

UNIVERZITET U BEOGRADU
ELEKTROTEHNIČKI FAKULTET

Majda A. Petrić

**ODREĐIVANJE POZICIJE MOBILNIH
KORISNIKA U JAVNIM MOBILNIM
SYSTEMIMA KORIŠĆENJEM METODA
ZASNOVANIH NA *SUPPORT VECTOR
MACHINE* ALGORITMIMA**

doktorska disertacija

Beograd, 2018

UNIVERSITY OF BELGRADE
SCHOOL OF ELECTRICAL ENGINEERING

Majda A. Petrić

**MOBILE USER POSITIONING IN
PUBLIC LAND MOBILE NETWORKS BY
USING METHODS BASED ON
SUPPORT VECTOR MACHINES**

Doctoral Dissertation

Belgrade, 2018

PODACI O MENTORU I ČLANOVIMA KOMISIJE

Mentor:

Dr Aleksandar Nešković, redovni profesor
Univerzitet u Beogradu - Elektrotehnički fakultet

Članovi komisije:

Dr Nataša Nešković, redovni profesor
Univerzitet u Beogradu - Elektrotehnički fakultet

Dr Nikola Tomašević, naučni saradnik
Institut Mihajlo Pupin

Dr Željko Đurović, redovni profesor
Univerzitet u Beogradu - Elektrotehnički fakultet

Dr Mirjana Simić Pejović, vanredni profesor
Univerzitet u Beogradu - Elektrotehnički fakultet

Datum odbrane:

ODREĐIVANJE POZICIJE MOBILNIH KORISNIKA U JAVNIM MOBILNIM SISTEMIMA KORIŠĆENJEM METODA ZASNOVANIH NA *SUPPORT VECTOR MACHINE* ALGORITMIMA

Rezime:

Tokom prethodnih godina, potreba za podrškom sve većeg broja LBS (*Location Based Services*) servisa dovela je do intenzivnog razvoja tehnika za pozicioniranje mobilnih korisnika (objekata) u radio sistemima. Pri tom, zahtevi koje sistemi za pozicioniranje treba da ispune, prvenstveno po pitanju tačnosti, ali i po pitanju kašnjenja, dostupnosti servisa, kompleksnosti i cene implementacije, postaju sve strožiji.

U okviru ove disertacije napravljen je pregled postojećih standardizovanih i nestandardizovanih metoda pozicioniranja u radio sistemima. Na osnovu sprovedene analize uočena su dva ključna nedostatka koja se javljaju pri korišćenju infrastrukture različitih radio sistema: dostupnost sistema u različitim tipovima okruženja i/ili cena implementacije.

Definisana je nova tehnika pozicioniranja koja se zasniva na korišćenju postojeće, globalno rasprostranjene infrastrukture javnih mobilnih sistema (GSM - *Global System for Mobile Communications*, DCS - *Digital Communication System*, UMTS - *Universal Mobile Telecommunication System*, LTE - *Long-Term Evolution*). Osim smanjenja cene implementacije sistema za pozicioniranje usled iskorišćenja već raspoložive mrežne infrastrukture, dodatni motiv za primenu ovog pristupa je dobro radio pokrivanje koje pružaju javni mobilni sistemi (*Public Land Mobile Networks*, PLMN), kako u *outdoor* okruženjima različitog stepena urbanizacije, tako i u *indoor* okruženjima. Drugim rečima, moguće je obezbediti dostupnost sistema za pozicioniranje nezavisno od tipa okruženja u kome se korisnik nalazi.

U okviru disertacije razvijena su dva nova algoritma za određivanje inicijalne pozicije mobilnog terminala na osnovu nivoa signala (*Received Signal Strength*, RSS) PLMN ćelija u njegovom okruženju i primeni *Support Vector Machine* algoritama mašinskog učenja. Prvi metod se zasniva na korišćenju *Support Vector Regression*

(SVR) algoritma za aproksimaciju nelinearne funkcije koja opisuje vezu između izmerenih RSS nivoa i prostornih koordinata u nekoj geografskoj oblasti. Drugi pristup koristi princip segmentacije geografskog okruženja od interesa na podprostore, korišćenjem *multiclass* klasifikatora realizovanog sa *Support Vector Classification* (SVC) strukturama. Naknadnom upotrebom SVR algoritama, za svaku podoblast se aproksimira funkcija za predikciju pozicije korisnika.

Performanse obe metode pozicioniranja verifikovane su korišćenjem realnih podataka koji su prikupljeni tokom mernih kampanja sprovedenih u *outdoor* i *indoor* okruženju na teritoriji grada Beograda.

Izvršena je analiza performansi SVR metode u *outdoor* okruženju za slučaj korišćenja infrastrukture GSM i/ili DCS sistema jednog operatora, kao i za slučaj definisanja različitog broja izvora radio signala (ćelija) koji su relevantni za proces pozicioniranja. Pokazano je da povećanje broja relevantnih ćelija čiji se signal koristi u procesu pozicioniranja, utiče na smanjenje broja velikih vrednosti grešaka pozicioniranja, ali da opšte performanse SVR metode pozicioniranja zavise u velikoj meri od kvaliteta signala relevantnih ćelija (nivoa i stabilnosti signala u prostoru od interesa).

Dodatno, pokazano je da se primenom principa segmentacije prostora i kombinovane SVC&SVR metode može dalje unaprediti tačnost pozicioniranja u *outdoor* okruženju, obezbeđivanjem veće homogenosti podataka koji se koriste za rešavanje problema regresije. Najveći doprinos primene ovog principa uočen je u domenu smanjenja broja grešaka srednje veličine (tj. *medium-sized* grešaka), na račun porasta broja relativno manjih vrednosti grešaka estimacije. Navedeni efekat postaje još izraženiji sa porastom stepena segmentacije.

Rezultati verifikacije SVR i SVC&SVR metode u realnom *outdoor* okruženju pokazali su da se primenom predloženih metoda može ostvariti tačnost pozicioniranja koja je u skladu sa zahtevima definisanim od strane Federalne komisije za komunikacije (*Federal Communications Commission*, FCC), a da se pri tom ne zahtevaju nikakve izmene postojeće GSM (DCS) signalizacije, kao ni izmene na mobilnim terminalima. Ograničavanjem broja relevantnih ćelija na 7, u skladu sa veličinom mernog izveštaja podržanog GSM/DCS standardom, primenom SVR metode u 67% slučajeva ostvarena je greška pozicioniranja manja od 47.2m (47.2m|67%), odnosno greška manja od 210m

u 90% slučajeva (210m|90%). Primenom SVC&SVR metode postignuto je dalje unapređenje tačnosti: 31.6m|67% i 192m|90%.

U okviru disertacije izvršena je i analiza uticaja istovremenog korišćenja infrastrukture većeg broja mobilnih operatera (Telenor, Mobilne Telefonije Srbije – MTS i VIP), kao i 5 različitih kriterijuma za selekciju relevantnih ćelija, na tačnost pozicioniranja. U tu svrhu, implementirano je 20 različitih SVR modela za pozicioniranje u test *indoor* okruženju. Pokazano je da se korišćenjem infrastrukture većeg broja mobilnih operatera može postići veća tačnost pozicioniranja, nego u slučaju korišćenja infrastrukture samo jednog operatera. Dodatno, pokazano je da je primena kriterijuma koji vrši selekciju ćelija koje imaju relativno visoke nivoe signala u određenom delu nekog okruženja (bez obzira na njihovu opštu radio-vidljivost u datom okruženju), pogodna u slučaju korišćenja infrastrukture i jednog i većeg broja operatera, kao i u slučaju primene principa segmentacije prostora na manje celine.

Prednosti uvođenja principa segmentacije prostora i primene kombinovane SVC&SVR metode potvrđene su i u slučaju *indoor* okruženja. Analiza performansi SVC&SVR metode u *indoor* okruženju izvršena je za 6 različitih podela prostora, a dobijeni rezultati ukazuju na to da povećanje stepena segmentacije prostora ima smisla samo do određene granice, kada porast broja velikih vrednosti grešaka, uzrokovan pogrešnom detekcijom podprostora, počinje da umanjuje dobitak ovog pristupa.

Tačnost SVR i SVC&SVR metode postignute tokom procesa verifikacije u realnom *indoor* okruženju, zadovoljavaju zahteve Federalne komisije za komunikacije definisane za *indoor* okruženja. Prilikom korišćenja infrastrukture sva tri mobilna operatera, SVR metod ostvario je srednju vrednost greške pozicioniranja od 10.1m, dok je primenom SVC&SVR metode postignuto dalje smanjenje vrednosti srednje greške pozicioniranja za 27%.

U okviru disertacije je takođe izvršeno poređenje performansi SVR i SVC&SVR metode sa performansama drugih, relevantnih PLMN tehnika, koje su verifikovane u realnim *outdoor* i *indoor* okruženjima. U cilju verodostojnog poređenja, metode koje su u relevantnim istraživanjima pokazale najbolje performanse, implementirane su i u *outdoor* i *indoor* okruženjima razmatranim u okviru ovog istraživanja. Pri identičnim uslovima, predložene SVR i SVC&SVR metode su ostvarile bolje performanse od

drugih *fingerprinting* tehnika zasnovanih na primeni kNN (*k Nearest Neighbours*), ANN (*Artificial Neural Networks*) i SVM algoritama.

Vreme potrebno za proračun prostornih koordinata SVR i SVC&SVR metode u *online* fazi iznosi manje od jedne sekunde, što ih čini pogodnim za realizaciju LBS servisa sa striktnim zahtevima po pitanju kašnjenja.

Implementacija predloženih metoda ne zahteva nikakve hardverske izmene na mobilnim terminalima. Izmene na strani mrežne infrastrukture ograničene su na izgradnju određenog broja SMLC (*Service Mobile Location Centre*) centara, u kojima se vrši proračun pozicije mobilnog korisnika. Dodatno, iako pozicioniranje korišćenjem većeg broja RSS merenja, od onog podržanog standardnom formom mernog izveštaja, zahteva određene izmene postojeće signalizacije u PLMN mrežama, date izmene ne bi trebalo da imaju veliki uticaj na kapacitet same PLMN mreže.

Ključne reči: Javni mobilni sistemi, tehnike pozicioniranja, mašinsko učenje, *Support Vector Machines*, *fingerprinting*, segmentacija prostora, nivo signala baznih stanica javnih mobilnih sistema, relevantni izvori radio signala za pozicioniranje.

Naučna oblast: tehničke nauke, elektrotehnika

Uža naučna oblast: telekomunikacije

UDK broj: 621.3

MOBILE USER POSITIONING IN PUBLIC LAND MOBILE NETWORKS BY USING METHODS BASED ON SUPPORT VECTOR MACHINES

Abstract:

Over the last years, the necessity of providing the support for various Location Based Services (LBS) has led to the intensive development of the techniques for mobile user (objects) positioning in radio systems. At the same time, the requirements that need to be fulfilled by the positioning technique in terms of accuracy, latency, availability, complexity and implementation costs, are getting higher.

In this dissertation, the overview of existing standardized and non-standardized positioning methods has been made. Based on the conducted analysis, two main drawbacks that occur when the infrastructure of the most radio system is used, have been detected: system availability in different types of environments and/or implementation costs.

A new positioning technique that utilizes existing, globally deployed network infrastructure of Public Land Mobile Networks, PLMN (GSM - *Global System for Mobile Communications*, DCS - *Digital Communication System*, UMTS - *Universal Mobile Telecommunication System*, LTE - *Long-Term Evolution*), has been proposed. Beside the implementation costs reductions due to the usage of already available network infrastructure, the additional motive for applying this approach is the good radio coverage of PLMN networks, both in indoor and outdoor environments of different urbanization levels. Therefore, it is possible to provide positioning system availability regardless of the type of environment in which user currently resides.

In this dissertation, two new algorithms for mobile terminal initial position determination, which use measured received signal strength levels (RSS) of nearby PLMN cells and Support Vector Machine learning algorithms, have been proposed. The first method is based on the use of Support Vector Regression algorithm for approximating a nonlinear function that describes relation between the measured RSS

levels and the spatial coordinates in some geographical area. The second approach uses the space-partitioning principle that divides a geographical area into smaller subspaces, by using multiclass classifier implemented with Support Vector Classification (SVC) structures. With the subsequent use of SVR algorithms, the function that estimates the exact spatial coordinates is being approximated for each subarea.

The proposed methods are verified by implementing SVR and combined SVC&SVR models using real data gathered during measurement campaigns conducted in outdoor and indoor environments on the territory of Belgrade city.

Performances of SVR positioning method in outdoor environment have been analysed for different scenarios of using infrastructure of GSM and/or DCS system of a one mobile operator, as well as for a different number of relevant radio sources (cells) defined. It has been shown that the increase in the number of relevant cells, whose signals are being used for the positioning purposes, reduces the number of big-scaled positioning errors. However, attention must be paid to the signal quality of relevant cells (in terms of signal levels and dynamics within the area of interest).

In addition, it has been shown that the use of space partitioning principle and combined SVC&SVR positioning algorithm can further improve positioning accuracy in outdoor environment, by providing better homogeneity of data used for solving the regression problem. The biggest contribution of this approach was observed in the decrease of the number of medium-sized positioning errors, on the account of the increase of the number of relatively small ones. This effect becomes even more pronounced with the higher degree of space-partitioning.

The results of SVR and SVC&SVR methods verification in the real outdoor environment has shown that these methods can achieve accuracy that is in accordance with the Federal Communications Commission (FCC) requirements, without requiring any modifications of the existing GSM (DCS) signalling, nor modifications of mobile devices. By limiting the number of relevant cells to 7, in compliance with the size of measurement report supported by the GSM/DCS signalling, the positioning error of less than 47.2m in 67% cases (47.2m|67%) and less than 210m in 90% cases (210m|90%) has been achieved with SVR method. By applying SVC&SVR method, the accuracy is further improved to 31.6m|67% and 192m|90%.

Within the dissertation, the impact of the simultaneous use of multiple mobile operators' infrastructures (Telenor, MTS and VIP) on positioning accuracy, as well as the impact of applying 5 different criteria for selecting relevant cells, was also analysed. For this purpose, 20 different SVR models for positioning in indoor environment have been implemented. It has been shown that the use of infrastructures of multiple mobile operators can provide higher positioning accuracy, compared to the case when infrastructure of only one operator is used. Additionally, the criteria that selects the cells that have relatively high signal levels in the certain part of the observed environment (regardless of their overall radio-visibility) has proven good performance in the case of both single-operator or multi-operator solutions, as well as in the case when space partitioning principle is applied.

The advantages of introducing the space partitioning principle and using combined SVC&SVR method were also confirmed in the case of indoor environment. The performance of SVC&SVR method in indoor environment was analysed for 6 different space partitions. The obtained results have shown that increasing the number of partitions provides accuracy improvements, but only to a certain point, when the increased number of large-scaled errors, caused by the wrong subspace selection, begins to decrease the performance gain achieved by the subspace size reduction.

It has been shown that accuracies obtained with SVR and SVC&SVR positioning methods in indoor environment are also in accordance with the FCC indoor requirements. The multi-operator SVR method has obtained the mean positioning error of 10.1m, while combined SVC&SVR method has provided further reduction of the mean positioning error by 27%.

The performances of SVR and SVC&SVR methods have also been compared to the performance of other relevant PLMN techniques, which have been verified in real outdoor and indoor environments. To provide a credible comparison, the methods for which the best performances were reported in the relevant studies, have also been implemented for outdoor and indoor environments used in this study. When compared over the same test beds, the proposed SVR and SVC&SVR methods have demonstrated better accuracy than other fingerprinting techniques based on kNN (k Nearest Neighbours), ANN (Artificial Neural Networks) and SVM algorithms.

In the case of both SVR and SVC&SVR methods, the time needed for position estimation in online phase is less than a second, which makes them suitable for the LBS services with the strict latency requirements.

The implementation of the proposed methods does not require any hardware changes to mobile devices. Changes to the network infrastructure are limited to the implementation of a certain number of SMLC (Service Mobile Location Center), in which the calculation of a user position is to be carried out. In addition, although positioning with the use of a larger number of RSS measurements, compared to the one supported by the standard measurement report, requires certain modifications of the existing PLMN signalling, these changes should not have a major impact on the PLMN network capacity.

Keywords: Public Land Mobile Networks (PLMN), positioning techniques, machine learning, *Support Vector Machines*, *fingerprinting*, space-partitioning, signal levels from PLMN base stations, relevant radio sources for positioning.

Scientific area: technical sciences, electrical engineering

Specific scientific area: telecommunications

UDK number: 621.3

SADRŽAJ

1.	UVOD.....	1
2.	PRINCIPI POZICIONIRANJA U RADIO SISTEMIMA.....	5
2.1.	PARAMETRI ZA OCENU KVALITETA PERFORMANSI TEHNIKA POZICIONIRANJA I ZAHTEVI REGULATORNIH TELA	5
2.1.1.	Tačnost metoda pozicioniranja.....	5
2.1.2.	Ostali parametri za ocenu performansi metoda pozicioniranja	7
2.1.3.	Zahtevi regulatornih tela	9
2.2.	PARAMETRI RADIO SIGNALA ZA POZICIONIRANJE U RADIO SISTEMIMA	12
2.3.	OPŠTE PODELE TEHNIKA ZA POZICIONIRANJE	18
2.3.1.	Podela metoda pozicioniranja prema tipu korišćene infrastrukture.....	18
2.3.2.	Podela metoda pozicioniranja prema korišćenom algoritmu.....	21
2.4.	OUTDOOR POZICIONIRANJE.....	27
2.4.1.	Satelitsko pozicioniranje	27
2.4.2.	Standardizovane metode ćelijskog pozicioniranja	31
2.4.3.	Nestandardizovane metode ćelijskog pozicioniranja.....	38
2.5.	INDOOR POZICIONIRANJE.....	43
2.5.1.	WLAN metode pozicioniranja	44
2.5.2.	Metode pozicioniranja korišćenjem radio tehnologija kratkog dometa.....	46
2.5.3.	Ćelijsko pozicioniranje.....	49
3.	SUPPORT VECTOR MACHINES (SVM).....	53
3.1.	UVOD U SUPPORT VECTOR MACHINES.....	53
3.2.	OSNOVI TEORIJE STATISTIČKOG UČENJA.....	56
3.2.1.	Definisanje problema učenja	56
3.2.1.	Metod minimiziranja empirijskog rizika	58
3.2.2.	Teorija konzistencije procesa učenja.....	59
3.2.3.	VC (Vapnik–Chervonenkis) dimenzije	61
3.2.4.	Metod minimiziranja strukturalnog rizika.....	64
3.3.	REŠAVANJE NELINEARNIH PROBLEMA PRIMENOM KERNEL METODE	66
3.3.1.	Modularnost algoritama mašinskog učenja baziranih na kernel metodi.....	67
3.3.2.	Kernel funkcije.....	69

3.4.	<i>SUPPORT VECTOR MACHINES</i> ZA REŠAVANJE PROBLEMA KLASIFIKACIJE I REGRESIJE	74
3.4.1.	Hard-margin klasifikator	75
3.4.2.	Soft-margin klasifikator	82
3.4.3.	Support Vector Regression.....	87
4.	NOVE METODE POZICIONIRANJA U JAVNIM MOBILNIM SISTEMIMA ZASNOVANE NA SVM ALGORITMIMA	95
4.1.	KORIŠĆENJE PARAMETRA NIVOVA SIGNALA NA PRIJEMU ZA ODREĐIVANJE POZICIJE MOBILNOG TERMINALA	96
4.1.1.	Merenje nivoa signala na prijemu – RSS parametar	96
4.1.2.	Prednosti korišćenja RSS parametra	99
4.1.3.	Nedostaci korišćenja RSS parametra i potencijalna rešenja	101
4.2.	POSTUPAK POZICIONIRANJA.....	104
4.3.	SVR MODEL ZA POZICIONIRANJE.....	107
4.4.	KOMBINOVANI SVC&SVR MODEL ZA POZICIONIRANJE	110
4.4.1.	Kombinovani SVC&SVR model	111
4.4.2.	Alternativni kombinovani SVC&SVR model sa ugneženim SVC slojevima ..	114
5.	PRIMENA SVM ALGORITAMA ZA POZICIONIRANJE U <i>OUTDOOR</i> OKRUŽENJU	117
5.1.	TEST <i>OUTDOOR</i> OKRUŽENJE I DEFINISANJE RELEVANTNIH RADIO IZVORA.....	117
5.1.1.	Prikupljanje podataka	117
5.1.2.	Definisanje relevantnih radio izvora	120
5.2.	TRENIRANJE I OPTIMIZACIJA SVM MODELA ZA POZICIONIRANJE	121
5.2.1.	Realizacija SVR modela za pozicioniranje	121
5.2.2.	Realizacija SVC&SVR modela za pozicioniranje.....	123
5.3.	ANALIZA PERFORMANSI SVR I SVC&SVR MODELA ZA POZICIONIRANJE U <i>OUTDOOR</i> OKRUŽENJU.....	125
5.3.1.	Tačnost pozicioniranja SVR metode	125
5.3.2.	Tačnost pozicioniranja kombinovane SVC&SVR metode.....	132
5.3.3.	Kompleksnost i kašnjenje SVM modela – outdoor okruženje	135
5.4.	POREĐENJE SA DRUGIM ČELIJSKIM METODAMA POZICIONIRANJA U <i>OUTDOOR</i> OKRUŽENJU.....	138
6.	PRIMENA SVM ALGORITAMA ZA POZICIONIRANJE U <i>INDOOR</i> OKRUŽENJU	145
6.1.	TEST <i>INDOOR</i> OKRUŽENJE I DEFINISANJE RELEVANTNIH RADIO IZVORA.....	145
6.1.1.	Prikupljanje podataka	145
6.1.2.	Odabir relevantnih ćelija	148
6.2.	TRENIRANJE I OPTIMIZACIJA SVM MODELA ZA POZICIONIRANJE	150
6.2.1.	Realizacija SVR modela za pozicioniranje	151
6.2.2.	Realizacija SVC&SVR modela za pozicioniranje.....	151
6.3.	ANALIZA PERFORMANSI SVR I SVC&SVR MODELA ZA POZICIONIRANJE U <i>INDOOR</i> OKRUŽENJU.....	153
6.3.1.	Tačnost pozicioniranja SVR metode	153

6.3.2.	Tačnost pozicioniranja kombinovane SVC&SVR metode.....	158
6.3.3.	Kompleksnost i kašnjenje SVM modela – indoor okruženje	164
6.4.	POREĐENJE SA DRUGIM ĆELIJSKIM METODAMA U <i>INDOOR</i> OKRUŽENJU.....	166
7.	ZAKLJUČAK.....	172
	LITERATURA.....	179
	BIOGRAFIJA.....	186

1. UVOD

Razvoj tehnika za određivanje pozicije mobilnih entiteta (ljudi, vozila ili predmeta) korišćenjem infrastrukture različitih radio sistema, predmet je velikog interesovanja naučne zajednice već duži niz godina.

Intezivan razvoj ovih tehnika prvobitno je motivisan bezbednosnim aspektom, odnosno, potrebom mobilnih operatora da obezbede servis hitnog poziva (*emergency call service*). S druge strane, razvoj tehnika za pozicioniranje u radio sistemima otvorio je vrata novoj generaciji telekomunikacionih servisa, tzv. LBS (*Location Based Services*) servisima. LBS servisi omogućavaju pružanje odgovarajućih informacija, sadržaja i usluga u zavisnosti od pozicije (lokacije¹) korisnika ili objekta od interesa. Primeri LBS servisa su bezbednosni servisi (servisi hitnog poziva, pomoć na putu, lični medicinski alarmi, hitni alarmi o vremenskim prilikama, stanju na putevima, itd), servisi praćenja ljudi i objekata, navigacija, servisi plaćanja zavisno od lokacije, oglašavanje (reklame), pružanje servisnih informacije o okruženju (najbliža bolnica, pumpa, prodavnica, parking mesto), itd.

U cilju obezbeđivanja adekvatnog kvaliteta LBS servisa, naročito servisa hitnog poziva, Federalna komisija za komunikacije (*Federal Communication Commission*, FCC) i Evropska komisija (*European Commission*, EC) definisale su zahteve po pitanju tačnosti i kašnjenja (vremena odziva) sistema za pozicioniranje. Trenutna istraživanja naučne zajednice orijentisana su ka razvoju tehnika pozicioniranja što veće tačnosti. Ipak, bitni faktori koji pri tom moraju biti ispoštovani su dostupnost tehnike pozicioniranja u različitim okruženjima (urbanim, suburbanim, ruralnim i zatvorenim

¹ Sa stanovišta pozicioniranja, reč *pozicija* i *lokacija* mogu imati različita značenja. U literaturi, pod pojmom *pozicija* obično se podrazumeva tačka u prostoru, predstavljena numerički u formi prostornih koordinata. S druge strane, pojam *lokacija* daje opisnu informaciju u formi određenog mesta (oblasti) u realnom svetu.

prostorima), dobra energetska efikasnost (mala potrošnja baterije mobilnog uređaja), kao i minimalne izmene na strani mreže i mobilnih uređaja, tj. niska cena implementacije.

Sistemi pozicioniranja koji se zasnivaju na korišćenju infrastrukture satelitskih sistema, kao što je GPS (*Global Positioning System*) i dalje predstavljaju najčešće korišćen pristup. Međutim, i pored visoke tačnosti pozicioniranja korisnika/objekta u *outdoor* okruženjima, performanse ovih sistema bivaju značajno degradirane u visoko urbanizovanim sredinama (tzv. gradskim kanjonima) usled efekta senki i višestruke (*mutipath*) propagacije, kao i u zatvorenim prostorima (*indoor* okruženjima) usled izrazito niskih nivoa signala sa satelita. Problemi dostupnosti GPS sistema motivisali su razvoj tehnika pozicioniranja koji se zasnivaju na korišćenju infrastrukture drugih radio sistema.

Cilj ove disertacije bio je realizacija nove tehnike za pozicioniranje koja može, sa zahtevanom tačnošću, da obezbedi informaciju o poziciji korisnika/objekta i u *outdoor* i *indoor* okruženju. U tu svrhu, dat je predlog korišćenja javnih mobilnih sistema (GSM - *Global System for Mobile Communications*, DCS - *Digital Communication System*, UMTS - *Universal Mobile Telecommunication System*, LTE - *Long-Term Evolution*), zbog globalne rasprostranjenosti njihove infrastrukture i dobrog radio pokrivanja, kako u *outdoor* okruženjima različitog stepena urbanizacije, tako i u *indoor* okruženjima.

U opštem slučaju, estimacija pozicije mobilnog uređaja može se vršiti na osnovu različitih parametara radio signala: nivoa signala na prijemu, vremena propagacije, ugla nailaska signala, itd. U okviru ovog istraživanja izvršena je teorijska analiza osnovnih svojstava parametara radio signala koji se mogu koristiti za potrebe pozicioniranja. Analizirana je osetljivost pojedinih parametara radio signala na radio propagacione uslove u različitim okruženjima, poput osetljivosti na višestruku propagaciju, nepostojanje direktne putanje između predajnika i prijemnika, itd. Dodatno, u obzir je uzet i uticaj korišćenja određenog parametra radio signala na mrežnu infrastrukturu i mobilne terminale (neophodnost dodatnih infrastrukturnih elemenata, hardverske i softverske izmene na mobilnim terminalima, izmene mrežne signalizacije). Cilj istraživanja bio je odabir optimalnog parametra sa stanovišta pozicioniranja i u *indoor* i *outdoor* okruženjima, čije korišćenje ima minimalni uticaj na cenu implementacije

sistema za pozicioniranje. Uzimajući u obzir navedene kriterijume, kao optimalan parametar radio signala za potrebe pozicioniranja odabran je nivo signala na prijemu.

U dosadašnjim istraživanjima razmatrano je korišćenje različitih matematičkih algoritama za potrebe estimacije pozicije mobilnog uređaja na osnovu određenih parametara radio signala. Cilj ovog istraživanja bio je da se ispitaju mogućnosti postizanja veće tačnosti pozicioniranja u odnosu na postojeće tehnike, korišćenjem *Support Vector Machine* (SVM) algoritama mašinskog učenja za pronalaženje nelinearne relacije koja postoji između nivoa signala baznih stanica izmerenih u nekoj tački prostora i prostornih koordinata date tačke. U tu svrhu, razvijene su dve nove metode za pozicioniranje u javnim mobilnim sistemima. Prvi metod se zasniva na korišćenju *Support Vector Regression* (SVR) algoritma mašinskog učenja. Drugi metod se zasniva na primeni principa segmentacije prostora na manje celine i kombinovanoj primeni *Support Vector Classification* (SVC) i *Support Vector Regression* (SVR) algoritama. Kod datog pristupa, mobilni uređaj se prvo lokalizuje u užoj zoni nekog geografskog okruženja, nakon čega se vrši estimacija prostornih koordinata njegove trenutne pozicije.

Bitan aspekt ovog istraživanja jeste verifikacija performansi predloženih SVM metoda pozicioniranja na primeru realnog *outdoor* i *indoor* okruženja. U tu svrhu, sprovedene su merne kampanje i izvršena je statistička analiza izmerenih nivoa signala u test *outdoor* i *indoor* okruženjima. Polazeći od pretpostavke da broj i prostorni raspored izvora radio signala, kao i karakteristike radio signala (tj. nivo i stabilnost signala), utiču na tačnost pozicioniranja, cilj ovog istraživanja bio je i da se ispitaju različiti kriterijumi za određivanje optimalnih radio izvora za potrebe pozicioniranja. Dodatan aspekt istraživanja bio je da se razmotri uticaj istovremenog korišćenja infrastrukture većeg broja mobilnih operatora na tačnost pozicioniranja.

Pored uvodnog dela, disertacija se sastoji od još šest poglavlja. U drugom poglavlju razmatrani su osnovni principi pozicioniranja u radio sistemima. Dat je pregled zahteva i kriterijuma za ocenu kvaliteta performansi tehnika pozicioniranja, izvršena je analiza parametara radio signala koji se mogu koristiti za potrebe pozicioniranja, kao i algoritama za estimaciju pozicije. Dodatno, dat je pregled postojećih standardizovanih i nestandardizovanih metoda pozicioniranja u *outdoor* i

indoor okruženjima. U okviru trećeg poglavlja izložene su osnovne teorije statističkog učenja i dat je detaljan opis SVM algoritama namenjenih rešavanju nelinearnih problema klasifikacije i regresije. Predlog nove tehnike pozicioniranja zasnovane na korišćenju SVM algoritama izložen je u četvrtom poglavlju. Poglavlje sadrži opis procedure pozicioniranja, kao i opis SVR i kombinovane SVC&SVR metode. Implementacija SVR i SVC&SVR metoda pozicioniranja na primeru realnog *outdoor* okruženja, razmatrana je u petom poglavlju. Poglavlje sadrži analizu rezultata verifikacije SVR metode pozicioniranja za različite kriterijume selekcije izvora radio signala, kao i analizu performansi kombinovane SVC&SVR metode pozicioniranja pri različitim stepenima segmentacije prostora. Komparativna analiza performansi implementiranih SVR i SVC&SVR modela i drugih metoda pozicioniranja u javnim mobilnim sistemima, za slučaj njihove primene u *outdoor* okruženjima, data je na kraju poglavlja pet. U poglavlju šest razmatrana je primena predloženih SVR i SVC&SVR metoda pozicioniranja u realnom *indoor* okruženju. Pored analize performansi datih modela za slučaj primene različitih kriterijuma selekcije radio izvora i različitih stepena segmentacije prostora, u eksperimentima sprovedenim u *indoor* okruženju dodatno je razmatran uticaj korišćenja infrastrukture većeg broja mobilnih operatora na tačnost pozicioniranja. Komparativna analiza performansi implementiranih SVR i SVC&SVR modela i drugih metoda pozicioniranja u javnim mobilnim sistemima, za slučaj njihove primene u *indoor* okruženjima, data je na kraju poglavlja šest. Zaključna razmatranja izložena su u završnom sedmom poglavlju.

2. PRINCIPI POZICIONIRANJA U RADIO SISTEMIMA

2.1. PARAMETRI ZA OCENU KVALITETA PERFORMANSI TEHNIKA POZICIONIRANJA I ZAHTEVI REGULATORNIH TELA

Određivanje pozicije mobilnog korisnika (tj. mobilnog terminala) u radio sistemima ne može se posmatrati kao jednostavan mehanizam proračuna geografskih koordinata. Naime, gotovo je nemoguće postići tačnu estimaciju pozicije korisnika u 100% slučajeva, tj. gde god da se on nalazi i kakvi god da su uslovi u njegovom trenutnom okruženju.

Kako na rezultat dobijen primenom neke metode pozicioniranja može uticati niz različitih faktora, može se govoriti samo o proceni pozicije, a ne tačnoj poziciji. Da bi se ocenio kvalitet procene pozicije mobilnog korisnika (mobilnog terminala) primenom neke od metoda pozicioniranja, uvedeno je nekoliko parametara [1]:

- 1) tačnost,
- 2) dostupnost i konzistencija,
- 3) kašnjenje,
- 4) priraštaj opterećenja i energetska efikasnost,
- 5) kompleksnost, skalabilnost i cena implementacije.

2.1.1. TAČNOST METODA POZICIONIRANJA

Parametar tačnosti predstavlja jedan od najbitnijih parametara za ocenu kvaliteta neke tehnike pozicioniranja. U osnovi, on definiše koliko je proračunata (estimirana)

pozicija mobilnog korisnika (terminala) geografski bliska njegovoj stvarnoj poziciji. Da bi se odredio stepen odstupanja estimirane pozicije od stvarne, neophodno je uzeti u obzir sledeće veličine:

- 1) grešku,
- 2) nesigurnost (eng. *uncertainty*) i
- 3) pouzdanost (eng. *confidence level*) pozicioniranja.

Greška pozicioniranja predstavlja razliku između stvarne i estimirane pozicije mobilnog korisnika (terminala), dobijene primenom nekog metoda pozicioniranja. Kako data razlika u fizičkom smislu predstavlja rastojanje, često se u literaturi označava kao *distance error* (DE).

Greška pozicioniranja kao parametar tačnosti može biti jako korisna prilikom razmatranja pojedinačnih slučajeva određivanja pozicije. Međutim, kako bi se ocenile generalne performanse neke tehnike pozicioniranja po pitanju tačnosti, pogodnije je razmatrati statistiku greške pozicioniranja, kroz parametre nesigurnosti i pouzdanosti.

Imajući u vidu da pozicija dobijena proračunom nije potpuno tačna, već da uvek postoji određena greška pozicioniranja, rezultat procene pozicije nije tačka već oblast u kojoj se korisnik može nalaziti. Data oblast može biti različitog oblika, u zavisnosti od primenjene tehnike pozicioniranja. Parametar nesigurnosti (*uncertainty*) pozicioniranja definisan je kao rastojanje od centra oblasti u kojoj se procenjuje pozicija korisnika do najudaljenije tačke na granici date oblasti. U tom pogledu, nesigurnost pozicioniranja može se tumačiti i kao potencijalno maksimalna vrednost greške pozicioniranja.

Ipak, i nakon što se definiše nesigurnost, ne može se garantovati da će u 100% slučajeva greška pozicioniranja biti manja od vrednosti nesigurnosti, odnosno da će se u 100% slučajeva korisnik naći unutar oblasti nesigurnosti. Zbog toga se parametar nesigurnosti najčešće razmatra zajedno sa stepenom pouzdanosti procene pozicije, pa se i performanse i zahtevi vezani za tačnost pozicioniranja predstavljaju njihovom kombinacijom.

Stepen pouzdanosti (*confidence level*) se obično izražava kao procenat ili verovatnoća. Vrednosti stepena pouzdanosti koje se najčešće koriste pri opisivanju tačnosti neke tehnike pozicioniranja su 10%, 33%, 50%, 67%, 90% i 95%. Ponekad se

parametar pouzdanosti takođe predstavlja i u vidu percentila (eng. *percentile*). Tako npr., 90th *percentile* DE predstavlja vrednost greške pozicioniranja koja nije premašena u 90% slučajeva. Ako bi za slučaj neke metode pozicioniranja ta vrednost iznosila npr. 300m, a procenjena oblast u kojoj se nalazi korisnik imala oblik kruga, onda bi se posmatrani primer mogao interpretirati na sledeći način: u 90% slučajeva, korisnik će se nalaziti unutar kruga poluprečnika 300m čiji se centar poklapa sa procenjenim koordinatama korisnika.

U literaturi, tačnost metoda pozicioniranja najčešće se analizira kroz srednju i medijansku vrednost greške pozicioniranja, kao i kroz funkcije gustine verovatnoće (*Probability Density Function*, PDF) i kumulativne funkcije raspodele (*Cumulative Distribution Function*, CDF) vrednosti greške pozicioniranja [2]. Pri tom, CDF funkcija se češće koristi nego PDF. Šta više, korišćenje CDF funkcije je sveobuhvatnije nego korišćenje kombinacije parametara nesigurnost/pouzdanost iz razloga što se tačnost neke metode pozicioniranja može proceniti sa grafika CDF funkcije za bilo koje vrednosti parametara nesigurnosti i pouzdanosti.

2.1.2. OSTALI PARAMETRI ZA OCENU PERFORMANSI METODA POZICIONIRANJA

Dostupnost i konzistencija

Dostupnost (*availability*) metode pozicioniranja ukazuje na to koliko je neka tehnika pozicioniranja dostupna u različitim tipovima okruženja (npr. ruralnom, izrazito urbanom, *indoor*, itd). Većina aplikacija koje se zasnivaju na poznavanju pozicije korisnika zahtevaju da primenjena metoda pozicioniranja bude dostupna nezavisno od tipa okruženja u kome se korisnik nalazi. Ipak, mnoge metode za pozicioniranje ne ispunjavaju ovaj uslov. Tako npr, GPS sistem, koji i dalje predstavlja najčešće korišćen sistem za pozicioniranje u *outdoor* okruženjima, nije dostupan u *indoor* okruženjima, kao i u izrazito urbanizovanim sredinama, tzv. gradskim kanjonima.

Dodatno, čest je slučaj da tačnost neke metode pozicioniranja zavisi od tipa okruženja u kome se ona primanjuje. Iz datog razloga razmatra se i konzistentnost metode, kao mera stabilnosti tačnosti metode pozicioniranja u različitim okruženjima.

Kašnjenje

Informacija o lokaciji mobilnog korisnika/terminala ima smisla samo ako je dobijena u nekom vremenskom intervalu koji je prihvatljiv za realizaciju konkretnog LBS servisa. Parametar kašnjenja definiše vremenski interval od pojave zahteva za određivanjem pozicije mobilnog terminala do dostavljanja njegovih procenjenih prostornih koordinata. Kod većine metoda pozicioniranja kašnjenje iznosi nekoliko sekundi.

Priraštaj opterećenja i energetska efikasnost

Primena neke metode za pozicioniranje dovodi do određenog priraštaja opterećenja kako mreže, tako i mobilnog terminala. Opterećenje se može ugrubo podeliti na signalizaciono i računarsko.

Priraštaj signalizacionog opterećenja je posledica razmene većeg broja signalizacionih (kontrolnih) poruka između mobilnog terminala i mreže, kao i između odgovarajućih elemenata u okviru mreže, u cilju upravljanja procesom pozicioniranja. Potrebno je naglasiti da primena velikog broja metoda za pozicioniranje zahteva određene izmene u postojećim signalizacijama (zavisno od tipa mreže). Dodatno, povećanje broja kontrolnih poruka utiče na smanjenje kapaciteta mreže.

Priraštaj računarskog opterećenja odnosi se na procenat procesorskog vremena koje se troši za potrebe proračuna lokacije mobilnog korisnika/terminala i rad sa bazama podataka, kao i na zahteve po pitanju memorijskih resursa.

Pod energetsom efikašnošću obično se podrazumeva priraštaj energetskog opterećenja mobilnog terminala, tj. potrošnja baterije mobilnog terminala izazvana potrebama postupka pozicioniranja. Najčešće je u korelaciji sa računarskom i signalizacionom opterećenjem, ali u pojedinim slučajevima i sa dodavanjem dodatnih primopredajnika mobilnom terminalu (npr. dodavanje GPS prijemnika za potrebe pozicioniranja).

Kompleksnost, skalabilnost i cena implementacije

Skalabilnost sistema za pozicioniranje predstavlja sposobnost sistema da se lako prilagodi budućim proširenjima, koja mogu biti u vidu pokrivanja (dostupnosti), učestalosti i ukupnog broja zahteva za pozicioniranje, nadogradnje mreže, itd. S druge strane, pod kompleksnošću se najčešće podrazumeva složenost postupka postavljanja (implementiranja) nekog sistema za pozicioniranje. Obe karakteristike utiču na cenu implementacije nekog sistema za pozicioniranje.

Cena implementacije može se okarakterisati kao odnos između troškova implementacije nekog sistema za pozicioniranje i benefita koji ona donosi kroz realizaciju niza LBS servisa. U troškove implementacije ubrajaju se troškovi na strani korisnika (hardverske/softverske izmene mobilnog terminala u cilju podrške LBS servisa), troškovi na strani mreže (dodavanje novih elemenata postojećoj arhitekturi, kreiranje potrebnih baza podataka, instalacija novih procesora, izmena signalizacije, itd), troškovi održavanja i planirani troškovi budućih proširenja sistema. Ipak pored troškova implementacije u formiranju ukupne cene veliku ulogu ima i povratak investicije, tj. budući profit koji donosi implementacija takvog sistema.

2.1.3. ZAHTEVI REGULATORNIH TELA

Kao što je već pomenuto, osnovna ideja o pozicioniranju mobilnih korisnika u radio sistemima nastala je iz potrebe da se korisnicima bežičnih mreža omogući servis hitnog poziva:

- E911 servis- na teritoriji Sjedinjenih Američkih Država (SAD) [3-6].
- E112 servis – na teritoriji Evropske Unije (EU) [7-9].

U skladu sa tim, Federalna komisija za komunikacije u SAD (*Federal Communication Commission, FCC*) i Evropska komisija (*European Commission, EC*) definisale su bezbednosne mere u pogledu zahtevane tačnosti estimacije pozicije i vremena dostavljanja te informacije nadležnom centru (*Public Safety Answering Point, PSAP*), koje mobilni operatori moraju da pruže svojim korisnicima. Takođe, definisani su i vremenski rokovi u okviru kojih mobilni operatori moraju da ispune zadate uslove.

Zahtevi po pitanju tačnosti pozicioniranja mobilnih korisnika na teritoriji SAD

Uslovi definisani od strane Federalne komisije za komunikacije u SAD, koje bi mobilni operatori trebalo da ispune u cilju podrške servisa hitnog poziva E911, definisani su, ali i menjani kroz nekoliko faza.

Faza I standardizacije servisa E911 počela je 1998. godine. Tada su definisani zahtevi da, u slučaju hitnog poziva, mobilni operatori moraju da izvrše identifikaciju broja mobilne stanice sa koje je upućen hitan poziv, kao i ćelije (bazne stanice) koja trenutno opslužuje datu mobilnu stanicu, i da dostavi date podatke PSAP centru u roku od 6 minuta.

Faza II razvoja E911 servisa počela je 2001. godine sa sledećim uslovima:

- U slučaju *network-based* metoda pozicioniranja (proračun koordinata korisnika vrši se na strani mreže), zahtevano je da greška pozicioniranja bude manja od 100m u 67% slučajeva (100m|67%), odnosno 300m u 95% slučajeva (300m|95%).
- U slučaju *mobile-based* metoda pozicioniranja (mobilni terminal vrši proračun prostornih koordinata), zahtevano je da greška pozicioniranja bude manja od 50m u 67% slučajeva (50m|67%), odnosno 150m u 95% slučajeva (150m|95%).
- Mobilni operatori moraju da obezbede koordinate korisnika u roku od 6 minuta od slanja zahteva.

Rok za ispunjenje ovih uslova bio je septembar 2012. godine, međutim većina operatora u SAD nije bila u stanju da ostvari FCC zahteve u predviđenom roku.

U septembru 2010. godine uslovi su relaksirani [4]:

- U slučaju *network-based* metoda pozicioniranja, zahtevano je da greška pozicioniranja bude manja od 100m u 67% slučajeva (100m|67%), odnosno 300m u 90% slučajeva (300m|90%).

- U slučaju *mobile-based* metoda pozicioniranja, zahtevano je da greška pozicioniranja bude manja od 50m u 67% slučajeva (50m|67%), odnosno 150m u 90% slučajeva (150m|90%).

U julu 2011, FCC postavlja novi zahtev po kome je predviđeno da do 2019. godine *mobile-based* i *network-based* dostignu isti standard po pitanju tačnosti (tj. strožije uslove).

Tabela 2.1. Zahtevana tačnost pozicioniranja, FCC [4]

Tip metode	67%	90%
<i>Mobile-based</i>	50 m	150 m
<i>Network-based</i>	100 m	300 m

Prethodno definisani zahtevi po pitanju tačnosti ne prave razliku između tipa okruženja, tj. da li se korisnik nalazi u *indoor* ili *outdoor* okruženju. Dodatni zahtevi, koji se odnose na određivanje pozicije korisnika u *indoor* okruženju definisani su u februaru 2014. godine [5], a dopunjeni 2015. godine [6]:

- Mobilni operatori treba da omoguće određivanje horizontalne pozicije mobilnog korisnika (x i y koordinata) sa greškom manjom od 50m u 50% slučajeva do 2018. godine, odnosno u 80% slučajeva do 2021. godine.
- Mobilni operatori treba da omoguće određivanje vertikalne pozicije mobilnog korisnika (z koordinata) sa greškom manjom od 3m u 50% slučajeva do 2018. godine, odnosno u 80% slučajeva do 2021. godine.
- Mobilni operatori moraju da obezbede koordinate korisnika u roku od 30 sekundi od slanja zahteva.

Tabela 2.2. Zahtevana tačnost pozicioniranja u *indoor* okruženju, FCC [5,6]

<i>Indoor</i> okruženje	50% (2018 godina)	80% (2021 godina)
Horizontalna pozicija (x, y)	50 m	50 m
Vertikalna pozicija (z)	3 m	3 m

Zahtevi po pitanju tačnosti pozicioniranja mobilnih korisnika na teritoriji EU

Za razliku od uniformisanih zahteva definisanih za teritoriju SAD od strane FCC, na nivou Evropske Unije još nisu usvojeni jedinstveni zahtevi po pitanju realizacije servisa hitnog poziva E112.

Realizacija programa uvođenja E112 servisa počela je 2000. godine od strane Evropske komisije (EC). Radna grupa CGALIES (*Coordination Group on Access to Location Information by Emergency Services*) je u izveštaju 2002. godine [7] dala predlog zahteva po pitanju tačnosti određivanja pozicije mobilnog korisnika (tabela 2.3). Pri tom, informacija o lokaciji korisnika mora biti dostupna najkasnije 30s od trenutka poziva. Dodato, gruba lokacija korisnika, tačnosti od oko 300m za sve tipove okruženja, trebala bi biti dostupna već 7s od trenutka poziva.

Međutim, jedinstveni zahtevi na nivou Evropske unije nisu usvojeni [8,9].

Zbog prethodno navedenih razloga, većina istraživanja se oslanja na zahteve postavljene od strane FCC komisije.

Tabela 2.3. Zahtevane tačnost pozicioniranja, E112 (CGALIES [7])

	<i>Indoor</i>	Urbano	Suburbano	Ruralno	Auto-put
Sa grubom procenom lokacije od strane korisnika	10 - 50 m	25 - 150 m	50 - 500 m	100 - 500 m	100 - 500 m
Bez procene lokacije od strane korisnika	10 - 50 m	10 - 150 m	10 - 500 m	10 - 500 m	10 - 500 m

2.2.PARAMETRI RADIO SIGNALA ZA POZICIONIRANJE U RADIO SISTEMIMA

Određivanje pozicije mobilnog korisnika (objekta) korišćenjem infrastrukture nekog radio sistema može se vršiti merenjem ugla nailaska signala ili merenjem rastojanja u odnosu na referentne tačke čije su koordinate poznate (npr. sateliti, bazne

stanice, *access points* (AP), itd). Pri tom, merenje rastojanja vrši se indirektno, merenjem nivoa radio signala na prijemu ili vremena propagacije radio signala.

Parametri radio signala koji se koriste pri estimaciji prostornih koordinata su:

- 1) nivo signala na prijemu (*Received Signal Strength, RSS*),
- 2) vreme prispeća signala (*Time Of Arrival, TOA*),
- 3) razlika u vremenu prispeća signala (*Time Difference Of Arrival, TDOA*),
- 4) ugao (pravac) nailaska signala (*Angle Of Arrival, AOA*).

Nivo signala na prijemu (RSS parametar)

Nivo signala na prijemu određen je propagacionim slabljenjem koje je funkcija rastojanja između predajnika i prijemnika (Tx-Rx rastojanje).


U slučaju propagacije signala kroz tzv. slobodan prostor, tj. prostor u kome je prva Frenelova zona slobodna od prepreka, veza između snage signala na prijemu i Tx-Rx rastojanja (rastojanja d) može se opisati jednostavnom relacijom [10]:

$$P_R(d) = P_T G_T G_R \left(\frac{\lambda}{4\pi d} \right)^2, \quad (2.1)$$

gde P_T predstavlja snagu na ulazu u antenu predajnika, G_T i G_R pojačanje antene predajnika i prijemnika, respektivno, a λ talasnu dužinu radio talasa.

Međutim, u realnim okruženjima propagacija radio talasa ne može se opisati jednostavnim mehanizmom, već predstavlja složenu kombinaciju niza propagacionih efekata poput refleksije radio talasa o različite površine, transmisije talasa kroz delimično transparentne prepreke, difrakcije o ivice prepreka, rasejanja, itd. U situacijama kada između predajnika i prijemnika ne postoji direktna optička vidljivost (*Line of Site, LOS*), signal na prijemu formiraju komponente koje su do tačke prijema stigle preko prethodno navedenih mehanizama prostiranja. Iz datog razloga signal na prijemu je nestabilan, kako u vremenu, tako i u odnosu na male, lokalne pomeraje prijemnika (i/ili predajnika). U pojedinim slučajevima, prostorni pomeraj reda dela talasne dužine može uzrokovati promenu nivoa signala na prijemu i do 30dB [10]. Navedene nestabilnosti nivoa signala na prijemu poznate su kao kratkotrajni (*short-*

term) fading [10]. Kako je on uzrokovan propagacijom radio talasa po višestrukim putanjama, često se u literaturi označava kao *multipath* fading. S druge strane, lokalna srednja vrednost nivoa signala varira sporije u odnosu na promenu položaja. Date varijacije zavise od opštih karakteristika propagacionog okruženja, poput Tx-Rx rastojanja, zaklonjenosti prijemnika preprekom, itd. Prethodno opisan efekat predstavlja dugotrajan (*long-term*) fading [10].



Slika 2.1. Ilustracija različitih propagacionih efekata i *multipath* propagacije

Zbog prethodno opisanih efekata do sad su razvijeni raznovrsni (složeni) matematički modeli za opis propagacije radio talasa kroz različite sredine, tj. za potrebe određivanja propagacionog slabljenja u određenim tipovima okruženja. Međutim, kako je *multipath* fading gotovo nemoguće egzatno predvideti, svi propagacioni modeli vrše estimaciju lokalne srednje ili medijanske vrednosti nivoa signala na prijemu. Drugim rečima, slaba tačka korišćenja RSS parametra za potrebe pozicioniranja jeste njegova osetljivost na *multipath* fading. Međutim, i pored određene osetljivosti na *multipath* fading, korišćenje RSS parametra za potrebe pozicioniranja ne zahteva postojanje direktne optičke vidljivosti između predajnika i prijemnika. To RSS parametru daje značajnu prednost u odnosu na TOA, TDOA i AOA parametre i čini ga najčešće korišćenim parametrom radio signala pri pozicioniranju u *indoor* i *outdoor* urbanim/suburbanim okruženjima. Dodatno, u slučaju *indoor* pozicioniranja, alternativna varijanta sa merenjem vremena bila bi problematična zbog zahtevane visoke rezolucije merenja vremena usled malih rastojanja.

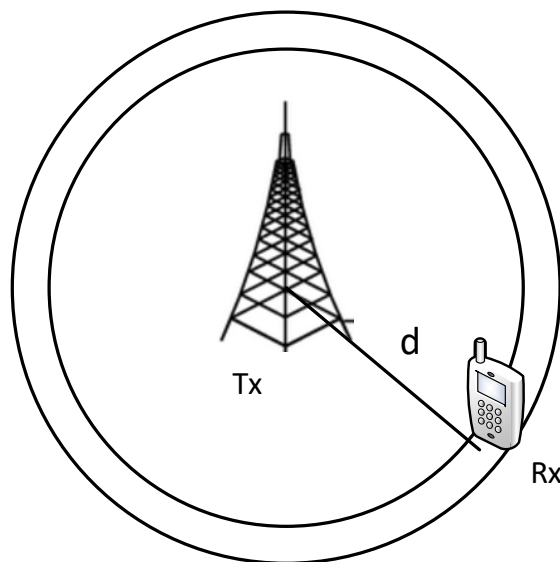
Vreme prispeća signala (TOA parametar)

TOA parametar predstavlja vreme prispeća signala do prijemnika R_x , emitovanog od strane predajnika T_x , odnosno vremenski trenutak koji na svom časovniku (*internal clock*) registruje prijemnik u trenutku prispeća signala.

Kod datog pristupa, rastojanje između predajnika i prijemnika može se proceniti merenjem vremena propagacije radio signala između datih tačaka, na osnovu poznate brzine propagacije signala (koja odgovara brzini svetlosti c u slobodnom prostoru). Da bi se na osnovu TOA parametra odredilo vreme propagacije, neophodno je da signal u sebi nosi informaciju o trenutku emitovanja od strane predajnika (t_{Tx}) - *timestamp*. Problem ovakvog pristupa jeste što trenutak emitovanja signala meri predajnik, svojim časovnikom, pa je neophodno uzeti u obzir vremenski *offset* u sinhronizaciji časovnika predajnika i prijemnika (ϵ_{sync}). Rastojanje između predajnika i prijemnika može se prikazati sledećom relacijom:

$$d = c(TOA - t_{Tx} - \epsilon_{sync}) \quad (2.2)$$

U prostoru, geometrijsko mesto tačaka istog TOA je kružnica poluprečnika d sa centrom u poziciji predajnika (u realnosti je prsten).



Slika 2.2. Ilustracija TOA pristupa

Kako je određivanje parametra ϵ_{sync} na nivou cele mreže praktično nemoguće, primena TOA metoda zahteva da mreža bude sinhronizovana (sinhronizacija svih

predajnika i prijemnika). Dati zahtev predstavlja i najveći nedostatak ovog pristupa jer većina mreža ne ispunjava navedeni uslov. Ova ograničenja se mogu prevazići merenjem *round-trip-time* (RTT) vrednosti, odnosno merenjem vremena koje protekne između slanja signala i primanja nazad tog istog signala (pod uslovom da je poznato vreme koje je potrebno prijemnoj strani da procesira signal i pošalje ga nazad).

Dodatni nedostatak TOA metode jeste velika osetljivost na uslove propagacije bez direktne optičke vidljivosti (*Non Line of Site*, NLOS, uslove propagacije), jer u datom slučaju vreme propagacije signala ne odražava stvarno rastojanje između predajnika i prijemnika. To čini upotrebu TOA parametra nepraktičnom u velikom broju realnih okruženja.

Razlika u vremenu prispeća signala (TDOA parametar)

TDOA parametar predstavlja razliku u vremenu prispeća signala na:

- 1) *downlink* smeru, tj. od prostorno odvojenih referentnih predajnika (npr. baznih stanica) do prijemnika mobilnog terminala;
- 2) *uplink* smeru, tj. od predajnika mobilnog terminala do više prostorno odvojenih referentnih prijemnika, npr. baznih stanica, LMU jedinica (*Location Measurement Unit*), itd.

Za slučaj primera merenja razlike u vremenu prispeća signala na *downlink* smeru, vrednost parametra TDOA predstavlja razliku TOA parametara, tj. vremena prispeća signala sa predajnika Tx_1 i Tx_2 , koje meri neki mobilni uređaj:

$$TDOA = TOA_1 - TOA_2 \quad (2.3)$$

Na osnovu izraza 2.2, vrednost parametra TOA se može predstaviti kao:


$$TOA = t_{Tx} + \varepsilon_{sync} + \frac{d}{c} \quad (2.4)$$

Korišćenjem izraza 2.4, izraz 2.3 može se transformisati u:

$$TDOA = t_{Tx1} - t_{Tx2} + \frac{d1-d2}{c} \quad (2.5)$$

Za posmatrani primer na *downlink* smeru, geometrijsko mesto tačaka u prostoru iste vrednosti TDOA parametra je hiperbola (u realnosti, zona oblika hiperbole) u čijim

žičama se nalaze referentni predajnici (npr. bazne stanice u slučaju javnih mobilnih sistema).



Slika 2.3. Ilustracija TDOA pristupa na *downlink* smeru


Osnovna prednost TDOA pristupa u odnosu na TOA jeste što ne zahteva sinhronizaciju između predajnika i prijemnika. Međutim, mora biti ispunjen uslov sinhronizacije referentnih tačaka u mreži (u prethodno navedenom primeru referentnih predajnika), kako bi se iz jednačina mogao eliminisati vremenski *offset* u sinhronizaciji časovnika predajnika i prijemnika (ϵ_{sync}). Dodatni nedostatak korišćenja TDOA parametara jeste velika osetljivost na NLOS uslove propagacije, kao i u slučaju TOA.

Ugao nailaska signala (AOA parametar)

AOA parametar određuje se primenom antenskih nizova koji mogu da detektuju ugao pod kojim dolazi signal maksimalne snage (ili koherentne faze), u odnosu na neki referentni pravac (slika 2.4). U prostoru, geometrijsko mesto tačaka istog AOA je ugao u odnosu na referentni pravac (u realnosti, zona u kojoj se nalazi mobilni terminal).

Kako je za merenje AOA parametara neophodno korišćenje antenskih nizova (visoke rezolucije), kao i primena specijalizovanih prijemnika, cena implementacije tehnika pozicioniranja koje koriste ovaj parametar je dosta visoka. Dodatno, precizno određivanje vrednosti AOA parametra zahteva LOS uslove propagacije, pa korišćenje

ovog parametra u pozicioniranju može pružiti adekvatnu tačnost samo u malom broju realnih situacija. Iz prethodno navedenih razloga, korišćenje AOA parametra je retko razmatran pravac pri razvoju tehnika za pozicioniranje.



Slika 2.4. Ilustracija AOA pristupa

2.3.OPŠTE PODELE TEHNIKA ZA POZICIONIRANJE

Postoje više načina klasifikacije postojećih metoda pozicioniranja u radio sistemima. Neke od najčešćih su podele prema:

- 1) tipu korišćene infrastrukture,
- 2) algoritmu za određivanje lokacije.

U nastavku poglavlja biće dat pregled osnovnih podela metoda pozicioniranja.

2.3.1. PODELA METODA POZICIONIRANJA PREMA TIPU KORIŠĆENE INFRASTRUKTURE

Postoji nekoliko načina klasifikacije metoda pozicioniranja prema tipu korišćene infrastrukture:

- podela na integrisane i samostalne metode,
- podela na *network-based*, *mobile-based* i hibridne metode,

- podela prema konkretnom tipu radio sistema čija se infrastruktura koristi (satelitski sistemi, javne mobilne mreže, WLAN (*Wireless Local Area Network*) mreže, itd).

Podela na integrisane i samostalne metode

Integrisane metode pozicioniranja koriste infrastrukturu radio mreža čija primarna funkcija nije pozicioniranje. Tipičan primer su metode koje koriste infrastrukturu ćelijskih sistema, tj. javnih mobilnih sistema (*Public Land Mobile Networks*, PLMN) poput GSM, DCS, UMTS i LTE. Prednost integrisanih metoda jeste u tome što koriste postojeću infrastrukturu (uz određene modifikacije i nadogradnje), čime se smanjuje cena implementacije. Međutim, negativan aspekt ovih metoda jeste povećanje opterećenja mreže uvođenjem servisa pozicioniranja.

S druge strane, samostalne metode koriste infrastrukturu koja je u potpunosti nezavisna od komunikacione mreže u kojoj se korisnik, čija se pozicija određuje, nalazi. Tipičan primer je GPS, ali i pojedini *indoor* sistemi pozicioniranja. Nedostatak ovih metoda jeste cena implementacije koja se ogleda u postavljanju nove infrastrukture za potrebe pozicioniranja, modifikacije mobilnog terminala radi podrške servisa pozicioniranja (ili potreba za novim, posebnim uređajem), kao i realizacija mehanizama za razmenu podataka između komunikacione mreže i nezavisne mreže za pozicioniranje.

Podela na network-based, mobile-based i hibridne metode

Network-based metode pozicioniranja su metode gde sva neophodna merenja, kao i sam proračun pozicije mobilnog terminala vrši mreža. S druge strane, kod *mobile-based* metoda, sva neophodna merenja vrši mobilni terminal i na osnovu njih samostalno proračunava svoju poziciju. Dodatno, postoje i hibridna rešenja. U slučaju da sva neophodna merenja vrši mobilni terminal, a da date podatke šalje nazad ka mreži gde se potom vrši proračun njegove pozicije, metod pozicioniranja se karakteriše kao *mobile-assisted-network-based*. Obrnuti slučaj, da mreža vrši sva neophodna merenja koja prosleđuje mobilnom terminalu radi procene pozicije, predstavlja *network-assisted-mobile-based* pristup. Ipak dati pristup se retko primenjuje u praksi.

Najčešće se prednost daje *network-based* metodama jer potencijalno ne moraju zahtevati nikakve izmene na strani mobilnog terminala, ili *mobile-assisted-network-based* metodama koje se u pojedinim slučajevima mogu realizovati sa zanemarljivim izmenama na strani korisničkog terminala.

Podela prema konkretnom tipu radio sistema čija se infrastruktura koristi

U zavisnosti od tipa radio sistema čija se infrastruktura koristiti za potrebe pozicioniranja, metode pozicioniranja mogu se podeliti na satelitske, ćelijske (javni mobilni sistemi), WLAN, UWB (*Ultra Wide Band*), RFID, *Bluetooth*, itd. Odabir određenog tipa radio sistema za potrebe pozicioniranja u velikoj meri zavisi od tipa okruženja u kome je potrebno omogućiti LBS servise, a prvenstveno od toga da li se radi o *outdoor* ili *indoor* okruženju.

Tako na primer, satelitske metode, među kojima je najpoznatiji sistem za globalno pozicioniranje, GPS, imaju veliku primenu u *outdoor* okruženjima gde mogu postići zavidnu tačnost. Međutim, kao što je i ranije pomenuto, date metode imaju jako loše performanse u visoko urbanizovanim sredinama (gradskim kanjonima) usled efekta senki i *multipath* propagacije, kao i u tunelima i *indoor* okruženjima usled izrazito niskih nivoa signala sa satelita, što ih u navedenim okruženjima čini neupotrebljivim. S druge strane, korišćenje radio sistema srednjeg i kratkog dometa (WLAN, UWB, RFID, *Bluetooth*, senzorske mreže, itd.) karakteristično je za metode namenjene pozicioniranju korisnika u zatvorenim prostorima, koji po pravilu predstavljaju zone manjih površina.

Kao što se može primetiti, većina razmatranih radio sistema nema infrastrukturu koja može da obezbedi istovremeno pozicioniranje i u *outdoor* i *indoor* okruženjima. Izuzetak predstavljaju danas široko rasprostranjeni ćelijski sistemi, tj. javni mobilne mreže, koji imaju adekvatno pokrivanje radio signalom u oba tipa okruženja. Data osobina ćelijskih sistema ujedno predstavlja i glavni motiv za korišćenje njihove infrastrukture pri razvoju nove metode pozicioniranja u okviru ovog istraživanja.

2.3.2. PODELA METODA POZICIONIRANJA PREMA KORIŠĆENOM ALGORITMU

U zavisnosti od algoritma koji se koristi pri proračunu koordinata mobilnog korisnika (objekta) na osnovu nekog od merenih parametara radio signala, metode pozicioniranja mogu se podeliti na:

- 1) blizinsko lociranje (*proximity sensing*),
- 2) determinističke (geometrijske) metode,
- 3) probabilističke metode,
- 4) *fingerprinting* metode.

Pored prethodno navedenih metoda, postoje i hibridna rešenja, koja predstavljaju kombinaciju dva ili više navedena pristupa.

Blizinsko lociranje (proximity sensing)

Blizinsko lociranje je metod pozicioniranja kojim se detektuje predajnik u mreži (npr. bazna stanica, AP, itd.) na koji je povezan mobilni terminal, a čije su koordinate poznate. U datom slučaju, estimirane prostorne koordinate korisnika odgovaraju poziciji referentnog predajnika. Navedeni metod predstavlja najjednostavnije rešenje sa stanovišta implementacije, jer u većini mreža (ćelijske, WLAN) ne zahteva nikakve modifikacije ni na strani mreže ni mobilnog terminala. Međutim, veliko ograničenje ovog pristupa jeste tačnost, koja direktno zavisi od veličine zone pokrivanja referentnog predajnika (servisne ćelije, AP). Tako npr. u slučaju ćelijskih sistema, u zavisnosti od tipa okruženja, poluprečnik jedne ćelije može se kretati od svega par metara (femto ćelije u *indoor* okruženjima) do desetina kilometara (makro ćelije u ruralnim okruženjima).

Determinističke (geometrijske) metode


Determinističke metode zasnivaju se na primeni geometrijskih principa prilikom određivanja pozicije mobilnog terminala na osnovu poznatih prostornih koordinata referentnih primopredajnika u mreži (npr. baznih stanica) i informacija o

rastojanjima/uglovima, dobijenih na osnovu merenih parametara radio signala. Pri tom, podaci o uglu ili rastojanju od referentnog primopredajnika tretiraju se kao poznati (određeni), odnosno nesigurnost tj. probabilistička priroda datih podataka se zanemaruje.

Deterministički modeli se mogu klasifikovati na angulaciju, cirkularnu lateraciju i hiperboličnu lateraciju.

Metod angulacije koristi se u slučaju određivanja pozicije mobilnog terminala na osnovu ugla nailaska signala (AOA parametra). Da bi se odredili uglovi između mobilnog terminala i referentnih primopredajnika poznatih koordinata (RP), neophodno je da bilo mobilni, bilo referentni primopredajnici budu opremljeni antenskim nizovima. Zbog kompleksnosti implementacije, ovaj metod se isključivo realizuje kao *network-based* rešenje, tj. antenski nizovi se postavljaju na strani referentnih primopredajnika (npr. bazne stanice).


Za određivanje pozicije mobilnog terminala u dvo-dimenzionom (2D) prostoru, potrebni su podaci o uglu nailaska signala koje izmere prijemnici barem dve RP. Pri tom, uglovi pod kojim nailaze signali sa mobilnog terminala uvek se mere u odnosu na istu osu za sve referentne prijemnike.



Slika 2.5. Angulacija

Cirkularna lateracija je metod koji se koristi kad je poznata informacija o rastojanju između mobilnog terminala i minimalno tri referentna primopredajnika (za slučaj 2D pozicioniranja), čije su koordinate poznate. Podatak o rastojanju proračunava se na osnovu izmerene vrednosti TOA parametra (izraz 2.2) ili RSS parametra (primenom nekog od propagacionih modela). Pozicija mobilnog terminala (x, y) određena je presekom 3 kružnice sa centrima u pozicijama referentnih primopredajnika i poluprečnicima koji odgovaraju procenjenim rastojanjima:

$$d_i = \sqrt{(x_i - x)^2 + (y_i - y)^2}, \quad i \geq 3. \quad (2.6)$$



Slika 2.6. Cirkularna lateracija


Kako u realnim situacijama rastojanje d_i dobijeno merenjem vremena ili snage (tj. nivoa) signala na prijemu nije u potpunosti tačno, već sadrži grešku usled nepotpune sinhronizacije (TOA) i višestruke propagacije (TOA, RSS), presek tri kružnice najčešće nije tačka nego zona određene površine (u zavisnosti od stepena tačnosti estimacije rastojanja).

Hiperbolična lateracija je metod koji se koristi kad je poznata informacija o razlici rastojanja između mobilnog terminala i barem tri referentna primopredajnika čije su koordinate poznate. Podatak o razlici rastojanja proračunava se na osnovu izmerene TDOA vrednosti (izraz 2.5).

Ako su d_i , odnosno d_k , poznata rastojanja između mobilnog terminala i i -tog, odnosno k -tog referentnog primopredajnika, onda razlika ta dva rastojanja $d_{i,k}$ ograničava moguće pozicije mobilnog terminala na hiperbolu, u čijim se žižama nalaze referentni primopredajnici i i k . Data hiperbola je definisana skupom tačaka za koje je razlika rastojanja od dve fiksne tačke konstantna:

$$d_{i,k} = d_i - d_k = \sqrt{(x_i - x)^2 + (y_i - y)^2} - \sqrt{(x_k - x)^2 + (y_k - y)^2} = \text{const.} \quad (2.7)$$

U datom slučaju, pozicija mobilnog terminala jednoznačno je određena presekom minimalno 2 hiperbole (slika 2.7). Međutim, kao i kod cirkularne lateracije, merenja razlika rastojanja nisu imuna na greške, pa u realnosti presek hiperbola nikad nije tačka već zona određene površine.



Slika 2.7. Hiperbolična lateracija

Probabilističke metode

Svi parametri radio signala koji se mogu koristiti za određivanje rastojanja (RSS, TOA, TDOA) ili ugla (AOA) pokazuju određeni nivo osetljivost na višestruku propagaciju, odnosno NLOS uslove prostiranja. Dodatno, sva merenja koja se vrše u

cilju procene rastojanja/ugla imaju određeni stepen neodređenosti. Problemi koji iz datih razloga mogu nastati prilikom primene determinističkih metoda su pojava višestrukih rešenja ili izostanak bilo kakvog rešenja.

Probabilističke metode pozicioniranja su pogodne u situacijama kada je tačnost ulaznih podataka loša. Za razliku od determinističkih, probabilističke metode pozicioniranja baziraju se na probabilističkim modelima kojima se opisuje zavisnost karakteristika signala koje prima mobilni terminal od njegove pozicije. Probabilističke metode tretiraju ulazne podatke o poziciji mobilnog terminala kao prostorne funkcije gustine verovatnoće i vrše združivanje funkcija gustine verovatnoće dobijenih iz različitih izvora informacija, u cilju dobijanja što je moguće tačnije informacije o poziciji mobilnog terminala. Negativan aspekt probabilističkih metoda jeste činjenica da su kompleksni i proračunski dosta zahtevniji u odnosu na druge metode, zbog čega nisu popularizovani u dosadašnjim istraživanjima.

Fingerprinting metode

Fingerprinting metode se zasnivaju na formiranju baze tzv. otiska (eng. *fingerprint*), koji predstavljaju vektore parametara radio signala izmerenih na određenim lokacijama (referentnim tačkama) u geografskoj zoni od interesa. U *fingerprint* bazi, svakom otisku pridružene su i prostorne koordinate tačke u kojoj je formiran dati vektor, tj. otisak. U većini dosadašnjih istraživanja koja se odnose na primenu nekog *fingerprinting* metoda, otisak lokacije se formira na osnovu izmerenih vrednosti RSS parametara. Međutim, u određenom broju istraživanja korišćeni su i TOA i TDOA parametar.

Osnovna ideja *fingerprinting* metoda jeste da se na osnovu izmerenih parametara radio signala na nepoznatoj lokaciji mobilnog korisnika formira *fingerprint*, koji se potom, korišćenjem odgovarajućeg algoritma, „poređi“ sa postojećim *fingerprint*-ima iz baze podataka.

Jedan od najjednostavnijih i često korišćenih algoritama za estimaciju nepoznate pozicije korišćenjem postojeće baze *fingerprint*-a jeste metod k najbližih suseda (k *Nearest Neighbours*, kNN) [11,12]. *Fingerprinting* metode zasnovane na kNN algoritmu pronalaze k otisaka iz baze koji su najbliži (tj. najsljedniji) otisku formiranom na

nepoznatoj lokaciji mobilnog terminala. Najčešće se stepen sličnosti (tj. „blizine“) dva otiska određuje na osnovu Euklidskog rastojanja između posmatrana dva vektora. Koordinate nepoznate lokacije određuju se na osnovu koordinata odabranih k najbližih suseda, kao njihova aritmetička sredina ili ponderisana aritmetička sredina (*weighted kNN* algoritam, WkNN [13]).

Pored kNN (WkNN) metode, zbog korišćenja baze *fingerprint-a*, u ove metode mogu se svrstati i tehnike pozicioniranja koje koriste algoritme mašinskog učenja i veštačke inteligencije, kakve su veštačke neuralne mreže (*Artificial Neural Networks*, ANN) [14] i *Support Vector Machines* (SVM) [15,16]. Pomenuti algoritmi imaju sposobnost pronalaženja (učenja) relacija koje postoje u skupovima podataka, odnosno pronalaženja modela u podacima (eng. *pattern recognition* algoritmi). Navedeni algoritmi koriste podatke iz *fingerprint* baze kako bi naučili (modelovali) relaciju koja postoji između izmerenih parametara radio signala (najčešće nivoa signala na prijemu) i prostornih koordinata u nekoj geografskoj oblasti. Naučena relacija (model) se potom koristiti za estimaciju nepoznatih koordinata korisnika, na osnovu parametara radio signala izmerenih na njegovoj trenutnoj lokaciji.

U opštem slučaju, primena *fingerprinting* metoda sastoji se iz dve faze: *offline* i *online*. *Offline* faza je pripremna faza koja podrazumeva proces formiranja baze *fingerprint-a*. Baza *fingerprint-a* može se kreirati korišćenjem podataka prikupljenim mernim kampanjama na terenu ili simulacijom, tj. korišćenjem nekog od modela za predikciju nivoa polja u okruženju od interesa. Osnovna prednost korišćenja baza sa otiscima formiranim merenjem u realnom okruženju jeste postizanje veće tačnosti pozicioniranja. S druge strane, merne kampanje su često vremenski zahtevne i naporne, pa mogu predstavljati negativan aspekt implementacije *fingerprinting* metoda. Međutim, nasuprot klasičnim metodama prikupljanja *fingerprint-a*, bilo manuelno ili u vidu *drive* testa (*car-driven*), u poslednje vreme se sve više promovišu tzv. *crowdsourcing* metode [17-19]. *Crowdsourcing* metode podrazumevaju da obični korisnici, koristeći svoje mobilne terminale, učestvuju u mernim kampanjama i formiranju *fingerprint* baza, bilo aktivno ili pasivno, čime se značajno može olakšati postupak formiranja, ali i ažuriranja *fingerprint* baza.

U slučaju korišćenja algoritama mašinskog učenja i veštačke inteligencije, *offline* faza dodatno obuhvata i proces učenja relacije između ulaznih i izlaznih podataka, odnosno formiranje (tj. treniranje) modela.

Nakon završene pripremne faze sledi *online* faza u kojoj sistem za pozicioniranje vrši estimaciju nepoznate pozicije mobilnog terminala na osnovu *fingerprint*-a formiranog na datoj lokaciji (najčešće izmerenih nivoa signala), korišćenjem nekog od prethodno navedenih algoritma.

Velika prednost korišćenja *fingerprinting* metoda jeste činjenica da navedeni pristup ne zahteva poznavanje propagacionih uslova u okruženju. Naime, usled složenih mehanizama propagacije koji postoje u gotovo svim realnim okruženjima, formiranje propagacionih modela predstavlja izuzetno težak zadatak, gde je uzimanje u obzir svih efekata gotovo nemoguće. Imajući to u vidu, najveći broj predloženih rešenja za pozicioniranje u sredinama sa NLOS uslovima propagacije, bazira se upravo na primeni *fingerprinting* metoda u kombinaciji sa RSS parametrima koji su manje osetljivi na NLOS propagaciju u odnosu TOA, TDOA i AOA. *Fingerprinting* metode predstavljaju dominantan pristup pozicioniranju u *indoor* okruženjima, a pokazale su i dobre performanse u urbanim i suburbanim *outdoor* okruženjima u slučaju korišćenja infrastrukture javnih mobilnih sistema.

2.4. OUTDOOR POZICIONIRANJE

Tehnike pozicioniranja namenjene upotrebi u *outdoor* okruženjima uglavnom se zasnivaju na korišćenju infrastrukture radio sistema koji mogu obezbediti globalno pokrivanje, kakvi su satelitski sistemi i javni mobilni sistemi (ćelijski sistemi). U skladu sa tim, može se izvršiti podela postojećih pristupa na satelitske i ćelijske tehnike pozicioniranja.

2.4.1. SATELITSKO POZICIONIRANJE

U nastavku poglavlja biće dat pregled metoda pozicioniranja koji se zasnivaju na korišćenju infrastrukture satelitskih sistema prilikom određivanja pozicije mobilnih

korisnika: GPS (*Global Positioning System*), GLONASS (*GLObal Navigation Satellite System*) i Galileo.

GPS (*Global Positioning System*)

GPS je operativni globalni navigacioni satelitski sistem (*Global Navigation Satellite System*, GNSS), kojim upravlja Ministarstvo odbrane SAD. Infrastruktura se sastoji od 24 satelita (21 aktivnih i 3 rezervna) raspoređenih u 6 MEO (*Medium Earth Orbit*) orbita, kao i 6 kontrolnih stanica na Zemlji, namenjenih nadgledanju i praćenju GPS satelita (5 monitoring stanica i 1 master kontrolna stanica, tzv. *Master Control Station*, u Kolorado Springsu).

Pozicioniranje korisnika koji raspolaže GPS prijemnikom vrši se na osnovu merenja rastojanja korisničkog GPS prijemnika od GPS satelita koji emituju signale proširenog spektra. Rastojanje se estimira na osnovu izmerenog TOA parametra signala sa satelita i primenom metode cirkularne lateracije. Metod zahteva da GPS prijemnik ima podatke o tačnoj poziciji satelita u trenutku kad je izvršeno merenje. Takođe neophodna je kompletna sinhronizacija između predajnika (satelita) i GPS prijemnika. Za kompenzaciju greške časovnika (vremenskog ofseta), u slučaju GPS sistema, primenjena je ideja da se osim promenljivih koje označavaju lokaciju GPS prijemnika (x, y, z) uvede i dodatna promenljiva – nepoznati vremenski ofset. Iz datog razloga, metod cirkularne lateracije zahteva TOA merenja od 4 satelita kako bi se odredila 3D pozicija GPS prijemnika i izvršila kompenzacija greške časovnika.

Tačnost pozicioniranja GPS sistema, ali i dostupnost sistema, zavisi u velikoj meri od tipa okruženja. Tačnost pozicioniranja se u proseku kreće od nekoliko metara do nekoliko desetina metara. Na osnovu eksperimentalnih podataka od oko 1000 učesnika iz 100 zemalja, koji su učestvovali u studiji iz 2014. godine [20], procenjena srednja greška pozicioniranja *smartphone*-a sa GPS prijemnikom iznosila je 4.9m, ali u slučaju *open-sky* okruženja, odnosno u situacijama kada postoji direktna optička vidljivost između satelita i GPS prijemnika. Problemi nastaju u urbanim okruženjima (tzv. gradskim kanjonima) ili ruralnim *outdoor* okruženjima sa gustom vegetacijom (npr. šume), u kojima nije moguće obezbediti LOS uslove sa dovoljnim brojem satelita. Dodatno, neizbežna pojava *multipath* propagacije u gradskim sredinama dovodi

do toga da npr. deo signala sa satelita dolazi direktnom a deo reflektovanom putanjom, usled čega može doći do greške u proceni vremena prispeća signala od satelita do GPS prijemnika. Ipak, najveći problem dostupnosti GPS sistema nastaje u *indoor* okruženjima, gde je zbog veoma niskih nivoa signala sa satelita pozicioniranje praktično nemoguće. U tom smislu, najveće ograničenje konvencionalnog GPS sistema za pozicioniranje jeste neraspoloživost ili velike greške pozicioniranja u *indoor* i urbanim *outdoor* okruženjima.

Drugo ograničenje GPS sistema za pozicioniranje može se javiti u domenu kašnjenja, odnosno potrebnog vremena za estimaciju pozicije mobilnog korisnika. Vrednost TTFF (*Time to First Fix*) parametra zavisi od početnih uslova proračuna pozicije, tj. tipa starta:

- *Cold start*: GPS prijemnik ne poseduje ikakve informacije o poslednjoj proračunatoj poziciji kao i *almanac* podatke. *Almanac* podatke čine zapravo *ephemeris* podaci za sve satelite (podaci na osnovu kojih GPS prijemnik na zemlji može izračunati tačnu poziciju satelita), kao i podaci o korekciji vremena za sve satelite. U slučaju *cold* starta vrednost TTFF se kreće između 2 min i 30 min.
- *Warm start*: GPS prijemniku su poznati podaci o poslednjoj poziciji, kao i *almanac* podaci, ali *ephemeris* podaci nisu više validni. U tom slučaju, vrednost TTFF se kreće između 30s i 40s.
- *Hot start*: GPS prijemniku su poznate sve neophodne informacije. U tom slučaju, vrednost TTFF se kreće između 5s i 10s.

Imajući u vidu FCC zahteve po pitanju LCS (*Location Services*), GPS u sadašnjem trenutku pokazuje vrlo ozbiljne nedostatke, kao što su:

- moguće veliko kašnjenje usled velike vrednosti TTFF,
- loša dostupnost, naročito u *indoor* okruženju,
- loša energetska efikasnost, odnosno, velika potrošnja baterije GPS prijemnika.

Jedno od unapređenja tačnosti GPS sistema poznato je pod nazivom *Differential GPS* (DGPS). DGPS koristi mrežu referentnih stanica na zemlji. Referentna stanica zna svoju tačnu poziciju i poredi je sa pozicijom estimiranom korišćenjem GPS sistema. Proračunata razlika u poziciji (korekcionni signal) emituje se *broadcast*-om i GPS prijemnici u okruženju referentne stanice koriste taj podatak da koriguju estimaciju svoje trenutne poziciju za istu tu vrednost.

Drugi vid unapređenja realizovan je kroz integraciju satelitskih i ćelijskih sistema, odnosno javnih mobilnih mreža, kroz tzv. *Assisted-GPS* (A-GPS). U datom slučaju, u okviru ćelijske mreže formira se referentna GPS mreža, na način da je uvek obezbeđena optička vidljivost prijemnika referentne mreže i satelita koji se u tom trenutku nalaze iznad tog dela zemljine kugle. Data mreža vrši kontinualno nadgledanje konstalacije satelita i obezbeđuje pomoćne podatke za pozicioniranje: grubu estimaciju pozicije mobilnog korisnika (najčešće pozicija servisne bazne stanice), vidljivost satelita, *ephemeris* podaci, *almanac*, podaci o korekciji vremena, itd. Kod A-GPS metode, mobilnom terminalu koji poseduje GPS prijemnik referentna mreža dostavlja pomoćne podatke što omogućava brz odziv i veću osetljivost prijemnika. Vreme akvizicije se time znatno smanjuje, a posledično i TTFF vreme, kao i potrošnja baterije mobilnog terminala (u poređenju sa konvencionalnim GPS prijemnikom integrisanim u mobilni terminal).

Dalji razvoj GPS sistema usmeren je na povećanje tačnosti i dostupnosti GPS sistema u NLOS okruženjima (urbana okruženja, *indoor*, itd.). Dodatno, planira se povećanje broja satelita, kao i smanjenje TTFF parametra sa budućom GPS infrastrukturom.

GLONASS

GLONASS predstavlja ruski globalni navigacioni satelitski sistem, koji je baziran na sličnom principu kao i GPS. Infrastruktura GLONASS sistema sastoji se od 24 operativna satelita raspoređenih u 3 MEO orbite. Kontrolni sistem na zemlji čine 12 stanica.

Prema ruskom sistemu za korekciju razlika i monitoring (*Russian System of Differential Correction and Monitoring*, SDCM), primenom GLONASS, u 95%

slučajeva, greške određivanja geografske širine i dužine kreću se od 4.5-7.5m, a nadmorske visine od 10-15m [21]. Civilni GLONASS pruža nešto manju tačnost od GPS sistema, osim u oblastima koje se nalaze na većim geografskim širinama usled bolje orbitalne pozicije GLONASS satelita.

Pojedini noviji prijemnici u mogućnosti su da koriste signale i GPS i GLONASS satelita. To im omogućava da koriste signale većeg broja satelita, u poređenju sa konvencionalnim GLONASS ili GPS prijemnikom, što naročito može biti korisno u urbanim kanjonima gde je vidljivost satelita narušena. Ipak, cene takvih terminala su dosta velike, što onemogućava njihovu masovnu primenu.

Galileo sistem pozicioniranja

Galileo je evropski globalni navigacioni satelitski sistem, razvijan od strane Evropske komisije (EC) i Evropske kosmičke agencije (*European Space Agency, ESA*). Galileo sistem je osmišljen kao nezavistan globalni sistem za pozicioniranje, koji bi bio pod upravom civilne vlasti i otvoren u potpunosti za javnost, za razliku od prvenstveno vojno-orijentisanih GPS i GLONASS sistema.

Do 2020. godine planirano je da satelitsku infrastrukturu Galileo sistema čine 30 satelita u 3 MEO orbite. Dva kontrolna centra na zemlji smeštena su u blizu Minhena (Nemačka) i u Fucinu (Italija).

Galileo je osmišljen kao sistem za pozicioniranje visoke tačnosti, sa planiranom tačnošću reda veličine 1m za obične korisnike (kao besplatan servis) i reda veličine 1cm za visokoprecizne servise koji će se naplaćivati ili biti dostupni samo u vojne svrhe. Takođe, planirano je da bude interoperabilan sa GPS i GLONASS sistemima.

2.4.2. STANDARDIZOVANE METODE ČELIJKOG POZICIONIRANJA

Metode pozicioniranja u ćelijskim sistemima nastale su prvenstveno iz potrebe mobilnih operatora da obezbede servis hitnog poziva (E112/E911). Metode ćelijskog pozicioniranja zasnivaju se na korišćenju infrastrukture javnih mobilnih sistema (*Public Land Mobile Networks, PLMN*): GSM (DCS), UMTS i/ili LTE. Kako se date metode

pozicioniranja oslanjaju na infrastrukture čiji primarni cilj nije pozicioniranje, već komunikacija, bilo je neophodno razviti posebne standarde, tzv. LCS standarde, kako bi se obezbedila implementacija servisa koji se baziraju na poznavanju lokacije korisnika (mobilnog uređaja) u ćelijskim radio sistemima.

Prema GSM LCS standardu [22], za GERAN (*GSM/EDGE Radio Access Network*) radio pristupnu mrežu su standardizovane četiri metode pozicioniranja:

- Cell-ID+TA (*Cell Identification + Timing Advance*),
- E-OTD (*Enhanced Observed Time Difference*),
- U-TDOA (*Uplink Time Difference of Arrival*) i
- A-GNSS (*Assisted Global Navigation Satellite System*).

Prema specifikaciji UMTS LCS standarda [23], za UTRAN (*UMTS Terrestrial Radio Access Network*) radio pristupnu mrežu su standardizovane četiri metode pozicioniranja:

- Cell-ID (*Cell Identification*),
- OTDOA-IPDL (*Observed Time Difference Of Arrival-Idle Period Downlink*),
- A-GNSS (*Assisted Global Navigation Satellite System*) i
- U-TDOA (*Uplink Time Difference of Arrival*).

Prema specifikaciji LTE LCS standarda [24], za E-UTRAN (*Evolved UTRAN*) radio pristupnu mrežu su standardizovane četiri metode pozicioniranja:

- *Enhanced* Cell-ID (E-CID),
- OTDOA (*Observed Time Difference Of Arrival*),
- A-GNSS (*Assisted Global Navigation Satellite System*) i
- U-TDOA (*Uplink Time Difference Of Arrival*).

Cell-ID metode u GSM/UMTS/LTE

Cell-ID metoda pozicioniranja zasniva se na *proximity sensing* principu, odnosno, na identifikaciji najbližeg predajnika poznatih koordinata. Po Cell-ID metodi, procenjene koordinate mobilne stanice su geografske koordinate bazne stanice sa koje se realizuje ćelija koja trenutno opslužuje tu mobilnu stanicu. Oblast u kojoj se korisnik nalazi je krug koji odgovara zoni pokrivanja servisne ćelije u slučaju omnidirekcionih baznih stanica, odnosno, kružni isečak koji odgovara zoni pokrivanja servisne ćelije u slučaju sektorskih baznih stanica.

Dobre osobine Cell-ID metode su visoka dostupnost, malo kašnjenje i mali priraštaj opterećenja. Negativna osobina ovog pristupa je loša tačnost. Na tačnost Cell-ID metode utiče tačnost podataka u bazi geografskih koordinata baznih stanica nekog operatora, tip bazne stanice (omnidirekciona/sektorska) i veličina servisne ćelije. Ipak, najveći uticaj na tačnost ove metode ima veličina servisne ćelije koja zavisi prvenstveno od tipa okruženja. Veličina makro ćelija kreće se od par kilometara u visoko urbanizovanim sredinama do par desetina kilometara u ruralnim sredinama (teorijski za GSM sistem do 35km). Dodatno, u urbanim okruženjima implementiraju se i manje ćelije: mikro (od nekoliko stotina metara do 1-2 km), pico (od nekoliko desetina do 100-200 metara) i femto (oko 10-20m). Drugim rečima, tačnost metode zavisi u velikoj meri od tipa okruženja, odnosno nije konzistentna. Dodatno, servisna bazna stanica (ćelija) ne mora uvek biti i najbliža mobilnom terminalu. Datu pojavu mogu izazvati standardne procedure u ćelijskim sistemima, poput procedura za sprečavanje „ping-pong“ efekta tj. učestalog *handover*-a (prebacivanja) mobilne stanice sa jedne na drugu bazne stanice, procedura za upravljanje saobraćajnim opterećenjem (*load balancing*), itd.

Poboljšanje Cell-ID pristupa je moguće korišćenjem TA (*Timing Advance*) i RTT (*Round Trip Time*) parametra, za GSM i UMTS sisteme respektivno. TA (GSM), tj. RTT (UMTS) parametar, odnose se na povratno vreme propagacije signala emitovanog od servisne bazne stanice (BTS/NodeB) ka mobilnoj stanici, što je proporcionalno dvostrukom rastojanju između bazne i mobilne stanice. Na taj način zona u kojoj se nalazi mobilna stanica (MS) ograničava se na prsten u čijem se centru nalazi servisna bazna stanica. Pri tom, korak između diskretnih vrednosti TA, odnosno RTT

parametara, odgovara rastojanju od 550m, odnosno 39m, respektivno, čime se u slučaju UMTS mreža postiže veća tačnost, nego u slučaju GSM.

Dodatna prednost Cell-ID+RTT metode jeste dostupnost RTT parametra za veći broj baznih stanica (NodeB), u slučaju da se mobilna stanica nalazi u stanju *soft handover*-a (SHO), tj. aktivnoj vezi sa više NodeB. U slučaju SHO, lokacija mobilne stanice određuje se primenom cirkularne lateracije, čime se smanjuje veličina estimirane oblasti u kojoj se nalazi mobilni korisnik. Obezbeđivanje dostupnosti većeg broja TA parametara kod GSM sistema moguće je kroz iniciranje forsiranog *handover*-a (FHO) mobilnog terminala na drugu GSM baznu stanicu. U slučaju UMTS sistema, kada se mobilna stanica ne nalazi u SHO stanju, veći broj RTT parametara moguće je obezbediti forsiranjem *soft handover*-a (FSHO) stanja. Međutim, potencijalne primene procedura forsiranog *handover*-a i *soft-handover*-a imale bi negativan uticaj na signalizaciono opterećenje, kao i na *downlink* kapacitet u slučaju UMTS sistema.

Enhanced Cell-ID (E-CID) metod u LTE mrežama zasniva se na korišćenju dodatnih parametara u cilju povećanja tačnosti Cell-ID metode: TA (*Timing Advance*) i AOA (*Angle of Arrival*). U LTE mrežama, postoje dve vrste TA parametra: TA tip 1 i TA tip 2. TA tip 1 je vreme definisano kao zbir povratnog vremena propagacije signala od bazne stanice (eNodeB) ka mobilnoj stanici i povratnog vremena propagacije signala od mobilne stanice ka eNodeB. TA tip 2 se definiše standardno, tj. kao povratno vreme propagacije signala (RTT) od eNodeB do UE. Tačnost merenja parametra TA tip 1 u LTE iznosi oko $0.3\mu\text{s}$, što odgovara rastojanju od 45m, dok tačnost merenja parametra TA tip 2 u LTE iznosi oko $1-2\mu\text{s}$, što odgovara rastojanju od oko 300m. Što se tiče merenja AOA parametra, ono se uvek vrši na *uplink*-u, jer se instalacija antenskih nizova u praksi može realizovati samo na strani eNodeB. Princip merenja AOA parametra zasniva se na tome da je signal koji dolazi od mobilne stanice fazno pomenen za neku vrednost između sukcesivnih antenskih elemenata. Stepen tog faznog pomeraja zavisi od ugla prispeća signala, razmaka između antenskih elemenata, kao i radne učestanosti. Merenjem faznog pomeraja, a znajući karakteristike antenskog sistema eNodeB, kao i radnu učestanost, moguće je estimirati parametar AOA. Primenom parametara RTT i AOA, E- CID metoda ima tačnost između 50m - 150m.

Ipak, glavni problem navedenih Cell-ID+TA, Cell-ID+RTT i E-CID metoda jesu NLOS uslovi propagacije koji znatno mogu uticati na vrednost TA/RTT/AOA parametara.

E-OTD (GSM), OTDOA-IPDL (UMTS) i OTDOA (LTE) metode

E-OTD metod pozicioniranja u GSM sistemu zasniva se na merenju vremena prispeća signala (TOA) od obližnjih baznih stanica do mobilnog terminala i primeni cirkularne lateracije, ili na merenju vremenske razlike prispeća signala (TDOA) od obližnjih baznih stanica i primeni hiperbolične lateracije. Kao što je već pomenuto, merenje TOA parametara zahteva sinhronizaciju između mobilne stanice i baznih stanica, dok merenje TDOA zahteva sinhronizaciju samo između baznih stanica međusobno. Obzirom da u GSM mrežama nijedan od ovih uslova nije ispunjen, za ostvarivanje *a posteriori* sinhronizacije mora se koristiti dodatna komponenta u GERAN pristupnoj mreži - LMU (*Location Measurement Unit*). E-OTD metod se implementira na *downlink* smeru veze, a može biti *mobile-based* ili *mobile-assisted network-based* rešenje.

U slučaju merenja TDOA parametra, mobilni terminal meri (u odnosu na svoje interno vreme) vremensku razliku prispeća signala na BCCH kanalima dve bazne stanice (tzv. *Observed Time Difference*, OTD), dok LMU jedinica meri vremensku razliku emitovanja signala sa te dve bazne stanice (tzv. *Real Time Difference*, RTD). Razlika OTD i RTD vremena predstavlja estimirani TDOA parametar. Potrebno je istaći da RTD parametar koji meri LMU jedinica zapravo predstavlja vremensku razliku prispeća signala od baznih stanica do LMU jedinice, a da se stvarna vrednost parametra RTD dobija uvođenjem korekcije za propagaciono kašnjenje signala između baznih stanica i LMU jedinica, pod pretpostavkom da su poznate njihove geografske koordinate. Međutim, problem ove korekcione procedure jesu situacije kada signali čije vreme prispeća meri LMU jedinica nisu rezultat direktne već reflektovane putanje, odnosno NLOS uslovi propagacije između baznih stanica i LMU. S druge strane, u slučaju merenja TOA parametra i primene cirkularne lateracije, zbog obezbeđivanja Tx-Rx sinhronizacije, neophodna je da vremena prispeća signala od baznih stanica meri ili

jedna LMU jedinica, ili različite LMU jedinice ali u odnosu na isto referentno vreme, što je moguće ukoliko su LMU jedinice opremljene GPS prijemnikom.

Tačnost E-OTD metode pozicioniranja procenjuje se od 50m do 500m, sa kašnjenjem do 10s. Primena E-OTD metode osetljiva je na geografski raspored baznih stanica u prostoru, koje učestvuju u procesu lateracije (minimalno 3), kao i na NLOS uslove propagacije. Dodatno, E-OTD metoda pozicioniranja zahteva modifikacije i na strani mobilne stanice i na strani mreže. Izmene na strani mreže odnose se na instaliranje LMU jedinica, pri čemu jedna LMU jedinica može obezbeđivati funkcionalnost za nekoliko obližnjih baznih stanica. Neophodne modifikacije na strani mobilne stanice odnose se na modifikacije standardnih terminala kako bi se izvršila neophodna OTD merenja i eventualno proračunala sopstvena pozicija (*mobile-based* varijante).

OTDOA-IPDL predstavlja ekvivalent E-OTD metode u UMTS sistemu. Za potrebe pozicioniranja u UMTS, LMU jedinice je neophodno instalirati samo za bazne stanice koje rade u UTRAN-FDD (*Frequency Division Duplexing*) modu, s obzirom da su bazne stanice u UTRAN-TDD (*Time Division Duplexing*) modu već međusobno sinhronizovane. LMU jedinice vrše RTD merenja servisne i susednih baznih stanica (NodeB), samo što se merenja u ovom slučaju vrše na pilot signalima, CPICH (*Common Pilot Channel*). Međutim, kao posledica činjenice da nodovi B (NodeBs) rade na istoj učestanosti, na *downlink* smeru može doći do tzv. *hearability* problema. Naime, u slučaju kad se mobilna stanica nalazi u blizini servisnog NodeB, njegov pilot signal može da maskira pilot signale sa susednih nodova B. Kako bi se omogućila "čujnost" pilot signala susednih nodova B, uvedeni su *idle* periodi u emisiji signala sa servisnog NodeB. Tačnost OTDOA-IPDL metode pozicioniranja procenjuje se od 50m do 200m, sa kašnjenjem do 5s.

OTDOA metoda pozicioniranja u LTE je slična kao istoimena metoda u UMTS ili E-OTD u GSM. Kod LTE OTDOA metode mere se vremenske razlike prispeća ćelijskih referentnih signala (*Cell-specific Reference Signal*, CRS) od nekoliko baznih stanica (eNodeBs) do mobilnog terminala. Nakon estimacije datih RSTD (*Reference Signal Time Difference*) vremenskih razlika, primenjuje se hiperbolička lateracija. *Hearability* problem, koji se i u ovom slučaju javlja, rešava se uvođenjem specijalnih

referentnih signala namenjenih isključivo pozicioniranju (*Positioning Reference Signal*, PRS). PRS signali se emituju periodično, zajedno sa CRS signalima kako bi povećali “čujnost” eNodeB.

U-TDOA metode u GSM/UMTS/LTE

U-TDOA metod pozicioniranja u GSM implementira se kao *network-based* rešenje. Merenja se vrše na *uplink* smeru veze, odnosno, meri se vreme prispeća (TOA) signala sa mobilne stanice do tri ili više baznih stanica/LMU jedinica. Izmerene vrednosti TOA se prosleđuju od baznih stanica/LMU jedinica do SMLC (*Serving Mobile Location Center*), gde se vrši proračun TDOA, a zatim primenjuje hiperbolička lateracija u cilju estimacije nepoznatih koordinata mobilne stanice.

Iako U-TDOA ne zahteva izmene na strani mobilnog terminala, prvi nedostatak ovog pristupa jeste to što zahteva da mobilna stanica bude u *dedicated* modu rada, odnosno da emituje signal. U slučaju da taj uslov nije ispunjen, mreža mora stimulisati emisiju signala sa mobilne stanice, što povećava signalizaciono opterećenje. Dodatno, kako je mobilna stanica u jednom trenutku u vezi samo sa jednom baznom stanicom (koja služi kao referentni prijemnik), ostale referentni prijemnici moraju biti LMU jedinice. Stoga, bitan preduslov koji zahteva U-TDOA jeste dovoljan broj LMU jedinica u okruženju mobilne stanice čija se pozicija određuje, što povećava cenu implementacije ove metode. Dodatno, kao i u slučaju E-OTD i OTDOA metoda na *downlink* smeru veze, U-TDOA metod je dosta osetljiv na NLOS uslove propagacije.

U-TDOA metod u UMTS i LTE je sličan prethodno opisanom metodu u GSM sistemu.

A-GNSS metod u GSM/UMTS/LTE

A-GNSS metod pozicioniranja u GSM/UMTS/LTE podrazumeva integraciju satelitskih i ćelijskih sistema, najčešće u vidu *Assisted-GPS* (A-GPS). Kao što je već pomenuto u prethodnom poglavlju 2.4.3, u okviru ćelijske mreže (GSM/UMTS/LTE) formira se referentna GPS mreža, na način da je uvek obezbeđena optička vidljivost prijemnika referentne mreže i satelita koji se u tom trenutku nalaze iznad tog dela

zemljine kugle. Data mreža vrši kontinualno nadgledanje konstalacije satelita i obezbeđuje pomoćne podatke za pozicioniranje.

Osim izmena na nivou mreže, A-GPS metoda zahteva i izmene na nivou mobilne stanice, koja mora biti opremljena GPS prijemnikom. Kada se javi zahtev za pozicioniranjem, pomoćni podaci koje obezbeđuje GPS referentna mreža se dostavljaju GPS prijemniku u okviru mobilne stanice, što omogućava brži odziv kao i veću osetljivost samog prijemnika Time se smanjuje TTFF vreme, pa se kašnjenje A-GPS metode procenjuje na 5-10s.

Tačnost A-GPS metode se kreće od 10-50m. A-GPS metod može biti realizovan kao *mobile-assisted* ili *mobile-based* rešenje. Ozbiljan nedostatak ove metode predstavljaju neophodne i softverske i hardverske izmene u okviru mobilne stanice, što povećava cenu implementacije metode. Dodatan problem je nedostupnost ove metode pozicioniranja u *indoor* okruženjima. Na kraju, korišćenje GPS prijemnika u okviru mobilne stanice povećava potrošnju baterije mobilnog terminala.

2.4.3. *NESTANDARDIZOVANE METODE ĆELIJSKOG POZICIONIRANJA*

U suštini, sve metode pozicioniranja standardizovane od strane ETSI (*European Telecommunications Standards Institute*) [22-24] imaju neki vid nedostatka. Iz datog razloga, ni jedno od navedenih rešenja nije prihvaćeno u potpunosti od strane mobilnih operatora.

U izveštaju Komiteta za komunikacije u okviru Evropske komisije (EC) za 2017. godinu [25], navedeno je da se u 25 država članica EU (od njih ukupno 28), podatak o poziciji korisnika u mobilnim mrežama dobija i dalje na osnovu najjednostavnije Cell-ID metode. Pri tom, postignuta tačnost pozicioniranja, koja je navedena u izveštaju, kreće se od 70m do 5km. Cell-ID+(RTT/TA) metod implementiran je u Litvaniji, dok je u Velikoj Britaniji i Estoniji implementirano tzv. *Advanced Mobile Location* (AML) rešenje, kod kog se osim Cell-ID informacije koriste GPS i WLAN podaci koje meri mobilna stanica. Navedena tačnost AML metode je 50m|80%, ali njena praktična primena zahteva da korisnik poseduje *smartphone* sa Android operativnim sistemom.

S druge strane, nedostaci standardizovanih pristupa, najviše u pogledu tačnosti ili otežane praktične implementacije, podstakle su intenzivan razvoj novih tehnika. Cilj ovih istraživanja je postizanje što veće tačnosti, ali uz ispunjenje zadatih zahteva po pitanju dozvoljenog kašnjenja i dostupnosti metode pozicioniranja u različitim okruženjima, kao i razumne kompleksnosti i cene implementacije.

Većina novijih istraživanja usmerena je na obogaćivanje Cell-ID informacije, ne samo sa TA/RTT parametrima, već i RSS merenjima. Pri tom, predložene su različite probabilističke i *fingerprinting* metode.

AECID (*Adaptive Enhanced Cell-ID*) metod predložen u [26], zasniva se na oportunističkom prikupljanju *fingerprint*-a koji sadrže precizne GPS koordinate lokacije, listu Cell-ID ćelija detektovanih u datoj tački, kao i dostupne TA/RTT i RSS parametre. *Fingerprint*-i se grupišu u klastera prema sličnosti. U slučaju generisanja zahteva za pozicioniranjem neke mobilne stanice (MS), na osnovu liste detektovanih ćelija i dostupnih TA/RTT i RSS merenja, vrši se odabir klastera, nakon čega se na osnovu *fingerprint*-a datog klastera proračunava poligon u kome se nalazi MS. Primenom AECID metode u urbanom i suburbanom okruženju [27], ostvareno je smanjenje oblasti u kojoj se potencijalno nalazi korisnik za 25%, u poređenju sa veličinom date oblasti u slučaju primene Cell-ID+TA metode. AECID metod koji umesto dostupnih TA/RTT i RSS merenja koristi samo RTT ili TA parametre, ispitivan je simuliranom UMTS i LTE okruženju u [28]. U datom slučaju, ostvarena redukcija zone u kojoj se procenjuje pozicija MS iznosi 20%.

Roos et al. [29] su dali predlog probabilističkog metoda koji se zasniva na konstruisanju statističkog propagacionog modela za opisivanje prostorne raspodele RSS parametra i primeni MLE (*Maximum Likelihood Estimate*) pristupa za procenu prostornih koordinata MS. Primenom ovog metoda ostvarena je tačnost od 320m|67%² u simuliranom GSM okruženju. Yamamoto et al. [30] su primenili Okumura propagacioni model za estimiranje prostornih funkcija gustina verovatnoće RSS vrednosti. U urbanom test okruženju, ostvarena je tačnost od 53m|67%. Međutim, potrebno je naglasiti da implementacija ovih probabilističkih metoda zahteva posedovanje podataka o tačnim pozicijama baznih stanica, snagama predajnika,

² Radi pojednostavljenja zapisa, u nastavku teze biće korišćena notacija DE[m]|P[%] za označavanje vrednosti greške pozicioniranja DE[m] koja nije premašena u P[%] slučajeva.

antenskom sistemu (usmerenje, pojačanje, dijagram zračenja antene), itd. Dodatno, probabilistički metodi su proračunski dosta zahtevni.

Drugi, dosta popularan pravac u pozicioniranju jeste korišćenje *fingerprinting* metoda, poput metode k najbližih suseda (kNN i WkNN), veštačkih neuralnih mreža (ANN), *Support Vector Machines* (SVM), itd. Iako formiranje baze *fingerprint*-a sa realnim podacima sa terena može biti naporan i vremenski zahtevan posao, dati pristup ne zahteva poznavanje karakteristika predajnika baznih stanica i modelovanje radio propagacionih uslova u nekom okruženju. S druge strane, razvoj *crowdsourcing* metoda u kojima obični mobilni korisnici svakodnevno prikupljaju podatke za formiranje i ažuriranje *fingerprint* baza, predstavlja obećavajuće rešenje problema mernih kampanja [17-19].

DCM (*Database Correlation Method*) tehnika pozicioniranja koji se zasniva na metodi najbližeg suseda (kNN za $k=1$) razmatrana je u [31]. Metrika za određivanje razlike, tj. rastojanja u domenu radio signala, između RSS *fingerprint*-a formiranog na trenutnoj poziciji MS i k -tog *fingerprint*-a iz baze, definisana je sa [31]:

$$d(k) = \sum_i (f_i - g_i(k))^2 + p(k) \quad (2.8)$$

gde f_i predstavlja RSS vrednost koju MS izmeri na BCCH kanalu i -te GSM ćelije, a $g_i(k)$ RSS nivo BCCH kanala i -te GSM ćelije u k -tom *fingerprint*-u iz baze. Član $p(k)$ predstavlja “penal”, tj. vrednost koja povećava rastojanje (razliku) između dva *fingerprint*-a u slučaju da RSS parametar neke ćelije nije sadržan u jednom od ta dva *fingerprint*-a. Predloženi metod ostvario je tačnost od 74m|67% u suburbanom i 44m|67% u urbanom okruženju. WkNN metod predložen u [32] ostvario je srednju grešku pozicioniranja od 112m i 242m u realnom urbanom i suburbanom okruženju, respektivno. kNN *fingerprinting* metod za pozicioniranje u LTE mrežama, koji pored izmerenih RSS, tj. RSRP (*Reference Signal Received Power*) parametara, koristi i TA podatke, postigao je tačnost od 62m|67% u realnom urbanom okruženju [33].

Probabilistički *fingerprinting* metod, nazvan CellSense, predložen je u [34]. CellSense metod deli zonu od interesa na mrežu (*grid*) podoblasti. Na osnovu RSS *fingerprint*-a prikupljenih u jednoj podoblasti kreiraju se histogrami RSS merenja za svaku od detektovanih GSM ćelija. U *online* fazi, na osnovu trenutno izmerenih RSS

vrednosti okolnih ćelija, određuje se najverovatnija podoblast u kojoj se MS nalazi. Potom se MS lokacija estimira se kao ponderisana (*weighted*) usrednjena vrednost k najverovatnijih *fingerpint* lokacija iz date podoblasti. CellSense metodom ostvarena je medijanska greška od 42m i 28m u realnom ruralnom i urbanom okruženju, respektivno. Primenom hibridnog rešenja, koje nakon određivanja najverovatnije podobalsti u okviru *grid*-a primenjuje klasičan kNN pristup, ostvarena je medijanska greška od oko 55m u oba tipa okruženja, ali uz značajnu redukciju vremena proračuna (oko 5.4 puta) [34]. Kombinovani probablističko *fingerprinting* metod predložen je i u [17], za pozicioniranje u LTE mrežama. RSS *fingerprint*-i (sa GPS koordinatama) prikupljeni metodom *crowdsourcing*-a u ruralnim i urbanim okruženjima u SAD, korišćeni su za formiranje radio mapa u vidu mreže (*grid*), gde je za svaku tačku u okviru *grid*-a izvršena statistička analiza RSS merenja. Za estimaciju lokacije korisnika predloženo je korišćenje MLE i WA (*Weighted Average*) metode. Metod je postigao medijansku grešku od 50m i 300m u urbanom i ruralnom okruženju, respektivno.

Metod zasnovan na RSS *fingerprinting*-u i primeni veštačkih neuralnih mreža postigao je tačnost od oko 50m|67% u urbanom GSM okruženju [35]. U [36] predložena je RSS *fingerprinting* tehnika koja vrši estimaciju pozicije mobilne stanice primenom *multilayer feedforward* neuralne mreže sa propagacijom greške unazad (*error backpropagation*). U slučaju korišćenja RSS vrednosti koje potiču od GSM, DCS i UMTS ćelija različitih mobilnih operatora ostvarena je tačnost od 68m|67% u suburbanom okruženju. Za isti tip okruženja, primenom principa segmentacije prostora na manje celine i kaskadno povezanih ANN mreža (*Cascade-correlated ANNs*, CC-ANNs) ostvareno je smanjenje srednje greške pozicioniranja sa 82m (bez segmentacije prostora) na 26m (20x20 segmenata) [37]. Pri tom, estimacija pozicije vršena je na osnovu RSS vrednosti koje potiču od GSM i DCS ćelija dva mobilna operatora.

Primena SVM algoritama za potrebe pozicioniranja korisnika u mobilnim mrežama razmatrano je do sad u par istraživanja. U [38] predloženo je korišćenje *Support Vector Classification* (SVC) algoritma za određivanje najverovatnije oblasti u kojoj se korisnik nalazi na osnovu trenutno izmerenih RSS vrednosti okolnih ćelija, nakon čega se za tačnu poziciju MS uzima tačka iz date oblasti najbližija u domenu radio signala (najbliži sused). Metod je implementiran u simuliranom UMTS urbanom okruženju korišćenjem kombinacije *Cost 231 Hata* i *Walfisch Ikegami* propagacionih

modela i ostvario je tačnost od 194m|67%. Metode pozicioniranja koje koriste *Support Vector Regression* (SVR) algoritam za estimaciju pozicije MS na osnovu TOA parametara razmatrane su u [39, 40]. U [39] predloženo je korišćenje LS-SVM (*Least-Square SVM*), dok [40] predstavlja nadogradnju prethodnog istraživanja u vidu realizacije WLS-SVM (*Weighted LS-SVM*) algoritma za pozicioniranje. Korišćenjem simuliranih TOA podataka postignute su tačnosti od 70m|67% u slučaju LS-SVM [39] i srednja greška od 35 – 65 m u slučaju WLS-SVM (u zavisnosti od veličine trening skupa podataka) [40].

U istraživanju [41] predložen je RSS *fingerprinting* metod zasnovan na korišćenju linearnog ϵ -insensitive SVR algoritma i nove kernel funkcije, nazvane SoE (*Sum of Exponential*), namenjene rešavanju problema nepostojećih RSS vrednosti u *fingerprint*-ima (npr. slučaj kada signal neke PLMN ćelije nije detektovan). Za predloženi metod prijavljena je medijanska greška od 75m-100m u urbanom okruženju, u zavisnosti od veličine trening skupa podataka.

Na kraju, inicijalna procena pozicije mobilne stanice može biti unapređena ukoliko je sistemu pozicioniranja dostupno više uzastopnih estimacija, tj. implementiranjem nekog od algoritama za praćenje (*tracking algorithm*) poput: *Kalman filter* (KF)/ *Extended Kalman filter* (EKF) [17, 42, 43], *Iterative Non-Linear Least-Squares* (ILS) [44], itd. Dodatno, u pojedinim situacijama, kada je kretanje mobilnog korisnika/objekta ograničeno na tačno određene putanje (npr. korisnik u vozilu), estimacija pozicije korisnika (vozila) može se dalje poboljšati primenom algoritama za povezivanje estimovane pozicije sa određenom oblašću na mapi, tzv. *map-matching* algoritmi [45]. Ipak, potrebno je naglasiti da je rad u okviru ovog istraživanja usmeren na problem određivanja inicijalne pozicije, kada uvid u prethodno kretanje tj. poziciju mobilne stanice nije poznat.

Tabelarni pregled tačnosti metoda navedenih u ovom poglavlju dat je u nastavku.

Tabela 2.4. Pregled tačnosti ćelijskih metoda pozicioniranja u *outdoor* okruženju

Metode pozicioniranja	Srednja DE [m]	Medijanska DE [m]	67% DE [m]	90% DE [m]	Tip okruženja
Statističko modelovanje (RSS) [29]	279	237	320	620 ^(95% DE)	GSM, simulirano
Probablistički metod sa Okomura propag. modelom (RSS) [30]	52.8	.	53.8	102 ^(95% DE)	GSM, urbano
DCM- <i>nearest neighbour</i> (RSS) [31]	-	-	44 / 74	90 / 190	GSM urbano/suburbano
WkNN (RSS) [32]	112 / 242	~ 90 / 180	~ 125 / 250	~200 / 500	GSM urbano/suburbano
kNN (RSS+TA) [33]	-	-	62	132 ^(95% DE)	LTE, urbano
CellSense (RSS) [34]	-	28 / 42	-	273 / 308 ^(95% DE)	GSM urbano/ruralno
NBL <i>crowdsourcing</i> (RSS) [17]	-	50 / 300	-	-	LTE urbano/ruralno
ANN (RSS) [35]	-	-	~50	~110 ^(95% DE)	GSM, urbano
Multi-system multi-operator ANN (RSS) [36]	59	50	68	137 ^(95% DE)	GSM/DCS/UMTS suburbano
C-C ANNs 1x1 [37]	82	72	90	177 ^(95% DE)	GSM/DCS, suburbano
C-C ANNs 20x20[37]	26	2	4	168 ^(95% DE)	GSM/DCS, suburbano
SVC (RSS) [38]	93	-	194	-	UMTS, simulirano
LS-SVM (TOA) [39]	-	65	70	100 ^(95% DE)	GSM, simulirano
WLS-SVM (TOA) [40]	35-65	-	-	-	GSM, simulirano
SVR SoE (RSS) [41]	95-125	75-100	-	-	GSM, urbano

2.5. INDOOR POZICIONIRANJE

Usled specifičnih uslova propagacije radio signala u *indoor* okruženjima, poput čestog nepostojanja LOS uslova i izražene pojave višestruke propagacije, većina istraživanja orijentisana je ka razvoju *indoor* sistema za pozicioniranje koji se zasnivaju na korišćenju radio tehnologija srednjeg i kratkog dometa. Najčešće su korišćene radio tehnologije poput lokalnih bežičnih mreža (*Wireless Local Area Networks*, WLAN), *Ultra-wideband* (UWB), *Bluetooth* i *Radio-frequency identification* (RFID) [46-48].

Dodatno, razmatrane su i upotrebe infracrvene (*Infrared Data Assosiation*, IrDA) i ultrazvučne tehnologije [46]. Međutim, glavni nedostatak korišćenja većine ovih tehnologija jeste potreba za postavljanjem dodatnih infrastrukturnih elemenata u *indoor* okruženjima u kojima je potrebno obezbediti servis pozicioniranja. Drugim rečima, dati sistemi za pozicioniranje se realizuju kao samostalni, namenski sistemi, koji zahtevaju izgradnju infrastrukturnih elemenata i dodatne radio interfejsne na mobilnim terminalima, kao i realizaciju mehanizama za razmenu podataka sa komunikacionom mrežom. Dati aspekti imaju veliki uticaj na cenu implementacije, pa samim tim i na dostupnost ovih sistema za pozicioniranje u velikom broju *indoor* okruženja, kao na pristupačnost sistema većini korisnika.

S druge strane, postojeća infrastruktura javnih mobilnih mreža već nudi zadovoljavajuće pokrivanje radio signalom velikog procenta *indoor* lokacija, usled čega je u startu moguće postići veću dostupnost sistema za pozicioniranje, uz dosta manje troškove implementacije (na strani i mreže i korisničkih terminala). Dodatno, navedeni pristup otvara mogućnost realizacije jedinstvenog sistema za pozicioniranje i u *outdoor* i *indoor* okruženjima.

2.5.1. WLAN METODE POZICIONIRANJA

WLAN metode pozicioniranja zasnivaju se na korišćenju WLAN mreža koje se sve češće implementiraju u javnim, poslovnim i rezidencijalnim objektima. Ujedno, ove metode su u poslednjih nekoliko godina predmet najvećeg broja istraživanja u okviru oblasti *indoor* pozicioniranja [49].

Većina WLAN metoda pozicioniranja zasniva se na korišćenju RSS parametara. Naime, usled NLOS uslova i propagacije po višestrukim putanjama, korišćenje AOA parametara za pozicioniranje u *indoor* okruženjima je gotovo nemoguće. S druge strane, glavni problem korišćenja TOA i TDOA parametara predstavlja zahtev za vrlo velikom rezolucijom merenja vremena, što je posledica propagacije signala brzinom svetlosti. Dodatno, sinhronizacija koju zahtevaju metode bazirane na merenju vremena je vrlo teško ostvariva u WLAN mrežama.

U opštem slučaju, WLAN metode se mogu realizovati kao *network-based* i *mobile-based* (*client-based*). U dosadašnjim istraživanjima, najčešće su predlagana *client-based* rešenja. *Client-based* rešenje podrazumeva da klijent (tj. mobilni terminal koji podržava IEEE 802.11 standard), kroz procedure pasivnog ili aktivnog skeniranja, meri nivoe signala (RSS parametre) *beacon* signala koje emituju APs (*Access Points*). Proračun koordinata vrši se u okviru klijenta, primenom nekog od probabilističkih, *fingerprinting* ili hibridnih metoda [49].

Probabilistički metod Horus [50] i *Bayesian* pristup [51] postigli su medijansku vrednost greške pozicioniranja od 2m, prilikom testiranja u *indoor* okruženjima dimenzija 59m x 19m i 25m x 15m, respektivno. Primenom kNN metode, RADAR sistem [52] postigao je medijansku vrednost greške pozicioniranja od 4m u prostoru dimenzija 43m x 22m. U [53], autori su testirali performase novog *Tilejunction* algoritma koji prvo detektuje oblast (*tile*) u kojoj se klijent najverovatnije nalazi, nakon čega primenom modifikovanog WkNN pristupa, koji koristi novu metriku za poređenje RSS *fingerprint*-a, proračunava poziciju klijenta. Performanse *Tilejunction* i RADAR algoritma su upoređene na test *indoor* okruženju dimenzija 100m x 80m. Ostvarene vrednosti medijanske greške pozicioniranja iznose 6.5m i 13m, respektivno. Primena ANN mreža i principa segmentacije prostora razmatrana je u [54]. Za *indoor* okruženje dimenzija 147m x 66m, primenom principa segmentacije prostora na manje celine i kaskadno povezanih ANN struktura (*Cascade-correlated ANNs*, CC-ANNs) ostvareno je smanjenje vrednosti medijanske greške pozicioniranja sa 7.75m na 5.59m [54]. Robustan ekstremni algoritam mašinskog učenja (*Robust Extreme Learning Machine*, RELM) predložen je za potrebe *indoor* pozicioniranja u [55], sa ciljem da se ubrza proces treniranja i poveća robustnost sistema za pozicioniranje na prisustvo šuma i varijacije u izmerenim RSS nivoima. Za test okruženje dimenzija 31.5 x 16.6m, ostvarena je srednja greška pozicioniranja od 2.94m primenom RELM, dok su za to isto okruženje primenom ANN i SVR pristupa ostvarene srednje greške pozicioniranja od 3.71m i 4.66m, respektivno.

I pored dobrih performansi po pitanju postignute tačnosti, jedan od problema *client-based* WLAN metoda jeste energetska efikasnost, odnosno potrošnja baterije mobilnog terminala usled činjenice da se proračun pozicije vrši na strani klijenta. Dodatno, i pored sve veće rasprostranjenosti WLAN mreža, njihova implementacija se

vrši prevashodno za potrebe pristupa Internetu, a ne pozicioniranja. Drugim rečima, prostorni raspored AP se obično optimizuje tako da se obezbedi adekvatno pokrivanje prostora od interesa WLAN signalom, uz korišćenje minimalnog broja AP. Dodatno, kako je osnovna funkcija WLAN mreža obezbeđivanje pristupa Internetu, u pojedinim okruženjima dostupnost WLAN sistema za pozicioniranje može biti ograničeno samo na određene delove nekog objekta (npr. lobi hotela).

Dalji razvoj WLAN metoda za pozicioniranje usmeren je na korišćenje podataka o rasporedu AP i unutrašnjoj strukturi *indoor* okruženja (npr. raspored zidova), korišćenje senzora za detekciju pokreta (*motion sensors*) u cilju estimacije putanje kretanja korisnika, korišćenje drugih senzora (npr. *Bluetooth*) za kolaborativnu lokalizaciju, itd [49].

2.5.2. METODE POZICIONIRANJA KORIŠĆENJEM RADIO TEHNOLOGIJA KRATKOG DOMETA

Bluetooth Low Energy (BLE) sistemi za pozicioniranje

Bluetooth je radio tehnologija namenjena razmeni podataka između uređaja koji se nalaze na malim rastojanjima, tj. koji formiraju WPAN (*Wireless Personal Area Network*) mrežu. *Bluetooth* tehnologija razvijena je od strane *Bluetooth Special Interest Group* (SIG) i koristi ISM (*Industrial, Scientific and Medical*) frekvencijski opseg od 2.4GHz, kao i WLAN tehnologija. *Bluetooth* domet zavisi od klase predajnika. Uređaji koji pripadaju klasi 1 imaju teorijski domet do 100m (za slučaj propagacije u slobodnom prostoru), dok klasa 2 omogućava domet do 10m. Većina mobilnih uređaja pripada klasi 2.

Pojava *Bluetooth Low Energy* (BLE) standarda podstakla je razvoj tzv. BLE *indoor* sistema za pozicioniranje [47]. BLE uređaji rade u istom frekvencijskom opsegu kao i klasični *Bluetooth* uređaji, ali imaju veću učestanost skeniranja kanala (oko 30 puta u sekundi), kraću *handshake* proceduru i znatno manju energetske potrošnje.

BLE *indoor* sistemi za pozicioniranje se zasnivaju na estimaciji udaljenosti mobilnog uređaja od jednog ili više fiksnih čvorova koji se nazivaju *BLE beacons*. *BLE beacon* uređaji vrše *broadcast* emitovanje kratkih poruka koje, između ostalog, sadrže

identifikator *beacon* uređaja i kalibrisanu RSS vrednost, koja tipično odgovara RSS vrednosti na rastojanju 1m od *beacon* uređaja. BLE pozicioniranje se najčešće vrši na osnovu izmerenih RSS nivoa BLE *beacon* signala, korišćenjem *proximity sensing* i *fingerprinting* metoda [56-58].

Proximity sensing pristup je naročito popularizovan sa razvojem BLE *beacon* uređaja. Najveću primenu ovaj metod nalazi kod realizacije LBS servisa koji se aktiviraju u slučaju kad se korisnik nađe u blizini određenog BLE *beacon* uređaja, npr. lokacijski-ciljano oglašavanje (tj. reklame), “*near-me*” aplikacije, itd. *Apple iBeacon* [56] je jedan primer BLE *proximity sensing* sistema koji je dostupan na tržištu. Kod *proximity* metoda, na malim udaljenostima od *beacon* uređaja (reda veličine metar), estimacija rastojanja na osnovu izmerene RSS vrednosti je dosta tačna (greška od nekoliko cm), pa je lako aktivirati LBS servis. Međutim, sa povećanjem udaljenosti drastično se pogoršava tačnost estimacije rastojanja na osnovu izmerene RSS vrednosti. Tako na rastojanju od 10m greška iznosi oko 5m [57]. Iako je *proximity* metod pogodan za realizaciju određenih LBS servisa, u opštem slučaju, *indoor* sistem za pozicioniranje treba da bude dostupan na skoro svakoj lokaciji u okviru nekog prostora, a ne samo u blizini određenog BLE *beacon* uređaja.

S druge strane, *fingerprinting* metode koriste RSS parametre većeg broja BLE *beacon* uređaja za estimaciju pozicije mobilnog terminala u okviru nekog *indoor* okruženja. Tačnost ovih metoda u velikoj meri zavisi od broja i rasporeda BLE *beacon* uređaja. U eksperimentu sprovedenom u *indoor* okruženju dimenzija 45m x 12m, sa postavljenih 19 BLE *beacon* uređaja, greška estimacije pozicije iznosila je manje od 2.6m u 95% slučajeva [57].

Iako danas noviji mobilnih uređaji podržavaju BLE tehnologiju, infrastrukturni elementi u vidu BLE *beacon* uređaja su retko gde prisutni. Ipak, instalacija BLE *beacon* uređaja pruža veći stepen fleksibilnosti u poređenju sa instalacijom WLAN APs. Razlog je prevashodno primarna funkcija koju WLAN mreže moraju da obezbede, a koja dominantno utiče na broj i raspored AP. Drugi razlog su manje dimenzije i baterijsko napajanje BLE *beacon* uređaja, pa je njihova instalacija nezavisna od izvora napajanja. Dodatna prednost BLE u odnosu na WLAN tehnologiju je i manja potrošnja baterije mobilnog terminala.

RFID (Radio-frequency identification) sistemi za pozicioniranje

RFID sistem se sastoji iz tzv. tagova (*tags*) i čitača. Tagovi se obično postavljaju na entitete čiju je poziciju potrebno odrediti, tj. pratiti. Pored svog ID koda, tagovi mogu emitovati i dodatne informacije, što proširuje primenu ove tehnologije.

Postoje tri tipa tag uređaja:

- Pasivni tagovi nemaju izvor napajanja, već koriste energiju indukovanu na njihovoj anteni od nadolazećeg radio talasa sa čitača. Koristeći datu energiju, pasivni tagovi emituju odgovor koji sadrži njihov ID kod i potencijalno dodatne informacije. Usled ovakvog načina funkcionisanja, pasivni tagovi imaju male domete, do nekoliko metara, ali su zato manjih dimenzija i jeftiniji.
- Aktivni tagovi su povezani na izvor napajanja što im omogućava neometano emitovanje signala. Usled toga imaju dosta veće domete (do par stotina metara), ali su dimenzije i cena ovakvih tagova dosta veće.
- Semi-aktivni tagovi imaju baterijsko napajanje.

U opštem slučaju, RFID sistemi za pozicioniranje su dizajnirani tako da čitač detektuje blizinu nekog taga (*proximity sensing* metod). U datom slučaju, apsolutna pozicija taga nije poznata, ali RFID sistem ima informaciju da se tag nalazi u odgovarajućoj zoni oko pozicije čitača, pri čemu veličina date zone zavisi od toga da li je RFID sistem aktivnog ili pasivnog tipa.

S druge strane, moguće je postaviti mrežu tagova u okviru nekog *indoor* okruženja. U datom slučaju, čitač se nalazi na entitetu čiju je poziciju potrebno odrediti. Ovaj tip pristupa koristi se kod aktivnih RFID sistema, gde se tačnost pozicioniranja može unaprediti korišćenjem RSS parametra [59]. Tačnost ovakvih metoda zavisi od gustine prostornog rasporeda tagova i dometa RFID čitača. Primera radi, autori u [59] su postavljanjem 71 RFID taga u okviru prostora površine 1600m², implementirali RFID sistem za pozicioniranje sa medijanskom greškom od 1.5m.

Primeri RFID sistema za pozicioniranje su SpotON [60] i LANDMARC [61].

UWB (Ultra-wideband) sistemi za pozicioniranje

UWB je širokopolasna radio tehnologija koja omogućava visoke protoke podataka na malim rastojanjima. UWB signal se definiše kao širokopolasni signal čija širina frekvencijskog spektra iznosi barem 500MHz ili barem 20% centralne frekvencije signala.

Postoji nekoliko načina generisanja UWB signala. Za potrebe pozicioniranja, najčešće se razmatra upotreba impulsne UWB tehnologije. Kod impulsne UWB tehnologije, signal se generiše u vidu niza kratkih impulsa, tako da trajanje impulsa iznosi manje od 1ns, a vremenski interval između dva uzastopna impulsa nekoliko desetina nanosekundi. Usled izrazito kratkog trajanja impulsa, reflektovana komponenta stiže do prijemnika nakon što je direktna komponenta već u potpunosti primljena. Na taj način moguće je razdvojiti reflektovanu komponentu signala od direktne, pa su UWB signali, za razliku od ostalih razmatranih radio signalima, praktično imuni na probleme *multipath* propagacije. U skladu sa tim, UWB sistemi za pozicioniranje mogu koristiti i precizna TDOA, TOA i AOA merenja direktne komponente signala. UWB sistemi za pozicioniranje mogu postići tačnost pozicioniranja reda veličine nekoliko cm [48].

Ipak, glavni nedostatak korišćenja UWB tehnologije jeste visoka cena UWB opreme i postavljanja infrastrukturnih elemenata, što značajno ograničava dostupnost ovakvih sistema za pozicioniranje, tj. njihovo korišćenje u široke komercijalne svrhe [62]. Primeri implementiranih UWB sistema za pozicioniranje su Ubisens [63] i PulsON [64].

2.5.3. ĆELIJSKO POZICIONIRANJE

Korišćenje infrastrukture javnih mobilnih sistema u cilju lokalizacije korisnika u *indoor* okruženjima je do sad bio predmet značajno manjeg broja istraživanja, u poređenju sa pristupima koji se zasnivaju na prethodno navedenim radio tehnologijama (pogotovo u odnosu na WLAN).

U istraživanjima koja razmatraju primenu ćelijskih metoda pozicioniranja u *indoor* okruženjima, najčešće je korišćen pristup kreiranja radio mape prostora na

osnovu izmerenih RSS vrednosti okolnih PLMN ćelija (tj. kreiranje RSS *fingerprint* baze) i primene neke *fingerprinting* tehnike.

Varshavsky et al [65] su ispitivali upotrebu kNN metode na tri različita test okruženja: hodnici jedne univerzitetske zgrade (88m x 103m), laboratorija (30m x 30m) i sprat u okviru privatne kuće (18m x 6m). Za sva tri okruženja, radio mape su formirane na osnovu RSS vrednosti izmerenih na 35 GSM kanala detektovanih u datim okruženjima. Međutim, potrebno je navesti da autori nisu pravili razliku između nivoa signala izmerenih na BCCH i saobraćajnim kanalima. S druge strane, usled ponavljanja radio kanala (eng. *frequency reuse*) i primene mehanizma frekvencijskog skakanja (eng. *frequency hopping*) u GSM mrežama, ne može se garantovati da RSS vrednost izmerena na nekom saobraćajnom kanalu potiču uvek od iste GSM ćelije, budući da je Cell-ID informacija izostavljena. Dodatno, saobraćajni kanali se ne emituju sa konstantnom snagom i njihov nivo može varirati u zavisnosti od saobraćajnog opterećenja. Iz navedenih razloga, korišćenje RSS nivoa izmerenih na saobraćajnim kanalima ne može obezbediti stabilno rešenje za problem pozicioniranja. Iako su autori [65] predložili korišćenje *greedy feature* tehnike [66] za selekciju GSM kanala čije će nivoe signala koristiti algoritam za pozicioniranje, udeo saobraćajnih kanala nakon procesa selekcije nije razmatran. Tačnost predložene kNN metode za navedene tipove okruženja prikazana je u tabeli 2.5.

Poređenje performansi kNN i WkNN ćelijskih metoda pozicioniranja u *indoor* okruženju sprovedeno je [67]. Kao test okruženje korišćena je zgrada univerziteta, a estimacija pozicije vršena je korišćenjem RSS vrednosti koje potiču od 22 GSM ćelije. WkNN model je pokazao najbolje performanse, ostvarivši medijansku grešku pozicioniranja od 8.7m i srednju grešku od 9.7m. Ipak, autori su izostavili podatak o veličini test okruženja za koje je ostvarena data tačnost. Birkel i Weber [68] su analizirali performanse WkNN metode pozicioniranja u slučaju korišćenja RSS vrednosti koje potiču od *indoor* UMTS NodeB instalacija (UMTS *small cells*) u poslovnom test okruženju dimenzija 20m x 15m. Za posmatrano okruženje sa *indoor* instalacijama UMTS ćelija postignuta je tačnost od 6m|80%.

Ipak, bilo da je u pitanju kNN ili WkNN metod, prostorni raspored referentnih tačaka, tj. gustina radio mape, ima veliki uticaj na tačnost pozicioniranja. Veza između

gustine radio mape i optimalnog broja suseda (referentnih tačaka) ispitivana je u simuliranom GSM *indoor* okruženju [69]. Ista grupa autora je takođe ispitivala hibridne GSM-WLAN metode pozicioniranja zasnovane na primeni kNN i WkNN algoritama [70]. U simuliranom GSM-WLAN *indoor* okruženju, kNN i WkNN metode su ostvarile slične performanse i smanjenje srednje greške pozicioniranja za 50% u poređenju sa slučajem kad se koristi infrastruktura samo GSM sistema.

Korišćenje *multi-layer feed-forward* ANN mreža za određivanje pozicije mobilnog korisnika na osnovu RSS vrednosti 7 DCS (GSM 1800 MHz) ćelija ispitivana je u [71]. Testiranjem predložene ANN metode u *indoor* okruženju dimenzija 28m x 15m ostvarena je medijanska greška pozicioniranja od 5.22m.

Primene SVM algoritama razmatrane su u [72-74]. Međutim, u navedenim istraživanjima razmatran je problem lokalizacije korisnika na nivou prostorije (*room level localization*). U [72] autori su analizirali performanse različitih klasifikatora prostorije, implementiranih korišćenjem SVC, ANN, kNN i *Gaussian Process* (GP) algoritama. Testiranjem navedenih klasifikatora na apartmanu sa 5 prostorija, najbolje performance demonstrirao je SVC klasifikator sa verovatnoćom ispravne selekcije prostorije od 98%. U [73] autori su ispitivali performanse klasifikatora prostorije zasnovanih na primeni SVC algoritama sa nadgledanim (*supervised*) učenjem [15] i polu-nadgledanim (*semi-supervised*) učenjem [75]. Očekivano, bolje performanse je pokazao *supervised* SVC klasifikator, a za laboratorijsko okruženje sa pet prostorija (23.08m x 12.4m) navedena je tačnost estimacije prostorije od 100%. Ipak, treba uzeti u obzir da su u posmatranom eksperimentu merenja uvek vršena u jednoj istoj tački u svakoj od prostorija. Samim tim, za treniranje i testiranje SVC klasifikatora korišćeni su RSS *fingerprint*-i formirani ponovljenim merenjima u istim mernim tačkama. Dalje unapređenje performansi predloženog SVC klasifikatora za detekciju prostorije razmatrano je u [74], uzimanjem u obzir vremenskih i prostornih ograničenja prilikom kretanja mobilnog korisnika (brzina kretanja korisnika, raspored zidova, nameštaja, itd). Na kraju, potrebno je naglasiti da su obećavajući rezultati navedeni u [72-74] dobijeni korišćenjem baze *fingerprint*-a koja sadrži RSS merenja dobijena skeniranjem celog GSM i DCS opsega, tj. 534 GSM/DCS kanala (tzv. „*full-channel*“ *fingerprint*-i). Dakle, kao i u slučaju [65], korišćene su i RSS vrednosti izmerene na nestabilnim saobraćajnim

kanalima, bez dostupne informacije o identifikatoru radio izvora, tj. GSM/DCS ćeliji koja ih emituje.

Za razliku od prethodno navedenih RSS *fingerprinting* pristupa, u [76] je predložen metod pozicioniranja u LTE mrežama zasnovan na korišćenju TOA parametara. Na osnovu TOA parametara CRS (*Cell-specific Reference Signal*) signala LTE ćelija detektovanih u realnom *indoor* okruženju i primene EKAT (*ESPRIT and Kalman filter for time of Arrival Tracking*) algoritma [43], ostvarena je tačnost od 7.69m|50%.

Tabela 2.5. Pregled tačnosti ćelijskih metoda pozicioniranja u *indoor* okruženju

Greška pozicioniranja (<i>Distance Error, DE</i>)							
Metode pozicioniranja	Ulazni parametri	Verovatnoća ispravne detekcije prostorije [%]	Srednja DE [m]	Medijanska DE [m]	67% DE [m]	95% DE [m]	Veličina test okruženja [m] x [m]
kNN [65]	RSS nivoi BCCH i saobraćajnih GSM kanala	-	-	3.02 2.50 1.94	-	17.92 10.70 7.79	88 x 103 30 x 30 18 x 6
WkNN [67]	RSS nivoi GSM ćelija	-	9.7	8.7	11.5	17.3	-
WkNN [68]	RSS nivoi <i>indoor</i> UMTS ćelija	-	-	-	-	6 ^(80% DE)	20 x 15
ANN [71]	RSS nivoi DCS ćelija	-	-	5.22	-	7.32	28 x 15
SVC [73]	RSS nivoi kanala celog GSM/DCS frekv. opsega	100%	-	-	-	-	23.08 x 12.4 (5 prostorija)
EKAT [76]	TOA (LTE)	-	9.61	7.69	-	17.13	-

3. SUPPORT VECTOR MACHINES (SVM)

3.1. UVOD U SUPPORT VECTOR MACHINES

Support Vector Machine (SVM) algoritmi pripadaju grupi algoritama mašinskog učenja za otkrivanje modela (obrazaca) u skupovima podataka (*pattern recognition* algoritmi). SVM algoritmi se zasnivaju na teoriji statističkog učenja (*statistical learning theory*) [77]. Zadatak teorije statističkog učenja jeste istraživanje statističke zavisnosti između slučajnih promenljivih, kroz izvlačenje što je moguće više informacija iz nekog ograničenog skupa podataka koji se koristi kao uzorak (*sample data*). Algoritmi mašinskog učenja bave se pronalaženjem opštih relacija, pravilnosti ili struktura koje su svojstvene nekom izvoru podataka. Cilj mašinskog učenja je formiranje opšteg modela na osnovu dostupnog uzorka podataka, tako da formirani model poseduje svojstvo generalizacije, tj. da donosi odluke ili vrši predikciju za nove podatke koje generiše isti izvor.

U zavisnosti od metode učenja, algoritmi mašinskog učenja mogu se klasifikovati na algoritme sa nadgledanom (kontrolisanom) metodom učenja (*supervised learning*), nenadgledanom metodom učenja (*unsupervised learning*) i tzv. *reinforcement learning* algoritme. Metoda nadgledanog učenja podrazumeva da su tokom procesa učenja opšte relacije (tj. treniranja modela) algoritmu dostupni primeri ulaznih podataka i njima odgovarajućih (željenih) izlaza. S druge strane, metoda nenadgledanog učenja podrazumeva da algoritam raspolaže samo ulaznim podacima (bez informacije o željenom izlazu), čime se algoritam pušta da sam otkrije model u podacima. Primeri nenadgledanog učenja su klasterizacija podataka (eng. *clustering*) i detekcija nepravilnosti u podacima tj. noviteta (eng. *novelty detection*). Kombinacija prethodne dve metode učenja predstavlja tzv. polu-nadgledani metod učenja (*semi-supervised*

learning), kod koga je željeni izlaz modela poznat samo za jedan deo ulaznih podataka iz celokupnog skupa uzoraka. U slučaju *reinforcement learning* metode, postoji interakcija algoritma sa dinamičnim okruženjem. Algoritmu nisu poznati ispravni primeri parova ulaznih-izlaznih podataka, već se učenje vrši na osnovu pozitivne ili negativne povratne informacije po principu nagrade i kazne.

Support Vector Machines pripadaju grupi algoritama sa nadgledanom (kontrolisanom) metodom učenja. U zavisnosti od tipa *learning* problema, moguće je izvršiti najosnovniju podelu SVM algoritama na:

- *Support Vector Classification* (SVC) – SVM za rešavanje problema klasifikacije, i
- *Support Vector Regression* (SVR) – SVM za rešavanje problema regresije.

Ipak, osnovni mehanizmi na kojima se zasniva funkcionisanje SVM algoritama nezavisni su od tipa *learning* problema koji je potrebno rešiti. U opštem slučaju, rad SVM algoritama može se podeliti u dve faze:

- *off-line* fazu (trening fazu, odnosno fazu učenja), i
- *on-line* fazu (test fazu, odnosno fazu izvršavanja).

Tokom *off-line* faze, SVM uči relaciju (funkciju modela) koja postoji između poznatih parova ulazno-izlaznih podataka koji se koriste kao uzorak (*sample data*). Proces pronalaženja statističke zavisnosti, odnosno formiranje opšteg modela u nekom skupu podataka, može predstavljati izrazito nelinearni problem. To je ujedno i slučaj sa pronalaženjem opšte veze između izmerenih parametara radio signala i prostornih koordinata u nekom geografskom okruženju. Jedan od glavnih razloga za odabir SVM kao osnove za razvoj algoritma za pozicioniranje u okviru ovog istraživanja, jesu njegove dobre performanse pri rešavanju nelinearnih problema, kako klasifikacije, tako i regresije. Naime, SVM algoritmi se zasnivaju na primeni kernel metoda [16], koji podrazumeva preslikavanje ulaznih podataka iz originalnog prostora u karakteristični prostor veće dimenzionalnosti (tzv. *feature domen*), u kome se opšte relacije koje postoje između podataka mogu predstaviti linearnim funkcijama. Problem povećanja kompleksnosti modela, usled povećanja dimenzionalnosti, rešava se korišćenjem specijalnih kernel funkcija, odnosno tzv. „kernel trika“ [15, 16]. Kernel trik se sastoji u

tome da se skalarni proizvod slika u karakterističnom prostoru može proračunati primenom kernel funkcija nad odgovarajućim ulaznim podacima iz originalnog prostora. SVM, kao algoritam za pronalaženje funkcije modela, mora da ispuni uslov da se u konačnoj funkciji modela, slike ulaznih podataka javljaju u formi skalarnih proizvoda, a ne zasebno. Ako je taj uslov ispunjen, nije potrebno poznavati same vrednosti slika u karakterističnom prostoru, već se proračun vrši nad originalnim podacima korišćenjem neke od kernel funkcija. Ovaj metod omogućava implicitno korišćenje karakterističnog prostora čija dimenzionalnost teorijski može biti i beskonačna, a da kompleksnost samog proračuna ostane ista kao u originalnom prostoru.

Druga bitna osobina SVM jeste dobro svojstvo generalizacije. Naime, pronalaženje opšteg modela korišćenjem ograničenog skupa trening podataka, podložno je problemu prepodešavanja (*overfitting*). Pod prepodešavanjem modela podrazumeva se da naučena funkcija modela nije dovoljno opšta, već da je karakteristična za korišćeni trening skup podataka. Na taj način formirani model gubi mogućnost generalizacije za nove (do tad „neviđene“) podatke. Bitno svojstvo SVM, koje će detaljnije biti razmatrano u nastavku rada, jeste primena tzv. *structural risk minimization* (SRM) principa [77, 78] za dobijanje modela sa dobrim generalizacionim svojstvima na osnovu ograničenog skupa trening podataka. SRM princip podrazumeva pronalaženje optimalne funkcije modela kroz uspostavljanje ravnoteže između minimiziranja empirijskog rizika i „kapaciteta“ seta funkcija koje neka *learning* mašina može da implementira, tj. tzv. VC (*Vapnik–Chervonenkis*) dimenzija [78, 79]. Tako formulisan optimizacioni problem ima konveksnu formu i zasniva se na rešavanju tzv. kvadratnog problema sa ograničenjima (*constrained quadratic programming problem*), čime je omogućeno da dobijeno rešenje ujedno predstavlja i globalno optimalno rešenje. Postizanje globalnog optimalnog rešenja predstavlja značajnu prednost SVM algoritma u odnosu na neke druge popularne algoritme mašinskog učenja, kao što su recimo veštačke neuralne mreže. Naime, u slučaju ANN mreža, proces optimizacije nije konveksan i “pati” od postojanja višestrukih lokalnih minimuma, pa krajnje rešenje ka kome model iskonvergira ne mora uvek biti i globalno optimalno rešenje.

Nakon pronalaženja opšte relacije u trening skupu podataka, SVM algoritam u *on-line* fazi koristi naučenu funkciju modela kako bi izvršio predikciju izlaza za nove

ulazne podatke. Još jedno bitno svojstvo SVM algoritama jeste pružanje tzv. “proređenog” rešenja (*sparse solution*). Proređeno rešenje podrazumeva da u naučenoj funkciji modela ne figurišu svi podaci trening skupa, već se predikcija novih izlaza vrši samo na osnovu jednog podskupa trening podataka koji se zovu *support* vektori, po kome je i ovaj algoritam mašinskog učenja dobio ime. Korišćenjem samo jednog dela trening skupa za predikciju novih izlaza (tj. *support* vektora), omogućena je brza *online* faza, što SVM algoritme čini pogodnim za primenu u aplikacijama i sistemima koji imaju strožije zahteve po pitanju kašnjenja, kakvi su i sistemi za pozicioniranje.

Fokus ovog poglavlja jeste opšta teorijska analiza *Support Vector Machines* algoritama. Na početku su izložene osnove teorije statističkog učenja na kojoj se zasniva SVM. Nakon toga je dat opis kernel metode kao osnove za rešavanje nelinearnih problema, dok jezgro poglavlja čini teorijska analiza strukture SVM algoritama namenjenih rešavanju nelinearnih problema klasifikacije (SVC) i regresije (SVR).

3.2. OSNOVI TEORIJE STATISTIČKOG UČENJA

Razvoj teorije statističkog učenja počinje u Rusiji, krajem 1960-tih godina [80, 81]. Međutim, do početka 1990-tih godina predstavljala je isključivo teorijsku analizu problema estimacije funkcije modela u nekom raspoloživom skupu podataka. U osnovi, kroz teoriju statističkog učenja definisane su osobine algoritama mašinskog učenja koje im omogućavaju dobra generalizaciona svojstva za nove (do tad „neviđene“) podatke. Praktičnu primenu teorija statističkog učenja dobija sredinom 1990-tih, razvojem novog algoritma baziranog na njoj, nazvanog *Support Vector Machines*, od strane Vapnika i njegovih saradnika iz *AT&T Bell Laboratories* [82-85].

3.2.1. DEFINISANJE PROBLEMA UČENJA

Model učenja na osnovu nekog raspoloživog seta podataka može se opisati korišćenjem sledeće tri komponente:

- 1) generatora slučajnih vektora \mathbf{x} , koji se generišu nezavisno iz fiksne, ali nepoznate raspodele verovatnoće $P(\mathbf{x})$,
- 2) supervizora koji za svaki ulazni vektor \mathbf{x} vraća izlaz y na osnovu uslovne raspodele verovatnoće $P(y|\mathbf{x})$, koja je takođe fiksna ali nepoznata,
- 3) *learning* mašine koja je u stanju da implementira skup funkcija F .

Problem učenja se u datom slučaju može opisati kroz odabir jedne funkcije f iz skupa funkcija F koja vrši predikciju izlaza na najbolji mogući način. Odabir date funkcije se vrši na osnovu trening skupa koji se sastoji od l slučajnih, nezavisnih observacija sa identičnom raspodelom (*independent and identically distributed*, i.i.d), izvedenih na osnovu združene raspodele verovatnoće $P(\mathbf{x}, y) = P(\mathbf{x})P(y|\mathbf{x})$:

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_l, y_l). \quad (3.1)$$

Odabir funkcije koja na najbolji mogući način aproksimira odgovor supervizora vrši se kroz procenu gubitka (*loss function*), odnosno odstupanja $L(y, f(\mathbf{x}))$ između željenog izlaza y (koji generiše supervizor za neki ulazni vektor \mathbf{x}) i izlaza $f(\mathbf{x})$ koji estimira *learning* mašina.

Očekivana vrednost gubitka je data kroz funkciju rizika (eng. *risk function*):

$$R(f) = \int L(y, f(\mathbf{x})) dP(\mathbf{x}, y) \quad (3.2)$$

Cilj je pronaći funkciju f iz klase funkcija F koja minimizira vrednost funkcije rizika (izraz 3.2), pri čemu je združena raspodela verovatnoće $P(\mathbf{x}, y)$ nepoznata, a jedine informacije koje su na raspolaganju su one sadržane u trening skupu.

Forma funkcije gubitka L zavisi od tipa problema koji se rešava. Tako na primer, za slučaj rešavanja problema binarne klasifikacije, izlaz supervizora može imati npr. vrednosti $y=1$ (za slučaj da ulazni vektor \mathbf{x} pripada prvoj klasi) ili $y=-1$ (za slučaj da ulazni vektor \mathbf{x} pripada drugoj klasi). Funkcija gubitka u datom slučaju ima formu:

$$L(y, f(\mathbf{x})) = \begin{cases} 0 & \text{if } y = f(\mathbf{x}) \\ 1 & \text{if } y \neq f(\mathbf{x}) \end{cases} \quad (3.3)$$

Za datu funkciju gubitka, funkcija rizika (izraz 3.2) daje vrednost verovatnoće greške klasifikacije. Cilj u datom slučaju jeste pronaći funkciju modela f koja će

minimizirati izraz 3.2, odnosno verovatnoću pogrešne klasifikacije, u situaciji kada nije poznata združena verovatnoća $P(\mathbf{x}, y)$, ali je poznat uzorak trening podataka (empirijski podaci).

U slučaju rešavanja problema regresije, izlaz supervizora može biti bilo koja realna vrednost. Često korišćen oblik jeste kvadratna funkcija gubitka:

$$L(y, f(\mathbf{x})) = (y - f(\mathbf{x}))^2 \quad (3.4)$$

Tada se rešavanje problema regresije svodi na estimiranje funkcije f koja minimizira izraz 3.2, u situaciji kada nije poznata združena verovatnoća $P(\mathbf{x}, y)$, ali je poznat uzorak trening podataka.

3.2.1. METOD MINIMIZIRANJA EMPIRIJSKOG RIZIKA

Kako bi se minimizirala funkcija rizika data izrazom 3.2, u uslovima kada združena raspodela verovatnoće $P(\mathbf{x}, y)$ nije poznata, najčešće se koristi princip zamene očekivanog rizika sa empirijskom procenom:

$$R_{emp}(f) = \frac{1}{l} \sum_{i=1}^l L(y_i, f(\mathbf{x}_i)) \quad (3.5)$$

Proces pronalaženja funkcije f iz neke klase funkcija F , koja minimizira $R_{emp}(f)$ predstavlja metod minimiziranja empirijskog rizika (*Empirical Risk Minimization*, ERM). Za slučaj npr. prethodno spomenute kvadratne funkcije gubitka (izraz 3.4), ERM metod se svodi na metod najmanjeg kvadrata (*least square method*).

Kako empirijski rizik predstavlja samo aproksimaciju stvarnog rizika, osnovni aspekti teorije statističkog učenja bave se pitanjima konzistencije procesa učenja (odnosno konvergencije ERM metoda ka stvarnom minimalnom riziku), brzine konvergencije i kontrolisanja brzine konvergencije (odnosno procesa generalizacije neke *learning* mašine) [77].

3.2.2. TEORIJA KONZISTENCIJE PROCESA UČENJA

Teorija konzistencije predstavlja asimptotsku teoriju koja definiše potrebne i dovoljne uslove za konvergenciju rešenja dobijenog ERM metodom ka najboljem mogućem rešenju, sa povećanjem broj opservacija, odnosno veličine trening skupa [77].

Neka je $L(y, f(\mathbf{x}))$ set funkcija gubitaka definisanih za prostor funkcija F , koje imaju ograničen gubitak za združenu verovatnoću $P(\mathbf{x}, y)$:

$$A \leq \int L(y, f(\mathbf{x})) dP(\mathbf{x}, y) \leq B, \quad \forall f \in F. \quad (3.6)$$

Da bi ERM princip bio konzistentan, potreban i dovoljan uslov jeste da empirijski rizik $R_{emp}(f)$ ravnomerno (uniformno) konvergira ka stvarnom riziku $R(f)$, za dati set funkcija $L(y, f(\mathbf{x}))$ [77]:

$$\lim_{l \rightarrow \infty} P \left\{ \sup_{f \in F} (R(f) - R_{emp}(f)) > \varepsilon \right\} = 0, \quad \forall \varepsilon > 0 \quad (3.7)$$

U izrazu 3.7, P predstavlja standardnu oznaka za verovatnoću a sup za supremum. Ovaj tip konvergencije naziva se još konvergencija sa jedne strane (*one-sided convergence*). Prethodno navedena teorema podrazumeva analizu tzv. najgoreg slučaja. Naime, neophodan (a ne samo dovoljan) uslov konvergencije jeste da odstupanje za slučaj „najgore“ funkcije iz skupa funkcija F , konvergira ka nuli:

$$\Delta(f_{worst}) = \sup_{f \in F} (R(f) - R_{emp}(f)). \quad (3.8)$$

Uslov za uniformnu konvergenciju (izraz 3.7) moguće je opisati preko koncepta entropije seta funkcija $L(y, f(\mathbf{x}))$ na skupu od l uzoraka [77].

Neka je set funkcija gubitaka $L(y, f(\mathbf{x}))$ ograničen, $A \leq L(y, f(\mathbf{x})) \leq B$, $f \in F$. Korišćenjem datog seta funkcija i trening podataka, moguće je formirati set l -dimenzionih vektora:

$$q(f) = (L(y_1, f(\mathbf{x}_1)), L(y_2, f(\mathbf{x}_2)), \dots, L(y_l, f(\mathbf{x}_l))), f \in F \quad (3.9)$$

Set vektora $q(f), f \in F$ ima minimalnu ε -mrežu (ε -net) od N elemenata, ako postoji N ($N = N^F(\varepsilon; (\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_l, y_l))$) vektora $q(f_1), q(f_2), \dots, q(f_N)$, takvih

da se za bilo koji vektor $q(f^*), f^* \in F$ može u datoj grupi od N vektora pronaći jedan koji se nalazi u ε -blizini tog $q(f^*)$ vektora (u datom metričkom sistemu). Radi pojednostavljenja izraza u nastavku teksta biće korišćena skraćena notacija za parove podatke iz trening skupa $z_i = (\mathbf{x}_i, y_i)$.

Logaritam slučajne vrednosti $N = N^F(\varepsilon; z_1, z_2, \dots, z_l)$ predstavlja slučajnu VC (*Vapnik–Chervonenkis*) entropiju seta funkcija $A \leq L(y, f(\mathbf{x})) \leq B$ na uzorku od l trening podataka:

$$H^F(\varepsilon; z_1, z_2, \dots, z_l) = \log \{N^F(\varepsilon; z_1, z_2, \dots, z_l)\} \quad (3.10)$$

Očekivana vrednost slučajne VC entropije seta funkcija $A \leq L(y, f(\mathbf{x})) \leq B$ na uzorku od l trening podataka data je izrazom:

$$H^F(\varepsilon; l) = E(H^F(\varepsilon; z_1, z_2, \dots, z_l)) \quad (3.11)$$

Konačno, za slučaj ograničene funkcije gubitka, empirijski rizik uniformno konvergira ka stvarnom riziku:

$$\lim_{l \rightarrow \infty} P \left\{ \sup_{f \in F} (R(f) - R_{emp}(f)) > \varepsilon \right\} = 0, \quad \forall \varepsilon > 0,$$

ako je ispunjen sledeći potreban i dovoljan uslov [77]:

$$\lim_{l \rightarrow \infty} \frac{H^F(\varepsilon; l)}{l} = 0, \quad \forall \varepsilon > 0. \quad (3.12)$$

Uslov dat izrazom 3.12 predstavlja potreban i dovoljan uslov za konzistenciju EMR principa, ali ne garantuje brzu asimptotsku konvergenciju.

Dovoljan uslov za brzu konvergenciju ERM metoda definisan je sledećim izrazom [77]:

$$\lim_{l \rightarrow \infty} \frac{H_{ann}^F(\varepsilon; l)}{l} = 0, \quad \forall \varepsilon > 0, \quad (3.13)$$

gde je $H_{ann}^F(\varepsilon; l)$ tzv. *annealed* VC entropija:

$$H_{ann}^F(\varepsilon; l) = \log E(N^F(\varepsilon; z_1, z_2, \dots, z_l)) \quad (3.14)$$

Na kraju, neophodno je definisati i uslov pod kojim je ERM proces konzistentan i brzo konvergira, nezavisno od tipa problema koji je potrebno rešiti (odnosno za različite združene verovatnoće $P(\mathbf{x}, y)$). Izraz dat u nastavku definiše potreban i dovoljan uslov konzistencije ERM metode za bilo koju združenu verovatnoću $P(\mathbf{x}, y)$ [77]:

$$\lim_{l \rightarrow \infty} \frac{G^F(\varepsilon; l)}{l} = 0, \quad \forall \varepsilon > 0, \quad (3.15)$$

gde je $G^F(\varepsilon; l)$ tzv. funkcija rasta (*growth function*):

$$G^F(\varepsilon; l) = \log \sup_{z_1, \dots, z_l} N^F(\varepsilon; z_1, z_2, \dots, z_l) \quad (3.16)$$

3.2.3. VC (VAPNIK–CHERVONENKIS) DIMENZIJE

Primena ERM metoda je opravdana u slučaju kad se raspolaže velikim brojem trening uzoraka. Međutim, u slučaju ograničenog (malog) trening skupa, mala vrednost empirijskog rizika ne garantuje uvek malu vrednost stvarnog rizika. Naime, kad *learning* mašina raspolaže malim brojem uzoraka, raste verovatnoća da naučena funkcija modela ne bude dovoljno opšta, već da oslikava relaciju koja je specifična za dati skup podataka. Prepodešavanje modela na trening skup (*overfitting*) dovodi do gubitka svojstva generalizacije.

U opštem slučaju, za neki *learning* problem i ograničen skup trening podataka, najbolja generalizaciona svojstva moguće je ostvariti uspostavljanjem balansa između tačnosti dobijene na datom (ograničenom) skupu podataka i „kapaciteta“ *learning* mašine, odnosno sposobnosti mašine da pronađe funkciju modela bez greške u bilo kom trening skupu [77]. Pojam kapaciteta odnosi se u stvari na „kapacitet“ seta funkcija koje može neka *learning* mašina da implementira. Slikovito objašnjenje „kapaciteta“ *learning* mašine dao je Burges [78]: „U slučaju velikog kapaciteta, *learning* mašina se ponaša kao botaničar sa fotografskim pamćenjem koji, kada mu se predstavi novo stablo, zaključuje da to nije drvo jer ima različiti broj listova od bilo čega što je ranije video. Sa druge strane, *learning* mašina sa malim kapacitetom ponaša se kao lenji

botaničar, koji će klasifikovati nešto kao drvo samo zato što je zeleno.“ U oba slučaja, *learning* mašina nema sposobnost generalizacije.

Merilo kapaciteta seta funkcija F prvi su formulisali *Vapnik* i *Chervonenkis* [79] kroz definiciju tzv. VC (*Vapnik-Chervonenkis*) dimenzija. Koncept VC dimenzija zasnovan je na zavisnosti funkcije rasta G od veličine trening skupa l [77]. Naime, svaka funkcija rasta zadovoljava ili sledeću jednakost:

$$G^F(l) = l \log 2 \quad (3.17)$$

ili je ograničena sledećom nejednakošću:

$$G^F(l) < h \left(\log \frac{l}{h} + 1 \right) . \quad (3.18)$$

Parametar h je ceo broj za koji važi:

$$G^F(h) = h \log 2$$

$$G^F(h+1) \neq (h+1) \log 2 .$$

Drugim rečima, funkcija rasta može biti ili linearna funkcija od parametra l ili ograničena logaritamskom funkcijom. Za neki set funkcija se kaže da ima beskonačnu VC dimenziju ako je funkcija rasta datog seta linearna. U suprotnom, ako je funkcija rasta ograničena logaritamskom funkcijom, VC dimenzija datog seta funkcija ima konačnu vrednost koja je jednaka parametru h .


Konačnost VC dimenzija seta funkcija koje implementira *learning* mašina predstavlja potreban i dovoljan uslov konzistencije ERM metode za bilo koju združenu verovatnoću $P(\mathbf{x}, y)$. Dodatno, konačnost VC dimenzija garantuje i brzu konvergenciju empirijskog rizika ka stvarnom riziku.

Ekvivalentna definicija VC dimenzija, za primer seta indikatorskih funkcija za rešavanje problema klasifikacije (tj. razdvajanje ulaznog skupa vektora $\{\mathbf{x}_i\}_{i=1}^l$ na dva podskupa: $f(\mathbf{x}_i) = -1$ ili $f(\mathbf{x}_i) = 1$), data je u nastavku.


VC dimenzija seta funkcija jednaka je h , ako i samo ako postoji skup od h vektora (podataka) $\{\mathbf{x}_i\}_{i=1}^h$ takvih da mogu biti razdvojeni (klasifikovani) na svih 2^h mogućih načina, a da pri tom ne postoji skup od p vektora $\{\mathbf{x}_i\}_{i=1}^p$, za $p > h$, koji zadovoljava taj

isti uslov. S druge strane, ako za bilo koju vrednost m , postoji m vektora koji zadovoljavaju gore navedeni uslov, onda dati set funkcija ima beskonačnu VC dimenziju. Slika 3.1 predstavlja ilustraciju 3 tačke u R^2 ravni, koje mogu biti razdvojene linearnim indikatorskim funkcijama na bilo koji od 2^3 načina. S druge strane, već u slučaju postojanja 4 tačke, nije moguće izvršiti njihovo razdvajanje na svih 2^4 načina pomoću linearnih indikatorskih funkcija (slika 3.2). Drugim rečima, set linearnih indikatorskih funkcija u dvodimenzionom prostoru ima VC dimenziju 3.

Bitno je napomenuti da set linearnih funkcija u n -dimenzionom prostoru (kako indikatorskih, tako i realnih), ima VC dimenziju $n+1$ [77].



Slika 3.1. Ilustracija VC dimenzija - 3 tačke u R^2 ravni [78]



Slika 3.2. Ilustracija VC dimenzija – 4 tačke u R^2 ravni

Uvođenje VC dimenzije kao parametra za kontrolisanje sposobnosti generalizacije u procesu učenja, predstavlja osnovu za konstrukciju metode za minimiziranje rizika

koja se može uspešno primeniti u slučaj ograničenog (malog) trening skupa - metode za minimiziranje strukturalnog rizika (*Structural Risk Minimization*, SRM).

3.2.4. METOD MINIMIZIRANJA STRUKTURALNOG RIZIKA

Metod minimiziranja strukturalnog rizika (SRM) zasniva se na uspostavljanju ravnoteže između dva oprečna faktora: vrednosti empirijskog rizika i kapaciteta seta funkcija koje neka *learning* mašina može da implementira [77]. Formulacija SRM metode data je u nastavku.

Neka je za set funkcija F koje može da implementira *learning* mašina, set funkcija gubitaka $L(y, f(\mathbf{x}))$ ograničen, $0 \leq L(y, f(\mathbf{x})) \leq B$, $f \in F$. Tada, za date vrednosti gubitka, važi sledeća nejednakost sa verovatnoćom $1 - \eta$ [77, 78]:

$$R(f) \leq R_{emp}(f) + \sqrt{\frac{h \left(\log\left(\frac{2l}{h}\right) + 1 \right) - \log\left(\frac{\eta}{4}\right)}{l}}, \quad (3.19)$$

gde h predstavlja VC dimenziju seta funkcija F , l veličinu trening skupa, a $0 \leq \eta \leq 1$. Desna strana nejednakosti 3.19 predstavlja gornju granicu rizika. Deo izraza 3.19 koji se nalazi pod korenskom funkcijom označava se kao *VC confidence*.

Za slučaj velike vrednosti l/h (veliki trening skup), *VC confidence* deo ima malu vrednost, odnosno vrednost empirijskog rizika postaje bliska vrednosti stvarnog rizika. U navedenom slučaju, mala vrednost empirijskog rizika garantuje malu vrednost stvarnog rizika, što opravdava primenu ERM metode kada na raspolaganju stoji veliki skup trening uzoraka. U suprotnom, za male vrednosti l/h , mala vrednost empirijskog rizika ne garantuje malu vrednost stvarnog rizika. U datom slučaju neophodno je minimizirati empirijski rizik kontrolišući pri tom kapacitet *learning* mašine.

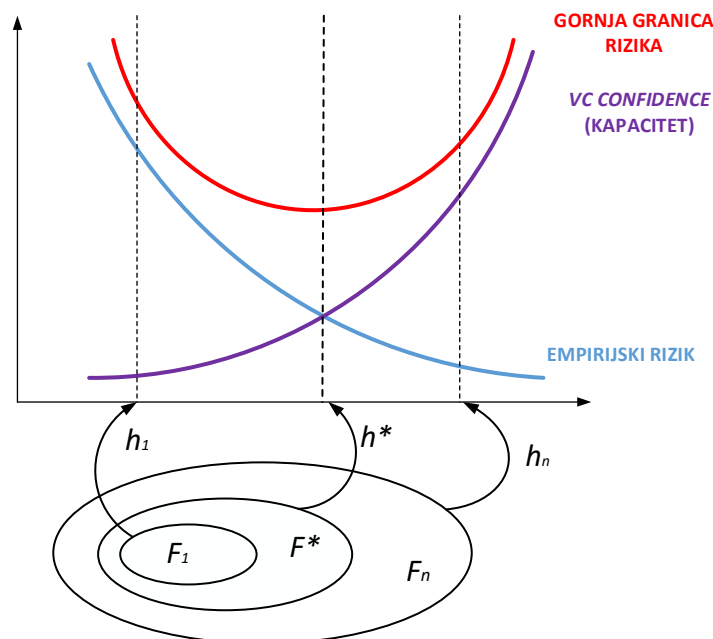
Može se primetiti da *VC confidence* zavisi od odabrane klase (seta) funkcija, dok vrednosti stvarnog i empirijskog rizika zavise od konkretne funkcije modela f odabrane tokom procesa učenja. Cilj je dakle, pronaći podskup seta funkcija F , koji minimizira gornju granicu rizika.

Kako vrednost VC dimenzije h predstavlja ceo broj, nije moguće organizovati pretragu podskupova tako da vrednost h „glatko“ (*smoothly*) varira. Umesto toga uveden je strukturalni princip, koji podrazumeva da se celokupni set funkcija F podeli na ugneždene (*nested*) podskupove F_k , tako da je $F_1 \subset F_2 \dots \subset F_k \dots$ (slika 3.3).

Dobijena struktura smatra se prihvatljivom (*admissible structure*) ako elementi strukture F_k zadovoljavaju sledeće uslove [77]:

- VC dimenzija h_k svakog podskupa funkcija F_k ima konačnu vrednost, odnosno važi da je $h_1 < h_2 \dots < h_k \dots$ (pri čemu VC dimenzija celokupnog seta funkcija F može biti beskonačna).
- Za svaki podskup funkcija F_k , vrednosti funkcija gubitaka $L(y, f_k(\mathbf{x}))$ su ograničene, $0 \leq L(y, f_k(\mathbf{x})) \leq B$, $f_k \in F_k$.

SRM princip se sastoji iz pronalaženja podskupa funkcija F_k (tj. elementa strukture) i određene funkcije f_k' iz datog podskupa, za koje gornja granica rizika (desni deo izraza 3.19) ima minimalnu vrednost (slika 3.3). SRM princip u stvari podrazumeva kompromis između kvaliteta aproksimacije i kompleksnosti odabrane funkcije za aproksimaciju (tj. funkcije modela).



Slika 3.3 Ilustracija SRM metode


U opštem slučaju, SRM princip može se jednostavno primeniti kroz treniranje serije *learning* mašina, gde svaka *learning* mašina može da implementira jedan podskup funkcija. U datom slučaju, cilj treniranja svake *learning* mašine postaje minimiziranje empirijskog rizika, a optimalno istrenirana mašina postaje ona za koju suma emirijskog rizika i *VC confidence* ima minimalnu vrednost.

3.3.REŠAVANJE NELINEARNIH PROBLEMA PRIMENOM KERNEL METODE

Pronalaženje funkcije modela u nekom skupu podataka, u velikom broju slučajeva odgovara rešavanju nelinearnog problema. U nastavku poglavlja dat je pregled tzv. kernel metode [16], na kojoj se bazira i SVM kao jedan od algoritama mašinskog učenja. Ovakav pristup za pronalaženje funkcije modela u nekom skupu podataka, u opštem slučaju, podrazumeva da se originalni podaci najpre preslikavaju u pogodno izabrani karakteristični (*feature*) prostor, a zatim da se u tom prostoru primenjuju algoritmi koji se baziraju na linearnoj algebri, geometriji ili statistici.

U opštem slučaju, algoritami za pronalaženje modela u podacima koji su bazirani na kernel metodama sastoje se iz dva dela: preslikavanja podataka iz originalnog u karakteristični prostor i nekog *learning* algoritma (tj. algoritma učenja), koji treba da izabere funkciju iz nekog predefinisnog skupa linearnih funkcija u tom prostoru, koja najbolje opisuje model u podacima. Na slici 3.4 ilustrovan je osnovni koncept kernel metoda: funkcijom mapiranja ϕ podaci se iz originalnog prostora preslikavaju u karakterističan prostor u kome nelinearni model (obrazac) u podacima postaje linearan.

Postoje dva razloga zašto bi jedan ovakav pristup trebalo da bude uspešan. Pre svega, detektovanje linearnih relacija je problem koji je već decenijama bio u fokusu oblasti kao što su mašinsko učenje i statistika, a postojeći algoritmi su efikasni i dobro razumljivi. Drugo, korišćenjem kernel funkcija, odnosno ranije pomenutog „kernel trika“ [15, 16], omogućeno je predstaviti linearne relacije veoma efikasno u visoko dimenzionim karakterističnim prostorima, zadržavajući pri tom kompleksnost proračuna kao u originalnom prostoru.



Slika 3.4 Osnovni koncept kernel metode [16]

Osnovni aspekti kernel pristupa mogu se sumirati na sledeći način:

- Ulazni podaci se preslikavaju u vektorski prostor, obično veće dimenzionalnosti, koji se naziva karakteristični prostor.
- Linearne relacije se pretražuju među slikama originalnih podataka u karakterističnom prostoru.
- Algoritam je konstruisan na takav način da koordinate slika originalnih podataka u karakterističnom prostoru nije neophodno poznavati, već samo njihove skalarne proizvode.
- Skalarni proizvod u karakterističnom prostoru može se proračunati dosta efikasno, zahvaljujući kernel funkcijama [16], koje operišu samo sa originalnim podacima.

3.3.1. MODULARNOST ALGORITAMA MAŠINSKOG UČENJA BAZIRANIH NA KERNEL METODI

Dizajn algoritama mašinskog učenja koji se baziraju na kernel metodi, može se sagledati kroz postojanje dva, međusobno nezavisna, koraka (modula):

- preslikavanje originalnog skupa podataka u karakteristični prostor,

- pronalaženje relacija između slika podataka u karakterističnom prostoru i njihovo predstavljanje korišćenjem linearnih funkcija.

Prvi korak, uvođenje karakterističnog prostora, vrši se implicitno, kroz odabir adekvatne kernel funkcije. Kernel funkcija se može definisati kao funkcija k koja za svako $\mathbf{x}_i \in X, (i=1..l)$ zadovoljava:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) \quad (3.20)$$


gde je ϕ funkcija mapiranja kojom se vrši preslikavanje originalnog ulaznog prostora X u karakteristični prostor X' :

$$\phi : \mathbf{x} \in X \rightarrow \phi(\mathbf{x}) \in X' \quad (3.21)$$

Drugi korak jeste dizajn algoritma za pronalaženje relacije u podacima koji su preslikani u proizvoljan karakterističan prostor. Uslov koji dati algoritam mora da ispuni jeste da se slike podataka u konačnoj (naučenoj) funkciji modela javljaju isključivo u formi skalarnih proizvoda, a ne zasebno. Ako je taj uslov ispunjen, onda nije potrebno poznavati koordinate slika u karakterističnom prostoru, već se skalarni proizvod slika u karakterističnom prostoru može jednostavno proračunati primenom kernel funkcije nad odgovarajućim podacima u originalnom prostoru (izraz 3.20). Time je omogućena efikasna primena algoritma u visoko dimenzionim prostorima, koji teorijski mogu biti i beskonačni.

Izbor tipa kernel funkcije, odnosno karakterističnog prostora, zavisi od podataka koji se analiziraju. S druge strane, nad podacima preslikanim u karakterističan prostor mogu se primeniti različiti tipovi algoritama za pronalaženje modela, u zavisnosti od tipa problema koji se želi rešiti: problem regresije, klasifikacije, klasterizacije ili detekcije nepravilnosti u podacima (*novelty detection*). Isto važi i u suprotnom smeru; određeni algoritam za pronalaženje relacija može se kombinovati sa bilo kojom kernel funkcijom i na taj način posredno primeniti na bilo koji tip podataka. Opisano svojstvo modularnosti kernel metoda omogućava uspešno rešavanje širokog opsega problema. Usled toga je i SVM našao uspešnu primenu na različim poljima: kategorizacija teksta, prepoznavanje i klasifikacija slika, rukopisa i govora, primenu u medicini i biologiji (npr. predikcija strukture proteina, predikcija uticaja hemoterapije na tok bolesti), itd.

Na slici 3.5 data je ilustracija modularne strukture SVM algoritma kao primera algoritma mašinskog učenja baziranog na kernel metodi. U prvom koraku, kernel funkcija obrađuje ulazne podatke (implicitno uvodi karakteristični prostor) i kao rezultat vraća kernel matricu, odnosno matricu skalarnih proizvoda slika podataka u karakterističnom prostoru. Algoritam za analizu modela u podacima koristi ovu matricu kako bi pronašao linearnu funkciju modela. Tako dobijena (naučena) funkcija modela se u *on-line* fazi koristi za predikciju izlaza za nove, do tad neviđene, ulazne podatke.



Slika 3.5 Modularna struktura SVM algoritma

3.3.2. KERNEL FUNKCIJE

Kernel funkcije igraju važnu ulogu u razvoju algoritama za pronalaženje modela u podacima. Da bi se u potpunosti iskoristile prednosti ovog pristupa, potrebno je definisati skup validnih kernel funkcija, zajedno sa mehanizmom za njihovu konstrukciju i prilagođavanje specifičnostima podataka koji se razmatraju.

Najjednostavniji primer kernel funkcije jeste linearna kernel funkcija, koja se dobija za slučaj da funkcija preslikavanje ϕ predstavlja identitet (odnosno, kada su originalni i karakteristični prostor identični). U datom slučaju, za svako $\mathbf{x}_i \in X$ i $\phi(\mathbf{x}_i) = \mathbf{x}_i$, ($i = 1 \dots l$), linearna kernel funkcija ima formu:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (3.22)$$

Korišćenje linearne *kernel* funkcije odgovara osnovnoj formi algoritma za pretragu linearnih relacija u originalnom domenu, jer su u ovom slučaju originalni i karakteristični domen identični.

Složeniji tip kernel funkcije jeste polinomska:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle^d, \quad (3.23)$$

gde parametar d predstavlja stepen polinomske kernel funkcije. U nastavku je dat primer polinomske kernel funkcije drugog reda. Za slučaj n -dimenzionog originalnog prostor $X \subseteq R^n$, kernel funkcija data izrazom:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle^2 \quad (3.24)$$

odgovara sledećem preslikavanju:

$$\phi: \mathbf{x}_i \rightarrow \phi(\mathbf{x}_i) = (x_p^i x_r^i)_{p,r=1}^n \in X' = R^{n^2} \quad (3.25)$$

s obzirom da je

$$\begin{aligned} \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle &= \left\langle (x_p^i x_r^i)_{p,r=1}^n, (x_p^j x_r^j)_{p,r=1}^n \right\rangle = \sum_{p,r} x_p^i x_r^i x_p^j x_r^j \\ &= \sum_p x_p^i x_p^j \sum_r x_r^i x_r^j = \langle \mathbf{x}_i, \mathbf{x}_j \rangle^2 \end{aligned} \quad (3.26)$$

Kroz izraz 3.26 dat je primer kako se skalarni proizvod slika u karakterističnom prostoru može izračunati bez eksplicitnog proračuna koordinata slika. Kernel funkcije smanjuje kompleksnost proračuna skalarnog proizvoda u karakterističnom prostoru, čineći na taj način kernel algoritme efikasnim u visoko dimenzionim karakterističnim prostorima.

Ako se uporede linearna i polinomska kernel funkcija, jasno je da se polinomska može jednostavno izvesti iz linearne kernel funkcije. Jedan od najvažnijih principa, kada je konstrukcija kernel funkcija u pitanju, podrazumeva da se kompleksnije kernel funkcije mogu konstruisati korišćenjem jednostavnijih. Takve transformacije obično zahtevaju određeni broj dodatnih operacija, ali je njihov uticaj ipak zanemarljiv u odnosu na prednosti koje te novodobijene kernel funkcije mogu imati. Naime, po ceni samo nekoliko dodatnih operacija u proračunu, moguće je konstruisati kernel funkcije koje odgovaraju karakterističnim prostorima čak beskonačne dimenzionalnosti.

U nastavku poglavlja biće opisani načini konstruisanja kernel funkcija. Međutim, prvi korak jeste definisanje osobina koje mora posedovati neka funkcija kako bi se mogla smatrati validnom kernel funkcijom. Pri tom, potrebno je definisati jednostavan način za testiranje validnosti neke potencijalne kernel funkcije, koji ne zahteva eksplicitnu konstrukciju funkcije mapiranja ϕ .

Osobine validne kernel funkcije

Validnost neke kernel funkcije može se ispitati kroz analizu tzv. *Gram*-ove matrice, koja sadrži proračune ispitivane kernel funkcije nad svim parovima ulaznih trening podataka [16].

Za dati skup vektora $S = \{\mathbf{x}_1, \dots, \mathbf{x}_l\}$, *Gram*-ova matrica se definiše kao $l \times l$ matrica \mathbf{G} , čiji su elementi $\mathbf{G}_{ij} = \langle \mathbf{x}_i, \mathbf{x}_j \rangle$. Ako se kernel funkcija k , kojoj odgovara preslikavanje ϕ , koristi za proračun skalarnog proizvoda slika u karakterističnim prostoru, onda pridružena *Gram*-ova matrica sadrži sledeće elemente [16]:

$$\mathbf{G}_{ij} = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle = k(\mathbf{x}_i, \mathbf{x}_j). \quad (3.27)$$

U ovom slučaju *Gram*-ova matrica se najčešće naziva kernel matrica, a označava se sa \mathbf{K} . Standardna notacija za prikazivanje kernel matrice je:

$$\mathbf{K} = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & k(\mathbf{x}_1, \mathbf{x}_2) & \cdots & k(\mathbf{x}_1, \mathbf{x}_l) \\ k(\mathbf{x}_2, \mathbf{x}_1) & k(\mathbf{x}_2, \mathbf{x}_2) & \cdots & k(\mathbf{x}_2, \mathbf{x}_l) \\ \vdots & \vdots & \ddots & \vdots \\ k(\mathbf{x}_l, \mathbf{x}_1) & k(\mathbf{x}_l, \mathbf{x}_2) & \cdots & k(\mathbf{x}_l, \mathbf{x}_l) \end{bmatrix}. \quad (3.28)$$

Data matrica je simetrična, jer važi $\mathbf{K}_{ij} = \mathbf{K}_{ji}$, odnosno $\mathbf{K}' = \mathbf{K}$. Potreban i dovoljan uslov da bi neka funkcija k bila validan kernel jeste da kernel matrica \mathbf{K} , čiji su elementi dati sa $k(\mathbf{x}_i, \mathbf{x}_j)$, bude pozitivna polu-određena matrica [16]. Za neku simetričnu matricu važi da je pozitivna polu-određena, ukoliko su sve njene sopstvene vrednosti ne-negativne. Dokaz ove teoreme može se naći u [16].

Bitno je naglasiti da je navedeni način provere validnosti kernel funkcije važeći za bilo koji tip ulaznih podataka, bilo da su to stringovi, diskretne strukture, slike,

vremenske serije, itd. Pod uslovom da je kernel matrica za neki konačan trening skup podataka pozitivna polu-određena, kernel funkcija će uvek proračunavati skalarnu proizvodnju parova ulaznih podataka preslikanih u neki karakterističan prostor.

Na kraju, potrebno je istaći da se u slučaju algoritama na bazi kernel metoda, kernel matrica ponaša kao informaciona matrica. Naime, u okviru kernel matrice sadržane su sve dostupne informacije o ulaznim podacima koje koristi neki *learning* algoritam za pronalaženje funkcije modela (slika 3.5). Dodatno, algoritmi kontrolisanog učenja, u koje se ubraja i SVM, pored podataka sadržanih u kernel matrici zahtevaju da im se u procesu učenja eksplicitno predaju i željeni izlazni podaci (tj. *target outputs*).

Konstrukcija kernel funkcija

Konstrukcija validne kernel funkcije može se izvršiti na dva načina. Prvi pristup podrazumeva definisanje funkcije mapiranja ulaznih podataka u karakterističan prostor (ϕ), koja se potom koristi za određivanje kernel funkcije na osnovu izraza 3.20:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j).$$

Drugi, češće korišćeni pristup jeste konstruisanje kernel funkcije direktno, bez poznavanja funkcije preslikavanja. U datom slučaju validnost nove kernel funkcije mora biti naknadno proverena. Drugim rečima, nova kernel funkcija mora odgovarati skalarnom proizvodu slika originalnih podataka u nekom proizvoljnom karakterističnom prostoru. Kao što je pomenuto u prethodnom poglavlju, validnost kernel funkcije može se proveriti ispitivanjem njene kernel matrice, formirane proračunom kernel funkcije nad svim parovima trening skupa podataka. Ako je dobijena kernel matrica pozitivna, polu-određena, odabrana funkcija predstavlja validnu kernel funkciju.

Najčešći i najjednostavniji pristup pri konstrukciji novih kernel funkcija jeste nadogradnja prostijih kernel funkcija [15,16]. U nastavku su dati primeri dozvoljenih operacija nad jednom ili više kernel funkcija, koje održavaju osobinu pozitivne polu-određenosti rezultujuće kernel matrice. U tom slučaju se kaže da je klasa kernel funkcija zatvorena u odnosu na ove operacije. Dakle, dokle god se može garantovati da će rezultat operacije nad jednom ili više postojećih kernel funkcija biti pozitivna polu-

određena kernel matrica, podaci će sigurno biti preslikani u neki novi karakteristični prostor, iako je originalni karakteristični prostor transformisan datim operacijama.

Primeri operacija nad postojećim kernel funkcijama $k_1(\mathbf{x}_i, \mathbf{x}_j)$ i $k_2(\mathbf{x}_i, \mathbf{x}_j)$ koji garantuju validnost novodobijene kernel funkcije k , dati su u nastavku [15,16]:

- $k(\mathbf{x}_i, \mathbf{x}_j) = ck_1(\mathbf{x}_i, \mathbf{x}_j)$
- $k(\mathbf{x}_i, \mathbf{x}_j) = f(\mathbf{x}_i)k_1(\mathbf{x}_i, \mathbf{x}_j)f(\mathbf{x}_j)$
- $k(\mathbf{x}_i, \mathbf{x}_j) = q(k_1(\mathbf{x}_i, \mathbf{x}_j))$
- $k(\mathbf{x}_i, \mathbf{x}_j) = \exp(k_1(\mathbf{x}_i, \mathbf{x}_j))$
- $k(\mathbf{x}_i, \mathbf{x}_j) = k_1(\mathbf{x}_i, \mathbf{x}_j) + k_2(\mathbf{x}_i, \mathbf{x}_j)$
- $k(\mathbf{x}_i, \mathbf{x}_j) = k_1(\mathbf{x}_i, \mathbf{x}_j)k_2(\mathbf{x}_i, \mathbf{x}_j)$
- $k(\mathbf{x}_i, \mathbf{x}_j) = k_3(\phi(\mathbf{x}_i), \phi(\mathbf{x}_j))$
- $k(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{A} \mathbf{x}_j$

gde je $c > 0$ konstanta, $f(\cdot)$ proizvoljna realna funkcija, $q(\cdot)$ polinomska funkcija sa ne-negativnim koeficijentima, $\phi(\mathbf{x}_i)$ funkcija mapiranja u karakterističan prostor R^n , $k_3(\cdot, \cdot)$ je validna kernel funkcija u karakterističnom prostoru R^n , \mathbf{A} je simetrična, pozitivna, polu-određena matrica.

Primeri kernel funkcija

U nastavku teksta dat je pregled najčešće korišćenih tipova kernel funkcija:

- Linearna: $k(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle = \mathbf{x}_i^T \mathbf{x}_j$
- Polinomska: $k(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j + c)^d$, $\gamma > 0, c \geq 0$
- *Radial Basis Function* (RBF) ili Gausova:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\gamma}\right), \gamma > 0$$
- *Laplacian* ili eksponencijalna: $k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|}{\gamma}\right), \gamma > 0$

- ANOVA RBF: $k(\mathbf{x}_i, \mathbf{x}_j) = \sum_{k=1}^n \exp\left(-\frac{(x_{i,k} - x_{j,k})^2}{\gamma}\right), \gamma > 0$
- Logaritamska: $k(\mathbf{x}_i, \mathbf{x}_j) = -\log\left(\|\mathbf{x}_i - \mathbf{x}_j\|^d + 1\right)$
- Sigmoid: $k(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^T \mathbf{x}_j + c), \gamma > 0, c \geq 0$
- Generalized T- Student: $k(\mathbf{x}_i, \mathbf{x}_j) = \frac{1}{1 + \|\mathbf{x}_i - \mathbf{x}_j\|^d}$
- Cauchy: $k(\mathbf{x}_i, \mathbf{x}_j) = \frac{1}{1 + \frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma^2}}$
- SPLINE:

$$k(\mathbf{x}_i, \mathbf{x}_j) = 1 + \mathbf{x}_i \mathbf{x}_j + \mathbf{x}_i \mathbf{x}_j \min(\mathbf{x}_i, \mathbf{x}_j) - \frac{\mathbf{x}_i + \mathbf{x}_j}{2} \min(\mathbf{x}_i, \mathbf{x}_j)^2 + \frac{1}{3} \min(\mathbf{x}_i, \mathbf{x}_j)^3.$$

3.4.SUPPORT VECTOR MACHINES ZA REŠAVANJE PROBLEMA KLASIFIKACIJE I REGRESIJE

Kao što je već pomenuto, teorija statističkog učenja se nalazi u osnovi razvoja *Support Vector Machines* algoritama namenjenih otkrivanju modela u skupovima podataka [77]. SVM koristi princip minimiziranja strukturalnog rizika (SRM metod) za dobijanje modela sa dobrim generalizacionim svojstvima na osnovu ograničenog skupa trening podataka. U slučaju SVM, optimizacioni problem je konveksan (slika 3.3) čime se garantuje da rešenje ka kome model iskonvergira ujedno predstavlja i globalno optimalno rešenje. Pri tom, pronalaženje nelinearne funkcije modela u podacima vrši se kroz implicitno mapiranje originalnih podataka u karakterističan prostor, korišćenjem kernel funkcija. Time se postiže da rešavanje optimizacionog problema odgovara pronalaženju linearne funkcije modela u karakterističnom prostoru, dok kompleksnost proračuna ostaje ista kao u originalnom.

U okviru ovog poglavlja biće predstavljene dve forme SVM namenjene rešavanju problema klasifikacije (*Support Vector Classification, SVC*) i regresije (*Support Vector Regression, SVR*).

U literaturi, standardna formulacija SVC algoritma odnosi se na slučaj rešavanja problema binarne klasifikacije [15, 16]. Binarni SVC algoritam rešava problem pronalaženja optimalne hiper-ravni koja razdvaja trening skup bez greške na dve nepreklapajuće klase u slučaju linearno separabilnih trening podataka (tzv. *hard-margin* klasifikator), ili uz dozvolu određenog nivoa odstupanja, tj. grešaka, u slučaju linerano neseperabilnih podataka (tzv. *soft-margin* klasifikator). U nastavku poglavlja dat je opis ta dva slučaja, kao osnova za razumevanje funkcionisanja SVC algoritma. S druge strane, u slučaju postojanja više klasa, neophodno je izvršiti određene modifikacije SVC algoritma kako bi se prilagodio rešavanju tzv. *multiclass* problema [86,87]. Modifikacije SVC algoritma koje su izvršene u okviru ovog istraživanja biće detaljno opisane u narednim poglavljima koja se bave praktičnom realizacijom algoritma za pozicioniranje mobilnih korisnika baziranog na SVM.

Drugi tip zadatka koji je moguće uspešno rešiti korišćenjem SVM jeste problem regresije, koji se odnosi na učenje realne funkcije koja modeluje vezu između ulaznih i izlaznih podataka, na osnovu konačnog trening skupa podataka. SVR algoritam može se posmatrati kao dalja transformacija SVC algoritma koji za izlaz daje realne, a ne diskretne vrednosti.

3.4.1. HARD-MARGIN KLASIFIKATOR

Neka je u opštem slučaju dat trening skup koji se sastoji od l parova $S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\} \subseteq (X \times Y)^l$, $X \subseteq R^n$ i $Y \subseteq R$. Vektor \mathbf{x}_i predstavlja n -dimenzioni vektor originalnog ulaznog prostora, $\mathbf{x} = (x_1, x_2, \dots, x_n)$, a y_i predstavlja željenu izlaznu vrednost (*target value*).

U slučaju rešavanja problema klasifikacije, y_i predstavlja klasu kojoj pripada ulazni vektor \mathbf{x}_i . Kod binarne klasifikacije izlaz y_i može imati dve vrednosti, npr. $y_i \in \{-1, +1\}$. Izlaz klasifikatora u datom slučaju daje indicaciju da li posmatrani vektor \mathbf{x}_i pripada izabranoj klasi (npr. za $y_i = -1$) ili ne ($y_i = +1$). Dalja generalizacija problema klasifikacije podrazumeva postojanje više klasa, odnosno *multiclass* problem. U slučaju postojanja npr. M klasa, izlaz klasifikatora može biti jedna od M diskretnih

vrednosti, npr. $y_i \in \{1, 2, \dots, M\}$, gde svaka vrednost predstavlja pripadnost test uzorka jednoj od M klasa. Greška generalizacije klasifikatora predstavlja verovatnoću da je slučajno izabrani test uzorak pogrešno klasifikovan.

SVC algoritam namenjen rešavanju problema binarne klasifikacije ima za cilj pronalaženje linerane funkcije koja vrši razdvajanje ulaznih podataka na dve klase. Linearni model može se predstaviti sledećom formom:

$$f(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b, \quad (3.29)$$

gde je $\phi(\cdot)$ funkcija mapiranja ulaznih podataka iz originalnog u karakterističan prostor većih dimenzija R^n , \mathbf{w} vektor težinskih koeficijenata, a b konstanta (*bias*). Ako pretpostavimo da su trening podaci linearno separabilni u odabranom karakterističnom prostoru, onda postoji barem jedna kombinacija parametara modela \mathbf{w} i b , za koju važi da funkcija modela f zadovoljava sledeće uslove:

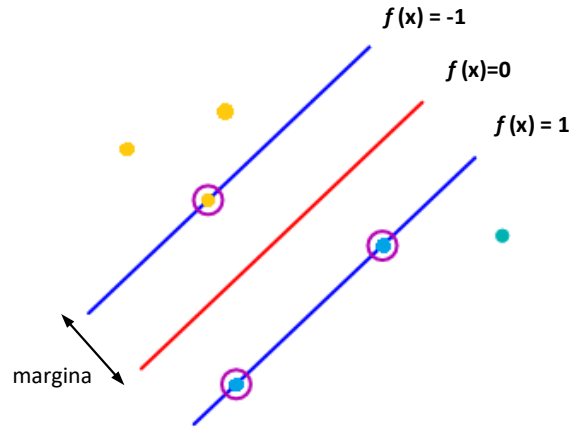
$$\begin{aligned} f(\mathbf{x}_i) &> 0 \text{ za } y_i = +1 \\ f(\mathbf{x}_i) &< 0 \text{ za } y_i = -1. \end{aligned} \quad (3.30)$$

U slučaju postojanja više kombinacija parametara modela \mathbf{w} i b , koje posmatrani trening skup klasifikuju na identičan način, neophodno je pronaći funkciju modela, tj. granicu odlučivanja (*decision boundary*) za koju će greška generalizacije biti minimalna.

SVC algoritam pristupa ovom problemu korišćenjem koncepta margine. Margina predstavlja perpendikularno rastojanje granice odlučivanja (tj. hiper-ravni) i nekog elementa iz trening skupa koji je njoj najbliži (slika 3.6). SVC vrši odabir granice odlučivanja na takav način da margina bude maksimalna moguća. U slučaju linearno separabilnih podataka u karakterističnom prostoru, granica odlučivanja, tj. hiper-ravan, leži u sredini regiona koji razdvaja trening skup na dve klase.

Koncept maksimalne margine ima osnove u teoriji statističkog učenja [77]. Naime, za SVC koji može da implementira neki set funkcija F , koncept odabira optimalne hiper-ravni koja pruža najveću moguću marginu odgovara u stvari odabiru podskupa seta funkcija F sa najmanjom VC dimenzijom [77]. U slučaju *hard-margin* SVC koji klasifikuje trening tačke bez greške, SRM (*structural risk minimisation*)

metoda omogućava minimiziranje stvarnog rizika svodeći vrednost empirijskog rizika na nulu uz odabir hiper-ravni koja daje maksimalnu marginu.



Slika 3.6. Ilustracija koncepta maksimalne margine kod *hard-margin* klasifikatora

Veličina margine, odnosno perpendikularno rastojanje slike ulaznog vektora \mathbf{x} u karakterističnom prostoru, tj $\phi(\mathbf{x})$, od granice odlučivanja (odnosno hiper-ravni definisane sa $f(\mathbf{x}) = 0$), može se izraziti kao [15]:

$$\frac{|f(\mathbf{x})|}{\|\mathbf{w}\|} \quad (3.31)$$

Kako su u ovom slučaju od interesa samo rešenja koja omogućavaju ispravnu klasifikaciju svih tačaka trening skupa, odnosno za koje važi da je $y_i f(\mathbf{x}_i) > 0$ za svako i , perpendikularno rastojanje nekog vektora \mathbf{x}_i (tačnije njegove slike u karakterističnom prostoru) od granice odlučivanja može se predstaviti sledećim izrazom [15]:

$$\frac{y_i f(\mathbf{x}_i)}{\|\mathbf{w}\|} = \frac{y_i (\mathbf{w}^T \phi(\mathbf{x}_i) + b)}{\|\mathbf{w}\|} . \quad (3.32)$$

Kao što je već napomenuto, margina predstavlja perpendikularno rastojanje između hiper-ravni i njoj najbliže tačke \mathbf{x}_i iz trening skupa. U datom slučaju, cilj optimizacije jeste odrediti parametre \mathbf{w} i b modela koji maksimiziraju marginu. Rešavanje ovog optimizacionog problema moguće je formulisati na sledeći način [15]:

$$\arg \max_{\mathbf{w}, b} \left\{ \frac{1}{\|\mathbf{w}\|} \min_i [y_i (\mathbf{w}^T \phi(\mathbf{x}_i) + b)] \right\} . \quad (3.33)$$

Kako je direktno rešavanje ovog optimizacionog problema dosta kompleksno, za njegovo rešavanje koristi se ekvivalentna forma. Naime, ako se uvede skaliranje parametara \mathbf{w} i b , $\mathbf{w} \rightarrow k\mathbf{w}$ i $b \rightarrow kb$, perpendikularno rastojanje bilo koje tačke \mathbf{x}_i iz trening skupa od hiper-ravni ostaje nepromenjeno. Data činjenica može se iskoristiti da se za tačku j koja je najbliža hiper-ravni postavi da važi sledeći uslov:

$$y_j(\mathbf{w}^T \phi(\mathbf{x}_j) + b) = 1. \quad (3.34)$$

U datom slučaju, za sve tačke trening skupa važiće sledeći izraz:

$$y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1, \quad i = 1, \dots, l. \quad (3.35)$$

Dati izraz predstavlja kanonski oblik granice odlučivanja, odnosno hiper-ravni. Tačke za koje važi jednakost predstavljaju aktivne tačke, dok su preostale neaktivne. Uzimajući u obzir definiciju margine, broj aktivnih tačaka na početku procesa optimizacije mora biti minimalno jedan, jer uvek postoji barem jedna tačka trening skupa koja je najbliža inicijalno postavljenoj hiper-ravni (tj. granici odlučivanja). S druge strane, nakon maksimiziranja margine, postojaće barem dve aktivne tačke, po jedna sa svake strane hiper-ravni, tj. po jedna na gornjoj i donjoj margini. Tako npr. kod slučaja ilustrovanog na slici 3.6 postoje 3 aktivne tačke.

Ovakav način definisanja granice odlučivanja, koji ne dozvoljava da se i jedna tačka trening skupa nađe u regionu između dve margine (slika 3.6), predstavlja *hard margin* klasifikator (klasifikator „tvrde“ margine).

Kako je najmanje rastojanje neke tačke od hiper-ravni jednako jedinici (izraz 3.34), optimizacioni problem dat izrazom 3.33 postaje problem maksimiziranja $\|\mathbf{w}\|^{-1}$, koji je ekvivalentan problemu minimiziranja $\|\mathbf{w}\|^2$. Optimizacioni problem postaje [15]:

$$\arg \min_{\mathbf{w}, b} \lambda \|\mathbf{w}\|^2, \quad (3.36)$$

gde je λ pozitivan broj. Radi pojednostavljenja kasnije analize pretpostavljeno je $\lambda = \frac{1}{2}$. Dalje se problem optimizacije svodi na:

$$\begin{aligned} & \min \frac{1}{2} \|\mathbf{w}\|^2 \\ & \text{pod uslovom } y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1, \quad i = 1, \dots, l. \end{aligned} \quad (3.37)$$

Dati optimizacioni problem predstavlja kvadratni problem sa ograničenjima (*constrained quadratic programming (QP) problem*), kod koga je potrebno minimizirati kvadratnu (konveksnu) funkciju u skladu sa ograničenjima datim linearnim nejednakostima. Pri tom, kako optimizacioni problem ima kvadratnu formu, lokalni minimum ujedno predstavlja i globalni minimum, odnosno jedinstveno optimalno rešenje.

Optimizacioni problem je moguće rešiti uvodeći *Lagrange*-ove multiplikatore [15] koji se koriste za pronalaženje stacionarne tačke funkcije više promenljivih, koja je ograničena sa jednim ili više uslova.

Za posmatrani optimizacioni problem, uvodeći *Lagrange*-ove multiplikatore $\alpha_i \geq 0$, po jedan za svaki uslov, dobija se *Lagrange*-ova optimizaciona funkcija [15, 16, 77]:

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i (\mathbf{w}^T \boldsymbol{\phi}(\mathbf{x}_i) + b) - 1), \quad (3.38)$$

koju treba minimizovati u odnosu na \mathbf{w} i b , odnosno maksimizirati u odnosu na $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_l)$. Rešenje optimizacionog problema leži u sedlastoj tački (*saddle point*) *Lagrange*-ove funkcije (slika 3.7). U sedlastoj tački, rešenje za \mathbf{w} , b i $\boldsymbol{\alpha}$ treba da zadovolji sledeće uslove:

$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\alpha})}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^l \alpha_i y_i \boldsymbol{\phi}(\mathbf{x}_i), \quad (3.39)$$


$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\alpha})}{\partial b} = 0 \Rightarrow \sum_{i=1}^l \alpha_i y_i = 0. \quad (3.40)$$

Prikaz vektora \mathbf{w} u vidu linearne kombinacije trening podataka u karakterističnom prostoru (izraz 3.39) predstavlja njegovu dualnu reprezentaciju, a *Lagrange*-ovi multiplikatori $\alpha_i \geq 0$ se još nazivaju dualnim promenljivama.

Na osnovu izvedenih uslova 3.39 i 3.40, moguće je eliminisati \mathbf{w} i b iz $L(\mathbf{w}, b, \boldsymbol{\alpha})$ izraza, čime se dobija dualna reprezentacija *Lagrange*-ove funkcije:

$$L(\boldsymbol{\alpha}) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{j=1}^l \sum_{i=1}^l \alpha_i \alpha_j y_i y_j \boldsymbol{\phi}(\mathbf{x}_i)^T \boldsymbol{\phi}(\mathbf{x}_j). \quad (3.41)$$

Izraz 3.41 treba maksimizirati u odnosu na $\boldsymbol{\alpha}$, uz ograničenja da je $\sum_{i=1}^l \alpha_i y_i = 0$ i $\alpha_i \geq 0$ za svako $i = 1, \dots, l$. Optimizacioni problem dat izrazom 3.41 i dalje predstavlja QP problem sa ograničenjima.



Slika 3.7. Uprošćen primer *Lagrange*-ova funkcije

Na osnovu izraza 3.41 može se primetiti da se prilikom rešavanja optimizacionog problema u dualnoj formi, slike originalnih podataka u karakterističnom prostoru ne javljaju zasebno, već samo u formi skalarnih proizvoda. Skalarni proizvodi slika u karakterističnom prostoru mogu se proračunati primenom kernel funkcija k nad originalnim podacima, kao što je dato izrazom 3.20:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j).$$

Uvođenjem tzv. „kernel trika“, optimizacioni problem se transformiše u:

$$L(\boldsymbol{\alpha}) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{j=1}^l \sum_{i=1}^l \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j), \quad (3.42)$$

a dobijeni izraz potrebno je maksimizirati u odnosu na $\boldsymbol{\alpha}$, uz sledeća ograničenja:

$$\sum_{i=1}^l \alpha_i y_i = 0 \text{ i } \alpha_i \geq 0 \text{ za svako } i = 1, \dots, l.$$

Na osnovu izraza 3.42 može se primetiti da se uvođenjem kernel funkcija gubi potreba za direktnim preslikavanjem ulaznih podataka u karakteristični prostor veće dimenzionalnosti. Drugim rečima, karakterističan prostor se uvodi implicitno, a proračun se i dalje vrši nad podacima u originalnom prostoru. Kompleksnost proračuna optimalnog vektora dualnih promenljivih $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_l)$, u smislu potrebnog broja

operacija, iznosi $O(l^3)$ [16] i ne zavisi od dimenzija karakterističnog prostora. Drugim rečima, SVM podržava preslikavanje ulaznih podataka u karakterističan prostor velike dimenzionalnosti, koja teorijski može biti i beskonačna.

Proračunom optimalnih vrednosti dualnih promenljivih $\alpha_1, \dots, \alpha_l$ i predstavljanjem vektora \mathbf{w} pomoću izraza 3.39, funkcija modela dobija sledeći oblik:

$$f(\mathbf{x}) = \sum_{i=1}^l \alpha_i y_i k(\mathbf{x}, \mathbf{x}_i) + b. \quad (3.43)$$

U opštem slučaju, rešenje kvadratnog optimizacionog problema sa ograničenjima mora da zadovolji *Karush-Kuhn-Tucker* (KKT) uslove [15, 88]. U slučaju razmatranog optimizacionog problema (izraz 3.42), KKT uslovi koji moraju biti zadovoljeni imaju sledeću formu [15]:

$$\alpha_i \geq 0 \quad (3.44)$$

$$y_i f(\mathbf{x}_i) - 1 \geq 0 \quad (3.45)$$

$$\alpha_i \{y_i f(\mathbf{x}_i) - 1\} = 0 \quad (3.46)$$

Uslov 3.45 predstavlja samo drugu formulaciju uslova 3.37. Na osnovu uslova 3.46, za svako i važi da je ili $\alpha_i = 0$ ili $y_i f(\mathbf{x}_i) = 1$. Parovi (\mathbf{x}_i, y_i) iz trening baze, za koje važi da je $\alpha_i = 0$, ne učestvuju u procesu estimacije izlaznih vrednosti za nove ulazne podatke (izraz 3.43). Ostali trening podaci \mathbf{x}_i , za koje važi uslov $\alpha_i \neq 0$, učestvuju u predikciji novih izlaza i date tačke trening skupa nazivaju se *support* vektorima. Pri tom, one zadovoljavaju relaciju $y_i f(\mathbf{x}_i) = 1$, odnosno leže na gornjoj ili donjoj margini (zaokružene tačke trening skupa na slici 3.6).

Osobina da bilo koji *support* vektor zadovoljava uslov $y_i f(\mathbf{x}_i) = 1$ može se iskoristiti za estimaciju vrednosti praga b funkcije modela f . Uzimajući u obzir izraz 3.43, dati uslov se za k -ti *support* vektor transformiše u:

$$y_k f(\mathbf{x}_k) = y_k \left(\sum_{i \in SV} \alpha_i y_i k(\mathbf{x}_k, \mathbf{x}_i) + b \right) = 1, \quad (3.47)$$

gde SV predstavlja skup *support* vektora, odnosno podskup tačaka originalnog trening skupa za koje važi da je $\alpha_i \neq 0$ i koje učestvuju u estimaciji novih izlaznih vrednosti.

Radi dobijanja stabilnijeg rešenja, može se vršiti usrednjavanje vrednosti b dobijenih za različite *support* vektore, odnosno:

$$b = \frac{1}{l_{SV}} \sum_{k \in SV} \left(y_k - \sum_{i \in SV} \alpha_i y_i k(\mathbf{x}_k, \mathbf{x}_i) \right), \quad (3.48)$$

gde l_{SV} predstavlja ukupan broj *support* vektora, a SV skup *support* vektora.

Konačno, nakon završenog procesa treniranja, naučena funkcije modela *hard-margin* binarnog klasifikatora može se predstaviti sledećim izrazom:

$$f(\mathbf{x}) = \sum_{i \in SV} \alpha_i y_i k(\mathbf{x}, \mathbf{x}_i) + b, \quad (3.49)$$

pri čemu se klasa novog ulaznog vektora \mathbf{x} u *online* fazi određuje na osnovu znaka vrednosti funkcije modela $f(\mathbf{x})$:

$$y = \text{sgn } f(\mathbf{x}). \quad (3.50)$$

Bitno svojstvo SVM koje se može sagledati kroz krajnju formu naučene funkcije modela jeste pružanje tzv. „proređenog“ rešenja (*sparse solution*). Proređeno rešenje podrazumeva da u *online* fazi algoritam vrši estimaciju novih izlaza samo na osnovu jednog podskupa trening podataka, odnosno *support* vektora kojima odgovaraju dualne promenljive različite od nule ($\alpha_i \neq 0$). Kako je broj *support* vektora manji od originalnog trening skupa, algoritam postaje efikasniji u *online* režimu rada, jer je za estimaciju vrednosti funkcije modela potrebno mnogo manje računskih operacija. Naime, usled postojanja „proređenog“ rešenja, proračun u *online* fazi ima kompleksnost $O(nl_{SV})$ umesto $O(nl)$, gde je n dimenzija ulaznih vektora (podataka) [16, 78]. Data osobina SVM omogućava korišćenje velikih trening skupova i kod aplikacija i sistema koji imaju stroge zahteve po pitanju kašnjenja, čime se izbegava prepodešavanja modela (*overfitting*) usled nedovoljnog broja trening uzoraka.

3.4.2. SOFT-MARGIN KLASIFIKATOR

Kao što je već napomenuto, prethodno razmatrani *hard-margin* SVC klasifikator podrazumeva slučaj linearno separabilnih trening podataka u karakterističnom prostoru.

Međutim, u praksi ovakav koncept često nije odgovarajući zbog postojanja šuma u trening podacima. Obezbeđivanje linerane razdvojenosti ovakvih podataka u karakterističnom prostoru zahteva kompleksne kernel funkcije i može rezultovati prepodešavanjem modela na trening podatke. Drugim rečima, kod *hard margin* SVC klasifikatora, postojanje određenog broja specifičnih podataka u trening skupu (*outliers*) može značajno uticati na uspostavljenu granicu odlučivanja. Za realne podatke ovo znači da klasifikator nije robustan, odnosno da ima loša svojstva generalizacije.

Opisani problem motivisao je razvoj robusnije verzije SVC algoritma, koja može da toleriše određeni šum, kao i postojanje netipičnih podataka (*outliers*) u trening skupu, a da to ne utiče značajno na naučenu funkciju modela. Data verzija SVC algoritma poznata je kao *soft-margin* klasifikator.


Soft-margin klasifikator dozvoljava da se određeni broj trening tačaka nađe sa pogrešne strane margine ili čak sa pogrešne strane razdvojne hiper-ravni, ali uz uvođenje tzv. „penala“ ili „kaznenih poena“ za date tačke. Za opis „penala“ uvedena je *slack* promenljiva $\xi_i \geq 0$ koja predstavlja funkciju rastojanja i -te tačke trening skupa, \mathbf{x}_i , od margine (slika 3.8). Vektor koji čine *slack* promenljive definisane za tačke trening skupa, $\boldsymbol{\xi} = (\xi_1, \xi_2, \dots, \xi_l)$, poznat je kao *margin slack* vektor. Za trening tačke koje se nalaze sa ispravne strane margine ili leže na njoj, važi da je $\xi_i = 0$. S druge strane, za tačke sa pogrešne strane margine *slack* promenljiva je definisana sa $\xi_i = |y_i - f(\mathbf{x}_i)|$.

Na osnovu definicije *slack* promenljive, važi da je za tačke koje leže na samoj granici odlučivanja, tj. za koje je $f(\mathbf{x}_i) = 0$, $\xi_i = 1$. Tačkama koje se nalaze između ispravne margine i granice odlučivanja odgovaraju *slack* promenljive sa vrednostima $0 < \xi_i \leq 1$, dok za one sa pogrešne strane granice odlučivanja važi da je $\xi_i > 1$ (slika 3.8).

Kanonski oblik granice odlučivanja, dat izrazom 3.35 kod *hard-margin* klasifikatora, u slučaju *soft-margin* verzije biva transformisan u:

$$y_i f(\mathbf{x}_i) \geq 1 - \xi_i, \quad \text{za } i = 1, \dots, l \text{ i } \xi_i \geq 0. \quad (3.51)$$

Odnosno, tačke za koje je $0 < \xi_i \leq 1$, nalaze se sa pogrešne strane margine ali će biti ispravno klasifikovane, dok će tačke za koje važi da je $\xi_i > 1$ biti pogrešno klasifikovane.



Slika 3.8. Koncept *soft-margin* klasifikatora i *slack* promenljivih

Kao i u slučaju *hard-margin* SVC klasifikatora, osnovni cilj je maksimizirati marginu, uvodeći pritom “penale” za tačke koje se nalaze sa pogrešne strane margine.

Optimizacioni problem koji treba rešiti, svodi se na:

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i \quad (3.52)$$

$$\text{pod uslovom } y_i (\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, \quad i = 1, \dots, l \text{ i } \xi_i \geq 0.$$

Konstanta $C > 0$ predstavlja *trade-off* parametar, koji kontroliše kompromis između veličine margine i broja trening tačaka koje se nalaze sa pogrešne strane margine. Drugim rečima, parametar C kontroliše balans između minimiziranja greške koja se pravi na trening skupu (tj. vrednosti empirijskog rizika) i kompleksnosti modela. Zadavanjem veće vrednosti parametra C , trening tačkama koje leže sa pogrešne strane margine dodeljuju se veće vrednosti „penala“. Slučaj $C \rightarrow \infty$ odgovara u stvari *hard-margin* klasifikatoru za linearno separabilni trening skup, jer ne dopušta pogrešnu klasifikaciju trening podataka.

Kao i u slučaju *hard-margin* SVC klasifikatora, optimizacioni problem dat izrazom 3.52 moguće je rešiti uvodeći *Lagrange*-ove multiplikatore $\alpha_i \geq 0$ i $\mu_i \geq 0$, čime se dobija *Lagrange*-ova optimizaciona funkcija [15, 16, 77]:

$$L(\mathbf{w}, b, \boldsymbol{\alpha}, \boldsymbol{\xi}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i [(y_i (\mathbf{w}^T \boldsymbol{\phi}(\mathbf{x}_i) + b) - 1 + \xi_i)] - \sum_{i=1}^l \mu_i \xi_i \quad (3.53)$$

KKT uslovi koje ovaj QP problem mora da zadovolji dati su sledećim izrazima [15]:

$$\begin{aligned} \alpha_i &\geq 0, \\ y_i f(\mathbf{x}_i) - 1 + \xi_i &\geq 0, \\ \alpha_i (y_i f(\mathbf{x}_i) - 1 + \xi_i) &= 0, \\ \mu_i &\geq 0, \\ \xi_i &\geq 0, \\ \xi_i \mu_i &= 0. \end{aligned} \quad (3.54)$$

Rešenje optimizacionog problema leži u sedlastoj tački *Lagrange*-ove funkcije. Diferenciranjem osnovne *Lagrange*-ove funkcije i izjednačavanjem sa nulom dobija se:

$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\alpha}, \boldsymbol{\xi})}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^l \alpha_i y_i \boldsymbol{\phi}(\mathbf{x}_i) \quad (3.55)$$

$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\alpha}, \boldsymbol{\xi})}{\partial b} = 0 \Rightarrow \sum_{i=1}^l \alpha_i y_i = 0 \quad (3.56)$$

$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\alpha}, \boldsymbol{\xi})}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \mu_i. \quad (3.57)$$

Iz uslova $\mu_i \geq 0$ i $C = \alpha_i + \mu_i$ sledi da je $\alpha_i \leq C$. Uvrštavanjem ovih uslova u osnovnu *Lagrange*-ovu funkciju dolazi se do dualne forme *Lagrange*-ove optimizacione funkcije [15]:

$$L(\boldsymbol{\alpha}) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j), \quad (3.58)$$

koju treba maksimizirati u odnosu na $\boldsymbol{\alpha}$, uz ograničenjima $0 \leq \alpha_i \leq C$ i $\sum_{i=1}^l \alpha_i y_i = 0$.

Data ograničenja nazivaju se *box constraints*.

Nakon proračuna optimalnih vrednosti *Lagrange*-ovih multiplikatora $\alpha_1, \dots, \alpha_l$ i predstavljanjem vektora \mathbf{w} preko njih (izraz 3.55), funkcija modela se može predstaviti u sledećem obliku:

$$f(\mathbf{x}) = \sum_{i=1}^l \alpha_i y_i k(\mathbf{x}, \mathbf{x}_i) + b. \quad (3.59)$$

Na osnovu KKT uslova, može se videti da za svaki par trening skupa ($i = 1, \dots, l$) važi da je $\alpha_i = 0$ ili $y_i f(\mathbf{x}_i) = 1 - \xi_i$.

U slučaju da je $\alpha_i = 0$, posmatrani par iz trening skupa podataka ne učestvuje u procesu predikcije izlaza (tj. klase) za nove ulazne podatke, čime je, kao i u slučaju *hard-margin* SVC klasifikatora, podržana osobina „proređenog“ rešenja.

Preostale tačke trening skupa, za koje je $\alpha_i > 0$, učestvuju u predikciji izlaza u *online* fazi i predstavljaju *support* vektore. Za date tačke važi da je $y_i f(\mathbf{x}_i) = 1 - \xi_i$. Pri tom, u slučaju kada je $\alpha_i < C$, tada važi da je $\mu_i > 0$, a time i da je $\xi_i = 0$. Odnosno, date tačke trening skupa leže na jednoj od margina. S druge strane, tačke za koje je ispunjeno da je $\alpha_i = C$ leže unutar margine i biće ispravno klasifikovane ako je $\xi_i \leq 1$, odnosno pogrešno ako je $\xi_i > 1$.

Na osnovu sprovedene analize, može se zaključiti da u procesu klasifikacije novih ulaznih podataka učestvuju samo tačke trening baze koje leže na margini ili sa njene unutrašnje strane. Date tačke trening skupa predstavljaju *support* vektore *soft-margin* SVC klasifikatora.

Sprovedena analiza može se iskoristiti za estimaciju parametra b funkcije modela *soft-margin* SVC klasifikatora. Vrednost praga b može se odrediti na osnovu činjenice da *support* vektori koji leže na jednoj od margina, zadovoljavaju uslov da je $\xi_i = 0$, odnosno da je $y_i f(\mathbf{x}_i) = 1$. Radi dobijanja stabilnijeg rešenja, može se vršiti usrednjavanje vrednosti b dobijene za različite *support* vektore koji zadovoljavaju prethodno pomenuti uslov, čime se dobija sledeći izraz:

$$b = \frac{1}{l_{SV^*}} \sum_{k \in SV^*} \left(y_k - \sum_{i \in SV^*} \alpha_i y_i k(\mathbf{x}_k, \mathbf{x}_i) \right), \quad (3.60)$$

gde l_{SV^*} predstavlja ukupan broj *support* vektora za koje je ispunjen uslov da je $0 < \alpha_i < C$ (tj. koji se nalaze na jednoj od margina).

Konačno, kao i u slučaju *hard-margin* SVC, klasifikacija novog ulaznog vektora \mathbf{x} vrši se na osnovu znaka funkcije modela $f(\mathbf{x})$ definisane izrazom 2.59, odnosno:

$$y = \text{sgn } f(\mathbf{x}). \quad (3.61)$$

3.4.3. SUPPORT VECTOR REGRESSION

Support Vector Regression (SVR) predstavlja SVM namenjen rešavanju problema regresije. U datom slučaju, izlaz SVM nije diskretna vrednost (tj. oznaka klase kojoj pripada ulazni podatak), nego neka realna vrednost $y \in R$. U opštem slučaju, izlaz može biti i vektor realnih vrednosti $\mathbf{y} \in R^m$. Iako je osnovni SVR algoritam razvijen za potrebe rešavanja jednodimenzionog problema regresije [15, 16, 89], za slučaj da izlaz ima formu vektora, tj. $\mathbf{y} \in R^m$, problem je moguće jednostavno rešiti paralelnim treniranjem m SVR mašina. Alternativni pristup, u vidu dalje generalizacije SVM za rešavanje problema više-dimenzione regresije (tzv. *multi-dimensional* SVR, MSVR) predložen je u [90].

U nastavku poglavlja biće opisana standardna forma SVR algoritma za slučaj rešavanja jednodimenzionog problema regresije.

Zadatak SVR algoritma jeste da estimira (nauči) funkciju koja na najoptimalniji način modeluje vezu između parova ulaznih i izlaznih podataka. Kao i u slučaju SVC, funkcija modela može se predstaviti sledećom formom:

$$f(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b, \quad (3.62)$$

gde je $\phi(\cdot)$ funkcija mapiranja ulaznih podataka iz originalnog u karakterističan prostor većih dimenzija R^n , \mathbf{w} vektor težinskih koeficijenata, a b konstanta (*bias*).

Optimizacioni problem svodi se na određivanje optimalnih parametara modela, tj. vektor težinskih koeficijenata \mathbf{w} i konstante b , za koje će vrednost greške, odnosno odstupanja stvarne vrednosti y od estimirane $f(\mathbf{x})$, biti minimlano.

Za proračun vrednosti greške estimacije najčešće se koriste linearna funkcija greške:

$$L(\mathbf{x}, y, f) = |y - f(\mathbf{x})|, \quad (3.63)$$

i kvadratna funkcija greške:

$$L(\mathbf{x}, y, f) = (y - f(\mathbf{x}))^2. \quad (3.64)$$

Međutim, kako bi se obezbedilo „proređeno“ rešenje, odnosno izdvajanje *support* vektora iz trening skupa, kod SVR uvedena je nova funkcija greške, tzv. ε -insensitive funkcija greške [91]. ε -insensitive funkcija greške dopušta greške u estimaciji koje su manje od neke vrednosti ε , $\varepsilon > 0$. U datom slučaju, ako stvarna vrednost y leži u ε okruženju funkcije modela, smatra se da je za datu tačku greška estimacije jednaka nuli.

Linearna ε -insensitive funkcija greške se može definisati kao [16]:

$$L^\varepsilon(\mathbf{x}, y, f) = \begin{cases} 0 & , |y - f(\mathbf{x})| \leq \varepsilon \\ |y - f(\mathbf{x})| - \varepsilon & , |y - f(\mathbf{x})| > \varepsilon \end{cases}. \quad (3.65)$$

Na sličan način, moguće je definisati kvadratnu ε -insensitive funkciju greške [16]:

$$L_2^\varepsilon(\mathbf{x}, y, f) = \begin{cases} 0 & , |y - f(\mathbf{x})| \leq \varepsilon \\ (|y - f(\mathbf{x})| - \varepsilon)^2 & , |y - f(\mathbf{x})| > \varepsilon \end{cases}. \quad (3.66)$$

Ilustracija ε regiona oko funkcije modela $f(\cdot)$, tzv. ε tube ili cev, prikazana je na slici 3.9. SVR uvedi pojam tzv. *slack* promenljive $\xi_i \geq 0$ ili $\bar{\xi}_i \geq 0$, kao merila greške estimacije (tj. „penal“) za svaku tačku \mathbf{x}_i trening skupa. Za i -tu tačku trening skupa *slack* promenljiva ima vrednost nula ako se data tačka nalazi unutar ε -regiona (slika 3.9):


$$f(\mathbf{x}_i) - \varepsilon \leq y_i \leq f(\mathbf{x}_i) + \varepsilon. \quad (3.67)$$

Slučaj $\xi_i > 0$ odgovara situaciji kada je $y_i > f(\mathbf{x}_i) + \varepsilon$, a $\bar{\xi}_i > 0$ kada je $y_i < f(\mathbf{x}_i) - \varepsilon$ (slika 3.9). Na osnovu toga može se zaključiti da za svaku tačku trening skupa važi da je $\xi_i \bar{\xi}_i = 0$. Uvodeći *slack* promenljive dozvoljava se da se trening tačke nađu i van ε -regiona, a odgovarajući uslovi koji u tom slučaju moraju biti ispunjeni su:

$$y_i \leq f(\mathbf{x}_i) + \varepsilon + \xi_i, \quad (3.68)$$

$$y_i \geq f(\mathbf{x}_i) - \varepsilon - \bar{\xi}_i. \quad (3.69)$$

Time se, kao i u slučaju *soft-margin* SVC klasifikatora, postižu bolja generalizaciona svojstva, jer se smanjuje uticaj šuma, kao i netipičnih podataka (*outliers*) u trening skupu, na naučenu funkciju regresije.



Slika 3.9. ε -insensitive region oko funkcije regresije (funkcije modela)

Način na koji će se tretirati tačke koje leže van ε -regiona, zavisi od tipa ε -insensitive funkcije greške. Analiza SVR algoritma biće izvršena za slučaj linearne i kvadratne ε -insensitive funkcije greške.

Linearni ε -insensitive SVR

U slučaju linearne ε -insensitive funkcije greške, SVR algoritam treba da reši sledeći optimizacioni problem [15, 16]:

$$\begin{aligned} \min \quad & C \sum_{i=1}^l (\xi_i + \bar{\xi}_i) + \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{pod uslovom} \quad & y_i \geq f(\mathbf{x}_i) - \varepsilon - \bar{\xi}_i, \\ & y_i \leq f(\mathbf{x}_i) + \varepsilon + \xi_i, \\ & \xi_i \geq 0 \text{ i } \bar{\xi}_i \geq 0, i = 1, \dots, l. \end{aligned} \quad (3.70)$$

Parametar C predstavlja „trade-off“ parametar kojim se kontroliše odnos između ukupne dozvoljene greške modela na trening skupu i kompleksnosti datog modela (tj. funkcije regresije).

Uvodeći *Lagrange*-ove multiplikatore $\alpha_i \geq 0$, $\bar{\alpha}_i \geq 0$, $\mu_i \geq 0$ i $\bar{\mu}_i \geq 0$ dobija se *Lagrange*-ova optimizaciona funkcija [15]:

$$L(\mathbf{w}, b, \boldsymbol{\alpha}, \boldsymbol{\xi}, \bar{\boldsymbol{\xi}}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi_i + \bar{\xi}_i) - \sum_{i=1}^l (\mu_i \xi_i + \bar{\mu}_i \bar{\xi}_i) - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i + f(\mathbf{x}_i) - y_i) - \sum_{i=1}^l \bar{\alpha}_i (\varepsilon + \bar{\xi}_i - f(\mathbf{x}_i) + y_i). \quad (3.71)$$

KKT uslovi koje ovaj QP problem mora da zadovolji dati su sledećim izrazima [15]:

$$\begin{aligned} \alpha_i (\varepsilon + \xi_i + f(\mathbf{x}_i) - y_i) &= 0, \\ \bar{\alpha}_i (\varepsilon + \bar{\xi}_i - f(\mathbf{x}_i) + y_i) &= 0, \\ \xi_i \mu_i &= 0, \\ \bar{\xi}_i \bar{\mu}_i &= 0. \end{aligned}$$

Pri tom moraju biti ispunjeni uslovi da je $\bar{\alpha}_i \alpha_i = 0$ i $\xi_i \bar{\xi}_i = 0$. Rešenje optimizacionog problema leži u sedlastoj tački *Lagrange*-ove funkcije. Diferenciranjem *Lagrange*-ove funkcije po \mathbf{w} , b , ξ_i i $\bar{\xi}_i$, dobijaju se sledeći izrazi:

$$\frac{\partial L}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) \phi(\mathbf{x}_i) \quad (3.72)$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) = 0 \quad (3.73)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \mu_i \quad (3.74)$$

$$\frac{\partial L}{\partial \bar{\xi}_i} = 0 \Rightarrow C = \bar{\alpha}_i + \bar{\mu}_i. \quad (3.75)$$

Kako za *Lagrange*-ove multiplikatore μ_i i $\bar{\mu}_i$ važi $\mu_i \geq 0$ i $\bar{\mu}_i \geq 0$, na osnovu izraza 3.74 i 3.75 sledi da je $0 \leq \alpha_i \leq C$ i $0 \leq \bar{\alpha}_i \leq C$. Data ograničenja predstavljaju *box constraints*, kao i u slučaju *soft-margin* SVC klasifikatora.

Uzimajući u obzir izvedene uslove 3.72 – 3.75, izraz 3.71 moguće je transformisati u dualnu formu *Lagrange*-ove optimizacione funkcije [15]:

$$L(\boldsymbol{\alpha}, \bar{\boldsymbol{\alpha}}) = \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) y_i - \varepsilon \sum_{i=1}^l (\alpha_i + \bar{\alpha}_i) - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \bar{\alpha}_i) (\alpha_j - \bar{\alpha}_j) k(\mathbf{x}_i, \mathbf{x}_j) \quad (3.76)$$

koju treba maksimizirati po $\boldsymbol{\alpha}$ i $\bar{\boldsymbol{\alpha}}$, uz sledeća ograničenja:

$$0 \leq \alpha_i \leq C,$$

$$0 \leq \bar{\alpha}_i \leq C \text{ i}$$

$$\sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) = 0.$$

Nakon rešavanja ovog QP problema i određivanja optimalnih vrednosti dualnih promenljivih α_i i $\bar{\alpha}_i$, uzimajući u obzir izraz 3.72, funkcija predikcije SVR modela može se predstaviti u sledećem obliku:

$$f(\mathbf{x}) = \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) k(\mathbf{x}, \mathbf{x}_i) + b. \quad (3.77)$$

Analizom KKT uslova može se doći do više korisnih zaključaka:

- Dualna promenljiva α_i biće različita od nule samo ako je $\varepsilon + \xi_i + f(\mathbf{x}_i) - y_i = 0$, što je ispunjeno za one tačke koje leže na gornjoj granici ε -regiona ($\xi_i = 0$) ili koje se nalaze iznad nje ($\xi_i \geq 0$).
- Analogno tome, dualna promenljiva $\bar{\alpha}_i$ imaće vrednost različitu od nule samo za one tačke koje leže na donjoj granici ε -regiona ($\bar{\xi}_i = 0$) ili ispod nje ($\bar{\xi}_i \geq 0$).
- Kako su uslovi $\varepsilon + \xi_i + f(\mathbf{x}_i) - y_i = 0$ i $\varepsilon + \bar{\xi}_i - f(\mathbf{x}_i) + y_i = 0$ međusobno isključivi, za svaku tačku \mathbf{x}_i važi da je $\alpha_i = 0$ ili $\bar{\alpha}_i = 0$ (ili oba).

Na osnovu izraza 3.77 može se zaključiti da tačke trening skupa, za koje istovremeno važi $\alpha_i = 0$ i $\bar{\alpha}_i = 0$, u *online* fazi ne učestvuju u predikciji izlaza za nove

ulazne podatke. Samo tačke trening skupa za koje je ispunjen uslov da je $\alpha_i \neq 0$ ili $\bar{\alpha}_i = 0$ učestvuju u predikciji novih izlaza i date tačke predstavljaju *support* vektore. Kod linearnog ε -insensitive SVR, *support* vektori su trening tačke koje leže na granici ε -oblasti ili se nalaze izvan nje.

Slično kao kod *soft-margin* SVC klasifikatora, parametar b funkcije modela može se odrediti na osnovu *support* vektora za koje je ispunjen uslov da je $0 < \alpha_i < C$ (ili $0 \leq \bar{\alpha}_i \leq C$). Na osnovu izvedene veze 3.74 i KKT uslova $\xi_i \mu_i = 0$, može se zaključiti da za date *support* vektore mora biti ispunjen uslov da je $\xi_i = 0$, odnosno $y_i = f(\mathbf{x}_i) + \varepsilon$ (dati *support* vektori leže na granici ε -oblasti). Tada se parametar b može proračunati na sledeći način:

$$b = \frac{1}{l_{SV^*}} \sum_{k \in SV^*} \left(y_k - \varepsilon - \sum_{i \in SV^*} (\alpha_i - \bar{\alpha}_i) k(\mathbf{x}_k, \mathbf{x}_i) \right), \quad (3.78)$$

gde l_{SV^*} predstavlja ukupan broj *support* vektora za koje je ispunjen uslov da je $0 < \alpha_i < C$.

Kvadratni ε -insensitive SVR

U slučaju kvadratne ε -insensitive funkcije greške, optimizacioni problem dat izrazom 3.70 dobija sledeću formu [16]:

$$\begin{aligned} \min \quad & C \sum_{i=1}^l (\xi_i^2 + \bar{\xi}_i^2) + \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{pod uslovom} \quad & y_i \geq f(\mathbf{x}_i) - \varepsilon - \bar{\xi}_i, \\ & y_i \leq f(\mathbf{x}_i) + \varepsilon + \xi_i, \quad i = 1, \dots, l. \end{aligned} \quad (3.79)$$

Postupak rešavanja ovog optimizacionog problema sličan je prethodno opisanom u slučaju linearnog ε -insensitive SVR algoritma. Uvodeći *Lagrange*-ove multiplikatore dobija se *Lagrange*-ova optimizaciona funkcija:

$$\begin{aligned} L(\mathbf{w}, b, \boldsymbol{\alpha}, \boldsymbol{\xi}, \bar{\boldsymbol{\xi}}) = & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi_i^2 + \bar{\xi}_i^2) - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i + f(\mathbf{x}_i) - y_i) \\ & - \sum_{i=1}^l \bar{\alpha}_i (\varepsilon + \bar{\xi}_i - f(\mathbf{x}_i) + y_i). \end{aligned} \quad (3.80)$$

Pri tom, KKT uslovi koji odgovaraju datom QP problemu dati su sledećim izrazima [16]:

$$\begin{aligned}\alpha_i(\varepsilon + \xi_i + f(\mathbf{x}_i) - y_i) &= 0, \\ \bar{\alpha}_i(\varepsilon + \bar{\xi}_i - f(\mathbf{x}_i) + y_i) &= 0,\end{aligned}$$

pri čemu je $\bar{\alpha}_i\alpha_i = 0$ i $\bar{\xi}_i\xi_i = 0$.

Istim postupkom kao u slučaju linearnog ε -insensitive SVR, dolazi se do dualne forme Lagrange-ove optimizacione funkcije [16]:

$$\begin{aligned}L(\boldsymbol{\alpha}, \bar{\boldsymbol{\alpha}}) &= -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \bar{\alpha}_i)(\alpha_j - \bar{\alpha}_j)k(\mathbf{x}_i, \mathbf{x}_j) - \frac{1}{2C} \sum_{i=1}^l (\alpha_i^2 + \bar{\alpha}_i^2) \\ &\quad + \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i)y_i - \varepsilon \sum_{i=1}^l (\alpha_i + \bar{\alpha}_i)\end{aligned}\quad (3.81)$$

koju treba maksimizirati po $\boldsymbol{\alpha}$ i $\bar{\boldsymbol{\alpha}}$, uz sledeća ograničenja:

$$\begin{aligned}\alpha_i &\geq 0, \\ \bar{\alpha}_i &\geq 0, \\ \bar{\alpha}_i\alpha_i &= 0, \text{ i} \\ \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) &= 0.\end{aligned}$$

Rešavanjem ovog QP problema po $\boldsymbol{\alpha}$ ($\bar{\boldsymbol{\alpha}}$) i predstavljanjem vektora težinskih koeficijenata \mathbf{w} pomoću izraza 3.72, funkcija predikcije SVR modela dobija sledeću formu:

$$f(\mathbf{x}) = \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i)k(\mathbf{x}, \mathbf{x}_i) + b. \quad (3.82)$$

Kao i u slučaju linearnog ε -insensitive SVR algoritma, u predikciji novih izlaza u *online* fazi učestvuju samo one tačke trening skupa za koje je ispunjen uslov $\alpha_i \neq 0$ ili $\bar{\alpha}_i \neq 0$. Date tačke su *support* vektori i nalaze se van ε -oblasti. Time je podržana osobina „proređenog“ rešenja koja omogućava efikasnu *online* fazu.

Konstanta b funkcije predikcije može se proračunati uzimanjem u obzir i -tog *support* vektora za koji je ispunjen uslov $\alpha_i > 0$ (ili $\bar{\alpha}_i \geq 0$) [16]:

$$b = y_i - \varepsilon - \frac{\alpha_i}{c} - \sum_{j=1}^l (\alpha_j - \bar{\alpha}_j) k(\mathbf{x}_i, \mathbf{x}_j). \quad (3.83)$$

Stabilnije rešenje moguće je dobiti usrednjavanjem vrednosti parametra b proračunatim za sve *support* vektore.

4. NOVE METODE POZICIONIRANJA U JAVNIM MOBILNIM SISTEMIMA ZASNOVANE NA SVM ALGORITMIMA

Fokus ovog istraživanja jeste razvoj nove metode za određivanje pozicije mobilnog korisnika korišćenjem infrastrukture PLMN sistema. Kao što je već istaknuto, osnovna prednost korišćenja infrastrukture PLMN sistema jeste njihova globalna teritorijalna rasprostranjenost i dobro radio-pokrivanje, kako u *outdoor* okruženjima sa različitim stepenima urbanizacije, tako i u *indoor* okruženjima.

Novе metode pozicioniranja, koje su predmet ove disertacije, vrše estimaciju pozicije mobilnog korisnika (objekta) korišćenjem podataka o nivoima signala (*Received Signal Strength*, RSS) okolnih PLMN ćelija, koje mobilni terminal meri na svojoj trenutnoj poziciji. U tom smislu, predložene metode predstavljaju *mobile-assisted network-based* tehniku, jer lokacijski-zavisne podatke (u ovom slučaju nivoe signala) prikuplja mobilni terminal i prosleđuje ka mreži, na čijoj strani se vrši proračun prostornih koordinata korisnika. Potrebno je naglasiti da novodefinisane metode omogućavaju određivanje inicijalne pozicije mobilnog korisnika, u slučaju kada prethodna pozicija, tj. „stanje“ mobilnog korisnika nije poznato.

U nastavku poglavlja izložen je postupak određivanja pozicije mobilnih korisnika i dat je detaljan opis predloženih algoritama za proračun prostornih koordinata korišćenjem SVM algoritma mašinskog učenja.

4.1. KORIŠĆENJE PARAMETRA NIVOVA SIGNALA NA PRIJEMU ZA ODREĐIVANJE POZICIJE MOBILNOG TERMINALA

4.1.1. MERENJE NIVOVA SIGNALA NA PRIJEMU – RSS PARAMETAR

Nivo signala na prijemu (RSS) predstavlja parametar radio signala čije je merenje definisano standardom u svim PLMN sistemima (3GPP TS 45.008 [92], ETSI TS 125 133 [93], 3GPP TS 36.133 [94]). Naime, kako bi se podržalo upravljanje mobilnošću korisnika u *idle* modu ili *handover* tokom uspostavljenog poziva, mobilni terminal periodično meri nivo signala na kontrolnom (ili pilot) kanalu servisne i okolnih ćelija. Izmerene vrednosti se u formi standardizovanog izveštaja (*Measurement Report*, MR) (3GPP TS 45.008 [92], ETSI TS 125 133 [93], 3GPP TS 36.133 [94]) šalju preko servisne ćelije nazad ka mreži. Za potrebe pozicioniranja izmerene RSS vrednosti se prosleđuju ka SMLC centru (*Serving Mobile Location Centre*), gde se na osnovu njih vrši proračun trenutne pozicije mobilnog terminala korišćenjem nekog od algoritama za pozicioniranje.

U slučaju GSM (DCS) sistema, RSS parametar predstavlja u stvari RxLev parametar, odnosno izmereni nivo signala na BCCH (*Broadcast Control Channel*) kontrolnom kanalu neke GSM ćelije. Lista BCCH kanala okolnih GSM ćelija, na kojima mobilna stanica meri (prati) nivo signala, definisana je u tzv. BA listi (*Broadcast Control Channel Allocation List*), koju mobilni terminal dobija od servisne ćelije. Postojeći GSM standard dozvoljava do 32 BCCH kanala (odnosno, 32 GSM radio kanala) da budu uključeni u BA listu (3GPP TS 45.008 [92], ETSI TS 144 018 [95]). BCCH kanale koji će biti uključeni u BA listu određuje mrežni operator, koji potencijalno može da dozvoli praćenje i merenje nivoa signala na GSM radio kanalima koji pripadaju i drugim operatorima. Na osnovu BA liste i liste BSIC kodova (*Base Station Identification Code*), generiše se GSM lista suseda (*GSM Neighbour Cell list*) (ETSI TS 144 018 [95]). Dodatno, mobilni terminal koji se nalazi u GSM modu rada, a podržava više tipova radio pristupa (*multi radio access technology*, multi-RAT), ima istovremeno mogućnost merenja i nadgledanja nivoa signala okolnih ćelija koje pripadaju drugim RAT tehnologijama (npr. UMTS, LTE) [92, 95, 96]. 3GPP TS 45.008 standard [92] definiše da u datom slučaju, multi-RAT mobilni terminal treba da podrži

nadgledanje (merenje) nivoa signala susednih UMTS ćelija koje rade na 3 različita radio kanala (maksimalno 32 UMTS ćelije po jednom radio kanalu), pri čemu je ukupan broj UMTS ćelija koje se mogu definisati u listi suseda, trenutno ograničen na 64. Takođe, za multi-RAT mobilne terminale, 3GPP TS 45.008 [92] standardom definisano je i merenje nivoa signala susednih LTE ćelija na najviše 3 radio kanala.

Kod UMTS (3G) sistema, mobilni terminal meri CPICH_RSCP (*Common Pilot Channel Received Scrambling Code Power*) parametar, koji predstavlja izmereni nivo signala na pilot kanalu (*Common Pilot Channel*, CPICH) koji emituje neka UMTS ćelija. PSC kodovi (*Primal Scrambling Code*) susednih UMTS ćelija, čije nivoe signala mobilni terminal nadgleda, definisani su u 3G listi suseda (*3G Neighbour Cell list*) (ETSI TS 144 018 [95], ETSI TS 125 133 [93]). 3G lista suseda može da sadrži do 96 UMTS ćelija [93, 95]. U slučaju podrške multi-RAT, ETSI TS 125 133 standardom [93] postavljeni su uslovi da mobilni terminal mora biti sposoban da podrži merenje nivoa signala na sledećem broju susednih ćelija: do 31 UMTS ćelije koje rade na istom radio kanalu kao servisna UMTS ćelija (32 *intra-frequency* UMTS ćelije, uključujući i servisnu), do 32 UMTS ćelije koje rade na preostala dva nosioca (32 *inter-frequency* UMTS ćelije), kao i do 32 inter-RAT ćelije (na maksimalno 32 GSM radio kanala i/ili 4 LTE radio kanala).

U slučaju LTE sistema, mobilni terminal meri RSRP (*Reference Signal Received Power*) parametar koji predstavlja nivo signala na PCI (*Physical Cell Identity*) sekvenci simbola koji emituje LTE ćelija (3GPP TS 36.133 [94]). Za razliku od predefinisanih lista suseda koje mobilni terminal dobija od servisne bazne stanice kod GSM ili UMTS sistema, LTE sistem podržava dinamičko kreiranje liste suseda. Dinamičko kreiranje liste suseda vrši se pomoću *Automatic Neighbour Relation* (ANR) funkcije implementirane u LTE baznoj stanici (tj. eNodeB) [96, 97], na osnovu LTE ćelija koje detektuje mobilni terminal. 3GPP TS 36.133 [94] standardom definisano je da mobilni terminal mora da podrži detektovanje PCI kodova i merenje RSRP vrednosti okolnih *intra-frequency* LTE ćelija i bez postojanja eksplicitne liste suseda sa unapred definisanim PCI kodovima. Takođe, mobilni terminal treba da podrži detektovanje PCI kodova i merenje RSRP vrednosti *inter-frequency* LTE ćelija na još 3 LTE nosioca, definisana od strane servisne ćelije [94]. Dodatno, mobilni terminal koji podržava i

druge RAT (GSM/UMTS), mora da podržava istovremeno merenje nivoa signala susednih GSM ćelija (na 32 GSM nosioca) i UMTS ćelija (na 3 UMTS nosioca) [94].

Načini mapiranja izmerenih vrednosti nivoa signala na prijemu (RSS) u vrednosti RxLev, CPICH_RSCP ili RSRP parametra, dati su u tabeli 4.1 (3GPP TS 45.008 [92], ETSI TS 125 133 [93], 3GPP TS 36.133 [94]).

Tabela 4.1 Opseg vrednosti RxLev, CPICH_RSCP ili RSRP parametra.

SISTEM	IZMAREN NIVO SIGNALA, RSS [dBm]	VREDNOST PARAMETRA RXLEV/CPICH_RSCP/RSRP
GSM (DCS)	$RSS < -110$	RXLEV = 0
	$-110 \leq RSS < -109$	RXLEV = 1

	$-49 \leq RSS < -48$	RXLEV = 62
	$-48 \leq RSS$	RXLEV = 63
UMTS	$RSS < -120$	CPICH_RSCP = -5
	$-120 \leq RSS < -119$	CPICH_RSCP = -4

	$-26 \leq RSS < -25$	CPICH_RSCP = 90
	$-25 \leq RSS$	CPICH_RSCP = 91
LTE	$RSS < -140$	RSRP = 0
	$-140 \leq RSS < -139$	RSRP = 1

	$-45 \leq RSS < -44$	RSRP = 96
	$-44 \leq RSS$	RSRP = 97

Izmerene vrednosti RSS parametara (RxLev, CPICH_RSCP ili RSRP) samo određenog broja susednih GSM (DCS), UMTS i/ili LTE ćelija, za koje je detektovan najviši nivo signala, šalju se nazad servisnoj baznoj stanici (ćeliji) u formi standardizovanog izveštaja (*Measurement Report*, MR). Struktura MR izveštaja, odnosno uslovi koji definišu za koliko i za koje ćelije će se rezultati merenja slati nazad ka mreži, zavise od više faktora [92, 95, 98]:

- Tipova RAT tehnologija i modova koje podržava mobilni terminal (GSM, UMTS FDD, UMTS TDD, LTE FDD, LTE TDD);
- Frekvencijskih opsega u okviru jedne RAT koje podržava mobilni terminal (npr. GSM 900MHz, GSM 1800MHz, itd.);
- Postavljenih pragova (*thresholds*), tj parametara koje definiše operator. Naime, za svaku RAT, operator definiše: maksimalan broj ćelija date RAT koje će se naći u izveštaju, broj ćelija za svaki frekvencijski opseg date RAT, minimalan nivo signala potreban da bi se za ćeliju date RAT generisao izveštaj, itd.

Tako npr. standardni MR izveštaj koji šalje mobilni terminal u GSM modu, može da sadrži, pored parametara servisne ćelije, izmerene parametre za još maksimalno 6 susednih ćelija. Pri tom, maksimalni broj susednih GSM ćelija koje mogu biti obuhvaćene izveštajem je 6, dok za druge RAT tehnologije (UMTS, LTE) taj broj iznosi 3 [92]. S druge strane, poboljšani tip MR izveštaja (*Enhanced Measurement Report*, EMR), može da sadrži parametre izmerene za 29 susednih ćelija.

4.1.2. PREDNOSTI KORIŠĆENJA RSS PARAMETRA

Kao što je ranije spomenuto, tehnike pozicioniranja u PLMN mrežama mogu se zasnivati na korišćenju različitih parametara radio signala: nivo signala na prijemu (RSS), vremena propagacije signala (*Time of Arrival*, TOA), vremenske razlike propagacije signala (*Time Difference of Arrival*, TDOA), ugla prispeća signala (*Angle of Arrival*, AoA), kombinacije prethodno navedenih parametara, itd. U zavisnosti od korišćenog pristupa, navedene tehnike pozicioniranja mogu imati različiti uticaj na mrežu i korisnički terminal, a samim tim i na cenu implementacije. Tako na primer, pristupi zasnovani na merenju TOA parametra zahtevaju sinhronizaciju između mobilnog terminala i baznih stanica, dok tehnike zasnovane na merenju TDOA zahtevaju međusobnu sinhronizovanost baznih stanica. Dati uslov u većini PLMN mreža nije ispunjen (GSM, UMTS FDD, LTE FDD), pa je neophodno uvođenje dodatnih hardverskih elemenata tj. LMU jedinica [99]. Dodatno, sa stanovišta neophodnih izmena, TOA/TDOA metode implemetirane na *downlink* smeru zahtevaju i

izmene na strani mobilnog terminala kako bi se omogućila neophodna merenja vremena pristizanja signala sa različitih baznih stanica [99]. U slučaju korišćenja podataka o pravcu nailaska radio signala (AoA) za potrebe pozicioniranja, neophodne su izmene na strani svake bazne stanice u vidu instalacije adaptivnih antenskih nizova, kao i specijalizovanih prijemnika [99], što znatno povećava troškove implementacije.

S druge strane, korišćenje RSS parametara ne zahteva nikakve hardverske izmene na strani mreže i mobilnih terminala, kao ni sinhronizaciju u okviru mreže. Prednost korišćenja RSS parametara za potrebe pozicioniranja jeste i u činjenici da su vrednosti navedenih parametara dostupne za veći broj ćelija. Dosadašnja istraživanja su pokazala da je u slučaju dostupnosti lokacijski-zavisnih radio parametara od više ćelija, moguće postići veću tačnost pozicioniranja [36]. Mobilni terminali već poseduju hardverske mogućnosti da mere nivo signala velikog broja okolnih ćelija, koje mogu pri tom pripadati različitim radio pristupnim tehnologijama (GSM, UMTS, LTE). Trenutna ograničenja odnose se na veličinu MR izveštaja, koji mobilni terminal šalje preko servisne ćelije nazad ka mreži. U tom pogledu, da bi se iskoristio veći broj izmerenih RSS vrednosti za potrebe pozicioniranja (od onih raspoloživih u MR izveštaju), neophodno je izvršiti određene izmene u postojećoj signalizaciji, kako bi se podržalo proširenje MR izveštaja. Ipak, date izmene ne bi trebalo da imaju veliki uticaj na kapacitet same PLMN mreže. Dakle, korišćenje svih raspoloživih RSS merenja za potrebe pozicioniranja zahteva samo odgovarajuće softverske izmene, bez potrebe za izmenama hardverske infrastrukture. U tom smislu, korišćenje RSS parametara za potrebe pozicioniranja ima neznatan uticaj na mrežu i mobilne terminale.

Dodatno, moguće je izvršiti i modifikacije liste suseda kako bi se podržalo merenje nivo signala ćelija drugih operatora. Naime, pokazano je da je moguće postići veću tačnost pozicioniranja ukoliko radio signali, iz kojih se dobijaju lokacijski-zavisni parametri, nisu međusobno korelisani, što u velikoj meri zavisi od prostornog rasporeda izvora radio signala [36,100,101]. U okviru mreže jednog operatora uobičajno je da su na jednoj lokaciji (*site*) kolocirane bazne stanice različitih RAT (GSM, DCS, UMTS i/ili LTE). Takođe, obično se sa jedne lokacije realizuje više ćelija nekog sistema (sektorizovane bazne stanice). Iz navedenih razloga, posmatrani radio signali mogu biti dosta korelisani, pa uzimanje u obzir RSS nivoa ćelija koje pripadaju drugim

operatorima i implementirane su na drugim lokacijama predstavlja dodatnu prednost (pored prvobitne prednosti u vidu povećanja broja raspoloživih RSS parametara).

Na kraju, kao što je već ranije spomenuto, prednosti korišćenja RSS parametara u odnosu na TOA, TDOA ili AOA postaju pogotovo izražene u sredinama sa dosta prepreka, odnosno u NLOS (*Non Line of Site*) uslovima propagacije koji su neizbežni u urbanizovanim sredinama i zatvorenim prostorima. Usled manje osetljivosti na NLOS uslove propagacije, RSS parametar postaje pravi kandidat za potrebe pozicioniranja korisnika u urbanizovanim sredinama i zatvorenim prostorima.

4.1.3. NEDOSTACI KORIŠĆENJA RSS PARAMETRA I POTENCIJALNA REŠENJA

Problem prilikom korišćenja RSS parametara za određivanje pozicije mobilnog terminala jeste u tome što vrednosti RSS parametara, izmerene na jednoj lokaciji, variraju u toku vremena zbog pojave *multipath* fedinga. Pojava *multipath* fedinga usled kombinovanja radio signala koji do prijemnika stižu po višestrukim putanjama, najizraženija je u urbanim zonama i zatvorenim prostorima sa velikim brojem prepreka, odnosno objekata (kako stacioniranih, tako i pokretnih). Međutim, i pored ovog problema, korišćenje RSS parametara u datim okruženjima ima prednost u odnosu na TOA, TDOA ili AOA zbog njihove izrazite osetljivosti na NLOS uslove propagacije.

U slučaju da sistem pozicioniranja koristi unapred formiranu RSS *finegrprint* bazu pri estimiranju pozicije mobilnog terminala, uticaj fluktuacija RSS vrednosti na grešku pozicioniranja može se smanjiti kroz odgovarajuću prethodnu obradu *fingerprint* baze. Najčešće korišćeni pristup jeste usrednjavanje vrednosti nivoa signala neke ćelije izmerenih u jednoj referentnoj tački u toku određenog vremenskog intervala [35, 65, 67 101]. S druge strane, u slučaju merenja RSS vrednosti prilikom kretanja (npr. *drive test*), jedan od mogućih pristupa jeste usrednjavanje RSS vrednosti izmerenih u nekoliko sukcesivnih tačaka duž rute, korišćenjem mehanizma klizećeg prozora (sa ili bez preklapanja) [31, 32].

Drugi potencijalni problem prilikom korišćenja RSS parametara za potrebe pozicioniranja jeste da na različitim lokacijama u okviru neke zone od interesa mobilni terminal detektuje različite ćelije, odnosno razlikuju se ćelije čiji je nivo signala iznad praga prijema mobilnog terminala (tzv. „radio-vidljive“ ćelije). Takođe, usled trenutno ograničene veličine MR izveštaja, za pojedine ćelije čiji je nivo signala iznad praga prijema, izmerena RSS vrednost ne mora biti dostupna sistemu za pozicioniranje. Drugim rečima, za sistem pozicioniranja takva ćelija kao da nije „radio-vidljiva“. U slučaju korišćenja *fingerprinting* metoda za potrebe pozicioniranja (u koje je moguće uvrstiti i SVM zbog korišćenja trening *fingerprint* baze), prethodno opisana pojava dovodi do tzv. problema nepostojeće vrednosti (eng. *missing value*) u bazi podataka [41].

Naime, kod SVM algoritama, estimacija nepoznatog izlaznog podatka vrši se proračunom kernel funkcije nad njemu odgovarajućim ulaznim podatkom (\mathbf{x}) i ostalim ulaznim podacima iz trening skupa \mathbf{x}_i (tj. *support* vektorima). Kao ilustracija, u nastavku je data funkcija modela SVR algoritma:

$$f(\mathbf{x}) = \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) k(\mathbf{x}, \mathbf{x}_i) + b. \quad (4.1)$$

U slučaju razmatranog problema pozicioniranja mobilnog korisnika, procena njegovih prostornih koordinata vrši se proračunom kernel funkcije nad vektorom RSS vrednosti izmerenih na njegovoj trenutnoj poziciji i vektorima RSS vrednosti iz trening baze (tj. *support* vektorima). U tom smislu, *kernel* funkcija može se shvatiti i kao funkcija kojom se porede neka dva ulazna vektora, tj. *fingerprint*-a. Otuda i ulazni RSS vektori koji se porede moraju biti istih dimenzija, a odgovarajući q -ti element kod svih RSS vektora mora poticati od iste q -te ćelije kako bi adekvatno poređenje bilo moguće. Zbog činjenice da u različitim tačkama nekog geografskog prostora postoji različita „radio-vidljivost“ ćelija, vektori izmerenih RSS parametara ne moraju imati podatke o nivou signala istih ćelija, a takođe ne moraju biti ni iste dužine. Drugim rečima, može se javiti problem nepostojanja izmerenog RSS parametra za određene ćelije, a time i problem proračuna *kernel* funkcije.

Navedeni problem moguće je rešiti pre svega definisanjem skupa ćelija koje se smatraju relevantnim izvorima radio signala u nekoj geografskoj oblasti. U okviru ovog

istraživanja ispitivani su različiti kriterijumi za definisanje relevantnih radio izvora za potrebe pozicioniranja u nekoj geografskoj oblasti, koji će biti predstavljeni nešto kasnije u nastavku rada.

Dodatno, neophodno je definisati i način tretiranja nepostojećih RSS vrednosti, odnosno situacije kada u MR izveštaju nedostaje RSS parametar za ćeliju koja je relevantna za potrebe pozicioniranja u posmatranoj geografskoj oblasti. Najčešći pristup rešavanju ovog problema, koji se može primeniti na različite tipove algoritama koji koriste *fingerprint* bazu (npr. ANN, KNN, SVM) jeste dodeljivanje neke fiksne vrednosti na mesto nepostojećeg RSS parametra. U znatnom broju dosadašnjih istraživanja za datu vrednost usvajana je vrednost nula [35, 41, 72, 73, 101]. Međutim, data vrednost ne opisuje na adekvatan način stvarne nivoe radio signala udaljenih ćelija. Vrednost koja predstavlja prirodnije rešenje za dati problem jeste vrednost praga prijema mobilnog terminala, odnosno minimalna vrednost RSS parametra definisana 3GPP standardom u zavisnosti od tipa sistema (tabela 4.1) [36, 67].

S druge strane, određeni autori dali su predloge koji se odnose na modifikaciju samih algoritama, kako bi se rešio problem nepostojećih RSS parametara u *fingerprint* bazi ili ulaznim podacima u okviru zahteva za pozicioniranje [31,67, 41]. Autori u [31, 67] dali su predlog tehnike pozicioniranja zasnovane na metodi najbližeg suseda (*Nearest Neighbour*, NN) gde je proračun mere sličnosti (tj. razlike) između vektora RSS vrednosti iz zahteva za pozicioniranje i onih iz *fingerprint* baze dat sledećim izrazom:

$$d(k) = \sum_i (f_i - g_i(k))^2 + p(k) \quad (4.2)$$

gde f_i predstavlja RSS vrednost koju mobilni terminal izmeri na BCCH kanalu i -te GSM ćelije, a $g_i(k)$ RSS nivo BCCH kanala i -te GSM ćelije u k -tom *fingerprint*-u iz baze. Sumom su obuhvaćene samo ćelije za koje RSS parametar postoji u oba *fingerprint*-a koja se porede. U suprotnom, dodaje se penal (kazna) $p(k)$.

U slučaju korišćenja SVM algoritma, u [41] dat je predlog modifikacije kernel funkcije. Autori su predložili novu kernel funkciju *Sum of Exponentials* (SoE):

$$K^{SoE} = k(\mathbf{x}_i, \mathbf{x}_j) = \sum_{q=1}^n \delta_{iq} e^{-\frac{|x_{iq} - x_{jq}|^2}{2\sigma^2}} \delta_{jq}, \quad (4.3)$$

gde δ_{iq} ima vrednost nula ako u vektoru \mathbf{x}_i ne postoji RSS vrednost koja odgovara ćeliji q . U suprotnom, parametar δ_{iq} je jednak jedinici. Međutim, potencijalni problem do koga može doći jeste veliko odstupanje proračunate kernel funkcije od stvarne vrednosti u slučaju kada je potrebno odbaciti veliki broj elemenata RSS vektora, što će biti i demonstrirano u jednom eksperimentu u nastavku rada.

4.2. POSTUPAK POZICIONIRANJA

Kao što je već spomenuto, predložena tehnika pozicioniranja može se svrstati u tzv. *mobile-assisted network-based* tehnike, jer se proračun koordinata vrši na strani mreže operatora na osnovu podataka (tj. RSS vrednosti) koje je mobilni terminal izmerio na svojoj trenutnoj poziciji.

Način funkcionisanja predložene tehnike pozicioniranja ilustrovan je na slici 4.1. Mobilni terminal periodično vrši merenja nivoa signala PLMN ćelija definisanih u listi suseda, kao deo standardne procedure upravljanja mobilnošću korisnika u *idle* modu ili *handover*-a u toku uspostavljenog poziva (tj. konekcije). Izmerene RSS vrednosti mobilni terminal prosleđuje preko servisne ćelije nazad ka mreži, tj. ka SMLC (*Serving Mobile Location Center*). U okviru SMLC centra vrši se proračun prostornih koordinata korišćenjem određenog SVM modela za pozicioniranje (slika 4.1).

Kao što je već pomenuto, proces merenja nivoa signala okolnih ćelija i generisanje izveštaja sa RSS vrednostima predstavlja standardnu proceduru u PLMN mrežama. U tom smislu, korišćenje RSS parametara za potrebe pozicioniranja ne zahteva izmene postojećeg hardvera, već samo određene softverske izmene kako bi se podržalo slanje mernog izveštaja sa većim brojem RSS vrednosti, koji potencijalno mogu pripadati različitim operatorima. Ipak, za realizaciju tehnike pozicioniranja kao *network-based* rešenja, neophodno je postojanje određenog broja SMLC centara u mreži, kao i implementacija SVM modela za pozicioniranje u okviru njih. U GSM mreži, SMLC može biti implementiran u okviru BSC kontrolera (*Base Station Controller*) ili zasebno [22]. Kod UMTS mreže, SMLC je uglavnom integrisan u okviru

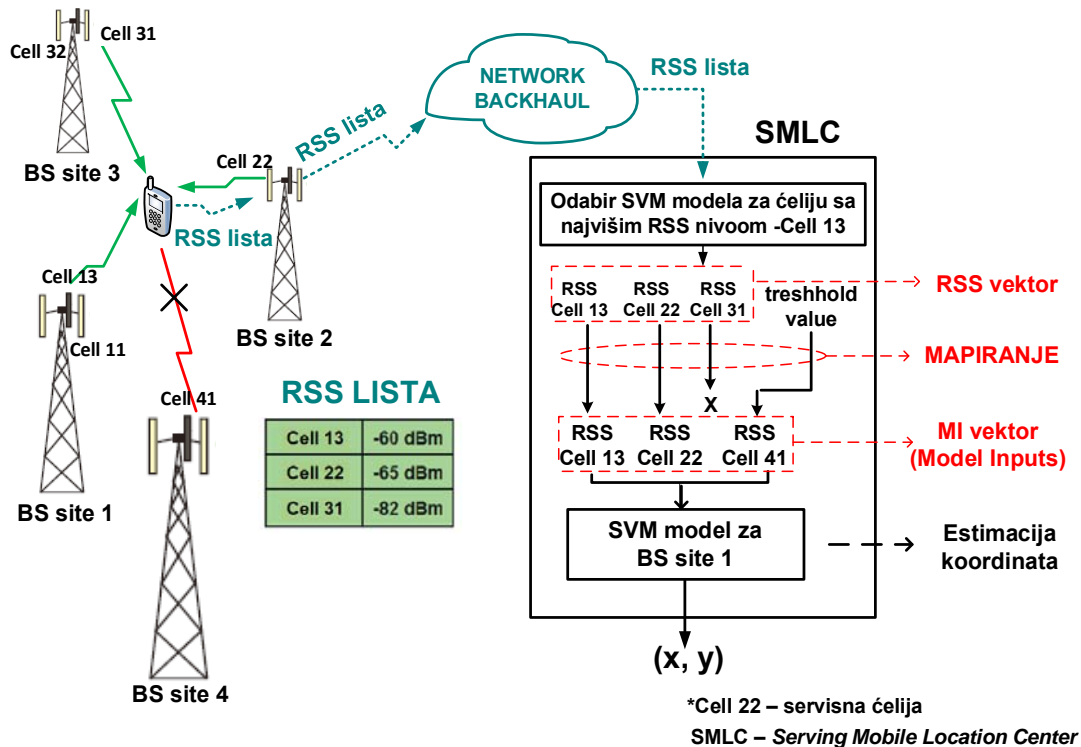
RNC (*Radio Network Controller*) kontrolera [23], dok se u slučaju LTE sistema E-SMLC (*Evolved SMLC*) ne nalazi u pristupnom delu mreže, već u jezgru, u vidu samostalnog elementa [24].

Ideja je da se SVM model za pozicioniranje realizuje na nivou lokacije bazne stanice (eng. *Base Station (BS) site*) tako da pokriva određenu geografsku oblast oko date lokacije. Kako se sa jedne BS lokacije obično realizuje više ćelija koje mogu pripadati različitim sistemima (GSM/DCS, UMTS i/ili LTE), a ponekad i različitim operatorima, jedan SVM model za pozicioniranje može potencijalno da se odnosi na više ćelija. U okviru nekog SMLC centra potrebno je onda implementirati SVM modele koji se odnose na ćelije koje se nalaze pod nadležnošću datog SMLC. Odabir konkretnog SVM modela za pozicioniranje vrši se na osnovu informacije o Cell-ID ćelije za koju je mobilni terminal izmerio najviši nivo signala. Razlog zbog koga se odabir konkretnog SVM modela za pozicioniranje vrši na osnovu Cell-ID ćelije sa najvišim nivoom signala, a ne Cell-ID servisne ćelije, leži u činjenici da usled određenih funkcionalnosti sistema (izbegavanja ping-pong efekta kod *handover*-a, *load balancing*-a, itd.), lokacija bazne stanice (tj. *BS site*) sa koje se realizuje servisna ćelija ne mora uvek biti najbliža mobilnom korisniku.

Nakon selekcije odgovarajućeg SVM modela za pozicioniranje vrši se mapiranje RSS vrednosti iz MR izveštaja u odgovarajuće ulaze modela za pozicioniranje. U nastavku rada, za ulaze modela biće korišćena oznaka MI (*model inputs*). Proces mapiranja uveden je kako bi se rešio problem nepostojećih RSS vrednosti u *fingerprints*-ima, razmatran u prethodnom poglavlju. U tu svrhu, za svaki SVM model neophodno je prvo definisati skup ćelija čiji su signali relevantni za proces pozicioniranja u datom geografskom okruženju. Pri tom, osim ćelija koje se realizuju sa BS lokacije (*BS site*) na koju se odnosi SVM model, skup relevantnih ćelija može sadržati i ćelije realizovane sa okolnih *site*-ova. Kriterijumi za odabir relevantnih ćelija, koji su razmatrani u ovom istraživanju, biće analizirani kasnije u radu.

Proces mapiranja vrši se tako da se izmerene RSS vrednosti iz MR izveštaja koje pripadaju ćelijama koje nisu relevantne za odabrani SVM model za pozicioniranje, odbacuju. S druge strane, u slučaju da neka ćelija koja je relevantna za odabrani SVM model nije „radio - vidljiva“ na trenutnoj poziciji mobilnog korisnika, za njoj

odgovarajuću MI vrednost usvaja se nivo signala koji odgovara minimalnoj vrednosti RSS parametra koju definiše 3GPP standard zavisno od tipa sistema (tabela 4.1) [92-94]. Tako na primer, u slučaju da u MR izveštaju nedostaje RSS vrednost neke GSM ćelije koja je relevantna za SVM model pozicioniranja, odgovarajući ulaz modela (MI) nakon mapiranja dobiće vrednost -110 dBm.



Slika 4.1. Ilustracija postupka određivanja pozicije mobilnog korisnika

Nakon završenog procesa mapiranja, u okviru SMLC čvora u mreži, odabrani SVM model za pozicioniranje vrši estimaciju prostornih koordinata mobilnog korisnika. U okviru ovog istraživanja razvijena su dva tipa modela za pozicioniranje zasnovana na SVM algoritmima mašinskog učenja: SVR model i kombinovani SVC&SVR model. SVR (*Support Vector Regression*) model vrši estimaciju koordinata mobilnog korisnika na osnovu mapiranih RSS vrednosti (MI) korišćenjem metode regresije. Drugi tip modela, nazvan kombinovani SVC&SVR model, zasniva se na segmentaciji prostora na podprostore (*space-partintining* princip). Proces pozicioniranja može se u datom slučaju podeliti na dve faze:

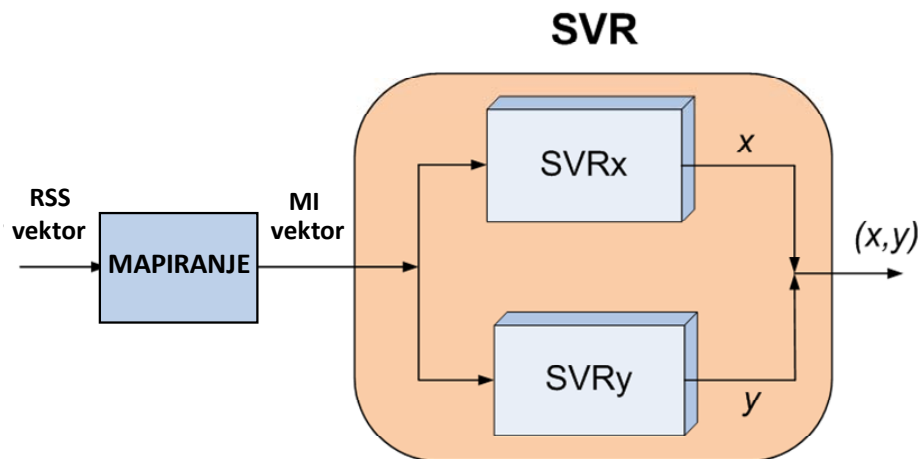
1. Određivanje podprostora u kome se korisnik nalazi korišćenjem SVC algoritma modifikovanog za rešavanje *multiclass* problema.
2. Određivanje prostornih koordinata korisnika u okviru datog podprostora metodom regresije, tj. primenom SVR algoritma.

Detaljan opis predložena dva tipa modela za pozicioniranje izložen je u nastavku.

4.3.SVR MODEL ZA POZICIONIRANJE

SVR model za pozicioniranje koristi metod regresije za određivanje prostornih koordinata korisnika na osnovu izmerenih RSS vrednosti koje se mapiraju u odgovarajuće ulaze modela za pozicioniranje (MI vrednosti). Kao što je već pomenuto, ulazi modela predstavljaju RSS vrednosti ćelija koje su relevantne za dati model pozicioniranja, odnosno geografsku oblast.

U okviru ovog istraživanja problem pozicioniranja razmatran je kao 2D problem. Iz datog razloga SVR model je realizovan kroz dva podmodela, SVRx i SVRy, namenjenih za estimaciju x i y koordinate, respektivno (slika 4.2).



Slika 4.2. Struktura SVR modela za pozicioniranje

Opšti teorijski opis SVR algoritma izložen je detaljno u poglavlju 3.4.3. U nastavku teksta biće ukratko opisan postupak primene SVR algoritma na konkretan problem pozicioniranja koji je razmatran u okviru ovog istraživanja.

Kod razmatranog problema pozicioniranja korišćena je sledeća notacija: neka se baza podataka (*fingerprint baza*) koja se koristi za treniranje SVR modela sastoji od l parova ulazno-izlaznih podataka prikupljenih u nekoj geografskoj oblasti. Za i -ti par ($i = 1..l$) ulaz u model pozicioniranja, \mathbf{MI}_i , jeste vektor od N mapiranih RSS vrednosti, koje je mobilni terminal izmerio na lokaciji i . N u datom slučaju predstavlja broj relevantnih ćelija za posmatranu geografsku oblast. Željeni izlaz modela u datom slučaju su koordinate (x_i, y_i) .

U posmatranom slučaju, zadatak SVR algoritma jeste da izvrši mapiranje ulaznih podataka (\mathbf{MI}_i) u karakterističan prostor (*feature space*) i aproksimira linearnu funkciju koja povezuje ulazne podatke u karakterističanom prostoru sa odgovarajućim prostornim koordinatama. Kako je SVR model realizovan kroz dva podmodela, SVRx i SVRy, neophodno je aproksimirati dve funkcije modela, koje će vršiti estimaciju x i y koordinate, respektivno. U oba slučaja primenjena je ista metodologija, tako da je u nastavku teksta dat opis postupka na primeru realizacije SVRx podmodela.

U slučaju SVRx podmodela, funkcija modela za estimaciju x koordinate može se predstaviti na sledeći način:

$$x_i = f(\phi(\mathbf{MI}_i)) = \mathbf{w}^T \phi(\mathbf{MI}_i) + b, \quad (4.4)$$

gde $\phi(\cdot)$ predstavlja nelinearno mapiranje ulaznih podataka iz originalnog prostora R^N u karakterističan prostor F veće dimenzionalnosti, tako da je $\phi: R^N \rightarrow F, \mathbf{MI}_i \rightarrow \phi(\mathbf{MI}_i)$. Problem regresije sada se svodi na određivanje vektora težinskih koeficijenata \mathbf{w} i konstante b .

U okviru ovog rada korišćena je kvadratna ε -insensitive funkcija gubitka, kako bi se kroz proces treniranja i optimizacije modela vršilo potiskivanje velikih vrednosti grešaka estimacije:

$$L_2^\varepsilon = \begin{cases} 0 & , |x_i - f(\phi(\mathbf{MI}_i))| \leq \varepsilon \\ \left(|x_i - f(\phi(\mathbf{MI}_i))| - \varepsilon \right)^2 & , |x_i - f(\phi(\mathbf{MI}_i))| > \varepsilon \end{cases}, \quad (4.5)$$

gde je ε unapred definisana pozitivna konstanta. Uvodeći *slack* promenljive ξ_i i $\bar{\xi}_i$ za trening tačke koje se nalaze van ε regiona, primarni optimizacioni problem može se definisati kao:

$$\begin{aligned} \min \quad & C \sum_{i=1}^l (\xi_i^2 + \bar{\xi}_i^2) + \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{pod uslovom} \quad & x_i \geq f(\phi(\mathbf{MI}_i)) - \varepsilon - \bar{\xi}_i, \\ & x_i \leq f(\phi(\mathbf{MI}_i)) + \varepsilon + \xi_i \\ & i = 1, \dots, l. \end{aligned} \quad (4.6)$$

Regularizacioni parametar C kontroliše „*trade-off*“ između ukupne dozvoljene greške modela na trening skupu i kompleksnosti datog modela (tj. funkcije regresije).

Koristeći postupak opisan u okviru poglavlja 3.4.3, optimizacioni problem dat izrazom 4.6 moguće je rešiti uvodeći *Lagrang*-ove multiplikatore $(\alpha_i, \bar{\alpha}_i)$ i korišćenjem KKT teoreme. Dualna (finalna) forma optimizacionog problema može se predstaviti sledećim izrazom:

$$\begin{aligned} L(\boldsymbol{\alpha}, \bar{\boldsymbol{\alpha}}) = & -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \bar{\alpha}_i)(\alpha_j - \bar{\alpha}_j) k(\mathbf{MI}_i, \mathbf{MI}_j) - \frac{1}{2C} \sum_{i=1}^l (\alpha_i^2 + \bar{\alpha}_i^2) \\ & + \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) x_i - \varepsilon \sum_{i=1}^l (\alpha_i + \bar{\alpha}_i) \end{aligned} \quad (4.7)$$

gde $k()$ predstavlja kernel funkciju, $k(\mathbf{MI}_i, \mathbf{MI}_j) = \phi^T(\mathbf{MI}_i) \phi(\mathbf{MI}_j)$. Dalje, izraz 4.7 potrebno je maksimizirati po $\boldsymbol{\alpha}$ i $\bar{\boldsymbol{\alpha}}$, uz sledeća ograničenja:

$$\begin{aligned} \alpha_i & \geq 0, \\ \bar{\alpha}_i & \geq 0, \\ \bar{\alpha}_i \alpha_i & = 0, \text{ i} \\ \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) & = 0. \end{aligned}$$

Rešavanjem ovog QP problema po $\boldsymbol{\alpha}$ ($\bar{\boldsymbol{\alpha}}$) i predstavljanjem vektora težinskih koeficijenata \mathbf{w} pomoću izraza 3.72 (poglavlje 3.4.3), dolazi se do funkcije predikcije SVRx podmodela, kojom se u *online* fazi vrši estimacija x koordinate za novi vektor RSS vrednosti doveden na ulaz modela za pozicioniranje (tj. \mathbf{MI} vektor):

$$x = f(\phi(\mathbf{MI})) = \sum_{i=1}^l (\alpha_i - \bar{\alpha}_i) k(\mathbf{MI}, \mathbf{MI}_i) + b. \quad (4.8)$$

Pri tom, konstanta b u okviru funkcije predikcije SVRx podmodela, određena je postupkom opisanim izrazom 3.83.

Kao što je već spomenuto, ista metodologija primenjena je i u postupku realizacije SVRy podmodela. Na ovom mestu potrebno je još istaći da na naučene funkcije regresije za estimaciju x i y koordinata u velikoj meri utiče odabir tipa *kernel* funkcije, kao i usvojene vrednosti parametara ε i C tokom trening faze. Način odabira datih parametara biće opisan u nastavku rada, za slučaj konkretne implementacije SVR modela za pozicioniranje u *outdoor* i *indoor* test okruženju.

4.4.KOMBINOVANI SVC&SVR MODEL ZA POZICIONIRANJE

Kombinovani SVC&SVR model za pozicioniranje koristi princip segmenatcije prostora od interesa na manje celine (podprostore). U prvom koraku određuje se podprostor u kome se korisnik trenutno nalazi, nakon čega se određuju koordinate korisnika u okviru datog podprostora. Navedeni pristup uveden je kako bi se ispitaio uticaj veličine prostora, koji pokriva neki SVR model za pozicioniranje, na tačnost pozicioniranja. Naime, osnovna pretpostavka jeste da su u slučaju realizacije modela za pozicioniranje za manju geografsku oblast, trening podaci prikupljeni u datom prostoru međusobno sličniji (homogeniji), i u pogledu izmerenih RSS vrednosti i prostornih koordinata. Time je moguće ostvariti bolje početne uslove za rešavanje problema regresije, odnosno, za pronalaženje funkcije modela koja omogućava tačniju predikciju. Princip segmenatcije prostora (*space-partitioning*) već se pokazao kao uspešan u slučaju pronalaženja funkcije modela u podacima korišćenjem neuralnih mreža [37].

Struktura kombinovanog SVC&SVR modela može se predstaviti kroz dva sloja (slika 4.3):


- SVC sloj – zadužen za rešavanje *multiclass* problema određivanja podprostora u kome se korisnik nalazi u okviru neke geografske oblasti.

- SVR sloj – zadužen za estimaciju koordinata trenutne pozicije mobilnog korisnika u okviru selektovane podoblasti.

4.4.1. KOMBINOVANI SVC&SVR MODEL

Kao što je već spomenuto, standardna formulacija SVC algoritma odnosi se na slučaj rešavanja problema binarne klasifikacije. S druge strane donošenje odluke o podprostoru u kome se korisnik nalazi predstavlja u opštem slučaju *multiclass* problem.

U okviru ovog istraživanja, za konstrukciju SVM *multiclass* klasifikatora odabran je pristup „jedan-protiv-svih“ („*one-vs-all*“) [86-87]. *One-vs-all* pristup podrazumeva da se *multiclass* klasifikator za M klasa konstruiše pomoću M nezavisnih binarnih klasifikatora.



Slika 4.3. Struktura kombinovanog SVC&SVR modela za pozicioniranje

Kod kombinovanog SVC&SVR modela sa jednim SVC slojem (slika 4.3), *multiclass* SVC klasifikator (tj. SVC sloj) realizovan je sa M binarnih SVC klasifikatora. Binarni SVC klasifikatori realizovani su kao *soft-margin* klasifikatori, kako bi se obezbedila veća otpornost modela na šum i postojanje netipičnih podataka (*outliers*) u trening skupu. Detaljan opis *soft-margin* SVC klasifikatora izložen u

poglavljju 3.4.2. U nastavku teksta biće opisane modifikacije primenje na binarni SVC *soft-margin* klasifikator kako bi se prilagodio posmatranom problemu određivanja podoblasti u kojoj se mobilni korisnik nalazi.

U slučaju korišćenog „one-vs-all“ pristupa, binarni SVC klasifikatori realizovani su tako da u „idealnom“ slučaju m -ti SVC klasifikator generiše kao željeni izlaz vrednost “-1” – ako ulazni vektor \mathbf{MI}_i , izmeren na poziciji i , pripada podprostoru m ($m=1..M$), ili “+1” – ako ne pripada datom podprostoru. Za svaki binarni SVC klasifikator ($m=1..M$) potrebno je pronaći funkciju modela f_m kojom se ulazni trening podaci ($i=1,..,l$) razdvajaju na dve klase na osnovu pripadnosti ili nepripadnosti posmatranom podprostoru m :

$$f_m(\phi(\mathbf{MI}_i)) = \mathbf{w}_m^T \phi(\mathbf{MI}_i) + b_m. \quad (4.9)$$

Pri tom, $\phi()$ predstavlja nelinearno mapiranje ulaznih podataka iz originalnog u karakterističan prostor. Kao što je već spomenuto, u slučaju *soft-margin* SVC klasifikatora dozvoljeno je da se određeni broj trening tačaka nađe sa pogrešne strane margine ili čak sa pogrešne strane razdvojne hiper-ravni, ali uz uvođenje tzv. „penala“ za date tačke u vidu *slack* promenljive, $\xi_{m,i} \geq 0$ (poglavljje 3.4.2).

Optimizacioni problem koji je potrebno rešiti ima sledeću formu (poglavljje 3.4.2):

$$\min \quad \frac{1}{2} \|\mathbf{w}_m\|^2 + C \sum_{i=1}^l \xi_{m,i}, \quad C \geq 0 \quad (4.10)$$

$$\text{pod uslovom: } class_{m,i}(\mathbf{w}_m^T \phi(\mathbf{MI}_i) + b_m) \geq 1 - \xi_{m,i}, \quad i = 1, \dots, l \quad \text{i} \quad \xi_{m,i} \geq 0,$$

gde $class_{m,i}$ ima vrednost “-1” – ako ulazni vektor \mathbf{MI}_i iz trening baze, izmeren na poziciji i , pripada podprostoru m ($m=1..M$), tj. “+1” – ako ne pripada datom podprostoru.

Kao što je već opisano u poglavljju 3.4.2, uvodeći *Lagrange* multiplikatore i primenom KKT teoreme, posmatrani optimizacioni problem može se predstaviti u krajnjoj formi:

$$\max \quad L(\boldsymbol{\alpha}_m) = \sum_{i=1}^l \alpha_{m,i} - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_{m,i} \alpha_{m,j} \text{class}_{m,i} \text{class}_{m,j} k(\mathbf{MI}_i, \mathbf{MI}_j) \quad *$$

pod uslovom: $0 \leq \alpha_{m,i} \leq C$ i $\sum_{i=1}^l \alpha_{m,i} \text{class}_{m,i} = 0$. (4.11)

Rešavanjem datog optimizacionog problema dolazi se do krajnje forme funkcije modela m -tog binarnog SVC klasifikatora:

$$f_m(\mathbf{MI}) = \sum_{i=1}^l \alpha_{m,i} \text{class}_{m,i} k(\mathbf{MI}, \mathbf{MI}_i) + b_m, \quad (4.12)$$

gde je konstantu b_m moguće odrediti na način već opisan u poglavlju 3.4.2 (izraz 3.60).

U slučaju posmatrane realizacije *multiclass* klasifikatora, estimacija podprostora definisana je sledećim postupkom. RSS vrednosti izmerene na trenutnoj (nepoznatoj) poziciji mobilnog korisnika mapiraju se u odgovarajuće ulaze modela za pozicioniranje (\mathbf{MI}), tj u RSS vrednosti ćelija relevantnih za dati model. Tako dobijeni \mathbf{MI} vektor dovodi se na ulaz M binarnih *soft-margin* SVC klasifikatora (gde je M broj podprostora definisan za posmatranu geografsku zonu). Binarni SVC klasifikatori treniraju se na takav način da na svom izlazu generišu vrednost “-1” ako ulazni \mathbf{MI} vektor pripada njihovom podprostoru, odnosno “+1” ako ne pripada. U idealnom slučaju, samo jedan binarni SVC klasifikator bi trebalo da generiše vrednost “-1”, dok bi svi ostali SVC klasifikatori za posmatrani \mathbf{MI} vektor trebalo da generišu vrednost “+1”. Međutim, u realnim situacijama moguće je da se desi da više SVC klasifikatora generiše vrednost “-1” na svom izlazu, ili s druge strane, da je ni jedan ne generiše.

Kako bi se izbegla potencijalna nejednoznačnost u klasifikaciji, izlaz binarnih SVC klasifikatora je modifikovan tako da ne bude znak funkcije modela (izraz 3.61), već realna vrednost funkcije modela (slika 4.3):

$$SVC_{m_izlaz} = f_m(\mathbf{MI}) = \sum_{i=1}^l \alpha_{m,i} \text{class}_{m,i} k(\mathbf{MI}, \mathbf{MI}_i) + b_m. \quad (4.13)$$

U datom slučaju, odluka o podprostoru donosi se na osnovu informacije o tome koji je binarni SVC klasifikator generisao najmanju vrednost na svom izlazu. Drugim rečima, algoritam poredi izlaze svih M binarnih klasifikatora i donosi odluku da se mobilni korisnik nalazi u podprostoru m ako je za \mathbf{MI} vektor formiran na njegovoj trenutnoj

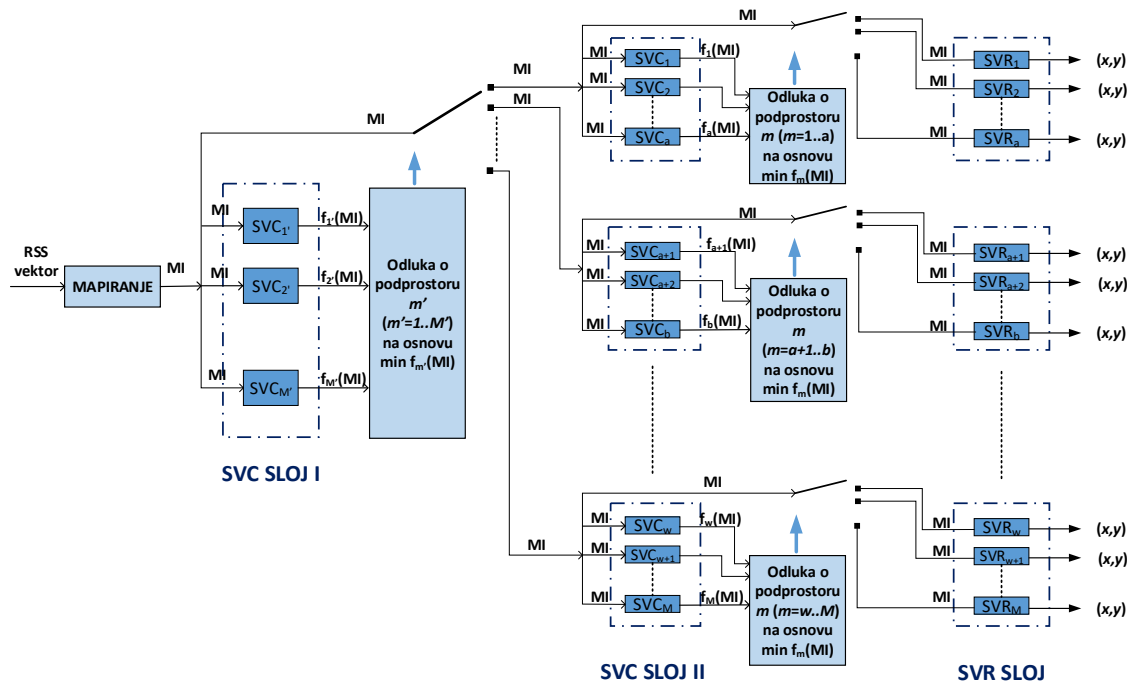
lokaciji, najmanja izlazna vrednost generisana upravo na izlazu m -tog binarnog SVC klasifikatora.

Nakon donošenja odluke o podprostoru, **MI** vektor se prosleđuje SVR sloju koji se sastoji iz više SVR podmodela. Broj SVR podmodela u okviru SVR sloja odgovara broju podprostora, dok je struktura SVR podmodela identična strukturi opisanoj u sekciji 4.3. Pri tom, kontrolna logika prosleđuje **MI** vektor na ulaz samo onog SVR podmodela koji se odnosi na odabrani podprostor, nakon čega dati SVR podmodel vrši estimaciju x i y koordinate na način opisan u poglavlju 4.3. Kako jedan SVR podmodel pokriva samo jedan deo (podprostor) posmatrane geografske oblasti, za treniranje SVR podmodela koriste se samo podaci (*fingerprint-i*) prikupljeni u njemu odgovarajućem podprostoru. Na taj način moguće je ostvariti bolje početne uslove za pronalaženje funkcije modela u podacima primenom metode regresije.

4.4.2. ALTERNATIVNI KOMBINOVANI SVC&SVR MODEL SA UGNEŽDENIM SVC SLOJEVIMA

U okviru ovog istraživanja razmatrana je i alternativna struktura SVC sloja u vidu više ugnežđenih SVC slojeva (*nested structure*). Navedena struktura može se koristiti u slučaju hijerarhijske segmentacije prostora prvo na veće podoblasti, nakon čega se date podoblasti dele na više manjih podprostora. Na slici 4.4. prikazan je primer *nested* strukture sa dva SVC sloja za slučaj podele neke geografske zone prvo na M' podoblasti, a potom dalje segmentacije svake podoblasti na određeni broj podprostora (ukupno M podprostora).

U slučaju *nested* strukture SVC sloja, donošenje odluke o podprostoru vrši se u dve ili više etapa. Svaki SVC sloj realizuje se na isti način kao kod osnovnog SVC&SVR modela za pozicioniranje, opisanog u prethodnom poglavlju.

Slika 4.4. Primer kombinovanog SVC&SVR modela sa *nested* strukturom

Postupak estimacije pozicije mobilnog korisnika je sledeći. Prvo se određuje šira podoblast u kojoj se korisnik nalazi (prvi podprostor u hijerarhiji). U slučaju da se data podoblast sastoji od npr. a manjih podprostora, \mathbf{MI} vektor se prosleđuje odgovarajućoj grupi od a binarnih SVC klasifikatora u sledećem, ugneždenom SVC sloju. Nakon određivanja sledećeg podprostora, postupak se ponavlja sve dok se ne dođe do najmanjeg podprostora u hijerarhiji podele. Nakon toga, \mathbf{MI} vektor se prosleđuje SVR sloju, tačnije SVR podmodelu koji pokriva dati podprostor (najmanji u hijerarhiji podele). Odabrani SVR podmodel vrši estimaciju x i y koordinate kao u slučaju prethodno opisanog SVC&SVR modela za pozicioniranje.

Iako korišćenje *nested* strukture povećava složenost modela za pozicioniranje, korišćenjem ovakvog pristupa u pojedinim scenarijima moguće je postići smanjenje vremena potrebnog za treniranje modela u celosti. Naime, u slučaju potrebe realizacije kombinovanog SVC&SVR modela za širu geografsku oblast, sa većim brojem definisanih podoblasti, vreme treniranja može postati negativan aspekt praktične implementacije. Kod osnovnog SVC&SVR modela, korišćeni “*one-against-all*” pristup podrazumeva treniranje po jednog SVC modela za svaku podoblast, korišćenjem pri tom svih trening podataka prikupljenih u geografskoj zoni koju treba da pokrije dati

SVC&SVR model za pozicioniranje. S druge strane, kod korišćene *nested* strukture SVC sloja, samo se SVC klasifikatori u prvom sloju treniraju korišćenjem svih trening podataka prikupljenih u datoj geografskoj oblasti. Već u sledećem SVC sloju, SVC modeli se treniraju korišćenjem samo dela trening podataka, koji su prikupljeni u određenom podprostoru. U tom smislu, ovakva arhitektura SVC sloja može biti povoljna za realizacije kombinovanih SVC&SVR modela za pozicioniranje za *outdoor* geografske oblasti, što će biti analizirano u nastavku rada.

5. PRIMENA SVM ALGORITAMA ZA POZICIONIRANJE U *OUTDOOR* OKRUŽENJU

U okviru ovog poglavlja biće prikazani rezultati implementiranja dva predložena SVM modela za pozicioniranje, SVR i kombinovanog SVC&SVR modela, korišćenjem podataka prikupljenih u realnom, suburbanom okruženju na teritoriji grada Beograda. Predloženi SVM modeli biće analizirani sa stanovišta tačnosti pozicioniranja, kompleksnosti i kašnjenja. Dodatno, biće prikazani rezultati komparativne analize performansi predloženih SVM modela i drugih obećavajućih metoda za pozicioniranje iz poglavlja 2.4.3, za slučaj kad se testiraju u istom *outdoor* okruženju.

Deo rezultata prikazanih u okviru ovog poglavlja disertacije, publikovano je u radovima **Error! Reference source not found.**

5.1. TEST *OUTDOOR* OKRUŽENJE I DEFINISANJE RELEVANTNIH RADIO IZVORA

5.1.1. *PRIKUPLJANJE PODATAKA*

Kao test *outdoor* okruženje korišćena je geografska oblast oko jedne BS lokacije (*site-a*) koja pripada mrežnom operatoru Mobilne Telefonije Srbije (MTS), a nalazi se u suburbanoj (*light urban*) zoni grada Beograda. Teren u datoj oblasti je ravničarski, sa gusto raspoređenim stambenim objektima srednje i niže visine. Kako se sa jedne lokacije obično realizuje više ćelija koje mogu pripadati različitim sistemima, a ponekad i različitim operatorima, u opštem slučaju, jedan SVM model za pozicioniranje može pokrivati geografsku zonu više ćelija.

Podaci o nivoima signala PLMN ćelija u datoj test zoni prikupljeni su tokom merne kampanje u vidu *drive* testa sprovedene 2009. godine [36]. U datom trenutku, mrežni operator MTS imao je na teritoriji grada Beograda oko 200 GSM BTS, 170 DCS BTS i 130 UMTS NodeB. Za potrebe prikupljanja podataka korišćen je mrežni skener *Radio Network Analyzer Rohde&Schwarz TSMQ* (R&S®TSMQ) u okviru R&S ROMES sistema [104] prikazanog na slici 5.1.



Slika 5.1. *Radio Network Analyzer Rohde&Schwarz TSMQ* (R&S®TSMQ) mrežni skener

R&S®TSMQ ima mogućnost merenja niza fizičkih parametara radio signala, kao i mogućnost demodulacije/dekodovanja sistemskih informacija GSM, DCS i UMTS sistema. Osetljivost GSM/DCS prijemnika R&S®TSMQ mrežnog skenera iznosi -112dBm, dok je osetljivost UMTS prijemnika -122dBm. Od sistemskih informacija koje R&S®TSMQ mrežni skener može da demoduliše/dekoduje, od posebnog značaja su identifikator PLMN ćelije (*Cell ID*), identifikator bazne stanice (BTS/NodeB), kao i identifikator mreže tj. mobilnog operatora (*Mobile Network Code, MNC*). R&S®TSMQ mrežni skener omogućava prikupljanje svih relevantnih podataka za pozicioniranje koji su inače dostupni mobilnom terminalu. Razlog za korišćenje R&S®TSMQ mrežnog skenera, a ne mobilnog terminala za prikupljanje podataka u *outdoor*, kao i kasnije u *indoor* mernoj kampanji, jeste u činjenici da omogućava merenje i beleženje RSS nivoa za veći broj okolnih PLMN ćelija. Na taj način, moguće je steći bolji uvid u radio-vidljivost i kvalitet radio-signala okolnih ćelija u geografskoj zoni od interesa, što

omogućava kvalitetniji izbor relevantnih izvora radio signala za potrebe pozicioniranja. U posmatranom slučaju, relevantni radio izvori su odabrane PLMN ćelije čiji se RSS nivoi koriste kao ulazni podaci SVM modela za pozicioniranje (*model inputs*, MI).

Dodatno, R&S ROMES merni sistem bio je opremljen diferencijalnim GPS prijemnikom za georeferenciranje mernih lokacija. Izmereni RSS nivoi okolnih PLMN ćelija, zajedno sa sistemskim informacijama i GPS koordinatama mernih lokacija, beleženi su korišćenjem *laptop* računara opremljenog sa „R&S Romes v4“ softverom.

Na slici 5.2 prikazana je geografska zona za koju su razvijeni predloženi SVM modeli za pozicioniranje. Za datu zonu usvojeno je da bude kružnog oblika sa centrom u poziciji BS *site*-a mobilnog operatora MTS, na koji se odnose realizovani SVM modeli. Pozicija MTS BS *site*-a na slici 5.2 je označena zelenim znakom „+“. Poluprečnik date zone određen je prvo izdvajanjem mernih tačaka u kojima je najviša izmerena RSS vrednost potekla od ćelija implementiranih sa posmatranog BS *site*-a. Dalje, poluprečnik je određen na takav način da se 99.9% prethodno izdvojenih mernih tačaka nađe unutar date oblasti. Datom procedurom dobijena je *outdoor* test zona poluprečnika 1km, a njoj odgovarajuća baza podataka sadržala je 31 391 mernu tačku. Prostorni raspored mernih tačaka u okviru test zone prikazan je plavom bojom.



Slika 5.2 Test *outdoor* okruženje

5.1.2. DEFINISANJE RELEVANTNIH RADIO IZVORA

Za geografsku oblast koju pokriva neki SVM model za pozicioniranje potrebno je definisati relevantne radio izvore, odnosno PLMN ćelije čiji će se RSS nivoi koristiti kao ulazni podaci SVM modela za pozicioniranje (tj. MI vrednosti).

SVM modeli za pozicioniranje su realizovani korišćenjem infrastrukture GSM i DCS sistema. GSM (DCS) sistem predstavlja i dalje globalno najrasprostranjeniji PLMN sistem. Dodatno, GSM primopredajnici su implementirani u gotovo svim mobilnim terminalima koji su danas u upotrebi. Dakle, motiv odabira infrastrukture GSM i DCS sistema bio je da se ispituju mogućnosti predloženih SVM metoda pozicioniranja pod uslovima koji omogućavaju najveću teritorijalnu dostupnost sistema za pozicioniranje u ovom trenutku, kao i mogućnost korišćenja beneficija takvog sistema od strane većine korisnika. Navedeni aspekt je naročito bitan sa stanovišta realizacije bezbednosnih servisa (npr. servis hitnog poziva), koji bi u idealnom slučaju trebali da budu dostupni svuda i svim mobilnim korisnicima, nezavisno od modela njihovog terminala.

Za potrebe eksperimenata sprovedenih u test *outdoor* okruženju, broj relevantnih GSM/DCS ćelija ograničen je na takav način da bude u saglasnosti sa maksimalnim brojem RSS merenja koja se mogu slati nazad ka mreži putem standardnog MR izveštaja (*Standard Measurement Report*) [92]. Cilj postavljanja ovakvog ograničenja bio je da se ispituju mogućnosti predložene tehnike pozicioniranja po pitanju tačnosti u uslovima koji su podržani postojećom GSM/DCS signalizacijom. U skladu sa tim, odabrano je 7 relevantnih GSM i 7 relevantnih DCS ćelija, koje pripadaju operatoru MTS. Kao kriterijum za odabir relevantnih ćelija korišćena je radio-vidljivost ćelija u okviru geografske zone koju pokriva SVM model za pozicioniranje. Drugim rečima, odabrane su ćelije koje su bile radio-vidljive u najvećem procentu mernih tačaka u posmatranoj test *outdoor* zoni.

Problem nepostojeće MI vrednosti u situacijama kada neka relevantna ćelija nije radio-vidljiva na trenutnoj poziciji mobilnog korisnika (ili njen RSS nivo nije dovoljno visok da bi data ćelija bila uvršćena u MR izveštaj), rešen je kroz proces mapiranja opisan u poglavlju 4.2. U datoj situaciji, za nepostojeću MI vrednost GSM ili DCS

ćelije usvajana je vrednost od -110dBm, koja odgovara minimalnoj vrednosti RSS parametra ($RxLev$) za GSM i DCS sistem prema 3GPP standardu[92].

5.2.TRENIRANJE I OPTIMIZACIJA SVM MODELA ZA POZICIONIRANJE

Za test *outdoor* okruženje sa slike 5.2, realizovana su dva tipa SVM modela za pozicioniranje: SVR model i kombinovani SVC&SVR model.

Celokupna baza podataka podeljena je na slučajan način na tri nezavisna podskupa, namenjenih treniranju, validaciji i verifikaciji predloženih SVM modela (podskupovi podataka veličine 15%, 35% i 50% originalne baze, respektivno). Tako formirani podskupovi podataka korišćeni su za implemenatciju i verifikaciju svih SVM modela implementiranih za posmatrano test *outdoor* okruženje. Jedino su se kod pojedinih modela razlikovali ulazni MI vektori pridruženi mernim tačkama (tj. rezultat mapiranja izmerenih nivoa signala), u zavisnosti od odabranog kriterijuma za selekciju relevannih ćelija za dato okruženje. Predloženi modeli implementirani su u programskom okruženju MATLAB. Treniranje i kasnija verifikacija performansi modela za pozicioniranje izvršena je na računaru sa procesorom *Intel Core 2 Quad Processor @2.4GHz* i 2GB RAM memorije.


5.2.1. REALIZACIJA SVR MODELA ZA POZICIONIRANJE

Struktura implemetiranog SVR modela opisana je detaljno u poglavlju 4.3. Kao što je već pomenuto, pri realizaciji SVR modela za pozicioniranje korišćena je kvadratna ϵ -insensitive funkcija greške kako bi se tokom procesa treniranja vršilo veće potiskivanje (penalizacija) velikih razlika u stvarnoj i estimovanoj izlaznoj vrednosti.

U opštem slučaju, rezultat treniranja modela (tj. naučena funkcija modela) u velikoj meri zavisi od odabira tipa kernel funkcije, njenih parametara, kao i veličine ϵ regiona i vrednosti regularizacionog parametra C . Iz datog razloga, u inicijalnoj fazi eksperimenta ispitivane su prvo performanse modela za više različitih tipova kernel funkcija: RBF (*Radial Basis Function*), *Laplacian*, *Generalized T-Student*, *Cauchy*,

ANOVA RBF i *SPLINE* kernel funkcija. Kako bi se izbeglo prepodešavanje modela (*overfitting*) na trening skup podataka, odnosno izdvajanje nedovoljno opšte relacije iz trening skupa ograničene veličine, optimalne vrednosti parametara kernel funkcije, kao i parametara ε i C , određivane su kroz proces validacije modela na nezavisnom skupu podataka (tzv. validacionom skupu).

U inicijalnom eksperimentu utvrđivanja optimalne kernel funkcije, zaseban SVR model implementiran je za svaku od 6 navedenih kernel funkcija i optimalno istreniran tako da srednja vrednost greške pozicioniranja datog modela na validacionom skupu bude minimalna. Pri tom, u datom eksperimentu korišćen je manji trening skup sastavljen od 10% podataka originalne baze. Tačnost pozicioniranja tako optimizovanih SVR modela testirana je potom na nezavisnom verifikacionom skupu (preostalih 50% tačaka originalne baze). Kumulativne funkcije raspodele vrednosti grešaka pozicioniranja (*Distance Error, DE*) SVR modela, implementiranih za 6 različitih tipova kernel funkcija i testiranih na verifikacionom skupu, prikazane su na slici 5.3. Potrebno je napomenuti, da će se u nastavku rada pod pojmom greške pozicioniranja (skraćeno DE), podrazumevati Euklidsko rastojanje između stvarne i estimirane pozicije mobilnog terminala.



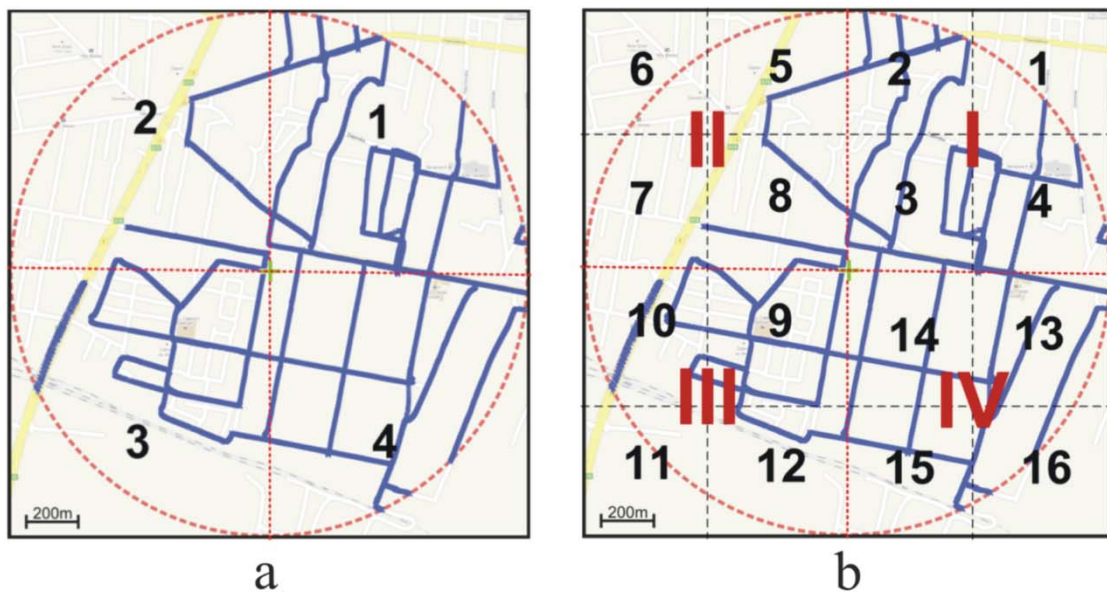
Slika 5.3. Uticaj odabira tipa kernel funkcije na tačnost SVR modela za pozicioniranje

Na osnovu dobijenih rezultata, *Laplacian* kernel funkcija odabrana je kao najbolje rešenje za implicitno uvođenje karakterističnog prostora. Dobijeni rezultati su u skladu

sa očekivanjima jer se *Laplacian* kernel funkcija, kao jedna varijanta RBF kernel funkcije, često koristi u situacijama kad postoji šum u trening podacima, pogotovo u slučaju potrebe za većim regulacionim uticajem na trening podatke [105]. Iz tog razloga, u nastavku istraživanja, *Laplacian* kernel funkcija je korišćena u svim implementacijama SVR, kao i kombinovanog SVC&SVR modela za pozicioniranje.

5.2.2. REALIZACIJA SVC&SVR MODELA ZA POZICIONIRANJE

U slučaju realizacije kombinovanog SVC&SVR modela, primenjen je pristup segmentacije zone pokrivanja modela za pozicioniranje na podprostore (*space-partitioning* princip). Posmatrano test *outdoor* okruženje podeljeno je geometrijskim putem na 4 i 16 podprostora (slika 5.4.a i 5.4.b, respektivno), Za data dva tipa segmentacije prostora, implemetirani su kombinovani SVC&SVR modeli: SVC&SVR_{2x2} i SVC&SVR_{4x4}.

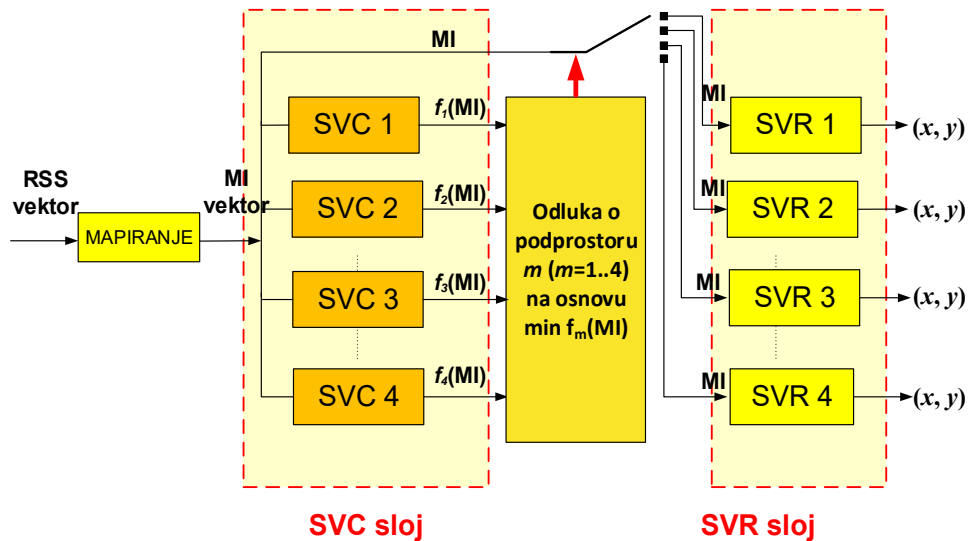



Slika 5.4. Podela test *outdoor* okruženja na podprostore:

a) SVC&SVR_{2x2} i b) SVC&SVR_{4x4}

Pri implementaciji SVC&SVR_{2x2} modela primenjen je pristup realizacije SVC klasifikatora u jednom sloju, opisan detaljno u poglavlju 4.4.1. Struktura SVC&SVR_{2x2} modela prikazan je na slici 5.5. S druge strane, za realizaciju SVC&SVR_{4x4} modela

korišćena je alternativna *nested* struktura sa ugneždenim SVC slojevima, detaljno opisana u poglavlju 4.4.2 (slika 5.6). U posmatranom slučaju, geografska zona od interesa podeljena je prvo na 4 podoblasti ($k=I..IV$), nakon čega je svaka od datih podoblasti podeljena na još 4 podprostora ($m=1..16$).

Slika 5.5. Struktura SVC&SVR_{2x2} modelaSlika 5.6. *Nested* struktura SVC&SVR_{4x4} modela

Za oba tipa kombinovanog SVC&SVR modela korišćeni su isti podskupovi podataka za treniranje, validaciju i verifikaciju, kao i kod prethodno opisanog SVR modela (veličine 15%, 35% i 50% originalne baze, respektivno). Međutim, u slučaju SVC&SVR_{2x2} modela, samo SVC_m podmodeli ($m=1..4$) su trenirani sa svim podacima trening skupa, dok su SVR_m podmodeli ($m=1..4$) trenirani samo sa delom podataka originalnog trening skupa, i to onima koji su prikupljeni u njima odgovarajućem podprostoru m . Isti princip primenjen je i prilikom treniranja SVC&SVR_{4x4} modela sa *nested* strukturom. SVC_k klasifikatori sloja I ($k=I..IV$) trenirani su sa svim podacima trening skupa. S druge strane, svaki SVC_m podmodel SVC sloja II ($m=1..16$) treniran je sa delom trening podataka prikupljenim u odgovarajućoj podoblasti k ($k=I..IV$). Dodatno, svaki SVR_m podmodel SVR sloja ($m=1..16$), treniran je samo sa delom trening podataka koji su prikupljeni u odgovarajućem podprostoru m .

Svi SVC i SVR podmodeli realizovani su korišćenjem *Laplacian* kernel funkcije. Kao i u slučaju SVR modela, optimalne vrednosti parametra kernel funkcije, kao i vrednosti ε i C , određene su kroz proces validacije modela na nezavisnom skupu podataka (tzv. validacionom skupu).

5.3. ANALIZA PERFORMANSI SVR I SVC&SVR MODELA ZA POZICIONIRANJE U *OUTDOOR* OKRUŽENJU

5.3.1. TAČNOST POZICIONIRANJA SVR METODE

Analiza tačnosti pozicioniranja predloženih SVM modela izvršena je kroz proces verifikacije, odnosno testiranjem performansi modela na nezavisnom, verifikacionom skupu (preostalih 50% tačaka iz baze podataka).

U prvom eksperimentu analizirana je tačnost pozicioniranja SVR modela za slučaj da se kao ulazni podaci (MI vrednosti) koriste nivoi signala:


- isključivo 7 relevantnih GSM ćelija (7GSM SVR model),
- isključivo 7 relevantnih DCS ćelija (7DCS SVR model),
- n GSM i m DCS ćelija.

Za poslednji razmatrani slučaj implementirana su tri kombinovana n GSM& m DCS SVR modela. U prvom slučaju kao MI vrednosti korišćeni su RSS novoi svih 7 GSM i 7 DCS ćelija relevantnih za datu *outdoor* oblast (7GSM&7DCS SVR model). Drugi tip modela realizovan je odabirom 7 ćelija sa najvećom radio-vidljivošću među relevantnim GSM i DCS ćelijama za datu oblast, tačnije 3 GSM i 4 DCS ćelije (3GSM&4DCS SVR). Kod trećeg modela korišćeni su RSS nivoi svih 7 relevantnih GSM ćelija i 3 DCS ćelije sa najvećom radio-vidljivošću u datoj oblasti.

Rezultati verifikacije predloženih modela dati su tabeli 5.1. Tačnost pozicioniranja datih modela razmatrana je sa stanovišta vrednosti srednje greške pozicioniranja (srednja DE), medijanske vrednosti greške pozicioniranja, vrednosti greške pozicioniranja koja nije premašena u 67 % (67% DE, eng. *67 percentile distance error*), odnosno 90% slučajeva (90% DE, eng. *90 percentile distance error*), kao i standardne devijacije greške pozicioniranja (σ DE). Kumulativna funkcija raspodele vrednosti greške pozicioniranja (*Cumulative Distribution Function*, u nastavku teksta CDF) za implemetirane SVR modele prikazana je na slici 5.7.

Tabela 5.1 Rezultati verifikacije tačnosti pozicioniranja SVR modela

Greška pozicioniranja (<i>Distance Error</i> , DE)					
SVR model	Srednja DE [m]	Medijanska DE [m]	67% DE [m]	90% DE [m]	σ – standardna devijacija DE [m]
7 GSM	65.1	6.2	47.2	210	114
7 DCS	129.2	79	137.7	315	143.5
3GSM&4DCS	111	64.6	119	285	139.4
7GSM&3 DCS	74.7	43.2	82.4	190	96.5
7GSM&7DCS	68.2	45.4	75.9	160	75.9



Slika 5.7 Kumulativna funkcija raspodele vrednosti greške pozicioniranja SVR modela

Razlike u tačnosti SVR modela za pozicioniranje (tabela 5.1) jasno ukazuju na uticaj koji na tačnost pozicioniranja ima odabir relevantnih ćelija, čiji se nivoi signala koriste kao ulazni podaci za estimaciju nepoznatih prostornih koordinata.

7GSM SVR model pokazao je dosta dobre performanse po pitanju ostvarene medijanske vrednosti greške pozicioniranja i vrednosti greške koja nije premašena u 67% slučajeva (67% DE). S druge strane, u određenom (manjem) broju slučajeva došlo je do relativno velike greške u estimaciji pozicije korisnika, što se odrazilo na vrednost 90% DE, a samim tim i na srednju vrednost greške pozicioniranja. Ipak, ostvarena tačnost je u potpunosti u skladu sa FCC zahtevima koja se odnose na *network-based* rešenja (150m|67% i 300m|90% [4]), kakva je i predložena metoda. Dodatno, 7GSM SVR model ispunjava i FCC zahteve u pogledu 67% DE definisane za *mobile-based* metode (50m|67% i 150m|90% [4]).


Veće vrednosti greške pozicioniranja javile su se za pojedine verifikacione tačke u kojima je, usled specifičnih uslova radio-propagacije, neočekivano detektovan dosta niži nivo signala pojedinih relevantnih ćelija (ili uopšte nije detektovan), u poređenju sa nivoima detektovanim u ostalim mernim tačkama u blizini. To je uzrokovalo pojavu da u pojedinim slučajevima, pogotovo u tačkama u kojima je detektovan signal manje od 3

relevantne ćelije, kreirani MI vektor bude sličniji MI vektorima formiranim za udaljene merne lokacije, nego za one u blizini. Naime, kako se u slučaju nepostojećih MI vrednosti usvaja fiksna vrednost od -110dBm, deo informacije o relativnom položaju mobilnog terminala u odnosu na relevantne ćelije čiji signal nije detektovan, se gubi. Razmatrana situacija mogla bi se uprošćeno interpretirati kao da se mobilni terminal nalazi na jednakoj udaljenosti od relevantnih ćelija čiji signal nije detektovao (tj. *site-ova* sa kojih su one realizovane), iako to nije realan slučaj. Sa smanjenjem broja detektovanih relevantnih ćelija, pogotovo ako to smanjenje nije tipično za užu geografsku oblast u kojoj se nalazi mobilni korisnik, raste i verovatnoća da će nakon mapiranja formirani MI vektor bili sličniji MI vektorima koji odgovaraju prostorno udaljenijim tačkama. Postojanje prostorno udaljenih tačaka sa sličnim MI vektorima u trening skupu stvara lošije uslove za rešavanje problema regresije, tj. pronalaženje funkcije predikcije SVR modela. Iz datog razloga, SVR model pravi veće greške pri estimaciji prostornih koordinata za lokacije na kojima su izmerene RSS vrednosti netipične za njihovo bliže okruženje (eng. *outlier* tačke), pogotovo ako je broj detektovanih relevantnih ćelija u njima mali.

Ako se za slučaj 7GSM SVR modela uporede medijanska i 67% DE sa 90% DE, može se zaključiti da je broj velikih vrednosti grešaka pozicioniranja relativno mali, odnosno da je odabir relevantnih ćelija bio takav da prethodno opisane („specifične“) situacije nisu bile česte. S druge strane, kod 7DCS SVR modela primetno je znatno povećanje udela srednjih i velikih vrednosti grešaka pozicioniranja (slika 5.7). Razlike u performansama ova dva modela mogu se objasniti kao posledica različite radio-vidljivosti i kvaliteta radio signala relevantnih ćelija ova dva modela u posmatranoj *outdoor* oblasti.

Za posmatrano test *outdoor* okruženje, na slici 5.8. su prikazani procenati mernih lokacija u kojima je radio-vidljiv određen broj relevantnih ćelija, u slučaju 7GSM i 7DCS SVR modela. U slučaju 7GSM SVR modela, procenat mernih lokacija u kojima je detektovan signal manje od 3 relevantne GSM ćelije iznosi manje od 5%. Dodatno, u najvećem procentu lokacija detektovano je 5 relevantnih GSM ćelija. S druge strane, u slučaju razmatranih DCS ćelija, taj broj smanjen je na 4, a povećan je udeo mernih lokacija u kojima je detektovano 3 ili manje relevantnih DCS ćelija. Dodatni faktor koji je uticao na tačnost 7DCS SVR modela jeste kvalitet radio signala relevantnih DCS

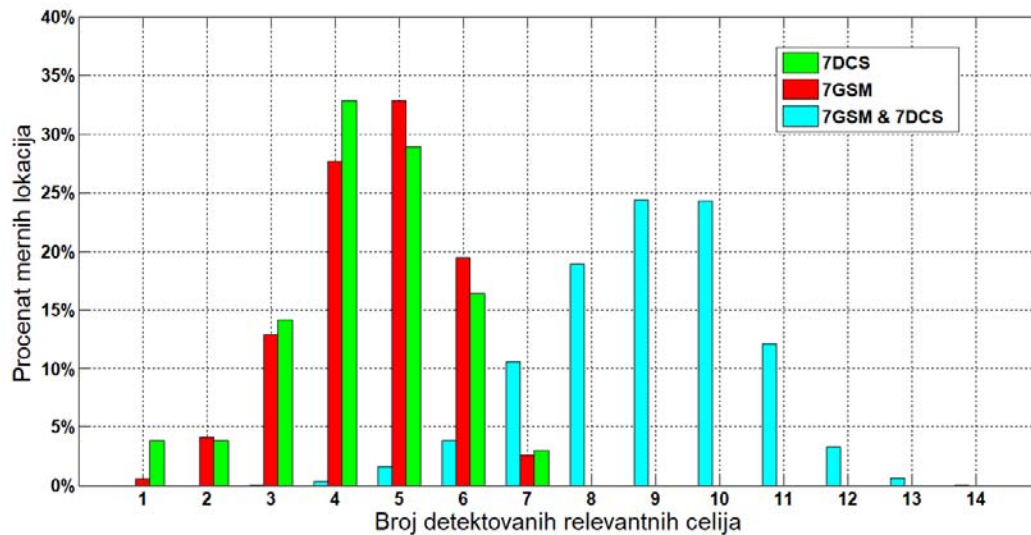
ćelija. Naime, DCS ćelije emituju radio signal u frekventijskom opsegu od 1800MHz, pa DCS signal trpi veće propagaciono slabljenje u odnosu na signal GSM 900MHz ćelija. Dodatno, pri višim frekvencijama radio signala, velike varijacije u nivou signala koje nastaju kao posledica *multipath* (kratkotrajnog) fedinga mogu se detektovati pri manjim lokalnim pomerajima prijemnika [10, 106]. Naime, kao posledica *multipath* fedinga, nagle promene u nivou prijemnog signala, koje u pojedinim slučajevima mogu iznositi 20-30dB, javljaju se pri pomerajima prijemnika koji odgovaraju polovini talasne dužine radio signala ($\lambda = c/f$, gde je c brzina svetlosti a f frekvencija radio talasa) [106]. Iz datog razloga, kod 7DCS SVR modela prisutne su veće varijacije nivoa signala relevantnih ćelija u prostorno bliskim tačkama, što stvara lošije uslove za treniranje modela, tj. pronalaženje funkcije za estimaciju prostornih koordinata.



Slika 5.8. Procentualna radio-vidljivost relevantnih ćelija prema mernim lokacijama: 7GSM SVR, 7DCS SVR i 3GSM&4DCS SVR model

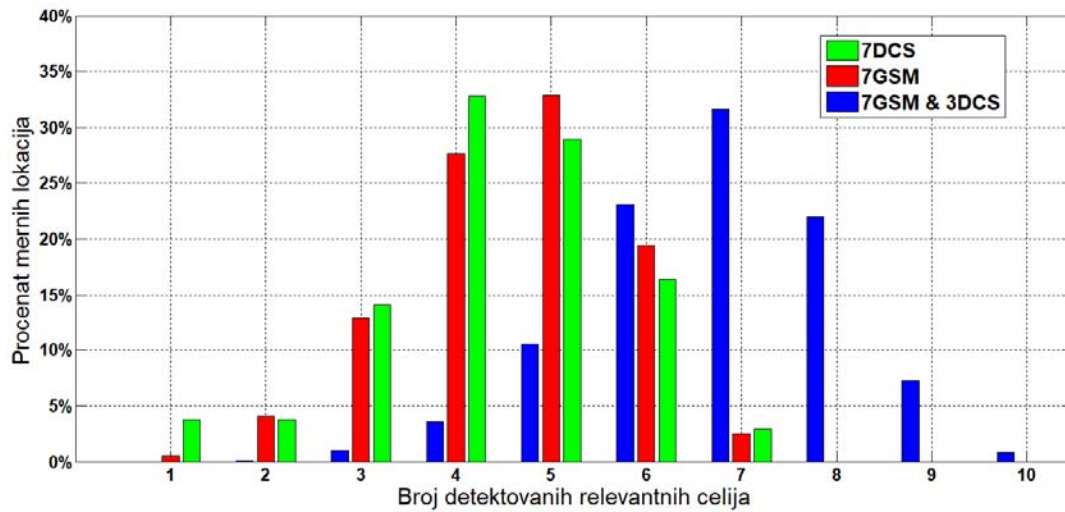
U slučaju korišćenja izmerenih RSS vrednosti koje potiču od relevantnih i GSM i DCS ćelija, postignute tačnosti implementiranih modela su negde između 7GSM i 7DCS SVR modela (slika 5.7). Iako je u slučaju 3GSM&4DCS SVR modela prosečna radio-vidljivost relevantnih ćelija po mernoj lokaciji veća u poređenju sa 7GSM SVR modelom (slika 5.8), nestabilniji nivoi DCS signala, kao i veći stepen kolociranosti relevantnih GSM i DCS ćelija (realizacija sa istog BS *site*-a), rezultovali su lošijim rezultatima u poređenju sa 7GSM modelom. S druge strane, u slučaju 7GSM&7DCS i

7GSM&3DCS modela primetno je smanjenje broja velikih vrednosti grešaka pozicioniranja, što je rezultovalo smanjenjem 90% DE. Smanjenje broja velikih vrednosti grešaka pozicioniranja je rezultat povećanja broja radio-vidljivih relevantnih ćelija po mernoj lokaciji, što je prikazano na slikama 5.9 i 5.10 za 7GSM&7DCS i 7GSM&3DCS SVR model, respektivno. Naime, povećanjem broja relevantnih ćelija za posmatranu oblast, ostvaren je uslov da su u svakoj tački radio-vidljiva barem 3 relevantna izvora radio signala. U slučaju 7GSM&3DCS modela, u oko 95% mernih lokacija bile su radio-vidljive 5 ili više relevantnih ćelija, dok je kod 7GSM&7DCS modela taj broj iznosio 6 ili više. Međutim, iako definisanje većeg broja relevantnih ćelija za neku geografsku oblast može uticati na smanjenje broja velikih vrednosti grešaka pozicioniranja, faktor koji se mora uzeti u obzir jeste i kvalitet signala odabranih ćelija u datoj oblasti. Naime, u slučaju 7GSM&7DCS i 7GSM&3DCS SVR modela, veća dinamika signala DCS ćelija u prostorno bliskim tačkama uticala je na generalno lošiju estimaciju funkcije predikcije modela za pozicioniranje, što se može sagledati kroz povećanje medijanske i 67 % DE u odnosu na 7GSM model.



Slika 5.9. Procentualna radio-vidljivost relevantnih ćelija prema mernim lokacijama:

7GSM SVR, 7DCS SVR i 7GSM&7DCS SVR model



Slika 5.10. Procentualna radio-vidljivost relevantnih ćelija prema mernim lokacijama: 7GSM SVR, 7DCS SVR i 7GSM&3DCS SVR model

Prehodno predstavljeni rezultati ukazuju na to da veliki uticaj na tačnost SVR modela za pozicioniranje ima broj nepostojećih MI vrednosti (tj. ulaznih podataka modela) i način na koji se one tretiraju. Usvajanjem fiksne vrednosti u datom slučaju, koja odgovara minimalnoj vrednosti RSS parametra prema 3GPP standardu, model za pozicioniranje dobija delimičnu informaciju o položaju mobilnog korisnika u odnosu na okolne relevantne ćelije. Kvalitativni podatak da je korisnik udaljen od relevantnih ćelija čiji signal nije detektovao je i dalje prisutan, ali ne i kvantitativan, koji bi ukazao na njegov relativan položaj u odnosu na date ćelije. Ipak, predloženi pristup pruža modelu više informacija o položaju korisnika nego često korišćen pristup kojim se za nepostojeći ulazni podatak usvaja vrednost nula. Dodatno, predloženi pristup za rešavanje problema nepostojećih MI vrednosti pokazao se kao robusniji i u poređenju sa metodom koja se zasniva na modifikaciji kernel funkcije [41], što će biti demonstrirano u nastavku rada.

Pored opšte radio-vidljivosti relevantnih ćelija u posmatranoj oblasti, bitan faktor koji takođe utiče na tačnost estimacije jeste kvalitet signala relevantnih ćelija. Rezultati verifikacije kombinovanih GSM/DCS SVR modela ukazuju da povećanje broja relevantnih izvora ne mora nužno voditi ka poboljšanju tačnosti pozicioniranja. S druge strane, kombinovanje podataka dobijenih od dva ili više mobilna sistema povećava

kompleksnost modela sa stanovišta implementacije. Zbog toga je neophodno izvršiti analizu kvaliteta signala ćelija detektovanih u geografskoj zoni od interesa, pre definisanja skupa relevantnih za potrebe pozicioniranja. Ipak, potrebno je napomenuti da su u posmatranom slučaju, kombinovani GSM/DCS SVR modeli implementirani korišćenjem infrastrukture jednog mobilnog operatora, pa je visok stepen kolociranosti GSM/DCS baznih stanica umanjio efekat koji bi povećanje broja relevantnih radio izvora potencijalno mogao da ima na tačnost pozicioniranja. Naime, korišćenje infrastrukture različitih mobilnih operatora povećava prostornu razdvojenost radio izvora, pa se smanjuje stepen korelisanosti radio signala čiji se parametri koriste za potrebe pozicioniranja. Prednosti korišćenja infrastrukture više mobilnih operatora biće prikazane za slučaj SVM modela implementiranih u test *indoor* okruženju.

5.3.2. TAČNOST POZICIONIRANJA KOMBINOVANE SVC&SVR METODE

U slučaju realizacije kombinovanih SVC&SVR modela kod kojih se primenjuje princip segmenatcije prostora, za relevantne ćelije odabrano je 7 GSM ćelija sa najvećom radio-vidljivošću u posmatranoj geografskoj zoni od interesa (iste ćelije kao u slučaju 7GSM SVR modela). Kao i kod prethodno analiziranih SVR modela, tačnost pozicioniranja kombinovanih SVC&SVR modela ispitivana je na nezavisnom (verifikacionom) skupu mernih tačaka (preostalih 50% tačaka iz baze podataka).


Rezultati verifikacije tačnosti kombinovanih SVC&SVR modela za pozicioniranje, za slučaj segmenatcije posmatrane *outdoor* oblasti na 4 i 16 manjih podprostora (SVC&SVR_{2x2} i SVC&SVR_{4x4} model, respektivno), prikazani su u tabeli 5.2. Radi boljeg sagledavanja uticaja segmentacije prostora na tačnost pozicioniranja, u tabeli 5.2 su prikazani i rezultati verifikacije 7GSM SVR modela. Radi pojednostavljenja notacije, u nastavku teksta dati model biće označen kao SVR model.

Na slici 5.11 data je ilustracija vrednosti grešaka pozicioniranja predstavljenih u tabeli 5.2, dok su kumulativne funkcije raspodele (CDF) vrednosti grešaka pozicioniranja SVR i kombinovanih SVC&SVR modela prikazane na slici 5.12.

Tabela 5.2. Rezultati verifikacije tačnosti pozicioniranja:

SVR, SVC&SVR_{2x2} i SVC&SVR_{4x4}


Greška pozicioniranja (<i>Distance Error, DE</i>)							
Modeli	Verovatnoća ispravne selekcije podprostora	Srednja DE [m]	Medijanska DE [m]	67% DE [m]	90% DE [m]	95% DE [m]	σ – standardna devijacija DE [m]
SVR	1	65.1	6.2	47.2	206	301	114
SVC&SVR _{2x2}	0.956	62.5	5.1	42.8	196	293.4	118.2
SVC&SVR _{4x4}	0.872	62.2	4.3	31.6	192	317	125.9



Slika 5.11. Uticaj segmentacije prostora na vrednost grešaka pozicioniranja

Uvođenjem principa segmentacije prostora ostvareno je poboljšanje tačnosti pozicioniranja kombinovanih SVC&SVR modela u odnosu na SVR model. Kroz smanjenje veličine prostora za koji se implementiraju SVR podmodeli u okviru kombinovanog SVC&SVR modela, ostvaruje se veća „homogenost“ podataka koji se koriste za njihovo treniranje, kako u prostornom, tako i u radio domenu. Na taj način ostvaruju se bolji početni uslovi za rešavanje problema regresije, tj. pronalaženje funkcije predikcije SVR podmodela za pozicioniranje. Povećanjem stepena segmentacije prostora, tj. daljim smanjivanjem veličine zone pokrivanja SVR podmodela, dati efekat postaje izraženiji, što se može videti na primeru SVC&SVR_{4x4}

modela. Najveće poboljšanje performansi u slučaju kombinovanih SVC&SVR modela ogleda se u smanjenju srednjih (*medium-sized*) vrednosti grešaka pozicioniranja, koje u najvećoj meri utiču na vrednost 67%DE.



Slika 5.12. Kumulativne funkcije raspodele (CDF) vrednosti grešaka pozicioniranja SVR, SVC&SVR_{2x2} i SVC&SVR_{4x4} modela

S druge strane, kao i u slučaju SVR modela, može se primetiti postojanje manjeg broja relativno velikih vrednosti grešaka pozicioniranja, koje su uticale na vrednost 90% DE (95% DE), a samim tim i na srednju vrednost greške pozicioniranja. U slučaju kombinovanih SVC&SVR modela, dodatan faktor koji utiče na pojavu pojedinih velikih vrednosti grešaka pozicioniranja (pored onih analiziranih u prethodnom poglavlju), jeste pogrešna detekcija podprostora u kome se korisnik trenutno nalazi. Pri tom, potrebno je istaći da u takvim situacijama generisane greške mogu pripadati širokom opsegu vrednosti. Na primer, u slučaju da je SVC sloj (klasifikator) doneo pogrešnu odluku i odabrao podprostor koji je geografski susedan podprostoru u kome se korisnik u stvari nalazi, generisana greška pozicioniranja ne mora biti velika. S druge strane, ako je odabran podprostor koji se udaljen od onog u kome se korisnik u stvari nalazi, vrednosti greške pozicioniranja u datom slučaju mogu biti znatne. Samim tim, može se primetiti da ne postoji striktno pravilo kojim se može opisati ponašanje vrednosti greške pozicioniranja u slučaju pogrešno odabranog podprostora. Dodatno, u slučaju korišćenja

nested strukture SVC klasifikatora (SVC&SVR_{4x4} model), pogrešan odabir podoblasti u prvom sloju klasifikatora (SVC sloj I) povećava verovatnoću da podprostor odabran na izlazu iz SVC sloja II ne bude susedan podprostoru u kome se korisnik zapravo nalazi.

Ipak, implementirani SVC&SVR modeli pokazali su dobre performanse po pitanju uspešne detekcije podprostora u kome se korisnik nalazi. Samim tim, prednosti smanjenja zone pokrivanja SVR podmodela preovladale su potencijalni problem pogrešne selekcije podprostora, što se može primetiti kroz smanjenje vrednosti i 90% DE, u odnosu na SVR model. Neznatno povećanje broja velikih vrednosti grešaka pozicioniranja, koje su posledica pogrešne detekcije podprostora može se primetiti tek kroz analizu vrednosti 95% DE, tj. vrednosti greške koja nije premašena u 95% slučajeva (tabela 5.2), i to u slučaju SVC&SVR_{4x4} modela.

Ipak, potrebno je naglasiti da su predloženi SVR i SVC&SVR modeli razvijeni za potrebe određivanja inicijalne pozicije mobilnog korisnika, odnosno za slučajeve kada sistemu za pozicioniranje nije poznata informacija o prethodnoj poziciji korisnika. S druge strane, može se primetiti da je oblik kumulativne funkcije raspodele (CDF) vrednosti greške pozicioniranja pogodan za naknadnu primenu algoritama za praćenje. Daljom nadogradnjom SVM modela za pozicioniranje sa nekim od algoritama za praćenje, po svojoj prilici, mogle bi se eliminisati velike vrednosti greške pozicioniranja koje odgovaraju nerealnom pomeraju mobilnog korisnika između dve uzastopne estimacije. Dodatno, u slučaju SVC&SVR modela moglo bi se očekivati i smanjenje broja velikih vrednosti grešaka pozicioniranja izazvanih pogrešnom estimacijom podprostora. Na taj način bi se potencijalno mogla smanjiti vrednost 90% DE, tako da predložene SVM metode pozicioniranja zadovolje u potpunosti i strožije FCC zahteve koji se odnose na *mobile-based* metode (150m|90%). Ipak, nadogradnja predloženih SVM metoda sa nekim od algoritama za praćenje je predmet budućeg istraživanja.

5.3.3. KOMPLEKSNOST I KAŠNENJE SVM MODELA – OUTDOOR OKRUŽENJE

U nastavku poglavlja analizirane su performanse SVM modela za pozicioniranje sa stanovišta njihove kompleksnosti i vremenskog kašnjenja koje unose u proces estimacije prostornih koordinata mobilnog korisnika.

U opštem slučaju, kompleksnost neke tehnike pozicioniranja može se definisati kao složenost procesa njene implementacije. U slučaju predloženih SVM tehnika pozicioniranja, kompleksnost implementacije obuhvata uloženi trud (*effort*) u formiranje *fingerprint* baza i optimalno treniranje SVM modela za pozicioniranje.

Kao što je već pomenuto, sprovođenje mernih kampanja u cilju formiranja *fingerprint* baza, predstavlja negativan aspekt svake *fingerprinting* metode, nezavisno od odabira algoritma na kome se zasniva estimacija prostornih koordinata (kNN, WkNN, ANN, SVM, itd.). Ipak, za potrebe formiranja *fingerprint* baza moguće je iskoristiti rezultate mernih kampanja koje mobilni operatori standardno sprovode u druge svrhe, na primer *drive* testovi za proveru radio pokrivanja u nekoj oblasti nakon instalacije nove ili nadogradnje postojeće bazne stanice. Dodatno, u *indoor* i *outdoor* okruženjima gde *drive* testovi nisu mogući, potencijalno rešenje za problem prikupljanja *fingerprint*-a predstavljaju već pomenute *crowdsourcing* metode, koje u poslednje vreme postaju predmet sve većeg interesovanja naučne zajednice [17-19]. *Crowdsourcing* koncept se zasniva na metodama kod kojih obični korisnici, korišćenjem sopstvenih mobilnih terminala, učestvuju u masovnim mernim kampanjama, bilo aktivno ili pasivno [18]. Primenom *crowdsourcing* metoda mogao bi se značajno olakšati postupak formiranja, ali i ažuriranja *fingerprint* baza u budućnosti.

Rezultati analize kompleksnosti SVR i SVC&SVR modela sa stanovišta vremena potrebnog za treniranje predloženih modela u zavisnosti od njihove strukture, prikazani su u tabeli 5.3. Na osnovu prikazanih rezultata može se primetiti da svi modeli zahtevaju dugo vreme treniranja, koje je najviše uslovljeno veličinom trening skupa. U opštem slučaju, kompleksnost treniranja SVM modela kreće se između $O(l^2)$ i $O(l^3)$, gde l predstavlja veličinu trening skupa [107]. Poređenja radi, kompleksnost treniranja ANN iznosi $O(l)$. Međutim, potrebno je istaći da se vrednosti prikazane u tabeli 5.3 odnose na treniranje SVM modela korišćenjem *Intel Core 2 Quad* procesora sa 2GB RAM memorije. Korišćenjem, novijih, moćnijih procesora, vremena treniranja bi se smanjila. Dodatno, pojedine obećavajuće tehnike za ubrzanje procesa treniranja SVM modela predložene su u [108, 109]. Metodom sekvencijalne optimizacije [108] ili kombinovanom metodom sekvencijalne i paralelne optimizacije [109] moguće je

redukovati kompleksnost na $O(l)$, čime bi se značajno moglo smanjiti vreme treniranja u slučaju velikih trening skupova.

Usled složenije strukture kombinovanih SVC&SVR modela, primetno je značajno povećanje vremena potrebnog za treniranje, u odnosu na slučaj kad se za neku geografsku oblast implementira osnovni SVR model. Međutim, poređenjem vremena treniranja SVC&SVR_{4x4} i SVC&SVR_{2x2} modela, može se primetiti da dalje povećanje broja podmodela (usled povećanja stepena segmentacije) ne utiče drastično na potrebno vreme za treniranje modela. Razlog je u korišćenju „*nested*“ strukturi SVC klasifikatora. Iako je u posmatranom slučaju ukupan broj SVC podmodela (tj. osnovnih binarnih klasifikatora) veći nego u slučaju korišćenja „*one-against-all*“ pristupa, za treniranje SVC podmodela drugog sloja koriste se podskupovi originalnog trening skupa, što značajno smanjuje vreme treniranja. Poređenja radi, za slučaj da je SVC&SVR_{4x4} model implementiran sa 16 SVC podmodela u jednom sloju (tj. kao „*one-against-all*“ rešenje), ukupno vreme treniranja iznosilo bi oko 266h (uzimajući u obzir prosečno vreme treniranja SVC podmodela korišćenjem celokupnog trening skupa). Priloženi rezultati jasno ukazuju na prednosti korišćenja predložene „*nested*“ strukture za potrebe rešavanja *multiclass* problema u slučaju većih geografskih oblasti, kad je potrebno primeniti veći stepen prostorne segmentacije.

Tabela 5.3. Kompleksnost (vreme treniranja) i kašnjenje SVR i SVC&SVR modela

MODELI	KOMPLEKSNOST						KAŠNJENJE	
	Broj SVC/SVR podmodela			Vreme treniranja (h)				
	SVC sloj I	SVC sloj II	SVR sloj*	Prosečno vreme treniranja SVC podmodela-sloj I	Prosečno vreme treniranja SVC podmodela-sloj II	Prosečno vreme treniranja SVR podmodela	Ukupno vreme treniranja	Prosečno vreme estimacije pozicije – <i>online</i> faza (s)
SVR	-	-	2	-	-	17.02	34.04	0.25
SVC&SVR _{2x2}	4	-	8	16.62	-	0.65	71.68	0.57
SVC&SVR _{4x4}	4	16	32	16.62	0.34	0.03	72.88	0.69

*Svaki SVR podmodel sastoji se od SVR_x i SVR_y podmodela.

Pored kompleksnosti, analizirano je i kašnjenje predložene tehnike za pozicioniranje. Kašnjenje nekog sistema za pozicioniranje definiše se kao vreme od slanja zahteva za pozicioniranjem pa do dostavljanja informacije o lokaciji u odgovarajućem formatu. Parametar kašnjenja može se modelovati kao suma propagacionih kašnjenja i vremena koje je potrebno modelu da obezbedi informaciju o poziciji. U slučaju PLMN mreža, propagaciona kašnjenja se uglavnom mogu ograničiti na nekoliko sekundi. Sa stanovišta vremena potrebnog modelu da estimira poziciju, potrebno je istaći da iako predloženi SVM modeli zahtevaju duže vreme treniranja, u *online* fazi su dosta efikasni usled SVM osobine da pruža tzv. proređeno rešenje (*sparse solution*). Drugim rečima, estimacija (predikcija) nepoznate pozicije u *online* fazi vrši se kroz evaluaciju kernel funkcije samo nad podskupom trening podataka koji predstavljaju *support* vektore. Kako je prosečno kašnjenje koje unose predloženi SVM modeli pri estimaciji pozicije ispod 1 sekunde (tabela 5.3), može se zaključiti da predložena metoda pozicioniranja zadovoljava zahteve po pitanju kašnjenja velikog broja LBS servisa (< 30s [4]). Dodatno, na osnovu vrednosti kašnjenja iz tabele 5.3, može se primetiti da uvođenje principa segmenatcije prostora i povećanje broja podoblasti, ne utiče značajno na kašnjenje predložene tehnike.

5.4. POREĐENJE SA DRUGIM ĆELIJSKIM METODAMA POZICIONIRANJA U *OUTDOOR* OKRUŽENJU

Poređenje tačnosti predloženih SVR i SVC&SVR metoda i tehnika ćelijskog pozicioniranja navedenih u poglavlju 2 dat je u tabeli 5.4. Pri tom, poređenje je izvršeno samo sa metodama čije su performanse testirane u realnim okruženjima.

U poređenju sa probablističkim metodom [30], implementirani SVM modeli za pozicioniranje ostvarili su bolje performanse sa stanovišta 67% DE. S druge strane, može se primetiti da probablistički model generiše manji broj relativno velikih vrednosti grešaka pozicioniranja. Ipak, potrebno je imati na umu da implementacija ovog metoda zahteva modelovanje propagacionih uslova u okruženju od interesa i posedovanje podataka o tačnim pozicijama baznih stanica, snagama predajnika, antenskom sistemu, itd. Dodatno, probablistički metodi su proračunski dosta zahtevniji.

S druge strane, predložene SVR i SVC&SVR metode ostvarile su veću tačnost od kombinovanih probablističko *fingerprinting* metoda [17, 34].

Tabela 5.4. Komparacija ćelijskih metoda pozicioniranja u *outdoor* okruženju

Greška pozicioniranja (<i>Distance Error, DE</i>)					
Metode pozicioniranja	Srednja DE [m]	Medijanska DE [m]	67% DE [m]	90% DE [m]	Tip okruženja
Probablistički metod sa Okomura propag. modelom (RSS) [30]	52.8	.	53.8	102 (95% DE)	GSM, urbano
DCM- <i>nearest neighbour</i> (RSS) [31]	-	-	44 / 74	90 / 190	GSM urbano/suburbano
WkNN (RSS) [32]	112 / 242	~ 90 / 180	~ 125 / 250	~200 / 500	GSM urbano/suburbano
CellSense (RSS) [34]	-	28 / 42	-	273 / 308 (95% DE)	GSM urbano/ruralno
NBL <i>crowdsourcing</i> (RSS) [17]	-	50 / 300	-	-	LTE urbano/ruralno
ANN (RSS) [35]	-	-	~50	~110 (95% DE)	GSM, urbano
<i>Multi-system multi-operator</i> ANN (RSS) [36]	59	50	68	137 (95% DE)	GSM/DCS/UMTS, suburbano
C-C ANNs 1x1 [37]	82	72	90	177 (95% DE)	GSM/DCS, suburbano
C-C ANNs 20x20 [37]	26	2	4	168 (95% DE)	GSM/DCS, suburbano
SVR SoE (RSS) [41]	95-125	75-100	-	-	GSM, urbano
SVR	65.1	6.2	47.2	206	GSM, suburbano
SVC&SVR _{2x2}	62.5	5.1	42.8	196	GSM, suburbano
SVC&SVR _{4x4}	62.2	4.3	31.6	192	GSM, suburbano

U poređenju sa tačnostima kNN i WkNN metoda navedenim u [31,32] za GSM suburbana okruženja, predloženi SVM modeli imaju slične performanse kao DCM metod najbližeg suseda [31], dok su im performanse značajno bolje u odnosu na WkNN metod predložen u [32].

Poredeći sa ANN metodom implementiranom u GSM urbanom okruženju [35], SVR i SVC&SVR metod ostvarili su bolje rezultate po pitanju 67% DE, ali lošije po pitanju 90% DE. Ipak, potrebno je napomenuti da je u [35] broj relevantnih GSM ćelija

čije su RSS vrednosti korišćene kao ulazni podaci modela za pozicioniranje iznosio 10, a ne 7, što je bio slučaj kod implementiranih SVR/SVC&SVR modela. Kao što je pokazano u poglavlju 5.3.1, povećanje broja relevantnih PLMN ćelija (tj. ulaznih podataka) ima pozitivan uticaj na smanjenje velikih vrednosti grešaka pozicioniranja, a samim tim i 90% DE.

Dobre performanse ANN metoda demonstrirane su i u [36] i [37]. Ipak potrebno je naglasiti da su u slučaju [36], kao ulazni podaci modela za pozicioniranje korišćene RSS vrednosti svih GSM/DCS i UMTS ćelija detektovanih u test okruženju (tačnije 163 ulazna podatka). Pri tom, korišćena je infrastruktura dva mobilna operatora. U [37], kao ulazni podaci korišćene su RSS vrednosti 32 GSM/DCS ćelije dva mobilna operatora.

S druge strane, u slučaju implementiranih SVR i SVC&SVR modela, broj relevantnih ćelija, tj. ulaznih podataka ograničen je na 7 u slučaju GSM (ili DCS) sistema, kako bi bio u skladu sa veličinom standardnog MR izveštaja (*Standard Measurement Report*) [92]. Cilj postavljanja ovakvog ograničenja bio je da se ispituju mogućnosti predložene SVM tehnike pozicioniranja u postojećim uslovima, tj. bez potrebe za izmenama postojeće GSM (DCS) signalizacije kako bi podržalo slanje izveštaja za veći broj izmerenih RSS parametara. Ipak, obećavajuće performanse u slučaju korišćenja RSS vrednosti većeg broja PLMN ćelija, koje pripadaju pri tom različitim operatorima, biće ispitane na *indoor* test okruženju, u nastavku rada.

Na kraju, implementirani SVR i SVC&SVR modeli demonstrirali su značajno bolju tačnost od prethodno predloženog SVR modela koji koristi SoE (*Sum of Exponentials*) kernel funkciju za rešavanje problema nepostojećih RSS vrednosti u bazi podataka, kao i u MR izveštaju dobijenom od mobilnog terminala [41].

U cilju što verodostojnije verifikacije performansi predloženih SVR i SVC&SVR metoda pozicioniranja, u nastavku rada izvršeno je poređenje njihove tačnosti sa tačnošću drugih obećavajućih *fingerprinting* metoda iz tabele 5.4, za slučaj kada se date metode implementiraju za test *outdoor* okruženje koje je razmatrano u ovom istraživanju. U tu svrhu, korišćenjem iste *fingerprint* baze kao pri implementaciji SVR i SVC&SVR modela, realizovani su kNN, ANN i SVR SoE modeli. Pri tom, kao i u

slučaju SVR i SVC&SVR modela, korišćeni su RSS parametri 7 relevantnih GSM ćelija.

SVR SoE model [41] je izabran kako bi se verodostojno uporedio SoE metod za rešavanje problema nepostojećih RSS vrednosti u *fingerprint*-ima, sa pristupom predloženim u ovom istraživanju (poglavlje 4.1.3). Dodatno, implementirani su kNN i ANN modeli zbog obećavajućih rezultata koji su postignuti u dosadašnjim istraživanjima [31, 36].


ANN model za pozicioniranje realizovan je kao *multilayer feedforward* neuralna mreža sa propagacijom greške unazad (*error backpropagation*), koja je predložena u [36]. Struktura ANN modela sastojala se iz ulaznog sloja, tri sakrivena sloja i izlaznog sloja. Broj perceptrona ulaznog sloja odabran je tako da odgovara broju ulaznih parametara, tj. MI vrednosti (7), dok je broj perceptrona u izlaznom sloju odabran tako da odgovara broju estimiranih izlaznih parametara, tj. x i y koordinati (2). Veličina sakrivenih slojeva dimenzionisana je prema [110], tako da broj perceptrona prvog skrivenog sloja bude približno 2 puta veći od broja perceptrona u ulaznom sloju (kako bi se omogućilo raščlanjivanje ulazne informacije na više manjih segmenata), dok je u narednim skrivenim slojevima broj perceptrona smanjivan linearno, konvergirajući ka broju izlaza. Za potrebe treniranja korišćena je *triangda* funkcija (*gradient descent training function with an adaptive learning rate*) [14], sa inicijalnom vrednošću brzine učenja (*learning rate*) od 0.1. Svi perceptroni su implementirani sa *hyperbolic tangent sigmoid* transfer funkcijom, osim perceptrona izlaznog sloja koji koriste linearnu transfer funkciju. Kao kriterijumska funkcija za analizu performansi neuralne mreže korišćena je srednja kvadratna greška (*mean squared error*, MSE).

Za posmatrano test *outdoor* okruženje, kNN metod je testiran za vrednosti parametra k od 1 do 10. Najbolje performanse ostvarene su za osnovni model najbližeg suseda, odnosno za $k=1$, te su dati rezultati predstavljeni u nastavku.

Pregled postignutih tačnosti SVR, SVC&SVR, SVR SoE, kNN i ANN modela za pozicioniranje u posmatranom test *outdoor* okruženju dat je u tabeli 5.5, dok su kumulativne funkcije raspodele greške pozicioniranja datih modela prikazane na slici 5.13.

Tabela 5.5. Poređenje performansi modela za pozicioniranje zasnovanih na primeni SVM, ANN i kNN algoritama, implementiranih za isto *outdoor* okruženje

Modeli	Greška pozicioniranja (<i>Distance Error, DE</i>)						
	Verovatnoća ispravne selekcije podprostora	Srednja DE [m]	Medijanska DE [m]	67% DE [m]	90% DE [m]	95% DE [m]	σ – standardna devijacija DE [m]
SVR	1	65.1	6.2	47.2	206	301	114
SVC&SVR _{2x2}	0.956	62.5	5.1	42.8	196	293.4	118.2
SVC&SVR _{4x4}	0.872	62.2	4.3	31.6	192	317	125.9
SVR SoE	1	229.3	204.5	264.6	418	497.4	134
ANN	1	148.5	118	166	289	379	116.6
kNN (k=1)	1	68	15.1	57.1	212	294.7	113.6



Slika 5.13. Kumulativne funkcije raspodele vrednosti greške pozicioniranja:

SVR, SVC&SVR_{2x2}, SVC&SVR_{4x4}, SVR SoE, kNN i ANN

Rezultati dobijeni primenom SVR SoE metode ukazuju na potencijalne nedostatke predloženog pristupa za rešavanje problema nepostojećih ulaznih podataka (RSS vrednosti) primenom modifikovane SoE kernel funkcije. Nasuprot pristupu korišćenom u ovom istraživanju da se za nepostojeće MI vrednosti usvaja fiksna vrednost praga (-110dBm u posmatranom slučaju), korišćenje SoE kernel funkcije

podrazumeva da se pojedini elementi ulaznog vektora (tj. RSS *fingerprint*-a), koji se odnose na ćelije čiji signal nije detektovan, jednostavno odbacuju. U datom slučaju, za par ulaznih vektora (RSS *fingerprint*-a), proračun SoE kernel funkcije vrši se samo nad onim parovima elemenata koji su zastupljeni u oba RSS *fingerprint*-a (poglavlje 4.1.3). Npr. u slučaju da jedan RSS *fingerprint* sadrži RSS vrednosti svih 7 relevantnih ćelija, a drugi samo od 3, SoE kernel funkcija će zanemariti 4 RSS merenja iz prvog *fingerprint*-a (ona koja nemaju odgovarajućeg „para“ u drugom *fingerprint*-u) i time odbaciti jedan deo korisnih informacija o prostoru. Problem do koga može doći jeste veliko odstupanje proračunate kernel funkcije od stvarne vrednosti u slučaju kada je potrebno odbaciti veliki broj elemenata RSS vektora. Iz tog razloga, korišćenje SoE kernel funkcije predložene u [41] pokazalo se kao manje pogodno za okruženja u kojima postoje veće varijacije u radio-vidljivosti relevantnih PLMN ćelija.

Analizom ostvarenih performansi kNN metode, može se zaključiti da oba SVM pristupa za pozicioniranje predložena u ovom radu, SVR i SVC&SVR, ostvaruju nešto bolje performanse od kNN metoda (slika 5.13). Dodatno, SVR i SVC&SVR modeli pokazali su znatno bolje performanse od ANN modela, za slučaj korišćenja istog broja ulaznih podataka (MI vrednosti). Lošije performanse ANN metode u odnosu na metode zasnovane na SVM algoritmima, mogu se objasniti činjenicom da proces optimizacije u slučaju ANN mreža „pati“ od postojanja višestrukih lokalnih minimuma, pa rešenje ka kome model iskonvergira ne mora biti i globalno optimalno rešenje. S druge strane, u slučaju SVM, funkcija rizika koju je potrebno minimizirati ima konveksan oblik, čime se garantuje da rešenje optimizacionog problema ujedno predstavlja i globalno (jedinstveno) optimalno rešenje [15, 16]. Dodatno, proces treniranja ANN mreža zasniva se na minimiziranju empirijskog rizika, dok se treniranje SVM modela zasniva se na principu minimiziranja strukturalnog rizika (poglavlje 3.2.4), što SVM čini otpornijim na problem prepodešavanja na trening podatke i pruža mu bolja generalizaciona svojstva.

Konačno, na osnovu rezultata testiranja SVR i SVC&SVR modela u realnom *outdoor* okruženju, može se zaključiti da obe predložene metode ćelijskog pozicioniranja u potpunosti ispunjavaju FCC zahteve definisane za *network-based* metode (150m|67% i 300m|90% [4]). Pri tom, implementacija predloženih SVM metoda

ne zahteva izmene postojeće GSM/DCS signalizacije, kao ni bilo kakve modifikacije postojećih mobilnih terminala. Dodatno, pokazano je da uvođenje principa segmentacije prostora na manje celine i primena kombinovane SVC&SVR metode, smanjuje dodatno grešku pozicioniranja u odnosu na SVR metod, a da pri tom ne utiče značajno na kašnjenje metode u *online* fazi. Korišćenje kombinovanih SVC&SVR modela može biti posebno od koristi u oblastima u kojima postoje izrazito „heterogeni“ uslovi propagacije radio signala (npr. usled nekih prirodnih prepreka).

Dalje unapređenje tačnosti predloženih SVM metoda moguće je ostvariti korišćenjem RSS parametara većeg broja PLMN ćelija, koje mogu pripadati infrastrukturi većeg broja operatora. Iako dati pristup zahteva izmenu postojeće signalizacije, kao i softverske izmene na strani mobilnih terminala, njegov opšti uticaj na kapacitet mreže, kao i na mobilne terminale, ne bi bio velik. S druge strane, povećanje broja ulaznih podataka SVM modela za pozicioniranje imao bi pozitivan uticaj na smanjenje velikih vrednosti grešaka pozicioniranja, kao što je pokazano u poglavlju 5.3.1. Za očekivati je da dati efekat bude još izraženiji u slučaju korišćenja infrastrukture većeg broja mobilnih operatora, usled manjeg stepena kolociranosti izvora radio signala. Na taj način bi se potencijalno mogla smanjiti vrednost 90%DE, tako da predložene SVR i SVC&SVR metode pozicioniranja zadovolje po tom kriterijumu i strožije FCC zahteve koji se odnose na *mobile-based* metode (50m|67% i 150m|90% [4]). Prednosti korišćenja infrastrukture više mobilnih operatora, kao i RSS parametara od većeg broja ćelija, biće ispitane za slučaj testiranja predložene SVR i SVC&SVR metode pozicioniranja u *indoor* okruženju.

Na kraju, potrebno je naglasiti da su predloženi SVR i SVC&SVR modeli razvijeni za potrebe inicijalnog određivanja pozicije mobilnog korisnika. Kao što je već pomenuto, oblik kumulativne funkcije raspodele (CDF) vrednosti greške pozicioniranja ovih modela pogodan je za naknadnu primenu nekog od algoritama za praćenje, koji bi, po svoj prilici, mogao da eliminiše velike vrednosti greške pozicioniranja. Ipak, nadogradnja predložene tehnike pozicioniranja sa nekim od algoritama za praćenje je predmet budućeg istraživanja.

6. PRIMENA SVM ALGORITAMA ZA POZICIONIRANJE U INDOOR OKRUŽENJU

Drugi segment ovog istraživanja bavio se ispitivanjem performansi predložene metode pozicioniranja u realnom *indoor* okruženju. U nastavku poglavlja biće prikazani rezultati testiranja tačnosti predloženih SVR i SVC&SVR modela za pozicioniranje u okviru prostorija Elektrotehničkog fakulteta u Beogradu. Pri tom, kao i u slučaju verifikacije performansi predložene SVM metode pozicioniranja u *outdoor* okruženju, korišćena je infrastruktura 2G javnih mobilnih sistema (GSM i DCS), jer predstavljaju i dalje globalno najrasprostranjeniji PLMN sistem.

Deo rezultata prikazanih u okviru ovog poglavlja disertacije, publikovano je u radovima **Error! Reference source not found.**

6.1. TEST INDOOR OKRUŽENJE I DEFINISANJE RELEVANTNIH RADIO IZVORA

6.1.1. PRIKUPLJANJE PODATAKA

U opštem slučaju, *indoor* okruženja mogu biti različitih veličina i stepena složenosti unutrašnje strukture, usled čega se radio-propagacioni efekti mogu značajno razlikovati od prostorije do prostorije. Iz navedenog razloga, potrebno je posvetiti posebnu pažnju odabiru *indoor* test okruženja u kome će se vršiti verifikacija performansi neke tehnike pozicioniranja. Poželjno je da dato okruženje ima dovoljno velike dimenzije, kao i kompleksnu unutrašnju strukturu koja obuhvata više različitih tipova prostorija. Samo u slučaju ispunjenja navedenih uslova može se očekivati da će


performanse neke tehnike za pozicioniranje biti u potpunosti ispitane pri različitim radio-propagacionim efektima koji mogu nastati u takvom kompleksnom okruženju.

Iz prethodno navedenih razloga, kao test *indoor* okruženje odabran je prostor Elektrotehničkog fakulteta (ETF), odnosno prizemlje zgrade Tehničkih fakulteta koja se nalazi u urbanoj zoni grada Beograda. Dimenzije test *indoor* okruženja iznose 147m x 66m, a prostor se sastoji od oko 80 manjih celina uključujući 2 amfiteatra, učionice, laboratorije, kancelarije, dugačke hodnike i 4 atrijuma u centralnim delovima zgrade. Raspored prostorija prikazan je na slici 6.1.

Merna kampanja u okviru prostorija Elektrotehničkog fakulteta obavljena je tokom proleća 2015. godine. Merenje RSS vrednosti vršeno je korišćenjem mrežnog skenera *Radio Network Analyzer Rohde&Schwarz TSMQ* (R&S®TSMQ) [104], kao i u slučaju test *outdoor* okruženja. Ukupan broj mernih lokacija unutar posmatranog *indoor* okruženja iznosio je 581, a njihov raspored prikazan je na slici 6.1. U okviru posmatranog test okruženja detektovano je 175 GSM i DCS ćelija, koje pripadaju infrastrukturi 3 operatora: Mobilna Telefonija Srbije – MTS, Telenor i VIP. Pri tom, potrebno je naglasiti da su sve detektovane GSM/DCS ćelije realizovane sa *outdoor* lokacija koje se nalaze izvan zgrade ETF-a, osim dve GSM mikro ćelije operatora MTS koje su realizovane sa *outdoor* lokacija koje se nalaze u atrijumima zgrade ETF-a. S druge strane, u posmatranom test okruženju ne postoje *indoor* instalacije GSM/DCS baznih stanica. Prostorne koordinate mernih tačaka određene su manuelno, korišćenjem laserskog daljinomera. Za svaku mernu tačku, x i y koordinata su definisane u odnosu na usvojeni koordinatni početak označen ružičastim znakom “+” na slici 6.1. Greška u estimaciji stvarne pozicije merne tačke može se smatrati da je manja od 15cm.

Potrebno je napomenuti da je i u ovom slučaju predložen metod za pozicioniranje testiran u 2D okruženju. Međutim, u zatvorenim prostorima, parametar visine (z koordinata) je obično diskretna vrednost koja daje informaciju o spratu na kome se korisnik nalazi u okviru posmatranog prostora. Imajući to na umu, predloženi SVR i SVC&SVR modeli mogu se modifikovati uvođenjem dodatnog sloja SVC klasifikatora namenjenog rešavanju *multiclass* problema detekcije sprata na kome se nalazi korisnik, nakon čega bi se primenom SVR ili SVC&SVR modela vršila estimacija pozicije korisnika u okviru odabranog sprata. Samim tim, proširenje predloženog metoda za

pozicioniranje, tako da obuhvata i estimaciju sprata u okviru nekog objekta, ne bi bilo komplikovano sa stanovišta implementacije.



Slika 6.1. Prizemlje Elektrotehničkog fakulteta i raspored mernih tačaka

Na osnovu prikupljenih podataka tokom merne kampanje kreirane su 4 *fingerprint* baze. Prvo, za svakog od tri mobilna operatora kreirana je zasebna *fingerprint* baza. Odnosno, svakoj mernoj tački (od njih 581) pridružena su tri različita RSS vektora, tako da svaki RSS vektor sadrži isključivo RSS vrednosti GSM/DCS ćelija jednog od tri mobilna operatora (MTS, Telenor ili VIP). S druge strane, četvrta *fingerprint* baza formirana je tako da RSS vektori pridruženi mernim tačkama sadrže RSS nivoe GSM/DCS ćelija sva tri mobilna operatora. Cilj formiranja ovakvih baza bio je da se ispituju performanse predložene metode za pozicioniranje u slučaju korišćenja infrastrukture više različitih operatora, nasuprot korišćenju infrastrukture samo jednog.

Kao posledica različitih radio-propagacionih efekata, u toku merne kampanje detektovane su značajne razlike u radio-vidljivosti GSM/DCS ćelija u različitim delovima posmatranog *indoor* okruženja. Tako na primer, pojedine ćelije su detektovane u svega nekoliko mernih tačaka. Kao i prilikom implementacije SVM metode za pozicioniranje u *outdoor* okruženju, dati problem je rešen tako što je za GSM/DCS ćelije čiji signal nije detektovan u nekoj mernoj tački usvajana RSS vrednost od -110dBm prilikom formiranja *fingerprint* baza.

6.1.2. ODABIR RELEVANTNIH ČELIJA

Usled kompleksne unutrašnje strukture posmatranog *indoor* okruženja, kao i činjenice da su detektovane GSM/DCS ćelije realizovane sa *outdoor* lokacija, za dato okruženje karakteristična je pojava niza različitih, složenih radio-propagacionih efekata: transmisija kroz višestruke zidove i prozore, višestruke refleksije, difrakcija, itd. Kao posledica propagacije radio signala po višestrukim putanjama (tj. *multipath* fadinga), uočene su značajne razlike u nivoima signala detektovanih GSM/DCS ćelija u prostorno bliskim tačkama, uključujući i njihovu različitu radio-vidljivost. S druge strane, nivo signala pojedinih ćelija bio je blizak nivou šuma u skoro celom *indoor* okruženju, čineći ih radio-vidljivim u svega nekoliko mernih tačaka. Uzimajući u obzir uočene pojave, dolazi se do zaključka da ne pružaju svi izmereni RSS nivoi istu količinu informacija o prostoru. Drugim rečima, korišćenje RSS nivoa svih detektovanih ćelija ne mora doprineti poboljšanju tačnosti pozicioniranja.

Iz datog razloga neophodno je izdvojiti radio izvore (tj. ćelije) koji u posmatranom okruženju doprinose tačnijoj estimaciji prostornih koordinata mobilnog korisnika. U nastavku rada ispitivano je 5 kriterijuma za odabir relevantnih radio izvora u *indoor* okruženju od interesa:

- **Kriterijum All_N.** *Fingerprint*-i sadrže RSS vrednosti svih N GSM/DCS ćelija detektovanih u okviru posmatranog okruženja.
- **Kriterijum TOP₇.** *Fingerprint*-i sadrže RSS vrednosti 7 GSM/DCS ćelija koje imaju najveću verovatnoću radio-vidljivosti u posmatranom okruženju. Kao i kod testiranja SVM metoda za pozicioniranje u *outdoor* okruženju, dati kriterijum odabran je zbog kompatibilnosti sa veličinom standardnog MR izveštaja [92].
- **Kriterijum RV_{20%}.** *Fingerprint*-i sadrže RSS vrednosti GSM/DCS ćelija koje su radio-vidljive barem u 20% mernih lokacija u posmatranom okruženju.
- **Kriterijum RV_{5%}.** *Fingerprint*-i sadrže RSS vrednosti GSM/DCS ćelija koje su radio-vidljive barem u 5% mernih lokacija u posmatranom okruženju.

- **Kriterijum Lev-85.** *Fingerprint*-i sadrže RSS vrednosti GSM/DCS ćelija za koje važi da im je srednja vrednost nivoa signala, kada se u obzir uzmu samo merne tačke u kojima je signal date ćelije detektovan, veća od -85dBm. Razlog za definisanje ovakvog kriterijuma jeste da se izvrši selekcija ćelija koje imaju relativno visok nivo signala u određenim delovima test okruženja (nezavisno od njihove generalne radio-vidljivosti u celom okruženju), kako bi potencijalno ostvarili bolji uslovi za naknadnu primenu metode segmentacije prostora na podprostore. U slučaju GSM i DCS sistema, kao „kvalitetne” ćelije definišu se one sa nivoom signala većim od -85dBm [98], pa je data vrednost korišćena kao kriterijum.

Navedenih 5 kriterijuma za selekciju relevantnih ćelija primenjeni su na prethodno formirane 4 *fingerprint* baze, opisane u poglavlju 6.1.1. U okviru tabele 6.1, za svaku od baza i svaki od kriterijuma, prikazan je broj relevantnih ćelija čiji se RSS nivoi koriste za potrebe pozicioniranja, odnosno kao ulazi SVM modela (MI vrednosti). Baze koje sadrže samo izmerene RSS vrednosti jednog operatora označene su kao *MTS*, *Telenor* i *VIP*, dok je baza koja sadrži RSS vrednosti sva tri operatora označena sa *All 3*.

Tabela 6.1. Broj ulaza modela (MI) za 4 tipa *fingerprint* baza i različite kriterijume selekcije relevantnih ćelija

Kriterijum selekcije relevantnih ćelija	Veličina MI vektora u <i>fingerprint</i> bazi			
	<i>MTS</i>	<i>Telenor</i>	<i>VIP</i>	<i>All 3</i>
All_N	38	65	72	175
TOP 7	7	7	7	7
RV_20%	14	18	20	52
RV_5%	19	33	28	80
Lev-85	22	33	22	77

U slučaju predloženih kriterijuma selekcije relevantnih GSM/DCS ćelija (osim TOP_7 kriterijuma), broj RSS vrednosti koje se koriste pri estimaciji prostornih koordinata mobilnog korisnika može biti veći od onog podržanog standardnom GSM/DCS signalizacijom. Međutim, kao što je već pomenuto u poglavlju 4.1.2, mobilni terminali već poseduju hardverske mogućnosti da mere nivo signala velikog broja okolnih ćelija. Izmene koje je potrebno izvršiti kako bi se omogućio prenos većeg broja izmerenih RSS vrednosti odnose se na izmene postojeće signalizacije, koje ne bi trebalo da imaju veliki uticaj na kapacitet same mreže. Dakle, korišćenje većeg broja RSS merenja za potrebe pozicioniranja zahteva samo odgovarajuće softverske izmene, bez potrebe za izmenama hardverske infrastrukture, pa je i potencijalni uticaj na mrežu i mobilne terminale neznatan.

6.2. TRENIRANJE I OPTIMIZACIJA SVM MODELA ZA POZICIONIRANJE

Kao i u slučaju test *outdoor* okruženja, za odabrano *indoor* okruženje sa slike 6.1, realizovana su dva tipa SVM modela za pozicioniranje: SVR model i kombinovani SVC&SVR model. Modeli su implementirani u programskom okruženju MATLAB. Treniranje i kasnija verifikacija performansi modela za pozicioniranje izvršena je na računaru sa procesorom tipa *Intel Core i5 Processor @2.26GHz* i 2GB RAM memorije.

Celokupna baza podataka podeljena je na slučajan način na tri nezavisna podskupa, namenjena treniranju, validaciji i verifikaciji predloženih SVM modela (podskupovi podataka veličine 70%, 15% i 15% originalne baze, respektivno). Prostorni raspored trening, validacionih i verifikacionih mernih tačaka prikazan je na slici 6.1. Na ovom mestu potrebno je naglasiti da je za sve implementirane SVM modele korišćena identična podela mernih tačaka na trening, validacione i verifikacione tačke. Jedino su se za različite SVM modele razlikovale veličine i vrednosti MI vektora pridruženih datim mernim tačkama, u zavisnosti od primenjenog kriterijuma selekcije relevantnih ćelija, kao i činjenice da li se koristi infrastruktura pojedinačnih operatora ili sva tri zajedno (tabela 6.1).

6.2.1. REALIZACIJA SVR MODELA ZA POZICIONIRANJE

Struktura SVR modela implementiranih za posmatarno *indoor* okruženje ista je kao u slučaju test *outdoor* okruženja i detaljno je opisana u poglavlju 4.3.


Kao što je već pomenuto u poglavlju 5.2.1, pri realizaciji SVR modela za pozicioniranje korišćena je kvadratna ε -insensitive funkcija greške. Na osnovu rezultata dobijenih prethodnim testiranjem SVR modela za različite tipove kernel funkcija u *outdoor* okruženju (poglavlje 5.2.1), za realizaciju SVR, kao i kombinovanih SVC&SVR modela za pozicioniranje u *indoor* okruženju, odabrana je *Laplacian* kernel funkcija. Optimalne vrednosti parametra *Laplacian* kernel funkcije, kao i parametara ε i C , određene su kroz proces validacije SVR modela na nezavisnom skupu podataka (tzv. validacionom skupu). Nakon završenog procesa treniranja i optimizacije, performanse SVR modela verifikovane su na nezavisnom, verifikacionom skupu mernih tačaka.

6.2.2. REALIZACIJA SVC&SVR MODELA ZA POZICIONIRANJE

U slučaju realizacije kombinovanog SVC&SVR modela, primenjen je prethodno razmatran pristup segmentacije prostora od interesa na podprostore (tj. *space-partitioning* princip). Posmatrano test *indoor* okruženje podeljeno je geometrijskim putem na 2 (SVC&SVR_{1x2}), 3 (SVC&SVR_{1x3}), 4 (SVC&SVR_{2x2}), 6 (SVC&SVR_{2x3}), 8 (SVC&SVR_{2x4}) i 12 (SVC&SVR_{2x6}) podprostora, na način prikazan na slikama 6.2(a), 6.2(b), 6.2(c), 6.2(d), 6.2(e) i 6.2(f), respektivno.

Pri realizaciji kombinovanih SVC&SVR modela primenjen je pristup realizacije *multiclass* SVC klasifikatora u jednom sloju („*one-against-all*“ metod), opisan detaljno u poglavlju 4.4.1. Struktura kombinovanih SVC&SVR modela prikazan je na slici 6.3, gde vrednost M odgovara broju podprostora: 2, 3, 4, 6, 8 i 12. Realizacija *multiclass* SVC klasifikatora u jednom sloju je odabrana zbog manje zone pokrivanja modela za pozicioniranje, u poređenju sa prethodno razmatranom implementacijom u *outdoor* okruženju. Naime, usled manje površine test *indoor* okruženja u odnosu na test *outdoor* okruženje, a time i manjeg broja trening tačaka, vreme treniranja modela je znatno kraće

(što će biti prikazano u nastavku poglavlja). Iz datog razloga, čak i u slučaju definisanja većeg broja podprostora, nije neophodno korišćenje *nested* strukture koja smanjuje vreme potrebno za treniranje modela, ali na račun usložnjavanja strukture modela (tj. algoritma za pozicioniranje).




Slika 6.2. Primena principa segmentacije prostora na podprostore u slučaju test *indoor* okruženja

Potrebno je napomenuti da u slučaju SVC&SVR_{1x2} modela postoji odstupanje od opšte strukture kombinovanog SVC&SVR modela koja je prikazana na slici 6.3. Naime, kako u datom slučaju detekcija podprostora predstavlja binarni klasifikacioni problem, njega je moguće rešiti samo pomoću jednog binarnog SVC klasifikatora (drugi SVC podmodel je u datom slučaju redundantan).

SVC_m podmodeli ($m=1..M$) trenirani su sa svim podacima trening skupa, dok su SVR_m podmodeli ($m=1..M$) trenirani samo sa delom podataka originalnog trening

skupa, tj. sa podacima koji su prikupljeni u njima odgovarajućem podprostoru m . Svi SVC i SVR podmodeli realizovani su korišćenjem *Laplacian* kernel funkcije. Kao i u slučaju SVR modela, optimalne vrednosti parametra *Laplacian* kernel funkcije, kao i vrednosti ε i C , određene su kroz proces validacije modela na nezavisnom, validacionom skupu podataka. Nakon završenog procesa treniranja i optimizacije, performanse SVC&SVR modela verifikovane su na nezavisnom, verifikacionom skupu mernih tačaka.



Slika 6.3. Struktura kombinovanog SVC&SVR modela za pozicioniranje

6.3. ANALIZA PERFORMANSI SVR I SVC&SVR MODELA ZA POZICIONIRANJE U *INDOOR* OKRUŽENJU

6.3.1. TAČNOST POZICIONIRANJA SVR METODE

Osim opšte analize performansi SVR modela za pozicioniranje u zatvorenom prostoru, u okviru ovog poglavlja izvršena je i analiza uticaja korišćenja infrastrukture jednog (*single-operator*) ili većeg broja operatora (*multi-operator*) na tačnost pozicioniranja. Za te potrebe implementirana su četiri tipa SVR modela koja kao ulazne podatke koriste RSS merenja koja potiču od GSM/DCS ćelija operatora MTS (SVR_MTS), Telenor (SVR_Telenor) i VIP (SVR_VIP), kao i sva tri operatora zajedno (SVR_ALL_3).

Za svaka od četiri tipa SVR modela, analizirana je tačnost pozicioniranja ostvarena u slučaju primene nekog od prethodno navedenih pet kriterijuma selekcije relevantnih ćelija. Komparativni pregled ostvarenih tačnosti implementiranih SVR modela za posmatrano *indoor* okruženje prikazan je u tabeli 6.2.

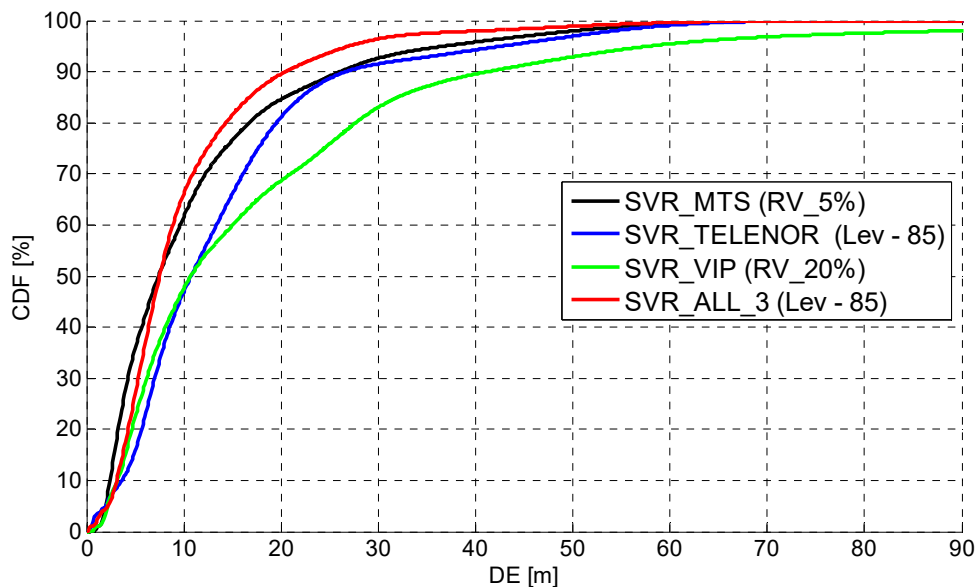
Table 6.2. Rezultati verifikacije performansi *single-operator* i *multi-operator* SVR modela za pozicioniranje: SVR_MTS, SVR_Telenor, SVR_VIP i SVR_ALL_3

Greška pozicioniranja (<i>Distance error- DE</i>)									
Mrežni operator	Kriterijum selekcije relevantne ćelije	Broj relevantnih ćelija	Srednja DE [m]	σ -standardna devijacija [m]	Medijanska DE [m]	67% DE* [m]	90% DE ⁺ [m]	MIN DE [m]	MAX DE [m]
MTS	Top 7	7	13.2	12.3	9.7	13.2	31.7	0.35	56
	RV_20%	14	11.3	11.3	7.9	11.3	25.4	0.3	56.1
	RV_5%	19	11.3	11.2	7.1	11	26.2	1	55.1
	All N	38	11.3	11.2	7.8	11.1	25.8	1.3	55.3
	Lev-85	22	11.3	11.1	7.9	11.4	25.7	0.6	55.3
Telenor	Top 7	7	18.2	14.7	13.1	21.8	39.3	1.2	58.1
	RV_20%	18	14.9	12.7	11.5	16.4	33.7	1.3	54.4
	RV_5%	33	13.8	11.9	10.8	15.7	26	0.9	54.2
	All_N	65	13.8	11.9	11	15.5	25.8	1	54.2
	Lev-85	33	13.9	11.7	10.9	15.3	25.2	0.4	54.3
VIP	Top 7	7	24.2	23	16.4	30.5	52.8	0.9	128
	RV_20%	20	18.2	20.2	10.7	18.6	40.9	0.8	120.5
	RV_5%	28	18.8	20.2	10.6	19.1	40.9	1.9	120.4
	All_N	72	19.3	20	13.1	18.5	40.9	1.8	120.4
	Lev-85	22	18.4	20.1	11.3	18.6	40.9	1.1	120.5
Sva 3 operatora	Top_7	7	14.4	17	10.4	13.7	27.3	1.3	119.4
	RV_20%	52	10.5	9.2	7.6	10.4	25.2	0.8	54.9
	RV_5%	80	10.3	8.8	7.8	10.8	19.4	0.6	56.1
	All_N	175	10.3	8.8	8	10.5	19.4	0.6	56.1
	Lev-85	77	10.1	8.8	7.5	9.9	20.6	0.3	55.5

Na osnovu prikazanih rezultata može se videti da svi implementirani SVR modeli, nezavisno od korišćenja infrastrukture određenog mobilnog operatora ili kriterijuma za selekciju relevantnih ćelija, zadovoljavaju FCC zahteve po pitanju horizontalne tačnosti u *indoor* okruženjima [5,6]. Postignute tačnosti ukazuju na opštu sposobnost SVR algoritma da „nauči“ nelinearne relacije koje postoje između izmerenih RSS vrednosti i prostornih koordinata u slučaju kompleksnih *indoor* okruženja, gde su izvori radio signala smešteni izvan objekta. Drugim rečima, pruža se mogućnost za iskorišćenje postojeće infrastrukture javnih mobilnih mreža za potrebe pozicioniranja mobilnih korisnika i u zatvorenim prostorima.

U nastavku poglavlja izvršena je analiza tačnosti pozicioniranja sa stanovišta korišćenja infrastrukture jednog ili više mobilnih operatora, kao i primene različitih kriterijuma selekcije relevantnih ćelija.

Radi bolje preglednosti i lakše komparativne analize dobijenih rezultata, na slici 6.4 prikazane su kumulativne funkcije raspodele (CDF) vrednosti greške pozicioniranja *single-operator* (SVR_MTS, SVR_Telenor i SVR_VIP) i *multi-operator* (SVR_ALL_3) SVR modela, za kriterijum selekcije relevantnih ćelija koji je u posmatranom slučaju obezbedio najbolje performanse.



Slika 6.4. Kumulativne funkcije raspodele vrednosti greške pozicioniranja *single-operator* i *multi-operator* SVR modela, za slučaj kriterijuma selekcije relevantnih ćelija koji obezbeđuje najbolje performanse

Poredeći rezultate verifikacije *single-operator* modela u posmatranom *indoor* okruženju (tabela 6.2) jasno se mogu videti razlike u ostvarenim tačnostima pozicioniranja u zavisnosti od konkretne mrežne infrastrukture koja je pri tom korišćena (infrastruktura operatora MTS, Telenor ili VIP).


Ako se izvrši komparativna analiza ukupnog broja detektovanih radio izvora (ćelija) pojedinačnih operatora (tabela 6.1) i rezultata verifikacije tačnosti pozicioniranja odgovarajućih SVR modela (tabela 6.2), može se zaključiti da veći uticaj na tačnost pozicioniranja ima prostorni raspored radio izvora i kvalitet njihovih signala u posmatranom okruženju, nego njihov ukupan broj. Tako na primer, iako su čak 72 ćelije operatora VIP detektovane u okviru posmatranog *indoor* okruženja, *single-operator* SVR_VIP modeli su ostvarili najlošije rezultate po pitanju tačnosti pozicioniranja. Međutim, analizom radio-vidljivosti i kvaliteta signala detektovanih VIP ćelija, može se primetiti da signale oko 60% datih ćelija karakteriše dosta nizak nivo (blizak nivou šuma) u većem delu test *indoor* okruženja, čineći date ćelije radio-vidljivim u manje od 5% mernih lokacija (tabela 6.1). Naime, u postojećoj infrastrukturi VIP mobilnog operatora po brojnosti prednjače DCS bazne stanice u odnosu na GSM. I pored gušće mrežne infrastrukture u posmatranom okruženju (u poređenju sa drugim operatorima), za slučaj *indoor* prostora većih dimenzija, kakvo je i odabrano test okruženje, usled većeg propagacionog slabljenja radio signala na 1800MHz, pojedine DCS ćelije mogu biti detektovane svega u nekoliko mernih tačaka. S druge strane, SVR_MTS modeli su, poredeći sa drugim *single-operator* SVR modelima, ostvarili najbolje performanse, iako je u posmatranom *indoor* prostoru detektovano najmanje MTS GSM/DCS ćelija. Navedeni rezultati ukazuju na to da se u pojedinim slučajevima više informacija o prostoru može dobiti iz manjeg broja, ali povoljno prostorno raspoređenih radio izvora. U slučaju SVR_MTS modela, povoljan uticaj na tačnost pozicioniranja imala je blizina lokacija sa kojih su realizovane prethodno pomenute 2 GSM BS ćelije (unutar atrijumima zgrade ETF-a).

S druge strane, istovremeno korišćenje infrastrukture različitih mobilnih operatora pri određivanju pozicije mobilnog korisnika, može da obezbedi tačnije i stabilnije rešenje (slika 6.4), u poređenju sa slučajem kada se koriste RSS vrednosti ćelija jednog mobilnog operatora. Naime, kako u opštem slučaju algoritam za pozicioniranje ne poseduje *a priori* znanje o lokacijama baznih stanica (radio izvora) u nekoj geografskoj

oblasti, korišćenje infrastrukture različitih operatora povećava verovatnoću da odabrani radio izvori budu prostorno razdvojeni i uniformnije raspoređeni, odnosno da radio signali odabranih relevantnih izvora budu manje korelisani. Takođe, povećava se broj radio izvora koji u posmatranom okruženju mogu obezbediti kvalitetan signal za potrebe estimacije pozicije.

Ono što je zajedničko za *single-operator* i *multi-operator* SVR modele jeste ponašanje vrednosti greške pozicioniranja u slučaju povećanja broja relevantnih izvora čije se RSS vrednosti koriste u procesu estimacije prostornih koordinata. Analizom rezultata dobijenih primenom predloženih kriterijuma za selekciju relevantnih ćelija na osnovu verovatnoće njihove radio-vidljivosti u posmatranom okruženju (Top_7, RV_20%, RV_5% i All_N), može se primetiti da srednja vrednost greške pozicioniranja SVR modela opada sa povećanjem broja RSS izvora (tj. ublažavanjem zahteva po pitanju verovatnoće radio-vidljivosti), ali samo do određene tačke (slika 6.5). Nakon dostizanja te granice, korišćenje RSS vrednosti dodatnih radio izvora, koji npr. imaju niske i nestabilne nivoe signala u većem delu posmatranog geografskog okruženja, ne doprinosi više povećanju tačnosti pozicioniranja, a u pojedinim slučajevima može je i pogoršati (SVR_VIP modeli). Dakle, korišćenje svih raspoloživih RSS vrednosti, ne mora doprineti povećanju tačnosti algoritma za pozicioniranje, a povećava kompleksnost implementacije modela.

S druge strane, Lev-85 kriterijum koji vrši selekciju samo onih ćelija koje imaju relativno visoke nivoe signala u određenom delu posmatranog okruženja (bez obzira na njihovu generalnu radio-vidljivost), pokazao je generalno dobre performanse i u slučaju *single-operator* i *multi-operator* SVR modela. Dodatni motiv za korišćenje ovog kriterijuma jeste u obezbeđivanju boljih uslova za uvođenje principa segmentacije prostora i lokalizacije korisnika u određenom delu posmatranog geografskog okruženja.



Slika 6.5. Ponašanje vrednosti greške pozicioniranja sa povećanjem broja relevantnih ćelija: SVR_MTS, SVR_Telenor, SVR_VIP i SVR_ALL_3

6.3.2. TAČNOST POZICIONIRANJA KOMBINOVANE SVC&SVR METODE

Uzimajući u obzir prethodno razmatrane prednosti korišćenja infrastrukture većeg broja operatora, kombinovani SVC&SVR model realizovan je kao *multi-operator* rešenje. Pri tom, za selekciju relevantnih ćelija odabran je Lev-85 kriterijum, kako bi se omogućili bolji uslovi za rešavanje *multiclass* problema određivanja užeg podprostora u kome se korisnik nalazi.


Kao što je već pomenuto u poglavlju 6.2.2, u cilju analize uticaja veličine podprostora na tačnost kombinovanog SVC&SVR modela za pozicioniranje, primenjeni su različiti obrasci segmentacije posmatranog *indoor* test okruženja, zasnovani na geometrijskom principu (slika 6.2).

Rezultati verifikacije tačnosti implementiranih kombinovanih SVC&SVR modela, za slučaj podele test *indoor* okruženja na 2 (SVC&SVR_{1x2}), 3 (SVC&SVR_{1x3}), 4 (SVC&SVR_{2x2}), 6 (SVC&SVR_{2x3}), 8 (SVC&SVR_{2x4}) i 12 (SVC&SVR_{2x6}) podprostora, prikazani su u tabeli 6.3. Radi lakšeg poređenja, prikazani su i rezultati verifikacije tačnosti *multi-operator* SVR modela, za slučaj primene Lev-85 kriterijuma (ekvivalent SVC&SVR_{1x1} modelu).

Kumulativne funkcije raspodele (CDF) vrednosti greške pozicioniranja implementiranih SVC&SVR modela prikazani su na slici 6.6. Poređenje ostvarenih dobitaka SVC&SVR modela u odnosu na SVR model, za različite obrasce podele prostora, detaljnije je prikazano na slici 6.7.

Tabela 6.3. Rezultati verifikacije performansi *multi-operator* SVR i SVC&SVR modela za pozicioniranje, za slučaj Lev-85 kriterijuma selekcije relevantnih ćelija

Greška pozicioniranja (<i>Distance error</i> – DE) [m]										
Modeli	Podela prostora	Verovatnoća ispravne selekcije podprost.	Srednja DE [m]	σ -standardna devijacija [m]	Medijanska DE [m]	67% DE [m]	90% DE [m]	95% DE [m]	MIN DE [m]	MAX DE [m]
SVR	1x1	1	10.1	8.8	7.5	9.9	20.6	26.1	0.3	55.5
SVC&SVR _{1x2}	1x2	0.98	7.6	5.7	6.5	8.7	13.2	14.9	0.6	40.2
SVC&SVR _{1x3}	1x3	0.90	8.3	8.1	6.6	8.6	16.2	21.8	1.2	56.8
SVC&SVR _{2x2}	2x2	0.89	7.6	9.7	5.2	7.9	12.7	14.8	0.3	82.6
SVC&SVR _{2x3}	2x3	0.81	7.6	8	5.3	7.2	16.7	22.4	0.8	54
SVC&SVR _{2x4}	2x4	0.77	7.4	6.5	5.7	7.5	13.7	23.4	0.5	35.5
SVC&SVR _{2x6}	2x6	0.69	8.3	8.7	5.2	7.4	19	26.3	0.7	50.7




Slika 6.6. Kumulativne funkcije raspodele vrednosti greške pozicioniranja *multi-operator* SVR i kombinovanih SVC&SVR modela za pozicioniranje za različite stepene segmentacije prostora

Kao i u slučaju *outdoor* test okruženja, dobijeni rezultati potvrđuju osnovnu pretpostavku da se uvođenjem principa segmentacije prostora ostvaruju bolji uslovi za rešavanje problema regresije, tj. pronalaženje funkcije za estimaciju koordinata u datom geografskom okruženju. Podelom posmatranog *indoor* test okruženja na podprostore, srednja greška pozicioniranja redukovana je sa 10.1m (SVR bez segmentacije prostora) na 7.4m (SVC&SVR_{2x4}). Na osnovu ostvarenih rezultata moguće je izvesti nekoliko zaključaka.

Najpre, sa povećanjem stepena segmentacije, veličina podprostora, za koji SVR podmodel pronalazi (uči) funkciju za estimaciju prostornih koordinata, se smanjuje, čime se ostvaruju bolji uslovi za aproksimaciju date funkcije. Kao posledica toga, povećava se broj malih vrednosti grešaka pozicioniranja, što vodi do generalnog smanjenja vrednosti medijanske i 67% DE, poredeći sa slučajem kad se jedan SVR model za pozicioniranje implementira za celo test okruženje (slika 6.7). Prikazani rezultati daju uvid u opšti uticaj koji veličina prostora, za koje se implementira jedan SVR model za pozicioniranje, ima na postignutu tačnost pozicioniranja. S druge strane, rezultati ostvareni primenom principa segmentacije prostora i kombinovane SVC&SVR metode ukazuju na robustnost i prilagodljivost predložene tehnike pozicioniranja

prostorima različitih veličina, čime se opravdava primena ovog pristupa u kompleksnim *indoor* okruženjima većih dimenzija.



Slika 6.7. Kumulativne funkcije raspodele vrednosti greške pozicioniranja *multi-operator* SVR i kombinovanih SVC&SVR modela za pozicioniranje za različite stepene segmentacije prostora

Drugi bitan aspekt primene principa segmentacije prostora jeste verovatnoća ispravne detekcije podprostora u kome se korisnik trenutno nalazi. Kao što je i bilo očekivano, dobijeni rezultati su pokazali da sa porastom broja podprostora, tj. stepenom segmentacije, dolazi do postepenog povećanja verovatnoće pogrešne klasifikacije tj. odabira podprostora. Pri tom, kao što je već pomenuto, na vrednost greške pozicioniranja pri pogrešno detektovanom podprostoru utiču dva oprečna faktora. Prvo, sa povećanjem stepena segmentacije, tj. smanjenjem veličine podprostora, vrednost greške pozicioniranja u slučaju selekcije podprostora koji je susedan onom u kome se korisnik zapravo nalazi, takođe se smanjuje. Međutim, sa povećanjem verovatnoće pogrešne selekcije podprostora, istovremeno raste i verovatnoća da odabran podprostor ne bude susedan onome u kome se korisnik zapravo nalazi. To sa druge strane može dovesti do određenog povećanja broja velikih vrednosti grešaka pozicioniranja. Zbog navedenih efekata, ponašanje greške pozicioniranja pri pogrešnoj selekciji podprostora ne može se opisati striktnim pravilom.

Analizom kumulativnih raspodela vrednosti DE za razmatrane tipove segmentacije posmatranog prostora (slika 6.7), može se videti da i pored slučajeva pogrešne detekcije podprostora, ne dolazi do opšteg povećanja broja velikih vrednosti grešaka pozicioniranja, u odnosu na SVR model. Šta više, smanjuje se broj velikih vrednosti DE na račun porasta broja srednjih (*medium-sized*) DE vrednosti. Na to ukazuju niže vrednosti 90%DE i 95%DE u poređenju sa onima postignutim primenom SVR modela. Drugim rečima, dobitak ostvaren smanjenjem zone pokrivanja SVR podmodela nadjačava potencijalni problem porasta broja velikih vrednosti DE usled pogrešne detekcije podprostora. Tek pri većem stepenu segmentacije prostora, tj. za slučaj 2x6 podele, procenat velikih DE vrednosti postaje blizak onome kod SVR modela (tabela 6.3).


Usled prethodno opisanih efekata, celokupna srednja vrednost greške pozicioniranja se smanjuje sa smanjenjem veličine podprostora, ali se takav trend završava zaključno sa primenom 2x4 prostorne podele (tabela 6.3). Sa daljim povećanjem stepena segmentacije (2x6 podele), srednja vrednost greške pozicioniranja počinje opet da raste. Dobijeni rezultati ukazuju na to da povećanje stepena segmentacije ima smisla samo do određene granice, kada porast broja velikih vrednosti

DE, uzrokovan pogrešnom detekcijom podprostora, počinje da umanjuje dobitak ostvaren smanjenjem veličine podprostora za koji se realizuju SVR podmodeli.

Određeno odstupanje od prethodno analiziranog opšteg ponašanja srednje greške pozicioniranja pri različitim stepenima segmenatcije prostora, moguće je primetiti kod 1x3 prostorne podele posmatranog *indoor* okruženja (tabela 6.3). U datom slučaju, i pored smanjenja veličine podprostora u odnosu na 1x2 podelu, dobitak ostvaren primenom 1x3 podele je manji nego u slučaju 1x2 podele (slika 6.7.a i 6.7.b). Dodatno, iako su za prostorne podele tipa 1x3 i 2x2 verovatnoće ispravne selekcije podprostora slične (90% i 89%, respektivno), podela tipa 1x3 proizvodi veći broj velikih vrednosti grešaka pozicioniranja, nego podela 2x2 (tabela 6.3).

Uočeno odstupanje može se objasniti kao posledica načina na koji je vršena segmentacije prostora. Naime, kao što je već ranije spomenuto, u okviru ovog istraživanja segmentacije prostora su vršene isključivo po geometrijskom principu, bez uzimanja u obzir stvarne unutrašnje strukture odabranog test okruženja (npr. rasporeda zidova, prozora, objekata, itd) i rasporeda izvora radio signala. Usled toga, pojedini obrasci podele prostora formiraju logičke celine koje su manje homogene u pogledu radio-propagacionih uslova i/ili pridružuju delove prostora sa sličnim radio-propagacionim uslovima različitim klasama (tj. logičkim podprostorima).

U tom smislu, kod posmatranog test okruženja, može se primetiti određena pravilnost u ponašanju vrednosti DE u slučaju 1x2, 2x2 i 2x4 prostornih podela, kao i s druge strane u slučaju podela tipa 1x3, 2x3 i 2x6 (slika 6.7). Uzrok ove pojave jeste specifična realizacija prethodno pomenute dve GSM ćelije operatora MTS u atrijumima test okruženja (slika 6.8). Naime, u cilju povećanja zone pokrivanja navedene dve GSM ćelije, signal na izlazu iz predajnika obe GSM bazne stanice je podeljen i emitovan preko dva odvojena antenska sistema (ćelija je podeljena, tj. splitovana). Usled toga, podele tipa 1x3, 2x3 i 2x6 su manje u skladu sa prirodno formiranim radio-propagacionim celinama u okviru posmatranog *indoor* okruženja, usled čega proizvode veći broj velikih vrednosti grešaka pozicioniranja, u poređenju sa 1x2, 2x2 i 2x4 tipovima podela (slika 6.7). Data pojava imala je najveći uticaj na vrednosti 90% DE (tabela 6.3).



Slika 6.8. Specifičnosti realizacije dve MTS GSM ćelije (Cell ID 18094 i Cell ID 18095) u atrijumima zgrade Elektrotehničkog fakulteta

Dakle, obrazac po kome se vrši segmentacija nekog prostora (*space-partitioning pattern*) može imati bitan uticaj na tačnost pozicioniranja. Primena obrazaca koji se ne zasnivaju nužno na geometrijskom principu, već uzimaju u obzir strukturu nekog *indoor* okruženja u cilju definisanja logičkih podprostora sa što „homogenijim“ radio-propagacionim uslovima, potencijalno bi mogla da dalje unapredi tačnost kombinovane SVC&SVR metode pozicioniranja.

Na kraju, demonstrirane performanse *multi-operator* SVR i SVC&SVR modela potvrđuju da obe metode mogu pružiti dobru tačnost pri estimaciji pozicije mobilnog korisnika u kompleksnim *indoor* okruženjima, koja je u skladu sa FCC zahtevima. Pri tom, uvođenjem principa segmentacije prostora moguće je ostvariti dodatno poboljšanje tačnosti, u poređenju sa slučajem kad se jedan SVR model implementira za ceo prostor od interesa. Predložen pristup može biti od posebnog interesa u slučaju kompleksnih *indoor* okruženja velikih dimenzija.

6.3.3. KOMPLESNOST I KAŠNJENJE SVM MODELA – INDOOR OKRUŽENJE

Osim analize tačnosti predloženih SVM modela u test *indoor* okruženju, izvršena je i analiza njihovih performansi po pitanju kompleksnosti (vremena treniranja) i

kašnjenja koje unose (tj. vremena potrebnog za estimaciju pozicije). Rezultati su predstavljeni u tabeli 6.4.

Tabela 6.4. Kompleksnost i kašnjenje SVR i SVC&SVR modela - *indoor* test okruženje

MODELI	KOMPLEKSNOŠT					KAŠNJENJE
	BROJ SVC/SVR PODMODELA		VREME TRENIRANJA (min)			
	SVC sloj	SVR sloj*	Prosečno vreme treniranja SVC podmodela	Prosečno vreme treniranja SVR podmodela	Ukupno vreme treniranja	Prosečno vreme estimacije pozicije – <i>online</i> faza (s)
SVR	-	2	-	1.7	3.40	0.02
SVC&SVR_{1x2}	1	4	0.71	0.22	1.59	0.01
SVC&SVR_{1x3}	3	6	0.72	0.075	2.61	0.04
SVC&SVR_{2x2}	4	8	0.75	0.043	3.34	0.07
SVC&SVR_{2x3}	6	12	0.69	0.018	4.36	0.07
SVC&SVR_{2x4}	8	16	1.03	0.007	8.35	0.14
SVC&SVR_{2x6}	12	24	1.03	0.002	12.41	0.32

*Svaki SVR podmodel SVR_x i SVR_y podmodela.

Poredeći sa vremenima potrebnim za treniranje SVM modela za slučaj test *outdoor* okruženja (poglavlje 5.3.3), može se primetiti da su vremena treniranja za slučaj *indoor* okruženja značajno manja. Razlog je u manjoj geografskoj zoni koju pokriva jedan SVM model, pa samim tim i manjim brojem potrebnih podataka za treniranje modela. Kao što je i očekivano, povećanjem stepena segmentacije dolazi do porasta vremena potrebnog za optimalno treniranje modela. Međutim, efekat porasta vremena treniranja modela zbog povećanja broja SVC podmodela biva donekle umanjen kroz efekat smanjenja vremena potrebnog za treniranje SVR podmodela. Samim tim, za razmatrane podele prostora, vremena treniranja predloženih SVM modela ostaju u okviru razumnih granica.

Na kraju, kao što se već i ranije pokazalo, predložene SVR i SVC&SVR modele karakteriše efikasnost u *online* fazi zbog osobine da pružaju „proređeno“ rešenje (*sparse solution*). Vreme potrebno za estimaciju prostornih koordinata nepoznate pozicije mobilnog korisnika iznosi manje od sekund i u *indoor* okruženju, čineći

predložen SVR i SVC&SVR metod pogodnim za realizaciju LBS servisa sa striktnim zahtevima po pitanju kašnjenja.

6.4. POREĐENJE SA DRUGIM ĆELIJSKIM METODAMA U INDOOR OKRUŽENJU

Komparativni pregled tačnosti predložene SVR, tj. SVC&SVR metode i tehnika pozicioniranja predloženih u relevantnim istraživanjima (poglavljje 2.5.3), dat je u tabeli 6.5.

Bitan aspekt, koji se mora uzeti u obzir pri komparaciji različitih metoda pozicioniranja, jeste tip *indoor* okruženja u kome su verifikovane performanse neke tehnike. Naime, kao što je već napomenuto, poželjno je da test okruženje ima dovoljno velike dimenzije, kao i kompleksnu unutrašnju strukturu, kako bi performanse neke tehnike za pozicioniranje mogle biti u potpunosti ispitane pri različitim (složenim) radio-propagacionim uslovima.

Uticaj veličine *indoor* okruženja na tačnost implementiranih WLAN metoda pozicioniranja razmatran je [54]. S druge strane, dati aspekt nije razmatran u dosadašnjim istraživanjima koja se odnose na primenu ćelijskih metoda pozicioniranja u *indoor* okruženjima.

Iz navedenih razloga, definisan je parametar $E(DE_{rand})$, koji predstavlja očekivanu vrednost greške pozicioniranja u nekom *indoor* okruženju dimenzija $a \times b$, u slučaju da se pozicija mobilnog korisnika određuje po slučajnom principu (*random*), bez primene ikakve tehnike pozicioniranja. Drugim rečima, dati parametar odgovara srednjoj vrednosti greške pozicioniranja u slučaju da tehnika pozicioniranja nema nikakve ulazne podatke osim dimenzija okruženja u kome se korisnik nalazi. U tom slučaju, očekivano rastojanje između dve slučajno odabrane tačke u okviru pravougaone oblasti dimenzija $a \times b$, u slučaju da su sve pozicije jednako verovatne (uniformna raspodela), definisano je sa [113]:

$$E(DE_{rand}) = \frac{1}{3} \sqrt{a^2 + b^2} + \frac{a^2}{6b} \ln \left(\frac{b + \sqrt{a^2 + b^2}}{a} \right) + \frac{b^2}{6a} \ln \left(\frac{a + \sqrt{a^2 + b^2}}{b} \right) - \frac{\sqrt{(a^2 + b^2)^5}}{15a^2b^2} + \frac{a^2b^2}{15a^2b^2} \quad (6.1)$$

Kako bi se u ostvario uvid u relativnu tačnost neke tehnike pozicioniranja, uzimajući u obzir veličinu okruženja u kome je data tehnika implementirana, medijanska vrednost greške pozicioniranja date tehnike normalizovana je sa vrednošću $E(DE_{rand})$, koja odgovara posmatranom *indoor* okruženju. Relativna tačnost neke tehnike je utoliko veća ukoliko je dati odnos manji.

Tabela 6.5. Komparacija RSS *finegrprinting* ćelijskih metoda pozicioniranja u *indoor* okruženju

	kNN [65]	WkNN [67]	ANN [71]	SVR	SVC&SVR (2x4)	WLAN CC-ANN [54]
Veličina test okruženja [m] x [m]	88 x 103 (hodnici)	-	28 x 15	147 x 66	147 x 66	147 x 66
$E(DE_{rand})$ [m]	49.87	-	11.48	57.63	57.63	57.63
Ulazni parametri	RSS nivoi do 35 GSM BCCH i saobraćajnih kanala	RSS nivoi 22 GSM ćelije	RSS nivoi 7 DCS ćelija	RSS nivoi 77 GSM/DCS ćelija	RSS nivoi 77 GSM/DCS ćelija	RSS nivoi 8 WLAN AP
Srednja DE [m]	-	9.7	-	10.1	7.4	8.54
Medijanska DE (DE_{median}) [m]	3.02	8.7	5.22	7.5	5.7	5.59
67% DE [m]	-	11.5	-	9.9	7.5	-
95% DE [m]	17.92	17.3	7.32	26.1	23.4	-
$DE_{median} / E(DE_{rand})$	0.061 *	-	0.455	0.130	0.099	0.097

* merenja su vršena isključivo u hodnicima

Poređenjem vrednosti medijanske i 95% DE kNN [65] i ANN [71] metode pozicioniranja, sa vrednostima ostvarenim primenom SVR, odnosno SVC&SVR metoda, moglo bi se zaključiti da kNN i ANN metode daju bolje rezultate od predloženih SVM metoda. Međutim, ako se uzmu u obzir veličine test okruženja, tj. odnos vrednosti medijanske DE i $E(DE_{rand})$, pokazuje se da je relativna tačnost SVR i SVC&SVR tehnika pozicioniranja veća u poređenju sa onom koju pruža ANN pristup. Što se tiče verifikacije kNN metode, potrebno je istaći da su merenja u [65] vršena isključivo u hodnicima u okviru jednog sprata dimenzija 88m x 103m, ne uzimajući u obzir kancelarije koje su okružene hodnicima ili se nalaze sa spoljne strane hodnika.

Samim tim, stvarna veličina test okruženja korišćenog za verifikaciju kNN metode u [65] je značajno manja od one navedene u tabeli 6.5.

U tabeli 6.5 su takođe prikazani rezultati verifikacije tačnosti WLAN metode pozicioniranja zasnovane na korišćenju kaskadno povezanih ANN mreža (*Cascade-correlated ANN*, CC-ANN) [54], koja je implementirana u istom test okruženju, kao i predloženi SVR i SVC&SVR modeli za pozicioniranje. U datom slučaju korišćena je infrastruktura WLAN mreže koja je implementirana sa ciljem da se obezbedi maksimalno pokrivanje *indoor* okruženja WLAN signalom uz instalaciju minimalnog broja AP. Dati pristup je u praksi najčešće i korišćen jer minimizira troškove izgradnje WLAN infrastrukture. Rezultati prikazani u tabeli 6.5 ukazuju na bitan zaključak da se primenom SVC&SVR metode ćelijskog pozicioniranja može ostvariti tačnost koja je porediva sa tačnošću WLAN metoda pozicioniranja. Dati rezultati opravdavaju predlog iskorišćenja infrastrukture postojećih ćelijskih sistema za potrebe *indoor* pozicioniranja, čime se značajno može smanjiti cena implementacije i povećati dostupnost *indoor* sistema za pozicioniranje.

Izvršena analiza performansi SVR modela za slučaj korišćenja infrastrukture jednog ili više mobilnih operatora, kao i različitih kriterijuma selekcije relevantnih ćelija (poglavlje 6.3.1), potvrđuje uticaj koji odabir izvora radio signala ima na ostvarenu tačnost neke tehnike pozicioniranja. Zbog toga, neophodno je izvršiti i analizu tačnosti tehnika razmatranih u tabeli 6.5 i sa stanovišta datog aspekta. ANN metod predložen u [71] koristi kao ulazne podatke RSS nivoe 7 DCS ćelija koje pripadaju jednom mobilnom operatoru. S druge strane, kod kNN metode implementirane u [65], korišćeni su RSS parametri izmereni na maksimalno 35 GSM radio kanala. Pri tom, korišćene su i RSS vrednosti izmerene na saobraćajnim kanalima, bez dostupne informacije o Cell-ID identifikatoru GSM ćelije koja je emitovala dati kanal. Kao što je već pomenuto, dat pristup ne može garantovati da RSS vrednost izmerena na nekom saobraćajnom kanalu potiču uvek od iste GSM ćelije, zbog ponavljanja frekvencija i primene mehanizma frekvencijskog skakanja u GSM mrežama, što predstavlja osnovni problem u slučaju primene *fingerprint* metoda. S druge strane, ovakav pristup dovodi i do povećanja stepena prostorne kolociranosti izvora radio signala, jer izmereni RSS parametri mogu poticati od radio kanala koji se emituju u okviru iste ćelije. Dodatno, saobraćani kanali

se ne emituju sa konstantnom snagom i njihov nivo može varirati u zavisnosti od saobraćajnog opterećenja. Na kraju, potrebno je još spomenuti, da autori u [65] nisu razmatrali da li detektovani radio kanali pripadaju jednom ili većem broju mobilnih operatora.

U cilju verodostojnog poređenja tehnika prethodno razmatranih u tabeli 6.5, sa stanovišta i veličine test okruženja i korišćenih ulaznih podataka, kNN i ANN modeli za pozicioniranje su takođe implementirani za test okruženje sa slike 6.1, korišćenjem iste baze podataka.


Kao i prethodno implementirani SVR i SVC&SVR modeli, ANN model je realizovan kao *multi-operator* rešenje, primenom Lev-85 kriterijuma za selekciju relevantnih ćelija. ANN model je implementiran u MATLAB okruženju, koristeći *Neural Networks Toolbox*. Kao i u slučaju modela kreiranog za *outdoor* test okruženje, korišćena je *multilayer feedforward* neuralna mreža sa propagacijom greške unazad. Struktura ANN modela sastojala se iz ulaznog sloja, 3 skrivena sloja i izlaznog sloja. Broj perceptrona ulaznog sloja odabran je tako da odgovara broju ulaznih parametara, tj. MI vrednosti (77), dok je broj perceptrona u izlaznom sloju odabran tako da odgovara broju estimiranih izlaznih parametara, tj. x i y koordinati. Kao i u slučaju modela realizovanih za test *outdoor* okruženje, veličina sakrivenih slojeva dimenzionisana je prema [110], tako da broj perceptrona prvog skrivenog sloja bude približno 2 puta veći od broja perceptrona u ulaznom sloju, dok je u narednim skrivenim slojevima broj perceptrona smanjivan linearno, konvergirajući ka broju izlaza. Za potrebe treniranja korišćena je *triangda* funkcija, sa inicijalnom vrednošću brzine učenja (*learning rate*) od 0.1. Svi perceptroni su implementirani sa *hyperbolic tangent sigmoid* transfer funkcijom, osim perceptrona izlaznog sloja koji koriste linearnu transfer funkciju. Kao kriterijumska funkcija za analizu performansi neuralne mreže korišćena je srednja kvadratna greška (MSE).

kNN modeli su takođe implementirani kao *multi-operator* rešenja. Međutim, kroz testiranje različitih kriterijuma za selekciju relevantnih ćelija pokazalo se da su performanse kNN modela za pozicioniranje nešto bolje u slučaju korišćenja svih raspoloživih RSS podataka, odnosno primenom *All_N* kriterijuma. Za dati slučaj,

testirani su kNN modeli za vrednosti parametra k od 1 do 10. U nastavku rada prikazani su rezultati za slučaj $k=1$, za koju je kNN metod ostvario najveću tačnost pozicioniranja. Kumulativne funkcije raspodele greške pozicioniranja kNN i ANN modela najboljih performansi upoređene su sa performansama *multi-operator* SVR i SVC&SVR_{2x4} na slici 6.9.

Tabela 6.6. Poređenje performansi SVR, SVC&SVR, ANN i kNN modela za pozicioniranje

Greška pozicioniranja (<i>Distance error – DE</i>)										
Modeli	Podela prostora	Verovatnoća ispravne selekcije podprostora	Srednja DE [m]	σ -standardna devijacija [m]	Medijanska DE [m]	67% DE [m]	90% DE [m]	95% DE [m]	MIN DE [m]	MAX DE [m]
SVR	1x1	1	10.1	8.8	7.5	9.9	20.6	26.1	0.3	55.5
SVC&SVR _{2x4}	2x4	0.77	7.4	6.5	5.7	7.5	13.7	23.4	0.5	35.5
ANN	1x1	1	12.6	10.8	10.5	12.9	27.3	30.5	1.1	63.7
kNN ($k=1$)	1x1	1	9.3	11.8	4.5	7.6	24	30.2	1.7	73.4



Slika 6.9. Poređenje performansi SVR, SVC&SVR, ANN i kNN modela za pozicioniranje – kumulativne funkcije raspodele grešaka pozicioniranja

U opštem slučaju, optimalan broj suseda kod primene kNN metoda zavisi od gustine radio mape (tj. broja i prostornog rasporeda referentnih tačaka). Slučaj da su najbolji rezultati pri primeni kNN metode ostvareni uzimanjem u obzir samo prvog najbližeg suseda ($k=1$), može se objasniti kao posledica kompleksne unutrašnje strukture posmatranog *indoor* okruženja, koje uzrokuje pojavu niza različitih radio-propagacionih efekata. Kao što je već i ranije istaknuto, dati efekti mogu prouzrokovati veliku razliku u nivoima radio signala izmerenim u prostorno bliskim tačkama, ali i obrnuti slučaj, da dve prostorno udaljene tačke budu slične u pogledu radio signala koji se detektuju u njima (bliske u radio domenu). Iz datog razloga, u ovakvom tipu složenog *indoor* okruženja, korišćenje većeg broja suseda pri estimaciji nepoznate pozicije, može degradirati tačnost modela za pozicioniranje. S druge strane, uzimanje u obzir samo jednog suseda pri estimaciji koordinata, može dovesti do problema u slučaju pogrešne procene najbližeg suseda, što može rezultovati određenim brojem dosta velikih vrednosti grešaka pozicioniranja. Najveći doprinos predložene SVR i SVC&SVR metode u odnosu na kNN jeste u smanjenju velikih vrednosti grešaka pozicioniranja (slika 6.9). U posmatranom test okruženju, primenom SVC&SVR metode ostvareno je smanjenje srednje vrednosti greške za oko 20% u poređenju sa primenom kNN metode.

Na osnovu rezultata prikazanih u tabeli 6.6 i slici 6.9 može se primetiti da su i SVR i kombinovani SVC&SVR modeli ostvarili bolje rezultate nego ANN pristup. Primenom SVC&SVR metode ostvareno je smanjenje srednje vrednosti greške za oko 40% u poređenju sa primenom ANN metode. Kao što je već ranije napomenuto, uzrok generalno boljih performansi SVM algoritma po pitanju tačnosti estimacije jeste to što pronalaženje (učenje) funkcije modela odgovara rešavanju konveksnog optimizacionog problema, koje garantuje jedinstveno (globalno) optimalno rešenje. S druge strane, konvergencija modela ka globalnom optimalnom rešenju nije zagarantovana u slučaju primene ANN mreža. Takođe, primenom SRM (*Structural Risk Minimization*) principa u slučaju SVM algoritama, nasuprot pristupa minimiziranja isključivo empirijskog rizika u slučaju ANN mreža, smanjuje se verovatnoća prepodešavanja modela na trening podatke, odnosno postižu se bolja generalizaciona svojstva modela.

7. ZAKLJUČAK

Intezivan razvoj tehnika za određivanje pozicije mobilnih korisnika prvenstveno je podstaknut realizacijom bezbednosnih servisa, poput servisa hitnog poziva i pomoći u vanrednim situacijama. S druge strane, razvoj tehnika za pozicioniranje u radio sistemima otvorio je vrata novoj generaciji komercijalnih LBS servisa, koji su predmet velikog interesovanja naučne zajednice već duži niz godina. Sa intezivnim razvojem LBS servisa postavljaju se sve strožiji zahtevi koje sistemi za pozicioniranje treba da ispune, prvenstveno po pitanju tačnosti, ali i po pitanju kašnjenja sistema, dostupnosti servisa, kompleksnosti i skalabilnosti sistema, i naravno, cene implementacije.

Cilj ove disertacije je bilo razvoj nove tehnike pozicioniranja koja može, sa zahtevanom tačnošću i u okviru zahtevanog vremena, da obezbedi informaciju o poziciji korisnika/objekta i u *outdoor* i *indoor* okruženju. Bitan aspekt koji je pri tom uzet u obzir jeste cena implementacije takvog novog rešenja. Osnovni doprinosi ove disertacije su sledeći:

- Napravljen je detaljan pregled postojećih standardizovanih i nestandardizovanih metoda pozicioniranja u radio sistemima. Na osnovu sprovedene analize uočena su dva ključna nedostatka koja se javljaju pri korišćenju infrastrukture različitih radio sistema: dostupnost sistema u različitim okruženjima i/ili cena implementacije.
- Dat je predlog nove tehnike pozicioniranja koja se zasniva na korišćenju infrastrukture javnih mobilnih sistema. Navedeni pristup omogućava iskorišćenje postojeće, globalno rasprostranjene PLMN infrastrukture, kao i razvoj servisa pozicioniranja kao dodatnog servisa posebne vrednosti (*value added service*) u okviru postojećeg radio komunikacionog sistema, čime se značajno smanjuje cena implementacije ovakvog rešenja. Dodatno, javni

mobilni sistemi imaju adekvatno pokrivanje radio signalom, kako *outdoor* okruženja različitih stepena urbanizacije, tako i *indoor* okruženja. Usled toga, dostupnost sistema za pozicioniranje nije ograničena na određene tipove okruženja, kao u slučaju korišćenja infrastrukture drugih radio sistema (GPS, WiFi, RFID, *Bluetooth*, itd).

- Razvijene su dve metode za estimaciju pozicije mobilnog korisnika na osnovu izmerenih RSS vrednosti PLMN ćelija u okruženju i primeni *Support Vector Machine* algoritama mašinskog učenja. Prvi predloženi metod pozicioniranja realizovan je korišćenjem SVR algoritma za aproksimaciju funkcije koja opisuje vezu između izmerenih RSS nivoa i prostornih koordinata u nekoj geografskoj oblasti. Kod drugog pristupa primenjen je princip segmentacije geografskog okruženja od interesa na podprostore, korišćenjem *multiclass* klasifikatora realizovanog sa SVC strukturama. Naknadnom upotrebom SVR algoritama, za svaku podoblast aproksimirana je funkcija za predikciju pozicije korisnika na osnovu izmerenih RSS vrednosti. Predložene SVM metode pozicioniranja ne zahtevaju posedovanje detaljnih informacija o izvorima radio signala (njihovoj poziciji, parametrima predajnika, karakteristikama antenskog sistema, itd.), kao ni detaljno poznavanje okruženja i modelovanje propagacionih uslova.
- Predložene metode pozicioniranja verifikovane su korišćenjem realnih podataka koji su prikupljeni tokom mernih kampanja sprovedenih u *outdoor* i *indoor* okruženju na teritoriji grada Beograda. U oba okruženja su korišćene infrastrukture i dalje globalno najrasprostranjenijih 2G javnih mobilnih mreža – GSM i DCS, sa ciljem da se ispitaju mogućnosti predloženih SVM metoda pozicioniranja pod uslovima koji omogućavaju najveću teritorijalnu dostupnost sistema za pozicioniranje u ovom trenutku, kao i mogućnost korišćenja beneficija takvog sistema od strane većine korisnika. Ipak, potrebno je istaći da se identična metodologija određivanja pozicije mobilnog korisnika može primeniti i u slučaju novijih generacija ćelijskih sistema, poput UMTS i LTE.

- Izvršena je analiza uticaja broja relevantnih ćelija i kvaliteta njihovog signala na tačnost SVR metode pozicioniranja u *outdoor* okruženju. Implementirano je pet SVR modela za pozicioniranje, korišćenjem RSS parametara GSM ili DCS ćelija jednog mobilnog operatora, ili kombinovanjem ta dva sistema. Uočeno je da veliki uticaj na tačnost SVR metode ima broj detektovanih relevantnih ćelija na trenutnoj poziciji mobilnog korisnika, kao i način na koji se tretiraju nepostojeće RSS vrednosti tj. ulazni podaci. Primećeno je da u pojedinim slučajevima, gde je detektovano manje od 3 relevantne ćelije, može doći do relativno velikih grešaka pri estimaciji pozicije. S druge strane, pokazano je da povećanje broja relevantnih ćelija definisanih za neku oblast, pozitivno utiče na smanjenje ovih tipova grešaka. Drugi efekat koji je uočen jeste uticaj kvaliteta radio signala na tačnost pozicioniranja (vrednosti nivoa signala relevantnih ćelija u zoni od interesa i dinamika signala u prostorno bliskim tačkama). S stanovišta kvaliteta radio signala, pozicioniranje na osnovu izmerenih nivoa GSM 900MHz signala pokazalo je bolje performanse nego pozicioniranje na osnovu izmerenih nivoa DCS 1800MHz signala.
- Pokazano je da je primenom principa segmentacije prostora i kombinovanog SVC&SVR modela moguće dalje unaprediti tačnost pozicioniranja, u odnosu na SVR metod. Najveći doprinos primene ovog principa uočen je u domenu smanjenja broja grešaka srednje veličine (tj. *medium-sized* grešaka), na račun porasta broja relativno manjih vrednosti grešaka estimacije. Usled toga primetno je smanjenje vrednosti medijanske greške i 67% DE. Navedeni efekat postaje još izraženiji sa porastom stepena segmentacije. Dodatno, realizovani *multiclass* SVC klasifikator pokazao je dobre performanse sa stanovišta uspešnosti detekcije ispravnog podprostora. Usled toga, tek pri većem stepenu segmentacije prostora, primetan je neznatan porast broja velikih vrednosti grešaka estimacije koje su posledica pogrešno odabranog podprostora.
- Rezultati verifikacije SVR i SVC&SVR metode u realnom *outdoor* okruženju pokazali su da se primenom predloženih metoda može ostvariti tačnost pozicioniranja koja je u skladu sa zahtevima definisanim od strane Federalne komisije za komunikacije (FCC), a da se pri tom ne zahtevaju nikakve izmene

postojeće GSM (DCS) signalizacije, kao ni izmene na mobilnim terminalima. U eksperimentu u kome je broj relevantnih ćelija ograničen na sedam, u skladu sa veličinom standardnog mernog izveštaja podržanog GSM/DCS signalizacijom, primenom SVR metode ostvarena je tačnost od 47.2m|67% i 210m|90%. Primenom SVC&SVR postignuto je dalje unapređenje tačnosti: 31.6m|67% i 192m|90%.

- Izvršena je analiza uticaja istovremenog korišćenja infrastrukture većeg broja mobilnih operatera (Telenor, MTS i VIP), kao i 5 različitih kriterijuma za selekciju relevantnih ćelija. U tu svrhu, implementirano je 20 različitih SVR modela za *indoor* okruženje. Pokazano je da u slučaju selekcije relevantnih ćelija na osnovu verovatnoće njihove radio-vidljivosti u okruženju od interesa, srednja vrednost greške pozicioniranja opada sa povećanjem broja RSS izvora (tj. ublažavanjem zahteva po pitanju verovatnoće radio-vidljivosti), ali samo do određene granice. Nakon dostizanja te granice, korišćenje RSS vrednosti dodatnih radio izvora koji imaju niske i nestabilne nivoe signala, ne doprinosi povećanju tačnosti pozicioniranja, a u pojedinim slučajevima može je i pogoršati. S druge strane, primena kriterijuma koji vrši selekciju ćelija koje imaju relativno visoke nivoe signala u određenom delu posmatranog okruženja (bez obzira na njihovu opštu radio-vidljivost), pokazala je generalno dobre performanse i u slučaju *single-operator* i *multi-operator* SVR modela (Lev-85 kriterijum).
- Pokazano je da se korišćenjem infrastrukture većeg broja mobilnih operatera može postići veća tačnost pozicioniranja, nego u slučaju korišćenja infrastrukture samo jednog operatera. Korišćenje RSS parametara ćelija koje se realizuju sa dodatnih BS lokacija (*BS site-ova*) smanjuje stepen korelisanosti između radio signala koji se koriste za potrebe pozicioniranja. Dodatno, povećava se broj radio izvora koji u posmatranom okruženju mogu obezbediti kvalitetan signal za potrebe estimacije pozicije.
- Kao i u slučaju verifikacije SVC&SVR metode u *outdoor* okruženju, pokazano je da se primenom principa segmentacije prostora može postići unapređenje tačnosti pozicioniranja i u *indoor* okruženju, pogotovo u slučaju

prostora većih dimenzija i kompleksne unutrašnje strukture. Performanse kombinovane SVC&SVR metode ispitivane su za 6 različitih podela prostora. Sa porastom stepena segmentacije uočeno je povećanje verovatnoće pogrešne detekcije podprostora. Međutim, tek pri većem stepenu segmentacije prostora, procenat velikih vrednosti grešaka pozicioniranja postaje blizak onome kod SVR modela. Dobijeni rezultati ukazuju na to da povećanje stepena segmentacije ima smisla samo do određene granice, kada porast broja velikih vrednosti DE, uzrokovan pogrešnom detekcijom podprostora, počinje da umanjuje dobitak ostvaren smanjenjem veličine podprostora za koji se realizuju SVR podmodeli.

- Rezultati verifikacije SVR i SVC&SVR metode u realnom *indoor* okruženju pokazali su da tačnost navedenih metoda zadovoljava FCC zahteve po pitanju horizontalne tačnosti u *indoor* okruženjima. *Multi-operator* SVR model ostvario je srednju i medijansku vrednost greške pozicioniranja od 10.1m i 7.5m, respektivno. Za optimalno odabran broj podprostora u slučaju posmatranog *indoor* okruženja (SVC&SVR_{2x4} model), primenom principa segmentacije prostora srednja greška pozicioniranja je redukovana za 27%, a medijanska za 24%, u odnosu na onu ostvarenu SVR metodom.
- Izvršeno je poređenje performansi nove SVR i SVC&SVR metode sa performansama drugih relevantnih PLMN tehnika iz poglavlja 2, koje su testirane u realnim *outdoor* okruženjima. U cilju verodostojnog poređenja, metode koje su u relevantnim istraživanjima pokazale najbolje performanse, implementirane su takođe i u posmatranom *outdoor* okruženju. Pri identičnim uslovima, SVC&SVR metod je ostvario smanjenje srednje greške pozicioniranja za 9% u odnosu na kNN metod, 58% u odnosu na ANN i 73% u odnosu na SVR metod sa *Sum of Exponential* (SoE) kernel funkcijom.
- Izvršeno je poređenje performansi nove SVR i SVC&SVR metode sa performansama drugih relevantnih PLMN tehnika iz poglavlja 2, koje su testirane u realnim *indoor* okruženjima. Dodatno, definisan je parametar za ocenu relativne tačnosti neke tehnike pozicioniranja uzimanjem u obzir veličine test okruženja u kome su verifikovane njene performanse. U cilju

verodostojnog poređenja, metode koje su u relevantnim istraživanjima pokazale najbolje performanse, implementirane su takođe i u posmatranom *indoor* okruženju. Pri identičnim uslovima, SVC&SVR metod ostvario je smanjenje srednje greške pozicioniranja za 20% u odnosu na kNN metod, odnosno 40% u odnosu na ANN. Dodatno, u istom *indoor* okruženju, predložena PLMN tehnika pozicioniranja ostvarila je tačnost blisku tačnosti WLAN tehnike koja koristi RSS parametre APs instaliranih unutar zgrade.

- Primenom predloženih SVR i SVC&SVR metoda, vreme potrebno za estimaciju prostornih koordinata iznosi manje od sekund, čineći navedene metode pogodnim za realizaciju LBS servisa sa striktnim zahtevima po pitanju kašnjenja.
- Očekivani uticaj predloženih *mobile-assisted network-based* tehnika pozicioniranja na postojeću mrežu operatora i mobilne terminale je neznatan. Predložene tehnike ne zahtevaju nikakve hardverske izmene na strani mobilnih terminala. Izmene na strani mrežne infrastrukture ograničene su na izgradnju određenog broja SMLC (*Service Mobile Location Centre*) centara. Dodatno, iako pozicioniranje korišćenjem većeg broja RSS merenja, od onog podržanog standardnom formom mernog izveštaja, zahteva određene izmene postojeće signalizacije u PLMN mrežama, date izmene ne bi trebalo da imaju veliki uticaj na kapacitet same PLMN mreže.

SVR i SVC&SVR metode predložene u disertaciji, namenjene su određivanju inicijalne pozicije mobilnog korisnika. Daljom nadogradnjom ovih metoda sa nekim od algoritama za praćenje, po svoj prilici, mogle bi se eliminisati velike vrednosti greške pozicioniranja koje odgovaraju nerealnom pomeraju mobilnog korisnika između dve uzastopne estimacije. Dodatno, u slučaju SVC&SVR metode moglo bi se očekivati i smanjenje broja velikih vrednosti grešaka izazvanih pogrešnom estimacijom prostora. Date pretpostavke predstavljaju bazu za buduća istraživanja.

Drugi pravac u budućem istraživanju jeste primena principa logičke segmentacije prostora u cilju definisanja podprostora sa što „homogenijim“ radio-propagacionim uslovima, u slučajevima gde se raspoložuje dodatnim informacijama o okruženju.

Na kraju, konstantan razvoj javnih mobilnih sistema daje mogućnost kombinovanja infrastruktura različitih generacija PLMN mreža za potrebe pozicioniranja. Dodatno, sa povećanjem gustine PLMN mreža kroz implementaciju *micro/pico/nano* ćelija očekuju se još bolji uslovi za definisanje užeg podprostora u kome se korisnik nalazi.

LITERATURA

- [1] Adusei I. K, Kyamakya K, Jobmann K. (2001) Mobile positioning technologies in cellular networks: an evaluation of their performance metrics. *Military Communications Conference - MILCOM 2002*, 1239 – 1244.
- [2] Papoulis A. (1991) *Probability, random variables and stochastic processes*. Polytechnic Institute of New York. McGraw-Hill.Inc.
- [3] Federal Communication Commission. (2001). FCC wireless 911 requirements.
- [4] Federal Communication Commission (2010). Wireless E911 location accuracy requirements. Second report and order.
- [5] Federal Communication Commission (2014). Wireless E911 location accuracy requirements. Third further notice of proposed rule marking.
- [6] Federal Communication Commission (2015). Wireless E911 location accuracy requirements. Fourth report and order.
- [7] Coordination Group on Access to Location Information for Emergency Services (CGALIES) (2002). Report on implementation issues related to access to location information by emergency services (E112) in European Union.
- [8] Electronic Communications Comitee (2014). ECC Report 225. Establishing criteria for the accuracy and reliability of the caller location information in support of Emergency Services.
- [9] European Emergency Number Association – ENNA (2014). Caller location in support of emergency services.
- [10] Nešković A. (2015). Radio komunikacije. Akademska misao.
- [11] Fukunaga K. (1990). *Introduction to statistical pattern recognition*. ACADEMIC PRESS.
- [12] Altman N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46 (3), 175–185.
- [13] Bhatia N, Vandana. (2010). Survey of nearest neighbor techniques. *International Journal of Computer Science and Information Security*, 8, 302-305.
- [14] Hassoun M. H. (1995). *Fundamentals of artificial neural networks*. MIT press.
- [15] Bishop C. M. (2006). *Pattern recognition and machine learning*. Springer Science + Business Media.
- [16] Shawe-Taylor J, Cristianini N. (2004). *Kernel methods for pattern analysis*. Cambridge University Press.
- [17] Margolies R, Becker R, et al (2017). Can you find me now? Evaluation of network-based localization in a 4G LTE network. *IEEE Conference on Computer Communications 2017*.

- [18] Wang B, Chen Q, Yang L, Chao C.H. (2016). Indoor smartphone localization via fingerprint crowdsourcing: challenges and approaches. *IEEE Wireless Communications*, 23(3), 82-90
- [19] Zhang X, Wong A. K. S, Lea C.T, Cheng R.S.K. (2017). Unambiguous association of crowd-sourced radio maps to floor plans for indoor localization. *IEEE Transaction on Mobile Computing*, 17(2), 488 – 502
- [20] Van Diggelen F, Enge P. (2015). The world's first GPS MOOC and worldwide laboratory using smartphones. *28th International Technical Meeting of The Satellite Division of the Institute of Navigation*, 361-369
- [21] Russian System of Differential Correction and Monitoring (SDCM). http://sdc.m.ru/smglo/st_glo?version=eng&reupdate&site=extern
- [22] ETSI TS 143 059 V13.2.0 (2016). Digital cellular telecommunications system (Phase 2+); Functional stage 2 description of Location Services (LCS) in GERAN
- [23] ETSI TS 125 305 V11.0.0 (2012). Universal Mobile Telecommunications System (UMTS); Stage 2 functional specification of User Equipment (UE) positioning in UTRAN
- [24] ETSI TS 136 305 V13.0.0 (2016). Evolved Universal Terrestrial Radio Access Network (E-UTRAN), Stage 2 functional specification of User Equipment (UE) positioning in E- UTRAN
- [25] European Commission – Communications Committee (2017). Implementation of the European emergency number 112 – Results of the tenth data-gathering round.
- [26] Wigren T. (2007). Adaptive enhanced Cell-ID fingerprinting localization by clustering of precise position measurements. *IEEE Transactions on Vehicular Technology*, 56(5), 3199-3209.
- [27] Shi L, Wigren T. (2009). AECID fingerprinting positioning performance. *IEEE GLOBECOM 2009*.
- [28] Wigren T. (2012). Fingerprinting localisation using round trip time and timing advance. *IET Communications*, 6, 419-427.
- [29] Roos T, Myllymäki P, Tirri H. (2002). A statistical modelling approach to location estimation. *IEEE Transactions on Mobile Computing*, 1, 59-69.
- [30] Yamamoto R, Matsutani H, Matsuki H, Oono T, Ohtsuka H. (2001). Position location technologies using signal strength in cellular systems. *53rd IEEE Vehicular Technology Conference*, 2570 – 2574.
- [31] Laitinen H, Lahteenmaki J, Nordstorm T. (2001). Database correlation method for GSM location. *53rd IEEE Vehicular Technology Conference*, 2504-2508
- [32] Lakmali B.D.S, Wijesinghe W.H.M.P, De Silva K.U.M, Liyanagama K.G, Dias S.A.D. (2007). Design, implementation & testing of positioning techniques in mobile networks. *3rd International Conference on Information and Automation for Sustainability*, 94-99
- [33] Hiltunen T, Turkka J, Mondal R, Ristaniemi T (2015). Performance evaluation of LTE radio fingerprint positioning with timing advancing. *10th International Conference on Information, Communications and Signal Processing (ICICS)*.

- [34] Ibrahim M, Youssef M. (2012). CellSense: An accurate energy-efficient GSM positioning system. *IEEE Transactions on Vehicular Technology*, 61 (1), 286 – 296
- [35] Takenga C.M, Wen Q, Kyamakya K. (2006). On the accuracy improvement issues in GSM location fingerprinting. *64th IEEE Vehicular Technology Conference*.
- [36] Borenovic M, Neskovic A, Budimir Dj. (2012). Multi-system-multi-operator localization in PLMN using neural networks. *International Journal of Communication Systems*, 25 (2), 67-83.
- [37] Borenovic M, Neskovic A, Neskovic N. (2013). Vehicle positioning using GSM and cascade-connected ANN structures. *IEEE Transactions on Intelligent Transportation Systems*, 14(1), 34-46.
- [38] Xuereb D, Debono C.J. (2010). Mobile terminal location estimation using Support Vector Machines. *4th International Symposium on Communications, Control and Signal Processing*.
- [39] Sun G, Guo W. (2005). Robust mobile geo-location algorithm based on LS-SVM. *IEEE Transactions on Vehicular Technology*, 54, 1037-1041
- [40] Jiyan H, Guan G, Qun W. (2011). Robust location algorithm based on weighted least-squares Support Vector Machine (WLS-SVM) for non-line-of-sight environments. *International Journal of the Physical Sciences*, 6, 5897-5905
- [41] Wu Z, Li C, Ng J.K, Leung K.R.P.H. (2007). Location estimation via Support Vector Regression. *IEEE Transactions on Mobile Computing*, 6, 311-321.
- [42] Zaidi R.Z, Mark L.B. (2005). Real-time mobility tracking algorithms for cellular networks based on Kalman filtering. *IEEE Transactions on Mobile Computing*, 4, 195-208.
- [43] Driusso M, Marshall C, et al (2017). Vehicular position tracking using LTE signals. *IEEE Transactions on Vehicular Technology*, 66 (4), 3376 – 3391
- [44] Pittino F, Driusso M, Torre A.D, Marshall C. (2017). Outdoor and indoor experiments with localization using LTE signals. *2017 European Navigation Conference (ENC)*, 311-321
- [45] Ni L, Wang Y, et al (2017). Accurate localization using LTE signalling data. *2017 IEEE International Conference on Computer and Information Technology*, 268-273
- [46] Gu Y, Lo A, Niemegeers I. (2009). A survey of indoor positioning systems for wireless personal networks. *IEEE Communication Surveys and Tutorials*, 11(1), 13 – 32
- [47] Davidson P, Piché R. (2017) A Survey of selected indoor positioning methods for smartphones. *IEEE Communication Surveys and Tutorials*, 19 (2), 1347 – 1370
- [48] Yassin A, Nasser Y, Awad M., et al (2017) Recent advances in indoor localization: A survey on theoretical approaches and applications. *IEEE Communication Surveys and Tutorials*, 19 (2), 1327 – 1346

- [49] He S, Chan S.H.G. (2016) Wi-Fi fingerprint-based indoor positioning: Recent advances and comparisons. *IEEE Communication Surveys and Tutorials*, 18 (1), 466 - 490
- [50] Youssef M, Agrawala A. (2005) The Horus WLAN location determination System. *International Conference on Mobile Systems, Applications And Services*, 205–218
- [51] Madigan D, Einahrawy E, Martin R. P, Ju W.H, Krishnan P, Krishnakumar A. (2005) Bayesian indoor positioning systems. *IEEE 24th Annual Joint Conference of the IEEE Computer and Communications Societies*, 1217–1227.
- [52] Bahl P, Padmanabhan V. N. (2000) RADAR: An in-building RF-based user location and tracking system. *IEEE INFOCOM 2000*, 775–784.
- [53] He S, Chan S. H. G. (2016) Tilejunction: Mitigating signal noise for fingerprint-based indoor localization. *IEEE Transaction on Mobile Computing*, 15(6), 1554 - 1568
- [54] Borenovic M, Neskovic A. (2009). Positioning in WLAN environment by use of artificial neural networks and space partitioning. *Annals of Telecommunications*, 64, 665-676
- [55] Lu X, Zou H, Zhou H, Xie L, Huang, G.B. (2016) Robust extreme learning machine with its application to indoor positioning. *IEEE Transaction on Cybernetics*, 46(1), 194 - 205.
- [56] Cavallini A. (Gaia-Matrix) (2013) iBeacons Bible 1.0. Dostupno na: <http://meetingofideas.files.wordpress.com/2013/12/ibeacons-bible-1-0.pdf>
- [57] Faragher R, Harle R. (2014) An analysis of the accuracy of Bluetooth low energy for indoor positioning applications. *27th International Technical Meeting of The Satellite Division of the Institute of Navigation*, 201–210.
- [58] Frost C, Jensen C. S, Luckow K. S, Thomsen B, Hansen R. (2012) Bluetooth indoor positioning system using fingerprinting. *Mobile Lightweight Wireless Systems*, 81, 136–150
- [59] Seco F, Plagemann C, Jimenez A. R, Burgard W. (2010) Improving RFID-based indoor positioning accuracy using Gaussian processes. *International Conference on Indoor Positioning and Indoor Navigation 2010*.
- [60] Hightower J, Borriello G. (2000). SpotON: An indoor 3D location sensing technology based on RF signal strength. UW CSE Technical Report #2000-02-02, University of Washington, Department of Computer Science and Engineering.
- [61] Ni L. M, Liu Y, Lau Y. C, Patil A. P. (2004) LANDMARC: Indoor location sensing using active RFID. *Wireless Networks*, 10 (6), 701–710
- [62] Sahinoglu Z, Gezici S, Güvenc I. (2011). *Ultra-wideband positioning systems: Theoretical limits, ranging algorithms and protocols*. Cambridge University Press.
- [63] Ubisense Real-time Location System. Dostupno online: <http://www.ubisense.net/en/>
- [64] Time Domain's PulsON® module. Dostupno online: <http://www.timedomain.com/>
- [65] Varshavsky A, De Lara E, Hightower J, LaMarca A, Otsason V. (2007) GSM indoor localization. *Pervasive and Mobile Computing*, 3(6), 698–720.

- [66] Blum A, Langley P. (1997) Selection of relevant features and examples in machine learning. *Journal on Artificial Intelligence*, 97(1-2), 245-271.
- [67] Lakmali B.D.S, Dias D. (2008) Database correlation for GSM location in outdoor & indoor environments. *International Conference on Information and Automation for Sustainability 2008*, 42-47.
- [68] Birkel U, Weber M. (2012) Indoor localization with UMTS compared to WLAN. *International Conference on Indoor Positioning and Indoor Navigation (IPIN) 2012*.
- [69] Machaj J, Brida P, Benikovsky J. (2014) Using GSM signals for fingerprint-based indoor positioning system. *ELEKTRO 2014*, 64-67.
- [70] Machaj J, Brida P. (2017) Impact of optimization algorithms on hybrid indoor positioning based on GSM and Wi-Fi signals. *Concurrency and Computation: Practice and Experience*, 29(23), DOI: 10.1002/cpe.3911
- [71] Stella M, Russo M, Begusic D. (2013) GSM-based approach for indoor localization. *International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering*, 7, 374-378
- [72] Ahriz I, Oussar Y, Denby B, Dreyfus G. (2010) Full-band GSM fingerprints for indoor localization using a machine learning approach. *International Journal of Navigation and Observation*. <http://dx.doi.org/10.1155/2010/497829>
- [73] Oussar Y, Ahriz I, Denby B, Dreyfus G. (2011) Indoor localization based on cellular telephony RSSI fingerprints containing very large numbers of carriers. *EURASIP Journal on Wireless Communications and Networking*. <https://doi.org/10.1186/1687-1499-2011-81>
- [74] Tian Y, Denby B, Ahriz I, Roussel P, Dreyfus G. (2015) Robust indoor localization and tracking using GSM fingerprints. *EURASIP Journal on Wireless Communications and Networking*. <https://doi.org/10.1186/s13638-015-0401-7>
- [75] Joachim T. (1999) *Transductive inference for text classification using support vector machines*. *International Conference on Machine Learning (ICML)*, 200–209
- [76] Driusso M, Marshall C, et al (2016). Indoor Positioning Using LTE Signals. *International Conference on Indoor Positioning and Indoor Navigation (IPIN) 2016*.
- [77] Vapnik V. (1999) An overview of statistical learning theory. *IEEE Transaction On Neural Networks*, 10(5), 988-999
- [78] Burges C. (1998). A tutorial on Support Vector Machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121-167.
- [79] Vapnik V, Chervonenkis A. (1971). On the uniform convergence of relative frequencies of events to their probabilities. *Theory of Probability and its Applications*, 16(2), 264–281.
- [80] Vapnik V, Lerner A. 1963. Pattern recognition using generalized portrait method. *Automation and Remote Control*, 24, 774–780.
- [81] Vapnik V, Chervonenkis A. (1964). A note on one class of perceptrons. *Automation and Remote Control*, 25, 774–780.
- [82] Cortes C, Vapnik V. (1995) Support vector networks. *Machine Learning*, 20, 273–297.

- [83] Scholkopf B, Burges C, Vapnik V. (1995). Extracting support data for a given task. *First International Conference on Knowledge Discovery & Data Mining*.
- [84] Scholkopf B, Burges C, Vapnik V. (1996). Incorporating invariances in support vector learning machines. *Artificial Neural Networks ICANN'96*, 47–52.
- [85] Vapnik V, Golowich S, Smola A. Support vector method for function approximation, regression estimation, and signal processing. *Advances in Neural Information Processing Systems*, 9, 281–287.
- [86] Hsu C.W, Lin C.J. (2002). A comparison of methods for multiclass Support Vector Machines. *IEEE Transactions on Neural Networks*, 13, 415–425.
- [87] Rifkin R, Klautau A. (2004). In defence of one-vs.-all classification. *Journal of Machine Learning Research*, 5, 101–141.
- [88] Boyd S, Vandenberghe L. (2004) *Convex Optimization*. Cambridge University Press.
- [89] Smola A, Scholkopf B. (2004). A tutorial on Support Vector Regression. *Statistics and Computing*, 14, 199–222.
- [90] Pérez-Cruz F, Camps-Valls G, Soria-Olivas E, Pérez-Ruixo J, Figueiras-Vidal A, Artés-Rodríguez A. (2002). Multi-dimensional function approximation and regression estimation. *International Conference on Artificial Neural Networks 2002*, 757–762.
- [91] Vapnik V. (1995) *The Nature of Statistical Learning Theory*. New York: Springer-Verlag.
- [92] 3GPP TS 45.008 V14.1.0 (2017). 3rd Generation Partnership Project; Technical Specification Group Radio Access Network; GSM/EDGE Radio subsystem link control.
- [93] ETSI TS 125 133 V11.9.0 (2014). Universal Mobile Telecommunications System (UMTS); Requirements for support of radio resource management (FDD).
- [94] 3GPP TS 36.133 V11.15.0 (2016). 3rd Generation Partnership Project; Technical Specification Group Radio Access Network; Evolved Universal Terrestrial Radio Access (E-UTRA); Requirements for support of radio resource management.
- [95] ETSI TS 144 018 V13.1.0 (2016). Mobile radio interface layer 3 specification; Radio Resource Control (RRC) protocol.
- [96] Ramiro J, Hamied K. (2011). *Self-Organizing Networks (SON): Self-planning, self-optimization and self-healing for GSM, UMTS and LTE*. Wiley. ISBN: 978-0-470-97352-3.
- [97] ETSI TS 136 300 V13.2.0 (2016). Evolved Universal Terrestrial Radio Access (E-UTRA) and Evolved Universal Terrestrial Radio Access Network (E-UTRAN); Overall description.
- [98] Ericsson (2011). User Description, GSM-UMTS-LTE cell reselection and handover.
- [99] Sun G, Chen J, Guo W, Liu K.J.R. (2005). Signal processing techniques in network-aided positioning. *IEEE Signal Processing Magazine*, 22, 12–23

- [100] Kushki A, Plataniotis K. N, Venetsanopoulos A.N. (2007). Kernel-based positioning in Wireless Local Area Networks. *IEEE Transaction on Mobile Computing*, 6 (6), 689-705.
- [101] Takenga C, Kyamakya K. (2007). A low-cost fingerprint positioning system in cellular networks. *CHINACOM 2007*, 915-920
- [102] Petrić M, Nešković A, Nešković N, Borenović M. (2014). SVM-based Models for Mobile Users' Initial Position Determination. *Journal of Navigation*, 67, 950-966.
- [103] Petrić M, Nešković A, Nešković N, Borenović M. (2013) RSS-based SVR models for GSM and DCS mobile users' localization. *EUROCON 2013*, 591-596.
- [104] R&S Coverage Measurement System - Operating Manual version 4.11. Rohde and Schwarz Test and Measurement.
- [105] Nicolas P. R. (2014). *Scala for machine learning*. Packt publishing.
- [106] Bertoni H.L. (1999). *Radio propagation for modern wireless systems*. Prentice Hall Professional Technical Reference.
- [107] Bottou L, Lin C.J. (2007). Support Vector Machine solvers. *Large-scale kernel machines*, MIT Press.
- [108] Platt J.C, (1999). Fast training of Support Vector Machines using sequential minimal optimization. *Advances in Kernel Methods: Support Vector Machines*, MIT Press.
- [109] Dong J, Krzyzak A, Suen, C.Y. (2005). Fast SVM training algorithm with decomposition on very large data sets. *IEEE Transactions on Pattern Analysis and Machine Learning*, 27, 603 – 618.
- [110] Shang Y, Wah W.B. (1996) Global optimization for neural network training. *Computer*, 29(3), 45–55.
- [111] Petrić M, Nešković A, Nešković N. (2015). Dynamic k Nearest Neighbours model for mobile user indoor positioning. *TELFOR 2015*, 165-168.
- [112] Petrić M, Nešković A, Nešković N. (2016). Realizacija i poređenje performansi modela za indoor pozicioniranje mobilnih GSM korisnika zasnovanih na kNN i ANN algoritmu. *Infoteh-Jahorina 2016*, 210-214.
- [113] Gaboune B, Laporte G, Soumis F. (1993) Expected distances between two uniformly distributed random points in rectangles and rectangular parallelepipeds, *Journal of the Operational Research Society*, 44(5), 513–519.

BIOGRAFIJA

Majda Petrić rođena je 20. oktobra 1986. godine u Beogradu. Devetu beogradsku gimnaziju „Mihajlo Petrović Alas“ završila je 2005. godine kao nosilac diplome „Vuk Stefanović Karadžić“. Osnovne studije na Elektrotehničkom fakultetu u Beogradu upisala je 2005. godine. Odsek za telekomunikacije i informacione tehnologije, smer Radio komunikacije, završila je 2009. godine sa prosečnom ocenom 9.62 i ocenom 10 za Diplomski rad na temu „Tehnike rutiranja u kognitivnim radio mrežama“. Diplomске – akademske master studije na Elektrotehničkom fakultetu, modul Sistemsko inženjerstvo i radio komunikacije, upisala je 2009. godine i završila ih u decembru 2010. godine sa prosečnom ocenom 10. Na osnovu master rada na temu „Analiza kvaliteta rada primopredajnika mobilnih GSM terminala korišćenjem mernog uređaja Rohde&Schwarz CMU200“ formirana je laboratorijska vežba za predmet Radio tehnika.

Doktorske studije na Elektrotehničkom fakultetu u Beogradu, modul Telekomunikacije, upisala je 2011. godine gde je položila sve ispite sa prosečnom ocenom 10.

Od juna 2009. godine radila je u Laboratoriji za radio komunikacije, na Katedri za telekomunikacije, kao saradnik na projektima procene uticaja elektromagnetnog zračenja baznih stanica mobilne telefonije na životnu sredinu. Kao student doktorskih studija i stipendista Ministarstva prosvete, nauke i tehnološkog razvoja, bila je angažovana na projektu TP-32051 „Razvoj i realizacija naredne generacije sistema, uređaja i softvera na bazi softverskog radija za radio i radarske mreže“ (2012 – 2013). Majda Petrić je kao student doktorskih studija bila angažovana u izvođenju laboratorijskih vežbi u okviru Laboratorije za radio komunikacije, na Katedri za telekomunikacije.

Majda Petrić je bila zaposlena kao asistent na Katedri za telekomunikacije na Elektrotehničkom fakultetu u Beogradu od februara 2013. do oktobra 2016. Bila je angažovana na računskim i laboratorijskim vežbama iz predmeta Radio komunikacije, Usmerene radio veze i Radio tehnika, kao i na laboratorijskim vežbama iz predmeta: Radio sistemi, Javni mobilni sistemi, Telekomunikacioni sistemi, Bežične mreže, Telekomunikacije 1 i Telekomunikacije 3. U toku rada na Fakultetu, učestvovala je na nekoliko projekata, između ostalog: veći broj studija o proceni i stručnih ocena uticaja GSM/UMTS/LTE baznih stanica na životnu sredinu (TELEKOM SRBIJA 2009-2016), projekat Ministarstva prosvete, nauke i tehnološkog razvoja TP-32051 „Razvoj i realizacija naredne generacije sistema, uređaja i softvera na bazi softverskog radija za radio i radarske mreže“ (2012-2013), projekat „Analiza međusobnog uticaja sekundarnog radara za nadzor vazdušnog saobraćaja i postojećih/planiranih radio-sistema na lokaciji Besna kobilica“ (Kontrola letenja Srbije i Crne Gore, 2015), projekat „Analiza međusobnog uticaja primarnog radara za nadzor vazdušnog saobraćaja i postojećih/planiranih radio-sistema na lokaciji Besna kobilica“ (Kontrola letenja Srbije i Crne Gore, 2016), Studija eksploatacije telekomunikacione mreže EMS-a (JP Elektromreže Srbije, 2015). Tokom 2014. godine učestvovala je u programu FP7 FET EYE za mlade istraživače (*Future and Emerging Technologies – Empowering Young Researchers*).

Majda Petrić je autor/koautor dva rada u naučnim časopisima međunarodnog značaja sa SCI liste, jedan kategorije M21 i jedan kategorije M22, kao i jednog rada u domaćem časopisu. Autor/koautor je tri rada u zbornicima međunarodnih naučnih skupova, kao i osam radova u zbornicima skupova nacionalnog značaja.

Прилог 1.

Изјава о ауторству

Потписани-а Мајда А. Петрић

број индекса 2011/5015

Изјављујем

да је докторска дисертација под насловом

Одређивање позиције мобилних корисника у јавним мобилним системима
коришћењем метода заснованих на Support Vector Machine алгоритмима

- резултат сопственог истраживачког рада,
- да предложена дисертација у целини ни у деловима није била предложена за добијање било које дипломе према студијским програмима других високошколских установа,
- да су резултати коректно наведени и
- да нисам кршио/ла ауторска права и користио интелектуалну својину других лица.

Потпис докторанда

У Београду, 12.03.2018

Мајда Петрић

Прилог 2.

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора Мајда А. Петрић

Број индекса 2011/5015

Студијски програм Телекомуникације

Наслов рада Одређивање позиције мобилних корисника у јавним мобилним системима коришћењем метода заснованих на Support Vector Machine алгоритмима

Ментор др Александар Нешковић, редовни професор

Потписани/а Мајда А. Петрић


Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла за објављивање на порталу **Дигиталног репозиторијума Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис докторанда

У Београду, 12.03.2018.



Прилог 3.

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Одређивање позиције мобилних корисника у јавним мобилним системима коришћењем метода заснованих на Support Vector Machine алгоритмима

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигитални репозиторијум Универзитета у Београду могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство

2. Ауторство - некомерцијално

3. Ауторство – некомерцијално – без прераде

4. Ауторство – некомерцијално – делити под истим условима

5. Ауторство – без прераде

6. Ауторство – делити под истим условима

(Молимо да заокружите само једну од шест понуђених лиценци, кратак опис лиценци дат је на полеђини листа).

Потпис докторанда

У Београду, 12.03.2018.

Олига Петровић

1. **Ауторство** - Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.

2. **Ауторство – некомерцијално.** Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.

3. **Ауторство - некомерцијално – без прераде.** Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.

4. **Ауторство - некомерцијално – делити под истим условима.** Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.

5. **Ауторство – без прераде.** Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.

6. **Ауторство - делити под истим условима.** Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.