

MODELIRANJE VPLIVOV NOTRANJIH
OKOLIJ NA LOKALIZACIJO Z
ULTRA-ŠIROKOPASOVNIMI RADIJSKIMI
SIGNALI

Klemen Bregar

Doktorska disertacija
Mednarodna podiplomska šola Jožefa Stefana
Ljubljana, Slovenija

Mentor: prof. dr. Mihael Mohorčič, Institut "Jožef Stefan", Ljubljana, Slovenija

Komisija za oceno doktorske disertacije:

prof. dr. Tomaž Javornik, predsednik, Institut "Jožef Stefan", Ljubljana, Slovenija

doc. dr. Roman Novak, član, Institut "Jožef Stefan", Ljubljana, Slovenija

prof. dr. Andrej Košir, član, Fakulteta za elektrotehniko, Univerza v Ljubljani, Ljubljana, Slovenija

MEDNARODNA PODIPLOMSKA ŠOLA JOŽEFA STEFANA
JOŽEF STEFAN INTERNATIONAL POSTGRADUATE SCHOOL



Klemen Bregar

MODELIRANJE VPLIVOV NOTRANJIH OKOLIJ NA
LOKALIZACIJO Z ULTRA-ŠIROKOPASOVNIMI RADIJ-
SKIMI SIGNALI

Doktorska disertacija

MODELLING THE EFFECTS OF INDOOR ENVI-
RONMENTS ON LOCALIZATION WITH ULTRA-
WIDEBAND RADIO SIGNALS

Doctoral Dissertation

Mentor: prof. dr. Mihael Mohorčič

Ljubljana, Slovenija, april 2019

Zahvala

Najprej bi se rad zahvalil mentorju prof. dr. Mihaelu Mohorčiču za vso izkazano pomoč in nasvete pri pripravi doktorske disertacije, pisanju člankov ter podporo skozi celotno obdobje mojega podiplomskega študija. Zahvalil bi se tudi doc. dr. Andreju Hrovatu in prof. dr. Tomažu Javorniku za vse debate in pomoč pri umeščanju ter nasvete pri obdelavi merilnih rezultatov v doktorski disertaciji. Zahvala gre tudi doc. dr. Romanu Novaku za vse nasvete, pomoč pri pisanju člankov ter pomoč pri kritični presoji rezultatov in idej.

Zahvalil bi se še vsem ostalim soavtorjem na člankih ter sodelavcem Odseka za komunikacijske sisteme na Institutu "Jožef Stefan".

Posebna zahvala gre komisiji za oceno doktorske disertacije, prof. dr. Tomažu Javorniku, doc. dr. Romanu Novaku in prof. dr. Andreju Koširju, za vse njihove komentarje in pripombe.

Posebna zahvala gre tudi staršem, bratoma, sorodnikom in vsem prijateljem, ki so me spremljali in podpirali tako v lepih kot tudi v težkih trenutkih na izbrani poti.

Delo, povezano z doktorsko disertacijo, je bilo financirano s strani Agencije za raziskovalno dejavnost Republike Slovenije, evropskih projektov Obzorja 2020 eWINE in SAAM ter nacionalnega aplikativnega projekta L2-7664 Napredne tehnike sledenja žarkom za karakterizacijo radijskega okolja in radijsko lokalizacijo.

Povzetek

Lokalizacija v notranjih okoljih postaja v sodobnem svetu vse bolj aktualna storitev, bodisi samostojna bodisi podporna drugim aplikacijam. Globalni navigacijski satelitski sistemi zagotavljajo storitev lokalizacije na prostem v pogojih neposredne vidljivosti med sprejemnikom in minimalnim zahtevanim številom navigacijskih satelitov. V notranjih okoljih so v večini primerov signali iz navigacijskih satelitov preveč oslabljeni, da bi lahko služili potrebam navigacije. Za lokalizacijo ljudi in stvari v notranjih okoljih zato potrebujemo namensko opremo, ki je del obstoječe infrastrukture ali pa je potrebna namestitev dopolnilnega sistema, ki zagotavlja referenčne lokalizacijske točke.

V doktorski disertaciji smo se posvetili zbiranju reprezentativnih meritev pogojev razširjanja ultra-širokopasovnih radijskih signalov v štirih značilnih notranjih okoljih. Pri tem smo uporabili cenovno dostopne ultra-širokopasovne radijske module, ki so omogočili obširne meritve za potrebe lokalizacije in analizo pogojev razširjanja. Analizirali smo vpliv pogojev razširjanja radijskih signalov brez neposredne vidljivosti na napako izmerjene razdalje na podlagi časa razširjanja signala, ki neposredno vpliva na točnost lokalizacijskih algoritmov.

Osrednji del disertacije predstavlja analiza postopkov za detekcijo pogojev razširjanja radijskih signalov brez neposredne vidljivosti in postopki za oceno napake izmerjene razdalje na podlagi analize impulznih odzivov kanala. Predlagali smo nov pristop z uporabo konvolucijskih nevronske mreže. Te za razliko od standardnih metod strojnega učenja za svoje delovanje ne zahtevajo predhodne kompleksne obdelave impulznih odzivov kanala in luščenja značilk. S pomočjo konvolucijskih nevronske mreže smo zgradili modele za razpoznavanje pogojev razširjanja signala brez neposredne vidljivosti in oceno napake izmerjene razdalje za štiri značilna notranja okolja. Posamezne modele smo ovrednotili z analizo uspešnosti na različnih naborih meritev, ki so bili narejeni v drugih prostorih, kot pa so bili narejeni nabori meritev za učenje modelov.

V doktorski disertaciji smo ovrednotili tudi računsko zahtevnost predlaganih algoritmov za detekcijo pogojev razširjanja brez neposredne vidljivosti na različno zmogljivih računskih platformah. Zaradi zelo učinkovite implementacije globokih nevronske mreže so predlagani algoritmi ustrezni za uporabo tako na majhnih vgradnih računalnikih na senzorskih vozliščih kot tudi v najzmogljivejših računskih centrih.

Analizirali smo uspešnost različnih lokalizacijskih algoritmov, ki temeljijo na metodi najmanjših kvadratov, in predlagali algoritem za sledenje, ki temelji na razširjenem Kalmanovem filtru. Algoritem uporablja informacijo o ocenjeni napaki izmerjene razdalje za uteževanje posameznih merilnih prispevkov in s tem močno izboljša zanesljivost in točnost sledenja položaju v izbranem notranjem okolju.

Abstract

Indoor localization is increasing in importance in the modern world, be it as a stand-alone service or as a supporting service for other applications. Global navigation satellite systems can provide a reliable outdoor localization service where a line-of-sight link between a receiver and the minimum required number of navigation satellites is fulfilled. In indoor environments, satellite signals are mostly too weak to be used for localization purposes. Thus, indoor localization requires additional custom equipment which can be part of an existing communication infrastructure or purposely deployed localization infrastructure that supplies reference localization points.

As part of the doctoral dissertation we conducted measurements of radio signal propagation characteristics in four representative indoor environments using ultra-wideband radios. To this end, we used off-the-shelf ultra-wideband radios that enabled thorough measurements suitable for the performance analysis of indoor localization algorithms. We analysed the impact of non-line-of-sight signal propagation conditions on ranging error based on time-of-flight measurements, which directly influences the accuracy of range-based localization algorithms.

The main focus was on the algorithms for detection of non-line-of-sight propagation conditions and estimation of ranging errors based on raw channel impulse response. We proposed a novel non-line-of-sight detection algorithm and a ranging error estimation algorithm based on convolutional neural networks which do not require any preprocessing of channel impulse response data. We built models for four representative indoor environments and we showed with an analysis of a thorough cross-validation process that algorithms based on convolutional neural networks outperform standard classification algorithms based on the complex feature extraction process.

We evaluated the computational complexity of proposed non-line-of-sight classification algorithms on different computational platforms. Despite high computational complexity of proposed convolution neural networks, their efficient implementation enables using the proposed models on small single-board-computers found in sensor nodes as well as on the best data-center-grade hardware.

We also analysed the performance of different least-squares-based localization algorithms and proposed a tracking algorithm based on an extended Kalman filter. By using ranging error estimation for each measurement contribution and modifying their weights, this algorithm substantially improved the tracking and localization performance in the selected indoor environment compared to the algorithms that did not use any range quality information.

Kazalo

Slike	xv
Tabele	xvii
Algoritmi	xxi
Kratice	xxiii
1 Uvod	1
1.1 Prispevki doktorske disertacije	2
1.2 Struktura doktorske disertacije	3
2 Pregled metod za lokalizacijo	7
2.1 Aktivne metode lokalizacije	8
2.1.1 Geometrijske metode	8
2.1.1.1 Tehnike lociranja na osnovi moči sprejetega signala	8
2.1.1.2 Tehnike lociranja na osnovi časa razširjanja signala	9
2.1.1.3 Tehnike lociranja na osnovi časovne razlike prihodov signala	10
2.1.1.4 Tehnike lociranja na osnovi dvosmernega časovnega žigosanja	10
2.1.1.5 Tehnike lociranja na osnovi kotov prihoda signala	12
2.1.2 Metode radiofrekvenčnega odtisa	12
2.1.3 Kooperativne metode	13
2.1.3.1 Sekvenčne metode	13
2.1.3.2 Metode multidimenzionalnega skaliranja	13
2.1.3.3 Metode širjenja zaupanja	15
2.1.4 Hibridne metode	16
2.1.4.1 Hkratna lokalizacija in kartiranje	17
2.1.4.2 Metode z uporabo Kalmanovega filtra	18
2.2 Pasivne metode lokalizacije	18
2.2.1 Radijska tomografija	18
3 Lokalizacija UWB in njene omejitve	21
3.1 Definicija UWB po standardu IEEE 802.15.4-2011	21
3.1.1 Komunikacijski blok UWB	22
3.1.1.1 Sinhronizacijska sekvenca - SYNC	22
3.1.1.2 Začetni razmejevalnik bloka - SFD	23
3.1.1.3 Glava podatkovnega bloka - PHR	23
3.1.1.4 Podatkovni blok	24
3.1.1.5 Modulacija BPM/BPSK - struktura podatkovnega simbola	25
3.2 Razširjanje signala UWB	26
3.2.1 Slabljenje praznega prostora	27
3.2.2 Lom	27

3.2.3	Odboj	28
3.2.4	Uklon	28
3.2.5	Motnje mirujočega ozadja	28
3.2.6	Absorbcija	28
3.3	Modeliranje kanala UWB	28
3.3.1	Model izgube poti	28
3.3.2	Počasno presihanje	29
3.3.3	Model hitrega presihanja	30
3.3.4	Model Saleh-Valenzuela	30
3.3.5	Predlagani parametri kanalov UWB po standardu IEEE 802.15.4-2011	32
3.4	Parametri profila močnostne zakasnitve signala	33
3.4.1	Energija sprejetega signala	33
3.4.2	Maksimalna amplituda profila močnostne zakasnitve	33
3.4.3	Čas vzpona profila močnostne zakasnitve	33
3.4.4	Koeficient simetrije	33
3.4.5	Koeficient sploščenosti	35
3.4.6	Povprečna presežna zakasnitev	35
3.4.6.1	RMS razpršitev zakasnitve	35
3.5	Merjenje razdalj z radijsko tehnologijo UWB	35
3.5.1	Dvosmerno časovno žigosanje	36
3.5.1.1	Dvosmerni obhod paketa	36
3.5.1.2	Dvakratni dvosmerni obhod paketa	36
4	Testno okolje	41
4.1	Večnamensko senzorsko vozlišče UWB	41
4.1.1	Senzorsko vozlišče SNPN-UWB	43
4.1.1.1	Sistemska programska oprema	44
4.1.1.2	Antenske karakteristike	44
4.1.1.3	Diagnostične informacije radijskega kanala UWB	44
4.1.1.3.1	Ocena moči prve fronte signala:	45
4.1.1.3.2	Ocena moči sprejetega signala:	45
4.1.1.3.3	Odstopanje RSS in kompenzacija:	45
4.2	Meritve značilnih notranjih okolij	45
4.2.1	Postopek zajemanja meritev UWB	46
4.2.1.1	Merilno senzorsko vozlišče	47
4.2.1.2	Merilno senzorsko omrežje	47
4.2.1.3	Merilni proces	47
4.2.2	Pridobivanje načrtov notranjih okolij	49
4.2.2.1	Pisarniško okolje	49
4.2.2.2	Industrijsko okolje	50
4.2.2.3	Majhno bivalno okolje v bloku	50
4.2.2.4	Bivalno okolje v stanovanjski hiši	50
5	Modeliranje vpliva okolja na razširjanje signala UWB	53
5.1	Predobdelava merilnih rezultatov	53
5.1.1	Kompenzacija enosmernega odstopanja merilne napake	53
5.1.2	Detekcija in odstranjevanje osamelcev	54
5.2	Analiza podatkovnih zbirk	55
5.2.1	Model izgube poti	56
5.2.2	Čas vzpona profila močnostne zakasnitve	59
5.2.3	Energija sprejetega signala	60

5.2.4	Izračun presežnih zakasnitev signala	61
5.2.4.1	Povprečna presežna zakasnitev	62
5.2.4.2	RMS razpršitev zakasnitve	62
5.2.5	Izračun statističnih parametrov oblike profila močnostne zakasnitve signala	62
5.2.5.1	Koeficient simetrije	63
5.2.5.2	Koeficient sploščenosti	63
6	Razpoznavanje pogojev razširjanja radijskega signala z globokim učenjem	65
6.1	Pregled obstoječih pristopov s strojnim učenjem	65
6.2	Konvolucijske nevronske mreže	67
6.2.1	Zgradba konvolucijskih nevronskih mrež	68
6.2.1.1	Konvolucijska nevronska plast	68
6.2.1.2	Aktivacijska plast	68
6.2.1.3	Združevalna plast	69
6.2.1.4	Polno povezana nevronska plast	69
6.2.1.5	Izhodna plast	69
6.2.2	Postopek učenja konvolucijske nevronske mreže	69
6.2.2.1	Vzratno razširjanje napake	69
6.2.2.2	Optimizacija z metodami gradientnega spusta	70
6.2.2.3	Paketna normalizacija	71
6.2.2.4	Regularizacija z naključnim izpuščanjem	72
6.3	Algoritem za detekcijo razširjanja brez neposredne vidljivosti	73
6.3.1	Zgradba nevronske mreže	74
6.3.2	Vhodni podatki razvrščevalnega algoritma	75
6.3.3	Ovrednotenje učinkovitosti algoritma za razvrščanje	75
6.3.3.1	Navzkrižna validacija v posameznih notranjih okoljih	77
6.3.3.2	Navzkrižna validacija v posameznih notranjih okoljih na različnih radijskih kanalih	79
6.3.3.3	Navzkrižna validacija med notranjimi okolji	79
6.3.3.4	Navzkrižna validacija med notranjimi okolji na različnih kanalih	79
6.4	Algoritem za oceno napake izmerjene razdalje	81
6.4.1	Zgradba nevronske mreže	83
6.4.2	Analiza učinkovitosti algoritma za oceno napake izmerjene razdalje	83
6.4.2.1	Navzkrižna validacija v posameznih notranjih okoljih	85
6.4.2.2	Navzkrižna validacija v posameznih okoljih na različnih radijskih kanalih	86
6.4.2.3	Navzkrižna validacija med notranjimi okolji	87
6.4.2.4	Navzkrižna validacija med notranjimi okolji na različnih kanalih	87
6.5	Primerjava učinkovitosti s klasičnimi algoritmi	88
6.6	Analiza računske učinkovitosti predlaganega razvrščevalnega algoritma	90
6.6.1	Testirane računske platforme	90
6.6.2	Določitev testov učinkovitosti	91
6.6.3	Rezultati analize učinkovitosti razvrščanja vzorcev	92
7	Lokalizacija z uporabo modelov za razvrščanje in regresijo	95
7.1	Lokalizacija z metodo najmanjših kvadratov	95
7.1.1	Metoda najmanjših kvadratov	96
7.1.2	Metoda najmanjših kvadratov z izločanjem NLoS razdalj	97

7.1.3	Metoda najmanjših kvadratov z odštevanjem ocenjene napake izmerjene razdalje	98
7.1.4	Metoda uteženih najmanjših kvadratov	98
7.2	Lokalizacija s Kalmanovim filtrom	99
7.3	Primerjava pristopov za izboljšanje lokalizacije	102
7.3.1	Ocena položaja z metodo najmanjših kvadratov brez zmanjševanja vpliva na točnost lokalizacije	102
7.3.2	Ocena položaja z metodo najmanjših kvadratov in detekcijo NLoS .	103
7.3.3	Ocena položaja z metodo najmanjših kvadratov in odštevanjem ocenjene napake	103
7.3.4	Ocena položaja z metodo uteženih najmanjših kvadratov	105
7.3.5	Ocena položaja z metodo uteženih najmanjših kvadratov in odštevanjem ocenjene napake	105
7.3.6	Ocena položaja z metodo razširjenega Kalmanovega filtra	107
7.3.7	Ocena položaja z uteženo metodo razširjenega Kalmanovega filtra . .	107
7.3.8	Ocena položaja z uteženo metodo razširjenega Kalmanovega filtra in odštevanjem ocenjene napake izmerjene razdalje	109
8	Zaključki	113
	Literatura	117
	Bibliografija	127
	Biografija	129

Slike

Slika 2.1:	Razvrščanje metod za določanje lokacije.	8
Slika 2.2:	Grafični prikaz postopkov merjenja razdalje TWR (zgoraj) in SDS-TWR (spodaj) [10].	11
Slika 2.3:	Določanje štirikotnika, ki ga omejuje presečišče kvadratov, določenih z razdaljami med sidrišči in iskanim vozliščem [26].	16
Slika 2.4:	Prikaz radijske tomografije [39].	19
Slika 3.1:	Struktura komunikacijskega bloka IEEE 802.15.4-2011 UWB [52].	22
Slika 3.2:	Struktura glave podatkovnega bloka (PHR) [10].	24
Slika 3.3:	Prikaz celotne verige kodiranja in modulacije podatkovnega bloka [10].	25
Slika 3.4:	Prikaz kodiranja podatkovnega bloka [10].	25
Slika 3.5:	Grafični prikaz BPM/BPSK modulacije [52].	26
Slika 3.6:	Zgradba podatkovnega simbola [10].	26
Slika 3.7:	Slika prikazuje možne asimetrične porazdelitve slučajne spremenljivke [66].	34
Slika 3.8:	Grafični prikaz postopka SS-TWR [52].	36
Slika 3.9:	Grafični prikaz DS-TWR postopka s štirimi poslanimi podatkovnimi paketi [52].	37
Slika 3.10:	Grafični prikaz DS-TWR postopka s tremi poslanimi podatkovnimi paketi [52].	38
Slika 4.1:	Prikaz dveh izvedb senzorskega vozlišča EVB1000.	42
Slika 4.2:	Senzorsko vozlišče SNPN-UWB.	43
Slika 4.3:	Graf odstopanja izmerjenih in dejanskih RSS vrednosti [52].	46
Slika 4.4:	Konceptualna shema eksperimentalnega senzorskega omrežja.	48
Slika 4.5:	Načrt celotnega nadstropja v pisarniškem okolju. Notranje dimenzije okolja so $15,4\text{ m} \times 12\text{ m}$	50
Slika 4.6:	Načrt industrijskega okolja. Notranje dimenzije okolja so $22\text{ m} \times 12,1\text{ m}$	51
Slika 4.7:	Načrt majhnega bivalnega okolja v bloku. Notranje mere okolja so $3,6\text{ m} \times 6,7\text{ m}$	51
Slika 4.8:	Načrt bivalnega okolja v nadstropju samostojne stanovanjske hiše. Notranje dimenzije okolja so $9,2\text{ m} \times 12,1\text{ m}$	52
Slika 5.1:	Slika prikazuje grafa z nekompenziranimi in kompenziranimi napakami izmerjene razdalje.	54
Slika 5.2:	Prikaz delovanja filtra osamelcev na grafu napake izmerjene razdalje v odvisnosti od medsebojne razdalje.	55
Slika 5.3:	Odvisnost RSS od razdalje v LoS pogojih v bivalnem okolju.	56
Slika 5.4:	Prikaz vpliva več različnih poti v prostoru na graf odvisnosti moči sprejetega signala od razdalje.	58
Slika 5.5:	Prikaz razlike eksponenta izgube poti pri določanju po metodi najmanjših kvadratov (LS) in po metodi uteženih najmanjših kvadratov (WLS).	59

Slika 5.6:	Grafi prikazujejo primerjavo različnih LoS in NLoS vzorcev.	60
Slika 6.1:	Graf prikazuje primerjavo dveh algoritmov z uporabo paketne normalizacije (z BN) in brez paketne normalizacije (brez BN). Število epoh opisuje število celotnih ponovitev učne množice v učnem postopku.	73
Slika 6.2:	Graf prikazuje primerjavo poteka učnih postopkov z (Z DR) in brez (Brez DR) regularizacije z naključnim izpuščanjem. Epoha pomeni enkratno ponovitev celotne učne množice v učnem procesu.	74
Slika 6.3:	Grafični prikaz zgradbe globoke nevronske mreže za razvrščanje vzorcev NLoS.	76
Slika 6.4:	Prikaz povprečnih impulznih odzivov na različnih komunikacijskih kanalih za isto lokacijo.	81
Slika 6.5:	Grafični prikaz zgradbe globoke nevronske mreže za ocenjevanje napake izmerjene razdalje.	84
Slika 6.6:	Prikaz učinkovitosti razvrščanja vzorcev na posameznih računskih platformah.	93
Slika 7.1:	Napaka izmerjene razdalje narašča z razdaljo in zahtevnostjo radijskega okolja.	98
Slika 7.2:	Uspešnost lokalizacijskega algoritma LS na celotni poti.	104
Slika 7.3:	Uspešnost lokalizacijskega algoritma LS z detekcijo pogojev NLoS.	104
Slika 7.4:	Uspešnost lokalizacijskega algoritma LS z odštevanjem ocenjene napake na celotni poti.	106
Slika 7.5:	Uspešnost lokalizacijskega algoritma WLS na celotni poti.	106
Slika 7.6:	Uspešnost lokalizacijskega algoritma WLS z odštevanjem ocenjene napake na celotni poti.	108
Slika 7.7:	Uspešnost lokalizacijskega algoritma EKF na celotni poti.	108
Slika 7.8:	Uspešnost lokalizacijskega algoritma EKF z uteževanjem prispevkov na celotni poti.	110
Slika 7.9:	Uspešnost lokalizacijskega algoritma EKF z uteževanjem prispevkov in odštevanjem ocenjene napake na celotni poti.	110

Tabele

Tabela 3.1:	Parametri simbolov sinhronizacijske sekvence.	23
Tabela 3.2:	Tabela bitnih hitrosti v glavi podatkovnega bloka.	24
Tabela 3.3:	Nastavitve dolžine sinhronizacijske sekvence (SYNC).	24
Tabela 3.4:	Podprti parametri podatkovnih PHY simbolov.	27
Tabela 3.5:	Parametri kanala UWB za različna notranja okolja [54].	32
Tabela 3.6:	Ocene napake izmerjenega časa $\hat{T}_{SS}$ v odvisnosti od T_{reply} in toleranc osnovne frekvence lokalne ure [52].	37
Tabela 4.1:	Tabela sevalnih karakteristik antene ACS5200HFAUWB [69].	44
Tabela 5.1:	Model izgube poti $PL(d)$ UWB kanala za različna notranja okolja. . . .	57
Tabela 5.2:	Tabela časov vzpona vhodnega signala.	60
Tabela 5.3:	Tabela energij sprejetih signalov.	61
Tabela 5.4:	Tabela presežnih zakasnitev UWB.	62
Tabela 5.5:	Tabela koeficientov simetrije.	63
Tabela 5.6:	Tabela koeficientov sploščenosti.	64
Tabela 6.1:	Uspešnost modela pri navzkrižni validaciji.	78
Tabela 6.2:	Povprečna uspešnost modela pri navzkrižni validaciji.	78
Tabela 6.3:	Uspešnost modelov pri navzkrižni validaciji za posamezne kanale. . . .	80
Tabela 6.4:	Uspešnost modelov pri navzkrižni validaciji med notranjimi okolji. . . .	80
Tabela 6.5:	Uspešnost modelov za razvrščanje med notranjimi okolji na posameznih kanalih.	82
Tabela 6.6:	Uspešnost modela pri napovedovanju napake izmerjene razdalje.	86
Tabela 6.7:	Povprečna uspešnost modela pri napovedovanju napake izmerjene razdalje.	86
Tabela 6.8:	Uspešnost modelov pri navzkrižni validaciji napovedovanja napake izmerjene razdalje za posamezne kanale.	87
Tabela 6.9:	Uspešnost modelov pri oceni napake izmerjene razdalje v posameznih notranjih okoljih.	87
Tabela 6.10:	Uspešnost modelov pri oceni napake izmerjene razdalje za posamezne kanale v posameznih notranjih okoljih.	88
Tabela 6.11:	Učinkovitost razvrševalnih algoritmov.	89
Tabela 6.12:	Izbrane računske platforme za analizo računske učinkovitosti.	92
Tabela 7.1:	Prikaz izboljševanja točnosti lokalizacije z večanjem števila razpoložljivih sidrnih vozlišč. Mediana absolutne napake (MedAE) se kljub večanju števila sidrnih vozlišč rahlo povečuje, kar kaže na večji delež rezultatov z višjo napako blizu sredinski vrednosti kot pri manjšem številu sidrnih vozlišč, po drugi strani pa se zmanjša delež rezultatov z zelo velikimi napakami, kar prispeva k manjši povprečni napaki rezultatov in njihovi manjši razpršenosti.	97

Tabela 7.2:	Točnost lokalizacije z metodo LS brez zmanjševanja vplivov meritev NLoS. Najboljše rezultate dobimo v primeru bivalnega okolja 2, kjer se povprečna absolutna napaka giblje med 0,19 m in 0,31 m. Najslabše rezultate dobimo v industrijskem okolju, kjer se MAE nahaja v območju od 0,73 m do 1,23 m. V bivalnem okolju 2 in industrijskem okolju najširši kanal CH4 kaže malenkost boljše rezultate v primerjavi z ostalimi rezultati.	103
Tabela 7.3:	Točnost lokalizacije z LS metodo in detekcijo pogojev NLoS. Zaradi majhnega števila položajev vozlišča, v katerem nam ostanejo na razpolago vsaj tri LoS sidrna vozlišča, so številčni rezultati zelo slabi. Najslabše se tu odreže pisarniško okolje z vrednostmi MAE v območju od 0,47 m do 2,71 m, najboljše razmere pa so v bivalnem okolju 2 z vrednostmi MAE med 0,15 m in 0,29 m. V večini primerov se sedaj najbolje izkaže kanal CH7.	105
Tabela 7.4:	Točnost lokalizacije z LS metodo in odštevanjem ocenjene napake izmerjene razdalje. V tabeli se jasno kaže prednost izbire najširših radijskih kanalov pri točnosti lokalizacije. Najboljše točnosti lokalizacije dobimo v bivalnem okolju 2, kjer se povprečna absolutna napaka giblje med 0,13 m na kanalu CH4 in 0,26 m na kanalu CH3. Najslabše se lokalizacija odreže v industrijskem okolju z vrednostmi MAE od 0,77 m na kanalu CH7 in 0,78 m na kanalu CH4 do 0,97 m na kanalu CH1.	107
Tabela 7.5:	Točnost lokalizacije z metodo WLS. Tudi tu opazimo trend, da radijski kanali z večjo pasovno širino dajejo boljše rezultate pri lokalizaciji. Najboljše rezultate dobimo v bivalnem okolju 2 z vrednostmi MAE med 0,14 m na kanalu CH4 in 0,47 m na kanalu CH5, najslabše pa se odreže industrijsko okolje z vrednostmi MAE med 0,66 m na kanalu CH7 in 0,98 m na kanalu CH3.	109
Tabela 7.6:	Točnost lokalizacije z metodo WLS in odštevanjem ocenjene napake izmerjene razdalje. Širina komunikacijskega kanala je tu ponovno glavni faktor, ki daje najboljše rezultate. Najboljše rezultate točnosti lokalizacije dobimo v bivalnem okolju 2 z vrednostmi srednje absolutne napake v območju od 0,10 m na kanalu CH7 do 0,19 m na kanalu CH3, najslabše pa se lokalizacija obnese v industrijskem okolju z vrednostmi MAE med 0,63 m na kanalu CH4 in 0,84 m na kanalu CH2.	111
Tabela 7.7:	Točnost lokalizacije z metodo EKF. Najslabše se lokalizacijski algoritem obnese v industrijskem okolju z vrednostmi MAE med 0,55 m na kanalu CH4 in 0,93 m na kanalu CH5, najboljše pa v bivalnem okolju 2 z vrednostmi MAE med 0,38 m na kanalu CH4 in 0,46 m na kanalu CH3. Opazimo, da izbira kanala z večjo pasovno širino pozitivno vpliva na točnost sledenja položaju.	111
Tabela 7.8:	Točnost lokalizacije z uteženo metodo EKF. Rezultati kažejo najslabše razmere v industrijskem okolju z vrednostmi MAE med 0,45 m na kanalih CH7 in CH5 ter 0,81 m na kanalu CH2. Najboljše točnosti sledenja položaju ponovno opazimo v bivalnem okolju 2 z vrednostmi MAE med 0,16 m na kanalu CH4 in CH7 ter 0,26 m na kanalu CH3.	112

Tabela 7.9: Točnost lokalizacije z uteženo metodo EKF s predhodnim odstranjevanjem ocenjenih napak izmerjene razdalje. Največje napake sledenja položaju opazimo v industrijskem okolju z vrednostmi MAE v območju med 0,26 m na kanalu CH5 in 0,66 m na kanalu CH2. Ponovno dobimo najboljše rezultate pri sledenju lokaciji v bivalnem okolju 2 z vrednostmi MAE med 0,08 m na kanalu CH7 in 0,17 m na kanalu CH3. 112

Algoritmi

Algoritem 6.1: Psevdokoda algoritma za analizo učinkovitosti.	91
---	----

Kratice

ADS-TWR	... asymmetric double sided two-way ranging ... asimetrično obojestransko dvosmerno časovno žigosanje
API	... application programming interface ... aplikacijski programski vmesnik
ART	... algebraic reconstruction technique ... algebraična rekonstrukcijska tehnika
AoA	... angle-of-arrival ... kot prihoda signala
BN	... batch normalization ... paketna normalizacija
BP	... belief propagation ... širjenje zaupanja
BPM	... burst position modulation ... modulacija z določanjem pozicije pulznih izbruhov
BPSK	... binary phase-shift keying ... binarna fazna modulacija
BR	... bit rate ... bitna hitrost
BW	... bandwidth ... pasovna širina
CDF	... cumulative distribution function ... kumulativna porazdelitvena funkcija
CDMA	... code division multiple access ... kodno deljeni dostop
CIR	... channel impulse response ... impulzni odziv kanala
CNN	... convolution neural network ... konvolucijska nevronska mreža
CPU	... central processing unit ... centralna procesna enota
CT	... computed tomography ... računalniška tomografija
DBN	... deep belief network ... mreže globokega prepričanja
DBSCAN	... density-based spatial clustering of applications with noise ... združevanje elementov v gruče na podlagi gostote elementov v gruči
DR	... dropout regularization ... regularizacija z naključnim izpuščanjem
DS-TWR	... double-sided two-way ranging ... obojestransko dvosmerno časovno žigosanje
DToA	... differential time-of-arrival

	... časovna razlika prihodov signala
EKF	... extended Kalman filter
	... razširjeni Kalmanov filter
EM	... expectation maximization
	... maksimizacija pričakovanja
EVD	... eigenvalue decomposition
	... razcep lastnih vrednosti
FEC	... forward error correction
	... vnaprejšnje popravljanje napak
FN	... false negative
	... lažno negativno
FP	... false positive
	... lažno pozitivno
GAN	... generative adversarial network
	... generativne nasprotujoče mreže
GNSS	... global navigation satellite system
	... globalni navigacijski satelitski sistem
GPU	... graphics processing unit
	... grafična procesna enota
IEEE	... Institute of Electrical and Electronics Engineers
IF	... intermediate frequency
	... medfrekvenca
JTAG	... Joint Test Action Group
LAN	... local area network
	... lokalno omrežje
LBS	... location-based services
	... lokacijske storitve
LCD	... liquid-crystal display
	... tekočerkristalni zaslon
LED	... light-emitting diode
	... svetleča dioda
LR-WPAN	... low-rate wireless personal area networks
	... brezžično osebno omrežje z nizkimi hitrostmi prenosa podatkov
LS	... least squares
	... metoda najmanjših kvadratov
LSTM	... long short-term memory
	... mreže z dolгим kratkotrajnim spominom
LTE	... Long-Term Evolution
LTS	... Long Term Support
	... dolgoročna podpora
LoS	... line-of-sight
	... neposredna vidljivost
MAE	... mean absolute error
	... povprečna absolutna napaka
MDS	... multidimensional scaling
	... metoda multidimenzionalnega skaliranja
MED	... mean excess delay
	... povprečna presežna zakasnitev
MLE	... maximum likelihood estimation
	... metoda iskanje največje verjetnosti

MLP	... multilayer perceptron ... večplastni perceptron
MPC	... multipath component ... komponenta poti
MQTT	... Message Queuing Telemetry Transport
MSE	... mean squared error ... povprečna kvadratna napaka
MSLE	... mean squared logarithmic error ... povprečna kvadratna logaritmična napaka
MedAE	... median absolute error ... mediana absolutne napake
NAG	... Nesterov accelerated gradient ... metoda Nesterovega pospešenega gradienta
NBP	... nonparametric belief propagation ... metoda neparametričnega širjenja zaupanja
NFC	... near-field communication ... komunikacija v bližnjem polju
NLoS	... non-line-of-sight ... pogoji brez neposrednje vidljivosti
OS	... operating system ... operacijski sistem
PCB	... printed circuit board ... tiskano vezje
PDF	... probability density function ... funkcija gostote verjetnosti
PDP	... power delay profile ... profil močnostne zakasnitve
PHR	... PHY header ... glava podatkovnega bloka
PL	... path loss ... izguba poti
PRF	... pulse repetition frequency ... frekvenca ponavljanja pulzov
PSD	... power spectral density ... spektralna gostota moči
QoS	... quality of service ... kakovost storitve
RAM	... random access memory ... pomnilnik z naključnim dostopom
RBF	... radial basis function ... radialna bazna funkcija
RBM	... restricted Boltzmann machine ... omejen Boltzmannov stroj
RF	... radio frequency ... radijska frekvenca
RMS	... root mean square ... koren povprečne kvadratne napake, efektivna vrednost
RNG	... ranging ... merjenje razdalje
RNN	... recurrent neural network

	... povratne nevronske mreže
RS	... Reed–Solomon
RSS	... received signal strength
	... moč sprejetega signala
RSSFP	... first path received signal strength
	... moč prve fronte sprejetega signala
RT	... RF tomography
	... radijska tomografija
RX	... receive
	... sprejem
ReLU	... rectified linear unit
	... linearni usmernik
SBC	... single-board computer
	... vgradni računalnik
SDS-TWR	... symmetric double-sided two-way ranging
	... simetrično obojestransko dvosmerno časovno žigosanje
SECDEC	... single error correct, double error detect
	... popravljanje enkratne napake z detekcijo dvakratne napake
SFD	... start of frame delimiter
	... začetni razmejevalnik bloka
SGD	... stochastic gradient descent
	... stohastični gradientni spust
SHR	... synchronization header
	... sinhronizacijska glava, preambula
SLAM	... simultaneous localization and mapping
	... sočasna lokalizacija in kartiranje
SPI	... Serial Peripheral Interface
	... serijsko periferno podatkovno vodilo
SS-TWR	... single-sided two-way ranging
	... enostransko dvosmerno časovno žigosanje
SV	... Saleh-Valenzuela
SVM	... support vector machine
	... metoda podpornih vektorjev
SYNC	... synchronization sequence
	... sinhronizacijska sekvenca
TN	... true negative
	... pravilno negativno
TP	... true positive
	... pravilno pozitivno
TWR	... two-way-ranging
	... dvosmerno časovno žigosanje
TX	... transmit
	... oddaja
ToF	... time of flight
	... čas razširjanja signala
UART	... universal asynchronous receiver-transmitter
	... univerzalno asinhrono serijsko vodilo
USB	... Universal Serial Bus
	... univerzalno serijsko vodilo
UWB	... ultra-wideband

WLS ... ultra-široki pas
 ... weighted least squares
 ... metoda uteženih najmanjših kvadratov

Poglavje 1

Uvod

V sodobnem svetu informacijskih tehnologij je stalna medsebojna povezljivost pogoj za zagotavljanje vse večje učinkovitosti in zanesljivosti različnih sistemov. S povezovanjem informacij iz različnih virov v realnem času so mogoče stalne optimizacije proizvodnih in drugih procesov. V želji po vse večji učinkovitosti postaja informacija o položaj naprav, predmetov in ljudi vse bolj pomembna za zanesljivo delovanje procesov. Že leta so globalni navigacijski satelitski sistemi (angl. global navigation satellite system, GNSS) tisti, ki omogočajo splošne navigacijske storitve, večjo prilagodljivost v prometu, lajšajo logistične procese, omogočajo z lokacijo povezane storitve (angl. location-based services, LBS), pomagajo pri ukrepanju ob naravnih nesrečah, reševanju itd. Glavna omejitev satelitskih navigacijskih sistemov je slabša točnost v gosto poseljenih naseljih z visokimi stavbami, v ozkih dolinah, v notranjih okoljih in nasploh povsod tam, kjer je neposredna vidljivost med sprejemnikom in sateliti na kakršen koli način omejena.

V mobilnih omrežjih pete (5G) in naslednjih generacij informacija o položaju bo ali pa že igra pomembno vlogo pri delovanju komunikacijskega sistema. Izzivi pete generacije komunikacijskih sistemov so predvsem v povečevanju podatkovnega prometa in števila naprav, zanesljivosti komunikacije pri uporabi v kritičnih sistemih in pri zahtevah po zmanjšanju porabe električne energije ter krajših odzivnih časih komunikacijskih sistemov. Peta generacija mobilnih omrežij bo prva, ki bo dovolj natančno izkoriščala informacijo o lokaciji v realnem času pri načrtovanju in optimizaciji omrežja [1]. Zaradi predvidenega velikega zgoščevanja omrežij, zlasti v različnih notranjih okoljih, bo vpeljava kooperativnih tehnik za avtomatsko organizacijo omrežij bistvenega pomena za zagotavljanje ustrezne kakovosti storitev (angl. Quality of Service, QoS). Visoka točnost informacije o položaju v sodobnih komunikacijskih sistemih lahko bistveno pripomore k boljšemu delovanju omrežij. V kombinaciji s tehnikami strojnega učenja in na splošno statističnega modeliranja lahko omogoči tudi spremljanje trenutnih in ocenjevanje prihodnjih vzorcev gibanja. Na podlagi teh lahko v gostih omrežjih majhnih celic (angl. small cell) omogočimo boljše izročanje povezav (angl. handover) najbolj ustrezni celici. Informacije o mobilnosti in položaju lahko s pomočjo tehnik dodeljevanja virov z zaznavanjem lokacije (angl. location-aware resource allocation techniques) zmanjšajo zakasnitve v komunikaciji zaradi zmožnosti ocene kakovosti radijskega kanala izven vseh dosedanjih časovnih okvirov.

Na aplikacijskem sloju se lokalizacija uporablja za namene navigacije, serviranja lokacijsko-relevantnih informacij uporabnikom v vsakdanjem življenju in v prometu, vodenja avtonomnih vozil v industrijskih okoljih, sledenja lokaciji inventarja v delovnih ali skladiščnih okoljih, sledenja in navigacije reševalnih ekip ob naravnih nesrečah in požarih, ter še za veliko drugih namenov. Pomembno vlogo bo lokalizacija odigrala v industrijskih sistemih četrte generacije (industrija 4.0), kjer bo informacija ključna za vodenje avtonomnih vozičkov za dostavo sestavnih delov in osnovnih surovin do različnih delovnih mest na

proizvodni liniji, za podporo pri sledenju produktom znotraj različnih stopenj proizvodnje, za vodenje večjih robotskih manipulatorjev v proizvodnji, sledenje vozilom in inventarju ter boljšemu nadzoru proizvodnih procesov. V prometu lahko visoka točnost položaja v kombinaciji z medsebojno komunikacijo vozil pripomore k zmanjšanju števila nesreč, večji pretočnosti prometa in boljši informiranosti voznikov, ki se odpravljajo na pot. V bolnišničnem okolju lahko lokalizacijski sistemi pomagajo pri sledenju premičnega diagnostičnega inventarja, sledenju pacientom ter boljšemu informiranju zdravniškega osebja o trenutni lokaciji ostalih strokovnjakov v organizaciji.

Za večino zgoraj omenjenih primerov uporabe je značilno, da so običajno povezani z radijsko zahtevnimi okolji, kjer zadovoljiv sprejem satelitskih signalov ni zagotovljen. Poleg nezanesljivosti satelitskih lokalizacijskih sistemov je v zahtevnih radijskih okoljih prisotno tudi veliko fiksnih in premičnih ovir, ki na tak ali drugačen način ovirajo razširjanje radijskih signalov. Motnje v razširjanju radijskega signala, ki jih povzročajo ovire, bistveno vplivajo na vrednosti parametrov, ki jih lahko zaznamo s komunikacijsko opremo in uporabimo za določanje lokacije. Omenjena problematika zahteva razvoj robustnejših lokalizacijskih metod, ki znajo zaznati pogoje razširjanja radijskega signala v izbranem radijskem okolju in znanje o okolju uporabiti za izboljšanje sicer manj zanesljive informacije o lokaciji.

1.1 Prispevki doktorske disertacije

V doktorski disertaciji se ukvarjamo z analizo razmer v notranjih radijskih okoljih z uporabo ultra-širokopasovnih (angl. ultra-wideband, UWB) radijskih tehnologij in njihovo uporabo za potrebe lokalizacije. Posvečamo se analizi vpliva različnih notranjih radijskih okolij na točnost lokalizacije in modeliranju vplivov notranjih okolij na lokalizacijo s pomočjo algoritmov strojnega učenja, predvsem globokega učenja (angl. deep learning). Z različnimi kombinacijami izhodnih podatkov naučenih modelov za razpoznavanje pogojev brez neposredne vidljivosti (angl. non-line-of-sight, NLoS) in za oceno napake izmerjene razdalje dosežemo, da je ocenjena informacija o položaju v izbranem notranjem okolju zanesljivejša.

Glavni doprinosi doktorske disertacije k znanosti na področju lokalizacije v notranjih okoljih so:

1. **Detekcija pogojev NLoS z uporabo globokega učenja.** Z uporabo pristopov globokega učenja smo zgradili modele za razpoznavanje razmer pri razširjanju signala brez neposredne vidljivosti. Odsotnost neposredne vidljivosti med oddajnikom in sprejemnikom namreč povečuje napako izmerjene razdalje, ker mora signal zaradi ovir na svoji poti namesto po direktni liniji potovati skozi ovire ali pa z odboji po daljši poti okoli ovir. Pristop z globokim učenjem primerjamo z običajnimi pristopi strojnega učenja in dokažemo boljšo učinkovitost predlaganih algoritmov.
2. **Ocena napake izmerjene razdalje z uporabo globokega učenja.** Z uporabo globokega učenja na impulznih odzivih kanala in pripadajočih napakah izmerjene razdalje zgradimo regresijske modele za ocenjevanje napake izmerjene razdalje. Ocenjene napake izmerjene razdalje lahko na različne načine uporabimo za izboljšanje metod lokalizacije.
3. **Analiza učinkovitosti posameznih algoritmov za lokalizacijo in sledenje z modeli za razvrščanje in oceno napake izmerjene razdalje.** Z globokim učenjem izdelane modele uporabimo za filtriranje vhodnih podatkov v algoritme za lokalizacijo in za uteževanje posameznih prispevkov. Z modeli pridobljena informacija različno doprinese k izboljšanju točnosti lokalizacije glede na kompleksnost algoritma

za oceno lokacije. Primerjamo tudi uspešnost različnih lokalizacijskih algoritmov z uporabo modelov radijskega okolja, pridobljenih s postopki globokega učenja.

4. **Obširna referenčna podatkovna zbirka meritev za lokalizacijo v notranjih okoljih z uporabo radijske tehnologije UWB.** V štirih značilnih notranjih okoljih smo postavili osem referenčnih fiksnih sidrnih vozlišč z znano lokacijo, mobilno vozlišče pa smo postavljali v točke z enako medsebojno oddaljenostjo na trajektoriji, ki opisuje pot osebe v tem okolju. V vsaki točki smo naredili serijo zaporednih meritev do vsakega od fiksnih sidrnih vozlišč. Meritve smo ponovili na vseh radijskih kanalih, ki jih izbrani radijski komunikacijski vmesnik UWB DW1000 podpira. Podatkovna zbirka za vsak izmerek hrani informacijo o izbranem sidrnem vozlišču, pravi lokaciji mobilnega vozlišča, pravi lokaciji sidrnega vozlišča, izmerjeni razdalji med vozliščema (čas razširjanja, ToF), morebitnem razširjanju brez neposredne vidljivosti (NLoS), moči sprejetega signala (RSS), moči prve fronte sprejetega signala (RSSFP), nastavitvi radijskega vmesnika, številu sprejetih simbolov sinhronizacijske glave sprejetega paketa in oceni impulznega odziva kanala za sprejeti paket. Ta sistematična referenčna podatkovna zbirka tako opisuje štiri trajektorije v štirih značilnih notranjih okoljih, ki jih lahko raziskovalci uporabijo za analizo različnih lokalizacijskih algoritmov na podatkih, pridobljenih z realno opremo v realnih in različno zahtevnih notranjih okoljih. Večina raziskav lokalizacije v notranjih okoljih temelji namreč na simulacijskih okoljih ali pa na zelo okrnjenih podatkovnih zbirkah, kjer so slabosti posameznih algoritmov za lokalizacijo težko opazne. Simulacijska okolja običajno preveč poenostavijo razmere radijskega okolja in zato rezultati pogosto vodijo v pretirano optimistične zaključke.
5. **Obširna analiza in modeliranje razširjanja radijskih signalov UWB v notranjih okoljih z uporabo cenovno dostopne komunikacijske opreme.** Na podlagi zbranih meritev smo analizirali razširjanje UWB radijskih signalov v značilnih notranjih okoljih, pri zajemanju meritev pa smo namesto drage laboratorijske opreme uporabili cenovno zelo dostopne radijske module UWB DW1000. Izbrani moduli zaradi razlike v ceni s faktorjem 1000 in več v primerjavi z dragimi spektralnimi analizatorji omogočajo zelo obsežne merilne kampanje, kjer lahko simuliramo razmere, ki bi se pojavile v realnem lokalizacijskem sistemu, pri tem pa žrtvujemo dobršno mero ločljivosti. Rezultati modeliranja razmer v različnih notranjih okoljih omogočajo primerjavo z referenčnimi modeli kanalov iz standarda IEEE 802.15.4-2011, dajejo pa tudi zelo dober vpogled v razmere v okoljih, ki jih standard zajema na podlagi le omejenega števila vzorcev.

Prispevki doktorske disertacije bodo pripomogli k boljšemu razumevanju, kako posamezna zahtevna okolja vplivajo na postopek radijske lokalizacije z ultra-širokopasovnim signalom. Obširne primerjave različnih postopkov na istih vhodnih podatkih tudi bolje prikazujejo prednosti in slabosti različnih pristopov. Odprta, prosto dostopna podatkovna zbirka omogoča tudi drugim raziskovalcem, da lahko testirajo postopke za lokalizacijo na podatkih, ki so zajeti v realnih značilnih notranjih okoljih z umetnim poustvarjanjem gibanja človeka.

1.2 Struktura doktorske disertacije

Doktorska disertacija je smiselno razdeljena na več poglavij. Po uvodnem poglavju se posvetimo pregledu obstoječih metod za radijsko lokalizacijo, kjer globalni navigacijski satelitski sistemi niso dosegljivi ali pa delujejo le z omejeno funkcionalnostjo. Pristope k

radijski lokalizaciji zaradi bogatega nabora metod in področij uporabe zelo težko razporedimo v univerzalne razrede. Če se omejimo samo na notranja okolja in na načine, kako pridemo do vhodnih podatkov za določanje položaja, lahko na najvišjem nivoju metode razdelimo na aktivne in na pasivne metode. Pri aktivnih metodah radijske lokalizacije je predmet ali oseba, ki ji ocenjujemo položaj, opremljena s senzorskim vozliščem. To vozlišče aktivno komunicira z referenčnim omrežjem, ki direktno ali posredno služi namenom določanja položaja. Pri pasivnih metodah predmet lokalizacije ni opremljen z nobenim komunikacijskim sistemom, položaj pa lahko določimo z analizo signalov in motenj, ki jih predmet ali oseba povzročata v radijskem okolju.

V tretjem poglavju se osredotočimo na uporabljeno tehnologijo UWB. Na podlagi standarda IEEE 802.15.4, ki določa funkcionalnost izbranega komunikacijskega vmesnika DW1000, predstavimo strukturo komunikacijskih blokov, komunikacijskih signalov ter simbolov. V nadaljevanju poglavja opišemo osnovne mehanizme, ki vplivajo na razširjanje signala UWB, in obdelamo osnovne parametre, s katerimi določamo modele kanalov v komunikacijskih sistemih UWB. Poleg standardnih modelov kanalov, ki opisujejo izgube moči signala v odvisnosti od razdalje in nosilne frekvence, se posvetimo tudi parametrom modela Saleh-Valenzuela, ki opisujejo obliko profila močnostne zakasnitve signala (angl. power delay profile, PDP). Predstavimo tudi klasične statistične parametre PDP, kot so povprečna presežna zakasnitev, RMS razpršitev zakasnitev (angl. RMS delay spread), največja presežna zakasnitev, koeficient simetrije in koeficient sploščenosti. V zadnjem delu tretjega poglavja se posvetimo še tehnikam merjenja časa razširjanja signala UWB med oddajnikom in sprejemnikom, ki jih podpira izbrani radijski modul UWB. Tehniko dvosmernega žigosanja (angl. Two-way-ranging, TWR) uporabimo za vse radijske meritve razdalje med sidrnim vozliščem in vozliščem z neznanim položajem.

V četrtem poglavju se posvetimo senzorskim vozliščem UWB, ki jih uporabimo v procesu izdelave podatkovne zbirke za lokalizacijo v notranjih okoljih. Podrobno predstavimo njihove značilnosti in diagnostične informacije o kanalu, ki jih lahko pridobimo za vsak sprejeti paket na posameznem senzorskem vozlišču. Za izvedbo meritev smo zgradili merilni sistem z oddaljenim dostopom za hitro izvajanje kompleksnih meritev. V vsakem izbranem značilnem notranjem okolju smo izdelali natančen načrt okolja, ki je služil za postavitve senzorskih vozlišč, načrtovanje trajektorije za sledenje in lokalizacijo ter za poznejšo analizo rezultatov.

V petem poglavju se osredotočimo na analizo pridobljenih meritev in izgradnjo modelov kanala v posameznih značilnih notranjih okoljih. Pridobljena podatkovna zbirka obsega več kot 400.000 individualnih meritev, ki skupaj opisujejo značilnosti posameznih notranjih okolij. Potrebna je bila ustrezna predobdelava podatkov z odstranjevanjem izjemnih vrednosti, da modeli čim bolj verno opisujejo razmere v okolju. Poglavje sklenemo s tabelo, ki na podlagi meritev s cenovno dostopnimi senzorskimi vozlišči definira parametre modelov kanalov. Te lahko primerjamo s parametri, pridobljenimi z referenčnimi laboratorijskimi instrumenti in zaradi zahtevnosti meritev bolj omejenimi podatkovnimi zbirkami.

V šestem poglavju obdelamo uporabno področje strojnega učenja za namene detekcije pogojev razširjanja na radijskih kanalih s poudarkom na globokem učenju. Osredotočimo se na konvolucijske nevronske mreže, ki tudi brez luščenja značilk iz surovih podatkov omogočajo izgradnjo zanesljivejših modelov v primerjavi s standardnimi pristopi s področja strojnega učenja. Pridobljene modele za razvrščanje vzorcev brez neposredne vidljivosti primerjamo s klasičnimi pristopi, kjer uporabimo izluščene značilke. Poleg modelov za razvrščanje zgradimo tudi modele za oceno napake izmerjene razdalje na podlagi impulznega odziva kanala. Vsi modeli so ovrednoteni v tabelah z navzkrižnimi validacijami. Ovrednotenje z navzkrižnimi validacijami smo naredili tako, da smo za učenje modela uporabili tri značilna notranja okolja, za ovrednotenje pa smo uporabili vzorce iz okolja, ki ni bilo

uporabljeno v učnem postopku. Na ta način je zagotovljeno, da rezultati ne odražajo poznavanja dejanskih meritev v izbranem okolju, ampak kažejo na zmožnost posploševanja trenutnega modela na razmere, ki mu še niso bile predstavljene. Naredimo tudi primerjavo računske učinkovitosti predlaganih algoritmov za razvrščanje, in pokažemo, da so uporabni tudi na računsko omejenih računalniških platformah.

V sedmem poglavju se posvetimo uporabi lokalizacijskih algoritmov v izbranih okoljih in uporabi informacije, ki jo lahko pridobimo s predhodno zgrajenimi razvrščevalnimi in regresijskimi modeli. Posvetimo se metodi najmanjših kvadratov, metodi uteženih najmanjših kvadratov in lokalizaciji z razširjenim Kalmanovim filtrom (angl. extended Kalman filter, EKF). Vse pristope validiramo v vseh štirih notranjih okoljih in uspešnost posameznih pristopov na izbranih trajektorijah prikažemo tudi grafično.

Disertacijo zaključimo v osmem poglavju, kjer povzamemo ugotovitve, podamo zaključke in nakažemo smernice za možne izboljšave in nadaljnje delo.

Poglavje 2

Pregled metod za lokalizacijo

Lokalizacijski sistemi omogočajo pridobivanje informacije o lokaciji ljudi, živali ali predmetov v določenem koordinatnem sistemu. Glede na referenčni koordinatni sistem jih v splošnem delimo na sisteme za globalno pozicioniranje in sisteme za lokalno pozicioniranje.

Sistemi za globalno pozicioniranje omogočajo določanje absolutne lokacije v globalnem koordinatnem sistemu z izhodiščem v središču Zemlje. Omogočajo določanje absolutne pozicije na Zemlji. Za referenčne točke v procesu lokalizacije izkoriščajo konstelacije namenskih globalnih navigacijskih satelitskih sistemov (GNSS), kot so ameriški GPS, evropski Galileo, ruski GLONASS, kitajski BaiDou in drugi.

Sistemi za lokalno pozicioniranje določajo relativni položaj v lokalnem koordinatnem sistemu z izhodiščem v poljubni točki znotraj območja delovanja. Za delovanje je potrebna namenska radijska oprema, ki je del obstoječe radijske infrastrukture (Wi-Fi dostopovne točke, mobilno omrežje itd.), ali pa potrebujejo povsem ločeno opremo, namenjeno izključno lokalizaciji.


Sisteme za lokalno pozicioniranje glede na način pridobivanja položaja nadalje delimo na aktivne in pasivne sisteme. V aktivnih lokalizacijskih sistemih je ciljni objekt (predmet, oseba, žival) opremljen z aktivno radijsko komunikacijsko opremo, ki aktivno sodeluje v procesu lokalizacije. Aktivne lokalizacijske sisteme delimo na:

- geometrijske sisteme, kjer lastnosti radijskih povezav v radijskem omrežju pretvorimo v razdaljo ali kote in položaj poiščemo na podlagi geometrijskih zakonitosti,
- negeometrijske sisteme, ki temeljijo na izkoriščanju principov radiofrekvenčnega oddaja,
- kooperativne sisteme, ki izkoriščajo informacijo o medsebojnih povezavah v radijskem komunikacijskem omrežju,
- hibridne sisteme, ki poleg radijskih pristopov izkoriščajo še dodatne informacije, ki jih pridobijo iz inercialnih senzorjev in ostalih virov konteksta okolja.

Pasivni lokalizacijski sistemi izkoriščajo zakonitosti razširjanja radijskih signalov v okolju za določanje položaja ciljnega objekta, ki ni opremljen z radijskim komunikacijskim vmesnikom. Delitev metod lokalnega pozicioniranja prikazuje slika 2.1.

Zaradi obsežnosti področja obstajajo še drugi načini delitve pristopov k lokalizaciji. V [2] so izbrali delitev glede na mobilnost referenčnih lokacij in vozlišč z neznano lokacijo. V [3] avtorji ločijo lokalizacijske pristope glede na to, ali se v postopku določanja položaja uporabljajo medsebojne razdalje, ali pa temeljijo na informaciji, ki z razdaljo ni povezana. V [4] pa avtorji razdelijo pristope glede na bližino referenčnih lokacij, geometrijske metode in metode na podlagi analize scene. Načini delitev pristopov lokalizacije so povezani predvsem s končnim namenom delitve in katerim delom postopka dajemo večji pomen.

Položaj na prostem običajno najlažje določimo z uporabo sistemov GNSS, ki so zaradi



Slika 2.1: Razvrščanje metod za določanje lokacije.

svoje dostopnosti in relativno visoke točnosti pozicioniranja najboljša izbira. Sprejemniki GNSS so vgrajeni v večino sodobnih mobilnih telefonov in so tako na razpolago praktično vsem mobilnim uporabnikom.

V notranjih okoljih so lokalizacijski sistemi GNSS zaradi razširjanja satelitskih signalov brez neposredne vidljivosti in posledično njihovega visokega slabljenja ter razširjanja po več poteh večinoma neuporabni. Napake ocenjenega položaja so v primeru uporabe v notranjih okoljih visoke, oziroma signali za določanje položaja niti niso na voljo. Poleg tega pa so zahteve po natančnosti lokalizacije v notranjih okoljih veliko višje zaradi večje omejenosti s prostorom. Za lokalizacijo v notranjih okoljih se zato uporablja drugačne pristope, ki namesto satelitskih signalov izkoriščajo signale iz namensko postavljene infrastrukture ali na nek način izkoriščajo lastnosti okolja.

2.1 Aktivne metode lokalizacije

Aktivne metode lokalizacije za delovanje zahtevajo, da je objekt lokalizacije opremljen z ustrezno radijsko opremo, ki je sposobna zaznati aktivni oddajnik ali pa oddajati radijski signal. Na podlagi pridobljenih informacij o stanju radijskega kanala med posameznimi napravami in objektom lokalizacije ali pa na podlagi informacije o medsebojni povezanosti vozlišč v radijskem omrežju lahko glede na naravo informacije sistem določi položaj objekta lokalizacije. Aktivne metode lokalizacije lahko glede na način pridobivanja informacije o položaju razdelimo na geometrijske metode, negeometrijske metode, kooperativne metode in na hibridne metode lokalizacije.

2.1.1 Geometrijske metode

Geometrijske metode izkoriščajo podatke o medsebojni razdalji med vozlišči v radijskem omrežju ali pa izkoriščajo informacijo o vpadnih kotih sprejetih signalov na kompleksnih antenskih sistemih. Na podlagi pridobljenih informacij z izkoriščanjem geometrijskih zakonitosti lahko na različne načine ocenimo položaj objekta.

2.1.1.1 Tehnike lociranja na osnovi moči sprejetega signala

Najbolj razširjen in splošno dostopen pristop za lokalizacijo je pristop z uporabo moči sprejetega signala (angl. received signal strength, RSS). RSS je informacija, ki jo zagotavlja večina sodobnih radijskih sprejemnikov za vsak sprejeti podatkovni paket. Radijski signal med oddajnikom in sprejemnikom običajno potuje po različno dolgih poteh, čemur pravimo razširjanje po več poteh. Na posamezne poti razširjanja signala vplivajo odboji, sipanje,

uklon in lom radijskega signala na ovirah v notranjem okolju (zidovi, stavbe, pohištvo, drevesa, itd.).

Moč sprejetega signala P_{RX} lahko modeliramo kot razliko med močjo oddanega signala P_{TX} in izgubo poti $PL(d_i)$, počasnim presihanjem L_S ter hitrim presihanjem L_F .

$$P_{RX}(d_i) = P_{TX} - PL(d_i) - L_S - L_F \quad (2.1)$$

Model izgube poti $PL(d_i)[dB]$ običajno določimo po enačbi (2.2), kjer $PL(d_0)$ predstavlja referenčno vrednost izgube poti pri referenčni razdalji d_0 , preostanek pa predstavlja logaritemsko odvisnost od razdalje d_i z eksponentom (gradientom) izgube poti n_p in komponento počasnega presihanja L_S . Eksponent izgube poti n_p narašča z zahtevnostjo radijskega okolja in tipično obsega vrednosti med 2 za slabljenje praznega prostora in 5 za zahtevna radijska okolja, kjer prevladuje razširjanje signala brez neposredne vidljivosti [5].

$$PL(d_i)[dB] = PL(d_0) + 10n_p \log_{10}\left(\frac{d_i}{d_0}\right) \quad (2.2)$$

Če predpostavimo, da lahko efekte hitrega presihanja omejimo s povprečenjem na večjem frekvenčnem območju, širšem področju ali pa v daljšem časovnem obdobju, je nedoločenost meritve razdalje preko RSS določena s počasnim presihanjem. Empirični model za počasno presihanje je definiran kot naključna spremenljivka $\mathcal{N}(0, \sigma_S^2)$ z logaritemsko normalno porazdelitvijo z varianco $\sigma_S^2[dB]$. Počasno presihanje je faktor, ki najbolj vpliva na natančnost RSS lokalizacijskih sistemov in se mu zaradi njegove odvisnosti od lokacije ne moremo izogniti brez obsežnega in zamudnega kalibracijskega kartiranja radijskega okolja.

Geometrijske tehnike lociranja na osnovi moči sprejetega signala uporabijo vrednosti RSS za izračun medsebojne razdalje na podlagi predhodno določenega modela izgube poti [6]–[9]. Enačba (2.3) opisuje izračun razdalje d iz izmerjene RSS vrednosti. d_0 je referenčna razdalja, pri kateri je bila izmerjena referenčna moč sprejetega signala $P_{RX}(d_0)$, n_p pa je eksponent izgube poti. Vrednosti $P_{RX}(d_0)$ in $P_{RX}(d_i)$ sta poleg počasnega in hitrega presihanja odvisni tudi od antenskih karakteristik, nastavljene oddajne moči, občutljivosti sprejemnika in okolja, n_p pa velja za isto okolje in antenske karakteristike. Zaradi omenjenih odvisnosti, so metode RSS zelo občutljive na spremembe v okolju in v strojni opreми. Vplive napak pri oceni razdalje iz vrednosti RSS rešujejo z različnimi pristopi, kot so povprečenje vrednosti RSS [7], adaptivno modeliranje [6], [8], uporaba Kalmanovega filtra [9] in drugi. S filtriranjem lahko zmanjšamo odvisnost rezultatov od počasnega in hitrega presihanja, odvisnosti od okolja in strojne opreme pa ne moremo zmanjšati brez dobrega poznavanja lastnosti obeh.

$$d = d_0 10^{\frac{P_{RX}(d_0) - P_{RX}(d_i)}{10n_p}} \quad (2.3)$$

2.1.1.2 Tehnike lociranja na osnovi časa razširjanja signala

Tehnike lokalizacije, ki temeljijo na času razširjanja signala, izkoriščajo zakonitost, da je čas, ki ga potrebuje radijski signal med dvema točkama, premo sorazmeren razdalji, ki jo ta prepotuje. Radijski signali se v zraku razširjajo s svetlobno hitrostjo, ki je enaka $c = 2,98 \cdot 10^8 \text{ ms}^{-1}$, prepotovano pot d in čas razširjanja τ pa povezuje enačba $d = c\tau$.

Čas potovanja signala od oddajnega do sprejemnega vozlišča določimo kot razliko časa oddaje signala t_m in časa sprejema radijskega signala t_i , kot prikazuje enačba (2.4).

$$\tau_i = t_i - t_m \quad (2.4)$$

V lokalnem koordinatnem sistemu predstavimo razdaljo med vozliščem z neznano lokacijo in enim od referenčnih vozlišč z evklidsko razdaljo, kot prikazuje enačba (2.5).

$$\tau_i = \frac{d_i}{c} = \frac{\sqrt{(x_i - x)^2 + (y_i - y)^2}}{c} \quad (2.5)$$

Če enačbo (2.5) kvadriramo in preuredimo, dobimo enačbo (2.6), ki nam kaže, da iskano vozlišče leži na krožnici s središčem v i -tem referenčnem vozlišču s polmerom d_i , ki predstavlja ocenjeno razdaljo med iskanim vozliščem in referenčnim vozliščem.

$$(x_i - x)^2 + (y_i - y)^2 = (c\tau_i)^2 \quad (2.6)$$

Shema lokalizacije na osnovi časa razširjanja signala zahteva, da so ure med oddajnim vozliščem in sprejemnimi vozlišči zelo natančno sinhronizirane. Zagotavljanje sinhronizacije globalnega časa med vsemi vozlišči, ki so udeležena v procesu lokalizacije, je zahtevna in z radijskimi viri potratna operacija, ki večinoma niti ni izvedljiva niti ni smiselna v senzorskih omrežjih. 1 ns napake v izmerjenem času potovanja signala namreč predstavlja približno 30 cm napake v izmerjeni razdalji.

2.1.1.3 Tehnike lociranja na osnovi časovne razlike prihodov signala

Predpostavimo, da lahko na vseh referenčnih vozliščih z znanimi lokacijami, ki so udeležena v procesu lokalizacije, določimo točen čas prihoda signala, ki ga je oddalo mobilno vozlišče. Vsa referenčna vozlišča morajo imeti tudi dostop do skupnega referenčnega časa ali pa morajo s sinhronizacijo zagotoviti njegovo pravilno propagacijo v sistemu.

Mobilno vozlišče v trenutku t_m odda signal, ki za pot d_i do i -tega referenčnega vozlišča potrebuje τ_i sekund in na i -to sidrno vozlišče (vozlišče s poznanin položajem) prispe ob času $t_i = \tau_i + t_m$. Z uporabo dveh izmerjenih časov prihoda signala do dveh referenčnih vozlišč lahko z definicijo njune razlike eliminiramo potreben čas oddaje t_m , kar prikazuje enačba (2.7).


$$\begin{aligned} t_i - t_j &= \tau_i + t_m - \tau_j - t_m \\ &= \tau_i - \tau_j \\ &= \frac{d_i}{c} - \frac{d_j}{c} \\ &= \frac{\sqrt{(x_i - x)^2 + (y_i - y)^2}}{c} - \frac{\sqrt{(x_j - x)^2 + (y_j - y)^2}}{c} \end{aligned} \quad (2.7)$$

Z dodatno tretjo meritvijo časa prispetja signala na vozlišču, ki ni enako prejšnjima dvema, dobimo dve nelinearni enačbi z dvema neznankama. Dobljeni sistem enačb ima lahko eno ali dve rešitvi. Da se izognemo občasnim večkratnim rešitvam sistema, lahko v nabor meritev dodamo še četrto meritev časa prispetja signala, da zagotovimo enoznačno rešitev sistema enačb in s tem posledično izračunano en položaj [5].

Pari vrednosti (x, y) , ki rešijo enačbi (2.4) in (2.5), opišejo hiperbolo. Meritvi časa prispetja signala na dveh različnih vozliščih ter njuna razlika, ki je opisana z enačbo (2.7), pa orišejo dve hiperboli, njuno presečišče pa določa lokacijo iskanega vozlišča. Zaradi matematične povezave s hiperbolami tej družini algoritmov pravimo tudi hiperbolični lokalizacijski algoritmi.

2.1.1.4 Tehnike lociranja na osnovi dvosmernega časovnega žigosanja

V brezžičnih senzorskih omrežjih je običajno težko upravičiti ali pa zagotoviti časovno sinhronizacijo med senzorskimi vozlišči. Sinhronizacija zahteva uporabo dodatnih fizičnih



Slika 2.2: Grafični prikaz postopkov merjenja razdalje TWR (zgoraj) in SDS-TWR (spodaj) [10].

povezav med referenčnimi vozlišči ali pa zaseda nezanemarljiv delež časa, ki je na razpolago za komunikacijo v izbranem frekvenčnem pasu. Vsa dodatna komunikacija zahteva dodatno energijo, ki je pri baterijsko napajanih sistemih zelo omejena in dragocena.

Če se hočemo znebiti zahteve po globalni sinhronizaciji sistemskih ur med senzorskimi vozlišči, je za merjenje razdalje potrebna izmenjava večjega števila sporočil. Osnovne frekvence kvarčnih kristalov, ki se uporabljajo v oscilatorjih sistemskih ur, so podvržene lezenju, ki ima pomemben vpliv na točnost informacije o času potovanja signala in posledično ocenjeni medsebojni razdalji. V komunikacijskem standardu IEEE 802.15.4a [10] sta navedeni dve shemi za merjenje razdalje brez globalne sinhronizacije sistemskih ur na posameznih senzorskih vozliščih: dvosmerno časovno žigosanje (angl. two-way ranging, TWR) in simetrično obojestransko dvosmerno časovno žigosanje (angl. symmetric double-sided two-way ranging, SDS-TWR). Metoda SDS-TWR zahteva večje število izmenjanih sporočil, je pa z uvedbo simetrije v merilno shemo sposobna izničiti večino vplivov lokalnega lezenja sistemskih ur na rezultat izmerjene medsebojne razdalje. Grafični prikaz obeh pristopov k merjenju medsebojne razdalje je prikazan na sliki 2.2.

Da bi zmanjšali število potrebnih podatkovnih paketov in vseeno omejili vpliv lezenja

lokalnih sistemskih ur na rezultat meritev, so nekateri avtorji predlagali alternative asimetrične sheme izmenjave podatkovnih paketov. Avtorji v [11] predlagajo shemo s tremi podatkovnimi paketi, kjer dvema zaporednima začetnima paketoma sledi odgovor s povzetkom vseh lokalnih časovnih žigov. V [12] avtorji s pristopom ADS-TWR omilijo zahteve po fiksnem času za odgovor t_{reply} in s tremi izmenjanimi podatkovnimi paketi uspejo zagotoviti boljšo stabilnost meritev od postopka TWR, hkrati pa jim uspe zmanjšati število potrebnih paketov in čas, ki je potreben za oceno ene medsebojne razdalje.

2.1.1.5 Tehnike lociranja na osnovi kotov prihoda signala

Za razliko od metod, ki temeljijo na merjenju časa, metode na osnovi kotov prihoda signala (angl. angle-of-arrival, AoA) izkoriščajo informacijo o vpadnem kotu signala na sprejemni anteni referenčnega vozlišča. Če imamo na razpolago meritve vpadnih kotov z dveh referenčnih vozlišč, lahko z uporabo trigonometrije izračunamo lokacijo mobilnega vozlišča.

Za zaznavo vpadnega kota sprejetega signala enostavne vsesmerne radijske antene niso primerne. Zaznavanje smeri vpadnega radijskega signala se lahko izvede s pomočjo adaptivnih antenskih skupin, ki so sestavljene iz večjega števila strateško razporejenih antenskih elementov. Vsak antenski element je povezan na svoj lasten vhodni radiofrekvenčni (RF) element, ki je sposoben aktivno prilagajati fazo sprejemnega signala. Z analizo celotne skupine sprejetih signalov na posamezni adaptivni antenski skupini lahko na podlagi faznih zamikov vpadnega signala na posameznih antenah znotraj skupine izluščimo smer vpadnega signala [13].

Za visoko ločljivost izmerjenega vpadnega kota sprejetega signala so potrebni kompleksni in dragi antenski sistemi, ki so običajno neprimerni za uporabo v nizkoenergijskih senzorskih omrežjih ter aplikacijah, kjer je bistvena ekonomska učinkovitost. Uporabnost se z višanjem frekvenčnega območja delovanja zvišuje, ker se z višanjem osnovne frekvence antenski sistemi manjšajo, tehnološki napredek pa omogoča izdelavo vse bolj integriranih antenskih sistemov.

2.1.2 Metode radiofrekvenčnega odtisa

Metode radiofrekvenčnega odtisa izkoriščajo enake informacije o sprejetem radijskem signalu kot geometrijske metode. Za razliko od njih metode radiofrekvenčnega odtisa izkoriščajo zakonitost, da je vsaka točka v okolju opisana z unikatnim naborom sprejetih radijskih signalov z različnih referenčnih oddajnih vozlišč (radiofrekvenčnim odtisom) v okolju [14]. Radiofrekvenčni odtis se lahko zazna tudi v obratni smeri, ko mobilno vozlišče oddaja radijski signal, referenčna vozlišča pa ta signal sprejemajo, nato pa razmerja parametrov z vseh referenčnih vozlišč opišejo unikatni položaj mobilnega vozlišča. Za lociranje z metodami radiofrekvenčnega odtisa se običajno uporablja informacija RSS, zasledimo pa lahko tudi izvedbe, ki izkoriščajo kote sprejetih signalov [15], impulzni odziv kanala [16] ali profil močnostne zakasnitve (angl. power delay profile, PDP) [17].

Sistemi za lociranje na podlagi radiofrekvenčnega odtisa so konceptualno v večini primerov sestavljeni iz centralnega lokacijskega strežnika in korelacijske podatkovne baze radiofrekvenčnih odtisov. Lokacijski strežnik sprejema radiofrekvenčne odtise in zahteve za položaje naprav. Korelacijska podatkovna baza hrani zbirko referenčnih radiofrekvenčnih odtisov, ki so povezani z unikatnimi geografskimi položaji. Baza se zgradi tekom učne faze, kjer se na referenčnih geografskih točkah zabeleži referenčne radiofrekvenčne odtise z meritvami, na podlagi modelov razširjanja radijskega signala ali pa s kombinacijo obeh. Tekom aktivne faze lokacijski strežnik sprejema posamezne radiofrekvenčne odtise in z algoritmi za iskanje najboljšega ujemanja vzorcev v korelacijski podatkovni bazi radiofrekvenčnih odzivov išče pripadajoče položaje mobilnih vozlišč.

Če so zgrajene izključno na podlagi meritev, metode radiofrekvenčnega odtisa tekom učne faze zahtevajo visoke vložke v času in denarju za natančno kartiranje radiofrekvenčnih odzivov v vseh geografskih točkah, ki jih zajema korelacijska podatkovna baza [14]. Pristop izgradnje korelacijskih podatkovnih baz izključno na podlagi modelov razširjanja radijskega signala pa zagotavlja le omejeno točnost lokalizacije. Kombinacija obeh pristopov z zmanjšanim obsegom kalibracijskih meritev in uporabo modelov razširjanja radijskega signala torej ponuja kompromis med točnostjo in kompleksnostjo učnega postopka [18]. Za vsako spremembo v radijskem okolju, ki je lahko spremenjena lokacija referenčnega vozlišča, dodatno sidrno vozlišče ali pa sprememba v samem radijskem okolju (novo pohištvo, spremenjeni zidovi, itd.), je potrebna ponovitev učne faze. Z namenom, da bi se zmanjšala obremenitev skrbnikov sistema s stalnim umerjanjem in povečala zanesljivost in enostavnost upravljanja sistema, so nekatere raziskovalne skupine uspešno vpeljale sodelovalno zaznavanje radiofrekvenčnih odtisov [19], [20]. To med delovanjem pozicionirnega sistema glede na izmerke mobilnih vozlišč in njihovih položajev aktivno prilagaja korelacijsko podatkovno bazo radiofrekvenčnih odtisov.

2.1.3 Kooperativne metode

Običajni postopki lociranja vozlišč določajo položaj posameznih iskanih vozlišč na podlagi lokacije referenčnih sidrnih vozlišč za vsako vozlišče posebej. V določenih situacijah vsa vozlišča v omrežju nimajo na dosegu zadostnega števila referenčnih sidrnih vozlišč za lociranje po klasičnih postopkih. Kooperativne metode ali metode s sodelovanjem poleg meritev razdalje ali katere druge značilnosti povezave med vozliščem in sidriščem izkoriščajo tudi meritve (razdalja, RSS itd.) med še nelociranimi vozlišči. Položaji za vsa iskana vozlišča se nato z različnimi načini sodelovanja med vozlišči izračunajo na nivoju celotnega omrežja.

2.1.3.1 Sekvenčne metode

Sekvenčne metode predstavljajo najbolj enostaven pristop med omrežnimi sodelovalnimi metodami pozicioniranja. Vsakemu vozlišču, ki ima na dosegu zadostno število sidrnih vozlišč (najmanj tri sidrna vozlišča za dvodimenzionalno lokalizacijo), se lahko po metodi najmanjših kvadratov izračuna položaj. Vozlišče se s pridobljenim lastnim položajem spremeni v virtualno sidrno vozlišče, ki služi ostalim vozliščem z neznanim položajem v omrežju kot sidrno vozlišče. Na ta način se proces pozicioniranja širi skozi celotno omrežje in ko ni več vozlišč z neznanim položajem, vsa vozlišča služijo kot sidrna vozlišča za morebitna nova vozlišča z neznanim položajem [21].

Slabost sekvenčnih metod se kaže kot omejena uporabnost v primeru, ko so vozlišča preveč oddaljena, da bi lahko posamezna vozlišča vzpostavila povezavo z zadostnim številom sosednjih vozlišč, sidrnih vozlišč in virtualnih sidrnih vozlišč. Dodatna slabost je razširjanje napake položaja po omrežju z večanjem oddaljenosti vozlišč od sidrnih vozlišč. Vsako naslednje vozlišče, ki se mu določa položaj na podlagi virtualnih sidrnih vozlišč poleg lastne napake lokalizacijskega postopka namreč pridobi še napako položaja virtualnega sidrnega vozlišča [21].

2.1.3.2 Metode multidimenzionalnega skaliranja

Metode multidimenzionalnega skaliranja (MDS) predstavljajo skupino centraliziranih statističnih metod, ki razporejajo objekte v prostoru s poljubnim številom dimenzij, da najbolj ustrezno opišejo matriko opazovanih podobnosti med posameznimi objekti in pri tem čim bolj ohranjajo razdalje med njimi. Ta skupina metod se v splošnem uporablja za prikazo-

vanje podobnosti med elementi v podatkovnih zbirkah na podlagi matrike z medsebojnimi razdaljami elementov.

Klasične metode MDS pričakujejo popolne matrike medsebojnih razdalj, ki pa jih je treba prilagoditi glede na dejansko medsebojno povezanost v omrežju. V večjih omrežjih večina vozlišč zaradi velikih medsebojnih razdalj ni povezana z vsemi ostalimi vozlišči. Manjkajoče medsebojne razdalje lahko nadomestimo z najboljšim možnim približkom v obliki najkrajše poti med vozliščema, ki jo lahko poiščemo s standardnimi algoritmi za iskanje najkrajše razdalje po teoriji grafov. Metode so dobre tudi v primerih, ko dejanske medsebojne razdalje niso znane. Tu se lahko uporabi zgolj informacija o medsebojni povezanosti, graf ali matrika medsebojnih razdalj pa opisuje logično organizacijo omrežja. Uporabi se lahko tudi na posameznih področjih omrežja ločeno, na koncu pa se odseke omrežja poveže v celoto. Rezultat lokalizacije z metodami MDS je relativni graf, ki za postavitev v realno okolje potrebuje referenčne točke, da se prilagodijo velikost, pozicija in orientacija pridobljenega grafa omrežja.

Običajen postopek lokalizacije MDS je opisan z naslednjimi koraki:

1. **Izgradnja matrike medsebojnih razdalj:** ustvarimo matriko dimenzij $N \times N$, kjer je N število vozlišč v omrežju. V matriko vnesemo vse izmerjene medsebojne razdalje med vozlišči, manjkajoče razdalje pa izračunamo s standardnimi algoritmi za računanje najkrajše razdalje v grafih, kot so npr. Dijkstrov, Floyd-Warshall algoritem idr. [22].
2. **Algoritem MDS:** Sedaj zgradimo matriko kvadriranih medsebojnih razdalj $\mathbf{D} = \{\rho_{ij}^2\}_{i,j=1}^N$, kjer $\rho_{i,j}$ predstavlja medsebojno razdaljo med vozliščema i in j , v matrični obliki pa jo zapišemo, kot je prikazano v (2.8).

$$\mathbf{D} = \begin{bmatrix} 0 & \cdots & \rho_{1N}^2 \\ \vdots & \ddots & \vdots \\ \rho_{N1}^2 & \cdots & 0 \end{bmatrix} \quad (2.8)$$

Cilj algoritma MDS je, da poišče položaje vozlišč na način, da so medsebojne razdalje v grafu ρ_{ij} čim bolj podobne pravim razdaljam v omrežju d_{ij} . Relativne koordinate vozlišč lahko izračunamo z dvojn timercentriranjem matrike $\mathbf{D}$, kot je prikazano v (2.9)

$$\mathbf{\Lambda} = -\frac{1}{2}\mathbf{C}\mathbf{D}\mathbf{C}, \quad (2.9)$$

kjer $\mathbf{C} = \mathbf{I}_N - (1/N)\mathbf{1}_N\mathbf{1}_N^T$ predstavlja centrirni operator, $\mathbf{I}_N$ je enotska matrika dimenzij $N \times N$ in $\mathbf{1}_N$ enotski vektor dolžine N . Rešitev poiščemo po postopku razcepa lastnih vrednosti (angl. eigenvalue decomposition, EVD) matrike $\mathbf{\Lambda}$ (2.10)

$$EVD(\mathbf{\Lambda}) = \mathbf{U}_d\mathbf{\Sigma}_d\mathbf{U}_d^T, \quad (2.10)$$

kjer je $\mathbf{U}$ matrika ortonormalnih vektorjev, $\mathbf{\Sigma}$ pa matrika lastnih vrednosti [22], [23]. Relativne koordinate vozlišč lahko sedaj določimo z uporabo dveh največjih lastnih vrednosti iz $\mathbf{\Sigma}_d$ in pripadajočih lastnih vektorjev iz $\mathbf{U}_d$, kot je prikazano v (2.11).

$$\hat{\mathbf{X}} = \mathbf{U}_d\sqrt{\mathbf{\Sigma}_d} = \{\hat{x}_i, \hat{y}_i\}_{i=1}^N \quad (2.11)$$

3. **Postavitev v realno okolje:** rezultat prejšnjega koraka je relativni graf, ki za postavitev na absolutne pozicije potrebuje še ustrezno rotacijo, premik in skaliranje. Z zadostnim številom referenčnih točk lahko celoten relativni graf pretvorimo v absolutni graf, kjer položaji vozlišč na grafu sovpadajo z geografskimi lokacijami v realnem okolju znotraj natančnosti, ki jo je v dani situaciji sposoben zagotoviti algoritem MDS.

2.1.3.3 Metode širjenja zaupanja

Metode širjenja zaupanja (angl. belief propagation, BP) v lokalizaciji so kooperativne lokalizacijske metode, ki so izpeljane iz splošnejših metod statističnega sklepanja. Metode statističnega sklepanja poleg položaja zagotavljajo tudi informacijo o negotovosti podanega rezultata. Ker so računsko zelo zahtevne, se z uporabo posebnih metod izmenjave sporočil poenostavijo in prevedejo na metode širjenja zaupanja. Z vpeljavo metod BP globalno računanje zaupanja položaja posameznih vozlišč v omrežju iz centralnega sistema porazdelimo med vsa vozlišča v omrežju.

Verjetnostne metode računanja položaja upoštevajo merilne negotovosti medsebojnih razdalj med vozlišči in apriorne funkcije gostote verjetnosti (angl. probability density function, PDF) neznanih položajev vozlišč, da ocenijo aposteriorne PDF položajev nelociranih vozlišč. Za določitev neznanega položaja zadostuje iskanje povprečne vrednosti ali maksimalne aposteriorne vrednosti PDF. Ker so te metode računsko izredno zahtevne in zato neprimerne za uporabo v senzorskih vozliščih, je treba vpeljati lokalno porazdeljeno izmenjavo sporočil.

Metode BP reorganizirajo globalno računanje marginalnih zaupanj na porazdeljeno računanje na nivoju posameznih vozlišč znotraj grafa. Predstavljajo enega najboljših pristopov za porazdeljeno sklepanje v statistični fiziki, umetni inteligenci, strojnem vidu in poleg ostalih področij tudi na področju lokalizacije [24], [25].

Vsako vozlišče t izračuna zaupanje v lastno stanje x_t s produktom normalizacijske konstante k , svojega lokalnega potenciala ψ_t in s sporočili svojih sosedov Γ_t

$$M_t(x_t) = k\psi_t(x_t) \prod_{u \in \Gamma_t} m_{ut}(x_t). \quad (2.12)$$

Sporočila m_{ut} iz vozlišča u do vozlišča t se izračunajo po enačbi (2.13)

$$m_{ut}(x_t) = \int_{x_u} \psi_u(x_u) \psi_{tu}(x_t, x_u) \prod_{g \in \Gamma_u \setminus t} m_{gu}(x_u) dx_u, \quad (2.13)$$

kjer $\psi_{tu}(x_t, x_u)$ predstavlja parni potencial med vozliščema t in u . Na desni strani je zapisan produkt po vseh sporočilih, ki gredo v vozlišče u , razen sporočila, ki pride iz vozlišča t . Sporočila iz vozlišča u v vozlišče t predstavljajo prepričanje vozlišča u o položaju vozlišča t . Sporočila in prepričanja so predstavljena kot funkcije gostote verjetnosti (PDF) in ni nujno, da so normalizirana.


Kadar so prisotne nelinearnosti in visoke negotovosti s porazdelitvami, ki niso normalne, osnovni pristop BP ni več ustrezen. Z metodo neparametričnega širjenja zaupanja (NBP) [24] in pristopom z uporabo delcev (angl. particles) se z uporabo stohastičnega iskanja približkov (angl. stochastic approximation) posodabljanje zaupanja in posodabljanje sporočil izvede v dveh korakih:

1. narišemo delce na podlagi zaupanja $M_t^i(x_t)$,
2. uporabimo predhodno določene delce za določanje približkov odhodnega sporočila m_{tu}^i .

Za dodatno poenostavitev postopka in njegovo pohitritev so avtorji v [26] predlagali nadgradnjo postopka NBP z dodatkom omejitev območja, na katerem se rišejo delci, s štirikotnikom, ki ga določa presečišče kvadratov sidrskih vozlišč, kot prikazuje slika 2.3.

Algoritem NBBP vsebuje naslednje tri razširitve algoritma NBP:

1. Določimo omejitev s štirikotnikom, ki ga določa prekrivanje kvadratov, določenih z razdaljami med sidrskimi vozlišči in iskanim vozliščem. V dobljenem omejenem območju narišemo delce.



Slika 2.3: Določanje štirikotnika, ki ga omejuje presečišče kvadratov, določenih z razdaljami med sidrišči in iskanim vozliščem [26].

2. V vsaki iteraciji izločimo nove delce, ki niso znotraj omejenega območja.
3. Iskana vozlišča se locirajo iterativno, vse dokler položaj ne zadosti konvergenčnim kriterijem. Rezultat je določen s povprečno vrednostjo in pripadajočo negotovostjo. Vozlišče sedaj postane sidrno vozlišče za ostala neznana vozlišča v omrežju.

Do sedaj omenjene metode delujejo dobro, če v omrežnem grafu ni zank. Če se v omrežnih grafih pojavijo zanke, v literaturi zasledimo rešitve, ki se z različnimi pristopi iz teorije grafov lotijo reševanja problema kroženja sporočil v omrežju in s tem slabšanja rezultatov lokalizacijskih algoritmov. Algoritem GBP-K [27] razdeli omrežni graf na gručice, kar vodi v širjenje zaupanja med gručami vozlišč in s tem v splošnem boljše sklepanje o položajih vozlišč. Slabost algoritma GBP-K je, da njegova računska zahtevnost narašča eksponentno z velikostjo gruč, kar otežuje uporabo v senzorskih omrežjih z omejeno računsko močjo. Uporabnejši metodi za lokalizacijo v senzorskih omrežjih sta NGBP-JT [28] in NBP-ST [29], ki temeljita na teoriji vpetih dreves (angl. spanning tree).

2.1.4 Hibridne metode

Vsak osnovni pristop k lokalizaciji je dovzeten za različne vplive merilnih negotovosti na natančnost ocenjenega položaja mobilnega vozlišča. S povezovanjem različnih osnovnih pristopov se na različne načine zmanjšuje velikost napake pri lokalizaciji, zmanjša se spremenljivost rezultata manj zanesljivega pristopa v danem trenutku in poveča zanesljivost rezultatov tudi v primeru izpada posamezne osnovne metode. V literaturi zasledimo rešitve, ki z uporabo različnih implementacij Kalmanovega filtra združujejo položaj GPS, meritve iz inercialnih senzorjev in kinematični model mobilnega vozlišča v zanesljivo rešitev za spremljanje položaja vozlišča tudi v primeručasne izgube signala GPS. V robotiki se je izkazal za uporabnega tudi pristop sočasne lokalizacije in kartiranja (angl. simultaneous localization and mapping, SLAM). Tu mobilno vozlišče sočasno odkriva značilnosti okolja, v katerem se nahaja, in na podlagi inkrementalno grajene mape okolja tudi določa svoj položaj glede na prepoznane značilnosti iz mape okolja.

2.1.4.1 Hkratna lokalizacija in kartiranje

Problem hkratne lokalizacije in kartiranja SLAM se je pojavil in razvil na področju mobilne robotike. Agent (vozlišče z neznanim položajem) postavimo v neznano okolje na neznani položaj, agent pa potem s pomočjo metode SLAM inkrementalno gradi mapo tega okolja, hkrati pa določa svoj položaj znotraj te mape. Položaj agenta in položaj predmetov v okolju in mapa okolja samega se pri metodi SLAM ocenjujejo sprotno, sistem pa za delovanje ne potrebuje nobenega predhodnega znanja o dotičnem okolju.

Verjetnostna metoda SLAM zahteva, da se porazdelitev verjetnosti P (2.14) izračuna za vsak časovni korak k .

$$P(\mathbf{x}_k, \mathbf{m} | \mathbf{Z}_{0:k}, \mathbf{U}_{0:k}, \mathbf{x}_0) \quad (2.14)$$

V vsakem koraku k so definirane naslednje spremenljivke:

- $\mathbf{x}_k$: vektor stanja, ki opisuje položaj in orientacijo agenta,
- $\mathbf{u}_k$: krmilni signal v koraku $k - 1$, ki je agenta pripeljal v stanje $\mathbf{x}_k$ v koraku k ,
- $\mathbf{m}_i$: vektor, ki opisuje pravi položaj i -tega predmeta v okolju,
- $\mathbf{z}_{ik}$: položaj i -tega predmeta v okolju, ki je bil ocenjen na podlagi agentovega opazovanja v koraku k ,
- $\mathbf{X}_{0:k} = \mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_k = \mathbf{X}_{0:k-1}, \mathbf{x}_k$: zgodovina vseh agentovih položajev,
- $\mathbf{U}_{0:k} = \mathbf{u}_0, \mathbf{u}_1, \dots, \mathbf{u}_k = \mathbf{U}_{0:k-1}, \mathbf{u}_k$: zgodovina vseh krmilnih signalov,
- $\mathbf{m} = \mathbf{m}_0, \mathbf{m}_1, \dots, \mathbf{m}_n$: seznam vseh mejnikov (angl. landmarks) v okolju,
- $\mathbf{Z}_{0:k} = \mathbf{z}_0, \mathbf{z}_1, \dots, \mathbf{z}_k = \mathbf{Z}_{0:k-1}, \mathbf{z}_k$: seznam vseh opazovanj mejnikov (angl. landmark observations).

Algoritem SLAM lahko implementiramo v dvokoračni rekurzivni obliki s korakoma predikcije (2.15) in merilne posodobitve (2.16) (angl. prediction/measurement-update) [30].

$$P(\mathbf{x}_k, \mathbf{m} | \mathbf{Z}_{0:k-1}, \mathbf{U}_{0:k}, \mathbf{x}_0) = \int P(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{u}_k) \times P(\mathbf{x}_{k-1}, \mathbf{m} | \mathbf{Z}_{0:k-1}, \mathbf{U}_{0:k-1}, \mathbf{x}_0) d\mathbf{x}_{k-1} \quad (2.15)$$

$$P(\mathbf{x}_k, \mathbf{m} | \mathbf{Z}_{0:k}, \mathbf{U}_{0:k}, \mathbf{x}_0) = \frac{P(\mathbf{z}_k | \mathbf{x}_k, \mathbf{m}) P(\mathbf{x}_k, \mathbf{m} | \mathbf{Z}_{0:k-1}, \mathbf{U}_{0:k}, \mathbf{x}_0)}{P(\mathbf{z}_k | \mathbf{Z}_{0:k-1}, \mathbf{U}_{0:k})} \quad (2.16)$$

Najpogostejše implementacije algoritma SLAM, ki jih zasledimo v literaturi, so izpeljane z uporabo razširjenega Kalmanovega filtra in Rao-Blackwell-ovega filtra delcev [30].

Na področju telekomunikacij in brezžičnih senzorskih omrežij se metode hkratne lokalizacije in kartiranja uporabljajo predvsem za adaptivno izgradnjo map jakosti prejetega signala v metodah radiofrekvenčnega odtisa in kot razširjene metode SLAM, kjer poleg klasičnih laserskih in vizualnih senzorjev za izboljšano zaznavanje okolice uporabijo tudi jakost signala v senzorskih omrežjih.

V [31] avtorji z uporabo algoritma maksimizacije pričakovanja (angl. expectation maximization, EM) na podlagi izmerjene jakosti signala iz mobilnih naprav v okolju razvijejo algoritem za adaptivno izgradnjo map razširjanja radijskega signala. Za lokalizacijo naprav v okolju uporabijo pristop s filtrom delcev. V [32] z metodo Wi-Fi GraphSLAM združijo števec korakov in podatke iz inercialnih senzorjev z metodo radiofrekvenčnega odtisa za izboljšanje natančnosti lokalizacije v primerjavi z navadno metodo GraphSLAM. V [33] z uporabo razširjenega Kalmanovega filtra (angl. extended Kalman filter, EKF) združijo podatke o premikanju robotovih koles (angl. odometry) in z metodo najmanjših kvadratov ocenjen položaj robota v senzorskem omrežju z metodo trilateracije za izboljšanje lokalizacije robota. Avtorji v [34] predstavijo modificirano metodo GraphSLAM pod novim imenom SignalSLAM. Metoda SignalSLAM združuje podatke iz inercialnih senzorjev, jakosti signalov Wi-Fi in LTE, položaj GPS ter informacije, pridobljene iz značk NFC in

QR, v sistem za lokalizacijo in izgradnjo map z uporabo pametnih mobilnih telefonov brez stalne informacije o absolutni lokaciji uporabnika.

2.1.4.2 Metode z uporabo Kalmanovega filtra

Kalmanov filter je filter, ki minimizira razliko med pravim in ocenjenim stanjem sistema. Uporablja se predvsem v sistemih za sledenje in vodenje, prva praktična uporaba Kalmanovega filtra pa je bila v navigacijskem računalniku vesoljskega programa Apollo.

Kalmanov filter predpostavlja, da stanje sistema v trenutku $t - 1$ preide v stanje v trenutku t , stanje v trenutku t pa določi v dveh ločenih korakih, ki jih delimo na korak ocene prihodnjega stanja (angl. predict) in korak posodobitve stanja (angl. update). V prvem koraku na podlagi kinematičnega modela sistema, predhodnega stanja sistema in predhodnega krmilnega vhoda izračunamo napoved stanja sistema.

V fazi posodobitve najprej izračunamo Kalmanovo ojačenje. Kalmanovo ojačenje določa, kako močno Kalmanov filter upošteva ocenjeno stanje v primerjavi s prispevkom meritev. Kadar so magnitude merilnih kovarianc majhne, so merilne negotovosti majhne in meritve natančne, filter pa jih upošteva bolj kot (v tem primeru) manj zanesljivo napovedano stanje sistema.

Kalmanov filter zahteva, da sta kinematični model sistema in merilni model linearna. V primeru nelinearnega kinematičnega modela in nelinearnega merilnega modela vpeljemo razširjeni Kalmanov filter (angl. extended Kalman filter, EKF). Ideja razširjenega Kalmanovega filtra je v linearizaciji nelinearnih enačb systemskega in merilnega modela okrog trenutne ocenjene točke ter uporaba klasičnega Kalmanovega filtra na lineariziranem modelu.


Avtorji v [35] so uporabili razširjeni Kalmanov filter za lokalizacijo na podlagi meritev RSS na pametnem mobilnem telefonu v notranjem okolju, kjer so bila postavljena Bluetooth sidrna vozlišča s tehnologijo iBeacon. Avtor v [36] uporabi Kalmanov filter za glajenje RSS za ocenjevanje razdalje za potrebe lokalizacije. V [37] avtorji za združevanje senzor-skih podatkov (angl. sensor fusion) uporabijo dva razširjena Kalmanova filtra. Prvi filter združuje podatke iz pospeškometra in žiroskopa v informacijo o smeri hoje pešca, drugi filter pa zlija informacije iz inercialnega sistema za sledenje pešcu in lokalizacijskega sistema Wi-Fi na principu radiofrekvenčnega odtisa v položaj uporabnika. V [38] pa avtorji vpeljejo hibridno metodo lokalizacije s kombinacijo linearnega Kalmanovega filtra in Kalmanovega filtra s sigma točkami (angl. unscented Kalman filter), ki upošteva nesimetrične porazdelitve izmerkov v situacijah brez neposredne vidljivosti (NLoS) in s tem doseže boljše rezultate od optimalnih ocenjevalnikov položaja pri danih pogojih.

2.2 Pasivne metode lokalizacije

Pasivne metode lokalizacije izkoriščajo izmerjene signale in značilnosti radijskega okolja, kjer se lokalizacija izvaja. Pri svojem delovanju objekt, ki mu določamo položaj, ni opremljen z nobenim aktivnim radijskim sistemom.

2.2.1 Radijska tomografija

Radijska tomografija (RT) izkorišča koncepte, na katerih temelji rentgenska računalniška tomografija (angl. computed tomography, CT). Ta v medicini in geofiziki na podlagi meritev razširjanja signala po številnih različnih poteh v mediju omogoča izračun prikaza pogojev razširjanja in s tem prikaz strukture medija. Radijska tomografija za razliko od rentgenske računalniške tomografije namesto rentgenskih žarkov uporablja radijske signale. Ti se za



Slika 2.4: Prikaz radijske tomografije [39].

razliko od rentgenskih žarkov s krajšimi valovnimi dolžinami razširjajo tudi v pogojih brez neposredne vidljivosti in zato do sprejemnika potujejo po različnih poteh [39].

V okolju, kjer se nahajajo brezžična vozlišča, ovire na poti del radijskega signala absorbirajo, odbijejo in razpršijo. Metoda radijske tomografije določi rastrsko sliko dimenzij $n \times m$, posamezni elementi slike (voksli) pa opisujejo slabljenje radijskega signala na danem mestu v okolju. Vsi možni pari O brezžičnih senzorskih vozlišč v okolju tvorijo $K = \frac{O^2 - O}{2}$ unikatnih brezžičnih povezav. Moč sprejetega signala posamezne povezave je odvisna od:

- oddajne moči ($P_i[dB]$),
- slabljenja zaradi senčnega presihanja, ki ga povzročijo ovire na poti signala ($S_i(t)[dB]$),
- hitrega presihanja, ki ga povzročajo konstruktivne in destruktivne interference v okolju ($F_i(t)[dB]$),
- statičnega slabljenja zaradi razdalje, sevalnega diagrama antene, idr. ($L_i[dB]$),
- merilnega šuma (ν_i).

Da lahko metoda tvori sliko slabljenja signalov, se posamezna povezava na sliki dimenzij $n \times m$ opiše na različne načine. V literaturi zasledimo direktne grafične metode in metode na osnovi inverza napovedovalnega modela (angl. forward model) [40]–[42]. V primeru direktnih metod in ozkopasovnih komunikacijskih sistemov izberejo večinoma geometrijski opis povezave med dvema senzorskima vozliščema z obliko elipse [39], [43], [44]. V primeru ultra-širokopasovnih komunikacij pa se uporabi kar ravno linijo [45] zaradi odpornosti tehnologije na vplive razširjanja signala po več poteh.

V primeru direktne metode lahko slabljenje zaradi senčnega presihanja $S_i(t)$ za posamezno povezavo poenostavljeno opišemo kot vsoto slabljenja v vseh $J = n \times m$ vokslih na tomografski sliki slabljenja signala, kar opisuje enačba (2.17). Vsak vksel v danem trenutku t prispeva različno raven slabljenja $x_j(t)$, ki ga opišemo z vpeljavo lokalnih uteži w_{kj} , kjer k predstavlja oznako povezave, j pa zaporedno številko voksla na tomografski sliki.

Vokslom, ki vplivajo na slabljenje signala posamezne povezave zaradi senčnega presihanja, določimo pripadajoče uteži glede na pričakovani model kanala, ostalim pa določimo utež 0.

$$S_i(t) = \sum_{j=1}^J w_{kj} x_j(t) \quad (2.17)$$

Za meritve moči sprejetega signala med vsemi senzorskimi vozlišči lahko predpostavimo, da se zgodijo sočasno, če se okolje znotraj enega cikla meritev ne spremeni dovolj, da bi to ključno vplivalo na rezultat. V tem primeru lahko vse meritve predstavimo v matrični obliki, ki jo predstavlja enačba (2.18).

$$\begin{aligned} \mathbf{y} &= \mathbf{W}\mathbf{x} + \mathbf{n}, \\ \text{kjer so} \\ \mathbf{y} &= [y_1, y_2, \dots, y_K]^T \\ \mathbf{x} &= [x_1, x_2, \dots, x_J]^T \\ \mathbf{n} &= [n_1, n_2, \dots, n_K]^T \\ [\mathbf{W}]_{i,j} &= w_{ij} \end{aligned} \quad (2.18)$$

$\mathbf{y}$ predstavlja vektor moči sprejetih signalov, $\mathbf{x}$ je vektor vseh vokslor in s tem tomografska slika slabljenja signala, $\mathbf{n}$ predstavlja šum, $\mathbf{W}$ pa utežno matriko dimenzij $J \times K$, kjer vsak stolpec matrike predstavlja en voksel, vsaka vrstica pa vektor uteži vseh vokslor za posamezno povezavo.

Za pridobitev tomografske slike iz linearnega modela, ki ga opisuje enačba (2.18), želimo poiskati optimalno rešitev po metodi najmanjših kvadratov (2.19).

$$\mathbf{x}_{LS} = \arg \min_{\mathbf{x}} \|\mathbf{W}\mathbf{x} - \mathbf{y}\|_2^2 \quad (2.19)$$

Rešitev po metodi najmanjših kvadratov dobimo z enačbo (2.20).

$$\mathbf{x}_{LS} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{y} \quad (2.20)$$

Ta zahteva, da je utežna matrika $\mathbf{W}$ polnega ranga oziroma da matrika ni singularna. Tega v primeru radijske tomografije praktično nikoli ne dosežemo, ker se slabljenje signala v relativno velikem številu vokslor ocenjuje na podlagi majhnega števila radijskih povezav. Zelo majhne šumne vrednosti v določenih vokslor in vokslor, ki jih ne zajema nobena od radijskih povezav med senzorskimi vozlišči, vnesejo zelo majhne ali ničelne vrednosti, ki po računanju inverzne matrike dajo neskončne ali pa izredno velike vrednosti, ki ne omogočajo izračuna inverzne matrike $\mathbf{W}^{-1}$.

Za rešitev inverznega problema lahko uporabimo pristop z Moore-Penroseovim posplošenim inverzom [46] ali pa uporabimo postopek regularizacije, ki v proces reševanja linearnega sistema vpelje dodatne informacije, da lahko rešimo sicer nerešljiv sistem linearnih enačb. V literaturi zasledimo različne pristope k regularizaciji in računanju inverznega problema. Zasledimo lahko rešitve z metodo regulariziranih najmanjših kvadratov in eksponentnega prostorskega razpada (angl. exponential spatial decay) [43], [44], [47], [48], Tikhonove regularizacije [39], regularizacije elastične mreže (angl. elastic net regularization) [45] in algebrajske rekonstrukcijske tehnike (angl. algebraic reconstruction technique, ART) [40].

Poglavje 3

Lokalizacija UWB in njene omejitve

Ultra-širokopasovna (angl. ultra-wideband, UWB) radijska tehnologija omogoča nizkoenergijske komunikacije v širokem frekvenčnem spektru z zelo kratkimi in šibkimi pulzi. Tehnologijo smatramo kot ultra-širokopasovno, če za komunikacijo uporablja pasovno širino, večjo od 500 MHz, ali pa pasovno širino, ki predstavlja vsaj 20 % centralne frekvence f_c [49], [50].

Sistemi UWB za komunikacijo uporabljajo izredno kratke pulze z dolžinami okrog 1 ns, za komunikacijo pa zaradi delovanja neposredno v osnovnem pasu ne potrebujejo medfrekvenčnega procesiranja (angl. intermediate frequency, IF).

Tipična dostopovna točka Wi-Fi po standardu IEEE 802.11a dosega 1 W oddajne moči in pri pasovni širini $B = 20$ MHz dosega spektralno gostoto moči (angl. power spectral density, PSD) 17 dBm/MHz. Sistemi UWB so omejeni na bistveno nižjo spektralno gostoto moči $PSD < -41.3$ dBm/MHz ali 74 pW/MHz. Kombinacija velike pasovne širine in nizke oddajne moči potisne sisteme UWB v območje šuma standardnih ozkopasovnih tehnologij in jim s tem omogoča sobivanje v istem frekvenčnem pasu.


Standard IEEE 802.15.4 [10], ki pokriva brezžična osebna omrežja z nizkimi hitrostmi prenosa podatkov (angl. low-rate wireless personal area networks, LR-WPAN), poleg ozkopasovnih komunikacij definira tudi ultra-širokopasovne komunikacije v treh frekvenčnih pasovih:

- 249,6 MHz - 749,6 MHz,
- 3,1 GHz - 4,8 GHz in
- 6,0 GHz - 10,6 GHz.

Izredno majhna dolžina pulzov, ki jih ultra-širokopasovni sistemi uporabljajo za komunikacijo, omogoča visoko časovno ločljivost sistema. Pulz dolžine 1 ns v prostoru zasede 30 cm, v frekvenčnem prostoru pa 1 GHz. Majhna dolžina, ki jo v prostoru zasede posamezen pulz, zagotavlja, da se odboji v prostoru ne prekrivajo in s tem ne povzročajo presihanja zaradi razširjanja po več poteh, ki je prisotno pri ozkopasovnih komunikacijskih sistemih, prva fronta signala pa je ravno tako ločena od signalnih komponent, ki jih določajo odboji [51]. Visoka časovna ločljivost omogoča merjenje razdalje med posameznimi vozlišči z natančnostjo v območju nekaj centimetrov. To postavlja sisteme UWB med tehnologije, ki omogočajo natančno določanje položaja in navigacije v notranjih okoljih.

3.1 Definicija UWB po standardu IEEE 802.15.4-2011

Standard IEEE 802.15.4 poleg ozkopasovnih komunikacij za brezžična osebna omrežja z nizkimi hitrostmi prenosa podatkov definira tudi ultra-širokopasovne komunikacije na osnovi pasovno omejenih pulzov. Standard UWB obsega 16 komunikacijskih kanalov, na vsakem



Slika 3.1: Struktura komunikacijskega bloka IEEE 802.15.4-2011 UWB [52].

od kanalov pa sta na razpolago vsaj dva kompleksna kanala. Kompleksni kanal je v standardu definiran kot kombinacija kanala in kode sinhronizacijske sekvence (angl. preamble) [10]. Različne kode sinhronizacijske sekvence omogočajo souporabo istega komunikacijskega kanala, kar se v komunikacijah označuje kot kodno deljeni dostop (angl. code division multiple access, CDMA).

Osnovna in tudi maksimalna dovoljena frekvenca generiranja pulzov je določena kot 499,2 MHz. Oddajnik UWB, ki je združljiv s standardom IEEE 802.15.4-2011, vsebuje pulzni generator z osnovno frekvenco generiranja pulzov 499,2 MHz.

3.1.1 Komunikacijski blok UWB

Komunikacije UWB po standardu IEEE 802.15.4-2011 temeljijo na izmenjavi komunikacijskih blokov. Komunikacijski blok UWB je sestavljen iz štirih podblokov. Sinhronizacijska glava ali preambula (angl. synchronization header, SHR) pomaga sprejemniku nastaviti ojačenje vhodnega signala, določiti začetek podatkovnega bloka, oceniti komunikacijski kanal in natančno določiti prvo fronto sprejetega signala za natančno merjenje razdalje in lokalizacijo. Sinhronizacijska glava je sestavljena iz sinhronizacijske sekvence (SYNC) in začetnega razmejevalnika bloka (angl. start of frame delimiter, SFD). Naslednja komponenta komunikacijskega bloka je glava podatkovnega bloka (angl. PHY header, PHR), ki nosi podatke o nastavitvah komunikacijskega vmesnika za prenos podatkov, kot so bitna hitrost (angl. bit rate, BR), dolžina podatkovnega bloka in dolžina sinhronizacijske sekvence v sinhronizacijski glavi. Zadnja komponenta komunikacijskega bloka je podatkovni blok, ki nosi koristno informacijo bloka. Zgradba komunikacijskega bloka je prikazana na sliki 3.1.

3.1.1.1 Sinhronizacijska sekvenca - SYNC

Sinhronizacijska sekvenca je sestavljena iz zaporedja sinhronizacijskih simbolov. Standard IEEE 802.15.4-2011 predpisuje uporabo štirih različnih dolžin sinhronizacijske sekvence: 16, 64, 1024 in 4096 simbolov.

Simboli v sinhronizacijski glavi so sestavljeni iz zaporedja pulzov, ki je določeno s kodo sinhronizacijske sekvence C_i (angl. preamble code). Standard UWB podpira dve različni dolžini kod preambule, in sicer kode z dolžino 31 in kode z dolžino 127. Vsaka koda C_i je sestavljena iz sekvence pulzov iz nabora $\{-1, 0, 1\}$ z lastnostmi perfektne periodične avtokorelacije. To sprejemniku omogoča določanje impulznega odziva komunikacijskega kanala med oddajnikom in sprejemnikom [10]. Standard določa 8 kod sinhronizacijske sekvence dolžine 31 in 16 kod sinhronizacijske sekvence dolžine 127.

Simboli so določeni kot ena celotna ponovitev izbrane kode sinhronizacijske sekvence z vstavljanjem $\delta_L - 1$ ničelnih pulzov za vsakim oddanim pulzom kode sinhronizacijske sekvence C_i . Z različno dolgimi δ_L in dolžinami kod sinhronizacijske sekvence dosežemo

Tabela 3.1: Parametri simbolov sinhronizacijske sekvence.

δ_L	Dolžina kode C_i	PRF_{maks} [MHz]	$\overline{PRF}$ [MHz]	Dolžina simbola (N_c)	T_{sim} [ns]
4	127	124,80	62,89	508	1017,63
16	31	31,20	16,10	496	993,59
64	31	7,80	4,03	1984	3974,36

različne ciljne frekvence ponavljanja pulzov (angl. pulse repetition frequency, PRF). Tabela 3.1 prikazuje vse podprte PRF, dolžine kod sinhronizacijske sekvence C_i , število pulzov v simbolu in trajanje simbolov T_{sim} .

3.1.1.2 Začetni razmejevalnik bloka - SFD

Začetni razmejevalnik bloka (SFD) loči sinhronizacijsko sekvenco od glave podatkovnega bloka (PHR). Zelo natančno nakazuje prehod na modulacijo BPM/BPSK v glavi podatkovnega bloka in podatkovnem bloku. To omogoča natančno in deterministično določanje časovnega žiga prve fronte sprejetega signala za potrebe natančnega merjenja razdalj in lokalizacijo.

Standard določa 64 simbolov dolgo sekvenco SFD za bitno hitrost 110 kb/s in 8 simbolov dolgo sekvenco za bitne hitrosti 850 kb/s, 6,81 Mb/s in 27,24 Mb/s. S sekvenco SFD je določeno zaporedje oddajanja simbolov sinhronizacijske sekvence, ki so določeni z izbrano kodo sinhronizacijske sekvence C_i . Posamezni elementi v sekvenci SFD določajo, če se simbol odda, če se odda inverzno ali če se ne odda.

- Sekvenca SFD 8: {0, +1, 0, -1, +1, 0, 0, -1}
- Sekvenca SFD 64: {0, +1, 0, -1, +1, 0, 0, -1, 0, +1, 0, -1, +1, 0, 0, -1, -1, 0, 0, +1, 0, -1, 0, +1, 0, +1, 0, 0, 0, -1, 0, -1, 0, -1, 0, 0, +1, 0, -1, -1, 0, -1, +1, 0, 0, 0, 0, +1, +1, 0, 0, -1, -1, -1, +1, -1, +1, +1, 0, 0, 0, 0, +1, +1}

3.1.1.3 Glava podatkovnega bloka - PHR

Glavo podatkovnega bloka sestavlja 19 bitov, ki so potrebni za uspešno dekodiranje podatkov v podatkovnem bloku.

Polje DR določa bitno hitrost, s katero se prenaša podatkovni blok, možne vrednosti pa so zapisane v tabeli 3.2.

Dolžina podatkovnega bloka (angl. frame length) je v glavi podatkovnega bloka opisana s 7-bitno nepredznačeno celoštevilčno vrednostjo, predstavlja pa število bitnih oktetov (B) v podatkovnem bloku.

Bit RNG v glavi podatkovnega bloka označuje, če je paket namenjen merjenju razdalje (angl. ranging) in je v tem primeru označen z 1, bit EXT pa je namenjen morebitnim razširitvam glave podatkovnega bloka v prihodnosti in je privzeto nastavljen na vrednost 0.

Biti $P1$ in $P0$ določata dolžino sinhronizacijske sekvence (SYNC), možne nastavitve pa prikazuje tabela (3.3).

Na koncu glave podatkovnega bloka je 6-bitna koda SECDEC (angl. single error correct, double error detect), ki služi za zaščito pred napakami v prenosu glave podatkovnega bloka zaradi šuma in napak v komunikacijskem kanalu. Biti SECDEC predstavljajo Hammingovo bločno kodo, ki je zmožna popraviti enkratno napako in detektirati dvojno napako pri prenosu glave podatkovnega bloka.

Glava podatkovnega bloka se za bitne hitrosti 850 kb/s, 6,8 Mb/s in 27 Mb/s oddaja z 850 kb/s brez Reed-Solomonovega kodiranja s kodirnim faktorjem 0,87, kar rezultira

Tabela 3.2: Tabela bitnih hitrosti v glavi podatkovnega bloka.

R1-R0	15,60 MHz in 62,40 MHz PRF	3,90 MHz PRF
00	0,11	0,11
01	0,85	0,85
10	6,81	1,70
11	27,24	6,81

Tabela 3.3: Nastavitve dolžine sinhronizacijske sekvence (SYNC).

P1-P0	SYNC dolžina (število simbolov)
00	16
01	64
10	1024
11	4096

v dejansko bitno hitrost 977 kb/s. Za bitno hitrost 110 kb/s se glava podatkovnega bloka oddaja z nominalno bitno hitrostjo 110 kb/s ravno tako brez Reed-Solomonovega kodiranja, kar se kaže v dejanski oddajni hitrosti 126,44 kb/s [52].


3.1.1.4 Podatkovni blok

Podatkovni blok nosi koristno informacijo komunikacijskega bloka UWB. Za povečanje zanesljivosti pravilnega prenosa podatkov je uporabljena tehnika vnaprejšnjega popravljanja napak (angl. forward error correction, FEC) s kombinacijo sistematičnega konvolucijskega kodiranja in sistematičnega Reed-Solomonovega bločnega kodiranja. Blok shema celotne verige kodiranja in modulacije podatkovnega bloka je prikazana na sliki 3.3.


Reed-Solomonov kodirnik zakodira vhodni blok M bitov v izhodni blok z dodatnimi 48 paritetnimi biti ($M + 48$). Če izbrani komunikacijski parametri iz tabele 3.4 določajo Viterbijevo kodno razmerje 0,5, sistematični konvolucijski kodirnik s polovičnim kodnim razmerjem zakodira po Reed-Solomonovem algoritmu predhodno zakodirani blok v sistematično zakodirani izhodni blok z dolžino $2M + 96$ bitov. Izhodni sistematični biti sistematičnega konvolucijskega kodirnika se uporabijo za določanje pozicije izbruha znotraj simbola, paritetni biti na izhodu sistematičnega konvolucijskega kodirnika pa za določanje polaritete izbruha znotraj simbola. Če izbrani komunikacijski parametri določajo Viterbijevo kodno razmerje 1, pozicijo izbruha znotraj simbola določajo sodi biti na izhodu Reed-Solomonovega kodirnika, polariteto pa lihi biti na izhodu Reed-Solomonovega kodirnika, kar grafično prikazuje slika 3.4.

Bit 0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
R1	R0	L6	L5	L4	L3	L2	L1	L0	RNG	EXT	P1	P0	C5	C4	C3	C2	C1	C0
DR		Dolžina podatkovnega bloka							Merjenje razdalje	Razširitev glave	Dolžina sekvence SYNC		Koda SECDEC					

Slika 3.2: Struktura glave podatkovnega bloka (PHR) [10].



Slika 3.3: Prikaz celotne verige kodiranja in modulacije podatkovnega bloka [10].



Slika 3.4: Prikaz kodiranja podatkovnega bloka [10].

3.1.1.5 Modulacija BPM/BPSK - struktura podatkovnega simbola

Podatkovni simbol UWB nosi dva bita informacije: en bit je določen s pozicijo izbruha pulzov, drugi bit pa je določen z njegovo polariteto.

Dolžino simbola $T_{dsym} = N_{cps}T_c$ določa število možnih pozicij pulzov N_{cps} z dolžino posameznega pulza T_c . Vsak simbol je razdeljen na dva enakovredna intervala $T_{BPM} = T_{dsym}/2$, ki omogočata modulacijo z določanjem pozicije pulznih izbruhov (angl. burst position modulation, BPM). Vsak podatkovni bit gre skozi konvolucijski kodirnik, ki generira paritetni bit za določanje faze (polaritete) posameznega izbruha pulzov, kar določa binarno fazno modulacijo (angl. binary phase-shift keying, BPSK). Modulacija BPM/BPSK je grafično prikazana na sliki 3.5.


Izbruh pulzov je sestavljen iz zaporedja N_{cpb} zaporednih pulzov z dolžino $T_{burst} = N_{cpb}T_c$. Pozicija izbruha pulzov v prvi ali drugi polovici simbola določa prvi bit informacije, njegova faza (-1 ali +1) pa določa drugi bit. Vsak interval T_{BPM} je nadalje razdeljen še na dve polovici, kjer je prva polovica namenjena oddajanju, druga polovica pa predstavlja zaščitni interval (angl. guard interval), ki zmanjšuje nivo lastne interference znotraj enega simbola zaradi razširjanja radijskega signala po več poteh. Struktura podatkovnega simbola je predstavljena na sliki 3.6.

Bitno hitrost določamo s številom pulzov na posamezen izbruh N_{cpb} in s tem s številom pulzov na simbol N_{cps} , pri čemer pa ostaja število pozicij izbruhov znotraj simbola N_{burst} konstantno. Možne konfiguracije podatkovnega simbola so prikazane v tabeli 3.4.


Podatki se pred pošiljanjem in pretvarjanjem v simbole kodirajo s kombinacijo konvolucijskega in Reed-Solomonovega kodiranja [10].

Število izbruhov na simbol N_{burst} je število možnih pozicij izbruha znotraj simbola in je konstantno za izbrano povprečno frekvenco oddajanja pulzov PRF. $N_{hop} = N_{burst}/4$ je dejansko število možnih pozicij izbruha pulzov, če upoštevamo, da je simbol sestavljen iz dveh BPM intervalov in polovico vsakega BPM intervala zavzema zaščitni interval.

Število pulzov na izbruh N_{cpb} predstavlja število oddanih pulzov T_c znotraj časa enega izbruha T_{burst} . Vsak izbruh je sestavljen iz več zaporednih pulzov, število pulzov na izbruh N_{cpb} pa posledično določa končno bitno hitrost. Za nižje bitne hitrosti vsak izbruh vsebuje več pulzov, dolžina izbruha pa je določena s številom pulzov in njihovo dolžino $T_c = 1/499.2 \text{ MHz} \approx 2,003205 \text{ ns}$ kot $T_{burst} = N_{cpb}T_c$. Dolžina posameznega simbola se izračuna kot $T_{dsym} = N_{burst}T_{burst}$.



Slika 3.5: Grafični prikaz BPM/BPSK modulacije [52].



Slika 3.6: Zgradba podatkovnega simbola [10].

Bitno hitrost določimo s kodnim razmerjem FEC in trajanjem posameznega simbola, kar prikazuje enačba (3.1).

$$BR = \frac{2FEC}{T_{dsym}} \quad (3.1)$$

3.2 Razširjanje signala UWB

Radijski kanal predstavlja vplive okolja, vplive oddajnika in sprejemnika ter vplive motenj sosednjih radijskih virov na radijski signal. Pred vsakim načrtovanjem komunikacijskih sistemov moramo najprej dobro definirati model kanala in proučiti pogoje razširjanja radijskega signala. Če je komunikacijski kanal ustrezno opisan za želen namen uporabe komunikacijskega sistema, lahko modelirane omejitve pri razširjanju signala ustrezno upoštevamo pri načrtovanju oddajnikov in sprejemnikov in s tem zagotovimo najboljšo možno učinkovitost komunikacijskega sistema pri danih pogojih.

Pomemben vidik vsakega modeliranja kanala je analiza porazdelitvenih funkcij posameznih parametrov kanala. Porazdelitve parametrov pridobimo največkrat z meritvami v reprezentativnih okoljih ali pa s simulacijami v dobro definiranih simulacijskih okoljih, ki dosledno opisujejo reprezentativna okolja. Pridobljeni modeli kanala običajno niso zmožni podati fizikalnega ozadja lastnosti kanala, ampak prikazujejo zgolj vpogled v statistično obnašanje kanala. Analitični modeli so zato zaradi kompleksnosti statističnih funkcij parametrov kanala, značilnosti razširjanja radijskega signala in geometrije posameznih okolij

Tabela 3.4: Podprti parametri podatkovnih PHY simbolov.

PRF [MHz]	Modulacija in kodiranje			Struktura podatkovnega simbola					Podatkovna hitrost		
	Viterbi kodno raz- merje	RS kodno raz- merje	FEC kodno raz- merje	N_{burst}	N_{hop}	N_{cpb}	N_{cps}	T_{burst} [ns]	T_{dsym} [ns]	SR [MHz]	BR [Mb/s]
3,9	0,5	0,87	0,44	128	32	32	4096	64,10	8205,13	0,12	0,11
3,9	0,5	0,87	0,44	128	32	4	512	8,01	1025,64	0,98	0,85
3,9	0,5	0,87	0,44	128	32	2	256	4,01	512,82	1,95	1,70
3,9	1	0,87	0,87	128	32	1	128	2,00	256,41	3,90	6,81
15,60	0,5	0,87	0,44	32	8	128	4096	256,41	8205,13	0,12	0,11
15,60	0,5	0,87	0,44	32	8	16	512	32,05	1025,64	0,98	0,85
15,60	0,5	0,87	0,44	32	8	2	64	4,01	128,21	7,80	6,81
15,60	1	0,87	0,87	32	8	1	32	2,00	64,10	15,60	27,24
62,40	0,5	0,87	0,44	8	2	512	4096	1025,64	8205,13	0,12	0,11
62,40	0,5	0,87	0,44	8	2	64	512	128,21	1025,64	0,98	0,85
62,40	0,5	0,87	0,44	8	2	8	64	16,03	128,21	7,80	6,81
62,40	0,5	0,87	0,44	8	2	2	16	4,01	32,05	31,20	27,24

zelo redki.

Glavne razlike med tradicionalnimi ozkopasovnimi pristopi k modeliranju kanalov in modeliranju kanalov UWB so v tem, da pri modeliranju UWB zaradi izredno velike pasovne širine ne moremo zanemariti s frekvenco pogojenih lastnosti razširjanja radijskega signala. Frekvenčno odvisni parametri se nanašajo na odboje, uklon, lom, izgubo poti, razširjanje v materialih in ostale pojave pri razširjanju elektromagnetnega valovanja.

Slabljenje moči radijskega signala, ki nastane tekom razširjanja med oddajnikom in sprejemnikom, imenujemo izguba poti. K celotnemu modelu izgube poti svoj delež prispevajo pojavi, ki nastanejo med razširjanjem signala v prostoru in z interakcijo signala s prostorom (predvsem ovirami). Pojavi, ki vplivajo na model izgube poti so slabljenje praznega prostora (angl. free space loss), lom, odboj, uklon, motnje mirujočega ozadja (angl. wave clutter) in absorpcija [53].

3.2.1 Slabljenje praznega prostora

Radijski signal se od antene normalno razširja v treh dimenzijah v vse smeri. Izguba energije, ki jo zaznamo, ko valovna fronta potuje od antene v prostor, nastane zaradi večanja površine valovne fronte z večanjem razdalje. Zmanjševanje moči signala zaradi večanja površine valovne fronte imenujemo slabljenje praznega prostora. Pri idealni vsesmerni anteni valovno fronto opisuje plašč krogle, povprečno moč sprejetega signala v praznem prostoru pa določa enačba (3.2),

$$P_{RX} = P_{TX} \left(\frac{\lambda}{4\pi d} \right)^2 \quad (3.2)$$

kjer je λ valovna dolžina radijskega signala, P_{TX} je oddajna moč, P_{RX} je sprejemna moč, d pa je razdalja med oddajno in sprejemno anteno.

3.2.2 Lom

Lom definiramo kot spremembo smeri valovne fronte, ko prečka mejo dveh medijev z različnimi lastnostmi razširjanja signala. Lomni kot med dvema različnima materialoma z različnima lomnima količnikoma dokaj natančno opisuje lomni zakon (Snellov zakon), ki ga prikazuje enačba (3.3), kjer je n_1 lomni količnik prvega medija, θ_1 vpadni kot na prehodu v drugi medij glede na normalo, n_2 lomni količnik drugega medija in θ_2 kot glede na normalo v drugem mediju po prehodu iz prvega medija.

$$n_1 \sin \theta_1 = n_2 \sin \theta_2 \quad (3.3)$$

3.2.3 Odboj

Odboj je pojav, ko valovna fronta na prehodu med dvema medijema z različnima lomnima količnikoma spremeni smer razširjanja do te mere, da se vrne nazaj v primarni medij. Odboj je lahko glede na naravo spoja med medijema zrcalen ali pa razpršen (ne ohranja prvotne slike, ampak samo energijo).

3.2.4 Uklon

Uklon se pojavi, ko valovanje potuje skozi ozko vrzel ali pa ko valovanje naleti na rob predmeta na svoji poti. Smer valovanja se na robovih predmetov namreč ukrivi ali bolje rečeno ukloni. Pojav uklona postaja močnejši z večanjem valovne dolžine valovanja.

3.2.5 Motnje mirujočega ozadja

Motnje mirujočega ozadja (angl. wave clutter) imenujemo neurejeno razširjanje signala ob grobi površini ali prehodu med materiali. Grobost površine za določen signal je odvisna od valovne dolžine in močno vpliva na spektralne komponente impulznega odziva kanala.

3.2.6 Absorbcija

Absorbcija predstavlja pojav, ko se del energije, ki jo nosi valovanje, pretvori v drugo obliko (običajno toplotno). Nastopa kot prispevek k celotnemu slabljenju signala. Pretvarjanje energije se dogaja na molekularnem in atomskem nivoju z interakcijo energije in medija, v katerem se valovanje razširja.

3.3 Modeliranje kanala UWB

Da lahko primerjamo pogoje razširjanja v posameznih reprezentativnih notranjih okoljih, potrebujemo orodja, s katerimi zgradimo modele kanala, ki z majhnim naborom številčnih vrednosti opišejo posamezne značilnosti razširjanja radijskega signala. Pomemben faktor pri načrtovanju komunikacijskih sistemov je padanje moči sprejetega radijskega signala (RSS) z večanjem razdalje. To opišemo z modelom izgube poti, kjer eksponent izgube poti opisuje, kako hitro se moč sprejetega signala zmanjšuje v odvisnosti od razdalje. Na vrednosti RSS vplivata tudi pojava počasnega in hitrega presihanja, ki sta posledica večjih ovir na poti radijskega signala in manjših kratkotrajnih sprememb v radijskem okolju.

Prednost sistemov UWB pred ozkopasovnimi sistemi je v njihovi visoki časovni ločljivosti, ki omogoča analizo razširjanja signala na podlagi impulznega odziva kanala (CIR). Z analizo CIR lahko ocenimo, na kakšen način je signal prispel do sprejemnika. Model Saleh-Valenzuela z naborom parametrov opisuje obliko CIR in s tem omogoča kompaktno predstavitev pogojev razširjanja v primerih z neposredno vidljivostjo, kjer je prva komponenta poti najmočnejša. V pogojih NLoS, kjer je prva komponenta poti šibkejša, obliko profila močnostne zakasnitve opišemo z logaritemsko-linearno porazdelitvijo.

3.3.1 Model izgube poti

Izguba poti (angl. path loss, PL) opisuje razmerje med močjo sprejetega signala P_{RX} in oddajno močjo P_{TX} (3.4). V enačbi (3.4) d predstavlja razdaljo med oddajnikom in sprejemnikom, f_c centralno frekvenco oddajnega signala, $E\{\}$ pa je matematično upanje, ki je pridobljeno na dovolj velikem območju, da uspe povprečiti efekte počasnega in hitrega presihanja [54]. Izguba poti narašča z naraščajočo razdaljo, ker se z večanjem razdalje

veča površina fronte signala in se energija oddanega valovanja zmanjšuje. Običajno jakost signala in izgubo poti zapisujemo v logaritemski obliki v decibelih ($PL_{dB} = 10 \log(PL)$).

$$PL(d) = \frac{E\{P_{RX}(d, f_c)\}}{P_{TX}} \quad (3.4)$$

Največja razdalja med oddajnikom in sprejemnikom, na kateri sistem še deluje zadovoljivo, je določena z izgubo poti, oddajno močjo in občutljivostjo sprejemnika. Poleg povprečne vrednosti izgube poti pa moramo za zadovoljivo delovanje sistema upoštevati še mejni pribitek (angl. safety margin), ki zajema predvidene efekte presihanja. Za sisteme UWB je običajno mejni pribitek ali pribitek za presihanje (angl. fading margin) majhen, ker zaradi velikega števila razrešljivih komponent poti in s tem njihove velike raznolikosti močno zmanjšamo vplive presihanja.

Model izgube poti v odvisnosti od razdalje med sprejemnikom in oddajnikom $PL(d)$ lahko zapišemo kot (3.5), kjer d_0 predstavlja referenčno razdaljo (na primer 1 m), PL_0 je izguba moči na referenčni razdalji, n pa je eksponent izgube moči pri razširjanju signala (angl. propagation path loss exponent).

$$PL(d) = PL_0 + 10n \log_{10}\left(\frac{d}{d_0}\right) \quad (3.5)$$

Izguba poti v frekvenčnem območju, ki ga pokriva standard IEEE 802.15.4-2011 UWB, izkazuje tudi frekvenčno odvisnost zaradi frekvenčne odvisnosti posameznih parametrov razširjanja radijskega signala. Frekvenčno odvisen model izgube poti podaja enačba (3.6),

$$PL(f, d) = E\left\{\int_{f-\Delta f/2}^{f+\Delta f/2} |H(\tilde{f}, d)|^2 d\tilde{f}\right\} \quad (3.6)$$

kjer je $|H(f, d)|$ prenosna funkcija med priključkoma sprejemne in oddajne antene, izbrana širina frekvenčnega pasu Δf pa je dovolj majhna, da so koeficient uklona, dielektrične konstante in ostali parametri znotraj pasu konstantni. Celotno frekvenčno odvisno izgubo poti dobimo z integriranjem po celotnem frekvenčnem pasu, ki ga uporabljamo za komunikacijo. Frekvenčno odvisnost izgube poti lahko zapišemo v obliki, ki jo prikazuje enačba (3.7),

$$PL(f) \propto f^{-2\kappa} \quad (3.7)$$

kjer κ tipično leži v območju med 0,5 do 1,5. $\kappa = 1$ predstavlja klasično izgubo poti praznega prostora, večje vrednosti pa lahko razložimo z dejstvom, da izgube zaradi uklona naraščajo z naraščanjem frekvence [55]. Avtorji v [56] so na podlagi meritev ugotovili, da so izgube zaradi senčenja praktično neodvisne od frekvence.

Za poenostavitev izračuna lahko predpostavimo, da lahko izgubo poti kot funkcijo razdalje in frekvence zapišemo kot produkt obeh odvisnosti (3.8).

$$PL(f, d) = PL(f)PL(d) \quad (3.8)$$

3.3.2 Počasno presihanje

Kljub visoki časovni ločljivosti sistemov UWB obstaja verjetnost, da v isto časovno enoto pade več komponent poti. To pomeni, da presihanje tudi v sistemih UWB ni zanemarljiv pojav. Razlika z ozkopasovnimi sistemi se kaže samo v številu komponent poti, ki padejo v posamezno časovno enoto. Zasledimo lahko uporabo različnih statističnih porazdelitev amplitud, kot so Rayleighjeva porazdelitev, Nakagamijeva porazdelitev za amplitude z velikimi zakasnitvami [57], Riceova porazdelitev za amplitude z majhnimi zakasnitvami v pogojih LoS [58] in logaritemsko normalna porazdelitev [59].

Počasno presihanje (angl. large-scale fading) ali tudi senčno presihanje (angl. shadowing) se izkazuje kot variacija moči posameznih komponent poti, ko se sprejemnik ali oddajnik premikata na razdaljah, ki so večje od 10 valovnih dolžin (10λ). Slednje je definirano kot tipično območje za povprečenje hitrega presihanja [55]. Počasno presihanje nastaja zaradi senčenja posameznih komponent poti na ovirah in se po tem loči od hitrega presihanja, ki je pogojeno z interakcijami med posameznimi komponentami poti. Počasno presihanje se kaže kot naključno spreminjanje moči sprejetega signala s povprečenjem za hitro presihanje na območjih z enakimi razdaljami med oddajnikom in sprejemnikom in s tem z enakim ojačenjem poti. Za ozkopasovne sisteme in sisteme UWB je bilo z meritvami ugotovljeno, da je logaritemsko normalna porazdelitev (angl. lognormal distribution) dober približek funkcije gostote verjetnosti moči sprejetega signala.

3.3.3 Model hitrega presihanja

Amplitude hitrega presihanja so porazdeljene po Nakagamijevi porazdelitvi [54], ki jo prikazuje enačba (3.9), kjer je Nakagamijev faktor $m \geq 0,5$, $\Gamma(m)$ je funkcija gama, Ω pa je povprečna kvadratna vrednost (angl. mean-square value) amplitude.

$$pdf(x) = \frac{2}{\Gamma(m)} \left(\frac{m}{\Omega}\right)^m x^{2m-1} \exp\left(-\frac{m}{\Omega}x^2\right) \quad (3.9)$$

Možna je tudi približna transformacija Nakagamijeve distribucije v Riceovo distribucijo z enačbama (3.10) in (3.11), kjer je K_r Riceov faktor, m pa Nakagamijev faktor.

$$m = \frac{(K_r + 1)^2}{2K_r + 1} \quad (3.10)$$

$$K_r = \frac{\sqrt{m^2 - m}}{m - \sqrt{m^2 - m}} \quad (3.11)$$

Ω predstavlja povprečno moč, parameter m je logaritemsko-normalno porazdeljena spremenljivka, njena povprečna vrednost je μ_m in standardni odklon σ_m , obe vrednosti pa sta lahko odvisni od zakasnitve.

$$\mu_m(\tau) = m_0 - k_m\tau \quad (3.12)$$

$$\sigma_m(\tau) = \hat{m}_0 - \hat{k}_m\tau \quad (3.13)$$

Za prvo komponento vsake gruče Nakagamijev faktor m modeliramo drugače kot za ostale komponente. Za prvo komponento se predpostavlja, da je faktor m determinističen in ni odvisen od časovnega zamika.

$$m = \tilde{m}_0 \quad (3.14)$$

3.3.4 Model Saleh-Valenzuela

Model Saleh-Valenzuela (SV) z enačbo (3.15) določa impulzni odziv kanala. V enačbi $a_{k,l}$ določa utež časovne enote (angl. tap) k -te komponente poti v l -ti gruči, T_l je zakasnitev l -te gruče, $\tau_{k,l}$ pa je zakasnitev k -te komponente poti relativno na čas prispetja l -te gruče T_l . Fazni koti komponent poti $\phi_{k,l}$ so enakomerno porazdeljeni na intervalu $[0, 2\pi]$.

$$h(t) = \sum_{l=0}^L \sum_{k=0}^K a_{k,l} \exp(j\phi_{k,l}) \delta(t - T_l - \tau_{k,l}) \quad (3.15)$$

Pomemben parameter modela, ki določa porazdelitev gruč znotraj impulznega odziva kanala, je število gruč L . Avtorji v [54] ga opisujejo s Poissonovo porazdelitvijo, ki jo prikazuje enačba (3.16).

$$pdf_L(L) = \frac{\bar{L}^L \exp(-\bar{L})}{L!} \quad (3.16)$$

Porazdelitev časov prispetij gruč (angl. cluster arrival times) opisuje Poissonov proces v enačbi (3.17), v kateri Λ_l predstavlja hitrost prihajanja gruč (angl. cluster arrival rate), ki je po definiciji neodvisna od zaporedne številke gruče l .

$$p(T_l|T_{l-1}) = \Lambda_l \exp[-\Lambda_l(T_l - T_{l-1})], l > 0 \quad (3.17)$$

Standardni model SV tudi za model časov prihodov komponent poti predpostavlja Poissonov proces. Avtorji v [54] so zaradi neskladja merilnih podatkov in predpostavljenih modelov za notranje bivalne prostore ter za notranja in zunanja pisarniška okolja predlagali model za opis časov prispetja komponent poti z mešanico dveh Poissonovih procesov, kar prikazuje enačba (3.18),

$$p(\tau_{k,l}|\tau_{(k-l),l}) = \beta\lambda_1 \exp[-\lambda_1(\tau_{k,l} - \tau_{(k-1),l})] + (\beta - 1)\lambda_2 \exp[-\lambda_2(\tau_{k,l} - \tau_{(k-l),l})], k > 0 \quad (3.18)$$

kjer je β mešana verjetnost (angl. mixture probability), λ_1 in λ_2 pa predstavljata hitrosti prihajanja komponent poti (angl. ray arrival rates).

Profil močnostne zakasnitve signala (angl. power delay profile, PDP) znotraj posamezne gruče opisuje eksponentna funkcija (3.19), kjer Ω_l predstavlja integral energije znotraj l -te gruče, γ_l pa je časovna konstanta razpada znotraj l -te gruče (angl. intra-cluster decay time constant).

$$E\{|a_{k,l}|^2\} = \Omega_l \frac{1}{\gamma_l[(1 - \beta)\lambda_1 + \beta\lambda_2 + 1]} \exp\left(\frac{-\tau_{k,l}}{\gamma_l}\right) \quad (3.19)$$

Časovna konstanta razpada znotraj posamezne gruče γ_l je linearno odvisna od časa prispetja gruče T_l (3.20), kjer k_γ opisuje naraščanje konstante razpada s časom prihoda gruče T_l .

$$\gamma_l \propto k_\gamma T_l + \gamma_0 \quad (3.20)$$

Povprečna energija l -te gruče sledi eksponentnemu razpadu,

$$10 \log(\Omega_l) = 10 \log\left(\exp\left(\frac{-T_l}{\Gamma}\right)\right) + M_{cluster} \quad (3.21)$$

kjer $M_{cluster}$ predstavlja normalno porazdeljeno spremenljivko, ki vsebuje senčno presihanje znotraj gruče.

Za primere brez neposredne vidljivosti med oddajnikom in sprejemnikom (NLoS) v industrijskem in pisarniškem okolju oblika profila močnostne zakasnitve običajno sledi logaritemsko-linearni porazdelitvi (angl. log-linear distribution) po enačbi (3.22).

$$E\{|a_{k,l}|^2\} = \left(1 - \chi \cdot \exp\left(\frac{-\tau_{k,l}}{\gamma_{rise}}\right)\right) \cdot \exp\left(\frac{-\tau_{k,l}}{\gamma_l}\right) \cdot \frac{\gamma_l + \gamma_{rise}}{\gamma_l} \frac{\Omega_l}{\gamma_l + \gamma_{rise}(1 - \chi)} \quad (3.22)$$

Parameter χ opisuje slabljenje prve komponente, γ_{rise} določa, kako hitro časovni profil moči signala doseže svoj lokalni maksimum, γ_l pa določa hitrost razpada po doseženem lokalnem maksimumu.

Tabela 3.5: Parametri kanala UWB za različna notranja okolja [54].

	Bivalno okolje		Pisarniško okolje		Industrijsko okolje	
	LoS	NLoS	LoS	NLoS	LoS	NLoS
Model izgube poti (PL)						
PL_0 [dB]	43,9	48,7	35,4	57,9	56,7	56,7
n	1,79	4,58	1,63	3,07	1,2	2,15
σ_S [dB]	2,22	3,51	1,9	3,9	6	6
Model kanala Saleh-Valenzuela						
$\bar{L}$	3	3,5	5,4	1	4,75	1
Λ [1/ns]	0,047	0,12	0,016	NA	0,0709	NA
λ_1 [1/ns]	1,54	1,77	0,19	NA	NA	NA
λ_2 [1/ns]	0,15	0,15	2,97	NA	NA	NA
β	0,095	0,045	0,0184	NA	NA	NA
Γ [ns]	22,61	26,27	14,6	NA	13,47	NA
k_γ	0	0	0	NA	0,926	NA
γ_0 [ns]	12,53	17,50	6,4	NA	0,651	NA
$\sigma_{cluster}$ [dB]	2,75	2,93	NA	NA	4,32	NA
Alternativni model profila močnostne zakasnitve						
χ	NA	NA	NA	0,86	NA	1
γ_{rise} [ns]	NA	NA	NA	15,21	NA	17,35
γ_1 [ns]	NA	NA	NA	11,84	NA	85,36
Hitro presihanje						
m_0 [dB]	0,67	0,69	0,42	0,50	0,36	0,30
k_m	0	0	0	0	0	0
$\hat{m}_0$ [dB]	0,28	0,32	0,31	0,25	1,13	1,15
$\hat{k}_m$	0	0	0	0	0	0
$\tilde{m}_0$	NA	NA	NA	NA	12,99	NA

3.3.5 Predlagani parametri kanalov UWB po standardu IEEE 802.15.4-2011

Skupina za modeliranje kanala UWB v standardu IEEE 802.15.4-2011 je zbrala reprezentativne meritve za različna notranja okolja in predlagala nabor parametrov modelov kanala, ki so prikazani v tabeli 3.5. Meritve zajemajo notranja bivalna okolja, notranja pisarniška okolja in notranja industrijska okolja [54].

Celoten nabor parametrov modela kanala zajema naslednje parametre:

- PL_0 : izguba poti na razdalji 1 m,
- n : eksponent izgube poti,
- σ_S : standardni odklon senčnega presihanja,
- $\bar{L}$: povprečna vrednost števila gruč,
- Λ : hitrost prihajanja gruč,
- $\lambda_1, \lambda_2, \beta$: hitrost prihajanja komponent poti (mešani Poissonov model),
- Γ : časovna konstanta razpada energije signala,
- k_γ, γ_0 : časovna parametra razpada znotraj gruče,
- $\gamma_{rise}, \gamma_l, \chi$: parametri alternativnega Riceovega modela časovnega profila signala,
- $\sigma_{cluster}$: varianca senčnega presihanja znotraj gruče,
- m_0, k_m : povprečna vrednost Nakagamijevega faktorja m,
- $\hat{m}_0, \hat{k}_m$: varianca Nakagamijevega faktorja m,
- $\tilde{m}_0$: Nakagamijev faktor za izrazite komponente.

3.4 Parametri profila močnostne zakasnitve signala

Poleg parametrov modela kanala je v literaturi na področju detekcije pogojev razširjanja brez neposredne vidljivosti (NLoS) zaslediti tudi uporabo drugih parametrov profila močnostne zakasnitve signala, kot so na primer energija sprejetega signala, maksimalna amplituda profila močnostne zakasnitve, čas naraščanja profila močnostne zakasnitve, koeficient sploščenosti (angl. kurtosis), koeficient simetrije (angl. skewness), povprečna presežna zakasnitev (angl. mean excess delay) in RMS razpršitev časovne zakasnitve (angl. RMS delay spread) [60]–[65].

3.4.1 Energija sprejetega signala

Celotno energijo sprejetega signala E_{rx} dobimo z integriranjem profila močnostne zakasnitve sprejetega signala (PDP). V realnem sistemu je PDP porazdeljen v časovne enote (angl. bin) s širino Δt , ki jo določata osnovna časovna ločljivost uporabljenega komunikacijskega sistema UWB in izbrana pasovna širina komunikacijskega kanala. Pri izbranem komunikacijskem sistemu UWB, ki temelji na radiu DW1000, je širina časovnih enot in s tem časovna ločljivost profila močnostne zakasnitve sprejetega signala $\Delta t = 1,0016$ ns.

V realnem sistemu z omejeno ločljivostjo namesto integriranja uporabimo seštevanje vseh komponent časovnega poteka moči sprejetega signala, kar prikazuje enačba (3.23),

$$E_{rx} = \int_{t_0}^{T_{pdp}} |p_{pdp}(t)|^2 dt = \sum_{n=0}^{N-1} |P_{pdp}(n)|^2 \Delta t \quad (3.23)$$

kjer T_{pdp} predstavlja čas zaključka PDP, $p_{pdp}(t)$ opisuje valovno obliko PDP, n je časovni korak, ki predstavlja ločljivost Δt PDP, $N = \frac{T_{pdp}}{\Delta t}$ je število časovnih enot, ki opisujejo PDP, $P_{pdp}(n)$ pa je diskretni ekvivalent $p_{pdp}(t)$, kjer vsaka enota vsebuje integrirano sprejeto energijo, ki je na sprejemnik prispela znotraj časovnih okvirov enote.

3.4.2 Maksimalna amplituda profila močnostne zakasnitve

Maksimalna amplituda signala P_{pdp_max} je enostavno največja vrednost, ki jo doseže profil močnostne zakasnitve sprejetega signala. Osnovna definicija temelji na zvezni valovni obliki PDP z dolžino T_{pdp} , za realni sistem pa imamo zopet niz N diskretnih vrednosti moči sprejetega signala znotraj posameznih časovnih enot $\Delta t = 1,0016$ ns. Definicijo maksimalne amplitude profila močnostne zakasnitve sprejetega signala prikazuje enačba (3.24).

$$P_{pdp_max} = \max_t |p_{pdp}(t)| = \max_{n \in \{0,1,\dots,N-1\}} |P_{pdp}(n)| \quad (3.24)$$


3.4.3 Čas vzpona profila močnostne zakasnitve

Čas vzpona profila močnostne zakasnitve T_r je parameter, ki opisuje, koliko časa rabi profil močnostne zakasnitve, da iz začetne vrednosti ob času t_l doseže svojo maksimalno vrednost ob času t_h . Enačba (3.25) prikazuje definicijo časa naraščanja profila močnostne zakasnitve sprejetega signala.

$$T_r = t_h - t_l \quad (3.25)$$

3.4.4 Koeficient simetrije

Koeficient simetrije γ_1 (angl. skewness) je definiran kot tretji standardizirani moment slučajne spremenljivke in služi kot mera za asimetrijo verjetnostne porazdelitve realne slučajne spremenljivke.



Slika 3.7: Slika prikazuje možne asimetrične porazdelitve slučajne spremenljivke [66].

Negativna vrednost koeficienta simetrije γ_1 opisuje porazdelitev, ko je večina porazdelitve v kumulativni porazdelitveni funkciji (angl. cumulative distribution function, CDF) skoncentrirana na desni strani porazdelitve, ali drugače, ko je levi del porazdelitve daljši od desnega.

Pozitivni koeficient simetrije opisuje situacijo, ko je večina porazdelitve v CDF skoncentrirana na levi strani porazdelitve oziroma ko je desni del porazdelitve daljši.

Pri simetričnih porazdelitvah je vrednost koeficienta simetrije enaka $\gamma_1 = 0$, povprečna vrednost porazdelitve pa je enaka mediani. Oba možna tipa asimetrij sta prikazana na sliki 3.7.

Standardizirani moment k -tega reda realne slučajne spremenljivke za povprečno vrednost je definiran kot količnik k -tega centralnega momenta μ_k in k -te potence standardnega odklona σ^k slučajne spremenljivke, kar prikazuje enačba (3.26).

$$\frac{\mu_k}{\sigma^k} \quad (3.26)$$

Centralni moment k -tega reda realne slučajne spremenljivke X za povprečno vrednost definira enačba (3.27), kjer je E operator pričakovane vrednosti, k pa je red centralnega momenta. Funkcija $f(x)$ opisuje gostoto verjetnosti zvezne univariantne verjetnostne porazdelitve, μ pa je pričakovana (povprečna) vrednost slučajne spremenljivke.

$$\mu_k = E[(X - E[X])^k] = \int_{-\infty}^{\infty} (x - \mu)^k f(x) dx \quad (3.27)$$

Centralni moment diskretne slučajne spremenljivke opisuje enačba (3.28).

$$\mu_k = E[(X - E[X])^k] = \sum_{i=0}^m (x_i - \mu_k)^k p_x(x_i) \quad (3.28)$$

Koeficient simetrije je definiran kot tretji standardizirani moment, ki ga prikazuje enačba (3.29). μ_3 predstavlja tretji centralni moment, σ pa je standardni odklon.

$$\gamma_1 = \frac{\mu_3}{\sigma^3} \quad (3.29)$$

Koeficient simetrije lahko za diskretni profil močnostne zakasnitve signala z n vzorci izračunamo po enačbi (3.32), kjer x_i predstavlja vrednost i -tega vzorca, $\bar{x}$ predstavlja povprečno vrednost PDP, m_3 je tretji centralni moment, m_2 pa varianca PDP.

$$\gamma_1 = \frac{m_3}{m_2^{(3/2)}} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^{(3/2)}} \quad (3.30)$$

3.4.5 Koeficient sploščenosti

Koeficient sploščenosti γ_2 (angl. kurtosis) opisuje sploščenost verjetnostne porazdelitve realne slučajne spremenljivke.

Koeficient sploščenosti definiramo kot količnik četrtega centralnega momenta μ_4 in četrte potence standardnega odklona σ . Definicijo koeficienta sploščenosti prikazuje enačba (3.31).

$$\frac{\mu_4}{\sigma^4} \quad (3.31)$$

Koeficient sploščenosti za diskretni profil močnostne zakasnitve sprejetega signala z n vzorci izračunamo po enačbi (3.32), kjer x_i predstavlja vrednost i -tega vzorca PDP, $\bar{x}$ predstavlja povprečno vrednost PDP, m_4 je četrti centralni moment, m_2 pa varianca PDP.

$$\gamma_2 = \frac{m_4}{m_2^2} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^2} \quad (3.32)$$

3.4.6 Povprečna presežna zakasnitev

Povprečna presežna zakasnitev (angl. mean excess delay, MED) τ_{med} opisuje časovno zakasnitev povprečne vrednosti PDP od časa prve sprejete komponente poti. Povprečno presežno zakasnitev izračunamo po enačbi (3.33), kjer $P_T = \sum_{i=1}^n P_i$ predstavlja vsoto moči sprejetega signala znotraj enega PDP, P_i predstavlja moč i -te časovne enote PDP, τ_i pa predstavlja časovno zakasnitev i -te časovne enote PDP [67].

$$\tau_{med} = \frac{\sum_{i=1}^n P_i \tau_i}{\sum_{i=1}^n P_i} = \frac{1}{P_T} \sum_{i=1}^n P_i \tau_i \quad (3.33)$$


3.4.6.1 RMS razpršitev zakasnitve

RMS razpršitev zakasnitve opisuje razpršenost PDP od povprečne presežne zakasnitve, pa do maksimalne presežne zakasnitve. RMS presežno zakasnitev izračunamo po enačbi (3.34), kjer P_i predstavlja moč i -te časovne enote PDP, τ_i pa časovno zakasnitev i -te časovne enote.

$$\tau_{RMS} = \sqrt{\frac{\sum_{i=1}^n P_i \tau_i^2}{\sum_{i=1}^n P_i} - \left(\frac{\sum_{i=1}^n P_i \tau_i}{\sum_{i=1}^n P_i}\right)^2} \quad (3.34)$$

3.5 Merjenje razdalj z radijsko tehnologijo UWB

Zaradi visoke časovne ločljivosti komunikacijskih sistemov UWB so za lokalizacijo najbolj primerni tisti pristopi, ki temeljijo na merjenju časa razširjanja signala. Različni pristopi k merjenju časa razširjanja zahtevajo različne nivoje zahtevnosti uporabljene strojne opreme. Tehnike lociranja na osnovi časa razširjanja (ToF) signala namreč zahtevajo natančno časovno sinhronizacijo med vsemi vozlišči v sistemu. Tehnike lociranja na osnovi časovne razlike prihodov signala (DToA) zahtevajo časovno sinhronizacijo referenčnih vozlišč (sidr-nih vozlišč). Tehnike na osnovi dvosmernega časovnega žigosanja (angl. two-way ranging, TWR) pa izkoriščajo zaporedno večkratno lokalno časovno žigosanje paketov in zaradi tega ne potrebujejo globalne časovne sinhronizacije na račun daljšega postopka meritve. Zaradi manjše zahtevnosti smo za analizo učinkovitosti lokalizacijskega sistema UWB in analizo vplivov na njegovo učinkovitost izbrali pristop z metodo TWR.



Slika 3.8: Grafični prikaz postopka SS-TWR [52].

3.5.1 Dvosmerno časovno žigosanje

Visoka časovna ločljivost radijskega vmesnika UWB DW1000, njegova podpora za točno časovno žigosanje sprejetih in oddanih paketov ter natančna kontrola nad dejanskim časom oddaje paketa omogoča izvedbo algoritmov TWR za merjenje razdalje in lokalizacijo [52].

3.5.1.1 Dvosmerni obhod paketa

Pri pristopu dvosmernega obhoda paketa (angl. single-sided two-way ranging, SS-TWR) vozlišče UWB odpošlje z lokalno uro ožigosan paket, ki ga referenčno sidrno vozlišče ob sprejemu ožigosa s svojo lokalno uro. Sidrno vozlišče nato odgovori s paketom, ki je tudi ožigosan z lokalno uro (tokrat na strani sidrnega vozlišča), izvirno vozlišče pa ga ob sprejemu označi s svojo lokalno uro. Čas potovanja paketa $\hat{T}_{SS}$ lahko sedaj izračunamo po enačbi (3.35), kjer T_{round} predstavlja celoten čas med oddajo začetnega paketa in sprejemom končnega paketa na strani vozlišča, T_{reply} pa opisuje čas, ki ga sidrno vozlišče porabi od sprejema začetnega paketa, pa do oddaje končnega paketa. Postopek grafično opisuje slika 3.8.

$$\hat{T}_{SS} = \frac{T_{round} - T_{reply}}{2} \quad (3.35)$$

Izmerjena časa T_{round} in T_{reply} izvirno vozlišče in sidrno vozlišče izmerita neodvisno drug od drugega. Ker se vsaka realna osnovna frekvenca lokalne ure razlikuje v mejah, ki jo določajo tolerance dejanskega lokalnega frekvenčnega izvora, se razlika v frekvencah lokalnih ur odraža v napaki, ki narašča z naraščanjem T_{reply} . Pristop SS-TWR je zato primeren samo za sisteme, kjer je ključnega pomena čim krajša prisotnost v frekvenčnem spektru oz. čim manjša poraba energije, z nizkimi tolerancami osnovnih frekvenc lokalne ure, kjer so zagotovljeni čim krajši časi T_{reply} in kjer točnost ni bistvenega pomena. Napako izmerjenega časa potovanja paketa lahko ocenimo po enačbi (3.36), kjer ε_A in ε_B predstavljata odstopanje lokalnih ur na vozliščih A in B od nominalne frekvence. Tabela 3.6 prikazuje vpliv časa T_{reply} na napako $\hat{T}_{SS}$ pri različnih tolerancah frekvence lokalne ure.


$$\varepsilon_{twr} = \frac{\varepsilon_B - \varepsilon_A}{2} \times T_{reply} \quad (3.36)$$

3.5.1.2 Dvakratni dvosmerni obhod paketa

Pristop z dvakratnim dvosmernim obhodom paketa (angl. double-sided two-way ranging, DS-TWR) zmanjšuje velikost napake izmerjene razdalje zaradi odstopanja frekvenc lokal-

Tabela 3.6: Ocene napake izmerjenega časa $\hat{T}_{DS}$ v odvisnosti od T_{reply} in toleranc osnovne frekvence lokalne ure [52].

T_{reply} [ms]	2 ppm [ns]	5 ppm [ns]	10 ppm [ns]	20 ppm [ns]	40 ppm [ns]
0,1	0,1	0,25	0,5	1	2
0,2	0,2	0,5	1	2	4
0,5	0,5	1,25	2,5	5	10
1	1	2,5	5	10	20
2	2	5	10	20	40
5	5	12,5	25	50	100



Slika 3.9: Grafični prikaz DS-TWR postopka s štirimi poslanimi podatkovnimi paketi [52].

nih ur od nominalne frekvence s ponovitvijo dvosmernega obhoda paketa v obratni smeri od predhodnega. Možna sta dva pristopa dvakratnega dvosmernega obhoda paketa: pristop s štirimi paketi in pristop s tremi podatkovnimi paketi.


Pristop DS-TWR z izmenjavo štirih podatkovnih paketov prikazuje slika 3.9. Postopek prične vozlišče A s pošiljanjem začetnega paketa. Referenčno sidrno vozlišče B paket sprejme in pošlje odgovor nanj. Sedaj se vlogi vozlišč v komunikaciji zamenjata. Vozlišče B sedaj pošlje novo začetno sporočilo po enakem postopku kot vozlišče A, le da komunikacija sedaj poteka v nasprotni smeri. Po tem postopku se izmenjajo 4 sporočila, ob vsaki oddaji in sprejemu pa se zabeleži lokalni časovni žig. Tako dobimo 8 lokalnih časovnih žigov, na podlagi katerih lahko izračunamo čas potovanja enega paketa $\hat{T}_{DS}$, ki ga definira enačba (3.37). V enačbi T_{round1} in T_{round2} opisujeta celotna časa obeh obhodov paketov, T_{reply1} in T_{reply2} pa opisujeta časa med sprejemom začetnega paketa in odgovorom nanj.

$$\hat{T}_{DS} = \frac{T_{round1} \times T_{round2} - T_{reply1} \times T_{reply2}}{T_{round1} + T_{round2} + T_{reply1} + T_{reply2}} \quad (3.37)$$

Napaka izmerjenega časa potovanja paketa je sedaj v velikostnem razredu ps, kar pomeni, da točnost algoritma za časovno žigosanje paketov bistveno več prispeva k napaki izmerjenega časa in lahko vpliv razlike v lokalnih urah praktično zanemarimo [52]. Ocenimo napake izmerjenega časa potovanja paketa lahko ocenimo z enačbo (3.38), kjer k_a in k_b predstavljata količnik med dejansko frekvenco lokalne ure in nominalno frekvenco in sta oba zelo blizu 1.

$$\varepsilon_{twr} = \hat{T}_{DS} \times \left(1 - \frac{k_a + k_b}{2}\right) \quad (3.38)$$

Pristop DS-TWR s tremi poslanimi paketi deluje zelo podobno kot pristop s štirimi paketi, le da se sedaj za začetek drugega kroga obhoda paketa upošteva že paket s poročilom prvega obhoda, ki ga pošlje referenčno sidrno vozlišče. S tem pristopom zmanjšamo število



Slika 3.10: Grafični prikaz DS-TWR postopka s tremi poslanimi podatkovnimi paketi [52].

potrebnih izmenjav paketov in s tem porabo energije, poleg tega pa lahko tudi zvišamo frekvenco meritev časa potovanja signala in s tem razdalje med dvema vozliščema. Grafični prikaz postopka DS-TWR s tremi paketi prikazuje slika 3.10.

Praktična izvedba postopka DS-TWR s tremi poslanimi paketi v našem senzorskem omrežju za lokalizacijo v notranjih okoljih obsega naslednje korake:

1. Senzorsko vozlišče z neznanim položajem referenčnemu sidrnemu vozlišču pošlje paket za začetek postopka merjenja razdalje z metodo DS-TWR. Ko je paket oddan, senzorsko vozlišče lokalno shrani časovni žig oddanega paketa T_{poll_TX} .
2. Referenčno sidrno vozlišče sprejme paket z zahtevo za merjenje razdalje in lokalno shrani časovni žig prejetega paketa T_{poll_RX} .
3. Referenčno sidrno vozlišče pošlje paket z odgovorom na zahtevo za merjenje razdalje in lokalno shrani časovni žig poslanega paketa T_{resp_TX} .
4. Senzorsko vozlišče sprejme paket z odgovorom na zahtevo za merjenje razdalje in lokalno shrani časovni žig sprejetega paketa T_{resp_RX} .
5. Senzorsko vozlišče sestavi zaključni paket v postopku merjenja razdalje, vsebina paketa pa so časovni žigi T_{poll_TX} , T_{resp_RX} in T_{final_TX} . Časovni žig T_{final_TX} ni dejanska vrednost časovnega žiga oddanega paketa, ampak je ocenjena vrednost časa oddaje paketa. Interni mehanizmi radia DW1000 namreč omogočajo oddajo paketa ob točno določenem času, kjer se oddajanje sinhronizacijske sekvence začne ob pravem času, da se začetni razmejevalnik bloka (sfd) odda ob vnaprej določenem času T_{final_TX} .
6. Referenčno sidrno vozlišče sprejme zaključni paket v postopku merjenja razdalje, določi časovni žig sprejetega zaključnega paketa T_{final_RX} in izračuna čas potovanja signala po zraku in s tem razdaljo med senzorskim vozliščem in referenčnim sidrnim vozliščem po formulah (3.39), (3.40), (3.41) in (3.42). T_{resp} predstavlja čas razširjanja začetnega paketa in paketa z odgovorom na začetni paket, T_{final} pa predstavlja čas razširjanja paketa z odgovorom na začetni paket in zaključnega paketa. Vsoto obeh časov delimo s štiri, da dobimo čas razširjanja radijskega signala v eno smer, razdaljo med vozliščema d pa izračunamo kot produkt časa razširjanja signala T_{tof} in svetlobne hitrosti $c = 299702547$ m/s

$$T_{resp} = (T_{resp_RX} - T_{poll_TX}) - (T_{resp_TX} - T_{poll_RX}) \quad (3.39)$$

$$T_{final} = (T_{final_RX} - T_{resp_TX}) - (T_{final_TX} - T_{resp_RX}) \quad (3.40)$$

$$T_{tof} = \frac{T_{resp} + T_{final}}{4} \quad (3.41)$$

$$d = c * T_{tof} \quad (3.42)$$

Poglavje 4

Testno okolje

V tem poglavju opisujemo testno okolje za testiranje in evalvacijo novih postopkov lokalizacije, ki zajema merilno opremo, testno senzorsko omrežje, merilni postopek in štiri značilna notranja okolja za evalvacijo.

4.1 Večnamensko senzorsko vozlišče UWB


Za raziskave razširjanja ultra-širokopasovnih (UWB) signalov v zahtevnih radijskih okoljih smo izbrali radio UWB za komunikacije v nizkoenergijskih senzorskih omrežjih DW1000 proizvajalca DecaWave. Izbrani komunikacijski vmesnik je združljiv s standardom IEEE802.15.4-2011 in podpira pulzno komunikacijo UWB s funkcijo merjenja razdalje med dvema senzorskima vozliščema na podlagi merjenja časa potovanja signala.

Glede na namen uporabe smo implementirali dva pristopa za uporabo radia DW1000:


- demonstracijski komplet EVK1000 z zunanjo vsesmerno anteno,
- samostojno vsestransko senzorsko vozlišče z integrirano keramično anteno.

Demonstracijski komplet EVK1000 je namenjen preizkušanju osnovnih funkcij radia DW1000 s priloženimi demonstracijskimi aplikacijami za osebni računalnik. Komplet vsebuje dve demonstracijski senzorski vozlišči z mikrokrmilnikom STM32F105, serijskim vmesnikom USB, alfanumeričnim prikazovalnikom LCD in odstranljivo ultra-širokopasovno anteno (Slika 4.1a). Ker sevalni diagrami za priloženo anteno niso znani, smo za potrebe analize razširjanja signalov uporabili dve vsesmerni referenčni anteni Cobham XPO2V-2.0-18.0/1397 (Slika 4.1b) z območjem delovanja v frekvenčnem pasu med 2,0 in 18,0 GHz. Programska koda, ki se izvaja na mikrokrmilniku, je dostopna tudi v izvorni obliki in s tem omogoča prilagajanje funkcionalnosti senzorskega vozlišča potrebam končne aplikacije. Senzorska vozlišča EVB1000 smo uporabili v procesu zajemanja realnih pogojev razširjanja v zahtevnih radijskih okoljih.

Drugi način uporabe radia DW1000 pa je njegova uporaba v realnih senzorskih omrežjih, kjer sta pomembni tudi nizka cena vozlišča in čim manjše dimenzije. V ta namen smo uporabili integrirano verzijo radia DW1000, v miniaturnem certificiranem modulu DWM1000 z vgrajeno keramično anteno. Modul za svoje delovanje zahteva nizko število dodatnih komponent in omogoča enostavno povezovanje z večino mikrokrmilnikov na trgu. Z uporabo DWM1000 v povezavi z mikrokrmilnikom STM32F103 smo dosegli visoko razmerje cena/zmogljivost in omogočili postavitev večjega ultra-širokopasovnega senzorskega omrežja v sklopu eksperimentalnega heterogenega senzorskega omrežja LOG-a-TEC na območju Instituta "Jožef Stefan".




(a) Senzorsko vozlišče EVB1000 s priloženo vse-smerno anteno.



(b) Senzorsko vozlišče EVB1000 z referenčno anteno.

Slika 4.1: Prikaz dveh izvedb senzorskega vozlišča EVB1000.



Slika 4.2: Senzorsko vozlišče SNPN-UWB.

4.1.1 Senzorsko vozlišče SNPN-UWB

Izbrani radijski modul z integrirano keramično anteno DWM1000, ki temelji na pulznem radiu UWB DW1000, omogoča integracijo v majhne elektronske naprave, kar mu daje širok nabor potencialnih končnih aplikacij. Zasnova senzorskega vozlišča SNPN-UWB temelji na visoki prilagodljivosti končni aplikaciji z vidika povezovanja na matično napravo, prav tako pa omogoča tudi samostojno uporabo vozlišča v aplikaciji samostojnega baterijskeko napajane nizekoenergijskega senzorskega vozlišča.

Podprti komunikacijski vmesniki na senzorskem vozlišču poleg radijskega vmesnika zajemajo tudi komunikacijski vmesnik SPI, komunikacijski vmesnik I²C, serijski vmesnik UART in virtualni serijski vmesnik preko vodila USB. Napajanje senzorskega vozlišča je ravno tako omogočeno iz več virov: napajanje iz konektorja VESNA-BUS, napajanje iz konektorja JTAG, napajanje iz konektorja USB in napajanje iz baterijskega konektorja.

Jedro senzorskega vozlišča SNPN-UWB predstavlja zmogljiv mikrokrmilnik STM32F103RE z 32-bitnim procesorskim jedrom ARM Cortex M3, 64 kB RAM in 512 kB pomnilnika FLASH ter frekvenco sistemske ure 72 MHz. Našteti performančni parametri omogočajo visoko odzivnost senzorske sistemske programske opreme za obravnavo dogodkov, povezanih z radijsko komunikacijo, in visoko prilagodljivost kompleksnosti sistemske programske opreme za potrebe končne aplikacije. Izbrani mikrokrmilnik po potrebi dopušča tudi prilagajanje stroškov končne montaže senzorskega sistema, saj družina STM32F103 ponuja nabor modelov mikrokrmilnikov z enakim razporedom pinov in enakim naborom funkcionalnosti z različno količino pomnilnikov FLASH in RAM. Pri montaži končnega sistema z nižjimi zahtevami po količini razpoložljivega pomnilnika, predvsem pa pri montaži večjih sistemov, ki zajemajo veliko število senzorskih vozlišč, se lahko doseže nezanemarljivo velik prihranek.

Osnovno PCB vezje v širino meri 32 mm, v dolžino pa 40 mm. Če upoštevamo še anteno radijskega modula DWM1000, celotno senzorsko vozlišče v dolžino doseže 50 mm. Senzorsko vozlišče SNPN-UWB prikazuje slika 4.2.

Tabela 4.1: Tabela sevalnih karakteristik antene ACS5200HFAUWB [69].

Frekvenca [MHz]				3200	4200	5200	6200	7200
Gain	Azimuth	θ	Peak [dB]	-0,88	2,73	2,51	4,16	1,31
			Average [dB]	-4,26	-1,22	-1,88	-1,10	-4,82
			Efficiency [%]	37,50	75,50	64,86	77,62	32,96
		ϕ	Peak [dB]	-3,84	-2,16	-1,91	-2,61	-5,20
			Average [dB]	-9,61	-8,20	-8,16	-9,96	-11,63
			Efficiency [%]	10,96	15,13	15,27	10,09	6,87
	Elevation 1	θ	Peak [dB]	-5,05	-2,32	-1,03	0,30	-0,68
			Average [dB]	-10,36	-8,84	-7,90	-6,99	-8,06
			Efficiency [%]	9,20	13,06	16,21	19,99	15,63
		ϕ	Peak [dB]	-2,99	1,98	1,81	2,92	0,20
			Average [dB]	-6,65	3,30	-3,37	-3,04	-3,71
			Efficiency [%]	21,62	46,77	46,02	49,65	42,55
	Elevation 2	θ	Peak [dB]	-5,83	-3,38	-2,05	0,26	-3,56
			Average [dB]	-10,76	-9,16	-7,01	-5,74	-8,27
			Efficiency [%]	8,39	12,13	19,90	26,66	14,89
		ϕ	Peak [dB]	-0,52	2,23	1,52	1,39	1,12
			Average [dB]	-5,23	-3,30	-3,66	-3,90	-4,74
			Efficiency [%]	29,99	46,77	43,05	40,73	33,57

4.1.1.1 Sistemska programska oprema

Sistemska programska oprema (angl. firmware) skrbi za celotno delovanje senzorskega vozlišča. Je osnovna programska oprema, ki se izvaja v mikrokrmilniku in skrbi za pravilno delovanje osnovnih komunikacijskih vmesnikov ter vso funkcionalnost senzorskega vozlišča.

Sistemska programska oprema senzorskega vozlišča SNPN-UWB nadzoruje delovanje komunikacijskega vmesnika UWB in komunicira z bolj kompleksno računalniško platformo z operacijskim sistemom GNU/Linux preko serijskega vmesnika UART. Senzorsko vozlišče skrbi za delovanje brezžičnega komunikacijskega protokola in omogoča njegovo prilagajanje. Platforma GNU/Linux izvaja visokonivojsko aplikacijo in preko aplikacijskega programskega vmesnika (angl. application programming interface, API) na vmesniku UART usmerja delovanje senzorskega vozlišča ter pridobiva meritve razdalje med vozlišči za potrebe lokalizacije.

4.1.1.2 Antenske karakteristike

Uporabljeni radijski modul DWM1000 ima vgrajeno keramično anteno Partron ACS5200HFAUWB. Antena je namenjena uporabi na cenovno učinkovitih senzorskih vozliščih in je zato v primerjavi z večjimi in bolj učinkovitimi vsesmernimi antenami, kot je na primer antena Cobham XPO2V-2.0-18.00/1397 [68], manj učinkovita. Antena ACS5200HFAUWB je kompaktna keramična antena dimenzij $8 \times 6 \times 1,2$ mm. Sevalne lastnosti antene za različne orientacije in različne frekvenčne pasove prikazuje tabela 4.1, sevalni diagrami antene pa so na voljo v tehničnih specifikacijah antene [69].

4.1.1.3 Diagnostične informacije radijskega kanala UWB

Komunikacijski vmesnik UWB DW1000 ponuja več virov informacij, ki pomagajo pri ocenjevanju delovanja radijskega vmesnika in stanja komunikacijskega kanala. Radijski vmesnik ponuja uporabo štirih elementov LED, ki signalizirajo aktivnosti oddajanja (TX) in aktivnosti sprejemanja (RX). Dostopen je pomnilnik z akumuliranim impulznim odzivom kanala. Dostopni so tudi indikatorji, ki lahko služijo za takojšnjo oceno kvalitete sprejetega

podatkovnega bloka, kot so na primer prve tri točke impulznega odziva kanala, največja moč impulznega odziva kanala in standardni odklon šuma.

V sistemih UWB za lokalizacijo je pomembno, da znamo oceniti kvaliteto radijskega kanala za posamezni podatkovni blok. Iz razpoložljivih diagnostičnih informacij lahko ocenimo tudi kvaliteto časovnih žigov in s tem kakovost informacije o medsebojni razdalji, kar neposredno vpliva na kakovost informacije o položaju.

Standardni odklon šuma impulznega odziva kanala nosi informacijo o nivoju šuma znotraj ocenjenega impulznega odziva kanala. Če standardni odklon šuma primerjamo z močjo prve fronte signala, lahko na podlagi razmerja med njima ocenimo zanesljivost določenega časovnega žiga sprejetega podatkovnega bloka.

4.1.1.3.1 Ocena moči prve fronte signala: Radio DW1000 med diagnostičnimi podatki za vsak posamezni sprejeti podatkovni blok ponuja moči za prve tri točke znotraj akumulatorja impulznega odziva kanala: FP_AMPL1, FP_AMPL2 in FP_AMPL3. Moč prve fronte sprejetega podatkovnega paketa lahko ocenimo z enačbo (4.1) [52]. F_1 , F_2 in F_3 predstavljajo prve tri točke impulznega odziva kanala (FP_AMPL1, FP_AMPL2 in FP_AMPL3), N predstavlja število akumuliranih simbolov pri sprejemu podatkovnega bloka, A pa je konstanta, ki za 16 MHz PRF znaša 115,72, za 64 MHz PRF pa 121,74.

$$RSS_{FP} = 10 \times \log_{10} \left(\frac{F_1^2 + F_2^2 + F_3^2}{N^2} \right) - A \text{ [dBm]} \quad (4.1)$$

4.1.1.3.2 Ocena moči sprejetega signala: Radio DW1000 ponuja oceno največje moči impulznega odziva kanala na podlagi vsote kvadratov akumuliranih magnitud v okolici največje moči sprejetega signala, ki je z močjo sprejetega signala povezana preko enačbe (4.2) [52]. C predstavlja moč impulznega odziva kanala, N število akumuliranih simbolov sinhronizacijske sekvence pri sprejemu podatkovnega bloka, A pa je enaka konstanta kot pri oceni moči prve fronte signala (4.1.1.3.1, enačba (4.1)).


$$RSS = 10 \times \log_{10} \left(\frac{C \times 2^{17}}{N^2} \right) - A \text{ [dBm]} \quad (4.2)$$

4.1.1.3.3 Odstopanje RSS in kompenzacija: Dokumentacija radia UWB DW1000 [52] navaja, da je moč sprejetega po enačbi (4.2) za šibke signale dober približek dejanske moči signala, za močnejše signale pa ocenjena vrednost moči signala odstopa od dejanske vrednosti moči sprejetega signala, kar prikazuje graf na sliki 4.3.

Ker v okviru doktorske disertacije za vse meritve uporabljamo 64 MHz PRF in ker so vse meritve narejene v notranjih okoljih, lahko privzamemo razmere, ki jih na grafu 4.3 prikazuje krivulja za razmere pri 64 MHz PRF in razširjanju signala po več poteh (64 MHz PRF Multipath). Pridobljene ocenjene vrednosti RSS lahko interpoliramo blizu pravih vrednosti z uporabo kubičnih zlepkov.

4.2 Meritve značilnih notranjih okolij

Za analizo pogojev razširjanja signala UWB v notranjih okoljih potrebujemo veliko število izmerkov pogojev razširjanja radijskega signala v več različnih značilnih notranjih okoljih, ki pokrivajo namembnosti od pisarniških prostorov, bivalnih prostorov, pa vse do radijsko zelo zahtevnega industrijskega okolja. Meritve znotraj vsakega notranjega okolja morajo pokriti čim več različnih kombinacij položajev oddajnika in sprejemnika, da pridobljena podatkovna zbirka meritev čim bolje pokrije raznolikost pogojev razširjanja znotraj enega okolja. Samo na podlagi nabora izmerkov, ki pokrivajo večino možnih situacij v dotičnem



Slika 4.3: Graf odstopanja izmerjenih in dejanskih RSS vrednosti [52].

radijskem okolju, lahko namreč predstavimo model kanala, ki verodostojno opisuje pogoje razširjanja radijskega signala.

Na podlagi pridobljenih izmerkov iz nabora notranjih okolij lahko prav tako sklepamo na pogoje razširjanja signala v dani situaciji. S tem lahko ocenimo vpliv trenutnega stanja radijskega kanala na kakovost pridobljene informacije o razdalji med oddajnikom in sprejemnikom, ki jo uporabljamo za lokalizacijo. Prvi faktor vpliva radijskega kanala na kakovost ocenjene razdalje med oddajnikom in sprejemnikom je ločevanje med razširjanjem v pogojih z neposredno vidljivostjo in razširjanjem v pogojih brez neposredne vidljivosti. V pogojih brez neposredne vidljivosti signal potuje po daljši poti od direktne poti, ker ovire na direktni poti med oddajnikom in sprejemnikom signalu preprečijo nadaljevanje poti po najkrajši poti. Preostanek radijskega signala, ki se ne ustavi na ovirah, le-te z odboji preusmerijo v prostor okoli njih. S tem radijskemu signalu podaljšajo čas razširjanja in z njim tudi najkrajšo razdaljo razširjanja, ki se uporablja za oceno razdalje med oddajnikom in sprejemnikom.

Poleg informacije NLoS lahko v primeru, če imamo v podatkovni zbirki poleg ocenjenih razdalj med oddajnikom in sprejemnikom tudi dejanske razdalje med njimi, na podlagi impulznega odziva kanala ali parametrov, ki jih pridobimo z njegovo obdelavo, izdelamo model za ocenjevanje napake izmerjene medsebojne razdalje. Informacija o ocenjeni napaki izmerjene medsebojne razdalje nam služi za adaptivno uteževanje posameznih izmerjenih razdalj v postopku lokalizacije za izboljšanje točnosti in natančnosti lokalizacijskih metod.

4.2.1 Postopek zajemanja meritev UWB

Za analizo razširjanja signala UWB in vplivov okolja na razširjanje ter lokalizacijo v različnih značilnih notranjih okoljih potrebujemo meritve, ki zajemajo informacijo o izmerjeni

razdalji, informacijo o pravi razdalji, informacijo o moči sprejetega signala za modeliranje slabljenja ter impulzni odziv kanala za analizo pogojev razširjanja in oceno vpliva na napako izmerjene razdalje oziroma točnost lokalizacije.

4.2.1.1 Merilno senzorsko vozlišče

Merilno senzorsko vozlišče zaradi enostavnosti izvedbe in cene izdelave sloni na računalniški platformi Raspberry Pi 3 (RPI3) s 64-bitnim štirijedrnim procesorjem ARM Cortex-A53 z osnovno frekvenco 1,2 GHz, gigabitnim Ethernet vmesnikom (300 Mb/s), 2,4/5 GHz dvo-pasovnim 100 Mb/s vmesnikom Wi-Fi in 1 GB RAM. Računalnik RPI3 služi kot osnova za priklop senzorskega vozlišča UWB SNPN-UWB (poglavje 4.1.1) s pulznim radijskim modulom UWB DWM1000. Vozlišče SNPN-UWB z RPI3 komunicira po asinhronem serijskem protokolu UART, ki omogoča upravljanje z delovanjem radia in beleženje merilnih rezultatov.

Uporaba tako zmogljivega računalnika (RPI3) z operacijskim sistemom GNU/Linux in njegovim celotnim ekosistemom visokonivojskih komunikacijskih ter aplikacijskih vmesnikov omogoča enostavno in zanesljivo komuniciranje s posameznimi senzorskimi vozlišči in s tem dobro kontrolo nad potekom eksperimentov. Poleg enostavnosti in zanesljivosti podpornega komunikacijskega omrežja zaradi visokih podatkovnih hitrosti na komunikacijskih vmesnikih pridobimo tudi kapacitete za prenos velike količine podatkov znotraj eksperimentov, ki nam jih nizkoenergijska senzorska vozlišča s svojimi brezžičnimi podatkovnimi vmesniki ne morejo ponuditi.


4.2.1.2 Merilno senzorsko omrežje

Merilno senzorsko omrežje sestavlja 9 senzorskih vozlišč. V času meritev je osem vozlišč razporejenih po prostoru in predstavljajo fiksna senzorska vozlišča, eno vozlišče pa je uporabljeno kot mobilno vozlišče in ga znotraj eksperimenta poljubno predstavljamo po prostoru, kjer se izvajajo meritve.

Eksperimentalno senzorsko omrežje sestavlja tudi osebni računalnik, na katerem se izvajata programska oprema za upravljanje z eksperimentom in programska oprema za zajemanje eksperimentalnih podatkov. Za komunikacijo med osebnim računalnikom in senzorskimi vozlišči skrbi usmerjevalnik Wi-Fi z Ethernet stikalom. Komunikacija poteka brezžično ali žično po lokalnem omrežju (LAN). Visokonivojski komunikacijski transport zagotavlja protokol MQTT (Message Queuing Telemetry Transport), ki deluje na principu pub-sub (angl. publish-subscribe). Znotraj omrežja deluje strežnik MQTT, ki skrbi za sprejemanje sporočil na vseh kanalih (angl. topic) in usmerjanje teh sporočil proti vozliščem, ki se prijavijo na posamezne kanale (angl. subscribe). Vozlišča želene podatke objavijo (angl. publish) na določenih kanalih, naprave, ki jih ti podatki zanimajo, pa se povežejo na dogovorjeni strežnik MQTT in poslušajo na zelenih kanalih oz. se prijavijo na podatke z določenih kanalov. Uporaba protokola MQTT omogoča enostavno prilagodljivost eksperimentalnih aplikacij na posameznih senzorskih vozliščih, ker ob spremembi števila vozlišč ni treba spreminjati aplikacij na senzorskih vozliščih, ampak le glavno aplikacijo na osebnem računalniku, ki vodi celoten potek eksperimenta. Konceptualno zgradbo eksperimentalnega sistema prikazuje slika 4.4.

4.2.1.3 Merilni proces

Merilni proces za vsako merilno točko nadzoruje kontrolna aplikacija na osebnem računalniku. Na vsakem od senzorskih vozlišč deluje merilna aplikacija, ki čaka na ukaze iz kontrolne aplikacije ter ji pošilja meritve.



Slika 4.4: Konceptualna shema eksperimentalnega senzorskega omrežja.

Od devetih senzorskih vozlišč jih je v merilnem procesu osem uporabljenih za fiksna referenčna vozlišča. Eno vozlišče je uporabljeno kot mobilno vozlišče, ki se mu v procesu lokalizacije išče položaj relativno ali absolutno glede na lokacije referenčnih vozlišč. Osem referenčnih vozlišč razpršimo po celotnem okolju, kjer izvajamo meritve, položaje pa izberemo tako, kot bi izbrali lokacije za referenčna sidna vozlišča. Pomembno je, da lokacije referenčnih sidnih vozlišč niso kolinearne in da je celotno merilno območje enakomerno pokrito z njimi, da v vseh možnih pozicijah mobilnega vozlišča dobimo vse vrste povezav (tako brez neposredne vidljivosti kot tudi z neposredno vidljivostjo).

Merilni proces za vsak položaj mobilnega vozlišča začnemo z opisom posameznih povezav med mobilnim vozliščem in posameznimi referenčnimi vozlišči. Če je fizična vizualna povezava med antenama prekinjena z ovirami, povezavo označimo z značko NLoS, če pa je vizualna povezava med antenama brez ovir, potem povezavo označimo z LoS. Ta informacija o neposredni vidljivosti med antenama je pomembna za nadaljnje analize razširjanja signala UWB in vplive okolja na točnost in natančnost lokalizacije v notranjih okoljih. Za vsak položaj mobilnega vozlišča najprej z laserskim merilnikom razdalje izmerimo njeno oddaljenost od objektov v okolju, za katera poznamo lokacijo glede na koordinatno izhodišče načrta, in s tem določimo pravo lokacijo na mapi okolja.

Ko je kontekst okolja mobilnega vozlišča določen, sprožimo merilno in kontrolno aplikacijo, ki sproži izvajanje meritev med mobilnim in fiksnimi vozlišči. Aplikacija za vsak par mobilno vozlišče - fiksno vozlišče izmeri 31 meritev, ki vsebujejo informacijo o pravi razdalji med vozliščema, informacijo o izmerjeni razdalji (ToF), moč sprejetega signala (RSS), nastavitve oddajnika in impulzni odziv kanala (CIR). Merilna in kontrolna aplikacija izvaja meritve posamezno za vsak par vozlišč (osem parov) na vseh šestih radijskih kanalih, ki so na razpolago, kar pomeni 1488 meritev za vsako pozicijo mobilnega vozlišča.


4.2.2 Pridobivanje načrtov notranjih okolij

Za potrebe analize in sistematično izvajanje meritev potrebujemo načrte izbranih notranjih okolij. Načrti izbranega okolja omogočajo podrobno analizo meritev glede na postavitev oddajnikov in sprejemnikov ter lažjo vizualno predstavitev rezultatov celotnega procesa izgradnje modelov radijskih kanalov. Nekaj načrtov je možno pridobiti iz projektne dokumentacije, ki je na voljo za posamezno stavbo, kjer se izbrano notranje okolje nahaja. Za podrobnejšo analizo vplivov radijskega okolja na napako izmerjene razdalje med oddajnikom in sprejemnikom z natančnostjo reda centimetrov je pomembno, da mere na načrtih ne odstopajo bistveno od dejanskih mer v okolju. Najbolje je, da bistveno ne presegajo napake 1 cm. Če se razlike med dejanskimi razdaljami in razdaljami, ki jih izračunamo glede na postavitev na podlagi načrtov, razlikujejo preveč, so lahko modeli, ki jih na podlagi teh načrtov izdelamo, napačni in s tem neuporabni.

Za potrebe analize vplivov radijskega okolja na razširjanje signala in lokalizacijo v notranjih okoljih smo zato izdelali nove načrte okolij, ki so temeljili na obstoječih načrtih. Pri izdelavi novih načrtov smo premerili vse razdalje, ki so vnesene v obstoječih načrtih, in jih posodobili z novimi merami, pridobljenimi z laserskim merilnikom razdalj Bosch GLM 120 C. Laserski merilnik GLM 120 C omogoča zelo natančne meritve razdalj na razdaljah med 8 cm in 120 m s tipično točnostjo boljšo od $\pm 7,5$ mm pri največji razdalji ($\pm 1,5$ mm + $\pm 0,05$ mm/m), ki pa v najslabšem primeru ne presega ± 21 mm pri največji razdalji in slabih merilnih pogojih (± 3 mm + $\pm 0,15$ mm/m).

4.2.2.1 Pisarniško okolje

Slika 4.5 prikazuje načrt pisarniškega okolja v prostorih Instituta "Jožef Stefan". Zidovi se po zgradbi v nekaterih primerih razlikujejo med seboj. Zidovi, ki omejujejo pisarniško oko-



Slika 4.5: Načrt celotnega nadstropja v pisarniškem okolju. Notranje dimenzije okolja so $15,4\text{ m} \times 12\text{ m}$.

lje, so nosilni zidovi, ki jih po vsej verjetnosti sestavljajo železobeton, izolacijski materiali in zaključni fasadni sloj. Notranji zidovi so večinoma montažne stene, ki so sestavljene iz nosilne konstrukcije in mavčnih plošč. Na več mestih v tem pisarniškem okolju se nahajajo tudi železobetonski nosilni stebri z nosilnimi elementi za streho, ker je omenjeno pisarniško okolje v podstrešnih prostorih stavbe.

4.2.2.2 Industrijsko okolje

Slika 4.6 prikazuje tloris manjše industrijske hale, kjer se nahaja veliko število strojev za obdelovanje kovin. Ti zaradi svoje goste postavitve predstavljajo številne ovire za razširjanje radijskega signala v prostoru. Konstrukcija zidov je pretežno betonska, strešna konstrukcija in strešna kritina objekta pa sta jekleni.

4.2.2.3 Majhno bivalno okolje v bloku


Slika 4.7 prikazuje tloris garsonjere v bloku, kjer mejne stene sestavljajo predvsem montažni materiali, kot so mavčne plošče, zunanja stena pa je železobetonska.

4.2.2.4 Bivalno okolje v stanovanjski hiši


Slika 4.8 prikazuje tloris podstrešnega stanovanja v stanovanjski hiši, kjer so zunanje stene opečnate, notranje stene pa sestavlja nosilna lesena konstrukcija, izolacijski material (kamena volna) in mavčne plošče.



Slika 4.6: Načrt industrijskega okolja. Notranje dimenzije okolja so $22\text{ m} \times 12,1\text{ m}$.



Slika 4.7: Načrt majhnega bivalnega okolja v bloku. Notranje mere okolja so $3,6\text{ m} \times 6,7\text{ m}$.



Slika 4.8: Načrt bivalnega okolja v nadstropju samostojne stanovanjske hiše. Notranje dimenzije okolja so $9,2\text{ m} \times 12,1\text{ m}$.

Poglavje 5

Modeliranje vpliva okolja na razširjanje signala UWB

Pred modeliranjem vplivov razširjanja signalov UWB v notranjih okoljih na točnost lokalizacije je treba pogledati, kako različne pogoje razširjanja v reprezentativnih notranjih okoljih opisujejo različni statistični parametri profila močnostne zakasnitve signalov UWB. Ustrezen nabor statističnih parametrov lahko namreč uporabimo za izgradnjo modelov za razvrščanje vzorcev in oceno napake izmerjene razdalje z uporabo postopkov strojnega učenja, te modele pa nato uporabimo za izboljšanje točnosti algoritmov za lokalizacijo.


5.1 Predobdelava merilnih rezultatov

V vseh realnih sistemih se iz različnih vzrokov v sistem prikradejo različna odstopanja, ki lahko kljub svoji navidezni nepomembnosti kvarijo model, ki temelji na izmerjenih podatkih. Pred analizo podatkov je zato običajno potrebna predobdelava podatkov, da izločimo osamelce (angl. outliers), enosmerne odstopanja merilnih vrednosti in ostale neželene komponente, ki se pojavijo v podatkovni zbirki.

5.1.1 Kompenzacija enosmerne odstopanja merilne napake

Razdalja, izmerjena na podlagi časa potovanja signala (ToF), zaradi različnih notranjih odstopanj posameznih radijskih modulov UWB odraža enosmerno odstopanje od evklidske razdalje. Vsak neumerjen radijski par UWB izkazuje svoje enosmerne odstopanje. To se v rezultatih merilne napake razdalje kaže kot začetno višje odstopanje, ki z večanjem medsebojne razdalje pada proti manjši vrednosti napake izmerjene razdalje in z nadaljnjim večanjem medsebojne razdalje spet narašča. Na sliki 5.1 je prikazan potek absolutne napake za različne evklidske razdalje med enim parom radijskih modulov UWB. Razvidno je, da zaradi enosmerne odstopanja izmerjene razdalje ravno izmerki, ki predstavljajo najkrajše razdalje LoS, navidez vsebujejo največjo merilno napako, ki pa se z večanjem medsebojne razdalje manjša. Absolutna napaka izmerjene razdalje s povečevanjem medsebojne oddaljenosti narašča, kar se kaže kot navidezno manjšanje enosmerne odstopanja od evklidske razdalje.

Enosmerne odstopanje absolutnih napak izmerjene razdalje lahko kompenziramo tako, da poiščemo najkrajšo evklidsko razdaljo tr_{min} med vsemi evklidskimi razdaljami v množici $\mathbf{R}_e$ v izbranem referenčnem okolju za posamezen radijski par in izbran radijski kanal (5.1). Predpostavimo, da je napaka izmerjene razdalje z umerjenim merilnim parom pri najmanjši evklidski razdalji zanemarljiva. Odstopanje izmerjene razdalje rng_{min} pri najkrajši evklidski razdalji tr_{min} odštejemo vsem izmerjenim razdaljam v množici meritev



Slika 5.1: Slika prikazuje grafa z nekompenziranimi in kompenziranimi napakami izmerjene razdalje.

$\mathbf{R}_m$ (5.2). Na ta način odstranimo enosmerno komponento, ki so jo v podatkovno zbirko vnesli neumerjeni radijski pari UWB in s tem dobimo množico kompenziranih meritev medsebojnih razdalj $\mathbf{R}_t$. Rezultat kompenzacije enosmernega odstopanja izmerjene razdalje prikazuje desni graf na sliki 5.1.


$$tr_{min} = \operatorname{argmin} \{\mathbf{R}_e\} \quad (5.1)$$

$$\mathbf{R}_t = \mathbf{R}_m - (rng_{min} - tr_{min}) \quad (5.2)$$

5.1.2 Detekcija in odstranjevanje osamelcev

V merilnih rezultatih se občasno zaradi različnih vzrokov pojavijo tudi osamelci (angl. outliers). V primeru merjenja razdalje na podlagi informacije ToF in posredno napaki izmerjene razdalje se v mejnih pogojih, ko so moči sprejetih signalov na meji občutljivosti sprejemnika, pojavijo velika odstopanja v izmerjeni razdalji. V mejnih pogojih so moči sprejetih signalov zelo blizu moči šuma. To lahko interni algoritem za detekcijo prve fronte sprejetega signala in določanje časovne oznake zavede, da namesto prve fronte, ki je običajno že pod nivojem šuma, kot prvo fronto zazna eno od zapoznelih komponent poti signala, ki je slučajno presegla nivo šuma. V primeru, ki je prikazan na levem grafu na sliki 5.2, vidimo, da je ena meritev presegla napako 30 m. Tipične največje presežne zakasnitve, ki jih zasledimo v pridobljeni podatkovni zbirki, običajno presegajo 100 ns, ki se preko svetlobne hitrosti prevedejo v razdaljo približno 30 m.

Za detekcijo osamelcev uporabimo pristop, ki temelji na združevanju v gruče (angl. clustering). Izbrani algoritem DBSCAN (angl. density-based spatial clustering of applications with noise) [70] spada med algoritme za združevanje v gruče, ki temeljijo na gostoti elementov v podatkovni zbirki. Kot rezultat poleg zaznanih gruč vrne tudi vse elemente, ki ne spadajo v eno izmed gruč in jih lahko smatramo kot šum ali osamelce. Glavna vhodna parametra N in ϵ algoritma DBSCAN določata najmanjše število sosednjih elementov N , ki se nahajajo znotraj kroga s polmerom ϵ . Algoritem DBSCAN za vsak element v dani podatkovni zbirki poišče vse sosednje elemente, ki se nahajajo znotraj kroga s polmerom ϵ . Elementi, ki imajo znotraj kroga s polmerom ϵ manj kot N sosednjih



Slika 5.2: Prikaz delovanja filtra osamelcev na grafu napake izmerjene razdalje v odvisnosti od medsebojne razdalje.

elementov, se smatrajo kot šum, ostali elementi pa se glede na minimalno gostoto, določeno s parametroma ϵ in N , povežejo v 1 ali več gruč. Za odstranjevanje osamelcev smo v našem primeru izbrali $\epsilon = 0,7$ za najmanjši polmer okolice vzorca in $N = 32$ za najmanjše število drugih vzorcev v okolici izbranega vzorca. Velikosti parametrov sta izbrani tako, da v množici vzorcev odstranimo tiste vzorce, ki zelo močno odstopajo od večine preostalih vzorcev.

DBSCAN algoritem je ravno tako kot algoritem k-means [71] primeren za uporabo na podatkovnih zbirkah z zelo velikim številom elementov, le da algoritem DBSCAN ne zahteva vnaprejšnjega določanja zelenega števila gruč. Za iskanje izjemnih vrednosti smo uporabili implementacijo DBSCAN algoritma znotraj Python knjižnice za strojno učenje scikit-learn [72].


Elemente, ki jih je algoritem DBSCAN označil za šum, odstranimo iz podatkovne zbirke, rezultat odstranjevanja osamelcev pa je prikazan na sliki 5.2, kjer je na desnem grafu zaradi odstranjenih izjemnih vrednosti porazdelitev napak izmerjene razdalje glede na evklidsko razdaljo bolj jasna.

5.2 Analiza podatkovnih zbirk

Z analizo podatkovnih zbirk, pridobljenih v reprezentativnih notranjih okoljih, pridobimo vpogled v odvisnost posameznih statističnih parametrov PDP od pogojev razširjanja signala. Razlike posameznih parametrov v pogojih razširjanja LoS od tistih v pogojih NLoS nam omogočajo razpoznavanje pogojev razširjanja in ocenjevanje vpliva pogojev razširjanja na rezultat meritve medsebojne razdalje med mobilnim senzorskim vozliščem in fiksnim sidrnim senzorskim vozliščem.

Statistični parametri PDP, ki vsak zase nosijo del informacije o pogojih razširjanja signala in jih analiziramo v tem poglavju, so:

- moč sprejetega signala,
- čas vzpona signala,
- energija sprejetega signala,
- povprečna presežna zakasnitev,



Slika 5.3: Odvisnost RSS od razdalje v LoS pogojih v bivalnem okolju.

- RMS razpršitev zakasnitve,
- koeficient simetrije,
- koeficient sploščenosti.

5.2.1 Model izgube poti

Izguba poti je eden glavnih parametrov, ki so pomembni pri načrtovanju komunikacijskih sistemov. Z modelom izgube poti lahko določimo osnovne parametre komunikacijskega sistema, ki ga načrtujemo, kot je na primer močnostna bilanca povezave (angl. link power budget), kar daje možnost ocene območja pokritja signala za posamezna radijska vozlišča v omrežju. Naš namen pri analizi podatkov pridobljenih meritev ni izgradnja modelov, ki bodo služili za načrtovanje novih omrežij UWB, ampak vpogled v razmere v dejanskih notranjih okoljih z uporabo cenovno dostopne komunikacijske opreme. Želimo primerjati modele v realnih okoljih s predlaganimi modeli v tabeli 3.5, ki so jih različni avtorji definirali kot uradne modele za komunikacijski standard IEEE 802.15.4a [54].

Izbrani radijski moduli UWB DWM1000 imajo zaradi nizke cene in primarne funkcije merjenja medsebojne razdalje na podlagi merjenja časa razširjanja signala omejeno sposobnost za merjenje moči sprejetega signala. Vhodna karakteristika izbranega radijskega modula UWB je linearna do točke stiskanja pri odstopanju od linearne karakteristike za 1 dB (angl. 1 dB compression point) pri -39 dBm [73]. To do -65 dBm, ki jih vidimo na karakteristiki na sliki 4.3, dopušča dovolj dinamičnega območja, da vhodni signal še ni popačen. Odstopanje izmerjene moči se pojavi zaradi metode določanja vhodne moči [52]. Notranji algoritem za določanje časa prispetja prve fronte signala namreč sprejema sinhronizacijske simbole prihajajočega paketa UWB in jih poravnane integrira v akumulatorju impulznega odziva kanala. Vrednost sprejete moči vhodnega signala in vhodne moči prve fronte določimo s formulama (4.2) in (4.1). Graf na sliki 4.3 prikazuje na ta način izmerjene vhodne moči sprejetega signala v odvisnosti od prave moči sprejetega signala.

V pogojih NLoS se moči sprejetega signala nahajajo bližje linearnemu merilnemu območju vhodnih moči, zato so tudi interpolirane vrednosti bližje realnim vrednostim, odvisnost

Tabela 5.1: Model izgube poti $PL(d)$ UWB kanala za različna notranja okolja.

	Bivalno okolje 1		Bivalno okolje 1		Pisarniško okolje		Industrijsko okolje	
	LoS	NLoS	LoS	NLoS	LoS	NLoS	LoS	NLoS
PL_0 [dB]	NA	61,2 ($\sigma = 5,75$)	NA	65,5 ($\sigma = 5,52$)	NA	56,3 ($\sigma = 3,72$)	NA	63,5 ($\sigma = 3,20$)
n	NA	4,28	NA	2,98	NA	3,73	NA	0,89
σ_S [dB]	NA	1,91	NA	1,75	NA	1,90	NA	1,46


izmerjene moči (v dBm) od razdalje pa poteka z eksponentom izgube moči n , ki je podoben tistim v tabeli 3.5 po standardu IEEE 802.15.4a. Model izgube poti $PL(d)$ lahko definiramo z enačbo (5.3), kjer PL_0 predstavlja izgubo poti pri referenčni razdalji (običajno 1 m), n je eksponent izgube moči ali naklon odvisnosti izgube poti od razdalje, preostali del enačbe pa opisuje logaritemsko zmanjševanje moči z večanjem razdalje.

$$PL(d) = PL_0 + 10n \log_{10}\left(\frac{d}{d_0}\right) \quad (5.3)$$


Izkaže se, da celo znotraj istega notranjega okolja dobimo različne vrednosti eksponentov in referenčnih slabljenj. Glavni razlog za to je predvsem v postavitvi osmih referenčnih vozlišč in trajektoriji, ki jo opiše mobilno vozlišče. Vsak par mobilno vozlišče - referenčno vozlišče predstavlja drugačen nabor pogojev razširjanja radijskega signala v notranjem okolju. V veliko primerih graf odvisnosti sprejete moči signala od razdalje na enakih razdaljah vsebuje meritve za položaje s povsem različnimi pogoji razširjanja signala. Mobilno vozlišče namreč opiše trajektorijo, ki lahko pride v bližino fiksnega vozlišča na enaki razdalji ampak z različnim številom sten ali ovir na svoji poti. To se jasno vidi predvsem na grafih za fiksni vozlišči A7 in A8 na sliki 5.4, kjer vidimo, da se lahko odvisnost sprejete moči deli na tri ali več različnih funkcij. Zaradi tega smo v vsakem okolju za postavitev modela izgube poti izbrali le tiste odvisnosti, ki ne izražajo več različnih funkcij odvisnosti in okvirno ustrezajo pričakovanim eksponentom izgube poti glede na tiste v standardnem modelu IEEE 802.15.4a [54].

Eksponente izgube poti za vse grafe odvisnosti RSS od razdalje smo zaradi velike razpršenosti vrednosti RSS izračunali tako, da smo najprej celotno območje razdelili na 10 enako velikih območij (glede na razdaljo) in izmerjene vrednosti RSS razporedili v pripadajoča območja. V vsakem območju smo izračunali standardni odklon vrednosti RSS, obratne vrednosti standardnih odklonov vseh območij pa smo uporabili za določanje modela izgube moči z metodo uteženih najmanjših kvadratov. Z uporabo uteži smo dosegli, da optimizacijska funkcija, ki išče najbolj ustrezno linearno funkcijo za model izgube poti, dodeli večjo veljavo mestom na grafu odvisnosti RSS od razdalje, kjer je razpršenost vzorcev manjša. Razliko v določanju eksponenta izgube poti med metodo najmanjših kvadratov in metodo uteženih najmanjših kvadratov prikazuje slika 5.5.

Rezultati modeliranja kanala v posameznih notranjih okoljih kažejo, da sta modela za Bivalno okolje 1 in Pisarniško okolje blizu modelom, ki so definirani v standardu IEEE 802.15.4a. Za Bivalno okolje 2 predvidevamo, da so vzrok za manjši eksponent n izgube poti $PL(d)$ manjše razdalje v prostoru kot pri ostalih notranjih okoljih. V industrijskem okolju pa je zaradi velikih kovinskih površin prisotnih veliko odbojev in s tem zmanjšano slabljenje signala. Zaradi visokih oddajnih moči in manjšega slabljenja signala se velik del meritev moči sprejetega signala nahaja blizu območja zasičenja merilne metode, kar po naših predvidevanjih vpliva na manjši naklon karakteristike slabljenja v odvisnosti od razdalje.



Slika 5.4: Prikaz vpliva več različnih poti v prostoru na graf odvisnosti moči sprejetega signala od razdalje.




Slika 5.5: Prikaz razlike eksponenta izgube poti pri določanju po metodi najmanjših kvadratov (LS) in po metodi uteženih najmanjših kvadratov (WLS).

5.2.2 Čas vzpona profila močnostne zakasnitve

Čas vzpona signala T_r opisuje, kako hitro vhodni signal od svoje začetne vrednosti doseže največjo moč. Ta parameter nosi informacijo o obliki profila močnostne zakasnitve, ki lahko zelo dobro služi kot eden od parametrov v procesu razvrščanja vzorcev na vzorce LoS in vzorce NLoS. V razmerah z neposredno vidljivostjo (LoS) je začetek profila močnostne zakasnitve vedno najvišja vrednost celotnega profila, ker je signal v pogojih z neposredno vidljivostjo po direktni poti vedno najmanj oslavljen in najmanj zakasnen. V pogojih brez neposredne vidljivosti (NLoS) je direktna pot prekinjena z ovirami in je zato direktna pot bolj oslABLjena od poti, ki jih signal z odboji naredi okoli ovir. Sprejemno anteno v pogojih NLoS zato običajno prve zadenejo šibkejšje komponente direktne poti, nato pa sledijo še zakasnjene in manj oslABLjene komponente alternativnih poti. V pogojih NLoS je zato pričakovati obliko profila močnostne zakasnitve z nizkimi začetnimi vrednostmi, počasnim naraščanjem do največje vrednosti in potem spet upadanjem moči vhodnega signala.

Zgolj čas vzpona signala za razvrščanje na vzorce LoS in NLoS ne zadošča, ko so pri razširjanju ovirane prav vse komponente sprejetega signala. Če komponente ostalih poti ne morejo okrog ovir z odboji oz. če so odboji ravno tako oslABLjeni z razširjanjem skozi ovire, predpostavka o počasnem naraščanju profila močnostne zakasnitve ne velja več. Lahko se nam zgodi, da je signal NLoS videti podoben signalom LoS, le da opazimo nižje vrednosti moči vhodnega signala. Na sliki 5.6 vidimo prikaz takih situacij. Narejena je primerjava med enim vzorcem LoS in dvema vzorcema NLoS. Prvi vzorec NLoS je predstavnik skupine s počasnim naraščanjem moči vhodnega signala in s tem daljšim časom vzpona signala T_r , drugi vzorec NLoS pa je predstavnik skupine, ki po obliki spominja na vzorce LoS in ga opisuje manjši čas vzpona T_r .

Rezultati analize časov vzpona signala na celotni podatkovni zbirki so prikazani v tabeli 5.2. Iz povprečnih vrednosti časov vzpona signala za posamezna notranja okolja lahko vidimo, da se vrednosti T_r za pogoje LoS opazno razlikujejo od tistih za pogoje NLoS. Ravno tako so večje največje vrednosti T_r za pogoje NLoS. Bivalni okolji in pisarniško okolje opisujejo dokaj podobne vrednosti T_r . Industrijsko okolje zaradi številnih kovinskih površin



Slika 5.6: Grafi prikazujejo primerjavo različnih LoS in NLoS vzorcev.

Tabela 5.2: Tabela časov vzpona vhodnega signala.

LoS			
	Čas vzpona signala [ns]		
	min	max	mean
Bivalno okolje 1	1,0	27,0	4,6
Bivalno okolje 2	2,0	18,0	4,4
Industrijsko okolje	1,0	58,1	7,3
Pisarniško okolje	1,0	23,0	5,2
Vsa okolja	1,0	58,1	5,4
NLoS			
	Čas vzpona signala [ns]		
	min	max	mean
Bivalno okolje 1	1,0	69,1	10,8
Bivalno okolje 2	1,0	37,1	7,8
Industrijsko okolje	1,0	82,1	17,1
Pisarniško okolje	1,0	42,1	10,1
Vsa okolja	1,0	82,1	11,7

in kovinskih delov okolja povečuje število odbojev in s tem podaljšuje presežne zakasnitve sprejetih signalov, v okolju NLoS pa omogoča sprejetje večjega števila komponent poti.

5.2.3 Energija sprejetega signala

Energija sprejetega signala E_{RX} opisuje količino sprejete energije znotraj enega sprejetega simbola sinhronizacijske sekvence. Ravno tako kot moč sprejetega signala energija sprejetega radijskega signala opisuje, kolikšen delež oddane energije smo prejeli na strani sprejemnika. Energijo sprejetega signala izračunamo tako, da seštejemo produkte časovnih enot profila močnostne zakasnitve (angl. bins) z njihovo širino. Za izračun energije sprejetega signala moramo postaviti meje profila močnostne zakasnitve vhodnega signala. Kot pri prejšnjih analizah smo za začetek profila močnostne zakasnitve izbrali začetek prve fronte signala, za končno mejo pa smo izbrali mesto, kjer profil močnostne zakasnitve pade pod nivo šuma, zvišanega za 3 dB. Energijo sprejetega signala izračunamo po enačbi (3.23), kjer $P_{PDP}(n)$ predstavlja moč profila močnostne zakasnitve v točki n , Δt je širina časovnega razdelka profila močnostne zakasnitve, ki pri radiu DW1000 UWB znaša $1,0016 ns$, N pa predstavlja število časovnih razdelkov profila močnostne zakasnitve v mejah od začetka prve fronte, pa do točke, kjer moč signala pade pod nivo šuma, povečanega za 3 dB.

Tabela 5.3: Tabela energij sprejetih signalov.

LoS			
	Energija sprejetega signala [μJ]		
	min	max	mean
Bivalno okolje 1	$2,59 \cdot 10^{-5}$	1,76	0,38
Bivalno okolje 2	$4,98 \cdot 10^{-7}$	1,81	0,46
Industrijsko okolje	$3,80 \cdot 10^{-4}$	2,92	0,37
Pisarniško okolje	$0,18 \cdot 10^{-4}$	1,74	0,42
Vsa okolja	$4,98 \cdot 10^{-7}$	2,82	0,42
NLoS			
	Energija sprejetega signala [μJ]		
	min	max	mean
Bivalno okolje 1	$3,20 \cdot 10^{-7}$	1,49	0,10
Bivalno okolje 2	$6,84 \cdot 10^{-6}$	1,87	0,21
Industrijsko okolje	$2,68 \cdot 10^{-5}$	1,81	0,10
Pisarniško okolje	$1,42 \cdot 10^{-7}$	1,61	0,09
Vsa okolja	$1,42 \cdot 10^{-7}$	2,94	0,11

V tabeli 5.3 so prikazani rezultati analize sprejete energije signalov za vsa štiri notranja okolja, ločeno za pogoje LoS in pogoje NLoS. Rezultati kažejo, da so sprejete energije v pogojih NLoS v povprečju manjše od sprejetih energij v pogojih LoS, glede na informacijo pa težje interpretiramo, kako zahtevno je izbrano radijsko okolje. Iz vrednosti energije sprejetega signala lahko samo razberemo, kako je bil signal na svoji poti oslabljen, ne vemo pa, na kakšen način je prispel do sprejemnika, kot je to nekoliko bolj razvidno iz časa vzpona signala. V kombinaciji z drugimi statističnimi parametri profila močnostne zakasnitve je lahko energija sprejetega signala poleg moči sprejetega signala in moči prve fronte sprejetega signala še vedno uporabna za razvrščanje vzorcev LoS in NLoS ter napovedovanje napake izmerjene razdalje.

5.2.4 Izračun presežnih zakasnitev signala

Presežna zakasnitev (angl. excess delay) signala opisuje značilnost radijskega kanala, da vsa oddana energija ne doseže sprejemnika naenkrat, ampak je porazdeljena v času glede na odboje, ki so jim signali podvrženi v vseh realnih okoljih. Največja presežna zakasnitev opisuje čas, ki ga izmerimo od prve sprejete komponente poti, pa do zadnje komponente sprejetega signala, ki jo še lahko ločimo od šuma oziroma je višja od določenega nivoja (npr. 10 dB manjša moč od najmočnejše komponente). Pomembna mera za velikost presežnih zakasnitev je RMS razpršitev zakasnitev (angl. RMS delay spread), ki predstavlja standardni odklon od povprečne vrednosti zakasnitev (angl. mean excess delay) komponent poti, uteženih glede na energijo posameznih komponent.

Saleh in Valenzuela [74] sta naredila obsežne meritve v prostorih Bellovih laboratorijev in potrdila, da so vrednosti RMS razpršitve zakasnitev odvisne predvsem od okolice oddajnika in sprejemnika, ne pa od razdalje med njima, kot so pred njima predvidevali nekateri drugi avtorji [54], [75]. Informacija o presežnih zakasnitvah je tako dobra dopolnilna mera za oceno pogojev razširjanja radijskega signala, ki za razliko od parametrov modela Saleh-Valenzuela ni reverzibilna. Pomaga lahko pri primerjavi meritev razširjanja radijskega signala v različnih radijskih okoljih v različnih merilnih kampanjah ter kot dodatni parameter za razvrščanje pogojev razširjanja radijskega signala.

Tabela 5.4: Tabela presežnih zakasnitev UWB.

LoS						
	RMS razpršitev zakasnitve [ns]			Povprečna presežna zakasnitev [ns]		
	min	max	mean	min	max	mean
Bivalno okolje 1	2,7	22,6	10,3	4,7	40,7	19,1
Bivalno okolje 2	2,0	25,9	9,6	3,7	48,0	17,9
Industrijsko okolje	2,3	75,1	31,5	4,6	132,9	56,6
Pisarniško okolje	2,7	28,2	12,7	4,6	50,6	23,4
Vsa okolja	0,5	74,3	16,4	1,5	125,2	29,9
NLoS						
	RMS razpršitev zakasnitve [ns]			Povprečna presežna zakasnitev [ns]		
	min	max	mean	min	max	mean
Bivalno okolje 1	1,5	44,5	18,5	3,4	79,1	33,2
Bivalno okolje 2	2,7	36,9	17,6	4,7	68,9	31,9
Industrijsko okolje	2,4	77,3	42,9	4,7	133,8	76,1
Pisarniško okolje	0,8	77,6	24,0	2,0	137,4	42,9
Vsa okolja	0,5	79,6	25,8	1,5	145,7	46,1

5.2.4.1 Povprečna presežna zakasnitev

Povprečna presežna zakasnitev je preprosto statistično povprečje zakasnitev znotraj PDP, ki ji je podvržen radijski signal pri razširjanju v kompleksnem radijskem kanalu. Povprečno presežno zakasnitev izračunamo kot prvi statistični moment časovnega profila moči sprejetega signala $P(\tau)$, kar opisuje enačba 3.33.

V tabeli 5.4 so v stolpcih s povprečnimi presežnimi zakasnitvami prikazane vrednosti za posamezna notranja okolja, ločeno tudi glede na stanja LoS in NLoS radijskega kanala. Zajete so najmanjše, največje in povprečne vrednosti povprečnih presežnih zakasnitev na radijskih kanalih v izbranih notranjih okoljih. Rezultati kažejo, da so povprečne vrednosti za pogoje LoS v posameznih okoljih opazno manjše od povprečnih vrednosti za razmere NLoS.

5.2.4.2 RMS razpršitev zakasnitve

RMS razpršitev zakasnitve (ang. RMS delay spread) predstavlja standardni odklon vrednosti presežnih zakasnitev proporcionalno uteženih s pripadajočo sprejeto energijo. Izračunamo ga kot drugi centralni moment PDP signala $P(\tau)$. RMS razpršitev zakasnitve izračunamo po enačbi (3.34).

V tabeli 5.4 v stolpcih z RMS razpršitvami zakasnitev opazimo podoben vzorec kot pri povprečnih vrednostih povprečnih presežnih zakasnitev. Povprečne vrednosti RMS razpršitev zakasnitev v pogojih NLoS so torej opazno večje od povprečnih vrednosti RMS razpršitev zakasnitev v pogojih LoS.

5.2.5 Izračun statističnih parametrov oblike profila močnostne zakasnitve signala

V teoriji verjetnosti in statistiki imamo na razpolago merila oblike porazdelitve realne slučajne porazdelitve. Uporabimo jih lahko za ovrednotenje oblike posamezne močnostne zakasnitve signala, z njimi pa lahko opišemo, v katero smer je nagnjen vrh PDP ali pa kako razpotegnjen, ali z drugimi besedami, kako potlačen je PDP. V literaturi, ki obravnava razvrščanje na vzorce LoS in vzorce NLoS, zasledimo poleg ostalih že omenjenih parametrov tudi uporabo koeficienta simetrije (angl. skewness) [62] in koeficienta sploščenosti

Tabela 5.5: Tabela koeficientov simetrije.

LoS			
	Koeficient simetrije		
	min	max	mean
Bivalno okolje 1	-0,74	2,55	1,19
Bivalno okolje 2	-1,05	2,91	1,14
Industrijsko okolje	-1,49	3,49	1,24
Pisarniško okolje	-0,58	2,78	1,31
Vsa okolja	-2,94	3,37	1,20
NLoS			
	Koeficient simetrije		
	min	max	mean
Bivalno okolje 1	-2,38	3,45	0,48
Bivalno okolje 2	-1,80	2,75	1,00
Industrijsko okolje	-1,50	3,12	0,29
Pisarniško okolje	-2,21	3,26	0,47
Vsa okolja	-2,94	3,48	0,49

(angl. kurtosis) [63], [64], [76], [77].

5.2.5.1 Koeficient simetrije

Koeficient simetrije γ_1 je tretji standardizirani moment slučajne spremenljivke, ki ga izračunamo po enačbi (3.30).

Koeficient simetrije γ_1 ima negativno vrednost, ko je porazdelitev nagnjena v desno ali ko je levi del porazdelitve do največje vrednosti daljši od desnega dela porazdelitve od največje vrednosti naprej. Pozitivni koeficient γ_1 opisuje porazdelitev, ki je nagnjena bolj v levo, torej ko je levi del porazdelitve do največje vrednosti krajši od desnega dela porazdelitve. Pri simetričnih porazdelitvah je koeficient simetrije γ_1 enak 0, povprečna vrednost porazdelitve pa je enaka mediani.

V tabeli 5.5 so prikazane najmanjše, največje in povprečne vrednosti koeficientov simetrije za posamezna notranja okolja. Rezultirajoče vrednosti kažejo, da so vrednosti simetrije višje v pogojih LoS kot pa v pogojih NLoS. Rezultati odražajo lastnost večine vzorcev LoS, da je večina energije oddanega signala porazdeljena bolj proti začetku PDP, pri vzorcih NLoS pa je malenkost premaknjena v desno smer, kar potrjujejo tudi rezultati analize časov vzponov v poglavju 5.2.2

5.2.5.2 Koeficient sploščenosti

Koeficient sploščenosti γ_2 je četrti standardizirani centralni moment verjetnostne porazdelitve realne slučajne spremenljivke. Tipično koeficient sploščenosti opisuje, kako je porazdelitev slučajne spremenljivke razpotežnjena v primerjavi z največjo vrednostjo. Večja vrednost sploščenosti opisuje tudi večjo varianco zaradi osamelcev (angl. outliers). Koeficient sploščenosti γ_2 izračunamo po enačbi (3.32). Sploščenost normalne porazdelitve je enaka 3.

V tabeli 5.6 so zbrane najmanjše, največje in povprečne vrednosti koeficientov sploščenosti za posamezna notranja okolja.

Tabela 5.6: Tabela koeficientov sploščenosti.

LoS			
	Koeficient sploščenosti		
	min	max	mean
Bivalno okolje 1	1,22	9,98	3,86
Bivalno okolje 2	1,00	10,76	3,60
Industrijsko okolje	1,31	20,91	6,41
Pisarniško okolje	1,25	12,38	4,41
Vsa okolja	1,00	20,59	4,58
NLoS			
	Koeficient sploščenosti		
	min	max	mean
Bivalno okolje 1	1,21	14,78	3,89
Bivalno okolje 2	1,23	11,37	4,23
Industrijsko okolje	1,26	17,52	4,37
Pisarniško okolje	1,09	14,27	4,10
Vsa okolja	0,99	18,08	4,13

Poglavje 6

Razpoznavanje pogojev razširjanja radijskega signala z globokim učenjem

Področje strojnega učenja se že desetletja ukvarja z razvijanjem in analizo uporabe računalniških sistemov za izgradnjo matematičnih ali statističnih modelov. Modeli se lahko z uporabo stalno izboljšujejo. Za izgradnjo modela se tipično uporablja vhodne podatke (vzorci), ki kolikor se da dobro opisujejo sistem, ki ga hočemo z metodami strojnega učenja opisati. Modeli, zgrajeni z metodami strojnega učenja, se nato uporabljajo za razpoznavanje, napovedovanje ali odločanje.

6.1 Pregled obstoječih pristopov s strojnim učenjem

V večini primerov se uporablja pristope nadzorovanega učenja (angl. supervised learning), kjer model za razvrščanje ali pa model za napovedovanje učimo nadzorovano z vzorci, za katere vemo, kateremu razredu pripadajo oz. kakšno vrednost imajo. Na področju podatkovnega rudarjenja se veliko uporabljajo postopki nenadzorovanega učenja (angl. unsupervised learning), predvsem v postopkih razvrščanja v skupine (angl. clustering), kjer algoritem brez nadzora učitelja sam ugotovi število kategorij in njihove značilnosti. Tretji pristop pri strojnem učenju pa je vzpodbujevalno učenje (angl. reinforcement learning), kjer učenje algoritma nadzorujemo z nagrajevanjem in kaznovanjem.

Na področju modeliranja razširjanja radijskih signalov in modeliranja vplivov okolja na učinkovitost lokalizacije nas zanimajo predvsem metode nadzorovanega učenja. Z njimi na podlagi vhodnih podatkov, ki jih pridobimo z meritvami v realnih okoljih, zgradimo modele za razpoznavanje stanj radijskega kanala in za napovedovanje oz. oceno prispevka radijskega okolja k napaki izmerjenega časa razširjanja radijskega signala.

Konvencionalne metode strojnega učenja za uspešno izgradnjo modela zahtevajo ustrezno predpripravo vhodnih podatkov, kjer iz kompleksnejših vhodnih podatkov z različnimi postopki izluščimo značilke, ki številčno opisujejo značilnosti vhodnega vzorca. S predhodno obdelavo vhodnim podatkom zmanjšamo dimenzije in s tem omogočimo, da učni proces modela poteka uspešno. Luščenje značilk iz vhodnih podatkov običajno zahteva premišljeno načrtovanje z veliko domenskega znanja [78].

Pomembni predstavniki algoritmov strojnega učenja so odločitvena drevesa [79], ki z obliko, ki spominja na miselni vzorec, domenskim strokovnjakom omogočajo vpogled v odločitveni proces. Odločitvena drevesa so zelo občutljiva na majhne spremembe v vrednostih odločitvenih parametrov, kar lahko povzroči velike spremembe v strukturi samega

drevesa že z zelo majhnimi spremembami v učni množici. Zasledimo lahko tudi več primerov uporabe Gaussovih procesov [64], [80], [81], ki poleg informacije o pripadajočem razredu vhodnega vzorca vračajo tudi informacijo o pripadajoči negotovosti. Zaradi majhne računske kompleksnosti so primerni tudi za uporabo na mobilnih napravah z nizko računsko zmogljivostjo, poleg tega pa za izgradnjo modela zadostuje že manjše število učnih vzorcev [81]. Zelo pomembno vlogo na področju strojnega učenja imajo tudi linearni razvrščevalniki, kot sta na primer metoda podpornih vektorjev z linearnim jedrom (angl. support vector machine, SVM) in logistična regresija. Ti razvrščevalniki v veliko primerih dosegajo podobne učinkovitosti pri razvrščanju kot nelinearni razvrščevalniki [82].

V literaturi, ki obravnava detekcijo pogojev razširjanja signala UWB brez neposredne vidljivosti (NLoS), in v literaturi, ki se ukvarja z izboljševanjem algoritmov za lokalizacijo in sledenje, so avtorji uporabili predvsem pristope, ki slonijo na luščenju značilk in uporabi že dostopnih značilk, ki jih vrača komunikacijska oprema (RSS, razdalja, nivo šuma ipd.). Najenostavnejši primeri obsegajo zgolj uporabo praga za detekcijo pogojev NLoS [83]–[85]. Zasledimo veliko primerov, ko avtorji uporabijo enostavni binarni test hipoteze (angl. binary hypothesis testing) [62], [86]–[89] ali pa test razmerja verjetnosti (angl. likelihood ratio test) [60], [90]–[92]. V kar nekaj primerih, kjer za detekcijo pogojev razširjanja uporabijo eno od metod strojnega učenja, se pojavi ena od oblik metode podpornih vektorjev (SVM) [61], [63], [65], [93] ali pa so avtorji primerjali različne kombinacije omenjenih pristopov [64], [81], [94].

Vsi omenjeni pristopi temeljijo na ročnem luščenju značilk iz vhodnih podatkov pred začetkom učnega postopka. Za razliko od ročnega postopka se področje reprezentacijskega učenja (angl. representation learning) ukvarja z metodami, ki so sposobne iz surovih vhodnih podatkov same izluščiti značilke za razvrščanje ali napovedovanje [78]. V skupino metod reprezentacijskega učenja spadajo tudi metode globokega učenja, ki zajemajo različne večplastne strukture umetnih nevronov, povezane v globoke nevronske mreže. Pri metodah globokega učenja gre za večnivojske predstavitve vhodnih podatkov, kjer vsaka plast nevronov pretvori vhodne podatke iz vhoda ali iz predhodne plasti v novo bolj abstraktno predstavitev podatkov. Z zadostnim številom transformacijskih plasti dosežemo, da se je sposobno globoko nevronske omrežje naučiti zelo kompleksnih funkcij.

Ključna komponenta za razvoj področja reprezentacijskega učenja, globokih nevronske mreže in umetnih nevronske mreže nasploh, je bilo odkritje, da je možno nevronske strukture učinkovito učiti z metodo vzvratnega razširjanja (angl. backpropagation) [95]. Bistveni za razvoj so bili tudi iterativni optimizacijski algoritmi, kot je na primer stohastični gradientni spust (angl. stochastic gradient descent, SGD) ter njegove nadgradnje in izpeljanke, kot so AdaGrad [96], RMSprop [97], [98], SGD Nesterov [97], [98], AdaDelta [99], Adam [100] in ostali.

Zaradi skorajda neomejenih možnosti, kako lahko povežemo osnovne gradnike umetnih nevronske mreže, obstaja veliko število različnih arhitektur algoritmov globokega učenja. Umetna nevronska mreža, ki se uporablja za učinkovito nenadzorovano kodiranje, je avtoenkoder [101]. Avtoenkoder z zaporednimi plastmi nevronske mreže poizkuša čim učinkoviteje zmanjšati dimenzije vhodnih podatkov, jih zakodirati in nato z zaporedjem plasti za rekonstrukcijo spet čim boljje reproducirati. Naslednji pomembni predstavniki so mreže globokega prepričanja (angl. deep belief networks, DBN), ki spadajo med generativne grafične modele, sestojijo pa iz zaporedja skritih nevronske plasti brez povezav med elementi znotraj plasti. Običajno so sestavljena iz zaporedja nenadzorovano naučenih omejenih Boltzmannovih strojev (angl. restricted Boltzmann machine, RBM). Tipično se učni postopek deli na dva dela: nenadzorovani učni postopek za avtomatsko luščenje značilk in nadzorovani postopek učenja, kjer strukturo pripravimo za razvrščanje vzorcev (uteži iz prve faze uporabimo kot začetne uteži za drugo nadzorovano fazo učenja) [102], [103]. Mrežam DBN

sledijo generativne nasprotujoče mreže (angl. generative adversarial network, GAN) s področja nenadzorovanega globokega učenja, kjer dve vzporedni nevronske mreži (generativna in diskriminatorna) tekmujeta v igri z ničelno vsoto (zero-sum game) [104]. Cilj generativne mreže je, da z ustvarjanjem vzorcev poizkuša prelatiti diskriminatorno mrežo, da so vhodni podatki del učne množice. Najbolj poznan rezultat generativno-diskriminatornega procesa so sintetične slike, ki so v večini primerov na prvi pogled zelo realistične [105]. Diskriminatorna mreža je običajno konvolucijska nevronska mreža [106], generativna mreža pa dekonvolucijska nevronska mreža [107].

Zelo pomembna družina nevronske mreže so tudi povratne nevronske mreže (angl. recurrent neural network, RNN), ki so za razliko od ostalih tipov sposobne upoštevati tudi časovno komponento in so zato primerne predvsem za modeliranje časovnih zaporedij in zaporedij nasploh (analiza teksta, razpoznavanje govora, razpoznavanje pisane besede, sinteza govora iz besede, strojno prevajanje itd.) [108], [109]. Izkaže se, da je učenje dolgotrajnih odvisnosti zelo zahtevno [110]. Kot rešitev so se pojavile mreže z dolgim kratkotrajnim spominom (angl. long short-term memory, LSTM) s posebej vgrajenimi spominskimi celicami. To jim omogoča, da si zapomnijo informacije za zelo dolga časovna obdobja [111]. Mreže LSTM so se izkazale za zelo učinkovite v primerjavi z običajnimi mrežami RNN, saj v praksi zasledimo celotne sisteme za razpoznavanje govora, ki zajemajo tako akustično analizo govora kot tudi pretvorbo v besedilo [112].

Omeniti je vredno še rekurzivne nevronske mreže (angl. recursive neural networks), ki imajo sposobnost modeliranja hierarhičnih struktur v učni množici [113], zaradi česar so uporabne za hierarhično razčlenjevanje (povezanost in medsebojna odvisnost komponent) grafičnih scen in povedi v naravnem jeziku.

Najbolj vidni predstavniki globokih nevronske mreže in vzrok za preporod zanimanja za uporabo globokega učenja na vseh področjih, predvsem pa na področju strojnega vida, so konvolucijske nevronske mreže (angl. convolutional neural network, CNN) [106], [114]. Zaradi enostavnejšega in zanesljivejšega postopka učenja v primerjavi z nevronske mreže s polno povezanostjo med nevroni so konvolucijske nevronske mreže doživele razcvet ravno v obdobju, ko so nevronske mreže zaradi takrat poznanih omejitev veljale za manj kompetentne v primerjavi z ostalimi pristopi modeliranja [78].

Konvolucijske nevronske mreže izkoriščajo svojo hierarhično strukturo s souporabo uteži, ki ne potrebuje predhodne obdelave podatkov z luščenjem značilnosti in so zaradi tega po kompleksnosti med enostavnejšimi nevronske mreže. Zaradi neobčutljivosti na zamik vhodnih podatkov so konvolucijske nevronske mreže idealne za razpoznavanje vzorcev na slikah, v različnih časovnih vrstah (zvočno, razpoznavanje govora, meritve velikosti, itd.), jezikovnih tehnologijah, videu in drugje. Ker so na področju razpoznavanja vzorcev na slikah in pri jezikovnih tehnologijah konvolucijske nevronske mreže dosegle tako veliko prednost pred ostalimi pristopi strojnega učenja in ker so impulzni odzivi kanalov ter pripadajoči profili časovnih zakasnitev zelo podobni časovnim vrstam in v eni dimenziji še vedno vizualni, pričakujemo, da so ustrezna izbira za izgradnjo modelov za razpoznavanje različnih pogojev razširjanja radijskega signala in ocenjevanje napake izmerjene razdalje. Poleg naštetih prednosti v primerjavi s klasičnimi pristopi strojnega učenja konvolucijske nevronske mreže ne potrebujejo predhodne obdelave podatkov in ročne luščenosti značilnosti.

6.2 Konvolucijske nevronske mreže

Za izgradnjo razvrščevalnega modela za detekcijo pogojev NLoS in za ocenjevanje izmerjene napake razdalje med senzorske vozlišči na podlagi impulznega odziva kanala smo izbrali konvolucijske nevronske mreže. Zaradi njihovih sposobnosti učenja zelo kompleksnih modelov in zmanjšane občutljivosti na zamik vhodnih podatkov (angl. input shift invariance)

omogočajo izgradnjo modelov, ki delujejo na vhodnih podatkih brez predhodne kompleksne obdelave. Predlagani algoritmi delujejo na surovih podatkih o impulznem odzivu kanala, ki jih pridobimo direktno z impulznega radia UWB DW1000 v lokalizacijskih sistemih, ki delujejo v realnem času.

Značilnost konvolucijskih nevronske mreže je, da jih lahko za sprejem želene oblike vhodnih podatkov v času načrtovanja poljubno organiziramo. Najbolj pogosti tipi vhodnih podatkov na področju uporabe konvolucijskih nevronske mreže so barvne slike, ki skupaj z barvnimi kanali zavzamejo 3 dimenzije, sivinske slike in razni spektrogrami zavzamejo 2 dimenziji, sekvence in vzorčni signali pa so običajno predstavljeni z enodimenzionalnimi matrikami. Glavne značilnosti so lokalna povezanost nevronov, skupna raba uteži znotraj iste mape značilk, združevalne plasti in globoka arhitektura mreže (uporaba večjega števila plasti).

6.2.1 Zgradba konvolucijskih nevronske mreže

Konvolucijske nevronske mreže so sestavljene iz različnega števila nevronske plasti. Tu gre predvsem za različna zaporedja konvolucijske plasti in združevalne plasti (angl. pooling layer). Na splošno konvolucijske nevronske mreže sestavljajo naslednji tipi plasti:

- konvolucijska plast (angl. convolutional layer),
- aktivacijska plast (angl. activation layer),
- združevalna plast (angl. pooling layer / spatial reduction layer),
- polno povezana nevronska plast (angl. fully-connected layer),
- izhodna plast (angl. output layer).

6.2.1.1 Konvolucijska nevronska plast

Posamezna konvolucijska plast je sestavljena iz množice umetnih nevronov, ki so razdeljeni v več ločenih map značilk (angl. feature maps). Vsak nevron je z naborom uteži znotraj svojega sprejemnega polja (angl. receptive field) lokalno povezan na pripadajoč del vhodnih podatkov ali mape značilk predhodne plasti. Znotraj iste mape značilk si nevroni delijo enak nabor uteži oziroma banke filtrov (angl. filter banks), kar navzven matematično deluje kot diskretna konvolucija, od koder so konvolucijske plasti tudi dobile ime. Vsaka mapa značilk si deli drugačen nabor uteži, s čimer dosežemo, da iz vhodnih podatkov z eno konvolucijsko plastjo izluščimo različne nabore značilk, ki opisujejo različne značilnosti vhodnega signala. Lokalne skupine vrednosti v podatkovni matriki ali vektorju so običajno močno korelirane, predstavljajo določene značilnosti/motiv, ki se lahko ponavljajo na več mestih v matriki. Z različnimi nabori uteži (banke filtrov) pa iz istih vhodnih podatkov izluščimo različne nabore značilk [78].

6.2.1.2 Aktivacijska plast

Konvolucijski plasti sledi aktivacijska plast, ki vsakemu izhodnemu nevronu predhodne konvolucijske plasti določi aktivacijsko funkcijo. Aktivacijska funkcija nevrona je tista funkcija, ki določa preslikavo med vsoto uteženih vhodov nevrona in s tem njegov izhodni signal. Če je aktivacijska funkcija nevrona linearna, vhod v aktivacijsko funkcijo pa je linearna kombinacija vhodnih vrednosti, lahko nevronu določimo le linearno prenosno funkcijo, kar pa za modeliranje nelinearnih sistemov ni primerno. Aktivacijska funkcija mora zato vnašati določeno nelinearnost, da se je celotno nevronske omrežje sposobno naučiti kompleksnih nelinearnih preslikav med vhodom in izhodom. Zaradi svoje računske učinkovitosti je predvsem v globokih učnih strukturah najbolj razširjena aktivacijska funkcija ReLU

(angl. rectified linear unit), ki v praksi predstavlja polvalni usmernik $f(z) = \max(z, 0)$ [78].

6.2.1.3 Združevalna plast

Naslednja pomembna sestavna enota konvolucijskih nevronskih mrež je plast za zmanjševanje števila značilk v nevronske mreži (angl. spatial reduction layer) ali drugače združevalna plast (angl. pooling layer). Ta z vzorčenjem izhodov predhodne plasti zmanjša dimenzije izhoda in s tem zmanjša vpliv položaja zaznanih značilk na končni rezultat. Poleg manjšega vpliva položaja značilk na končni rezultat združevalna plast tudi zmanjša število uteži in s tem število učinkivih parametrov v nadaljnjih plasteh nevronske mreže. V združevalni plasti se kot združevalno funkcijo pogosto uporablja funkcija ohranjanja maksimalnih vrednosti (angl. max pooling). Ta izmed vseh vrednosti znotraj združevalnega okna (angl. pooling window) izbere najvišjo vrednost in jo posreduje naslednji plasti. Velikost združevalnega okna in korak združevanja (angl. stride) določata, kako močno se zmanjšajo dimenzije izhoda predhodne plasti. Če je na primer širina združevalnega okna $w_{pool} = 2$ in če je korak $s_{pool} = 2$, potem funkcija ohranjanja maksimalne vrednosti v enodimenzionalnem primeru izmed dveh vrednosti v združevalnem oknu izbere najvišjo in se po vhodnem vektorju premakne za dve enoti naprej. Na ta način se vhodne dimenzije zmanjšajo za faktor 2. Dobra praksa glede na literaturo je, da število uteži skozi celotno konvolucijsko nevronske mrežo ostaja konstantno. Za združevalno plastjo lahko tako v primeru skrčenja za faktor 2 v naslednji konvolucijski plasti podvojimo število map značilk in s tem število uteži [115].

6.2.1.4 Polno povezana nevronska plast

Nizu konvolucijskih in združevalnih plasti običajno sledi še polno povezana nevronska plast (angl. fully connected layer), kjer je vsak posamezen nevron povezan na vse izhode predhodne plasti. Kombinacija konvolucijskih plasti in združevalnih plasti namreč deluje kot enota za avtomatsko predobdelavo vhodnih podatkov, ki nadomesti tradicionalno kompleksno izluščanje značilk (angl. feature extraction). Polno povezana plast običajno svoje izhode preda izhodni nevronske plasti (angl. readout layer), ki nosi informacijo o razpoznavnem razredu vhodnih podatkov.

6.2.1.5 Izhodna plast

Izhodna plast je zaključna plast konvolucijske nevronske mreže, ki poskrbi za ustrezno preslikavo informacij na izhodih polno povezane nevronske plasti v prostor rezultatov. Tu gre lahko za pretvorbo množice izhodov polno povezane plasti v oznake razredov ali pa zgolj v linearno preslikavo zvezne spremenljivke, ki jo s konvolucijskim nevronske modelom napovedujemo oz. ocenjujemo.

6.2.2 Postopek učenja konvolucijske nevronske mreže

Učenje nevronskih mrež z velikim večdimenzionalnim prostorom parametrov zahteva uporabo učinkovitih učnih in optimizacijskih algoritmov. Kriterijske funkcije (angl. objective function) so pogosto stohastične zaradi vmesnega zmanjševanja dimenzij, regularizacije z naključnim izpuščanjem (angl. dropout regularization) in ostalih virov šuma.

6.2.2.1 Vzratno razširjanje napake

Najpomembnejši koncept za učenje globokih nevronskih mrež in koncept, ki je sploh omogočil razvoj večplastnih nevronskih struktur, je postopek vzratnega razširjanja napake

(angl. backpropagation) [95]. Po postopku vzratnega razširjanja napake najprej izračunamo gradient kriterijske funkcije glede na uteži nevronske mreže ter vhodne in izhodne podatke. V praksi se za postopek računanja gradientov uporablja verižno pravilo za odvajanje (angl. chain rule), kjer izračunamo gradient kriterijske funkcije glede na vhodne podatke, tako da izračunamo gradient glede na izhodne podatke in napake izhodnih podatkov. Vzratno razširjanje napake torej deluje na podlagi razširjanja izhodnih napak nazaj proti vhodu.

6.2.2.2 Optimizacija z metodami gradientnega spusta

Vzratno razširjanje napake je le metoda za računanje in razširjanje gradientov po nevronske mreži. Za učinkovito učenje je potreben še ustrezen optimizacijski algoritem, ki uporablja vzratno razširjanje napake za izračun gradientov kriterijske funkcije in postopoma spreminja uteži povezav med elementi nevronske mreže ter s tem čim bolj minimizira kriterijsko funkcijo.

Večina optimizacijskih metod za učenje globokih nevronske mreže temelji na metodi gradientnega spusta [98]. Gradientni spust minimizira kriterijsko funkcijo $J(\mathbf{W})$ pri utežeh v nevronske mreži $\mathbf{W} \in \mathbb{R}^d$ s popravljanjem uteži $\mathbf{W}$ v nasprotni smeri gradienta kriterijske funkcije $\nabla_{\mathbf{W}} J(\mathbf{W})$. Parameter hitrosti učenja η določa velikost koraka, s katerim algoritem popravlja uteži za postopno približevanju lokalnemu minimumu. Algoritem gradientnega spusta torej sledi spustu gradienta kriterijske funkcije proti minimalni vrednosti.

Glede na količino podatkov, ki jih uporabimo v posameznem koraku optimizacije, metodo gradientnega spusta delimo na tri podmetode:

- Paketni gradientni spust (angl. batch gradient descent) izračuna gradient kriterijske funkcije glede na parametre $\mathbf{W}$ za celotno učno množico. Ta pristop za vsako posamezno posodobitev uteži nevronske mreže izračuna gradient celotne učne množice. Zato so posodobitve počasne, v primerih, ko pa je celotna učna množica večja od pomnilnika, pa je metoda tudi neizvedljiva. S to metodo tudi ni možno posodabljanje modela na osnovi toka podatkov (angl. online learning). Paketni gradientni spust ima za konveksne ploskve napak zagotovljeno konvergenco v globalni minimum, za nekonveksne primere pa konvergenco v lokalni minimum [98].
- Stohastični gradientni spust (angl. stochastic gradient descent, SGD) posodablja uteži nevronske mreže za vsak par vhoda x_i in izhoda y_i . Zaradi tega so posodobitve uteži $\mathbf{W}$ bolj pogoste in hitrejšje, kar omogoča tudi učenje na toku podatkov. Zaradi pogostega posodabljanja in prilagajanja vsakemu učnemu vzorcu posebej kriterijska funkcija med postopkom učenja običajno močno niha. Ta lastnost običajno omogoča preskok iz lokalnega v globalni minimum.
- Gradientni spust z mini paketi (angl. mini-batch gradient descent) posodablja uteži nevronske mreže z manjšimi paketi učnih vzorcev, kar zmanjša velikost nihanj kriterijske funkcije med postopkom učenja. To vodi v stabilnejšo konvergenco, manjša količina podatkov pa je tudi primerna za učinkovito računanje na različnih računskih platformah in optimiziranih knjižnicah za računanje z matrikami.

Zaradi velike popularnosti gradientnega spusta na različnih področjih optimizacije se je razvilo veliko število različnih metod, ki se po svoje lotevajo pomanjkljivosti osnovnega postopka stohastičnega gradientnega spusta.

Pristop z metodo na osnovi momenta (angl. momentum) [116] izkorišča ideje iz fizike s področja gibanja na klancu. Predmet pri spustu po klancu pridobi gibalno količino, ki ob nenadni spremembi naklona v nasprotno smer (v hrib) predmet še vedno potiska naprej, dokler gibalne količine ne zmanjka. Pri tem optimizacijskem postopku torej moment pomaga stohastičnemu gradientnemu spustu, da pridobi na hitrosti pri spustu proti

minimumu, ravno tako pa preprečuje, da bi kratkotrajne spremembe gradienta preprečile nadaljevanje v predhodni smeri. Na ta način se zmanjšajo oscilacije običajnega stohastičnega gradientnega spusta in izboljša konvergenca.

Pristop po metodi Nesterovega pospešenega gradienta (angl. Nesterov accelerated gradient, NAG) v optimizacijskem postopku namesto gradienta trenutnega stanja $\mathbf{W}$ upošteva gradient ocenjenega prihodnjega stanja. Pristop je primeren za konveksne optimizacijske probleme [98].

Pomemben optimizacijski algoritem je tudi Adagrad [96], ki adaptivno prilagaja hitrost učenja za posamezne uteži nevronske mreže in je uporaben za delo z redkimi podatkovnimi matrikami (angl. sparse data). Zaradi adaptivnega prilagajanja hitrosti učenja je algoritem enostaven za učenje nevronskih mrež, ker ne potrebuje ročnega iskanja ustreznega parametra za hitrost učenja η . Slabost Adagrad algoritma je, da algoritem s časom akumulira visoke vrednosti preteklih gradientov, ki upočasnjujejo učenje, s tem pa algoritmu preprečijo, da bi akumuliral novo znanje.

Algoritma Adadelta [99] in RMSprop [97] sta bila razvita neodvisno drug od drugega, a oba rešujeta omejitev algoritma Adagrad s podobnim pristopom. Oba algoritma namesto celotne zgodovine gradientov vzdržujeta eksponentno povprečje preteklih gradientov. RMSprop za razliko od algoritma Adadelta na koncu deli hitrost učenja η s kvadratom povprečja preteklih gradientov.

Kingma in Ba [100] sta predlagala računsko učinkovit stohastični optimizacijski algoritem Adam (angl. adaptive moment estimation), ki deluje na osnovi gradientov prvega reda z nizkimi zahtevami po količini pomnilnika. Nizka poraba pomnilnika izhaja iz dejstva, da metoda za izračun uteži in momentov ter adaptivno prilagajanje hitrosti učenja namesto celotne zgodovine uporablja eksponentna povprečja preteklih gradientov in momentov. Algoritem Adam zagotavlja hitro in zanesljivo konvergenco učnega postopka, ki je večinoma veliko hitrejša kot pri primerljivih optimizacijskih algoritmih, kot so Adagrad, SGD in drugi [100]. Adam združuje dobre lastnosti algoritmov Adagrad in RMSprop, je enostaven za konfiguracijo, privzete nastavitve pa v večini primerov zagotavljajo dobro konvergenco na večini problemov [98].

6.2.2.3 Paketna normalizacija

Učenje nevronskih mrež je lahko zelo nepredvidljiv postopek, ker se med postopkom učenja spreminjajo porazdelitve parametrov na vhodih posameznih skritih plasti, saj se v procesu učenja ravno tako spreminjajo parametri predhodnih plasti. To lahko privede do upočasnitve učnega postopka, zahteva ustrezno izbiro začetnih parametrov in povzroča zasičenja v aktivacijskih funkcijah. Avtorji v [117] so predlagali postopek normalizacije vhodov, ki je del nevronske strukture in normalizira vhode za vsak mini paket posebej.

Normaliziranje vrednosti vhodnih podatkov se računa na posameznih elementih mini paketa tako, da imajo normalizirane vrednosti znotraj mini paketa povprečno vrednost $\mu_B = 0$ in varianco $\sigma_B^2 = 1$. Postopek normalizacije posameznih elementov vhodnih podatkov opisuje enačba (6.3), kjer $\hat{x}^{(k)}$ predstavlja normalizirano vrednost elementa na k -tem mestu, $x^{(k)}$ je nespremenjena vrednost k -tega elementa, $E[x^{(k)}]$ je povprečna vrednost ali matematično upanje, ki ga izračunamo za mesto k na podlagi vseh k -tih elementov znotraj mini paketa, $Var[x^{(k)}]$ je varianca k -tih elementov znotraj mini paketa, ϵ pa je majhna konstanta, ki jo dodamo za izboljšanje numerične stabilnosti.

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (6.1)$$

$$\sigma_{\mathcal{B}}^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_{\mathcal{B}})^2 \quad (6.2)$$

$$\hat{x}^{(k)} = \frac{x^{(k)} - E[x^{(k)}]}{\sqrt{Var[x^{(k)}] + \epsilon}} \quad (6.3)$$

Ker normaliziranje vhodnih podatkov vpliva na to, česa se nevronska mreža lahko nauči, je treba transformaciji vhodnih podatkov z normaliziranjem dodati še transformacijo s skaliranjem $\gamma^{(k)}$ in zamikom $\beta^{(k)}$ (angl. scale and shift), da transformacija vhodnih podatkov predstavlja identiteto. Enačba (6.4) predstavlja transformacijo, ki s skaliranjem in zamikom vzdržuje nivo sposobnosti učenja nevronske mreže. Parametri $\gamma^{(k)}$ in $\beta^{(k)}$ se določijo tekom učnega procesa.

$$y^{(k)} = \gamma^{(k)} \hat{x}^{(k)} + \beta^{(k)} \quad (6.4)$$

Po zaključenem postopku učenja določimo še izhodne parametre normalizacije mini paketov na podlagi celotne učne množice. Vsak mini paket vsebuje m vzorcev, celotna učna množica pa j mini paketov. Enačba (6.5) služi izračunu povprečne vrednosti mini paketov v celotni učni množici, enačba (6.6) izračunu variance mini paketov v celotni učni množici, enačba (6.7) pa določi normaliziran izhod iz trenutnega nevrona v nevronske plasti.

$$E_x = \frac{1}{m} \sum_{i=1}^j \mu_{\mathcal{B}}^{(i)} \quad (6.5)$$

$$Var_x = \left(\frac{m}{m-1} \right) \frac{1}{m} \sum_{i=1}^j \sigma_{\mathcal{B}}^{2(i)} \quad (6.6)$$


$$y = \frac{\gamma}{\sqrt{Var_x + \epsilon}} x + \left(\beta + \frac{\gamma E_x}{\sqrt{Var_x + \epsilon}} \right) \quad (6.7)$$

Avtorji so dokazali, da paketna normalizacija (angl. batch normalization, BN) dovoljuje izbiro višjih hitrosti učenja, izboljša konvergenco, regularizira model, poenostavi izbiro začetnih parametrov in olajša učenje globljih nevronske strukture. Primerjavo poteka učnega postopka za model s paketno normalizacijo in za model brez paketne normalizacije prikazuje slika 6.1. Vidimo, da model s paketno normalizacijo veliko hitreje in bolj stabilno doseže višje vrednosti natančnosti na testni množici.

6.2.2.4 Regularizacija z naključnim izpuščanjem

Namen učenja nevronske mreže je prilagajanje uteži sinaptičnih povezav med nevroni v nevronske mreži z namenom učenja avtomatskih izločevalcev značilk v skritih plasteh za uspešno razpoznavanje razreda podatkov na vhodu. Ker je običajno povezava med vhodom in izhodom nevronske mreže zaradi zelo velikega števila povezav med nevroni v skritih plasteh zelo kompleksna, je do pravilnega rezultata možno priti z več različnimi kombinacijami uteži v nevronske mreži. Problem je še posebej izrazit v primerih, ko za učenje uporabimo učne množice z majhnim številom učnih vzorcev. Zelo hitro se zgodi, da zaradi kompleksnosti nevronske mreže razvrščanje vhodnih vzorcev deluje odlično na učnih podatkih, na testnih podatkih pa so rezultati bistveno slabši.

Temu problemu pravimo prepreleganje učni množici (angl. overfitting), ki pa ga lahko rešimo s povečanjem števila vzorcev v učni množici. Ker je pridobivanje učnih vzorcev in s tem večanje učne množice dolgotrajno in zamudno delo, lahko problem prepreleganja omilimo tudi z učenjem več vzporednih nevronske mrež, ki se ločeno naučijo različnih



Slika 6.1: Graf prikazuje primerjavo dveh algoritmov z uporabo paketne normalizacije (z BN) in brez paketne normalizacije (brez BN). Število epoh opisuje število celotnih ponovitev učne množice v učnem postopku.


predstavitev učnih množic. Ta pristop je računsko zelo zahteven tako v času učenja kot tudi v času razpoznavanja vhodnih vzorcev, zato so v [118] predlagali pristop z naključnim izpuščanjem (angl. dropout regularization) nevronov v skritih plasteh v posameznih korakih učnega procesa.

Ob vsakem učnem koraku znotraj polno povezane nevronske plasti vsak nevron naključno izključimo iz nevronske mreže z neko verjetnostjo $P_{dropout}$, ki je običajno velika okrog 0,5 [119]. Regularizacija z naključnim izpuščanjem simulira efekt, ki bi ga dobili, če bi vzporedno učili večje število nevronskih mrež in bi na koncu njihove rezultate združevali v en glavni rezultat. Primerjavo dveh učnih postopkov, enega z in drugega brez regularizacije z naključnim izpuščanjem prikazuje slika 6.2. Opazimo lahko, da nevronska mreža z regularizacijo prikazuje boljšo in hitrejšo konvergenco učnega postopka, kar skrajša potreben čas za učenje globoke nevronske mreže.

6.3 Algoritem za detekcijo razširjanja brez neposredne vidljivosti

Za detekcijo razširjanja signala brez neposredne vidljivosti (NLoS) smo izbrali pristop z razvrščanjem vzorcev (angl. classification). Nevronske mreže za razvrščanje so običajno sestavljene iz ene ali več zaporednih skritih nevronskih plasti, nevronska mreža pa zaključimo z izhodno nevronska plastjo, ki namesto klasične nelinearne aktivacijske funkcije (npr. ReLU) vsebuje aktivacijsko funkcijo softmax. Aktivacijska funkcija softmax normalizira izhodne parametre, da se vsi nahajajo na intervalu $[0, 1]$, njihova vsota pa je vedno enaka 1. Izhodne vrednosti aktivacijske funkcije softmax so torej verjetnosti, da vhodni vzorec pripada posameznemu razredu.

Izhodne vrednosti nevronske mreže in s tem tudi oznake vhodnih vzorcev so zakodirane



Slika 6.2: Graf prikazuje primerjavo poteka učnih postopkov z (Z DR) in brez (Brez DR) regularizacije z naključnim izpuščanjem. Epoha pomeni enkratno ponovitev celotne učne množice v učnem procesu.

po principu enega vročega bita (angl. one hot encoding), tako da vsakemu razredu s podatki pripada eno mesto v izhodnem binarnem vektorju. V našem primeru, ko lahko vhodni vzorci pripadajo razredoma LoS in NLoS, izhodni vektor vsebuje dva bita, po enega za vsak razred. Če vhodni vzorec pripada razredu LoS, potem je izhodni vektor enak $y = [0 \ 1]$, če pa pripada razredu NLoS, pa je izhodni vektor enak $y = [1 \ 0]$.

Kot kriterijsko funkcijo pri razvrščanju vzorcev se običajno uporabi kategorično navzkrižno entropijo (angl. categorical cross entropy), ki glede na odstopanje izhodov nevronske mreže softmax od vhodnega razreda določi izgubo (angl. loss) v trenutnem učnem koraku. Bolj kot izhodna verjetnost razreda odstopa od vhodne, večja je izguba učnega koraka. Kategorična navzkrižna entropija izrazito močno kaznuje velika odstopanja od ciljnega razreda (izhode z verjetnostjo blizu nasprotnega razreda), z manjšanjem odstopanja pa kaznen zelo hitro upada in se manjša proti 0, ko je verjetnost na izhodu enaka razredu vhodnega vzorca.

6.3.1 Zgradba nevronske mreže

Konvolucijska nevronska mreža za razvrščanje vzorcev impulznega odziva radijskega signala UWB na vzorce LoS in NLoS je sestavljena iz kombinacije več konvolucijskih plasti, polno-povezane nevronske plasti in združevalnih plasti. Prva plast je konvolucijska plast z globino filtra $d = 10$ (10 map značilk), širino sprejemnega polja $w = 2$ in aktivacijsko funkcijo ReLU. Sledita ji dve zaporedni konvolucijski plasti z globino $d = 10$ in širino sprejemnega polja $w = 4$. Prvim trem konvolucijskim plastem sledi združevalna plast, ki zmanjša velikost vhodnih vzorcev za polovico. Ker so dimenzije zmanjšane za polovico, v naslednji plasti podvojimo globino konvolucijske plasti, da ohranimo konstantno število uteži na plast v nevronske mreži. Združevalni plasti sledita dve zaporedni konvolucijski plasti z globino $d = 20$ in širino sprejemnega polja $w = 4$. Dodamo še združevalno plast, ki

ponovno zmanjša dimenzije za polovico. Za združevalno plastjo dodamo polno-povezano plast s 128 nevroni in regularizacijo z naključnim izpuščanjem z verjetnostjo $p = 0,5$. V izhodni plasti sta dva nevrona z aktivacijsko funkcijo softmax. V vseh konvolucijskih nevronskih plasteh je pred aktivacijsko funkcijo dodana še funkcija paketne normalizacije za izboljšanje in pospešitev konvergence učnega postopka. Zgradba nevronske mreže za razvrščanje je prikazana na sliki 6.3.

Eksaktnih pravil za sestavljanje globokih nevronskih mrež ni. Pri sestavljanju se držimo smernic, da med posameznimi plastmi vzdržujemo enako število uteži, da v konvolucijskih plasteh uporabljamo funkcijo paketne normalizacije in v polno povezani plasti regularizacijo z naključnim izpuščanjem. Strukturo nevronske mreže s poizkušanjem popravljamo toliko časa, da se učinkovitost razvrševalnega algoritma preneha izboljševati.

Za izgradnjo in uporabo nevronske mreže za razvrščanje vzorcev NLoS smo uporabili knjižnice za strojno učenje scikit-learn [72], Keras [120] in TensorFlowTM[121], ki omogočajo učinkovito implementacijo algoritmov strojnega učenja na zelo širokem spektru računskih naprav vse od majhnih vgradnih računalnikov (angl. single-board computer, SBC) do zmogljivih delovnih postaj s pospeševalniki GPU in do izvedbe na celotnih podatkovnih centrih.

6.3.2 Vhodni podatki razvrševalnega algoritma

Impulzni odziv kanala je v impulznem radiu UWB DW1000 na voljo za vsak veljaven sprejet komunikacijski blok. Podatki se nahajajo v akumulatorju radia in vsebujejo 992 podatkovnih točk za 16 MHz PRF in 1016 podatkovnih točk za 64 MHz PRF z ločljivostjo približno 1,0016 ns ali polovico periode osnovne frekvence oddajnika UWB IEEE 802.15.4-2011, ki znaša 499,2 MHz.

Vsaka ovojnica impulznega odziva v akumulatorju začne naraščati s prvo fronto sprejetega signala. Interni algoritem za detekcijo prve fronte signala zazna in določi točen indeks začetka prve fronte v akumulatorju in ga objavi v posebnem registru, ki je tako kot impulzni odziv dostopen preko komunikacijskega vmesnika na radiu. Indeks prve fronte signala nam pomaga, da iz akumulatorja vedno izluščimo impulzni odziv od začetka prve fronte signala naprej.


V večini primerov je znotraj akumulatorja približno 152 podatkovnih točk, ki prikazujejo dejanski impulzni odziv, ostale točke pa prikazujejo šum, ki je prisoten na kanalu. Kot vhod za modele CNN zato uporabimo prvih 152 podatkovnih točk po zaznanem začetku prve fronte signala.

6.3.3 Ovrednotenje učinkovitosti algoritma za razvrščanje

Postopek izgradnje modela za razvrščanje impulznih odzivov posameznih radijskih paketov na podlagi impulznega odziva kanala moramo ustrezno ovrednotiti. Zanima nas predvsem delovanje v notranjih okoljih, zelo pomembna pa je tudi sposobnost prenosa znanja iz enega okolja v povsem novo okolje. Tu nas zanima, kako dobro model za razvrščanje impulznih odzivov razpozna vzorce v novem okolju, v katerem ni bil deležen učnega procesa.

Za ovrednotenje učinkovitosti algoritma za razvrščanje uporabimo standardne kazalnike učinkovitosti, ki jih izračunamo na podlagi matrike zamenjav (angl. confusion matrix) [122]. Vrstice v matriki zamenjav predstavljajo razrede vhodnih vzorcev, stolpci pa predstavljajo razrede, v katere so bili vzorci razvrščeni z izbranim modelom za razvrščanje. Možne razporeditve glede na matriko zamenjav so pravilno pozitivni (angl. true positive, TP), pravilno negativni (angl. true negative, TN), napačno pozitivni (angl. false positive, FP) in napačno negativni (angl. false negative, FN).

Uporabljeni kazalniki učinkovitosti so:



Slika 6.3: Grafični prikaz zgradbe globoke nevronske mreže za razvrščanje vzorcev NLoS.

- **Točnost (angl. accuracy):** $\frac{TP+TN}{TP+TN+FP+FN}$ prikaže delež pravilno razvrščenih vzorcev.
- **Natančnost (angl. precision):** $\frac{TP}{TP+FP}$ prikaže delež pravilno razvrščenih NLoS vzorcev med vzorci, ki so bili razvrščeni kot NLoS vzorci.
- **Priklic ali občutljivost (angl. recall or sensitivity):** $\frac{TP}{TP+FN}$ prikaže delež pravilno razvrščenih NLoS vzorcev med vsemi NLoS vzorci.
- **F1 ali harmonično povprečje natančnosti in priklica:** $\frac{2 \cdot \text{natančnost} \cdot \text{občutljivost}}{\text{natančnost} + \text{občutljivost}}$.

6.3.3.1 Navzkrižna validacija v posameznih notranjih okoljih

Prvi korak pri analizi učinkovitosti algoritma je ovrednotenje delovanja predlagane nevronske strukture znotraj posameznih notranjih okolij z metodo navzkrižne validacije. Pri navzkrižni validaciji razdelimo nabor podatkov na več enako velikih delov (zelo pogosta je 10-kratna navzkrižna validacija), nato pa izvajamo postopek, kjer en del izvzamemo za ovrednotenje modela, s preostankom podatkov pa naučimo model za razvrščanje vzorcev. Postopek ponavljamo tako dolgo, da vsi predhodno pripravljeni deli nabora podatkov enkrat nastopijo kot nabor podatkov za ovrednotenje. Na koncu izračunamo povprečno uspešnost razvrščanja vseh navzkrižnih validacij. Navzkrižna validacija nam poda povprečno uspešnost modela za razvrščanje pri različnih kombinacijah učnih in testnih podatkov znotraj istega nabora podatkov, v našem praktičnem primeru pa znotraj istega notranjega okolja dobimo vpogled v to, kako dobro model deluje v posameznih delih izbranega referenčnega okolja.

Naše podatkovne zbirke ne vsebujejo merilnih vzorcev na naključnih lokacijah, ampak nabore meritev na vnaprej določenih točkah v prostoru, ki opisujejo trajektorijo, ki bi jo opisala oseba s hojo ali pa avtonomna naprava (avtonomni voziček, robot itd.) s premikanjem. Zato smo podatkovno zbirko na učne in testne množice razdelili na podlagi enako velikih zaporedij točk na trajektoriji. Daljše trajektorije vsebujejo okrog 85 merilnih točk. Nabor podatkov smo razdelili tako, da smo testno množico določili z izborom $\mathcal{V}$ zaporednih merilnih točk. $\mathcal{V}$ smo izračunali tako, da smo število merilnih točk delili z 10 in rezultat zaokrožili navzdol. S tem dosežemo, da so vse testne množice enako velike. Za razliko od klasične navzkrižne validacije v našem primeru nekaj merilnih točk nikoli ne nastopi v vlogi testne množice. V primeru s 85 merilnimi točkami je velikost testne množice $\mathcal{V} = 8$, zadnjih 5 merilnih točk na trajektoriji pa nikoli ne nastopi v vlogi testne množice.

V tabeli 6.1 so navedene vrednosti posameznih metrik ločeno za vsa štiri notranja okolja in razdeljeno po posameznih validacijskih korakih. Posamezni koraki navzkrižne validacije predstavljajo posamezne odseke trajektorije znotraj istega okolja, različne vrednosti metrik uspešnosti pa kažejo na različne zahtevnosti radijskega okolja znotraj posameznih odsekov izbrane trajektorije. Tabela 6.1 je zelo obsežna in predvsem informativne narave, da si lahko predstavljamo, da so določeni odseki v notranjem okolju bolj zahtevni za razširjanje radijskega signala kot drugi.

Zelo pomemben parameter uspešnosti modelov za razvrščanje je parameter priklica. Priklic posameznega razreda vzorcev namreč pove, kako občutljiv je algoritem, da med vsemi vzorci enega razreda pravilno razpozna čim več ustreznih vzorcev. Priklic 100 % pove, da algoritem za razvrščanje na primer pri detekciji vzorcev NLoS pravilno razpozna vse vzorce NLoS.

Tabela 6.2 prikazuje povprečno uspešnost modelov znotraj posameznih notranjih okolij. Povprečne uspešnosti so izračunane tako, da se rezultati razvrščanja vseh posameznih validacijskih korakov združijo v eno matriko in nato izračunajo kumulativne metrike na osnovi vseh teh podatkov.

Tabela 6.1: Uspešnost modela pri navzkrižni validaciji.

Bivalno okolje 1										
	1	2	3	4	5	6	7	8	9	10
Točnost	86.64	92.14	84.83	87.82	94.36	94.16	92.51	84.67	78.41	87.19
Natančnost LoS	70.88	84.90	61.31	68.67	94.48	84.18	82.88	79.95	61.31	71.56
Priklic LoS	66.09	87.63	83.06	73.61	82.26	94.39	90.48	78.90	62.96	90.35
F1 LoS	68.40	86.24	70.55	71.06	87.95	88.99	86.51	79.42	62.13	79.87
Vzorci LoS	2604	3348	2604	2418	2976	2976	3162	4464	3348	3348
Natančnost NLoS	90.68	95.10	94.73	93.15	94.33	98.05	96.44	87.44	85.35	95.79
Priklic NLoS	92.40	93.90	85.32	91.44	98.40	94.09	93.24	88.13	84.46	85.95
F1 NLoS	91.53	94.50	89.78	92.29	96.32	96.03	94.81	87.78	84.90	90.61
Vzorci NLoS	9300	8556	9300	9486	8928	8928	8742	7440	8556	8556
Bivalno okolje 2										
	1	2	3	4	5	6	7	8	9	10
Točnost	72.46	90.61	96.81	91.95	93.09	91.06	94.84	93.10	96.56	96.57
Natančnost LoS	54.75	92.26	98.41	95.20	95.54	90.42	94.70	92.82	98.34	97.93
Priklic LoS	92.58	96.03	97.94	94.46	95.24	98.52	98.64	98.42	97.64	98.16
F1 LoS	68.81	94.11	98.17	94.83	95.39	94.30	96.63	95.54	97.99	98.04
Vzorci LoS	3906	9300	10416	9300	8928	8928	8928	8928	10230	10416
Natančnost NLoS	94.53	83.41	86.02	80.75	85.85	93.93	95.35	94.21	86.20	86.89
Priklic NLoS	62.64	71.24	88.91	82.99	86.66	68.68	83.43	77.15	89.90	85.48
F1 NLoS	75.35	76.84	87.44	81.86	86.25	79.35	89.00	84.83	88.01	86.18
Vzorci NLoS	7998	2604	1488	2604	2976	2976	2976	1674	1488	1488
Pisarniško okolje										
	1	2	3	4	5	6	7	8	9	10
Točnost	89.00	93.68	96.20	93.57	87.80	92.02	89.43	87.83	88.10	93.83
Natančnost LoS	81.63	79.09	81.60	80.31	81.08	88.22	80.61	79.48	70.98	88.92
Priklic LoS	72.28	90.14	97.74	87.01	86.16	80.74	76.01	84.79	88.68	86.02
F1 LoS	76.67	84.25	88.94	83.53	83.54	84.31	78.24	82.05	78.85	87.45
Vzorci LoS	2976	2232	1860	2232	4278	3162	2976	3906	2976	2976
Natančnost NLoS	91.10	97.65	99.57	96.94	91.95	93.24	92.15	92.32	95.88	95.39
Priklic NLoS	94.58	94.50	95.92	95.08	88.72	96.10	93.91	89.31	87.91	96.43
F1 NLoS	92.81	96.05	97.71	96.00	90.31	94.65	93.02	90.79	91.73	95.91
Vzorci NLoS	8928	9672	10044	9672	7626	8742	8928	7998	8928	8928
Industrijsko okolje										
	1	2	3	4	5	6	7	8	9	10
Točnost	92.20	85.64	91.32	91.40	88.21	83.32	77.59	72.00	82.17	89.07
Natančnost LoS	88.26	85.76	88.36	92.40	91.45	85.77	86.22	70.26	76.85	84.60
Priklic LoS	92.30	84.37	91.48	91.32	90.49	87.89	76.34	66.26	82.64	86.63
F1 LoS	90.23	85.06	89.89	91.86	90.97	86.82	80.98	68.20	79.64	85.60
Vzorci LoS	4650	5766	5022	6324	7812	7440	7440	5394	5022	4464
Natančnost NLoS	94.92	85.54	93.62	90.29	82.20	78.95	66.89	73.30	86.59	91.86
Priklic NLoS	92.13	86.84	91.21	91.49	83.85	75.69	79.66	76.76	81.84	90.54
F1 NLoS	93.50	86.18	92.40	90.88	83.01	77.29	72.72	74.99	84.15	91.19
Vzorci NLoS	7254	6138	6882	5580	4092	4464	4464	6510	6882	7440

Opazimo, da model za Bivalno okolje 1 kaže slabšo uspešnost v primerjavi z modelom za Bivalno okolje 2. Razlika se zelo verjetno pojavi zaradi bistveno slabše natančnosti pri razpoznavanju vzorcev LoS, ki se pojavi zaradi bistveno manjšega števila vzorcev LoS v primerjavi s številom vzorcev NLoS. Ker je razmerje med številom vzorcev LoS in številom vzorcev NLoS v Bivalnem okolju 2 bistveno višje od tistega v Bivalnem okolju 1, je tudi model za razpoznavanje vzorcev bolj prilagojen razpoznavanju vzorcev LoS. Najbolj uravnotežen je model za razpoznavanje vzorcev v Industrijskem okolju, kjer tudi podatkovna zbirka vsebuje uravnoteženo število vzorcev LoS proti številu vzorcev NLoS.

Tabela 6.2: Povprečna uspešnost modela pri navzkrižni validaciji.

	Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
Točnost	88.27	91.71	91.15	85.29
Natančnost LoS	75.84	92.30	80.87	85.45
Priklic LoS	81.19	97.04	84.31	84.95
F1 LoS	78.42	94.61	82.55	85.20
Vzorci LoS	31248	89280	29574	59334
Natančnost NLoS	93.13	89.51	94.74	85.13
Priklic NLoS	90.79	75.70	93.41	85.63
F1 NLoS	91.95	82.03	94.07	85.38
Vzorci NLoS	87792	29760	89466	59706

6.3.3.2 Navzkrižna validacija v posameznih notranjih okoljih na različnih radijskih kanalih

Modeli za razvrščanje v razred LoS in NLoS v poglavju 6.3.3.1 so zgrajeni na podlagi podatkov, ki vsebujejo impulzne odzive za šest različnih radijskih kanalov na treh različnih osnovnih frekvencah in s tremi različnimi pasovnimi širinami radijskega kanala. Izkaže se, da so impulzni odzivi na posameznem kanalu različni od impulznih odzivov na drugem kanalu in istem položaju z enakim stanjem radijskega okolja. Primerjava povprečnih impulznih odzivov vseh šestih radijskih kanalov za isti položaj je prikazana na sliki 6.4. Rezultati postopka ovrednotenja uspešnosti modela so podani v tabeli 6.3.

V rezultatih opazimo, da modeli za razvrščanje vzorcev pri višjih frekvencah delujejo slabše kot tisti pri nižjih. V industrijskem okolju se pokaže še boljša uspešnost razvrščevalnih algoritmov z višanjem pasovne širine. Najboljše rezultate za razvrščanje vzorcev v Industrijskem okolju dobimo na kanalu 4 (CH4), ki je najširši kanal, ki ga radio DW1000 podpira, poleg tega pa vključuje frekvenčna območja kanalov 1, 2 in 3. Zaključimo lahko, da je v okoljih z malo odboji za razvrščanje vzorcev LoS in NLoS bolje uporabiti nižje frekvence, v okoljih z veliko odboji pa večjo pasovno širino.

Uporabljeni radijski kanali z njihovimi pripadajočimi centralnimi frekvencami f_c in pasovnimi širinami BW so:

- CH1, $f_c = 3494,4$ MHz, $BW = 499,2$ MHz,
- CH2, $f_c = 3993,6$ MHz, $BW = 499,2$ MHz,
- CH3, $f_c = 4492,8$ MHz, $BW = 499,2$ MHz,
- CH4, $f_c = 3993,6$ MHz, $BW = 1331,2$ MHz,
- CH5, $f_c = 6489,6$ MHz, $BW = 499,2$ MHz,
- CH7, $f_c = 6489,6$ MHz, $BW = 1081,6$ MHz.

6.3.3.3 Navzkrižna validacija med notranjimi okolji

Naša želja je, da na podlagi zajetih meritev v različnih notranjih okoljih izdelamo čim bolj univerzalne modele za razvrščanje vzorcev NLoS. To bi omogočilo uporabo izboljšanih sistemov za lokalizacijo v notranjih okoljih brez začetnega zahtevnega in dolgotrajnega umerjanja sistema. Za oceno, kako se zgrajeni modeli odzivajo v povsem novih okoljih, smo izvedli metodo navzkrižne validacije na nivoju nabora notranjih okolij. Uporabili smo pristop štirikratne navzkrižne validacije, kjer je v vsakem koraku eno od notranjih okolij nastopalo kot testni nabor podatkov za ovrednotenje uspešnosti modela, podatki iz ostalih notranjih okolij pa so bili uporabljeni za izgradnjo modela. Rezultati so prikazani v tabeli 6.4.

Najslabše rezultate razvrščanja vzorcev dobimo z ovrednotenjem modela na podatkih iz Industrijskega okolja. Predvidevamo, da pride do tako slabih rezultatov zaradi izrazitih razlik v vplivu okolja na razširjanje radijskega signala. Obe bivalni okolji in pisarniško okolje so med seboj po zgradbi še vedno dokaj podobna okolja. Industrijsko okolje je pokrito z jekleno streho, vsebuje veliko kovinskih površin (stroji), ki delujejo kot reflektorji in s tem povečujejo število komponent poti v sprejetem signalu in zmanjšujejo slabljenje signala pri razširjanju od oddajnika do sprejemnika.

6.3.3.4 Navzkrižna validacija med notranjimi okolji na različnih kanalih


Ravno tako kot pri navzkrižni validaciji modelov notranjih okolij za posamezne kanale (poglavje 6.3.3.2) želimo preveriti tudi uspešnost modelov v posameznih notranjih okoljih in ločenih kanalih.

Tabela 6.3: Uspešnost modelov pri navzkrižni validaciji za posamezne kanale.

Bivalno okolje 1						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	92.46	90.22	87.22	89.50	85.08	87.32
Natančnost LoS	81.76	79.35	74.19	78.33	72.44	78.40
Priklic LoS	91.76	84.83	78.69	82.95	69.66	71.35
F1 LoS	86.47	82.00	76.37	80.57	71.03	74.71
Vzorci LoS	5208	5208	5208	5208	5208	5208
Natančnost NLoS	96.93	94.46	92.25	93.80	89.35	90.12
Priklic NLoS	92.71	92.14	90.25	91.83	90.57	93.00
F1 NLoS	94.78	93.29	91.24	92.81	89.95	91.54
Vzorci NLoS	14632	14632	14632	14632	14632	14632
Bivalno okolje 2						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	93.73	93.26	90.90	93.13	90.78	92.95
Natančnost LoS	93.91	93.38	91.17	93.50	91.67	92.95
Priklic LoS	98.00	97.95	97.30	97.62	96.48	98.04
F1 LoS	95.91	95.61	94.13	95.52	94.01	95.43
Vzorci LoS	14880	14880	14880	14880	14880	14880
Natančnost NLoS	93.09	92.79	89.85	91.78	87.46	92.98
Priklic NLoS	80.93	79.17	71.71	79.66	73.69	77.68
F1 NLoS	86.58	85.44	79.76	85.29	79.99	84.64
Vzorci NLoS	4960	4960	4960	4960	4960	4960
Pisarniško okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	93.98	91.39	88.98	91.82	91.56	93.27
Natančnost LoS	86.75	81.11	74.99	83.73	80.84	83.86
Priklic LoS	89.43	85.19	83.47	83.24	86.53	90.26
F1 LoS	88.07	83.10	79.00	83.49	83.59	86.95
Vzorci LoS	4929	4929	4929	4929	4929	4929
Natančnost NLoS	96.47	95.02	94.32	94.47	95.44	96.70
Priklic NLoS	95.49	93.44	90.80	94.65	93.22	94.26
F1 NLoS	95.98	94.22	92.53	94.56	94.32	95.46
Vzorci NLoS	14911	14911	14911	14911	14911	14911
Industrijsko okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	83.90	85.70	74.98	87.74	83.38	85.39
Natančnost LoS	81.91	84.95	78.65	87.05	84.04	85.27
Priklic LoS	86.88	86.66	68.36	88.57	82.28	85.44
F1 LoS	84.33	85.80	73.14	87.81	83.15	85.36
Vzorci LoS	9889	9889	9889	9889	9889	9889
Natančnost NLoS	86.13	86.47	72.17	88.44	82.75	85.50
Priklic NLoS	80.94	84.75	81.56	86.91	84.47	85.34
F1 NLoS	83.45	85.60	76.58	87.67	83.60	85.42
Vzorci NLoS	9951	9951	9951	9951	9951	9951

Tabela 6.4: Uspešnost modelov pri navzkrižni validaciji med notranjimi okolji.

	Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
Točnost	85.98	90.63	90.08	64.07
Natančnost LoS	67.42	90.99	81.62	91.61
Priklic LoS	89.84	97.12	77.53	29.78
F1 LoS	77.03	93.96	79.52	44.95
Vzorci LoS	33108	89280	29946	61566
Natančnost NLoS	95.92	89.18	92.69	58.82
Priklic NLoS	84.60	71.14	94.23	97.35
F1 NLoS	89.91	79.15	93.45	73.33
Vzorci NLoS	93372	29760	90582	63426



Slika 6.4: Prikaz povprečnih impulznih odzivov na različnih komunikacijskih kanalih za isto lokacijo.

Rezultati, podani v tabeli 6.5, so tu zaradi razlik v notranjih okoljih pričakovano slabši. Še vedno opazimo vzorec, da se med modeli za prve tri radijske kanale (CH1, CH2 in CH3) izplača izbrati kanal z najnižjo centralno frekvenco (CH1), v pisarniškem in industrijskem okolju pa se bolje odrežeta kanala z najvišjo centralno frekvenco (CH5 in CH7), kjer zadnji najširši kanal (CH7) vrne še rahlo boljši rezultat od ožjega kanala (CH5).

Na podlagi rezultatov lahko zaključimo, da so modeli, ki so zgrajeni na podlagi meritev iz okolij, ki večinoma niso bistveno drugačna od okolja, v katerem želimo model za razvrščanje uporabljati, običajno dovolj dobri za razvrščanje vzorcev LoS in NLoS. Če so vsa okolja, ki so bila uporabljena za izgradnjo modela, bistveno drugačna od okolja, kjer se bo razvrščanje vzorcev uporabljalo, pa je model le pogojno uporaben.

6.4 Algoritem za oceno napake izmerjene razdalje

Najbolj pomembna značilnost pulznih radijev UWB DW1000 za uporabo v lokalizacijskih sistemih je njihova zmožnost merjenja medsebojne razdalje na podlagi časa razširjanja radijskega signala. Na kakovost časovnih žigov sprejetih paketov vplivajo predvsem razmere na radijskem kanalu. Če je radijski signal na sprejemniku šibek in so na poti razširjanja prisotne ovire, algoritem za določanje časovnega žiga iz sprejetega signala težje določi pravi čas začetka sprejetega paketa. Za oceno izmerjene napake lahko tako kot pri razvrščanju vzorcev LoS in NLoS uporabimo izmerjene impulzne odzive in pripadajoče informacije o dejanski napaki izmerjene razdalje. Za ocenjevanje napake uporabimo metodo regresije, ki modelira odvisnost izhodnih od vhodnih parametrov.

Implementacija regresije z globokimi nevronskimi mrežami je zelo podobna implementaciji razvrščevalnih algoritmov, le da pri regresiji kot izhodno aktivacijsko funkcijo obi-

Tabela 6.5: Uspešnost modelov za razvrščanje med notranjimi okolji na posameznih kanalih.

Bivalno okolje 1						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	91.32	88.23	82.42	84.17	81.93	84.44
Natančnost LoS	78.63	76.33	60.72	73.31	60.30	64.37
Priklic LoS	91.81	79.78	93.08	62.18	90.63	90.78
F1 LoS	84.71	78.02	73.49	67.29	72.42	75.33
Vzorci LoS	5518	5518	5518	5518	5518	5518
Natančnost NLoS	96.91	92.71	96.97	87.27	95.96	96.17
Priklic NLoS	91.15	91.23	78.65	91.97	78.84	82.19
F1 NLoS	93.94	91.96	86.85	89.56	86.56	88.63
Vzorci NLoS	15562	15562	15562	15562	15562	15562
Bivalno okolje 2						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	88.95	92.18	86.99	91.27	85.04	86.99
Natančnost LoS	87.74	91.64	87.42	91.27	83.46	85.37
Priklic LoS	99.11	98.57	96.54	97.71	99.85	99.75
F1 LoS	93.08	94.98	91.75	94.38	90.92	92.00
Vzorci LoS	14880	14880	14880	14880	14880	14880
Natančnost NLoS	95.65	94.45	84.89	91.28	98.87	98.49
Priklic NLoS	58.45	73.02	58.33	71.96	40.62	48.71
F1 NLoS	72.56	82.36	69.14	80.47	57.59	65.18
Vzorci NLoS	4960	4960	4960	4960	4960	4960
Pisarniško okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	92.89	89.34	87.42	81.80	90.76	91.64
Natančnost LoS	86.53	87.58	76.43	66.53	80.13	87.08
Priklic LoS	84.55	66.52	71.39	53.80	83.49	77.92
F1 LoS	85.53	75.61	73.82	59.49	81.78	82.25
Vzorci LoS	4991	4991	4991	4991	4991	4991
Natančnost NLoS	94.93	89.75	90.74	85.63	94.47	92.95
Priklic NLoS	95.65	96.88	92.72	91.05	93.16	96.18
F1 NLoS	95.29	93.18	91.72	88.26	93.81	94.53
Vzorci NLoS	15097	15097	15097	15097	15097	15097
Industrijsko okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
Točnost	68.19	66.45	68.27	62.10	73.69	75.59
Natančnost LoS	89.95	91.31	72.28	94.74	73.56	86.70
Priklic LoS	39.88	35.23	57.70	24.40	72.72	59.58
F1 LoS	55.26	50.84	64.17	38.81	73.14	70.62
Vzorci LoS	10261	10261	10261	10261	10261	10261
Natančnost NLoS	62.11	60.61	65.66	57.35	73.81	69.90
Priklic NLoS	95.68	96.75	78.52	98.69	74.63	91.13
F1 NLoS	75.33	74.53	71.52	72.55	74.22	79.11
Vzorci NLoS	10571	10571	10571	10571	10571	10571

čajno izberemo linearno aktivacijo, kriterijska funkcija za optimizacijski postopek pa je ena od statističnih metrik za merjenje izhodne napake. V literaturi lahko zasledimo uporabo povprečne kvadratne napake, povprečne absolutne napake, povprečne absolutne odstotne napake, povprečne kvadratne logaritmčne napake in še nekaj drugih.

6.4.1 Zgradba nevronske mreže

Izbrana struktura nevronske mreže za ocenjevanje napake izmerjene razdalje na podlagi impulznega odziva kanala je zelo podobna strukturi nevronske mreže za razvrščanje impulznih odzivov vzorcev NLoS in LoS. Ker so podatki na vhodu modela za napovedovanje napake izmerjene razdalje enaki podatkom na vhodu modela za razvrščanje, je lahko večina strukture nevronske mreže enaka. Na enakih podatkih namreč konvolucijska nevronska struktura enako dobro izlušči značilke vhodnega signala in jih razpozna v polno povezani plasti ter jih z izhodno plastjo prevede v oceno napake izmerjene razdalje.


Na vhodu nevronske mreže je postavljena konvolucijska plast z globino filtra $d = 10$ in širino sprejemnega polja $w = 2$. Vhodni konvolucijski plasti sledita dve zaporedni konvolucijski plasti z globino filtra $d = 10$ in širino sprejemnega polja $w = 4$. Za tremi zaporednimi konvolucijskimi plastmi se nahaja združevalna plast s funkcijo ohranjanja maksimalnih vrednosti s korakom $s = 2$, ki razpolovi razsežnost vhodnih podatkov. Prvi združevalni plasti sledita dve zaporedni konvolucijski plasti z globino $d = 20$ in širino sprejemnega polja $w = 4$. Sledi nova združevalna plast s funkcijo ohranjanja maksimalnih vrednosti s korakom $s = 2$, ki ponovno razpolovi dimenzije vhodne plasti. Za drugo združevalno plastjo se nahaja polno povezana nevronska plast s 128 nevroni in regularizacijo z naključnim izpuščanjem z verjetnostjo $p = 0,5$. Izhodno plast predstavlja en nevron z linearno aktivacijo, izhodna vrednost pa je ocena napake izmerjene razdalje za impulzni odziv na vhodu.

Vse nevronske plasti razen izhodne uporabljajo aktivacijsko funkcijo ReLU, vse konvolucijske plasti pa imajo vgrajeno paketno normalizacijo, ki izboljša in pospeši konvergenco učnega postopka. Izbrana kriterijska funkcija učnega postopka je povprečna kvadratna napaka (MSE), ki izhodne vrednosti kaznuje progresivno z naraščanjem napake izhoda. Pomembno je, da pričakovani izhodi ne vsebujejo osamelcev, saj lahko privedejo do slabše uspešnosti algoritma za oceno napake izmerjene razdalje. V procesu priprave učnih in testnih množic odstranimo osamelce (vzorci z močno odstopajočimi vrednostmi napak izmerjene razdalje). Na sliki 6.5 je prikazana struktura nevronske mreže za oceno napake izmerjene razdalje na podlagi impulznega odziva.

6.4.2 Analiza učinkovitosti algoritma za oceno napake izmerjene razdalje

Uspešnosti algoritma za oceno napake izmerjene razdalje zaradi zveznosti izhodne funkcije ne ocenjujemo na enak način kot pri algoritmi za razvrščanje. Namesto nabora diskretnih vrednosti, ki jih lahko pri algoritmi za razvrščanje zavzame izhod, izhod regresijskega algoritma opisuje zvezna funkcija odvisne spremenljivke (ocenjena vrednost na podlagi vhoda). Kako dobro regresijski model opisuje in ocenjuje dejansko stanje na vhodnih podatkih, običajno ovrednotimo z razliko med napovedano vrednostjo in dejansko vrednostjo. Če model vrača ocene z majhnimi odstopanji od pravih vrednosti, lahko zaključimo, da je model dober, v nasprotnem primeru pa je model slab. Za ovrednotenje uspešnosti regresijskega modela na množici tesnih podatkov je surovi pristop z opazovanjem posameznih odstopanj od pričakovane vrednosti običajno nepraktičen in preveč zamuden. Ravno tako je otežena primerjava s podobnimi modeli.

Za vrednotenje uspešnosti modelov za napovedovanje in ocenjevanje so bile razvite številne statistične ocene, ki z eno vrednostjo opisujejo uspešnost modela. Posamezne



Slika 6.5: Grafični prikaz zgradbe globoke nevronske mreže za ocenjevanje napake izmerjene razdalje.

metrike na različne načine opišejo porazdelitev odstopanj od pravih vrednosti. Nekatere porazdelitve bolj utežujejo večja odstopanja, druge manjša, nekatera pa delno opisujejo tudi porazdelitev odstopanj. Med najbolj pogostimi metrikami za oceno uspešnosti regresijskih modelov najdemo povprečno absolutno napako (angl. mean absolute error, MAE), povprečno kvadratno napako (angl. mean squared error, MSE), mediano absolutne napake (angl. median absolute error, MedAE), razloženo variacijo (angl. explained variation), povprečno kvadratno logaritmčno napako (angl. mean squared logarithmic error, MSLE) in determinacijski koeficient R^2 (angl. coefficient of determination). Za vrednotenje uspešnosti algoritma za oceno napake izmerjene razdalje smo izbrali MAE, MedAE in MSE metrike.

Povprečna absolutna napaka (MAE), ki jo podaja enačba (6.8), je mera za razliko med dvema zveznima spremenljivkama y za dejanske in $\hat{y}$ za ocenjene vrednosti. Predstavlja povprečno absolutno oddaljenost ocenjenih vrednosti od pravih izmerjenih vrednosti. Uporaba absolutne razdalje prepreči, da bi se negativne in pozitivne razlike med seboj izničile in s tem zmanjšale oceno odstopanja od prave oz. pričakovane vrednosti.

$$MAE(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} |y_i - \hat{y}_i| \quad (6.8)$$

Mediana absolutne napake (MedAE), podana v enačbi (6.9), je mera uspešnosti modela za ocenjevanje vrednosti, ki namesto povprečne vrednosti odstopanj ocenjene vrednosti $\hat{y}$ od prave vrednosti y vzame mediano odstopanj. Mediana absolutne napake je bolj odporna na osamelce od povprečne absolutne napake, poleg tega pa v kombinaciji s povprečno absolutno napako kaže na porazdelitev ocenjenih vrednosti. Če je mediana absolutne napake manjša od povprečne absolutne napake, lahko sklepamo, da je porazdelitev bolj nagnjena proti levi in s tem napake v večini manjše od povprečne vrednosti. Na podlagi te primerjave lahko sklepamo, da je model za oceno napake izmerjene razdalje nagnjen k manjšim odstopanjem in s tem boljši.

$$MedAE(y, \hat{y}) = median(|y_1 - \hat{y}_1|, \dots, |y_n - \hat{y}_n|) \quad (6.9)$$

Povprečna kvadratna napaka (MSE) je mera uspešnosti modela, ki poda povprečno vrednost kvadratov odstopanj ocenjene vrednosti $\hat{y}_i$ od prave vrednosti y_i . Povprečna absolutna napaka je vedno pozitivna, na vrednost povprečne kvadratne napake pa močno vplivajo osamelci. Povprečna kvadratna napaka zaradi občutljivosti na osamelce v kombinaciji s povprečno absolutno napako prikazuje, kako so porazdeljena odstopanja ocenjenih napak od dejanskih napak. Če so napake velike, je povprečna kvadratna napaka občutno večja, ker kvadrati razlik naraščajo s kvadratom napake.

$$MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2 \quad (6.10)$$

6.4.2.1 Navzkrižna validacija v posameznih notranjih okoljih

Podobno kot v poglavju 6.3.3.1 spet uporabimo pristop z 10-kratno validacijo. Zbirko merilnih podatkov razdelimo na 10 enako velikih kosov, od katerih je vsak kot validacijska množica uporabljen samo enkrat. Zaradi enostavnejše razdelitve glede na pozicije na trajektoriji uporabimo celoštevilski ostanek pri deljenju števila pozicij na trajektoriji, preostanek pa se vedno priključi učni množici. Tako dobimo 10 validacijskih korakov z različnimi validacijskimi vzorci, ki jih posamezen model tekom učnega procesa še ni videl. Zbirka rezultatov vseh 10 validacijskih korakov s povprečno uspešnostjo tako ustvari boljšo

Tabela 6.6: Uspešnost modela pri napovedovanju napake izmerjene razdalje.

Bivalno okolje 1										
	1	2	3	4	5	6	7	8	9	10
MAE	0.19	0.23	0.15	0.19	0.23	0.21	0.23	0.19	0.14	0.17
MSE	0.07	0.15	0.05	0.08	0.10	0.09	0.11	0.12	0.04	0.07
MedAE	0.15	0.15	0.10	0.12	0.15	0.14	0.13	0.11	0.10	0.10
št. vzorcev	11904	11904	11904	11904	11904	11902	11903	11904	11904	11904
Bivalno okolje 2										
	1	2	3	4	5	6	7	8	9	10
MAE	0.14	0.11	0.07	0.11	0.10	0.10	0.10	0.08	0.07	0.06
MSE	0.04	0.04	0.01	0.03	0.03	0.02	0.02	0.01	0.01	0.01
MedAE	0.10	0.07	0.06	0.08	0.06	0.07	0.07	0.06	0.06	0.05
št. vzorcev	11904	11904	11904	11904	11904	11904	11904	11904	11904	11904
Pisarniško okolje										
	1	2	3	4	5	6	7	8	9	10
MAE	0.34	0.30	0.29	0.33	0.28	0.21	0.31	0.18	0.20	0.21
MSE	0.20	0.19	0.16	0.21	0.15	0.08	0.20	0.06	0.06	0.07
MedAE	0.26	0.19	0.21	0.23	0.20	0.16	0.19	0.15	0.19	0.19
št. vzorcev	11901	11903	11904	11899	11904	11902	11902	11901	11904	11902
Industrijsko okolje										
	1	2	3	4	5	6	7	8	9	10
MAE	0.49	0.35	0.34	0.29	0.25	0.26	0.25	0.35	0.33	0.33
MSE	0.63	0.25	0.25	0.21	0.15	0.17	0.15	0.24	0.23	0.22
MedAE	0.24	0.22	0.21	0.16	0.15	0.13	0.15	0.23	0.21	0.22
št. vzorcev	11904	11904	11904	11904	11904	11904	11904	11904	11904	11904

Tabela 6.7: Povprečna uspešnost modela pri napovedovanju napake izmerjene razdalje.

	Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
MAE	0.19	0.09	0.27	0.33
MSE	0.09	0.02	0.14	0.25
MedAE	0.12	0.06	0.20	0.19
št. vzorcev	119037	119040	119022	119040

sliko o uspešnosti modela znotraj istega notranjega okolja kot pa enokoračna validacija, ki se izvede samo na enem mestu v prostoru.

Rezultati 10-kratne validacije modelov za ocenjevanje napake izmerjene razdalje za posamezna notranja okolja so ločeno za vse validacijske korake prikazani v tabeli 6.6. Iz rezultatov lahko razberemo, da je industrijsko okolje bolj zahtevno za ocenjevanje napake izmerjene razdalje od bivalnega in pisarniškega okolja. Posamezni validacijski koraki in položaji, ki jih validacijski koraki zajemajo, običajno ne odstopajo bistveno od povprečja, kjer pa odstopajo, pa je to posledica lokalno drugačnih razmer od dela okolja, za katerega je bil dotični model naučen.

Povprečne uspešnosti modelov v posameznih notranjih okoljih so predstavljene v tabeli 6.7. Na podlagi rezultatov za povprečne uspešnosti modelov lahko ponovno zaključimo, da je industrijsko okolje zaradi številnih ovir in površin, ki povzročajo odboje, opazno zahtevnejše od ostalih okolij.

6.4.2.2 Navzkrižna validacija v posameznih okoljih na različnih radijskih kanalih

V poglavju 6.3.3.2 smo na podlagi rezultatov zaključili, da so modeli za razvrščanje vzorcev LoS in NLoS bolj uspešni, če za učenje in ovrednotenje uspešnosti uporabimo samo podatke enega komunikacijskega kanala. Enak postopek ovrednotenja smo opravili tudi na modelih za ocenjevanje napake izmerjene razdalje, rezultati ovrednotenja uspešnosti po posameznih kanalih in notranjih okoljih pa so prikazani v tabeli 6.8.

Ponovno opazimo, da je izbira kanalov z nižjimi frekvencami ugodnejša za izgradnjo modela za oceno napake izmerjene razdalje. Ravno tako se izboljša uspešnost ocenjevanja napake izmerjene razdalje, če uporabimo najširši radijski kanal, ki pokriva skoraj celoten frekvenčni pas prvih treh kanalov. Pri oceni napake izmerjene razdalje sta sedaj oba najširša kanala (CH4 in CH7) neodvisno od njunih centralnih frekvenc po uspešnosti zelo primerljiva.

Tabela 6.8: Uspešnost modelov pri navzkrižni validaciji napovedovanja napake izmerjene razdalje za posamezne kanale.

Bivalno okolje 1						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.22	0.22	0.24	0.17	0.22	0.17
MSE	0.09	0.10	0.11	0.07	0.15	0.07
MedAE	0.15	0.15	0.17	0.11	0.14	0.10
št. vzorcev	19840	19839	19840	19838	19840	19840
Bivalno okolje 2						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.11	0.11	0.15	0.08	0.12	0.07
MSE	0.03	0.03	0.05	0.02	0.04	0.02
MedAE	0.07	0.08	0.10	0.06	0.07	0.05
št. vzorcev	19840	19840	19840	19840	19840	19840
Pisarniško okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.31	0.31	0.33	0.26	0.31	0.24
MSE	0.19	0.19	0.19	0.15	0.18	0.12
MedAE	0.23	0.24	0.26	0.19	0.24	0.17
št. vzorcev	19840	19836	19840	19826	19840	19840
Industrijsko okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.41	0.34	0.51	0.28	0.45	0.35
MSE	0.35	0.26	0.53	0.18	0.41	0.27
MedAE	0.26	0.22	0.35	0.16	0.31	0.21
št. vzorcev	19840	19840	19840	19840	19840	19840

Tabela 6.9: Uspešnost modelov pri oceni napake izmerjene razdalje v posameznih notranjih okoljih.

	Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
MAE	0.21	0.15	0.32	0.43
MSE	0.10	0.04	0.50	0.40
MedAE	0.13	0.13	0.20	0.30
št. vzorcev	126477	119040	120510	124992

6.4.2.3 Navzkrižna validacija med notranjimi okolji

Kot pri modelih za razvrščanje vzorcev LoS in NLoS nas tudi pri modelih za oceno napake izmerjene razdalje zanima, kako se modeli izkažejo, ko za učenje uporabimo podatke drugih notranjih okolij kot za ovrednotenje uspešnosti modela. Ker naša podatkovna zbirka vsebuje merilne podatke iz štirih notranjih okolij, na tem mestu izvedemo 4-kratno navzkrižno validacijo, kjer v vsakem koraku validacije vzorci iz enega notranjega okolja služijo kot vzorci za ovrednotenje uspešnosti, vzorci iz ostalih treh notranjih okolij pa kot učni vzorci. Rezultati ovrednotenja uspešnosti modela so podani v tabeli 6.9.

Rezultati ovrednotenja uspešnosti modela kažejo, da je ocenjevanje napake izmerjene razdalje najtežje v okoljih, ki so bistveno drugačna od okolij, v katerih so bili modeli zgrajeni. Industrijsko okolje zaradi svojih drugačnih pogojev za raširjanje signala kaže najslabše rezultate pri ocenjevanju napak izmerjene razdalje. Sledi mu pisarniško okolje, najboljše pa se odrežejo modeli pri navzkrižni validaciji v obeh notranjih okoljih.

6.4.2.4 Navzkrižna validacija med notranjimi okolji na različnih kanalih

Preverili smo tudi uspešnost modelov za oceno napake izmerjene razdalje v različnih notranjih okoljih ločeno za posamezne komunikacijske kanale. Ti rezultati so zbrani v tabeli 6.10.

Pri navzkrižni validaciji na različnih kanalih ugotovimo, da najboljše rezultate pri ocenjevanju napake izmerjene razdalje dobimo z uporabo modelov, ki so bili zgrajeni na podlagi vzorcev na najširših radijskih kanalih (CH4 in CH7). Če najširših kanalov zaradi katerega koli razloga ne moremo izbrati, je naslednja najboljša odločitev, da za napovedovanje napake izmerjene razdalje izberemo kanal z najnižjo centralno frekvenco (CH1).

Tabela 6.10: Uspešnost modelov pri oceni napake izmerjene razdalje za posamezne kanale v posameznih notranjih okoljih.

Bivalno okolje 1						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.23	0.21	0.24	0.20	0.23	0.19
MSE	0.10	0.10	0.12	0.09	0.14	0.08
MedAE	0.17	0.13	0.17	0.13	0.15	0.12
št. vzorcev	21080	21079	21080	21078	21080	21080
Bivalno okolje 2						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.15	0.15	0.17	0.12	0.14	0.11
MSE	0.04	0.04	0.06	0.02	0.05	0.02
MedAE	0.12	0.14	0.14	0.11	0.11	0.09
št. vzorcev	19840	19840	19840	19840	19840	19840
Pisarniško okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.33	0.33	0.38	0.31	0.33	0.29
MSE	0.52	0.52	0.56	0.50	0.50	0.47
MedAE	0.19	0.19	0.24	0.18	0.19	0.16
št. vzorcev	20088	20084	20088	20074	20088	20088
Industrijsko okolje						
	CH1	CH2	CH3	CH4	CH5	CH7
MAE	0.46	0.46	0.61	0.39	0.51	0.44
MSE	0.49	0.41	0.65	0.28	0.61	0.41
MedAE	0.25	0.34	0.49	0.32	0.28	0.31
št. vzorcev	20832	20832	20832	20832	20832	20832

6.5 Primerjava učinkovitosti s klasičnimi algoritmi

Predlagani model za detekcijo pogojev razširjanja signala brez neposredne vidljivosti s konvolucijskimi nevronske mrežami na podlagi neobdelanih surovih podatkov o impulznem odzivu kanala smo primerjali z običajnimi pristopi za razvrščanje vzorcev. Slednji uporabljajo izluščene značilke, ki jih določimo v fazi predobdelave vhodnega signala. Za potrebe klasičnega pristopa smo pripravili naslednje značilke: RSS, RSS prve fronte, povprečna presežna zakasnitev, RMS razpršitev zakasnitve, koeficient sploščenosti in koeficient simetrije.

Med klasičnimi pristopi z izluščenimi značilkami in vhodnimi vektorji majhnih dimenzij smo izbrali večplastni perceptron (angl. multilayer perceptron, MLP) in metodo podpornih vektorjev (angl. support vector machine, SVM). Uporabili smo implementacije iz knjižnice za strojno učenje scikit-learn [72] v programskem jeziku Python. Implementacijo SVM smo analizirali z dvema različnima jedrnima funkcijama (angl. kernel function), linearno jedrno funkcijo in radialno bazno funkcijo (angl. radial basis function, RBF).

Večplastni perceptron smo sestavili iz treh plasti, in sicer iz vhodne plasti s šestimi vhodnimi nevroni, iz skrite plasti s 152 nevroni in izhodne plasti z enim izhodnim nevrom. Za aktivacijsko funkcijo smo izbrali funkcijo ReLU. Izbrani optimizacijski algoritem za učni postopek je bil Adam s faktorjem hitrosti učenja $\eta = 10^{-4}$ (angl. learning rate) in začetnimi stanji sinaps oziroma uteži nastavljenimi na majhne naključne vrednosti. Vhodni podatki za klasične algoritme strojnega učenja so vektorji šestih predhodno omenjenih značilk. Celotna učna množica je bila pred učenjem in razvrščanjem še skalirana, da smo postavili vse vhodne spremenljivke v enako območje vrednosti. S tem se izboljšata konvergenca učnega postopka in uspešnost pri razpoznavanju vzorcev. Omenjenega postopka za model s konvolucijsko nevronske mrežo ne potrebujemo, ker že postopek paketne normalizacije v konvolucijski nevronske mreži poskrbi, da uteži znotraj nevronske mreže v učnem postopku ne dosežejo nerazumnih vrednosti.

Učne in testne množice za 10-kratno navzkrižno validacijo so sestavljene po enakem postopku, kot je bilo opisano v prejšnjih poglavjih. Skozi vse eksperimente se tako uporablja enake nabore učnih in testnih vzorcev, da je zagotovljena kar se da visoka stopnja primerljivosti rezultatov. Za primerjavo klasičnih algoritmov za razvrščanje vzorcev smo se osredotočili le na povprečne rezultate 10-kratne validacije, da se zagotovi večjo pregle-

Tabela 6.11: Učinkovitost razvrščevalnih algoritmov.

Bivalno okolje 1				
	SVM (linear)	SVM (RBF)	MLP	CNN
Točnost	86.14	86.18	84.87	88.27
Natančnost LoS	72.73	73.02	70.42	75.84
Priklic LoS	75.49	75.12	73.01	81.19
F1 LoS	74.08	74.06	71.69	78.42
Vzorci LoS	31248	31248	31248	31248
Natančnost NLoS	91.16	91.05	90.27	93.13
Priklic NLoS	89.93	90.12	89.09	90.79
F1 NLoS	90.54	90.59	89.67	91.95
Vzorci NLoS	87792	87792	87792	87792
Bivalno okolje 2				
	SVM (linear)	SVM (RBF)	MLP	CNN
Točnost	89.52	89.76	89.05	91.71
Natančnost LoS	90.17	89.90	90.67	92.30
Priklic LoS	96.55	97.28	95.19	97.04
F1 LoS	93.25	93.44	92.88	94.61
Vzorci LoS	89280	89280	89280	89280
Natančnost NLoS	86.85	89.18	83.04	89.51
Priklic NLoS	68.42	67.19	70.63	75.70
F1 NLoS	76.54	76.64	76.33	82.03
Vzorci NLoS	29760	29760	29760	29760
Pisarniško okolje				
	SVM (linear)	SVM (RBF)	MLP	CNN
Točnost	89.44	89.64	87.95	91.15
Natančnost LoS	78.41	78.87	75.32	80.87
Priklic LoS	79.32	79.62	76.59	84.31
F1 LoS	78.86	79.24	75.95	82.55
Vzorci LoS	29574	29574	29574	29574
Natančnost NLoS	93.14	93.24	92.22	94.74
Priklic NLoS	92.78	92.95	91.70	93.41
F1 NLoS	92.96	93.09	91.96	94.07
Vzorci NLoS	89466	89466	89466	89466
Industrijsko okolje				
	SVM (linear)	SVM (RBF)	MLP	CNN
Točnost	82.23	82.24	79.20	87.00
Natančnost LoS	80.13	80.79	77.19	85.45
Priklic LoS	83.87	82.77	80.60	87.98
F1 LoS	81.96	81.77	78.86	86.69
Vzorci LoS	57288	57288	57288	57288
Natančnost NLoS	84.36	83.65	81.23	88.53
Priklic NLoS	80.71	81.75	77.90	86.10
F1 NLoS	82.49	82.68	79.53	87.30
Vzorci NLoS	61752	61752	61752	61752

dnost in lažjo analizo rezultatov. Rezultati primerjave uspešnosti algoritma za razvrščanje vzorcev LoS in NLoS z uspešnostjo klasičnih algoritmov strojnega učenja so prikazani v tabeli 6.11.

Ob primerjavi rezultatov posameznih razvrščevalnikov lahko zaključimo, da algoritem s konvolucijskimi nevronskimi mrežami izkazuje rahlo boljše uspešnost, ki pa jo pridobimo predvsem na račun kompleksnosti samega razvrščevalnega algoritma. Zelo pomembna faktorja uspešnosti sta predvsem faktorja priklica (občutljivost) vzorcev LoS in NLoS, ki opisujeta sposobnost algoritma, da pravilno razpozna vzorce LoS in NLoS. Rezultati kažejo, da za uspešno razvrščanje vzorcev izbira algoritma ni tako bistvenega pomena, kot smo predvidevali. Pomembna je predvsem ustrezna priprava vhodnih podatkov. V primeru klasičnih algoritmov to zahteva postopek luščenja značilk, za kar je potrebna dobršna mera domenskega znanja. Potrebno je tudi ustrezno čiščenje podatkovne zbirke, da preprečimo neželene osamelce, ki lahko kritično vplivajo na uspešnost zgrajenih modelov. Pri klasičnih algoritmih je zelo pomembno skaliranje vhodnih podatkov, ki pa ga pri razvrščanju z globokim učenjem nadomesti vgrajeni pristop paketne normalizacije. Pri pristopu z globokim učenjem razen odstranjevanja osamelcev ne potrebujemo predobdelave vhodnih podatkov. To poenostavitev plačamo z veliko višjo kompleksnostjo modela in močno zmanjšano računsko učinkovitostjo.

6.6 Analiza računske učinkovitosti predlaganega razvrščevalnega algoritma

Konvolucijske nevronske mreže smo implementirali s pomočjo osnovnih gradnikov nevronskih mrež v knjižnici Keras, ki v našem primeru za računsko izvedbo vseh procesov uporablja odprtokodno knjižnico TensorFlow. Knjižnica TensorFlow je zasnovana za delo na različnih računskih platformah od zmogljivih delovnih postaj, strežnikov, računalniških gruč, pa do vstopnih modelov pametnih telefonov in malih vgradnih računalnikov z operacijskim sistemom GNU/Linux. Predlagani lokalizacijski sistemi naj bi delovali v realnem času in v realnem okolju s prenosnimi napravami, ki jih vsakodnevno uporabljamo, in napravami, ki so običajno na voljo za montažo kot infrastrukturne naprave na fiksnih mestih. Zato nas zanima predvsem delovanje predlaganih algoritmov na računsko omejenih oziroma manj zmogljivih napravah.

Za tovrstne naprave je bila izdelana knjižnica TensorFlow Lite¹, ki je namensko zasnovana za delovanje na pametnih telefonih z najnižjimi možnimi zahtevami po računski zmogljivosti in zahtevami po količini pomnilnika. Namesto standardne knjižnice za strukturirano serializacijo podatkov Protocol Buffers² je uporabljena knjižnica za podatkovno serializacijo FlatBuffers³, ki je z vidika obsežnosti manjša za cel velikostni razred in za razliko od Protocol Buffers izpušča določene procese za poenostavitev komunikacije in zmanjšanje računskih zahtev.

Predhodna verzija z zmanjšanimi zahtevami po računski zmogljivosti je tudi TensorFlow Mobile⁴. Obe knjižnici podpirata uporabo samo na mobilnih platformah z operacijskima sistemoma Android in iOS. Na standardni GNU/Linux platformi je brez predelav glede na naše poznavanje področja možna samo uporaba standardne verzije knjižnice TensorFlow.

6.6.1 Testirane računske platforme

Za testiranje in analizo učinkovitosti predlaganih algoritmov s konvolucijskimi nevronskimi mrežami smo izbrali osem široko dostopnih računalniških platform. Glede na zmogljivost smo jih razvrstili na: računsko omejene platforme, visoko-zmogljive platforme in ultra-zmogljive platforme. Računsko omejene platforme so namenjene uporabi za senzorska vozlišča v porazdeljenih senzorskih omrežjih, mobilne uporabniške terminale (angl. remote user terminals) ali prehode na obrobju omrežja (angl. edge gateways). Visoko-zmogljive platforme so namenjene uporabi v računsko intenzivnih aplikacijah, centraliziranih strežniških aplikacijah in za izvajanje oblačnih storitev. Ultra-zmogljive platforme so namenjene za uporabo v aplikacijah, kjer so zaradi velikih količin podatkov in zahtevnosti nalog potrebne velike količine pomnilnika RAM, večje število procesorskih jeder in namenski računski pospeševalniki.

Ena najbolj razširjenih cenovno dostopnih platform je vgradni računalnik Raspberry Pi⁵ z GNU/Linux operacijskim sistemom Raspbian⁶, ki temelji na GNU/Linux distribuciji Debian. Vse obstoječe verzije sistema Raspberry Pi uporabljajo mikroprocesorje ARM, ki so podobni tistim, ki se uporabljajo v pametnih mobilnih telefonih. V sklopu analize učinkovitosti smo uporabili verzijo 1 (RPI1) z eno-jedrnim mikroprocesorjem ARM1176JZF-S, 512 MB pomnilnika RAM, z osnovno frekvenco sistemske ure 700 MHz in novejšo ter zmo-

¹TensorFlow Lite, <https://www.tensorflow.org/mobile/tflite/>

²Protocol Buffers, <https://developers.google.com/protocol-buffers/>

³FlatBuffers, <https://google.github.io/flatbuffers/>

⁴TensorFlow Mobile, <https://www.tensorflow.org/mobile/>

⁵Raspberry Pi, <https://www.raspberrypi.org/>

⁶Raspbian, <https://www.raspberrypi.org/downloads/raspbian/>

gljivejšo tretjo verzijo platforme (RPI3) s štiri-jedrnim mikroprocesorjem ARM Cortex-A53, 1 GB pomnilnika RAM in z osnovno frekvenco sistemske ure 1,2 GHz. Tretjo računsko omejeno platformo predstavlja mrežni računalnik (angl. netbook, NET) (NET) s 64-bitnim procesorjem x86 Intel Atom N450 z dvema procesnima nitima (angl. thread), 2 GB pomnilnika RAM in frekvenco sistemske ure 1,66 GHz.

Visoko-zmogljive platforme predstavljajo ultra-lahki prenosni računalnik in dve visokozmogljivi mobilni delovni postaji. Lenovo Yoga ultrabook (UB) deluje na 64-bitnem procesorju Intel i7-4500U s štirimi procesorskimi nitmi pri osnovni frekvenci sistemske ure 1,8 GHz in 8 GB pomnilnika RAM. Naslednja visoko-zmogljiva platforma je mobilna delovna postaja HP EliteBook 8560w (WS1) s procesorjem Intel i7-2670QM z osmimi procesorskimi nitmi in 8 GB pomnilnika RAM. Zadnja, najzmogljivejša platforma je mobilna delovna postaja Dell XPS15 (WS2) s procesorjem Intel i7-6700HQ z osmimi procesorskimi nitmi in 16 GB pomnilnika RAM. Vse računske platforme razen platform Raspberry Pi uporabljajo isto verzijo GNU/Linux operacijskega sistema Ubuntu 16.04.3 LTS, platformi Raspberry PI pa uporabljata GNU/Linux operacijski sistem Raspbian, ki temelji na GNU/Linux operacijskem sistemu Debian 9.1. Vsi tehnični parametri izbranih računskih platform so zbrani v tabeli 6.12.

Za analizo računskih učinkovitosti smo dodali še dve ultra-zmogljivi platformi, ki sta dokaj pogosti v okoljih z delom na področju globokega učenja. Zagotavljata visoko računsko zmogljivost in predvsem kratke čase učenja zelo zahtevnih globokih nevronske mrež. V praksi sta obe platformi združeni v eni delovni postaji. Platforma G4 predstavlja klasično visoko-zmogljivo delovno postajo z 20-nitnim procesorjem Intel i9-7900X in 32 GB pomnilnika RAM. Druga platforma (RTX) je dejansko priključena na prvo platformo in je grafični pospeševalnik Nvidia RTX 2080 Ti z 68 serijskimi procesorskimi enotami (angl. streaming multiprocessor), 4352 aritmetičnimi enotami, pospeševalnikom za računske operacije nad matrikami in osnovnim taktom 1,35 GHz. Platforma RTX brez osnovne delovne postaje ne more delovati, knjižnica TensorFlow pa lahko uporablja samo eno od obeh platform sočasno. Grafični pospeševalniki so uporabni kot izjemni pospeševalniki za učenje globokih nevronske mrež, ki brez težav za 10-krat zmanjšajo čas učenja v primerjavi s klasičnimi večnamenskimi procesorji.

6.6.2 Določitev testov učinkovitosti

Določili smo specifičen test učinkovitosti algoritma za razvrščanje vzorcev LoS in NLoS, ki je pokazal, kako hitro je izbrana računsko platforma sposobna razpoznati vzorce glede na število vzorcev v paketu. Knjižnica TensorFlow je optimirana za numerično računanje z velikimi organiziranimi večdimenzionalnimi numeričnimi matrikami (tenzorji) in je zato pričakovati, da deluje najboljše z večjimi paketi vhodnih vzorcev. Test je napisan v programskem jeziku Python z uporabo dodatnih matematičnih knjižnic NumPy in Pandas ter dodatno knjižnico za strojno učenje scikit-learn [72].

Algoritem 6.1: Psevdokoda algoritma za analizo učinkovitosti.

Vhod: *testna_mnozica* $\leftarrow$ *nalozi_podatke*

za *i* = 0 **do** 11 **delaj**

zacetni_cas $\leftarrow$ *trenutni_cas*;

za *j* = 1 **do** 1000 **delaj**

 | *razvrsti*(*testna_mnozica.naslednjiPaket*(2^i));

konec

koncni_cas $\leftarrow$ *trenutni_cas*;

ucinkovitost[*i*] $\leftarrow$ $(1000 * 2^i) / (koncni_cas - zacetni_cas)$;

konec

Tabela 6.12: Izbrane računske platforme za analizo računske učinkovitosti.


	RPI1	NET	RPI3
CPU	ARM1176JZF-S	Atom N450	ARM Cortex-A53
Frekvenca CPU [GHz]	0.7	1.66	1.2
Število niti	1	2	4
RAM	512 MB	2 GB	1 GB
OS	Debian 9.1	Ubuntu 16.04	Debian 9.1
TF ver.	1.4.0	1.4.0	1.4.0
	UB	WS1	WS2
CPU	i7-4500U	i7-2670QM	i7-6700HQ
Frekvenca CPU [GHz]	1.8 - 3.0	2.2 - 3.1	2.6 - 3.5
Število niti	4	8	8
RAM	8 GB	8 GB	16 GB
OS	Ubuntu 16.04	Ubuntu 16.04	Ubuntu 16.04
TF ver.	1.4.0	1.4.0	1.4.0
	G4	RTX	
CPU	i9-7900X	RTX 2080 Ti	
Frekvenca CPU [GHz]	3.3 - 4.3	1.35 - 1.635	
Število niti	20	68	
RAM	32 GB	11 GB	
OS	Ubuntu 18.04	Ubuntu 18.04	
TF ver.	1.12.0	1.12.0	

Predlagani test je predstavljen v psevdokodi z algoritmom 6.1. Algoritem najprej naloži in nastavi model za razvrščanje. V naslednjem koraku naloži testno podatkovno zbirko iz *.csv* datotek in jih ustrezno oblikuje za serviranje konvolucijski nevronske mreži. Prvih 152 podatkovnih točk od začetnega indeksa prve fronte impulznega odziva vsakega vzorca se izbere in doda v tabelo testnih vzorcev. V naslednjem koraku algoritem izmeri čase za izvajanje 1000 ponovitev razvrščanja za posamezne velikosti paketov vzorcev. Velikosti paketov vzorcev se inkrementalno večajo po formuli 2^n , kjer gre n od 0 do 11. Na ta način določimo množico testnih paketov velikosti $\{1, 2, 4, 8, 16, 32, 64, 128, 256, 512, 1024, 2048\}$.

Proces razvrščanja posameznega vzorca poteka tako, da je vsak vhodni paket vzorcev impulznega odziva kanala predan konvolucijski nevronske mreži za razvrščanje s predhodno naučenim modelom za razvrščanje vzorcev LoS in NLoS. Število razvrščenih vzorcev znotraj niza 1000 ponovitev delimo s porabljenim časom za razvrščanje teh vzorcev, s čimer dobimo učinkovitost razvrščanja algoritma za izbrano velikost paketa vzorcev v obliki *vzorci/s*.

6.6.3 Rezultati analize učinkovitosti razvrščanja vzorcev

Zahteve po računski zmogljivosti za posamezne računske platforme so odvisne od tega, kje v omrežju se platforma nahaja in kakšna je njena funkcija. V primeru lokalizacijskega sistema UWB, ki izkorišča informacijo o impulznem odzivu kanala, potrebuje posamezno vozlišče zgolj sposobnost za razvrščanje do največ nekaj deset vzorcev na sekundo, naprava v obrobju omrežja (angl. edge device), kot na primer sidrno vozlišče, pa zahteva sposobnost razvrščanja nekaj sto vzorcev na sekundo. Kadar se lokalizacija izvaja na centraliziranem lokalizacijskem sistemu, mora biti centralna računska platforma sposobna razvrstiti nekaj



Slika 6.6: Prikaz učinkovitosti razvrščanja vzorcev na posameznih računskih platformah.

tisoč vzorcev na sekundo, da so osvežitve položaja dovolj hitre in da ima centralna naprava še dovolj procesorskih ciklov za izvajanje ostalih opravil.

Vse testirane računske platforme so izkazale podobno obnašanje z naraščanjem velikosti paketov vzorcev. Učinkovitost je naraščala z večanjem paketov vzorcev, naraščanje pa se je zaustavilo v trenutku, ko so bili računski viri optimalno izkoriščeni. TensorFlow je namreč zasnovan tako, da deluje optimalno na večjih kosih podatkov, kar je lepo razvidno iz slike 6.6. Učinkovitost razvrščevalnega algoritma je za majhne pakete vzorcev omejena s hitrostjo prenosa podatkov in odzivnih časov posameznih komponent v računski verigi za razvrščanje (nalaganje podatkov, razvrščanje). Za večje pakete vzorcev je manj časa porabljenega za nalaganje podatkov na posamezen vzorec, opravila pa so lažje razporejena med več razpoložljivih računskih enot (niti) znotraj računske platforme. Večina računskih platform doseže vrh učinkovitosti razvrščanja pri paketih s 1024 vzorci, razen najmanj zmogljivih platform RPI1 in NET in najzmogljivejše platforme RTX. Prvi dve platformi dosežeta vrh učinkovitosti pri manjših paketih vzorcev zaradi manjše količine razpoložljivega pomnilnika, manjšega števila računskih niti in slabše učinkovitosti mikroprocesorja. Platforma RTX doseže najvišjo učinkovitost pri velikostih paketov vzorcev, ki presegajo omejitve razpoložljivega pomnilnika RAM na računsko omejenih platformah.

Platforma RPI1 je sposobna razvrstiti 92 vzorcev na sekundo pri 4 vzorcih v paketu. To je zadostna zmogljivost za izvajanje tridimenzionalne lokalizacije na večini mobilnih naprav. Najvišjo učinkovitost platforma RPI1 doseže z 212 razvrščanji na sekundo z 256 vzorci v paketu. Novejša različica iste platforme RPI3 je dovolj zmogljiva za delovanje v funkciji naprave v obrobju omrežja s 514 razvrščanji na sekundo pri 4 vzorcih v paketu, 3577 razvrščanji na sekundo z 256 vzorci v paketu in doseže največjo učinkovitost 4252 razvrščanj na sekundo z 2048 vzorci v paketu. Računska platforma NET je ravno tako primerna za funkcijo naprave v obrobju omrežja z največjo učinkovitostjo 1688 razvrščanj na sekundo z 2048 vzorci v paketu, a je zaradi zastarelosti kljub višjemu cenovnemu razredu naprave v primerjavi s platformama RPI1 in RPI3 manj učinkovita.

Visoko-zmogljive računske platforme so primerne za uporabo v centraliziranih sistemih za lokalizacijo, kjer najmanj učinkovita platforma UB doseže 3723 razvrščanj na sekundo pri 4 vzorcih v paketu, 17339 razvrščanj na sekundo pri 256 vzorcih v paketu in doseže največjo učinkovitost 18183 razvrščanj pri 512 vzorcih v paketu. Visoko-zmogljiva računska platforma WS1 doseže 1223 razvrščanj na sekundo pri 4 vzorcih v paketu, 29182 razvrščanj na sekundo pri 256 vzorcih v paketu in doseže največjo učinkovitost 34933 razvrščanj na

sekundo pri 2048 vzorcih v paketu. Najnovejša med visoko-zmogljivimi platformami in najbolj učinkovita med njimi WS2 doseže 1686 razvrščanj na sekundo pri 4 vzorcih v paketu, 39713 razvrščanj na sekundo pri 256 vzorcih v paketu in doseže največjo učinkovitost 50531 razvrščanj na sekundo z 2048 vzorci v paketu.

Ultra-zmogljivi računski platformi močno odstopata od ostalih po številu razvrščenih vzorcev na časovno enoto. Platforma G4 pri paketih s 4 vzorci doseže hitrost 2840 vzorcev na sekundo, pri 256 vzorcih v paketu doseže hitrost razvrščanja z 27343 vzorci na sekundo, največjo hitrost pa doseže pri 2048 vzorcih na sekundo in to kar 85854 vzorcev na sekundo. Platforma RTX pri 4 vzorcih v paketu doseže 1143 vzorcev na sekundo, pri 256 vzorcih v paketu doseže hitrost 65702 vzorcev na sekundo, največjo hitrost razvrščanja pa doseže pri 16384 vzorcih na sekundo, in sicer 552485 vzorcev na sekundo. Platforma RTX se izkaže za uporabno v primerih, ko je potrebno razvrščanje izredno velikega števila vzorcev v paketu, platforma G4 pa je na splošno uporabna za vse načine uporabe.

Rezultati analize dokazujejo, da lahko lokalizacijo, ki uporablja konvolucijske nevronske mreže za izboljševanje točnosti lokalizacije, uporabimo tudi na računsko omejenih napravah v distribuiranih lokalizacijskih sistemih. Porazdeljena izvedba takih lokalizacijskih algoritmov ima številne prednosti pred centraliziranimi sistemi:

- zmanjšana potreba po prenašanju impulznih odzivov kanala v centralno računsko enoto,
- hitrejši odzivni časi pri lokalizaciji,
- večja skalabilnost sistemov za lokalizacijo.

Poglavje 7

Lokalizacija z uporabo modelov za razvrščanje in regresijo

Položaj oseb in predmetov v notranjih okoljih lahko določimo na veliko načinov [123]. Eden od njih je aktivna lokalizacija na podlagi razdalj med točko z neznanim položajem in referenčnimi točkami z znano lokacijo. Pulzni radio UWB DW1000 omogoča, da na podlagi ocenjenega časa dvosmernega potovanja paketa izmerimo razdalje do vseh sidrnih vozlišč in z eno od številnih matematičnih metod ocenimo položaj.

V senzorskih omrežjih imajo senzorska vozlišča običajno na razpolago omejene računske zmogljivosti, poleg tega pa je vse podvrženo tudi varčevanju z energijo. Računanje položaja z linearnimi metodami najmanjših kvadratov je običajno suboptimalno v primerjavi z iterativnimi metodami, ponuja pa razumno točnost pozicioniranja z nizko zahtevnostjo implementacije, ki je bistvena v sistemih z omejenimi računskimi in energijskimi viri [124]. Z uporabo ocen za napako izmerjene razdalje lahko na različne načine izboljšamo točnost lokalizacije, če pa uporabimo metodo uteženih najmanjših kvadratov, pa se točnost zaradi uteževanja posameznih prispevkov glede na njihovo zanesljivost še dodatno poveča.

Drugi sklop pristopov za sledenje in lokalizacijo pa zajema različne izvedbe z uporabo razširjenega Kalmanovega filtra. Različne izvedbe Kalmanovih filtrov se veliko uporabljajo v sistemih za lokalizacijo in sledenje [125]. Prednost pristopov s Kalmanovim filtrom v primerjavi z metodami najmanjših kvadratov je predvsem v upoštevanju kinematičnega modela sistema in s tem fizikalnih omejitev gibanja objekta, ki mu sledimo. Poleg uporabe modela, je naslednje stanje sistema vedno odvisno od predhodnega stanja, kar še dodatno omejuje razpršenost ocen položajev objekta. Razširjeni Kalmanov filter se veliko uporablja predvsem v povezavi z metodo hkratne lokalizacije in kartiranja (SLAM) [126] in za zlivanje različnih senzorskih virov s kinematičnim modelom sistema (npr. GPS v povezavi inercialnih senzorjev za izboljšanje navigacije ob začasni izgubi GPS signala [127]).

V tem poglavju za izboljšanje lokalizacije na različne načine uporabimo modele za razvrščanje in modele za oceno napake izmerjene razdalje iz poglavja 6. V prvem delu se posvetimo različnim pristopom z uporabo metode najmanjših kvadratov, v drugem delu pa predlagamo pristop z razširjenim Kalmanovim filtrom (angl. Extended Kalman Filter).

7.1 Lokalizacija z metodo najmanjših kvadratov

Najenostavnejši pristop k lokalizaciji z metodo najmanjših kvadratov (angl. least squares, LS) dobimo, če predpostavimo, da je problem iskanja položaja linearen. Z linearizacijo poenostavimo izračun in se izognemo računsko zahtevnejšemu iterativnemu reševanju problemov. Problema lokalizacije in njenega izboljševanja se bomo v sklopu metode najmanjših kvadratov lotili z naslednjimi pristopi:

- z metodo najmanjših kvadratov z nespremenjenimi meritvami razdalj,
- z metodo najmanjših kvadratov z izločanjem meritev NLoS (meritve NLoS določimo z razvrščevalnim algoritmom NLoS),
- z metodo najmanjših kvadratov z odštevanjem ocenjene napake izmerjene razdalje (napako izmerjene razdalje ocenimo z regresijskim algoritmom za oceno napake izmerjene razdalje),
- z metodo uteženih najmanjših kvadratov (angl. weighted least squares, WLS),
- z metodo WLS in odštevanjem ocenjene napake od izmerjenih razdalj.

7.1.1 Metoda najmanjših kvadratov

Razdaljo med vozliščem z iskanim položajem in sidrnim vozliščem z znano lokacijo lahko zapišemo kot evklidsko razdaljo (7.1)

$$d_i = \|\mathbf{p} - \mathbf{p}_i\| = \sqrt{(x - x_i)^2 + (y - y_i)^2}, \quad (7.1)$$

kjer $\hat{d}_i$ predstavlja izmerjeno razdaljo med vozliščem z neznanim položajem in i-tim sidrnim vozliščem, $\mathbf{p} = [x \ y]^T$ je neznani položaj vozlišča, $\mathbf{p}_i = [x_i \ y_i]^T$ pa je znana lokacija i-tega sidrnega vozlišča [124].

Izmerjeno razdaljo $\hat{d}_i$ modeliramo z enačbo (7.2),

$$\hat{d}_i = d_i + n_i \quad (7.2)$$

kjer d_i predstavlja evklidsko razdaljo brez merilne napake, n_i pa je merilna napaka, ki jo modeliramo kot Gaussov proces z ničelno povprečno vrednostjo in varianco σ_i^2 .

Po zajemu vseh meritev razdalj $\hat{d}_i$ od vozlišča z neznanim položajem $\mathbf{p}$ pa do vseh sidrnih vozlišč $\mathbf{p}_i$, dobimo sistem enačb (7.3).

$$(x - x_i)^2 + (y - y_i)^2 = \hat{d}_i^2, i = 1, 2, \dots, N \quad (7.3)$$

Z reorganizacijo enačbe (7.3) dobimo enačbo (7.4),

$$-2x_i x - 2y_i y + x^2 + y^2 = \hat{d}_i^2 - x_i^2 - y_i^2 \quad (7.4)$$

nato uvedemo novo spremenljivko $R = x^2 + y^2$ in z $\boldsymbol{\theta} \doteq [x \ y \ R]^T$ definiramo oceno položaja. Sedaj lahko sistem enačb (7.4) zapišemo v matrični obliki $\mathbf{b} = \mathbf{A}\boldsymbol{\theta}$ z matrikama (7.5) in (7.6).

$$\mathbf{A} = \begin{bmatrix} -2x_1 & -2y_1 & 1 \\ -2x_2 & -2y_2 & 1 \\ \vdots & \vdots & \vdots \\ -2x_N & -2y_N & 1 \end{bmatrix} \quad (7.5)$$

$$\mathbf{b} = \begin{bmatrix} \hat{d}_1^2 - x_1^2 - y_1^2 \\ \hat{d}_2^2 - x_2^2 - y_2^2 \\ \vdots \\ \hat{d}_N^2 - x_N^2 - y_N^2 \end{bmatrix} \quad (7.6)$$

Algoritem z metodo najmanjših kvadratov poišče takšno vrednost $\boldsymbol{\theta}$, da se signalni model $s[n]$ čim bolj prilega podatkom $b[n]$. Kriterij za napako metode najmanjših kvadratov je definiran z enačbo (7.7) [128]. Vrednost θ , ki minimizira napako $J(\theta)$, predstavlja oceno po metodi najmanjših kvadratov.

$$J(\theta) = \sum_{n=0}^{N-1} (b[n] - s[n])^2 \quad (7.7)$$

Tabela 7.1: Prikaz izboljševanja točnosti lokalizacije z večanjem števila razpoložljivih sidrskih vozlišč. Mediana absolutne napake (MedAE) se kljub večanju števila sidrskih vozlišč rahlo povečuje, kar kaže na večji delež rezultatov z višjo napako blizu sredinski vrednosti kot pri manjšem številu sidrskih vozlišč, po drugi strani pa se zmanjša delež rezultatov z zelo velikimi napakami, kar prispeva k manjši povprečni napaki rezultatov in njihovi manjši razpršenosti.

št. sider	MAE [m]	MedAE [m]	σ [m]
3	1.745	0.796	3.220
4	1.059	0.641	1.262
5	0.896	0.610	0.895
6	0.829	0.616	0.751
7	0.806	0.638	0.675
8	0.786	0.659	0.612
9	0.779	0.672	0.572
10	0.773	0.679	0.551

Matrični zapis (7.8) lahko uporabimo za vektorske zapise signala $\mathbf{s} = [s[0]s[1] \dots s[N-1]]^T$, kjer je $\mathbf{A}$ znana opazovalna matrika (angl. observation matrix) dimenzij $N \times p$ s polnim rangom matrike p .

$$\mathbf{s} = \mathbf{A}\boldsymbol{\theta} \quad (7.8)$$

Oceno položaja po metodi najmanjših kvadratov dobimo z minimiziranjem enačbe (7.7), kar rezultira v linearno matrično enačbo (7.10) v normalni obliki.


$$J(\boldsymbol{\theta}) = (\mathbf{b} - \mathbf{A}\boldsymbol{\theta})^T(\mathbf{b} - \mathbf{A}\boldsymbol{\theta}) \quad (7.9)$$

$$\hat{\boldsymbol{\theta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} \quad (7.10)$$

Pristop k ocenjevanju položaja po metodi najmanjših kvadratov je najenostavnejši pristop, ki temelji na izmerjenih razdaljah med vozliščem z neznanim položajem in več sidrnimi vozlišči. Uporabimo ga v primeru, ko ne poznamo varianc izmerjenih razdalj oziroma merilnih negotovosti. Predpostavimo, da imajo vsi izmerki enako merilno negotovost, zato je točnost ocenjenega položaja močno odvisna od dejanskih merilnih negotovosti izmerjenih napak oziroma dejanskih napak izmerjenih razdalj. Z večanjem števila razpoložljivih sidrskih vozlišč in izmerjenih razdalj do njih se zaradi lastnosti metode najmanjših kvadratov po iskanju najboljšega prileganja meritev končnemu rezultatu točnost lokalizacije izboljšuje, kar je prikazano v tabeli 7.1.

7.1.2 Metoda najmanjših kvadratov z izločanjem NLoS razdalj

Razdalje NLoS v postopku lokalizacije zaradi pozitivnega odstopanja izmerjene razdalje od prave razdalje vnašajo napako v ocenjen položaj. Prvi pristop, s katerim bomo poskušali zmanjšati napako ocenjenega položaja, je pristop z odstranjevanjem razdalj NLoS iz nabora razdalj za lokalizacijo. Z modeli za razvrščanje vzorcev LoS in NLoS iz poglavja 6.3 bomo na podlagi pridobljenih impulznih odzivov ocenili, katere razdalje spadajo v razred NLoS, in jih odstranili iz nabora izmerkov za lokalizacijo. Zapomniti si je treba, da za uspešno oceno položaja v dvodimenzionalnem koordinatnem sistemu potrebujemo vsaj tri izmerke razdalje do treh nekolinearnih sidrskih vozlišč.



Slika 7.1: Napaka izmerjene razdalje narašča z razdaljo in zahtevnostjo radijskega okolja.

7.1.3 Metoda najmanjših kvadratov z odštevanjem ocenjene napake izmerjene razdalje

Naslednji pristop za izboljšanje točnosti lokalizacije, ki temelji na metodi najmanjših kvadratov, je pristop z zmanjševanjem izmerkov razdalj za pripadajoče ocene napake izmerjene razdalje. Pri tem pristopu uporabimo regresijske modele za oceno napake izmerjene razdalje iz poglavja 6.4. Impulzne odzive za posamezne izmerke razdalje med iskanim položajem in sidrnim vozliščem podamo na vhod modela za oceno napake izmerjene razdalje in dobljeno oceno napake odštejemo od izmerjene razdalje. Izmerjena razdalja je vedno večja od evklidske razdalje, ker vplivi okolja, v katerem se signal razširja, podaljšajo pot signala ali pa zmanjšajo hitrost njegovega razširjanja, merilni šum pa je v večini primerov zanemarljivo majhen v primerjavi z napako, ki jo vnese razširjanje v realnem okolju. Tako pridobljene vhodne podatke sedaj uporabimo v klasičnem algoritmu za oceno položaja po metodi najmanjših kvadratov.

7.1.4 Metoda uteženih najmanjših kvadratov

Pri ocenjevanju položaja po metodi najmanjših kvadratov smo predpostavili, da so merilne napake in s tem variance za vse prispevke enake. V realnem okolju se izkaže, da napaka izmerjene razdalje narašča z večanjem vpliva efekta razširjanja brez neposredne vidljivosti in z naraščajočo razdaljo, kar prikazuje slika 7.1. Doprinos merilnih napak razdalje na končno učinkovitost lokalizacijskega algoritma je destruktiven, zato vpeljemo uteževanje posameznih izmerkov, kar lahko bolj poudari doprinose izmerkov z večjim ocenjenim zaupanjem proti izmerkom z nižjim ocenjenim zaupanjem [124].

Z vpeljavo diagonalne $N \times N$ pozitivno definitne utežne matrike $\mathbf{W}$ (7.11),

$$\mathbf{W} = \begin{bmatrix} w_1 & 0 & \dots & 0 \\ 0 & w_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & w_n \end{bmatrix}, \quad (7.11)$$

lahko kriterijsko funkcijo (7.9) preoblikujemo v novo obliko, ki je prikazana z enačbo (7.12).

$$\begin{aligned} J(\theta) &= \sum_{n=0}^{N-1} w_i (b[n] - s[n])^2 \\ &= (\mathbf{b} - \mathbf{A}\theta)^T \mathbf{W} (\mathbf{b} - \mathbf{A}\theta) \end{aligned} \quad (7.12)$$

Kot utež w_i za posamezno izmerjeno razdaljo med vozliščem in sidrnim vozliščem izberemo inverz produkta izmerjene razdalje d_i in kvadrata ocenjene napake ϵ_i , kar prikazuje enačba (7.13). Na ta način še dodatno poudarimo zanesljivost prispevkov bližnjih sidrnih vozlišč z manjšimi napakami izmerjene razdalje na učinkovitost lokalizacijskega algoritma.

$$w_i = \frac{1}{d_i \epsilon_i^2}. \quad (7.13)$$

Ocenjeni položaj vozlišča $\hat{\theta}_{WLS}$ lahko sedaj zapišemo v obliki za izračun po metodi uteženih najmanjših kvadratov z enačbo (7.14).

$$\hat{\theta}_{WLS} = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{b} \quad (7.14)$$

Tipično se za uteževanje pri metodi uteženih najmanjših kvadratov kot uteži uporablja inverzne vrednosti variance posameznih prispevkov $w_i = 1/\sigma_i^2$ [129]. Za izračun posameznih uteži uporabimo regresijske modele za oceno napake izmerjene razdalje in z njimi na podlagi impulznih odzivov posameznih izmerkov ocenimo pripadajočo napako izmerjene razdalje ϵ_i . Predpostavimo, da varianco naših meritev razdalje določa kvadrat ocenjene napake izmerjene razdalje ϵ_i^2 , zaradi naraščanja napake z večanjem medsebojne razdalje d_i pa kvadratno vrednost ocenjene napake pomnožimo še z izmerjeno razdaljo. Da bi omilili prispevek k uteževanju zaradi večanja medsebojne razdalje smo namesto kvadrata razdalje uporabili samo izmerjeno razdaljo. Na podlagi predlagane enačbe (7.13) izračunamo utež posameznega izmerka w_i , ki ga dodamo v utežno matriko $\mathbf{W}$. Sedaj z uporabo utežne matrike (7.14) v enačbi (7.14) izračunamo položaj za podan nabor izmerkov do sidrnih vozlišč.

7.2 Lokalizacija s Kalmanovim filtrom

Kalmanov filter je algoritem, ki upošteva skupne verjetnostne porazdelitve (angl. joint probability distribution) časovno odvisnih spremenljivk in oceni neznano veličino za vsak časovni okvir posebej, tako da je ocena (npr. položaja) običajno bolj točna kot pa ocena, ki temelji na enem samem izmerku (npr. v primeru metode najmanjših kvadratov) [5]. Uporaba Kalmanovega filtra je zelo razširjena na področju vodenja in navigacije vozil, analize časovnih vrst, ekonometrije, robotike in nasploh povsod, kjer potrebujemo zanesljivo sledenje odvisnim spremenljivkam na toku časovnega zaporedja odvisnih in neodvisnih spremenljivk tudi z upoštevanjem prejšnjega stanja sistema.

Kalmanov filter je tako namenjen učinkovitemu sledenju spremenljivkam v časovnem zaporedju. Na področju lokalizacije ga ne uporabljamo za enkratno določanje položaja, ampak za sledenje objektom in osebam.

Proces ocene položaja s Kalmanovim filtrom je sestavljen iz dveh korakov:

- ocena stanja,
- posodobitev stanja.

V koraku ocene stanja sistema (7.15) [5] oceno novega stanja sistema $\hat{\mathbf{x}}_k^-$ ocenimo s pomočjo kinematičnega modela sistema v obliki matrike prehajanja stanj $\mathbf{F}_k$, prejšnjega stanja sistema $\hat{\mathbf{x}}_{k-1}^+$ in vektorja vhodov $\mathbf{u}_{k-1}$. Kovariančno matriko stanja $\mathbf{P}_k^-$ izračunamo z

matriko prehajanja stanj, kovariančne matrike predhodnega stanja sistema $\mathbf{P}_{k-1}^+$ in kovariančne matrike šuma sistema $\mathbf{Q}_{k-1}$. Nadpisan znak $(-)$ pri posameznem stanju pomeni, da je to stanje matrike ali vektorja po koraku ocene stanja, nadpisan znak $(+)$ pa oznaka stanja po zaključnem koraku posodobitve stanja.

$$\begin{aligned}\hat{\mathbf{x}}_k^- &= \mathbf{F}_k \cdot \hat{\mathbf{x}}_{k-1}^+ + \mathbf{B}_k \cdot \mathbf{u}_{k-1} \\ \mathbf{P}_k^- &= \mathbf{F}_k \cdot \mathbf{P}_{k-1}^+ \cdot \mathbf{F}_k^T + \mathbf{Q}_{k-1}\end{aligned}\quad (7.15)$$

Matrika $\mathbf{B}$ predstavlja krmilno matriko, ki skupaj s krmilnim vektorjem $\mathbf{u}$ določa krmilne vhode v sistem. To je uporabno v primerih, ko modeliramo na primer gibanje robota, kjer poleg modela gibanja robota poznamo tudi krmilne vhode v obliki navorov na kolesih. Ker v primeru lokalizacije in sledenja človeku med hojo v notranjih okoljih kontrolne funkcije ne poznamo, uporabimo model sistema brez kontrolnih vhodov (torej brez $\mathbf{B}$ in $\mathbf{u}$).

V koraku posodobitve stanja (7.16) [5] izračunamo Kalmanovo ojačenje (angl. Kalman gain) $\mathbf{K}_k$ iz ocenjene kovariančne matrike stanja $\mathbf{P}_k^-$, merilne funkcije $\mathbf{H}_k$ in merilne kovariančne matrike $\mathbf{R}_k$. Kalmanovo ojačenje kontrolira razmerje, kako filter pri oceni stanja sistema utežuje prispevka ocenjenega stanja $\hat{\mathbf{x}}_k^-$ in meritev z_k . Ko je merilna kovariančna matrika $\mathbf{R}_k$ sestavljena iz majhnih kovariančnih vrednosti v primerjavi z vrednostmi v kovariančni matriki stanja sistema, so meritve vredne visokega zaupanja. Kalmanovo ojačenje v tem primeru poveča utežitev prispevka meritev nasproti prispevku ocene stanja na podlagi kinematičnega modela. Kovariančno matriko sistema po posodobitvi stanja $\mathbf{P}_k^+$ in posodobitev stanja z meritvami $\hat{\mathbf{x}}_k^+$ izračunamo kot prikazujejo enačbe (7.16).

$$\begin{aligned}\mathbf{K}_k &= \mathbf{P}_k^- \cdot \mathbf{H}_k^T \cdot [\mathbf{H}_k \cdot \mathbf{P}_k^- \cdot \mathbf{H}_k^T + \mathbf{R}_k]^{-1} \\ \mathbf{P}_k^+ &= [\mathbf{I} - \mathbf{K}_k \cdot \mathbf{H}_k] \cdot \mathbf{P}_k^- \\ \hat{\mathbf{x}}_k^+ &= \hat{\mathbf{x}}_k^- + \mathbf{K}_k \cdot (z_k - \mathbf{H}_k \cdot \hat{\mathbf{x}}_k^-)\end{aligned}\quad (7.16)$$

Za sledenje osebi smo izbrali preprost kinematični model, ki predpostavlja konstantno hitrost osebe [130]. Model opisujejo štiri spremenljivke: pozicija po x-osi x , pozicija po y-osi y , hitrost po x-osi $\dot{x}$ in hitrost po y-osi $\dot{y}$. Osnovna oblika Kalmanovega filtra zahteva linearni model sistema in linearni merilni model. Linearni kinematični model sistema je določen z enačbo (7.17), merilni model pa je nelinearen. Kadar je kateri koli od modelov nelinearen, se poslužimo pristopa z razširjenim Kalmanovim filtrom (angl. extended Kalman filter, EKF) [5]. S pristopom EKF vse nelinearne modele najprej lineariziramo v okolici trenutne točke, potem pa postopek zaključimo s standardnim postopkom Kalmanovega filtra na lineariziranih modelih.

$$\mathbf{f}_k(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) = \begin{bmatrix} x + \Delta t \cdot \dot{x} \\ y + \Delta t \cdot \dot{y} \\ \dot{x} \\ \dot{y} \end{bmatrix}\quad (7.17)$$

Iz enačbe (7.17) najprej razvijemo sistemsko matriko (matrika prehajanja stanj) $\mathbf{F}_k$, ki je prikazana z enačbo (7.18). V enačbi Δt predstavlja časovni korak filtra, ki predstavlja časovno razliko med dvema zaporednima posodobitvama filtra oz. hitrost posodabljanja stanja sistema.

$$\mathbf{F}_k = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}\quad (7.18)$$

Kovariančna matrika stanja se samodejno posodablja z vsako iteracijo uporabe filtra. Pomembno je le, da izberemo smiselne začetne vrednosti varianc σ^2 za začetno kovariančno matriko stanja $\mathbf{P}_0$, potem pa v naslednjih korakih filter prevzame vse potrebne procese posodabljanja vrednosti kovariančne matrike stanja $\mathbf{P}_k$.

Za varianci položajev po x in y -osi (σ_x^2 in σ_y^2) lahko na podlagi tega, da začetni položaj določimo z uporabo metode najmanjših kvadratov, uporabimo kar kvadrat standardnega odklona točnosti lokalizacije za osem sidrnih vozlišč, ki je podana v tabeli 7.1. Standardni odklon točnosti položaja z uporabo osmih sidrnih vozlišč je $\sigma_{x,y} = 0,612 m$, iz tega pa sledi, da sta izbrani varianci $\sigma_x^2 = 0,375 m^2$ in $\sigma_y^2 = 0,375 m^2$. Za variance hitrosti ($\sigma_{\dot{x}}^2$ in $\sigma_{\dot{y}}^2$) lahko predpostavimo, da je največja sprememba hitrosti med dvema zaporednima točkama $\Delta v = 0,1 m s^{-1}$, kar je enako trem standardnim odklonom hitrosti ($3\sigma_{\dot{x},\dot{y}} = \Delta v = 0,1 m s^{-1}$), varianci hitrosti po oseh x in y pa sta $\sigma_{\dot{x}}^2 = 0,0011 m^2 s^{-2}$ in $\sigma_{\dot{y}}^2 = 0,0011 m^2 s^{-2}$. Začetno kovariančno matriko stanja prikazuje enačba 7.19.

$$\mathbf{P}_0 = \begin{bmatrix} \sigma_x^2 & 0 & 0 & 0 \\ 0 & \sigma_y^2 & 0 & 0 \\ 0 & 0 & \sigma_{\dot{x}}^2 & 0 \\ 0 & 0 & 0 & \sigma_{\dot{y}}^2 \end{bmatrix} \quad (7.19)$$

Pri modeliranju s Kalmanovim filtrom predpostavimo, da so veličine znotraj celotnega časovnega koraka (ena posodobitev stanja sistema) konstantne. V resnici se veličine ves čas vsaj malo spreminjajo na podlagi zunanjih dejavnikov, ki jih nismo vključili v model sistema. Predpostavimo lahko, da se v našem primeru hitrost spreminja z značilnostni belega šuma $w(t)$ s povprečno vrednostjo $\mu_w = 0$. S tem predpostavimo, da so spremembe v povprečju enake 0.

Ker je šum zvezni proces, moramo za izpeljavo diskretne matrike sistemškega šuma $\mathbf{Q}$ integrirati na diskretnem intervalu dolžine Δt , kar prikazuje enačba (7.20).

$$\mathbf{Q} = \int_0^{\Delta t} \mathbf{F}(t) \mathbf{Q}_c \mathbf{F}^T(t) dt \quad (7.20)$$

Zvezni šum $\mathbf{Q}_c$ s spektralno gostoto moči Φ_S je definiran z matriko (7.21). Spektralne gostote moči šuma Φ_S običajno ne poznamo, zato jo moramo obravnavati kot inženirski faktor, kjer s poskušanjem faktor nastavljamo toliko časa, da filter dobro deluje.

$$\mathbf{Q}_c = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \Phi_S \quad (7.21)$$

Z integriranjem izraza $\mathbf{F} \mathbf{Q}_c \mathbf{F}^T$ na časovnem intervalu $[0, \Delta t]$ dobimo matriko procesnega šuma (7.22).

$$\mathbf{Q} = \begin{bmatrix} \frac{\Delta t^3}{3} & 0 & \frac{\Delta t^2}{2} & 0 \\ 0 & \frac{\Delta t^3}{3} & 0 & \frac{\Delta t^2}{2} \\ \frac{\Delta t^2}{2} & 0 & \Delta t & 0 \\ 0 & \frac{\Delta t^2}{2} & 0 & \Delta t \end{bmatrix} \Phi_s \quad (7.22)$$

Merilna enačba ostaja enaka kot pri metodi najmanjših kvadratov in je bila že predhodno predstavljena z enačbo (7.1). Merilna enačba predstavlja evklidsko razdaljo med senzorskim vozliščem z neznanim položajem in sidrnim vozliščem z znano lokacijo. Merilni model je zaradi nelinearne merilne enačbe posledično nelinearen in ga moramo za uporabo v postopku EKF za določanje položaja linearizirati s parcialnimi odvodi merilne enačbe po

posameznih komponentah vektorja stanj $(x, y, \dot{x}, \dot{y})$. V našem primeru uporabimo osem sočasnih meritev razdalje do osmih sidrnih vozlišč. To pomeni, da merilna funkcija (merilna matrika) $\mathbf{H}$ vsebuje osem merilnih vektorjev. Vsaka vrstica merilne funkcije predstavlja parcialne odvode merilne enačbe (2.5) po posameznih komponentah vektorja stanja sistema za vsako izmerjeno razdaljo posebej. Merilna funkcija je predstavljena z enačbo (7.23).

$$\mathbf{H} = \begin{bmatrix} \frac{(x-x_1)}{\sqrt{(x-x_1)^2+(y-y_1)^2}} & \frac{(y-y_1)}{\sqrt{(x-x_1)^2+(y-y_1)^2}} & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ \frac{(x-x_{N-1})}{\sqrt{(x-x_{N-1})^2+(y-y_{N-1})^2}} & \frac{(y-y_{N-1})}{\sqrt{(x-x_{N-1})^2+(y-y_{N-1})^2}} & 0 & 0 \end{bmatrix} \quad (7.23)$$

Posodobitev stanja se izvaja v merilnem prostoru za razliko od koraka ocene stanja, ki se izvaja v prostoru stanj. Za izračun posodobitve stanja novemu ocenjenemu stanju $\hat{\mathbf{x}}_k^-$ prištejemo produkt Kalmanovega ojačenja in merilnih residuov $\mathbf{y}$ (7.24). Merilne residue izračunamo kot razliko med izmerjenimi razdaljami in produktom merilne funkcije in stanjem sistema.

$$\mathbf{y}_k = \mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_k^- \quad (7.24)$$

7.3 Primerjava pristopov za izboljšanje lokalizacije

Analizo učinkovitosti predlaganih algoritmov za detekcijo pogojev brez neposredne vidljivosti in za oceno napake izmerjene razdalje s konvolucijskimi nevronskimi mrežami smo izvedli na testni skupini podatkov, ki niso bili prisotni v učnem procesu, da bi zmanjšali vpliv znanih vzorcev na rezultate analize.

Primerjali smo tudi učinkovitost različnih lokalizacijskih pristopov na osnovi metode najmanjših kvadratov, metode uteženih najmanjših kvadratov in Kalmanovega filtra, s pristopi za zmanjševanje vpliva napak izmerjene razdalje in brez zmanjševanja vpliva napak na lokalizacijske algoritme. V vseh primerih zmanjševanja vplivov napak izmerjene razdalje na natančnost lokalizacije smo uporabili predlagane razvrševalne in ocenjevalne algoritme s konvolucijskimi nevronskimi mrežami.

7.3.1 Ocena položaja z metodo najmanjših kvadratov brez zmanjševanja vpliva na točnost lokalizacije

Rezultati osnovnega lokalizacijskega pristopa z metodo najmanjših kvadratov so prikazani v tabeli 7.2. Na sliki 7.2 je prikazan potek ocenjenega položaja v primerjavi s časovnim zaporedjem pravih položajev na predvideni trajektoriji. Opazimo lahko visoka odstopanja ocenjenega položaja od pravega položaja, še posebej pa je odstopanje izrazito v delu poti, kjer je direktna pot med enim sidrnim vozliščem in mobilnim senzorskim vozliščem povsem prekinjena z večjo jekleno oviro.

Metoda je kljub velikemu številu sidrnih vozlišč zelo občutljiva na napake izmerjene razdalje med mobilnim vozliščem in sidrnimi vozlišči. Najboljše rezultate dobimo v bivalnem okolju 2, kjer znaša povprečna absolutna napaka (MAE) na celotni poti 0,25 m, najslabše pa se metoda obnese v industrijskem okolju, kjer povprečna absolutna napaka doseže 1,01 m. Večje prednosti uporabe najširšega komunikacijskega kanala (CH4) sedaj ne opazimo, lahko pa potrdimo, da se metoda z uporabo najširšega kanala v bivalnem okolju 2 in industrijskem okolju odreže za spoznanje boljše kot na ostalih z zelo majhno razliko, v pisarniškem okolju pa je najboljši drugi najširši kanal na najvišji centralni frekvenci (CH7).

Tabela 7.2: Točnost lokalizacije z metodo LS brez zmanjševanja vplivov meritev NLoS. Najboljše rezultate dobimo v primeru bivalnega okolja 2, kjer se povprečna absolutna napaka giblje med 0,19 m in 0,31 m. Najslabše rezultate dobimo v industrijskem okolju, kjer se MAE nahaja v območju od 0,73 m do 1,23 m. V bivalnem okolju 2 in industrijskem okolju najširši kanal CH4 kaže malenkost boljše rezultate v primerjavi z ostalimi rezultati.

		Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.53	0.27	0.63	1.16
	MSE	0.39	1.87	0.54	0.10
	MedAE	0.47	0.25	0.54	0.95
CH2	MAE	0.50	0.25	0.70	0.85
	MSE	0.32	0.11	0.66	1.02
	MedAE	0.47	0.19	0.67	0.80
CH3	MAE	0.61	0.29	0.73	1.09
	MSE	0.47	0.14	0.69	1.84
	MedAE	0.60	0.22	0.63	0.91
CH4	MAE	0.54	0.19	0.66	0.77
	MSE	0.39	0.06	0.58	0.82
	MedAE	0.47	0.14	0.59	0.73
CH5	MAE	0.58	0.31	0.69	1.23
	MSE	0.43	0.15	0.58	2.10
	MedAE	0.55	0.24	0.64	1.20
CH7	MAE	0.57	0.23	0.58	0.84
	MSE	0.40	0.08	0.40	1.01
	MedAE	0.53	0.18	0.55	0.73
vsi kanali	MAE	0.55	0.25	0.66	1.01
	MSE	0.39	0.11	0.57	1.49
	MedAE	0.51	0.19	0.60	0.87

7.3.2 Ocena položaja z metodo najmanjših kvadratov in detekcijo NLoS


Detekcijo pogojev NLoS lahko uporabimo za odstranjevanje meritev razdalje NLoS in s tem približevanje točnosti lokalizacije z eksaktnimi meritvami LoS. Dosežene točnosti lokalizacije so pričakovano nižje od tistih z eksaktno informacijo o stanju kanala, tak pristop pa je tudi uporaben samo v primeru, ko imamo na razpolago veliko število sidrnih vozlišč, predvsem pa morajo vsaj tri sidrna vozlišča ustrezati pogojem LoS. Rezultati so predstavljeni v tabeli 7.3.

Ker je v vseh štirih reprezentativnih notranjih okoljih veliko pozicij na izmerjeni trajektoriji, kjer niso na razpolago vsaj tri razdalje do sidrnih vozlišč v pogojih LoS, na sliki 7.3 vidimo veliko manjkajočih ocenjenih pozicij. Za zmanjševanje napak položaja tak pristop v okoljih z majhnim številom povezav LoS do sidrnih vozlišč ni primeren. Čeprav smo s tem pristopom odstranili večino meritev razdalje v pogojih NLoS, so rezultati v tabeli 7.3 slabi. Z odstranjevanjem meritev NLoS namreč v veliko primerih povzročimo, da so ustrezna vozlišča LoS neugodno razporejena in je zato ocena položaja slabša. Kljub slabim rezultatom je v nekaterih situacijah vseeno bolje, da dobimo slabo oceno položaja, kot pa da je sploh ne dobimo.


7.3.3 Ocena položaja z metodo najmanjših kvadratov in odštevanjem ocenjene napake

V primeru lokalizacije po metodi najmanjših kvadratov in direktnega odštevanja ocenjene napake izmerjene razdalje uporabimo predhodno zgrajeni model za ocenjevanje napake izmerjene razdalje s konvolucijsko nevronske mrežo. Od vsake izmerjene razdalje pred ocenjevanjem položaja odštejemo ocenjeno napako. Rezultati so prikazani v tabeli 7.4 in na sliki 7.4. Na sliki 7.4 opazimo, da so sedaj odstopanja ocenjenega položaja od pravega položaja na trajektoriji manjša kot pa v primeru z metodo LS brez zmanjševanja napake. Še vedno se metoda najbolje obnese v bivalnem okolju 2 in najslabše v industrijskem okolju.

Bolj jasno kot v prejšnjih primerih se sedaj opazi boljša učinkovitost izbrane lokalizacijske metode z uporabo najširših radijskih kanalov. V pisarniškem okolju se lokalizacijska metoda z odštevanjem ocenjene napake najbolje izkaže na kanalu CH7, v ostalih notranjih okoljih pa na najširšem radijskem kanalu (CH4). Širina radijskega kanala namreč vpliva



Slika 7.2: Uspešnost lokalizacijskega algoritma LS na celotni poti.



Slika 7.3: Uspešnost lokalizacijskega algoritma LS z detekcijo pogojev NLoS.

Tabela 7.3: Točnost lokalizacije z LS metodo in detekcijo pogojev NLoS. Zaradi majhnega števila položajev vozlišča, v katerem nam ostanejo na razpolago vsaj tri LoS sidrna vozlišča, so številčni rezultati zelo slabi. Najslabše se tu odreže pisarniško okolje z vrednostmi MAE v območju od 0,47 m do 2,71 m, najboljše razmere pa so v bivalnem okolju 2 z vrednostmi MAE med 0,15 m in 0,29 m. V večini primerov se sedaj najbolje izkaže kanal CH7.

		Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.42	0.27	0.74	0.81
	MSE	1.63	0.15	0.95	1.38
	MedAE	0.20	0.17	0.61	0.53
CH2	MAE	1.07	0.21	1.29	0.83
	MSE	56.53	0.10	5.47	1.62
	MedAE	0.26	0.14	0.64	0.50
CH3	MAE	2.76	0.26	1.53	1.69
	MSE	302.66	0.13	49.67	11.63
	MedAE	0.35	0.18	0.58	0.76
CH4	MAE	1.18	0.15	1.61	0.81
	MSE	56.98	0.05	18.24	1.21
	MedAE	0.23	0.09	0.94	0.57
CH5	MAE	0.47	0.29	2.71	1.45
	MSE	1.48	0.15	183.13	9.37
	MedAE	0.19	0.19	0.31	0.48
CH7	MAE	0.48	0.20	0.47	0.56
	MSE	8.15	0.08	0.32	1.38
	MedAE	0.13	0.14	0.39	0.14
vsi kanali	MAE	1.33	0.21	2.34	0.68
	MSE	113.01	0.10	140.47	1.33
	MedAE	0.21	0.13	0.45	0.27

na časovno ločljivost radijskega vmesnika, višja časovna ločljivost pa omogoča boljše razločevanje komponent poti in s tem večjo količino informacije v impulznem odzivu kanala o razširjanju sprejetega signala v izbranem radijskem okolju. Poleg večje količine informacije pa je radijski vmesnik sposoben bolj natančno določiti časovni žig prve fronte, ki je pomemben za natančno merjenje časa potovanja in merjenja razdalje.

7.3.4 Ocena položaja z metodo uteženih najmanjših kvadratov


Ocenjeno napako izmerjene razdalje, ki jo dobimo s pomočjo predhodno zgrajenega modela za ocenjevanje napake s konvolucijsko nevronske mreže, skupaj z izmerjeno razdaljo uporabimo za uteževanje posameznih izmerjenih razdalj. Kot je prikazano v tabeli 7.5 in na sliki 7.5, pričakovano dosežemo večje točnosti lokalizacijskega algoritma kot v primeru algoritma za ocenjevanje položaja po metodi najmanjših kvadratov brez pristopov za zmanjševanje vpliva napak izmerjenih razdalj na točnost lokalizacije. Prednost metode uteženih najmanjših kvadratov se pokaže z višanjem števila razpoložljivih sidrnih vozlišč.

Na sliki 7.5 lahko vidimo, da sedaj ocenjena trajektorija mobilnega vozlišča veliko bolje sledi pravi trajektoriji. Izračunane uteži na podlagi izmerjenih razdalj in ocen njihovih napak namreč zmanjšajo prispevke slabih povezav NLoS in močnejše utežijo prispevke povezav, ki kažejo značilnosti pogojev LoS. Očitne odvisnosti rezultatov lokalizacije v tabeli 7.5 od širine radijskega kanala sedaj ne opazimo.


Najboljše rezultate pri sledenju mobilnemu vozlišču dobimo v bivalnem okolju 2, kjer povprečna absolutna napaka doseže 0,18 m, najslabše rezultate pa dobimo v industrijskem okolju, kjer povprečna absolutna napaka doseže 0,64 m.

7.3.5 Ocena položaja z metodo uteženih najmanjših kvadratov in odštevanjem ocenjene napake

Kombinacija ocenjevanja položaja z metodo uteženih najmanjših kvadratov in odštevanja ocenjene napake izmerjene razdalje prikazuje najboljše rezultate med preizkušenimi metodami najmanjših kvadratov z vidika točnosti ocenjevanja neznanega položaja vozlišča na podlagi izmerjenih razdalj do razpoložljivih sidrnih vozlišč, in to kljub uporabi vseh raz-



Slika 7.4: Uspešnost lokalizacijskega algoritma LS z odštevanjem ocenjene napake na celotni poti.



Slika 7.5: Uspešnost lokalizacijskega algoritma WLS na celotni poti.

Tabela 7.4: Točnost lokalizacije z LS metodo in odštevanjem ocenjene napake izmerjene razdalje. V tabeli se jasno kaže prednost izbire najširših radijskih kanalov pri točnosti lokalizacije. Najboljše točnosti lokalizacije dobimo v bivalnem okolju 2, kjer se povprečna absolutna napaka giblje med 0,13 m na kanalu CH4 in 0,26 m na kanalu CH3. Najslabše se lokalizacija odreže v industrijskem okolju z vrednostmi MAE od 0,77 m na kanalu CH7 in 0,78 m na kanalu CH4 do 0,97 m na kanalu CH1.

		Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.41	0.19	0.43	0.97
	MSE	0.25	0.05	0.28	1.40
	MedAE	0.34	0.17	0.36	0.79
CH2	MAE	0.43	0.18	0.47	0.83
	MSE	0.27	0.04	0.30	0.96
	MedAE	0.37	0.15	0.40	0.77
CH3	MAE	0.42	0.26	0.52	0.96
	MSE	0.25	0.09	0.34	1.48
	MedAE	0.37	0.23	0.48	0.76
CH4	MAE	0.35	0.13	0.40	0.78
	MSE	0.18	0.02	0.23	0.88
	MedAE	0.29	0.11	0.35	0.69
CH5	MAE	0.37	0.22	0.42	0.92
	MSE	0.20	1.22	0.23	0.08
	MedAE	0.31	0.17	0.36	0.79
CH7	MAE	0.33	0.14	0.38	0.77
	MSE	0.16	0.04	0.19	0.84
	MedAE	0.27	0.10	0.32	0.64
vsi kanali	MAE	0.40	0.18	0.42	0.80
	MSE	0.25	0.05	0.25	0.98
	MedAE	0.33	0.15	0.38	0.66

položljivih meritev ne glede na stanje kanala (LoS/NLoS). Rezultati so prikazani v tabeli 7.6 in na sliki 7.6.

Na sliki 7.6 opazimo, da ocenjeni položaj še vedno opazno niha med obema stranema trajektorije pravih položajev, se pa v povprečju nahaja bližje pravim položajem kot s predhodnimi metodami. Najboljše rezultate doseže metoda v bivalnem okolju 2, kjer povprečna absolutna napaka znaša 0,13 m, najslabše rezultate pa dobimo v industrijskem okolju, kjer povprečna absolutna napaka znaša 0,47 m. Opazimo lahko tudi malo boljše rezultate z uporabo kanalov z višjimi centralnimi frekvencami (CH5 in CH7) ter najširšega kanala (CH4).

7.3.6 Ocena položaja z metodo razširjenega Kalmanovega filtra


Rezultati lokalizacije z razširjenim Kalmanovim filtrom (EKF) so prikazani v tabeli 7.7 in na sliki 7.7. Vizualna predstavitev uspešnosti lokalizacije z metodo EKF je prikazana na sliki 7.7.

Kalmanov filter za razliko od metod najmanjših kvadratov upošteva kinematični model sistema, ki mu sledimo. Sistem je v našem primeru človek, ki s konstantno hitrostjo sledi začrtani trajektoriji. Na sliki 7.7 se vidi, da sedaj trajektorija, ki jo opišejo ocenjeni položaji, ne niha več okrog trajektorije s pravimi položaji, ampak bolj gladko sledi začrtani trajektoriji. Spremembe smeri so bolj gladke in manj sunkovite.


Najboljše rezultate lokalizacije dobimo v bivalnem okolju 2, kjer povprečna absolutna napaka znaša 0,58 m, najslabše pa v industrijskem okolju, kjer povprečna absolutna napaka znaša 0,74 m. Razlike med posameznimi kanali sedaj niso tako očitne, da bi lahko opazili vzorec, ki bi dajal prednost določenim kanalom.

7.3.7 Ocena položaja z uteženo metodo razširjenega Kalmanovega filtra

Rezultati lokalizacije z uteženo metodo razširjenega Kalmanovega filtra so prikazani v tabeli 7.8. Vizualna predstavitev poteka enega virtualnega sprehoda po predvideni poti in rezultat lokalizacije na podlagi meritev sta prikazana na sliki 7.8.



Slika 7.6: Uspešnost lokalizacijskega algoritma WLS z odštevanjem ocenjene napake na celotni poti.



Slika 7.7: Uspešnost lokalizacijskega algoritma EKF na celotni poti.

Tabela 7.5: Točnost lokalizacije z metodo WLS. Tudi tu opazimo trend, da radijski kanali z večjo pasovno širino dajejo boljše rezultate pri lokalizaciji. Najboljše rezultate dobimo v bivalnem okolju 2 z vrednostmi MAE med 0,14 m na kanalu CH4 in 0,47 m na kanalu CH5, najslabše pa se odreže industrijsko okolje z vrednostmi MAE med 0,66 m na kanalu CH7 in 0,98 m na kanalu CH3.

		Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.40	0.22	0.46	0.73
	MSE	0.20	0.09	0.29	0.90
	MedAE	0.40	0.15	0.38	0.58
CH2	MAE	0.40	0.19	0.46	0.89
	MSE	0.21	0.07	0.29	1.30
	MedAE	0.38	0.14	0.43	0.73
CH3	MAE	0.45	0.23	0.53	0.98
	MSE	0.26	0.09	0.35	1.72
	MedAE	0.46	0.17	0.49	0.77
CH4	MAE	0.38	0.14	0.39	0.71
	MSE	0.19	0.04	0.21	0.91
	MedAE	0.36	0.11	0.34	0.53
CH5	MAE	0.34	0.47	0.25	0.75
	MSE	0.18	0.10	0.31	1.15
	MedAE	0.31	0.17	0.40	0.52
CH7	MAE	0.27	0.17	0.39	0.66
	MSE	0.11	0.05	0.20	0.89
	MedAE	0.24	0.12	0.34	0.45
vsi kanali	MAE	0.35	0.18	0.43	0.64
	MSE	0.17	0.06	0.25	0.67
	MedAE	0.31	0.13	0.38	0.51

Na sliki 7.8 opazimo, da utežena metoda EKF bolje sledi trajektoriji s pravimi položaji, so pa zaradi nezveznega spreminjanja uteži posameznim merilnim prispevkom spremembe bolj hitre in izrazite.


Najboljše rezultate sledenja trajektoriji dobimo v bivalnem okolju 2, kjer povprečna absolutna napaka znaša 0,19 m, najslabše pa v industrijskem okolju s povprečno absolutno napako 0,48 m. Boljše rezultate lahko s to metodo pričakujemo z uporabo najširših radijskih kanalov (CH4 in CH7).

7.3.8 Ocena položaja z uteženo metodo razširjenega Kalmanovega filtra in odštevanjem ocenjene napake izmerjene razdalje


Ocenjene uspešnosti lokalizacije z uteženim razširjenim Kalmanovim filtrom in zmanjševanjem izmerjene razdalje za ocenjeno napako izmerjene razdalje prikazuje tabela 7.9, na sliki 7.9 pa je prikazan potek ocenjenega položaja na predvideni trajektoriji v primerjavi s pravimi položaji na trajektoriji.

Na sliki 7.9 vidimo, da metoda EKF z uporabo ocenjene napake izmerjene razdalje za uteževanje in direktnega zmanjševanja napake izmerjene razdalje najlepše sledi trajektoriji s pravimi položaji. Spremembe med posameznimi zaporednimi točkami na trajektoriji z ocenjenimi položaji zaradi nezveznega spreminjanja uteži merilnih prispevkov in odštevanja ocenjenih merilnih napak na določenih mestih skokoviti, še vedno pa so ta odstopanja manjša kot pri predhodnih metodah.

Metoda zaradi upoštevanja kinematičnega modela sistema in ocene kakovosti posameznih merilnih prispevkov doseže najboljše rezultate med preizkušenimi metodami. V tabeli 7.9 vidimo, da v bivalnem okolju 2 dosežemo najboljše rezultate, kjer povprečna absolutna napaka znaša 0,1 m, najslabše pa v industrijskem okolju, kjer povprečna absolutna napaka znaša 0,3 m. Opazimo lahko tudi, da najboljše rezultate v večini notranjih okolij dobimo z uporabo kanala 7 (CH7), ki združuje visoko pasovno širino (1081,6 MHz) in najvišjo osnovno frekvenco, ki jo podpira radio DW1000 (6489,6 MHz).



Slika 7.8: Uspešnost lokalizacijskega algoritma EKF z uteževanjem prispevkov na celotni poti.



Slika 7.9: Uspešnost lokalizacijskega algoritma EKF z uteževanjem prispevkov in odštevanjem ocenjene napake na celotni poti.

Tabela 7.6: Točnost lokalizacije z metodo WLS in odštevanjem ocenjene napake izmerjene razdalje. Širina komunikacijskega kanala je tu ponovno glavni faktor, ki daje najboljše rezultate. Najboljše rezultate točnosti lokalizacije dobimo v bivalnem okolju 2 z vrednostmi srednje absolutne napake v območju od 0,10 m na kanalu CH7 do 0,19 m na kanalu CH3, najslabše pa se lokalizacija obnese v industrijskem okolju z vrednostmi MAE med 0,63 m na kanalu CH4 in 0,84 m na kanalu CH2.

		Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.29	0.15	0.32	0.66
	MSE	0.11	0.03	0.15	319.05
	MedAE	0.27	0.13	0.27	0.46
CH2	MAE	0.30	0.14	0.31	0.84
	MSE	0.13	0.03	0.14	1.27
	MedAE	0.26	0.13	0.27	0.64
CH3	MAE	0.31	0.19	0.32	0.72
	MSE	0.13	0.05	0.15	1.11
	MedAE	0.27	0.17	0.28	0.55
CH4	MAE	0.22	0.11	0.28	0.63
	MSE	0.08	0.02	8.30	0.86
	MedAE	0.19	0.09	0.22	0.42
CH5	MAE	0.20	0.17	0.25	0.52
	MSE	0.06	0.05	0.10	0.62
	MedAE	0.16	0.14	0.21	0.33
CH7	MAE	0.15	0.10	0.23	0.52
	MSE	0.04	0.02	0.08	0.61
	MedAE	0.12	0.08	0.19	0.29
vsi kanali	MAE	0.22	0.13	0.27	0.47
	MSE	0.29	0.39	0.10	0.02
	MedAE	0.18	0.12	0.24	0.36

Tabela 7.7: Točnost lokalizacije z metodo EKF. Najslabše se lokalizacijski algoritem obnese v industrijskem okolju z vrednostmi MAE med 0,55 m na kanalu CH4 in 0,93 m na kanalu CH5, najboljše pa v bivalnem okolju 2 z vrednostmi MAE med 0,38 m na kanalu CH4 in 0,46 m na kanalu CH3. Opazimo, da izbira kanala z večjo pasovno širino pozitivno vpliva na točnost sledenja položaju.

		Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.53	0.43	0.57	0.85
	MSE	0.38	0.27	0.43	0.85
	MedAE	0.52	0.35	0.52	0.85
CH2	MAE	0.54	0.41	0.57	0.68
	MSE	0.37	0.25	0.45	0.57
	MedAE	0.48	0.35	0.61	0.70
CH3	MAE	0.66	0.46	0.65	0.78
	MSE	0.53	0.32	0.52	0.75
	MedAE	0.59	0.37	0.58	0.81
CH4	MAE	0.57	0.38	0.55	0.55
	MSE	0.39	0.22	0.40	0.36
	MedAE	0.54	0.33	0.52	0.57
CH5	MAE	0.65	0.45	0.61	0.93
	MSE	0.52	0.29	0.46	1.09
	MedAE	0.60	0.36	0.60	0.99
CH7	MAE	0.57	0.40	0.50	0.68
	MSE	0.39	0.23	0.32	0.59
	MedAE	0.56	0.34	0.47	0.66
vsi kanali	MAE	0.58	0.42	0.57	0.74
	MSE	0.41	0.26	0.42	0.67
	MedAE	0.55	0.35	0.55	0.76

Tabela 7.8: Točnost lokalizacije z uteženo metodo EKF. Rezultati kažejo najslabše razmere v industrijskem okolju z vrednostmi MAE med 0,45 m na kanalih CH7 in CH5 ter 0,81 m na kanalu CH2. Najboljše točnosti sledenja položaju ponovno opazimo v bivalnem okolju 2 z vrednostmi MAE med 0,16 m na kanali CH4 in CH7 ter 0,26 m na kanalu CH3.

		Bivalno okolje 1	Bivalno okoje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.38	0.22	0.40	0.54
	MSE	0.21	0.07	0.24	0.43
	MedAE	0.29	0.18	0.31	0.49
CH2	MAE	0.36	0.21	0.40	0.81
	MSE	0.18	0.07	0.24	1.04
	MedAE	0.31	0.18	0.32	0.67
CH3	MAE	0.50	0.26	0.50	0.69
	MSE	0.36	0.11	0.36	0.66
	MedAE	0.42	0.21	0.44	0.62
CH4	MAE	0.37	0.16	0.36	0.62
	MSE	0.20	0.04	0.21	0.73
	MedAE	0.31	0.13	0.24	0.47
CH5	MAE	0.31	0.25	0.41	0.45
	MSE	0.17	0.09	0.25	0.32
	MedAE	0.23	0.21	0.34	0.39
CH7	MAE	0.22	0.16	0.35	0.45
	MSE	0.08	0.04	0.21	0.35
	MedAE	0.16	0.14	0.25	0.40
vsi kanali	MAE	0.32	0.19	0.38	0.48
	MSE	0.16	0.05	0.23	0.33
	MedAE	0.25	0.16	0.29	0.43

Tabela 7.9: Točnost lokalizacije z uteženo metodo EKF s predhodnim odstranjevanjem ocenjenih napak izmerjene razdalje. Največje napake sledenja položaju opazimo v industrijskem okolju z vrednostmi MAE v območju med 0,26 m na kanalu CH5 in 0,66 m na kanalu CH2. Ponovno dobimo najboljše rezultate pri sledenju lokaciji v bivalnem okolju 2 z vrednostmi MAE med 0,08 m na kanalu CH7 in 0,17 m na kanalu CH3.

		Bivalno okolje 1	Bivalno okolje 2	Pisarniško okolje	Industrijsko okolje
CH1	MAE	0.26	0.12	0.30	0.38
	MSE	0.10	0.03	0.12	0.22
	MedAE	0.22	0.08	0.25	0.32
CH2	MAE	0.22	0.12	0.30	0.66
	MSE	0.07	0.02	0.14	0.78
	MedAE	0.17	0.11	0.25	0.50
CH3	MAE	0.29	0.17	0.37	0.41
	MSE	0.12	0.04	0.22	0.24
	MedAE	0.25	0.14	0.27	0.35
CH4	MAE	0.17	0.10	0.28	0.48
	MSE	0.05	0.02	0.14	0.49
	MedAE	0.13	0.07	0.20	0.31
CH5	MAE	0.17	0.13	0.28	0.26
	MSE	0.05	0.03	0.14	0.10
	MedAE	0.14	0.09	0.20	0.21
CH7	MAE	0.13	0.08	0.26	0.30
	MSE	0.02	0.01	0.13	0.17
	MedAE	0.10	0.06	0.16	0.21
vsi kanali	MAE	0.18	0.10	0.28	0.30
	MSE	0.05	0.02	0.14	0.13
	MedAE	0.14	0.08	0.22	0.26

Poglavje 8

Zaključki

V doktorski disertaciji smo se posvetili lokalizaciji v notranjih okoljih z radijsko tehnologijo UWB in analizi vplivov pogojev razširjanja na točnost lokalizacije. Pregledali smo obstoječe pristope k radijski lokalizaciji v notranjih okoljih in ugotovili, da je področje dobro razvito z ogromnim številom različnih metod. Smiselno jih lahko organiziramo v skupine glede na način, kako so pridobljene osnovne informacije in katere medsebojne povezave med senzorskimi vozlišči upoštevamo.

Zgradili smo podatkovno zbirko z meritvami v štirih različnih značilnih notranjih okoljih. Te meritve zainteresiranim raziskovalcem in inženirjem omogočajo podrobno analizo razmer v različnih notranjih okoljih z uporabo cenovno dostopnih radijskih modulov UWB. Vzorci v podatkovni zbirki poleg standardnih parametrov, ki opisujejo stanje komunikacijskega kanala, vsebujejo tudi oceno impulznega odziva kanala za vsak posamezen izmerek v podatkovni zbirki. Podatki v podatkovni zbirki so organizirani tako, da opisujejo smiselno trajektorijo, ki bi jo lahko v izbranem notranjem okolju obhodila oseba s konstantno hitrostjo premikanja. To omogoča podrobnejšo analizo lokalizacijskih algoritmov, ker vključuje vse realne pogoje razširjanja signala, ki jih simulacijsko okolje z omejenimi računskimi viri ne more poustvariti v celoti. Na ta način je omogočena podrobna analiza zmogljivosti algoritmov za lokalizacijo, ki dobro opiše njihovo obnašanje v realnem okolju. Na podlagi pridobljene podatkovne zbirke smo parametrično modelirali profile močnostnih zakasnitev sprejetega signala (PDP) in s tem poizkušali poustvariti vse relevantne modele kanalov, ki jih zasledimo v literaturi. Pri tem smo namesto izredno drage laboratorijske opreme uporabili večje število poceni senzorskih vozlišč, kar je omogočilo obširnejše zajemanje pogojev v izbranih notranjih okoljih.

Na podlagi pridobljene obširne podatkovne zbirke smo s pomočjo pristopov globokega učenja izdelali razvrševalne in regresijske modele za ocenjevanje pogojev razširjanja radijskega signala na posameznih komunikacijskih kanalih. Z razvrščanjem smo se lotili detekcije pogojev razširjanja radijskega signala brez neposredne vidljivosti (NLoS) med oddajnikom in sprejemnikom. Z odsotnostjo neposredne vidljivosti se napake izmerjene razdalje, ki jih uporabimo v postopku lokalizacije, močno povečajo. Z zavračanjem NLoS izmerkov razdalje pod pogojem, da so sidrna vozlišča gosto posejana v prostoru, dosežemo izboljšanje točnosti izbranih lokalizacijskih algoritmov. S primerjavo globokih razvrševalnih algoritmov s klasičnimi algoritmi strojnega učenja smo dokazali, da globoka nevronska omrežja dosegajo boljše uspešnosti pri razvrščanju vzorcev od klasičnih algoritmov z luščenjem značilk. Dokazali smo tudi, da globoki algoritmi kljub svoji kompleksnosti omogočajo zadovoljive hitrosti razvrščanja vzorcev tudi na računsko omejenih računalniških platformah.

Na podlagi meritev razdalj s časom razširjanja radijskega signala (ToF) in pravih položajev mobilnega ter sidrnih vozlišč smo zgradili globoke regresijske modele za ocenjeva-

nje napake izmerjene razdalje na podlagi profila močnostne zakasnitve sprejetega signala (PDP). Ocene napak so v zadnjem poglavju služile za izboljšanje uspešnosti posameznih lokalizacijskih algoritmov, ki smo jih uporabili za sledenje trajektoriji mobilnega senzorskega vozlišča. S pridobljenimi ocenami napak izmerjenih razdalj smo pripravili uteži za uteževanje posameznih meritev v lokalizacijskem procesu ali pa za surovo zmanjševanje izmerjenih razdalj z ocenjenimi napakami. Na ta način smo dosegli veliko boljše prilaganje ocenjene trajektorije pravi trajektoriji oziroma izboljšali točnost lokalizacijskega procesa. Dokazali smo, da vsaka ocena razmer v realnem okolju pripomore k izboljšanju zanesljivosti in točnosti lokalizacijskih algoritmov.

Z uporabo predlaganih modelov za detekcijo razširjanja radijskega signala brez neposredne vidljivosti in modelov za oceno napake izmerjene razdalje v kombinaciji z razširjenim Kalmanovim filtrom občutno izboljšamo uspešnost postopka določanja položaja oseb in stvari v notranjih okoljih. Uporaba tako naprednih algoritmov za sledenje omogoča uporabo cenovno dostopnih radijskih modulov UWB v zahtevnih radijskih okoljih z manjšim številom potrebnih referenčnih vozlišč in večjo točnostjo lokalizacijskega postopka. Pristopi z naprednimi postopki lokalizacije so zato zanimivi predvsem za uporabo v mobilnih omrežjih pete generacije, v industrijskih procesih, za sledenje inventarju, podpori reševalnim ekipam pri posredovanju v požarih in naravnih nesrečah, avtonomnih vozilih v proizvodnih procesih ter drugih primerih uporabe.

Na podlagi analize uspešnosti algoritmov za določanje položaja in sledenje lahko povzamemo, da je pri načrtovanju in postavljanju sistemov za lokalizacijo UWB, kjer uporabimo tudi algoritme za razpoznavanje pogojev NLoS ter algoritme za oceno izmerjene napake, najbolj pomembna izbira čim širšega komunikacijskega kanala. Večja pasovna širina in z njo večji razpon radijskih frekvenc pozitivno vplivata na količino informacije, ki jo nosi profil močnostne zakasnitve signala o značilnosti razširjanja v notranjem okolju. Izkáže se tudi, da izločanje NLoS meritev z uporabo razvrščevalnega algoritma NLoS večinoma ni praktično uporabno. Izločanje vzorcev NLoS namreč manjša število razpoložljivih sidrnih vozlišč in s tem slabša pogoje za izračun položaja. Najbolj neugodne so razmere, ko so sidrna vozlišča kolinearna ali blizu kolinearnosti in so zato napake izračunanega položaja velike. V veliko primerih zaradi velikega števila odstranjenih sidrnih vozlišč položaja celo ni možno izračunati. V marsikateri situaciji je zato bolj pomembno, da oceno položaja imamo kljub slabšemu rezultatu, kot pa da ocene sploh nimamo.

Za nadaljnje delo je zanimiva predvsem primerjava predlaganega pristopa napredne uporabe modelov za oceno napake izmerjene razdalje v kombinaciji z razširjenim Kalmanovim filtrom z drugimi ocenjevalnimi algoritmi, kot sta na primer filter z delci (angl. particle filter) in Kalmanov filter s sigma točkami (angl. unscented Kalman filter). Oba filtra z uporabo vzorčenja izboljšata probleme razširjenega Kalmanovega filtra, ki zaradi razširjanja kovariančnih matrik skozi linearizirane matematične modele v primeru večjih nelinearnosti vnaša velike napake v končni rezultat. Smiselno bi bilo primerjati tako računsko učinkovitost omenjenih algoritmov kot tudi kakovost pridobljene ocene položaja.

Nadaljnje delo bo obsegalo analizo delovanja algoritmov za sledenje oseb na testnem senzorskem omrežju UWB v sklopu eksperimentalnega testnega senzorskega omrežja LOG-a-TEC na Institutu Jožef Stefan. Pomembni vidiki analize algoritmov so predvsem analiza vpliva časovne razpršenosti izmerkov razdalje do različnih sidrnih vozlišč na točnost lokalizacije, odpornost algoritmov na manjkajoče izmerke razdalj in analiza vplivov različnih geometrijskih razporeditev sidrnih vozlišč na točnost lokalizacije posameznih lokalizacijskih algoritmov. Pomemben del nadaljnjega dela bo tudi razvoj lokalizacijske sheme na osnovi razlike časa prispetja signala (TDoA) na sidrna vozlišča, ki zahteva natančno sinhronizacijo lokalnih ur na sidrnih vozliščih. Lokalizacijska shema TDoA omogoča sledenje veliko večjemu številu mobilnih vozlišč in v ocenjeni položaj ne vnaša napak zaradi časovne

razpršenosti izmerkov razdalj.

Literatura

- [1] R. Di Taranto, S. Muppirisetty, R. Raulefs, D. Slock, T. Svensson in H. Wymeersch, "Location-aware communications for 5G networks: How location information can improve scalability, latency, and robustness of 5G", *IEEE Signal Processing Magazine*, zv. 31, št. 6, str. 102–112, nov. 2014, ISSN: 1053-5888. DOI: 10.1109/MSP.2014.2332611.
- [2] G. Han, H. Xu, T. Q. Duong, J. Jiang in T. Hara, "Localization algorithms of wireless sensor networks: A survey", *Telecommunication Systems*, zv. 52, št. 4, str. 2419–2436, apr. 2013, ISSN: 1572-9451. DOI: 10.1007/s11235-011-9564-7. spletni naslov: <https://doi.org/10.1007/s11235-011-9564-7>.
- [3] A. Mesmoudi, M. Feham in N. Labraoui, "Wireless sensor networks localization algorithms: A comprehensive survey", *CoRR*, zv. abs/1312.4082, 2013. arXiv: 1312.4082. spletni naslov: <http://arxiv.org/abs/1312.4082>.
- [4] A. Hrovat, T. Javornik, M. Mohorčič in R. Novak, "Radijska lokalizacija v notranjih okoljih : Pregled pristopov", *Elektrotehniški vestnik*, zv. 84, št. 4, str. 155–166, 2017, ISSN: 0013-5852.
- [5] R. Zekavat in R. M. Buehrer, *Handbook of Position Location: Theory, Practice and Advances*, 1st. Wiley-IEEE Press, 2011, ISBN: 9780470943427.
- [6] H. Ahn in W. Yu, "Environmental-adaptive RSSI-Based indoor localization", *IEEE Transactions on Automation Science and Engineering*, zv. 6, št. 4, str. 626–633, okt. 2009, ISSN: 1545-5955. DOI: 10.1109/TASE.2008.2009126.
- [7] W. Xue, W. Qiu, X. Hua in K. Yu, "Improved Wi-Fi RSSI measurement for indoor localization", *IEEE Sensors Journal*, zv. 17, št. 7, str. 2224–2230, apr. 2017, ISSN: 1530-437X. DOI: 10.1109/JSEN.2017.2660522.
- [8] S. Cai, W. Liao, C. Luo, M. Li, X. Huang in P. Li, "CRIL: an efficient online adaptive indoor localization system", *IEEE Transactions on Vehicular Technology*, zv. 66, št. 5, str. 4148–4160, maj 2017, ISSN: 0018-9545. DOI: 10.1109/TVT.2016.2597303.
- [9] A. Maddumabandara, H. Leung in M. Liu, "Experimental evaluation of indoor localization using wireless sensor networks", *IEEE Sensors Journal*, zv. 15, št. 9, str. 5228–5237, sep. 2015, ISSN: 1530-437X. DOI: 10.1109/JSEN.2015.2438193.
- [10] "IEEE standard for local and metropolitan area networks–Part 15.4: Low-rate wireless personal area networks (LR-WPANs)", *IEEE Std 802.15.4-2011 (Revision of IEEE Std 802.15.4-2006)*, str. 1–314, sep. 2011. DOI: 10.1109/IEEESTD.2011.6012487.
- [11] M. Kwak in J. Chong, "A new double two-way ranging algorithm for ranging system", v *2010 2nd IEEE International Conference on Network Infrastructure and Digital Content*, sep. 2010, str. 470–473. DOI: 10.1109/ICNIDC.2010.5657814.

- [12] Y. Jiang in V. C. M. Leung, “An asymmetric double sided two-way ranging for crystal offset”, v *2007 International Symposium on Signals, Systems and Electronics*, jul. 2007, str. 525–528. DOI: 10.1109/ISSSE.2007.4294528.
- [13] N. Patwari, J. N. Ash, S. Kyperountas, A. O. Hero, R. L. Moses in N. S. Correal, “Locating the nodes: Cooperative localization in wireless sensor networks”, *IEEE Signal Processing Magazine*, zv. 22, št. 4, str. 54–69, jul. 2005, ISSN: 1053-5888. DOI: 10.1109/MSP.2005.1458287.
- [14] A. Khalajmehrabadi, N. Gatsis in D. Akopian, “Modern WLAN fingerprinting indoor positioning methods and deployment challenges”, *IEEE Communications Surveys Tutorials*, zv. 19, št. 3, str. 1974–2002, thirdquarter 2017, ISSN: 1553-877X. DOI: 10.1109/COMST.2017.2671454.
- [15] S. Wielandt, M. V. Shah, N. A. Athaullah, U. M. Sayyad, R. B. Yadav, R. M. Dharamdasani, L. De Strycker in M. Kuhn, “2.4 GHz single anchor node indoor localization system with angle of arrival fingerprinting”, v *2017 Wireless Days*, mar. 2017, str. 152–154. DOI: 10.1109/WD.2017.7918132.
- [16] N. A. Khanbashi, N. Alsindi, S. Al-Araji, N. Ali in J. Aweya, “Performance evaluation of CIR based location fingerprinting”, v *2012 IEEE 23rd International Symposium on Personal, Indoor and Mobile Radio Communications - (PIMRC)*, sep. 2012, str. 2466–2471. DOI: 10.1109/PIMRC.2012.6362771.
- [17] D. Slock, “Diversity aspects of power delay profile based location fingerprinting”, v *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, mar. 2012, str. 2861–2864. DOI: 10.1109/ICASSP.2012.6288514.
- [18] S. Yiu in K. Yang, “Gaussian process assisted fingerprinting localization”, *IEEE Internet of Things Journal*, zv. 3, št. 5, str. 683–690, okt. 2016, ISSN: 2327-4662. DOI: 10.1109/JIOT.2015.2481932.
- [19] Y. Luo, Y. P. Chen in O. Hoeber, “Wi-Fi-Based indoor positioning using human-centric collaborative feedback”, v *2011 IEEE International Conference on Communications (ICC)*, jun. 2011, str. 1–6. DOI: 10.1109/icc.2011.5963278.
- [20] S. He, B. Ji in S. -.-. G. Chan, “Chameleon: Survey-free updating of a fingerprint database for indoor localization”, *IEEE Pervasive Computing*, zv. 15, št. 4, str. 66–75, okt. 2016, ISSN: 1536-1268. DOI: 10.1109/MPRV.2016.69.
- [21] Y. Zhang, Q. Huang in J. Liu, “Sequential localization algorithm for active sensor network deployment”, v *20th International Conference on Advanced Information Networking and Applications - Volume 1 (AINA'06)*, zv. 2, apr. 2006, str. 171–178. DOI: 10.1109/AINA.2006.304.
- [22] N. Saeed in H. Nam, “Robust multidimensional scaling for cognitive radio network localization”, *IEEE Transactions on Vehicular Technology*, zv. 64, št. 9, str. 4056–4062, sep. 2015, ISSN: 0018-9545. DOI: 10.1109/TVT.2014.2366515.
- [23] H. Jamali-Rad in G. Leus, “Dynamic multidimensional scaling for low-complexity mobile network tracking”, *IEEE Transactions on Signal Processing*, zv. 60, št. 8, str. 4485–4491, avg. 2012, ISSN: 1053-587X. DOI: 10.1109/TSP.2012.2197751.
- [24] A. T. Ihler, J. W. Fisher, R. L. Moses in A. S. Willsky, “Nonparametric belief propagation for self-localization of sensor networks”, *IEEE Journal on Selected Areas in Communications*, zv. 23, št. 4, str. 809–819, apr. 2005, ISSN: 0733-8716. DOI: 10.1109/JSAC.2005.843548.

- [25] M. A. Caceres, F. Penna, H. Wymeersch in R. Garello, "Hybrid cooperative positioning based on distributed belief propagation", *IEEE Journal on Selected Areas in Communications*, zv. 29, št. 10, str. 1948–1958, dec. 2011, ISSN: 0733-8716. DOI: 10.1109/JSAC.2011.111205.
- [26] V. Savic in S. Zazo, "Nonparametric boxed belief propagation for localization in wireless sensor networks", v *2009 Third International Conference on Sensor Technologies and Applications*, jun. 2009, str. 520–525. DOI: 10.1109/SENSORCOMM.2009.87.
- [27] J. S. Yedidia, W. T. Freeman in Y. Weiss, "Exploring artificial intelligence in the new millennium", v, G. Lakemeyer in B. Nebel, ur., San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2003, pogl. Understanding Belief Propagation and Its Generalizations, str. 239–269, ISBN: 1-55860-811-7. spletni naslov: <http://dl.acm.org/citation.cfm?id=779343.779352>.
- [28] V. Savic in S. Zazo, "Sensor localization using nonparametric generalized belief propagation in network with loops", v *2009 12th International Conference on Information Fusion*, jul. 2009, str. 1966–1973.
- [29] —, "Nonparametric belief propagation based on spanning trees for cooperative localization in wireless sensor networks", v *2010 IEEE 72nd Vehicular Technology Conference - Fall*, sep. 2010, str. 1–5. DOI: 10.1109/VETECF.2010.5594105.
- [30] H. Durrant-Whyte in T. Bailey, "Simultaneous localization and mapping: Part I", *IEEE Robotics Automation Magazine*, zv. 13, št. 2, str. 99–110, jun. 2006, ISSN: 1070-9932. DOI: 10.1109/MRA.2006.1638022.
- [31] T. Dumont in S. L. Corff, "Simultaneous localization and mapping in wireless sensor networks", *Signal Processing*, zv. 101, str. 192–203, 2014, ISSN: 0165-1684. DOI: <https://doi.org/10.1016/j.sigpro.2014.02.011>. spletni naslov: <http://www.sciencedirect.com/science/article/pii/S0165168414000814>.
- [32] J. Huang, D. Millman, M. Quigley, D. Stavens, S. Thrun in A. Aggarwal, "Efficient, generalized indoor WiFi GraphSLAM", v *2011 IEEE International Conference on Robotics and Automation*, maj 2011, str. 1038–1043. DOI: 10.1109/ICRA.2011.5979643.
- [33] E. Menegatti, A. Zanella, S. Zilli, F. Zorzi in E. Pagello, "Range-only SLAM with a mobile robot and a wireless sensor networks", v *2009 IEEE International Conference on Robotics and Automation*, maj 2009, str. 8–14. DOI: 10.1109/ROBOT.2009.5152449.
- [34] P. Mirowski, T. K. Ho, S. Yi in M. MacDonald, "Signalslam: Simultaneous localization and mapping with mixed WiFi, Bluetooth, LTE and magnetic signals", v *International Conference on Indoor Positioning and Indoor Navigation*, okt. 2013, str. 1–10. DOI: 10.1109/IPIN.2013.6817853.
- [35] S.-H. Lee, I.-K. Lim in J.-K. Lee, "Method for improving indoor positioning accuracy using extended kalman filter", *Mobile Information Systems*, zv. 2016, št. 2369103, 2016. spletni naslov: <https://doi.org/10.1155/2016/2369103>.
- [36] Y. Sung, "RSSI-Based distance estimation framework using a kalman filter for sustainable indoor computing environments", *Sustainability*, zv. 8, št. 11, 2016, ISSN: 2071-1050. DOI: 10.3390/su8111136. spletni naslov: <http://www.mdpi.com/2071-1050/8/11/1136>.

- [37] Z.-A. Deng, Y. Hu, J. Yu in Z. Na, "Extended kalman filter for real time indoor localization by fusing WiFi and smartphone inertial sensors", *Micromachines*, zv. 6, št. 4, str. 523–543, 2015, ISSN: 2072-666X. DOI: 10.3390/mi6040523. spletni naslov: <http://www.mdpi.com/2072-666X/6/4/523>.
- [38] Y. Zhao, X. Li, Y. Wang in C. Xu, "Biased constrained hybrid kalman filter for range-based indoor localization", *IEEE Sensors Journal*, zv. 18, št. 4, str. 1647–1655, feb. 2018, ISSN: 1530-437X. DOI: 10.1109/JSEN.2017.2768556.
- [39] J. Wilson in N. Patwari, "Radio tomographic imaging with wireless networks", *IEEE Transactions on Mobile Computing*, zv. 9, št. 5, str. 621–632, maj 2010, ISSN: 1536-1233. DOI: 10.1109/TMC.2009.174.
- [40] V. Picco, T. Negishi, S. Nishikata in D. Erricolo, "RF tomography in free space: Experimental validation of the forward model and of a conjugate gradient inversion algorithm", v *2013 International Conference on Electromagnetics in Advanced Applications (ICEAA)*, sep. 2013, str. 1361–1364. DOI: 10.1109/ICEAA.2013.6632472.
- [41] L. L. Monte, M. C. Wicks in B. Yazıcı, "RF tomography for building penetration", v *2011 IEEE RadarCon (RADAR)*, maj 2011, str. 420–424. DOI: 10.1109/RADAR.2011.5960573.
- [42] Y. Guzel, T. Tran, M. C. Wicks in L. L. Monte, "RF tomography for ground penetrating radar: Simulation and experimentation", v *2015 IEEE Radar Conference (RadarCon)*, maj 2015, str. 1531–1535. DOI: 10.1109/RADAR.2015.7131239.
- [43] M. Wang, Z. Wang, X. Bu in E. Ding, "An adaptive weighting algorithm for accurate radio tomographic image in the environment with multipath and WiFi interference", *International Journal of Distributed Sensor Networks*, zv. 13, št. 1, str. 1550147716683826, 2017. DOI: 10.1177/1550147716683826. eprint: <https://doi.org/10.1177/1550147716683826>. spletni naslov: <https://doi.org/10.1177/1550147716683826>.
- [44] C. Alippi, M. Bocca, G. Boracchi, N. Patwari in M. Roveri, "RTI goes wild: Radio tomographic imaging for outdoor people detection and localization", *CoRR*, zv. abs/1407.8509, 2014. arXiv: 1407.8509. spletni naslov: <http://arxiv.org/abs/1407.8509>.
- [45] B. Beck, X. Ma in R. Baxley, "Ultrawideband tomographic imaging in uncalibrated networks", *IEEE Transactions on Wireless Communications*, zv. 15, št. 9, str. 6474–6486, sep. 2016, ISSN: 1536-1276. DOI: 10.1109/TWC.2016.2585141.
- [46] K. Mihelič, "Posplošeni inverzi realnih matrik", Doktorska disertacija, Univerza v Mariboru, Fakulteta za naravoslovje in matematiko, 2015. spletni naslov: <https://dk.um.si/IzpisGradiva.php?lang=slv&id=48241>.
- [47] O. Kaltiokallio, M. Bocca in N. Patwari, "A fade level-based spatial model for radio tomographic imaging", *IEEE Transactions on Mobile Computing*, zv. 13, št. 6, str. 1159–1172, jun. 2014, ISSN: 1536-1233. DOI: 10.1109/TMC.2013.158.
- [48] M. Bocca, O. Kaltiokallio, N. Patwari in S. Venkatasubramanian, "Multiple target tracking with rf sensor networks", *IEEE Transactions on Mobile Computing*, zv. 13, št. 8, str. 1787–1800, avg. 2014, ISSN: 1536-1233. DOI: 10.1109/TMC.2013.92.
- [49] L. Yang in G. B. Giannakis, "Ultra-wideband communications: An idea whose time has come", *IEEE Signal Processing Magazine*, zv. 21, št. 6, str. 26–54, nov. 2004, ISSN: 1053-5888. DOI: 10.1109/MSP.2004.1359140.

- [50] R. S. Kshetrimayum, "An introduction to UWB communication systems", *IEEE Potentials*, zv. 28, št. 2, str. 9–13, mar. 2009, ISSN: 0278-6648. DOI: 10.1109/MPOT.2009.931847.
- [51] S. Gezici, Z. Tian, G. B. Giannakis, H. Kobayashi, A. F. Molisch, H. V. Poor in Z. Sahinoglu, "Localization via ultra-wideband radios: A look at positioning aspects for future sensor networks", *IEEE Signal Processing Magazine*, zv. 22, št. 4, str. 70–84, jul. 2005, ISSN: 1053-5888. DOI: 10.1109/MSP.2005.1458289.
- [52] Decawave, *DW1000 user manual*, v2.05, 2015. spletni naslov: http://thetoolchain.com/mirror/dw1000/dw1000%5C_user%5C_manual%5C_v2.05.pdf.
- [53] M. Ghavami, L. Michael in R. Kohno, *Ultra Wideband Signals and Systems in Communication Engineering*. John Wiley & Sons, 2005.
- [54] A. F. Molisch, K. Balakrishnan, C.-c. Chong, S. Emami, A. Fort, J. Karedal, J. Kunisch, H. Schantz, U. Schuster in K. Siwiak, "IEEE 802.15.4a channel model - final report", v *Converging: Technology, work and learning*. Australian Government Printing Service, [Online]. Available, 2004.
- [55] A. F. Molisch, "Ultra-wide-band propagation channels", *Proceedings of the IEEE*, zv. 97, št. 2, str. 353–371, feb. 2009, ISSN: 0018-9219. DOI: 10.1109/JPROC.2008.2008836.
- [56] A. Durantini, W. Ciccognani in D. Cassioli, "UWB propagation measurements by PN-sequence channel sounding", v *2004 IEEE International Conference on Communications (IEEE Cat. No.04CH37577)*, zv. 6, jun. 2004, 3414–3418 Vol.6. DOI: 10.1109/ICC.2004.1313178.
- [57] D. Cassioli, M. Z. Win in A. F. Molisch, "The ultra-wide bandwidth indoor channel: From statistical model to simulations", *IEEE Journal on Selected Areas in Communications*, zv. 20, št. 6, str. 1247–1257, avg. 2002, ISSN: 0733-8716. DOI: 10.1109/JSAC.2002.801228.
- [58] J. Kunisch in J. Pamp, "Measurement results and modeling aspects for the UWB radio channel", v *2002 IEEE Conference on Ultra Wideband Systems and Technologies (IEEE Cat. No.02EX580)*, maj 2002, str. 19–23. DOI: 10.1109/UWBS.2002.1006310.
- [59] J. Foerster in Q. Li, "UWB channel modeling contribution from intel", jan. 2002.
- [60] J. Khodjaev, Y. Park in A. Saeed Malik, "Survey of NLOS identification and error mitigation problems in UWB-based positioning algorithms for dense environments", *Annals of telecommunications - annales des télécommunications*, zv. 65, št. 5, str. 301–311, jun. 2010, ISSN: 1958-9395. DOI: 10.1007/s12243-009-0124-z. spletni naslov: <https://doi.org/10.1007/s12243-009-0124-z>.
- [61] L. Z. Shiwei Tian in G. Li, "A support vector data description approach to NLOS identification in UWB positioning", *Mathematical Problems in Engineering*, zv. 2014, str. 6, maj 2014. DOI: 10.1155/2014/963418. spletni naslov: <http://dx.doi.org/10.1155/2014/963418>.
- [62] B. Silva in G. P. Hancke, "IR-UWB-Based non-line-of-sight identification in harsh environments: Principles and challenges", *IEEE Transactions on Industrial Informatics*, zv. 12, št. 3, str. 1188–1195, jun. 2016, ISSN: 1551-3203. DOI: 10.1109/TII.2016.2554522.

- [63] S. Marano, W. M. Gifford, H. Wymeersch in M. Z. Win, "NLOS identification and mitigation for localization based on UWB experimental data", *IEEE Journal on Selected Areas in Communications*, zv. 28, št. 7, str. 1026–1035, sep. 2010, ISSN: 0733-8716. DOI: 10.1109/JSAC.2010.100907.
- [64] H. Wymeersch, S. Marano, W. M. Gifford in M. Z. Win, "A machine learning approach to ranging error mitigation for UWB localization", *IEEE Transactions on Communications*, zv. 60, št. 6, str. 1719–1728, jun. 2012, ISSN: 0090-6778. DOI: 10.1109/TCOMM.2012.042712.110035.
- [65] W. Li, T. Zhang in Q. Zhang, "Experimental researches on an UWB NLOS identification method based on machine learning", v *2013 15th IEEE International Conference on Communication Technology*, nov. 2013, str. 473–477. DOI: 10.1109/ICCT.2013.6820422.
- [66] D. P. Doane in L. E. Seward, "Measuring skewness: A forgotten statistic?", *Journal of Statistics Education*, zv. 19, št. 2, 2011.
- [67] A. A.-Z. Simon R. Saunders, *Antennas and Propagation for Wireless Communication Systems, 2nd Edition*. John Wiley & Sons, 2007, ISBN: 978-0-470-84879-1.
- [68] M. A. Cobham Antenna Systems, *Xpo2v-2.0-18.00/1397*. spletni naslov: <http://www.european-antennas.co.uk/media/1815/ds1397-250210.pdf>.
- [69] Partron, *ACS5200HFAUWB dielectric chip antenna*. spletni naslov: https://datasheet.lcsc.com/szlcsc/Partron-ACS5200HFAUWB_C224424.pdf.
- [70] M. Ester, H.-P. Kriegel, J. Sander, X. Xu in sod., "A density-based algorithm for discovering clusters in large spatial databases with noise.", v *Kdd*, zv. 96, 1996, str. 226–231.
- [71] J. MacQueen, "Some methods for classification and analysis of multivariate observations", v *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics*, Berkeley, Calif.: University of California Press, 1967, str. 281–297. spletni naslov: <https://projecteuclid.org/euclid.bsmsp/1200512992>.
- [72] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot in É. Duchesnay, "Scikit-learn: Machine learning in python", English, *Journal of Machine Learning Research*, okt. 2011. spletni naslov: <http://hal.inria.fr/hal-00650905>.
- [73] Decawave, *DW1000 datasheet*, Dostop 12.3.2019, Decawave, 2015. spletni naslov: <https://www.decawave.com/sites/default/files/resources/dw1000-datasheet-v2.09.pdf>.
- [74] A. A. M. Saleh in R. Valenzuela, "A statistical model for indoor multipath propagation", *IEEE Journal on Selected Areas in Communications*, zv. 5, št. 2, str. 128–137, feb. 1987, ISSN: 0733-8716. DOI: 10.1109/JSAC.1987.1146527.
- [75] H. Schmid, "A prediction model for multipath propagation of pulse signals at VHF and UHF over irregular terrain", *IEEE Transactions on Antennas and Propagation*, zv. 18, št. 2, str. 253–258, mar. 1970, ISSN: 0018-926X. DOI: 10.1109/TAP.1970.1139661.
- [76] T. Van Nguyen, Y. Jeong, H. Shin in M. Z. Win, "Machine learning for wideband localization", *IEEE Journal on Selected Areas in Communications*, zv. 33, št. 7, str. 1357–1380, jul. 2015, ISSN: 0733-8716. DOI: 10.1109/JSAC.2015.2430191.

- [77] İ. Güvenç, C.-C. Chong, F. Watanabe in H. Inamura, “NLOS identification and weighted least-squares localization for UWB systems using multipath channel statistics”, *EURASIP Journal on Advances in Signal Processing*, zv. 2008, št. 1, str. 271–284, avg. 2007, ISSN: 1687-6180. DOI: 10.1155/2008/271984. spletni naslov: <https://doi.org/10.1155/2008/271984>.
- [78] Y. LeCun, Y. Bengio in G. Hinton, “Deep learning”, *Nature*, zv. 521, str. 436–44, maj 2015. DOI: 10.1038/nature14539.
- [79] J. R. Quinlan, “Induction of decision trees”, *Machine Learning*, zv. 1, št. 1, str. 81–106, mar. 1986, ISSN: 1573-0565. DOI: 10.1007/BF00116251. spletni naslov: <https://doi.org/10.1007/BF00116251>.
- [80] M. Seeger, “Gaussian processes for machine learning”, *International journal of neural systems*, zv. 14, št. 02, str. 69–106, 2004.
- [81] Z. Xiao, H. Wen, A. Markham, N. Trigoni, P. Blunsom in J. Frolik, “Non-line-of-sight identification and mitigation using received signal strength”, *IEEE Transactions on Wireless Communications*, zv. 14, št. 3, str. 1689–1702, mar. 2015, ISSN: 1536-1276. DOI: 10.1109/TWC.2014.2372341.
- [82] G. Yuan, C. Ho in C. Lin, “Recent advances of large-scale linear classification”, *Proceedings of the IEEE*, zv. 100, št. 9, str. 2584–2603, sep. 2012, ISSN: 0018-9219. DOI: 10.1109/JPROC.2012.2188013.
- [83] D. Kim, G. Kwon, J. Pyun in J. Kim, “NLOS identification in UWB channel for indoor positioning”, v *2018 15th IEEE Annual Consumer Communications Networking Conference (CCNC)*, jan. 2018, str. 1–4. DOI: 10.1109/CCNC.2018.8319264.
- [84] J. Schroeder, S. Galler, K. Kyamakya in K. Jobmann, “NLOS detection algorithms for ultra-wideband localization”, v *2007 4th Workshop on Positioning, Navigation and Communication*, mar. 2007, str. 159–166. DOI: 10.1109/WPNC.2007.353628.
- [85] N. Alsindi, C. Duan, J. Zhang in T. Tsuboi, “NLOS channel identification and mitigation in ultra wideband ToA-based wireless sensor networks”, v *2009 6th Workshop on Positioning, Navigation and Communication*, mar. 2009, str. 59–66. DOI: 10.1109/WPNC.2009.4907804.
- [86] K. Yu in Y. J. Guo, “Statistical NLOS identification based on AOA, TOA, and signal strength”, *IEEE Transactions on Vehicular Technology*, zv. 58, št. 1, str. 274–286, jan. 2009, ISSN: 0018-9545. DOI: 10.1109/TVT.2008.924975.
- [87] A. Abbasi in H. Liu, “Improved line-of-sight/non-line-of-sight classification methods for pulsed ultrawideband localisation”, *IET Communications*, zv. 8, št. 5, str. 680–688, mar. 2014, ISSN: 1751-8628. DOI: 10.1049/iet-com.2013.0438.
- [88] X.-y. JIANG, H.-s. ZHANG in W. WANG, “Nlos error mitigation with information fusion algorithm for UWB ranging systems”, *The Journal of China Universities of Posts and Telecommunications*, zv. 19, št. 2, str. 22–29, 2012, ISSN: 1005-8885. DOI: [https://doi.org/10.1016/S1005-8885\(11\)60241-0](https://doi.org/10.1016/S1005-8885(11)60241-0). spletni naslov: <http://www.sciencedirect.com/science/article/pii/S1005888511602410>.
- [89] Z. Zhou, Z. Yang, C. Wu, L. Shangguan, H. Cai, Y. Liu in L. M. Ni, “WiFi-Based indoor line-of-sight identification”, *IEEE Transactions on Wireless Communications*, zv. 14, št. 11, str. 6125–6136, nov. 2015, ISSN: 1536-1276. DOI: 10.1109/TWC.2015.2448540.
- [90] M. A. Landolsi, A. Muqaibel in A. F. Almutairi, “UKF-based channel estimation and LOS/NLOS classification in UWB wireless networks”, *Journal of Engineering Research*, zv. 4, str. 86–102, jun. 2016. DOI: 10.7603/s40632-016-0015-1.

- [91] I. Guvenc, C. Chong in F. Watanabe, “NLOS identification and mitigation for UWB localization systems”, v *2007 IEEE Wireless Communications and Networking Conference*, mar. 2007, str. 1571–1576. DOI: 10.1109/WCNC.2007.296.
- [92] A. H. Muqaibel, M. A. Landolsi in M. N. Mahmood, “Practical evaluation of NLOS/LOS parametric classification in UWB channels”, v *2013 1st International Conference on Communications, Signal Processing, and their Applications (ICC-SPA)*, feb. 2013, str. 1–6. DOI: 10.1109/ICCSPA.2013.6487304.
- [93] C. Wu, H. Hou, W. Wang, Q. Huang in X. Gao, “TDOA based indoor positioning with nlos identification by machine learning”, okt. 2018, str. 1–6. DOI: 10.1109/WCSP.2018.8555654.
- [94] Z. Xiao, H. Wen, A. Markham, N. Trigoni, P. Blunsom in J. Frolik, “Identification and mitigation of non-line-of-sight conditions using received signal strength”, v *2013 IEEE 9th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, okt. 2013, str. 667–674. DOI: 10.1109/WiMOB.2013.6673428.
- [95] D. E. Rumelhart, G. E. Hinton in R. J. Williams, “Learning representations by back-propagating errors”, *Nature*, zv. 323, št. 6088, str. 533, 1986.
- [96] J. Duchi, E. Hazan in Y. Singer, “Adaptive subgradient methods for online learning and stochastic optimization”, *J. Mach. Learn. Res.*, zv. 12, str. 2121–2159, jul. 2011, ISSN: 1532-4435. spletni naslov: <http://dl.acm.org/citation.cfm?id=1953048>. 2021068.
- [97] T. Tieleman in G. Hinton, “Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude”, *COURSERA: Neural networks for machine learning*, zv. 4, št. 2, str. 26–31, 2012.
- [98] S. Ruder, “An overview of gradient descent optimization algorithms”, *CoRR*, zv. abs/1609.04747, 2016. arXiv: 1609.04747. spletni naslov: <http://arxiv.org/abs/1609.04747>.
- [99] M. D. Zeiler, “ADADELTA: an adaptive learning rate method”, *CoRR*, zv. abs/1212.5701, 2012. arXiv: 1212.5701. spletni naslov: <http://arxiv.org/abs/1212.5701>.
- [100] D. P. Kingma in J. Ba, “Adam: A method for stochastic optimization”, *CoRR*, zv. abs/1412.6980, 2014. spletni naslov: <http://arxiv.org/abs/1412.6980>.
- [101] G. Hinton in R. Salakhutdinov, “Reducing the dimensionality of data with neural networks”, *Science*, zv. 313, št. 5786, str. 504–507, 2006.
- [102] F. Movahedi, J. L. Coyle in E. Sejdić, “Deep belief networks for electroencephalography: A review of recent contributions and future outlooks”, *IEEE Journal of Biomedical and Health Informatics*, zv. 22, št. 3, str. 642–652, maj 2018, ISSN: 2168-2194. DOI: 10.1109/JBHI.2017.2727218.
- [103] A. Mohamed, G. Hinton in G. Penn, “Understanding how deep belief networks perform acoustic modelling”, v *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, mar. 2012, str. 4273–4276. DOI: 10.1109/ICASSP.2012.6288863.
- [104] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville in Y. Bengio, “Generative adversarial nets”, v *Advances in Neural Information Processing Systems 27*, Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence in K. Q. Weinberger, ur., Curran Associates, Inc., 2014, str. 2672–2680. spletni naslov: <http://papers.nips.cc/paper/5423-generative-adversarial-nets.pdf>.

- [105] T. Salimans, I. Goodfellow, W. Zaremba, V. Cheung, A. Radford in X. Chen, “Improved techniques for training gans”, v *Advances in Neural Information Processing Systems*, 2016, str. 2234–2242.
- [106] Y. Lecun, L. Bottou, Y. Bengio in P. Haffner, “Gradient-based learning applied to document recognition”, *Proceedings of the IEEE*, zv. 86, št. 11, str. 2278–2324, nov. 1998, ISSN: 0018-9219. DOI: 10.1109/5.726791.
- [107] M. D. Zeiler in R. Fergus, “Visualizing and understanding convolutional networks”, v *European conference on computer vision*, Springer, 2014, str. 818–833.
- [108] I. Sutskever, J. Martens in G. E. Hinton, “Generating text with recurrent neural networks”, v *Proceedings of the 28th International Conference on Machine Learning (ICML-11)*, 2011, str. 1017–1024.
- [109] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk in Y. Bengio, “Learning phrase representations using RNN encoder-decoder for statistical machine translation”, *ArXiv preprint arXiv:1406.1078*, 2014.
- [110] Y. Bengio, P. Simard in P. Frasconi, “Learning long-term dependencies with gradient descent is difficult”, *Trans. Neur. Netw.*, zv. 5, št. 2, str. 157–166, mar. 1994, ISSN: 1045-9227. DOI: 10.1109/72.279181. spletni naslov: <http://dx.doi.org/10.1109/72.279181>.
- [111] S. Hochreiter in J. Schmidhuber, “Long short-term memory”, *Neural computation*, zv. 9, št. 8, str. 1735–1780, 1997.
- [112] A. Graves, A.-r. Mohamed in G. Hinton, “Speech recognition with deep recurrent neural networks”, v *Acoustics, speech and signal processing (icassp), 2013 ieee international conference on*, IEEE, 2013, str. 6645–6649.
- [113] R. Socher, C. C. Lin, C. Manning in A. Y. Ng, “Parsing natural scenes and natural language with recursive neural networks”, v *Proceedings of the 28th international conference on machine learning (ICML-11)*, 2011, str. 129–136.
- [114] Y. L. Cun, B. Boser, J. S. Denker, R. E. Howard, W. Habbard, L. D. Jackel in D. Henderson, “Advances in neural information processing systems 2”, v, D. S. Touretzky, ur., San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1990, pogl. Handwritten Digit Recognition with a Back-propagation Network, str. 396–404, ISBN: 1-55860-100-7. spletni naslov: <http://dl.acm.org/citation.cfm?id=109230.109279>.
- [115] Y. LeCun in Y. Bengio, “Convolutional networks for images, speech, and time series”, v *The Handbook of Brain Theory and Neural Networks*, M. A. Arbib, ur., Cambridge, MA, USA: MIT Press, 1998, pogl. Convolutional Networks for Images, Speech, and Time Series, str. 255–258, ISBN: 0-262-51102-9. spletni naslov: <http://dl.acm.org/citation.cfm?id=303568.303704>.
- [116] N. Qian, “On the momentum term in gradient descent learning algorithms”, *Neural Networks*, zv. 12, št. 1, str. 145–151, 1999, ISSN: 0893-6080. DOI: [https://doi.org/10.1016/S0893-6080\(98\)00116-6](https://doi.org/10.1016/S0893-6080(98)00116-6). spletni naslov: <http://www.sciencedirect.com/science/article/pii/S0893608098001166>.
- [117] S. Ioffe in C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift”, *ArXiv preprint arXiv:1502.03167*, 2015.
- [118] G. E. Hinton, A. Krizhevsky, I. Sutskever in N. Srivastva, *System and method for addressing overfitting in a neural network*, US Patent App. 15/222,870, nov. 2016.

- [119] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever in R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors", *CoRR*, zv. abs/1207.0580, 2012. spletni naslov: <http://arxiv.org/abs/1207.0580>.
- [120] F. Chollet in sod., *Keras*, <https://github.com/fchollet/keras>, 2015.
- [121] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. J. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Józefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. G. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. A. Tucker, V. Vanhoucke, V. Vasudevan, F. B. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu in X. Zheng, "Tensorflow: Large-scale machine learning on heterogeneous distributed systems", *CoRR*, zv. abs/1603.04467, 2016. arXiv: 1603.04467. spletni naslov: <http://arxiv.org/abs/1603.04467>.
- [122] M. Kulin, C. Fortuna, E. De Poorter, D. Deschrijver in I. Moerman, "Data-Driven design of intelligent wireless networks: An overview and tutorial", *Sensors*, zv. 16, št. 6, 2016, ISSN: 1424-8220. DOI: 10.3390/s16060790. spletni naslov: <http://www.mdpi.com/1424-8220/16/6/790>.
- [123] A. Yassin, Y. Nasser, M. Awad, A. Al-Dubai, R. Liu, C. Yuen, R. Raulefs in E. Abo-utanios, "Recent advances in indoor localization: A survey on theoretical approaches and applications", *IEEE Communications Surveys Tutorials*, zv. 19, št. 2, str. 1327–1346, Secondquarter 2017. DOI: 10.1109/COMST.2016.2632427.
- [124] Y. Wang, "Linear least squares localization in sensor networks", *EURASIP Journal on Wireless Communications and Networking*, zv. 2015, št. 1, str. 51, mar. 2015, ISSN: 1687-1499. DOI: 10.1186/s13638-015-0298-1. spletni naslov: <https://doi.org/10.1186/s13638-015-0298-1>.
- [125] D. Dardari, P. Closas in P. M. Djurić, "Indoor tracking: Theory, methods, and technologies", *IEEE Transactions on Vehicular Technology*, zv. 64, št. 4, str. 1263–1278, apr. 2015, ISSN: 0018-9545. DOI: 10.1109/TVT.2015.2403868.
- [126] A. Chatterjee in F. Matsuno, "A neuro-fuzzy assisted extended kalman filter-based approach for simultaneous localization and mapping (SLAM) problems", *IEEE Transactions on Fuzzy Systems*, zv. 15, št. 5, str. 984–997, okt. 2007, ISSN: 1063-6706. DOI: 10.1109/TFUZZ.2007.894972.
- [127] X. He, Y. Le in W. Xiao, "Mems imu and two-antenna gps integration navigation system using interval adaptive kalman filter", *IEEE Aerospace and Electronic Systems Magazine*, zv. 28, št. 10, str. 22–28, okt. 2013, ISSN: 0885-8985. DOI: 10.1109/MAES.2013.6642828.
- [128] D. W. Marquardt, "An algorithm for least-squares estimation of nonlinear parameters", *Journal of the society for Industrial and Applied Mathematics*, zv. 11, št. 2, str. 431–441, 1963.
- [129] H.-C. Shin, "Weighted least squares estimation with sampling weights", *Journal of Mathematics and Statistics*, 2013.
- [130] Y. Zhou, J. Li in D. Wang, "Posterior cramér–rao lower bounds for target tracking in sensor networks with quantized range-only measurements", *IEEE Signal Processing Letters*, zv. 17, št. 2, str. 157–160, feb. 2010, ISSN: 1070-9908. DOI: 10.1109/LSP.2009.2035672.

Bibliografija

Objave v povezavi z delom

Članki v revijah

- K. Bregar in M. Mohorčič, "Improving indoor localization using convolutional neural networks on computationally restricted devices", *IEEE Access*, zv. 6, str. 17 429–17 441, 2018, ISSN: 2169-3536. DOI: 10.1109/ACCESS.2018.2817800.
- K. Bregar, R. Novak in M. Mohorčič, "Evaluation of range-based indoor tracking algorithms by merging simulation and measurements", *EURASIP Journal on Wireless Communications and Networking*, 2019, sprejeto v objavo s popravki.

Prispevek na konferenci

- K. Bregar, R. Novak in M. Mohorčič, "Combining measurements and simulations for evaluation of tracking algorithms", v *2018 European Conference on Networks and Communications (EuCNC)*, jun. 2018, str. 1–250. DOI: 10.1109/EuCNC.2018.8442678.
- A. Hrovat, K. Bregar in T. Javornik, "Measurement based ultra-wideband channel model for mobile communications in tunnels", v *12th European Conference on Antennas and Propagation (EuCAP 2018)*, apr. 2018, str. 1–5. DOI: 10.1049/cp.2018.0810.
- K. Bregar, A. Hrovat in M. Mohorčič, "NLOS channel detection with multilayer perceptron in low - rate personal area networks for indoor localization accuracy improvement", v *Zbornik 8. Študentske konference Mednarodne podiplomske šole Jožefa Stefana - 1. del*, M. PAVLIN, J. VIDMAR, A. KROFLIČ, J. A. ROBINSON, K. BREGAR in A. MATAVŽ, ur., Mednarodna podiplomska šola Jožefa Stefana, Ljubljana, maj 2016, str. 130–139, ISBN: 978-961-94034-0-2. spletni naslov: http://ipssc.mps.si/2016/Proceedings8_IPSSC_2016_Part1.pdf.
- K. Bregar, A. Hrovat in T. J. R. Novak, "Channel impulse response based vehicle analysis in tunnels", v *13th European Conference on Antennas and Propagation (EuCAP 2019)*, EurAAP = European Association for Antennas in Propagation, 2019.

Druge objave

Članki v revijah

- M. Vucnik, T. Solc, U. Gregorc, A. Hrovat, K. Bregar, M. Smolnikar, M. Mohorcic in C. Fortuna, "Continuous integration in wireless technology development", *IEEE Communications Magazine*, zv. 56, št. 12, str. 74–81, dec. 2018, ISSN: 0163-6804. DOI: 10.1109/MCOM.2018.1800107.

Prispevek na konferenci

- K. Bregar in V. Avbelj, "Multi-functional wireless body sensor - analysis of autonomy", v *2013 36th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, maj 2013, str. 322–325.

Biografija

Klemen Bregar se je leta 2013 pridružil Odseku za komunikacijske sisteme na Institutu Jožef Stefan še kot absolvent univerzitetnega študijskega programa avtomatika - inteligentni sistemi na Fakulteti za elektrotehniko v Ljubljani. Po zaključenem študiju se je zaposlil na Odseku za komunikacijske sisteme sprva kot asistent, nato pa je bil pod mentorstvom prof. dr. Mihaela Mohorčiča sprejet v nacionalni program usposabljanja mladih raziskovalcev s financiranjem Javne agencije za raziskovalno dejavnost Republike Slovenije. V študijskem letu 2013/2014 se je vpisal na podiplomski doktorski študij smeri Informacijske in komunikacijske tehnologije na Mednarodni podiplomski šoli Jožefa Stefana.

V času študija je objavil prispevke v znanstvenih revijah in na konferencah s področja doktorske disertacije in s svojim raziskovalnim delom sodeloval na evropskih projektih Obzorja 2020 eWINE (Elastic Wireless Networking Experimentation) in SAAM (Supporting Active Ageing Through Multimodal Coaching) ter na nacionalnem aplikativnem raziskovalnem projektu L2-7664 (Napredne tehnike sledenja žarkom za karakterizacijo radijskega okolja in radijsko lokalizacijo).

V času doktorskega študija je sodeloval tudi pri razvoju mobilnega merilnega sistema za dolgotrajno spremljanje srčnega ritma Savvy/PCARD, ki so ga s soavtorji s prijavo tehnološke izboljšave uspešno prenesli v industrijo in prejeli Puhovo priznanje za pomembne dosežke na področju medicinske opreme za leto 2017.

Raziskovalni interesi Klemna Bregarja zajemajo predvsem uporabo tehnik strojnega učenja s poudarkom na uporabi tehnik globokega učenja na področju brezžičnih komunikacijskih tehnologij, aktivno in pasivno lokalizacijo v zahtevnih radijskih okoljih, razširjanje radijskih signalov UWB, radijsko tomografijo in senzorska omrežja.

