ravnini. Dodatno, izračunati podaci o točnosti određivanja smjera kretanja virtualnog izvora zvuka u vertikalnoj ravnini (83,56 posto točno određenih smjerova kretanja za vlastiti individualni HRTF skup, u usporedbi s 55,07 posto za individualni HRTF skup druge osobe i 44,12 posto za generički HRTF skup) pokazuju da korištenje vlastitog individualnog HRTF skupa u procesu binauralne sinteze značajno povećava točnost dinamičke lokalizacije virtualnog zvučnog izvora koji se kreće uz promjenu elevacije (a bez promjene azimuta). Iz dobivenih se rezultata zaključuje da korištenje vlastitog individualnog HRTF skupa u procesu binauralne sinteze dovodi do prirodnije i realističnije percepcije tako sintetizirane virtualne zvučne okoline i potiče dublje uranjanje u virtualnu okolinu.

Rezultati statističke analize u vezi točnosti lokalizacije u horizontalnoj ravnini pokazuju da nema statistički značajnog povećanja točnosti lokalizacije korištenjem vlastitog individualnog HRTF skupa u usporedbi s HRTF skupom druge osobe. Upotreba generičkog HRTF skupa pri određivanju početnog kuta u horizontalnoj ravnini dovodi do značajno niže točnosti lokalizacije u usporedbi s ostalim testiranim HRTF skupovima. Dijagram pravokutnika koji pokazuje točnost određivanja završnog kuta zvučnog izvora u horizontalnoj ravnini pokazuje da je upotreba generičkog HRTF skupa rezultirala točnijom lokalizacijom u usporedbi s drugim HRTF skupovima, ali to se povećanje nije pokazalo statistički značajnim. Mogući razlog za takav rezultat je veća rezolucija generičkog HRTF skupa [157], koji sadrži HRTF funkcije izmjerene za 2702 definirana smjera, u usporedbi s individualnim skupovima HRTF funkcija koji sadrže HRTF funkcije izmjerene za 1460 definiranih smjerova. Kako bi se dodatno osiguralo da gustoća HRTF skupa ne bude čimbenik koji može utjecati na provedbu ispitivanja točnosti lokalizacije, buduća istraživanja bi trebala uzeti u obzir HRTF skupove koji sadrže HRTF funkcije izmjerene za točno određene smjerove, te za jednak broj smjerova u svim skupovima. Mogući razlog izostanka poboljšanja u točnosti lokalizacije zvuka u horizontalnoj ravnini korištenjem vlastitog individualnog HRTF skupa može biti taj što na točnost horizontalne lokalizacije zvuka primarno utječu interauralne vremenske i intenzitetne razlike, a manji značaj ima individualna morfologija glave i školjke uha [158]. Stoga, za lokalizaciju izvora zvuka u horizontalnoj rav-

nini, generički HRTF skupovi mogu se koristiti bez značajnijeg gubitka točnosti lokalizacije u usporedbi s individualnim HRTF skupovima.


Rezultati dobiveni ispitivanjem subjektivne evaluacije prirodnosti i eksternalizacije virtualnog zvučnog izvora, koje je ispitivalo sposobnost prepoznavanja vlastitog individualnog HRTF skupa, pokazuju da su ispitanici kao grupa pokazali značajan stupanj sposobnosti identificiranja vlastitog individualnog HRTF skupa kada se njihov HRTF skup grupirao s individualnim HRTF skupovima triju drugih osoba, što pokazuje značajan pozitivan odmak od potpuno slučajnog odabira. U navedenom ispitivanju, ispitanici su imali mogućnost samo odabrati HRTF skup koji smatraju svojim vlastitim. Učinkovitiji pristup, koji bi trebao biti razmotren u budućem istraživanju, bio bi implementacija sustava rangiranja u kojem su sva četiri korištena HRTF skupa rangirani [159]. Ovaj pristup bio bi posebno koristan u situacijama u kojima bi ispitanici imali poteškoće u razlikovanju između vlastitog HRTF skupa i individualnog HRTF skupa druge osobe (u rijetkim slučajevima sličnosti fizičkih karakteristika uha ili oblika glave). Nadalje, potencijalno ograničenje navedenog pristupa je da se mogao koristiti stvarni referentni zvučni izvor. Iako bi upotreba navedenog referentnog izvora mogla rezultirati statistički značajnijim rezultatima u prezentiranom ispitivanju zbog mogućnosti direktne usporedbe stvarnog izvora i virtualnog izvora sintetiziranog uz primjenu vlastitog individualnog HRTF skupa, postoji razlog zašto stvarni zvučni izvor nije korišten u navedenoj postavi ispitivanja. Budući da bi za takvu postavu bilo potrebno da ispitanici skinu slušalice za referentni signal, skidanje slušalica bi potencijalno utjecalo na kalibraciju uređaja za praćenje položaja glave pričvršćenog na slušalice. U budućem istraživanju, bit će razmotreno adekvatno korištenje referentnog zvučnog signala bez utjecaja na kalibraciju cijelog binauralnog sustava.

Nadalje, provedena je dodatna statistička analiza kako bi se istražilo postojanje korelacije između rezultata dva ispitivanja, pomoću raspršenog dijagrama [160] i Pearsonovog koeficijenta korelacije [161]. Međutim, rezultati nisu pokazali statistički značajnu korelaciju (slika 5.11).

Uz poboljšanje navedene metode prepoznavanja vlastitog HRTF skupa u budućem istraživanju, mogućnost korelacije između rezultata dvije metode mogla bi biti ponovno razmotrena. Što se tiče kašnjenja signala binauralnog audio sustava korištenog u ispitivanju točnosti lokalizacije virtualnog zvučnog izvora, očekuje se da bi smanjenje vremena kašnjenja na vrijednost manju od 50 milisekundi dodatno povećalo točnost lokalizacije kada se koriste vlastiti individualni HRTF skupovi za ispitanike. U budućem istraživanju, nadogradnje i poboljšanja binauralnog audio sustava potencijalno mogu rezultirati smanjenim kašnjenjem, pružajući tako dobro polazište za nova ispitivanja čiji bi rezultati dodatno potvrdili rezultate ovog doktorskog istraživanja.

Uz korištenje inovativne metode mjerenja individualnih HRTF skupova, te nove i naprednije metode ispitivanja točnosti lokalizacije virtualnih zvučnih izvora, prezentirani rezultati slažu se s prethodnim istraživanjima [13, 14, 15], koja su također prezentirala statistički značajna poboljšanja performansi kada se u binauralnom audio sustavu koristi vlastiti individualni HRTF





**Slika 5.11:** Graf korelacije dva ispitivanja po rezultatima broja uspješnih pogađanja vlastitog individualnog HRTF skupa ispitivanja subjektivnog vrednovanja prirodosti i eksternalizacije (x os) i apsolutnog odstupanja od programski zadanog kuta ispitivanja točnosti lokalizacije (y os).

skup, posebno u slučaju lokalizacije virtualnih zvučnih izvora na vertikalnoj osi [40]. Navedeni rezultati potvrđuju tvrdnju da korištenje vlastitog individualnog HRTF skupa pruža prirodnije iskustvo slušanja uz izraženiju percepciju uronjenosti u zvučnu okolinu. Jedno istraživanje potvrđuje unaprijeđenja u lokalizaciji izvora zvuka korištenjem individualnog HRTF skupa u usporedbi s generičkim, ali naglasak je stavljen na uvjerljive performanse generičkog HRTF skupa [162]. S druge strane, jedno drugo istraživanje nije pronašlo razliku između korištenja vlastitog individualnog HRTF skupa i generičkog HRTF skupa u dinamičkim virtualnim okruženjima [16], pri čemu su metodologija i dizajn ispitivanja navedenog istraživanja značajno različiti od prezentiranih u glavnom istraživanju ove disertacije. Zbog ovih proturječnih rezultata, buduća istraživanja mogla bi se koncentrirati na identifikaciju učinkovitosti različitih metoda dinamičke lokalizacije virtualnih zvučnih izvora.

# Poglavlje 6

## Zaključak

U ovoj doktorskoj disertaciji predstavljeno je istraživanje ispitivanja kvalitete cijelog sustava binauralne sinteze uz praćenje položaja glave. Navedeno istraživanje predstavlja novu metodu za procjenu točnosti lokalizacije virtualnih zvučnih izvora u binauralnim audio sustavima, s naglaskom na identificiranje mogućih poboljšanja korištenjem vlastitog individualnog HRTF skupa u procesu binauralne sinteze umjesto generičkog HRTF skupa ili individualnog HRTF skupa druge osobe.

Provedena su tri različita mjerenja performansi uređaja s ugrađenim IMU senzorima kako bi se adekvatno ispitala kvaliteta uređaja za praćenje položaja glave, uz korištenje različitih vrsta dostupnih uređaja, te su ispitane i statičke i dinamičke performanse uređaja. Statička mjerenja pokazala su relativnu stabilnost ispitanih uređaja, te su otkrila početne izazove mjerenja koje je trebalo uzeti u obzir kod dinamičkih mjerenja. Dinamička mjerenja metodom rotacijske platforme otkrila su izazove mjerenja kao što su problemi s frekvencijom uzorkovanja senzora i magnetske smetnje uzrokovane motorom rotacijske platforme. Dinamička mjerenja metodom njihala pokazala su da je većina pametnih telefona i ugradbenih sustava pružila zadovoljavajuću kvalitetu izračuna podataka o orijentaciji uz zanemarivo kašnjenje, ispunjavajući osnovni zahtjev za kvalitetno praćenje položaja glave pri kreiranju virtualnih zvučnih okruženja. Korištenje podataka s magnetometra pridonijelo je smanjenju senzorskog odstupanja orijentacije u usporedbi s metodom rotacijske platforme. Na temelju sva tri ispitivanja uređaja s ugrađenim IMU senzorima, za ispitivanja kvalitete binauralne sinteze zaključeno je da je za praćenje položaja glave moguće koristiti kvalitetni uređaj baziran na ugradbenom sustavu ili pametni telefon.

Rezultati preliminarne ispitivanja ukazuju da su oba ispitana bežična uređaja za praćenje položaja glave jednako učinkovita, iako se očekivala razlika zbog načina prijenosa podataka o položaju. Također, izbor binauralnog dekodera nije utjecao na točnost lokalizacije i doživljaj eksternalizacije virtualnog zvučnog izvora. Veća količina odjeka primijenjena na virtualni zvučni izvor rezultirala je doživljajem jače eksternaliziranosti izvora. Kao glavno ograničenje ispitivanja prepoznata je potreba za korištenjem individualnih HRTF skupova za postizanje veće

točnosti lokalizacije zvučnog izvora.

U glavnom ispitivanju ove doktorske disertacije, implementacijom individualnih HRTF skupova u sustav binauralne sinteze umjesto generičkih, ostvareno je poboljšanje u točnosti lokalizacije za vlastiti individualni HRTF skup u vertikalnoj ravnini. Rezultati također sugeriraju izostanak statistički značajnog poboljšanja u točnosti lokalizacije u horizontalnoj ravnini kada se koristi vlastiti HRTF skup u usporedbi s drugim HRTF skupovima. Ispitivanje subjektivnog vrednovanja prirodnosti i eksternalizacije virtualnih zvučnih izvora također je pokazalo indiciju statistički značajne razine sposobnosti prepoznavanja individualnog vlastitog HRTF skupa, ali metodologija zahtijeva daljnje usavršavanje u budućem radu kao potvrdu dobivenih rezultata.

# Poglavlje 7

## Dodatak

### 7.1 Popis kratica

Tekst doktorske disertacije koristi određene kratice koje su uobičajene u obuhvaćenim znanstvenim i inženjerskim područjima, u radovima pisanim većinom na engleskom jeziku. Potpuni značaj takvih kratica na engleskom jeziku naveden je u zagradi pri prvom pojavljivanju kartice, a u ostatku teksta koristi se isključivo kratica. Tablica 7.1 predstavlja kratice, te potpuni značaj svih korištenih kratica na engleskom jeziku.

**Tablica 7.1:** Kratice korištene u tekstu

| Kratica | Potpuni značaj kratice                |
|---------|---------------------------------------|
| VR      | <i>virtual reality</i>                |
| AR      | <i>augmented reality</i>              |
| HRTF    | <i>head-related transfer function</i> |
| 3D      | <i>three-dimensional</i>              |
| ITD     | <i>interaural time difference</i>     |
| ILD     | <i>interaural level difference</i>    |
| HRIR    | <i>head-related impulse response</i>  |
| IMU     | <i>inertial measurement unit</i>      |
| MEMS    | <i>microelectromechanical system</i>  |
| DoF     | <i>degrees of freedom</i>             |

|          |                                              |
|----------|----------------------------------------------|
| GPS      | <i>global positioning system</i>             |
| FPGA     | <i>field-programmable gate array</i>         |
| BLE      | <i>Bluetooth low energy</i>                  |
| OSC      | <i>open sound protocol</i>                   |
| UDP      | <i>user datagram protocol</i>                |
| DAW      | <i>digital audio workstation</i>             |
| HOA      | <i>higher-order Ambisonics</i>               |
| VST      | <i>virtual studio technology</i>             |
| DUT      | <i>device under test</i>                     |
| GMT      | <i>Greenwich mean time</i>                   |
| UTC      | <i>coordinated universal time</i>            |
| HO-DirAC | <i>higher-order directional audio coding</i> |
| ANOVA    | <i>analysis of variance</i>                  |
| DC       | <i>direct current</i>                        |
| AC       | <i>alternating current</i>                   |
| FWER     | <i>family-wise error rate</i>                |

## 7.2 Tablice rezultata preliminarnog ispitivanja kvalitete bi-nauralne sinteze

**Tablica 7.2:** Srednje vrijednosti i standardne devijacije za statični zvučni izvor u preliminarnom mjerenju (mjerna jedinica: °)

|          | NX i IEM |          | NX i HO-DirAC |          | Pametni telefon i IEM |          | Pametni telefon i HO-DirAC |          |
|----------|----------|----------|---------------|----------|-----------------------|----------|----------------------------|----------|
|          | Prosjek  | St. dev. | Prosjek       | St. dev. | Prosjek               | St. dev. | Prosjek                    | St. dev. |
| Osoba 1  | 2,4      | 2,5      | 4,2           | 2,7      | 2                     | 2,0      | 3,8                        | 2,4      |
| Osoba 2  | 2,2      | 1,6      | 2,4           | 0,5      | 2,2                   | 2,9      | 3,2                        | 2,7      |
| Osoba 3  | 1,2      | 1,1      | 2,2           | 1,1      | 3,6                   | 2,9      | 2,8                        | 3,6      |
| Osoba 4  | 5,6      | 3,2      | 3,4           | 2,1      | 7,4                   | 3,8      | 4,8                        | 3,8      |
| Osoba 5  | 7,2      | 2,4      | 3,6           | 3,9      | 4,6                   | 4,5      | 7                          | 3,4      |
| Osoba 6  | 3,8      | 3,1      | 1,8           | 1,9      | 4,6                   | 2,9      | 4,4                        | 2,3      |
| Osoba 7  | 7,8      | 2,2      | 1,8           | 1,9      | 3,6                   | 1,7      | 3,6                        | 1,8      |
| Osoba 8  | 6,4      | 2,4      | 6,2           | 3,9      | 6,2                   | 3,7      | 8,2                        | 1,3      |
| Osoba 9  | 8,2      | 6,6      | 4             | 3,7      | 4,4                   | 6,2      | 12,8                       | 7,5      |
| Osoba 10 | 6,4      | 4,6      | 3,6           | 3,8      | 1,2                   | 0,8      | 7,8                        | 4,3      |
| Osoba 11 | 5,2      | 3,3      | 2,4           | 4,3      | 3,4                   | 2,7      | 7                          | 5,1      |
| Osoba 12 | 7,6      | 2,1      | 1,4           | 1,1      | 1,8                   | 1,5      | 4,6                        | 6,5      |
| Osoba 13 | 11,2     | 7,5      | 9,8           | 8,6      | 18,6                  | 10,1     | 11,2                       | 2,2      |
| Osoba 14 | 13,2     | 6,4      | 14,4          | 10,1     | 13,8                  | 4,0      | 17,8                       | 7,5      |
| Osoba 15 | 3,6      | 5,5      | 5,8           | 1,3      | 3,2                   | 2,9      | 4                          | 2,5      |

**Tablica 7.3:** Srednje vrijednosti i standardne devijacije za dinamički zvučni izvor u preliminarnom mjerenju (mjerna jedinica: °)

|          | NX i IEM |          | NX i HO-DirAC |          | Pametni telefon i IEM |          | Pametni telefon i HO-DirAC |          |
|----------|----------|----------|---------------|----------|-----------------------|----------|----------------------------|----------|
|          | Prosjek  | St. dev. | Prosjek       | St. dev. | Prosjek               | St. dev. | Prosjek                    | St. dev. |
| Osoba 1  | 4,3      | 3,2      | 9,3           | 7,6      | 4,7                   | 4,6      | 7,0                        | 3,6      |
| Osoba 2  | 5,7      | 1,5      | 5,7           | 5,1      | 2,0                   | 0,0      | 3,7                        | 3,8      |
| Osoba 3  | 4,3      | 3,5      | 4,7           | 2,5      | 3,7                   | 3,2      | 7,0                        | 4,6      |
| Osoba 4  | 6,0      | 3,0      | 7,7           | 4,9      | 8,3                   | 2,9      | 9,7                        | 4,9      |
| Osoba 5  | 6,7      | 5,9      | 3,3           | 4,2      | 2,3                   | 0,6      | 12,7                       | 5,5      |
| Osoba 6  | 3,0      | 2,6      | 3,7           | 1,5      | 2,7                   | 2,1      | 1,7                        | 2,1      |
| Osoba 7  | 10,7     | 1,5      | 7,0           | 6,1      | 1,7                   | 2,9      | 12,3                       | 1,5      |
| Osoba 8  | 12,0     | 7,5      | 6,7           | 3,2      | 10,7                  | 5,1      | 7,3                        | 4,7      |
| Osoba 9  | 8,3      | 6,0      | 13,7          | 11,8     | 11,0                  | 14,9     | 14,0                       | 7,0      |
| Osoba 10 | 12,7     | 5,8      | 14,7          | 5,0      | 6,7                   | 4,5      | 5,7                        | 4,9      |
| Osoba 11 | 6,7      | 9,8      | 10,3          | 0,6      | 11,7                  | 7,6      | 14,0                       | 13,7     |
| Osoba 12 | 6,7      | 7,4      | 6,0           | 1,7      | 6,0                   | 3,0      | 5,0                        | 4,0      |
| Osoba 13 | 18,7     | 6,4      | 26,0          | 8,7      | 13,0                  | 2,6      | 19,0                       | 2,0      |
| Osoba 14 | 8,3      | 0,6      | 9,7           | 9,3      | 6,3                   | 5,1      | 18,0                       | 11,0     |
| Osoba 15 | 4,0      | 4,4      | 4,7           | 1,2      | 2,7                   | 2,1      | 5,7                        | 1,5      |

**Tablica 7.4:** Srednje vrijednosti za ispitivanje eksternalizacije virtualnog zvučnog izvora u preliminar-  
nom mjerenju (ocjene od 1 do 9)

|                 | <b>IEM - 0 s</b> | <b>IEM - 0,4 s</b> | <b>IEM - 0,8 s</b> | <b>Ho-DirAC - 0 s</b> | <b>Ho-DirAC - 0,4 s</b> | <b>Ho-DirAC - 0,8 s</b> |
|-----------------|------------------|--------------------|--------------------|-----------------------|-------------------------|-------------------------|
| <b>Osoba 1</b>  | 1                | 3                  | 5                  | 1                     | 2                       | 4,5                     |
| <b>Osoba 2</b>  | 1                | 7,5                | 7,5                | 2,5                   | 9                       | 5,5                     |
| <b>Osoba 3</b>  | 1,5              | 3                  | 6,5                | 1                     | 2,5                     | 8                       |
| <b>Osoba 4</b>  | 1,5              | 6,5                | 8,5                | 3,5                   | 5,5                     | 6                       |
| <b>Osoba 5</b>  | 2,5              | 6                  | 8,5                | 2                     | 3                       | 8,5                     |
| <b>Osoba 6</b>  | 2                | 5                  | 8,5                | 1,5                   | 3,5                     | 8                       |
| <b>Osoba 7</b>  | 2                | 3,5                | 6                  | 1                     | 7,5                     | 5,5                     |
| <b>Osoba 8</b>  | 3                | 5,5                | 8,5                | 2                     | 5,5                     | 7,5                     |
| <b>Osoba 9</b>  | 1                | 5,5                | 8,5                | 1                     | 2                       | 6                       |
| <b>Osoba 10</b> | 5                | 5                  | 5                  | 3,5                   | 6                       | 4,5                     |
| <b>Osoba 11</b> | 2                | 6,5                | 7,5                | 3                     | 7,5                     | 7,5                     |
| <b>Osoba 12</b> | 1                | 4                  | 6,5                | 1                     | 3                       | 6                       |
| <b>Osoba 13</b> | 1                | 8,5                | 4,5                | 1                     | 9                       | 5                       |
| <b>Osoba 14</b> | 1,5              | 4                  | 6,5                | 4,5                   | 4                       | 3,5                     |
| <b>Osoba 15</b> | 2                | 4,5                | 7,5                | 1,5                   | 4                       | 8                       |



## 7.3 R kod za izračun rezultata ANOVA ponovljenih mjerenja

```

1 library(xlsx)
2 library(rstatix)
3 library(reshape)
4 library(tidyverse)
5 library(dplyr)
6 library(ggpubr)
7 library(plyr)
8 library(datarium)
9
10 #ucitavanjeexceldatotekeza4skupine
11 #(vertikalnailihorizontalnaos,startniilizavršnikut)
12 data<-read.xlsx("Documents/Podaci.xlsx",sheetName="Sheet1")
13
14 #prilagodbazapisapodataka
15 data<-data%>%
16   gather(key ="HRTF", value ="Angle") %>%
17   convert_as_factor(Subject, HRTF)
18 data.frame(head(data, 75))
19
20 summary<-data%>%
21   group_by(HRTF) %>%
22   get_summary_stats(Angle, type ="mean_sd")
23 data.frame(summary)
24
25 #crtanjedijagramapravokutnika
26 levels(data$HRTF)
27 par(mar=c(6,6,2,2) +0.1)
28 boxplot(Angle~HRTF,data=data, ylim =c(0, 60), whisklwd = 2,
29   staplelwd = 2.5, xaxt="n",col=c('khaki','cadetblue',
30   'darkolivegreen1'), xlab="HRTFskup",
31   ylab="Apsolutnoodstupanjeodprogramiranogkuta",
32   cex.lab=2.6, cex.axis= 1.8 , cex.main=2.4, cex.sub=2.4)
33 legend('topright',text.width = 0.6, cex = 1,
34   c("Genericki","Individualnidrugeosobe",
35   "Individualnivlastiti"),
36   border="black", fill =c('khaki','cadetblue',
37   'darkolivegreen1'))
38
39 #provjeraoutliera
40 outlier<-data%>%
41   group_by(HRTF) %>%
42   identify_outliers(Angle)
43 data.frame(outlier)

```

```
44
45 #provjeranormalnosti
46 normality<-data%>%
47     group_by(HRTF) %>%
48     shapiro_test(Angle)
49 data.frame(normality)
50
51
52 #pretpostavkasfericnostiiANOVA
53 res<-anova_test(data=data,dv=Angle ,
54                 wid=Subject ,within=HRTF)
55 get_anova_table(res)
56
57
58 #usporednaanaliza
59 pair<-data%>%
60 pairwise_t_test(Angle~HRTF,paired=TRUE ,
61                 p.adjust.method ="bonferroni")
62 data.frame(pair)
```

## 7.4 Tablice rezultata glavnog ispitivanja točnosti lokalizacije virtualnog zvučnog izvora

**Tablica 7.5:** Glavno ispitivanje točnosti lokalizacije - srednje vrijednosti i standardna devijacija za horizontalni početni kut (mjerna jedinica: °)

| Redni broj ispitanika | Generički HRTF skup |          | Ind. HRTF skup druge osobe |          | Ind. Vlastiti HRTF skup |          |
|-----------------------|---------------------|----------|----------------------------|----------|-------------------------|----------|
|                       | Prosjeak            | St. dev. | Prosjeak                   | St. dev. | Prosjeak                | St. dev. |
| Osoba 1               | 8,3                 | 2,9      | 9,0                        | 1,0      | 3,3                     | 1,5      |
| Osoba 2               | 5,3                 | 5,1      | 9,0                        | 9,6      | 5,7                     | 6,0      |
| Osoba 3               | 12,0                | 7,9      | 7,7                        | 2,5      | 12,3                    | 10,8     |
| Osoba 4               | 13,0                | 3,6      | 19,3                       | 1,2      | 13,0                    | 12,2     |
| Osoba 5               | 19,7                | 17,8     | 17,7                       | 16,6     | 14,0                    | 9,6      |
| Osoba 6               | 10,3                | 8,1      | 10,7                       | 5,1      | 10,7                    | 6,0      |
| Osoba 7               | 24,7                | 9,0      | 24,0                       | 13,3     | 17,3                    | 7,5      |
| Osoba 8               | 23,3                | 8,1      | 12,0                       | 10,4     | 11,0                    | 8,2      |
| Osoba 9               | 16,3                | 2,5      | 6,0                        | 3,6      | 5,7                     | 4,0      |
| Osoba 10              | 3,7                 | 2,5      | 4,3                        | 1,2      | 0,7                     | 1,2      |
| Osoba 11              | 13,0                | 8,5      | 7,7                        | 2,5      | 12,3                    | 8,7      |
| Osoba 12              | 28,0                | 20,1     | 24,0                       | 18,5     | 20,7                    | 9,8      |
| Osoba 13              | 14,7                | 10,1     | 14,0                       | 3,5      | 11,3                    | 7,1      |
| Osoba 14              | 30,3                | 11,0     | 21,3                       | 9,1      | 20,7                    | 4,0      |
| Osoba 15              | 17,3                | 5,8      | 10,0                       | 5,0      | 26,3                    | 12,7     |
| Osoba 16              | 12,0                | 7,9      | 5,3                        | 5,9      | 9,3                     | 4,9      |
| Osoba 17              | 19,7                | 9,0      | 14,3                       | 9,0      | 17,3                    | 7,5      |
| Osoba 18              | 10,3                | 5,1      | 10,3                       | 4,5      | 4,0                     | 5,3      |
| Osoba 19              | 21,3                | 8,7      | 15,0                       | 8,7      | 17,3                    | 6,4      |
| Osoba 20              | 8,3                 | 1,2      | 5,7                        | 3,1      | 7,0                     | 3,6      |
| Osoba 21              | 16,3                | 19,9     | 11,7                       | 7,6      | 12,0                    | 10,6     |
| Osoba 22              | 6,3                 | 2,5      | 4,3                        | 1,2      | 7,3                     | 2,5      |
| Osoba 23              | 18,0                | 13,9     | 11,0                       | 5,3      | 12,3                    | 6,4      |
| Osoba 24              | 7,0                 | 1,7      | 12,7                       | 6,4      | 15,7                    | 5,1      |
| Osoba 25              | 10,3                | 5,1      | 1,0                        | 1,7      | 4,0                     | 3,6      |

**Tablica 7.6:** Glavno ispitivanje točnosti lokalizacije - srednje vrijednosti i standardna devijacija za horizontalni završni kut (mjerna jedinica: °)

| Redni broj ispitanika | Generički HRTF skup |          | Ind. HRTF skup druge osobe |          | Ind. Vlastiti HRTF skup |          |
|-----------------------|---------------------|----------|----------------------------|----------|-------------------------|----------|
|                       | Prosjek             | St. dev. | Prosjek                    | St. dev. | Prosjek                 | St. dev. |
| Osoba 1               | 5,3                 | 3,8      | 6,7                        | 3,5      | 11,7                    | 10,0     |
| Osoba 2               | 3,3                 | 2,5      | 10,7                       | 7,8      | 10,0                    | 4,0      |
| Osoba 3               | 3,7                 | 8,1      | 7,7                        | 2,1      | 5,7                     | 1,2      |
| Osoba 4               | 8,0                 | 4,4      | 18,0                       | 8,6      | 14,0                    | 16,4     |
| Osoba 5               | 7,7                 | 4,6      | 3,3                        | 4,0      | 7,3                     | 6,7      |
| Osoba 6               | 8,0                 | 7,0      | 10,7                       | 0,6      | 6,3                     | 4,2      |
| Osoba 7               | 8,3                 | 6,4      | 17,3                       | 5,2      | 19,7                    | 12,3     |
| Osoba 8               | 3,0                 | 5,2      | 3,0                        | 2,0      | 4,3                     | 3,1      |
| Osoba 9               | 4,3                 | 7,6      | 3,7                        | 2,5      | 3,0                     | 2,0      |
| Osoba 10              | 4,0                 | 6,1      | 3,0                        | 1,7      | 3,3                     | 0,6      |
| Osoba 11              | 13,0                | 6,5      | 14,0                       | 12,7     | 13,0                    | 11,7     |
| Osoba 12              | 5,3                 | 3,5      | 5,3                        | 5,9      | 9,3                     | 4,2      |
| Osoba 13              | 1,3                 | 2,1      | 6,7                        | 1,5      | 3,7                     | 4,7      |
| Osoba 14              | 9,0                 | 4,6      | 6,3                        | 3,1      | 3,7                     | 3,8      |
| Osoba 15              | 7,0                 | 5,6      | 11,3                       | 5,3      | 9,7                     | 3,2      |
| Osoba 16              | 6,7                 | 7,1      | 11,3                       | 7,5      | 6,7                     | 2,5      |
| Osoba 17              | 13,0                | 10,6     | 11,0                       | 6,1      | 19,0                    | 17,0     |
| Osoba 18              | 9,0                 | 6,1      | 6,0                        | 2,6      | 1,0                     | 1,0      |
| Osoba 19              | 6,3                 | 0,6      | 5,7                        | 2,3      | 10,3                    | 0,6      |
| Osoba 20              | 4,0                 | 7,8      | 8,7                        | 7,8      | 5,3                     | 3,8      |
| Osoba 21              | 11,7                | 13,0     | 7,0                        | 4,0      | 3,7                     | 3,1      |
| Osoba 22              | 5,0                 | 4,4      | 7,3                        | 1,2      | 9,3                     | 6,0      |
| Osoba 23              | 4,0                 | 7,8      | 12,0                       | 2,6      | 11,0                    | 5,3      |
| Osoba 24              | 7,7                 | 2,5      | 16,0                       | 7,2      | 10,7                    | 7,0      |
| Osoba 25              | 6,3                 | 6,5      | 2,7                        | 0,6      | 4,7                     | 4,7      |


**Tablica 7.7:** Glavno ispitivanje točnosti lokalizacije - srednje vrijednosti i standardna devijacija za vertikalni početni kut (mjerna jedinica: °)

| Redni broj ispitanika | Generički HRTF skup |          | Ind. HRTF skup druge osobe |          | Ind. Vlastiti HRTF skup |          |
|-----------------------|---------------------|----------|----------------------------|----------|-------------------------|----------|
|                       | Prosjek             | St. dev. | Prosjek                    | St. dev. | Prosjek                 | St. dev. |
| Osoba 1               | 24,7                | 28,0     | 35,7                       | 37,6     | 9,0                     | 7,2      |
| Osoba 2               | 22,0                | 0,0      | 13,0                       | 0,0      | 10,0                    | 0,0      |
| Osoba 3               | 35,3                | 38,7     | 28,3                       | 18,8     | 9,3                     | 6,0      |
| Osoba 4               | 25,3                | 38,7     | 43,7                       | 45,6     | 12,7                    | 6,8      |
| Osoba 5               | 59,0                | 60,8     | 54,0                       | 0,0      | 47,0                    | 65,8     |
| Osoba 6               | 8,0                 | 13,9     | 58,3                       | 23,5     | 12,7                    | 11,0     |
| Osoba 7               | 36,3                | 42,2     | 28,3                       | 37,8     | 36,0                    | 45,0     |
| Osoba 8               | 24,5                | 0,0      | 24,3                       | 14,5     | 19,7                    | 12,4     |
| Osoba 9               | 35,3                | 29,8     | 38,3                       | 32,1     | 31,0                    | 23,3     |
| Osoba 10              | 8,0                 | 3,5      | 28,3                       | 12,3     | 24,3                    | 16,9     |
| Osoba 11              | 19,7                | 0,6      | 21,7                       | 27,4     | 11,0                    | 7,9      |
| Osoba 12              | 46,3                | 52,2     | 39,7                       | 46,8     | 7,3                     | 6,8      |
| Osoba 13              | 19,7                | 26,3     | 36,3                       | 41,4     | 32,0                    | 48,5     |
| Osoba 14              | 5,3                 | 0,6      | 5,0                        | 4,4      | 14,3                    | 9,0      |
| Osoba 15              | 20,7                | 29,7     | 34,0                       | 26,6     | 3,0                     | 0,0      |
| Osoba 16              | 20,3                | 5,5      | 25,3                       | 21,1     | 17,7                    | 16,2     |
| Osoba 17              | 25,3                | 15,5     | 50,0                       | 4,4      | 6,0                     | 3,6      |
| Osoba 18              | 35,3                | 20,0     | 30,0                       | 6,2      | 15,7                    | 6,0      |
| Osoba 19              | 43,0                | 37,0     | 16,7                       | 4,2      | 26,0                    | 19,1     |
| Osoba 20              | 34,7                | 9,0      | 35,3                       | 27,3     | 25,7                    | 17,2     |
| Osoba 21              | 49,7                | 26,7     | 50,0                       | 31,8     | 17,0                    | 11,5     |
| Osoba 22              | 49,7                | 24,4     | 51,3                       | 43,7     | 18,7                    | 12,1     |
| Osoba 23              | 41,0                | 32,6     | 30,3                       | 31,8     | 34,3                    | 33,9     |
| Osoba 24              | 27,0                | 25,5     | 22,0                       | 31,4     | 37,7                    | 28,9     |
| Osoba 25              | 22,3                | 14,6     | 34,3                       | 3,2      | 18,3                    | 12,6     |


**Tablica 7.8:** Glavno ispitivanje točnosti lokalizacije - srednje vrijednosti i standardna devijacija za vertikalni završni kut (mjerna jedinica: °)

| Redni broj ispitanika | Generički HRTF skup |          | Ind. HRTF skup druge osobe |          | Ind. vlastiti HRTF skup |          |
|-----------------------|---------------------|----------|----------------------------|----------|-------------------------|----------|
|                       | Prosjek             | St. dev. | Prosjek                    | St. dev. | Prosjek                 | St. dev. |
| Osoba 1               | 51,0                | 34,2     | 40,7                       | 26,3     | 34,3                    | 35,2     |
| Osoba 2               | 40,0                | 0,0      | 39,0                       | 0,0      | 9,5                     | 0,0      |
| Osoba 3               | 30,3                | 24,1     | 26,0                       | 15,9     | 12,3                    | 11,0     |
| Osoba 4               | 15,0                | 10,0     | 30,7                       | 12,9     | 11,7                    | 4,2      |
| Osoba 5               | 20,0                | 0,0      | 35,0                       | 0,0      | 11,3                    | 12,1     |
| Osoba 6               | 27,3                | 28,6     | 6,7                        | 3,8      | 28,0                    | 11,5     |
| Osoba 7               | 17,3                | 15,7     | 7,3                        | 8,1      | 16,3                    | 14,0     |
| Osoba 8               | 16,5                | 0,0      | 20,7                       | 23,4     | 18,3                    | 16,2     |
| Osoba 9               | 45,0                | 10,0     | 13,0                       | 13,1     | 31,3                    | 12,9     |
| Osoba 10              | 4,3                 | 4,0      | 14,0                       | 6,1      | 8,3                     | 8,5      |
| Osoba 11              | 47,7                | 33,3     | 53,3                       | 29,9     | 11,7                    | 9,6      |
| Osoba 12              | 21,3                | 9,3      | 28,3                       | 11,6     | 20,7                    | 5,5      |
| Osoba 13              | 52,0                | 10,6     | 50,0                       | 13,5     | 42,0                    | 1,5      |
| Osoba 14              | 22,7                | 4,0      | 21,0                       | 21,4     | 13,7                    | 12,1     |
| Osoba 15              | 8,0                 | 5,0      | 50,3                       | 4,2      | 16,3                    | 11,6     |
| Osoba 16              | 37,3                | 24,2     | 57,3                       | 18,6     | 33,0                    | 25,2     |
| Osoba 17              | 30,7                | 16,0     | 14,0                       | 14,7     | 22,0                    | 9,6      |
| Osoba 18              | 20,7                | 26,1     | 27,3                       | 30,7     | 21,7                    | 25,1     |
| Osoba 19              | 37,7                | 9,3      | 20,0                       | 30,3     | 30,0                    | 28,0     |
| Osoba 20              | 13,3                | 10,4     | 17,7                       | 13,3     | 17,0                    | 9,6      |
| Osoba 21              | 22,7                | 16,2     | 24,3                       | 8,7      | 12,7                    | 4,5      |
| Osoba 22              | 8,0                 | 2,6      | 25,7                       | 20,0     | 21,7                    | 22,3     |
| Osoba 23              | 18,3                | 11,9     | 18,0                       | 18,7     | 7,7                     | 4,0      |
| Osoba 24              | 24,3                | 16,9     | 20,7                       | 22,1     | 13,3                    | 6,5      |
| Osoba 25              | 21,7                | 23,7     | 24,3                       | 13,1     | 24,3                    | 22,5     |

## 7.5 Grafovi prosječnih vrijednosti rezultata ispitanika glavnog ispitivanja točnosti lokalizacije




**Slika 7.1:** Pojedinačni prosječni rezultati i trake grešaka ispitivanja točnosti lokalizacije za horizontalni početni kut.




**Slika 7.2:** Pojedinačni prosječni rezultati i trake grešaka ispitivanja točnosti lokalizacije za horizontalni završni kut.





**Slika 7.3:** Pojedinačni prosječni rezultati i trake grešaka ispitivanja točnosti lokalizacije za vertikalni početni kut.



**Slika 7.4:** Pojedinačni prosječni rezultati i trake grešaka ispitivanja točnosti lokalizacije za vertikalni završni kut.

# Literatura

- [1]Ward, M. C., “Leveraging a Long and Tuneful History: Perspectival Manipulation, Surround Sound, and Dolby Atmos”, in *The Oxford Handbook of Cinematic Listening*. Oxford University Press, 04 2021, dostupno na: <https://doi.org/10.1093/oxfordhb/9780190853617.013.10>
- [2]Fitzpatrick, F., “3 Ways Spatial Audio Can Transform The Future Of Digital Health”, dostupno na: <https://www.forbes.com/sites/frankfitzpatrick/2022/01/13/3-ways-spatial-audio-can-transform-the-future-of-digital-health/?sh=5afcc26d208f> (pristupljeno 13. lipnja 2024.).
- [3]Middlebrooks, J. C., “Chapter 6 - Sound localization”, in *The Human Auditory System*, ser. *Handbook of Clinical Neurology*, Aminoff, M. J., Boller, F., Swaab, D. F., (ur.). Elsevier, 2015, Vol. 129, str. 99-116, dostupno na: <https://www.sciencedirect.com/science/article/pii/B9780444626301000068>
- [4]Shilling, R. D., Shinn-Cunningham, B., “Virtual auditory displays”, in *Handbook of virtual environments: Design, implementation, and applications*, Stanney, K. M., (ur.). Mahwah, NJ, USA: Lawrence Erlbaum Associates Publishers, 2002, str. 65–92.
- [5]Broderick, J., Duggan, J., Redfern, S., “The Importance of Spatial Audio in Modern Games and Virtual Environments”, in *2018 IEEE Games, Entertainment, Media Conference (GEM)*, 2018, str. 1-9.
- [6]Johnston, D., Egermann, H., Kearney, G., “The Use of Binaural Based Spatial Audio in the Reduction of Auditory Hypersensitivity in Autistic Young People”, *International Journal of Environmental Research and Public Health*, Vol. 19, No. 19, 2022, dostupno na: <https://www.mdpi.com/1660-4601/19/19/12474>
- [7]Braj čić, H., Situm, M., “Virtual Reality in Medicine”, *Rad Hrvatske akademije znanosti i umjetnosti. Medicinske znanosti*, Vol. 543, 01 2020, str. 39-43.
- [8]Liu, D., Dede, C., Huang, R., Richards, J., *Virtual, Augmented, and Mixed Realities in Education*. Singapore: Springer, 01 2017.

- [9]Polcar, J., Horejsi, P., “Knowledge acquisition and cyber sickness: A comparison of VR devices in virtual tours”, *MM Science Journal*, Vol. 2015, 06 2015, str. 613-616.
- [10]Berger, C. C., Gonzalez-Franco, M., Tajadura-Jiménez, A., Florencio, D., Zhang, Z., “Generic HRTFs May be Good Enough in Virtual Reality. Improving Source Localization through Cross-Modal Plasticity”, *Frontiers in Neuroscience*, Vol. 12, 2018, dostupno na: <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2018.00021>
- [11]Jenny, C., Reuter, C., “Usability of Individualized Head-Related Transfer Functions in Virtual Reality: Empirical Study With Perceptual Attributes in Sagittal Plane Sound Localization”, *JMIR Serious Games*, Vol. 8, No. 3, Sep 2020, str. e17 576:8-e17 576:9, dostupno na: <https://doi.org/10.2196/17576>
- [12]Møller, H., “Fundamentals of binaural technology”, *Applied Acoustics*, Vol. 36, No. 3, Jan. 1992, str. 171–218, dostupno na: <https://www.sciencedirect.com/science/article/pii/0003682X9290046U>
- [13]Oberem, J., Richter, J.-G., Setzer, D., Seibold, J., Koch, I., Fels, J., “Experiments on localization accuracy with non-individual and individual HRTFs comparing static and dynamic reproduction methods”, dostupno na: <https://www.biorxiv.org/content/10.1101/2020.03.31.011650v1> Pages: 2020.03.31.011650 Section: New Results. Mar. 2020.
- [14]Wang, L., Zeng, X., Ma, X., “Advancement of Individualized Head-Related Transfer Functions (HRTFs) in Perceiving the Spatialization Cues: Case Study for an Integrated HRTF Individualization Method”, *Applied Sciences*, Vol. 9, No. 9, Jan. 2019, str. 1867, number: 9 Publisher: Multidisciplinary Digital Publishing Institute, dostupno na: <https://www.mdpi.com/2076-3417/9/9/1867>
- [15]Andersen, J. S., Miccini, R., Serafin, S., Spagnol, S., “Evaluation of Individualized HRTFs in a 3D Shooter Game: 2021 Immersive and 3D Audio”, *2021 Immersive and 3D Audio*, 2021, str. 1–10, place: Piscataway, NJ, USA Publisher: IEEE, dostupno na: <http://www.scopus.com/inward/record.url?scp=85123190054&partnerID=8YFLogxK>
- [16]Rummukainen, O. S., Robotham, T., Habets, E. A. P., “Head-Related Transfer Functions for Dynamic Listeners in Virtual Reality”, *Applied Sciences*, Vol. 11, No. 14, Jan. 2021, str. 6646, number: 14 Publisher: Multidisciplinary Digital Publishing Institute, dostupno na: <https://www.mdpi.com/2076-3417/11/14/6646>
- [17]Crocker, M., Arenas, J., *Human Hearing, Speech and Psychoacoustics*. John Wiley & Sons Inc, 01 2021, str. 95-124.

- [18]Masterton, B., Heffner, H., Ravizza, R., “The Evolution of Human Hearing”, The Journal of the Acoustical Society of America, Vol. 45, 05 1969, str. 966-85.
- [19]Judaš, M., Kostović, I., Temelji neuroznanosti. MD, 1997, dostupno na: <https://urn.nsk.hr/urn:nbn:hr:105:136919>
- [20]Leljak, L., “Šum i slušanje”, diplomski rad, Sveučilište u Zagrebu, Filozofski fakultet u Zagrebu, 2019, dostupno na: <https://www.bib.irb.hr:8443/1026982>
- [21]Chari, D. A., Limb, C. J., “Tinnitus”, The Medical Clinics of North America, Vol. 102, No. 6, Nov. 2018, str. 1081–1093.
- [22]Gelfand, S., Essentials of Audiology. Thieme, 01 2011, str. 87-88.
- [23]Valiente, A. R., Trinidad, A., Berrocal, J. R. G., Górriz, C., Camacho, R. R., “Extended high-frequency (9–20 khz) audiometry reference thresholds in 645 healthy subjects”, International Journal of Audiology, Vol. 53, No. 8, 2014, str. 531-545.
- [24]Kim, S., Lim, E., Kim, H., Park, J., Jarng, S., Lee, S., “Sex Differences in a Cross Sectional Study of Age-related Hearing Loss in Korean”, Clin Exp Otorhinolaryngol, Vol. 3, No. 1, 2010, str. 27-31, dostupno na: <http://e-ceo.org/journal/view.php?number=110>
- [25]Helfer, K., Wilber, L., “Hearing Loss, Aging, and Speech Perception in Reverberation and Noise”, Journal of speech and hearing research, Vol. 33, 04 1990, str. 149-55.
- [26]Spagnol, S., Geronazzo, M., Avanzini, F., “On the Relation Between Pinna Reflection Patterns and Head-Related Transfer Function Features”, TASLP, 03 2013.
- [27]Blauert, J., Spatial Hearing: The Psychophysics of Human Sound Localization. The MIT Press, 10 1996, dostupno na: <https://doi.org/10.7551/mitpress/6391.001.0001>
- [28]Middlebrooks, J. C., Green, D. M., “Directional dependence of interaural envelope delays”, The Journal of the Acoustical Society of America, Vol. 87, No. 5, May 1990, str. 2149–2162.
- [29]Wightman, F. L., Kistler, D. J., “Sound Localization”, in Human Psychophysics, Yost, W. A., Popper, A. N., Fay, R. R., (ur.). New York, NY: Springer New York, 1993, str. 155–192, dostupno na: [https://doi.org/10.1007/978-1-4612-2728-1\\_5](https://doi.org/10.1007/978-1-4612-2728-1_5)
- [30]Kapralos, B., Jenkin, M. R., Milios, E., “Virtual Audio Systems”, Presence: Teleoperators and Virtual Environments, Vol. 17, No. 6, 12 2008, str. 527-549, dostupno na: <https://doi.org/10.1162/pres.17.6.527>

- [31]Horvat, M., “Tehnike stereo snimanja”, prezentacija iz predmeta Elektroakustika i audiotehnika 2023/2024, Sveučilište u Zagrebu, Muzička akademija, 2024, [https://www.fer.unizg.hr/\\_download/repository/Eat%2004%20Tehnike%20stereo%20snimanja%202023-24.pptx](https://www.fer.unizg.hr/_download/repository/Eat%2004%20Tehnike%20stereo%20snimanja%202023-24.pptx) (pristupljeno 13. lipnja 2024.).
- [32]Brüel & Kjær, “TYPE 4128-C HEAD AND TORSO SIMULATOR (HATS)”, dostupno na: <https://www.bksv.com/en/transducers/simulators/head-and-torso/hats-type-4128c> (pristupljeno 13. lipnja 2024.).
- [33]Röttger, S., Schröger, E., Grube, M., Grimm, S., Rübsamen, R., “Mismatch negativity on the cone of confusion”, *Neuroscience letters*, Vol. 414, 04 2007, str. 178-182.
- [34]Cheng, C. I., Wakefield, G. H., “Introduction to Head-Related Transfer Functions (HRTFs): Representations of HRTFs in Time, Frequency, and Space”, *J. Audio Eng. Soc.*, Vol. 49, No. 4, 2001, str. 231–249, dostupno na: <https://www.aes.org/e-lib/browse.cfm?elib=10196>
- [35]Yang, Z., Choudhury, R., “Personalizing head related transfer functions for earables”, in *ACM SIGCOMM 2021 Conference (SIGCOMM '21)*, August 23–27, 2021, Virtual Event, USA. ACM, New York, NY, USA, 08 2021, str. 137-150.
- [36]Yu, G., Wu, R., Liu, Y., Xie, B., “Near-field head-related transfer-function measurement and database of human subjects”, *The Journal of the Acoustical Society of America*, Vol. 143, 03 2018, str. EL194-EL198.
- [37]Berwick, N., Lee, H., “Spatial Unmasking Effect on Speech Reception Threshold in the Median Plane”, *Applied Sciences*, Vol. 10, No. 15, 2020, dostupno na: <https://www.mdpi.com/2076-3417/10/15/5257>
- [38]Vorländer, M., “Signal Processing for Auralization”, in *Auralization: Fundamentals of Acoustics, Modelling, Simulation, Algorithms and Acoustic Virtual Reality*, Vorländer, M., (ur.). Cham: Springer International Publishing, 2020, str. 99–118, dostupno na: [https://doi.org/10.1007/978-3-030-51202-6\\_7](https://doi.org/10.1007/978-3-030-51202-6_7)
- [39]Hammershøi, D., Møller, H., “Binaural Technique — Basic Methods for Recording, Synthesis, and Reproduction”, in *Communication Acoustics*, Blauert, J., (ur.). Berlin, Heidelberg: Springer, 2005, str. 223–254, dostupno na: [https://doi.org/10.1007/3-540-27437-5\\_9](https://doi.org/10.1007/3-540-27437-5_9)
- [40]Rummukainen, O., Robotham, T., Plinge, A., Wefers, F., Herre, J., Habets, E., “Listening Tests with Individual versus Generic Head-Related Transfer Functions in Six-Degrees-of-Freedom Virtual Reality”, *Audio for Virtual, Augmented and Mixed*

- Realities: Proceedings of ICSA 2019 ; 5th International Conference on Spatial Audio ; September 26th to 28th, 2019, Ilmenau, Germany, Nov. 2019, str. 55–62, dostupno na: [https://www.db-thueringen.de/receive/dbt\\_mods\\_00039954](https://www.db-thueringen.de/receive/dbt_mods_00039954)
- [41]Li, S., Peissig, J., “Measurement of Head-Related Transfer Functions: A Review”, *Applied Sciences*, Vol. 10, No. 14, 2020, dostupno na: <https://www.mdpi.com/2076-3417/10/14/5014>
- [42]Møller, H., Sørensen, M. F., Hammershøi, D., Jensen, C. B., “Head-Related Transfer Functions of Human Subjects”, *Journal of The Audio Engineering Society*, Vol. 43, 1995, str. 300-321, dostupno na: <https://api.semanticscholar.org/CorpusID:55874617>
- [43]Richter, J.-G., Behler, G. K., Fels, J., “Evaluation of a fast HRTF measurement system”, in 140th International AES Convention, Paris, France, June 04-07 2016.
- [44]Pausch, F., Doma, S., Fels, J., “Hybrid multi-harmonic model for the prediction of interaural time differences in individual behind-the-ear hearing-aid-related transfer functions”, *Acta Acustica*, Vol. 6, 2022, str. 34, publisher: EDP Sciences, dostupno na: <https://acta-acustica.edpsciences.org/articles/aacus/abs/2022/01/aacus210045/aacus210045.html>
- [45]Carpentier, T., Bahu, H., Noisternig, M., Warusfel, O., “Measurement of a head-related transfer function database with high spatial resolution”, in 7th Forum Acusticum(EAA), Krakow, Poland, Sep. 2014, dostupno na: <https://hal.science/hal-01247583>
- [46]RWTH AACHEN UNIVERSITY Institute for Hearing Technology and Acoustics, “The ITA HRTF-database: A high-resolution head-related transfer function (HRTF) and three-dimensional (3D) ear model database”, dostupno na: <https://www.akustik.rwth-aachen.de/cms/institut-fuer-hoertechnik-und-akustik/forschung/~lsly/hrtf-datenbank/?lidx=1> (pristupljeno 13. lipnja 2024.).
- [47]Mäkivirta, A., Malinen, M., Johansson, J., Saari, V., Karjalainen, A., Vosough, P., “Accuracy of photogrammetric extraction of the head and torso shape for personal acoustic HRTF modeling”, in Audio Engineering Society Convention 148, May 2020, dostupno na: <http://www.aes.org/e-lib/browse.cfm?elib=20740>
- [48]Hoene, C., Patino Mejia, I. C., Cacerovschi, A., “MySofa—Design Your Personal HRTF”, in Audio Engineering Society Convention 142, May 2017, dostupno na: <http://www.aes.org/e-lib/browse.cfm?elib=18640>

- [49]Reijniers, J., Partoens, B., Peremans, H., “DIY Measurement of Your Personal HRTF at Home: Low-Cost, Fast and Validated”, in Audio Engineering Society Convention 143, Oct. 2017, dostupno na: <http://www.aes.org/e-lib/browse.cfm?elib=19347>
- [50]Gan, W.-S., Peksi, S., He, J., Ranjan, R., Hai, N. D., Chaudhary, N. K., “Personalized HRTF Measurement and 3D Audio Rendering for AR/VR Headsets”, in Audio Engineering Society Convention 142, May 2017, dostupno na: <http://www.aes.org/e-lib/browse.cfm?elib=18706>
- [51]Zandi, N. H., El-Mohandes, A. M., Zheng, R., “Individualizing Head-Related Transfer Functions for Binaural Acoustic Applications”, dostupno na: <http://arxiv.org/abs/2203.11138> ArXiv:2203.11138 [cs, eess]. Mar. 2022.
- [52]Roginska, A., Geluso, P. (ed.), Immersive Sound: The Art and Science of Binaural and Multi-Channel Audio. Routledge & CRC Press, 2018.
- [53]Jambroši ć, K., Krhen, M., Horvat, M., Oberman, T., “The use of inertial measurement units in virtual reality systems for auralization applications”, dostupno na: <https://doi.org/10.18154/RWTH-CONV-238864> 2019.
- [54]Tikander, M., Harma, A., Karjalainen, M., “Acoustic Positioning and Head Tracking Based on Binaural Signals”, in Audio Engineering Society Convention 116, May 2004, dostupno na: <http://www.aes.org/e-lib/browse.cfm?elib=12744>
- [55]Jambroši ć, K., Krhen, M., Horvat, M., Jagušć, T., “Measurement of IMU sensor quality used for head tracking in auralization systems”, Proceedings of e-Forum Acusticum 2020 / Parizet, Etienne ; Becot, Francois-Xavier - Lyon : Universite Lyon, 2020, 2063-2070, 2020, str. 2063-2070.
- [56]Ricci, L., Taffoni, F., Formica, D., “On the Orientation Error of IMU: Investigating Static and Dynamic Accuracy Targeting Human Motion”, PLOS ONE, Vol. 11, No. 9, Sep. 2016, str. 1–15, publisher: Public Library of Science, dostupno na: <https://doi.org/10.1371/journal.pone.0161940>
- [57]Tedaldi, D., Pretto, A., Menegatti, E., “A robust and easy to implement method for IMU calibration without external equipments”, in Proceedings - IEEE International Conference on Robotics and Automation, 09 2013.
- [58]Planinec, V., Jambroši ć, K., Franćek, P., Horvat, M., “Overview of Audio Systems with Head-Tracking”, in The 9th Congress of the Alps Adria Acoustics Association – Conference Proceedings, 2021, str. 191-201.



- [59]Muhanna, M., “Virtual reality and the CAVE: Taxonomy, interaction challenges and research directions”, Journal of King Saud University - Computer and Information Sciences, Vol. 34, 06 2015.
- [60]Dom Barnard, “Degrees of Freedom (DoF): 3-DoF vs 6-DoF for VR Headset Selection”, dostupno na: <https://virtualspeech.com/blog/degrees-of-freedom-vr> (pristupljeno 13. lipnja 2024.).
- [61]Fohl, W., Hemmer, D., “An FPGA-Based Virtual Reality Audio System”, in Audio Engineering Society Convention 138, May 2015, dostupno na: <http://www.aes.org/e-lib/browse.cfm?elib=17752>
- [62]Arduino, “ARDUINO NANO”, dostupno na: <https://store.arduino.cc/arduino-nano> (pristupljeno 13. lipnja 2024.).
- [63]Arduino, “ARDUINO UNO WiFi Rev2”, dostupno na: <https://store-usa.arduino.cc/products/arduino-uno-wifi-rev2> (pristupljeno 13. lipnja 2024.).
- [64]Jambrošić, K., Planinec, V., Horvat, M., Franček, P., “Precision of inertial measurement unit sensors in head-tracking systems used for binaural synthesis”, INTER-NOISE and NOISE-CON Congress and Conference Proceedings, Vol. 263, No. 4, Aug. 2021, str. 2634–2645.
- [65]Hexler, “TouchOSCMk1 - Fully modular touch control surface for OSC and MIDI”, dostupno na: <https://hexler.net/touchosc-mk1> (pristupljeno 13. lipnja 2024.).
- [66]Kim, J., Palmisano, S., Luu, W., Iwasaki, S., “Effects of Linear Visual-Vestibular Conflict on Presence, Perceived Scene Stability and Cybersickness in the Oculus Go and Oculus Quest”, Frontiers in Virtual Reality, Vol. 2, 04 2021.
- [67]Meta, “Meta Quest 3: New Mixed Reality VR Headset”, <https://www.meta.com/quest/quest-3/>. (pristupljeno 13. lipnja 2024.).
- [68]Unity, “Unity Real-Time Development Platform | 3D, 2D VR & AR Engine”, <https://unity.com/>. (pristupljeno 13. lipnja 2024.).
- [69]Epic Games, “Unreal Engine: The most powerful real-time 3D creation platform”, dostupno na: <https://www.unrealengine.com/en-US/> (pristupljeno 13. lipnja 2024.).
- [70]D’Andrea Fonseca, W., Rocha Carvalho, D., Hollebon, J., Mareze, P. H., Fazi, F. M., “Head tracker using webcam for auralization”, INTER-NOISE and NOISE-CON Congress and Conference Proceedings, Vol. 263, No. 1, Aug. 2021, str. 5071–5082.

- [71]Tekkök, S. C., Söyünmez, M. E., Bostancı, B., Ekim, P. O., “Face Detection, Tracking and Recognition with Artificial Intelligence”, in 2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), 2021, str. 1-5.
- [72]HTC, “HTC Vive”, dostupno na: <https://www.vive.com/us/> (pristupljeno 13. lipnja 2024.).
- [73]Wright, M., Freed, A., “Open SoundControl: A New Protocol for Communicating with Sound Synthesizers”, in International Conference on Mathematics and Computing, 1997, dostupno na: <https://www.semanticscholar.org/paper/Open-SoundControl%3A-A-New-Protocol-for-Communicating-Wright-Freed/afacaeaa009f8f1dae8368fd5175bfe8fac06766>
- [74]Dannenberg, R. B., “O2: A Network Protocol for Music Systems”, Wireless Communications and Mobile Computing, Vol. 2019, May 2019, str. 8424381, publisher: Hindawi, dostupno na: <https://doi.org/10.1155/2019/8424381>
- [75]Kisi ć, D., Horvat, M., Jambrošić, K., Planinec, V., “A Brief Overview of Sound Reproduction Systems for Listening Tests Used in the Subjective Evaluation of Sound Insulation”, Akustika, Vol. 37, 2020, str. 33-40.
- [76]“ZYLIA PRO - 3rd order Ambisonics microphone array with software”, dostupno na: <https://www.zylia.co/zylia-pro.html> (pristupljeno 13. lipnja 2024.).
- [77]Kisi ć, D., “Vrednovanje kvalitete zvučne izolacije i akustike prostora slušnim ispitivanjima”, dostupno na: <https://hrzz.hr/dominik-kisic/> (pristupljeno 13. lipnja 2024.).
- [78]Rudrich, D., Frank, M., “Improving Externalization in Ambisonic Binaural Decoding”, in DAGA 2019 Fortschritte der Akustik, Rostock, 04 2019.
- [79]Werner, D., Wiggins, B., Fitzmaurice, E., Development of an Ambisonic Guitar System GASP: Guitars with Ambisonic Spatial Performance. Focal Press, 01 2021, str. 21.
- [80]Waves, “Waves NX - Virtual Mix Room over Headphones”, dostupno na: <https://www.waves.com/plugins/nx#introducing-nx-virtual-mix-room> (pristupljeno 13. lipnja 2024.).
- [81]Valenti, R. G., Dryanovski, I., Xiao, J., “Keeping a Good Attitude: A Quaternion-Based Orientation Filter for IMUs and MARGs”, Sensors, Vol. 15, No. 8, 2015, str. 19 302–19 330, dostupno na: <https://www.mdpi.com/1424-8220/15/8/19302>

- [82]Institute of Electronic Music and Acoustics, “Tutorial: Basic Routing in REAPER”, dostupno na: [https://plugins.iem.at/docs/tutorial\\_basicrouting/](https://plugins.iem.at/docs/tutorial_basicrouting/) (pristupljeno 13. lipnja 2024.).
- [83]Institute of Electronic Music and Acoustics, “IEM Plug-in Suite”, dostupno na: <https://plugins.iem.at/> (pristupljeno 13. lipnja 2024.).
- [84]Kapralos, B., Jenkin, M. R., Milios, E., “Virtual Audio Systems”, Presence: Teleoperators and Virtual Environments, Vol. 17, No. 6, 12 2008, str. 527-549, dostupno na: <https://doi.org/10.1162/pres.17.6.527>
- [85]Becher, A., Angerer, J., Grauschopf, T., “Novel Approach to Measure Motion-To-Photon and Mouth-To-Ear Latency in Distributed Virtual Reality Systems”, dostupno na: <http://arxiv.org/abs/1809.06320> ArXiv:1809.06320 [cs]. Sep. 2018.
- [86]Rebenitsch, L., Owen, C., “Review on cybersickness in applications and visual displays”, Virtual Real., Vol. 20, No. 2, jun 2016, str. 101–125, dostupno na: <https://doi.org/10.1007/s10055-016-0285-9>
- [87]Fucci, V., Liu, J., You, Y., Cuijpers, R., “Measuring Audio-Visual Latencies in Virtual Reality Systems”, in The Smart Innovation, System and Technologies (SIST) Book Series. Germany: Springer, Jul. 2023.
- [88]Billeter, M., Röthlin, G., Wezel, J., Iwai, D., Grundhöfer, A., “A LED-Based IR/RGB End-to-End Latency Measurement Device”, in 2016 IEEE International Symposium on Mixed and Augmented Reality (ISMAR-Adjunct), 2016, str. 184-188.
- [89]Di Luca, M., “New method to measure end-to-end delay of virtual reality”, Presence: Teleoper. Virtual Environ., Vol. 19, No. 6, dec 2010, str. 569–584, dostupno na: [https://doi.org/10.1162/pres\\_a\\_00023](https://doi.org/10.1162/pres_a_00023)
- [90]Feldstein, I. T., Ellis, S. R., “A Simple Video-Based Technique for Measuring Latency in Virtual Reality or Teleoperation”, IEEE Transactions on Visualization and Computer Graphics, Vol. 27, No. 9, sep 2021, str. 3611–3625, dostupno na: <https://doi.org/10.1109/TVCG.2020.2980527>
- [91]Gruen, R., Ofek, E., Steed, A., Gal, R., Sinclair, M., Gonzalez-Franco, M., “Measuring System Visual Latency through Cognitive Latency on Video See-Through AR devices”, in 2020 IEEE Conference on Virtual Reality and 3D User Interfaces (VR), 2020, str. 791-799.

- [92]Stauffert, J.-P., Niebling, F., Latoschik, M. E., “Simultaneous Run-Time Measurement of Motion-to-Photon Latency and Latency Jitter”, in 2020 IEEE Conference on Virtual Reality and 3D User Interfaces (VR), 2020, str. 636-644.
- [93]Lindau, A., “The Perception of System Latency in Dynamic Binaural Synthesis”, in NAG/DAGA 2009 Conference Proceedings, Rotterdam, Netherlands, March 2009.
- [94]Rappin, C., Palacino, J., Rueff, P., Feichter, L., Paquier, M., “Latency Detection Threshold of Head-Tracking for Different Head Rotation Speeds in Binaural Rendering”, in Forum Acusticum 2023, European Acoustics Association, Torino, Italy, September 2023.
- [95]Apple, “About spatial audio with Dolby Atmos in Apple Music”, dostupno na: <https://support.apple.com/en-us/109354> (pristupljeno 13. lipnja 2024.).
- [96]Samsung, “How to use 360 Audio on Galaxy Buds Pro, Buds 2 & Buds Live”, dostupno na: <https://www.samsung.com/uk/support/mobile-devices/how-to-use-360-audio-on-galaxy-buds-pro-buds2-and-buds-live/> (pristupljeno 13. lipnja 2024.).
- [97]Dolby Laboratories, “Dolby Atmos for cinema playback”, dostupno na: <https://professional.dolby.com/cinema/dolby-atmos/> (pristupljeno 13. lipnja 2024.).
- [98]Youtube, “Upotreba prostornog zvuka u videozapisima od 360 stupnjeva i VR videozapisima”, dostupno na: <https://support.google.com/youtube/answer/6395969> (pristupljeno 13. lipnja 2024.).
- [99]Google, “Resonance Audio Overview”, dostupno na: <https://resonance-audio.github.io/resonance-audio/discover/overview.html> (pristupljeno 13. lipnja 2024.).
- [100]Flux Software Engineering, “ReaVolution for Spat Revolution - FLUX:: IMMERSIVE”, dostupno na: <https://www.flux.audio/project/reavolution-for-spat-revolution/> (pristupljeno 13. lipnja 2024.).
- [101]Steinberg, “Nuendo”, dostupno na: <https://www.steinberg.net/nuendo/virtual-reality/> (pristupljeno 13. lipnja 2024.).
- [102]Adobe, “VR editing in Premiere Pro”, dostupno na: <https://helpx.adobe.com/premiere-pro/using/VRSupport.html> (pristupljeno 13. lipnja 2024.).
- [103]Dear Reality, “THE EVOLUTION OF MIXING - Dear Reality”, dostupno na: <https://www.dear-reality.com/> (pristupljeno 13. lipnja 2024.).

- [104]Teng, H., Jiang, H., Ho, X., Lim, W. Y. B., Ng, J., Yu, H., Xiong, Z., Niyato, D., Miao, C., “Predictive Analytics for COVID-19 Social Distancing”, in Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence IJCAI-21, 08 2021, str. 5016-5019.
- [105]MelodyVR, “MelodyVR”, dostupno na: <https://melodyvr.com/> (pristupljeno 13. lipnja 2024.).
- [106]Zylia, “ZYLIA Concert Hall”, dostupno na: <https://www.meta.com/experiences/3901710823174931/> (pristupljeno 13. lipnja 2024.).
- [107]Fran ček, P., Jambrošić, K., Horvat, M., Planinec, V., “The Performance of Inertial Measurement Unit Sensors on Various Hardware Platforms for Binaural Head-Tracking Applications”, *Sensors*, Vol. 23, No. 2, 2023, dostupno na: <https://www.mdpi.com/1424-8220/23/2/872>
- [108]Wittmann, F., Lamercy, O., Gassert, R., “Magnetometer-Based Drift Correction During Rest in IMU Arm Motion Tracking”, *Sensors*, Vol. 19, No. 6, 2019, dostupno na: <https://www.mdpi.com/1424-8220/19/6/1312>
- [109]Kos, A., Tomažič, S., Umek, A., “Evaluation of Smartphone Inertial Sensor Performance for Cross-Platform Mobile Applications”, *Sensors*, Vol. 16, No. 4, 2016, dostupno na: <https://www.mdpi.com/1424-8220/16/4/477>
- [110]Gonzalez, R., Dabove, P., “Performance Assessment of an Ultra Low-Cost Inertial Measurement Unit for Ground Vehicle Navigation”, *Sensors*, Vol. 19, No. 18, 2019, dostupno na: <https://www.mdpi.com/1424-8220/19/18/3865>
- [111]El-Sheimy, N., Hou, H., Niu, X., “Analysis and Modeling of Inertial Sensors Using Allan Variance”, *IEEE Transactions on Instrumentation and Measurement*, Vol. 57, No. 1, 2008, str. 140-149.
- [112]Niu, X., Wang, Q., Li, Y., Li, Q., Liu, J., “Using Inertial Sensors in Smartphones for Curriculum Experiments of Inertial Navigation Technology”, *Education Sciences*, Vol. 5, No. 1, 2015, str. 26–46, dostupno na: <https://www.mdpi.com/2227-7102/5/1/26>
- [113]Wang, L., Zhang, C., Gao, S., Wang, T., Lin, T., Li, X., “Application of Fast Dynamic Allan Variance for the Characterization of FOGs-Based Measurement While Drilling”, *Sensors*, Vol. 16, No. 12, 2016, dostupno na: <https://www.mdpi.com/1424-8220/16/12/2078>

- [114]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, dostupno na: <http://dx.doi.org/10.1561/20000000094>
- [115]Milam, J., “Design and Evaluation of Novel Attitude Estimation System Using MEMS Sensors for Indoor UAS”, *Graduate Theses, Dissertations, and Problem Reports*, Jan. 2018, dostupno na: <https://researchrepository.wvu.edu/etd/3711>
- [116]Kim, M.-S., Yu, S.-B., Lee, K.-S., “Development of a high-precision calibration method for inertial measurement unit”, *International Journal of Precision Engineering and Manufacturing*, Vol. 15, No. 3, Mar. 2014, str. 567–575, dostupno na: <https://doi.org/10.1007/s12541-014-0372-3>
- [117]Yean, S., Lee, B. S., Yeo, C. K., Vun, C. H., Oh, H. L., “Smartphone Orientation Estimation Algorithm Combining Kalman Filter With Gradient Descent”, *IEEE Journal of Biomedical and Health Informatics*, Vol. 22, No. 5, 2018, str. 1421-1433.
- [118]The MathWorks Inc., “MATLAB Mobile Overview”, dostupno na: <https://www.mathworks.com/products/matlab-mobile.html> (pristupljeno 13. lipnja 2024.).
- [119]MATLAB, “ahrsfilter: Orientation from accelerometer, gyroscope, and magnetometer readings”, dostupno na: <https://www.mathworks.com/help/fusion/ref/ahrsfilter-system-object.html> (pristupljeno 13. lipnja 2024.).
- [120]MATLAB, “imufilter: Orientation from accelerometer and gyroscope readings”, dostupno na: <https://www.mathworks.com/help/fusion/ref/imufilter-system-object.html> (pristupljeno 13. lipnja 2024.).
- [121]Radin Charel, S. E., Binugroho, E. H., Rosyidi, M. A., Dewanto, R. S., Pramadihanto, D., “Kalman filter for angle estimation using dual inertial measurement units on unicycle robot”, in *2016 International Electronics Symposium (IES)*, 2016, str. 256-261.
- [122]Choi, K., Jang, S.-A., Kim, Y.-H., “Calibration of Inertial Measurement Units Using Pendulum Motion”, *International Journal of Aeronautical and Space Sciences*, Vol. 11, No. 3, Sep. 2010, str. 234–239.
- [123]Wikipedia, “Pendulum”, dostupno na: <https://en.wikipedia.org/w/index.php?title=Pendulum&oldid=1209173208> (pristupljeno 13. lipnja 2024.).
- [124]Planinec, V., Jambrošić, K., Franček, P., Horvat, M., “Virtual sound source perception challenges of binaural audio systems with head-tracking”, in *51st International Congress and Exposition on Noise Control Engineering (Internoise 2022)*, Glasgow, UK, August 2022.

- [125]Kim, S.-M., Choi, W., “On the externalization of virtual sound images in headphone reproduction: A Wiener filter approach”, *The Journal of the Acoustical Society of America*, Vol. 117, No. 6, 05 2005, str. 3657-3665, dostupno na: <https://doi.org/10.1121/1.1921548>
- [126]Schörkhuber, C., Zaunschirm, M., Höldrich, R., “Binaural Rendering of Ambisonic Signals via Magnitude Least Squares”, in *DAGA 2018 Conference Proceedings*, München, Germany, 2018.
- [127]Politis, A., McCormack, L., Pulkki, V., “Enhancement of ambisonic binaural reproduction using directional audio coding with optimal adaptive mixing”, in *2017 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA)*, 2017, str. 379-383.
- [128]Politis, A., Vilkamo, J., Pulkki, V., “Sector-Based Parametric Sound Field Reproduction in the Spherical Harmonic Domain”, *IEEE Journal of Selected Topics in Signal Processing*, Vol. 9, No. 5, 2015, str. 852-866.
- [129]Chiba, K., “NXosc”, dostupno na: <https://audiooo.com/nxosc> (pristupljeno 13. lipnja 2024.).
- [130]Bit Shape, “GyrOSC”, dostupno na: <https://www.bitshapesoftware.com/instruments/gyrosc/> (pristupljeno 13. lipnja 2024.).
- [131]Oh, F. P., Deborah M., “Two-Way ANOVA”, in *Making Sense of Statistics*, 7th ed. Routledge, 2018, str: 8.
- [132]Frost, J., “How to do Two-Way ANOVA in Excel”, dostupno na: <https://statisticsbyjim.com/anova/two-way-anova-excel/> Nov. 2019.
- [133]Planinec, V., Reijniers, J., Horvat, M., Peremans, H., Jambrošić, K., “The Accuracy of Dynamic Sound Source Localization and Recognition Ability of Individual Head-Related Transfer Functions in Binaural Audio Systems with Head Tracking”, *Applied Sciences*, Vol. 13, No. 9, 2023, dostupno na: <https://www.mdpi.com/2076-3417/13/9/5254>
- [134]Earfish, “HRTF measurement kit - Measure your own HRTF and turn REAPER into your personal head-tracked virtual 3D mixing studio”, dostupno na: <https://www.earfish.eu/> (pristupljeno 13. lipnja 2024.).
- [135]SparkFun Electronics, “SparkFun OpenLog Artemis”, dostupno na: [https://www.sparkfun.com/products/16832?\\_ga=2.110212293.1551537288.1710889979-298089404.1710889979](https://www.sparkfun.com/products/16832?_ga=2.110212293.1551537288.1710889979-298089404.1710889979) (pristupljeno 13. lipnja 2024.).

- [136]Axagon, “ADA-17 USB - HQ MINI AUDIO”, dostupno na: <https://www.axagon.eu/en/produkt/ada-17> (pristupljeno 13. lipnja 2024.).
- [137]The Acoustics Research Institute of the Austrian Academy of Sciences, “SOFA (Spatially Oriented Format for Acoustics)”, dostupno na: [https://www.sofaconventions.org/mediawiki/index.php/SOFA\\_\(Spatially\\_Oriented\\_Format\\_for\\_Acoustics\)](https://www.sofaconventions.org/mediawiki/index.php/SOFA_(Spatially_Oriented_Format_for_Acoustics)) (pristupljeno 13. lipnja 2024.).
- [138]Mackensen, P., “Auditive Localization. Head movements, an additional cue in Localization”, doktorski rad, Technische Universität Berlin, 2004, dostupno na: <https://d-nb.info/970186762/34>
- [139]McCormack, L., Politis, A., “SPARTA & COMPASS: Real-time implementations of linear and parametric spatial audio reproduction and processing methods”, in AES Conference on Immersive and Interactive Audio. Audio Engineering Society, Mar. 2019, str. 1–12, AES International Conference on Immersive and Interactive Audio ; Conference date: 27-03-2019.
- [140]McCormack, L., Politis, A., “Spatial Audio Real-Time Applications”, dostupno na: <https://leomccormack.github.io/sparta-site/> (pristupljeno 13. lipnja 2024.).
- [141]Cuevas-Rodríguez, M., Picinali, L., González-Toledo, D., Garre, C., de la Rubia-Cuestas, E., Molina-Tanco, L., Reyes-Lecuona, A., “3D Tune-In Toolkit: An open-source library for real-time binaural spatialisation”, PLOS ONE, Vol. 14, No. 3, 03 2019, str. 1-37, dostupno na: <https://doi.org/10.1371/journal.pone.0211899>
- [142]R Foundation for Statistical Computing, “R: A Language and Environment for Statistical Computing”, Vienna, Austria, dostupno na: <https://www.r-project.org/> (pristupljeno 13. lipnja 2024.).
- [143]Park, E., Cho, M., Ki, C.-S., “Correct use of repeated measures analysis of variance”, The Korean Journal of Laboratory Medicine, Vol. 29, No. 1, Feb. 2009, str. 1–9.
- [144]Pažin, I., “Analiza varijance ponovljenih mjerenja”, diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet u Zagrebu, Jul. 2014, dostupno na: <https://urn.nsk.hr/urn:nbn:hr:217:530462>
- [145]Finnstats, “Repeated Measures of ANOVA in R: Complete Tutorial”, dostupno na: <https://finnstats.com/index.php/2021/04/06/repeated-measures-of-anova-in-r/> (pristupljeno 13. lipnja 2024.).



- [146]Bonthu, H., “Detecting and Treating Outliers | Treating the odd one out!”, dostupno na: <https://www.analyticsvidhya.com/blog/2021/05/detecting-and-treating-outliers-treating-the-odd-one-out/> (pristupljeno 13. lipnja 2024.).
- [147]Shapiro, S. S., Wilk, M. B., “An analysis of variance test for normality (complete samples)”, *Biometrika*, Vol. 52, No. 3-4, 12 1965, str. 591-611, dostupno na: <https://doi.org/10.1093/biomet/52.3-4.591>
- [148]Mauchly, J. W., “Significance Test for Sphericity of a Normal  $n$ -Variate Distribution”, *The Annals of Mathematical Statistics*, Vol. 11, No. 2, 1940, str. 204 – 209, dostupno na: <https://doi.org/10.1214/aoms/1177731915>
- [149]Buhlmann, H., Huber, P. J., “Pairwise Comparison and Ranking in Tournaments”, *The Annals of Mathematical Statistics*, Vol. 34, No. 2, 1963, str. 501–510, dostupno na: <http://www.jstor.org/stable/2238395>
- [150]Armstrong, R. A., “When to use the Bonferroni correction”, *Ophthalmic and Physiological Optics*, Vol. 34, No. 5, 2014, str. 502-508, dostupno na: <https://onlinelibrary.wiley.com/doi/abs/10.1111/opo.12131>
- [151]Edwards, D. G., Hsu, J. C., “Multiple comparisons with the best treatment”, *Journal of the American Statistical Association*, Vol. 78, No. 384, 1983, str. 965–971.
- [152]Dunn, O. J., “Multiple Comparisons Among Means”, *Journal of the American Statistical Association*, Vol. 56, No. 293, 1961, str. 52–64, dostupno na: <http://www.jstor.org/stable/2282330>
- [153]Grubiši ć, A., “Hi-kvadrat test i njegove primjene”, seminarski rad, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, 2003, dostupno na: [http://bib.irb.hr/datoteka/145851.Ani\\_Grubisic\\_hi\\_kvadrat.pdf](http://bib.irb.hr/datoteka/145851.Ani_Grubisic_hi_kvadrat.pdf)
- [154]Tallarida, R. J., Murray, R. B., *Chi-Square Test*. New York, NY: Springer New York, 1987, str. 140–142, dostupno na: [https://doi.org/10.1007/978-1-4612-4974-0\\_43](https://doi.org/10.1007/978-1-4612-4974-0_43)
- [155]Wagner-Menghin, M. M., *Binomial Test*. John Wiley & Sons, Ltd, 2014, dostupno na: <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781118445112.stat06340>
- [156]Dujman, J., “Uporaba neparametarske statistike u inženjerskim problemima”, završni rad, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, 2017, dostupno na: <https://zir.nsk.hr/islandora/object/fsb%3A3729/datastream/PDF/view>
- [157]Pollack, K., Kreuzer, W., Majdak, P., Pollack, K., Kreuzer, W., Majdak, P., “Perspective Chapter: Modern Acquisition of Personalised Head-Related Transfer Functions – An

- Overview”, in *Advances in Fundamental and Applied Research on Spatial Audio*. IntechOpen, Apr. 2022, dostupno na: <https://www.intechopen.com/chapters/81515>
- [158]Middlebrooks, J. C., Green, D. M., “Sound Localization by Human Listeners”, *Annual Review of Psychology*, Vol. 42, No. Volume 42, 1991, 1991, str. 135-159, dostupno na: <https://www.annualreviews.org/content/journals/10.1146/annurev.ps.42.020191.001031>
- [159]Robotham, T., Rummukainen, O. S., Kurz, M., Eckert, M., Habets, E. A. P., “Comparing Direct and Indirect Methods of Audio Quality Evaluation in Virtual Reality Scenes of Varying Complexity”, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 28, No. 5, 2022, str. 2091-2101.
- [160]Moore, D. S., Notz, W., Fligner, M. A., “Chapter 4 - Scatterplots and correlation”, in *The Basic Practice of Statistics*. W.H. Freeman and Company, 2013.
- [161]Schober, P., Boer, C., Schwarte, L. A., “Correlation Coefficients: Appropriate Use and Interpretation”, *Anesthesia & Analgesia*, Vol. 126, No. 5, May 2018, str. 1763, dostupno na: [https://journals.lww.com/anesthesia-analgesia/fulltext/2018/05000/correlation\\_coefficients\\_\\_appropriate\\_use\\_and.50.aspx](https://journals.lww.com/anesthesia-analgesia/fulltext/2018/05000/correlation_coefficients__appropriate_use_and.50.aspx)
- [162]Armstrong, C., Thresh, L., Murphy, D., Kearney, G., “A Perceptual Evaluation of Individual and Non-Individual HRTFs: A Case Study of the SADIE II Database”, *Applied Sciences*, Vol. 8, No. 11, 2018, dostupno na: <https://www.mdpi.com/2076-3417/8/11/2029>

# Životopis

Vedran Planinec rođen je 26. listopada 1995. u Zagrebu, u Hrvatskoj. Upisao je preddiplomski studij Elektrotehnike na Fakultetu elektrotehnike i računarstva (FER) Sveučilišta u Zagrebu, gdje je 2018. godine stekao zvanje prvostupnika. Iste godine upisao je diplomski studij Elektronike na FER-u. Nakon obrane diplomskog rada pod nazivom "*Aktivni dvostazni zvučnik*", diplomirao je 2020. godine. Iste godine upisao je poslijediplomski doktorski studij na FER-u, te preuzima i mjesto asistenta na Zavodu za elektroakustiku FER-a. Od tada je uključen u sljedeće prijediplomske i diplomske kolegije: Audioprodukcija, Audiosustavi, Audiotehnika, Audioelektronika i Uvod u DJ opremu i miksanje pjesama. Njegovo istraživanje uključuje audio sustave s praćenjem položaja glave, binauralnu sintezu, HRTF funkcije, procesiranje akustičkih signala i psihoakustička mjerenja.

## Popis objavljenih djela

### Znanstveni radovi u časopisima

1. Planinec, V., Reijniers, J., Horvat, M., Peremans, H., Jambrošić, K., "The Accuracy of Dynamic Sound Source Localization and Recognition Ability of Individual Head-Related Transfer Functions in Binaural Audio Systems with Head Tracking", *Applied Sciences*, Vol. 13, No. 9, travanj 2023., str. 5254, <https://doi.org/10.3390/app13095254>
2. Franček, P., Jambrošić, K., Horvat, M., Planinec, V., "The Performance of Inertial Measurement Unit Sensors on Various Hardware Platforms for Binaural Head-Tracking Applications", *Sensors*, Vol. 23, No. 2, siječanj 2023, str. 872, <https://doi.org/10.3390/s23020872>
3. Kisić, D., Horvat, M., Jambrošić, K., Planinec, V., "A Brief Overview of Sound Reproduction Systems for Listening Tests Used in the Subjective Evaluation of Sound Insulation", *Akustika*, Vol. 37, 2020., str. 33-40

## **Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom**

1. Planinec, V., Jambrošić, K., Horvat, M., Franček, P., "Accuracy of Dynamic Sound Source Localization in Binaural Audio Systems with Head-Tracking Utilizing Generic and Individual HRTFs", Book of peer-reviewed papers of 10th Congress of the Alps Adria Acoustics Association. Ljubljana: Slovensko društvo za akustiko, 2023., str. 202-207
2. Planinec, V., Jambrošić, K., Franček, P., Horvat, M., "Virtual sound source perception challenges of binaural audio systems with head-tracking", Proceedings Inter-noise 2022 / Craik, Robert (ur.). Glasgow: Institute of Acoustics, 2022
3. Franček, P., Jambrošić, K., Horvat, M., Planinec, V., "Simple dynamic measurement system for testing IMU sensor precision in spatial audio", Euroregio BNAM 2022 - Conference Proceedings / Christensen, Flemming ; Ordonez, Rodrigo (ur.). Aalborg: Danish Acoustical Society, 2022., str. 297-305
4. Jambrošić, K., Planinec, V., Horvat, M., Franček, P., "Precision of inertial measurement unit sensors in head-tracking systems used for binaural synthesis", Proceedings of Inter-Noise 2021 / Singh, Rajendra (ur.). Washington (MD): International Institute of Noise Control Engineering, 2021., str. 2634-2645, doi: 10.3397/IN-2021-2190
5. Kisić, D., Horvat, M., Planinec, V., Jambrošić, K., "How does the choice of the sound reproduction system affect the perceptual evaluation of impact sound insulation?", Proceedings of Euronoise 2021. Sociedade Portuguesa de Acústica (SPA), 2021., str. 1868-1874
6. Kudrna, N., Jambrošić, K., Planinec, V., "Loudspeaker Equalization in Real-Life Multichannel Environments", The 9th Congress of the Alps Adria Acoustics Association – Conference Proceedings / Mesterházy, B., Márkus, M.(ur.). Budimpešta: Optikai, Akusztikai, Filmés Színháztechnikai Tudományos Egyesület (OPAKFI), 2021., str. 181-190
7. Planinec, V., Jambrošić, K., Franček, P., Horvat, M., "Overview of Audio Systems with Head-Tracking", The 9th Congress of the Alps Adria Acoustics Association – Conference Proceedings / Mesterházy, Beáta ; Márkus, Miklós (ur.). Budimpešta: Optikai, Akusztikai, Film- és Színháztechnikai Tudományos Egyesület (OPAKFI), 2021., str. 191-201

# Biography

Vedran Planinec was born on October 26, 1995, in Zagreb, Croatia. He enrolled in the undergraduate program in Electrical Engineering at the Faculty of Electrical Engineering and Computing (FER) at the University of Zagreb, where he obtained his bachelor's degree in 2018. In the same year, he enrolled in the graduate program in Electronics at FER. Upon completing his master's thesis titled "Active two-way loudspeaker", he graduated in 2020. In the same year, he enrolled in postgraduate doctoral studies at FER and took on the position of teaching assistant at the Department of Electroacoustics at FER. Since then, he has been involved in the following undergraduate and graduate courses: Audio Production, Audio Systems, Audiotechnics, Audio Electronics, and Introduction to DJ Equipment and Mixing. His research includes audio systems with head tracking, binaural synthesis, HRTF (Head-Related Transfer Functions), acoustic signal processing, and psychoacoustic measurements.