

Realizacija i poređenje performansi modela za *indoor* pozicioniranje mobilnih GSM korisnika zasnovanih na kNN i ANN algoritmu

Majda Petrić, Aleksandar Nešković, Nataša Nešković
 Elektrotehnički fakultet Univezriteta u Beogradu
 Beograd, Republika Srbija
 majdap@etf.rs, neshko@etf.rs, natasha@etf.rs

Sadržaj — U okviru rada predstavljena su dva modela za određivanje pozicije mobilnog korisnika u zatvorenom prostoru, bazirana na metodi k najbližih suseda (*k Nearest Neighbours*, kNN) i veštačkoj neuralnoj mreži (*Artificial Neural Networks*, ANN). Oba predložena modela se zasnivaju na korišćenju infrastrukture široko rasprostranjenih GSM mreža. Realizacija i ispitivanje tačnosti predloženih modela za pozicioniranje izvršeni su korišćenjem realnih podataka prikupljenih tokom merne kampanje sprovedene u okviru zgrade Elektrotehničkog fakulteta u Beogradu. kNN modelom postignuta je medijanska vrednost greške pozicioniranja od 4.5m, dok je ANN model pokazao bolje performanse sa stanovišta redukcije velikih vrednosti grešaka pozicioniranja.

Ključne riječi – *indoor pozicioniranje; GSM; fingerprinting; kNN; ANN.*

I. UVOD

Tokom proteklih nekoliko godina, zabeležen je izrazit rast broja LBS servisa (*Location-based Services*) [1], koji koriste informaciju o trenutnoj poziciji korisnika. Prateći dati trend, zahtevi po pitanju tačnosti (tj. vrednosti greške pozicioniranja), dostupnosti, kašnjenja i cene implementacije savremenih sistema za pozicioniranje, postaju sve strožiji.

Najčešće korišćeni sistemi za pozicioniranje, poput GPS sistema (*Global Positioning System*), zasnivaju se na korišćenju infrastrukture satelitskih sistema. Iako omogućavaju veliku tačnost pozicioniranja u *outdoor* okruženjima, u *indoor* okruženjima se susreću sa ozbiljnim ograničenjima koja onemogućavaju njihovu upotrebu u zatvorenom prostoru. Usled toga, tokom proteklih godina, kao alternativna rešenja za pozicioniranje u zatvorenom prostoru predložene su različite tehnike koja se zasnivaju na korišćenju radio tehnologija srednjeg i malog dometa, poput WLAN (*Wireless Local Area Networks*), Zigbee, UWB (*Ultra-wideband*), RFID (*Radio-frequency identification*), *Bluetooth*, kao i tehnologija na bazi infrared i ultrazvučnih talasa [2-3]. Naročito su tehnike zasnovane na korišćenju WLAN mreža bile intenzivno istraživane [4-7]. Međutim, glavni nedostatak prethodno navedenih pristupa jeste neophodnost

implementacije dodatnih infrastrukturnih elemenata u *indoor* okruženja od interesa. Usled toga, novi pristup *indoor* pozicioniranju, koji se zasniva na korišćenju infrastrukture sveprisutnih javnih mobilnih mreža (*Public Land Mobile Networks*, PLMNs), postaje sve popularniji. Korišćenjem infrastrukture postojećih javnih mobilnih mreža podržano je pozicioniranje mobilnih korisnika i u *outdoor* i *indoor* okruženju. Dodatno, zone pokrivanja PLMN mreža značajno prevazilaze zone pokrivanja WLAN mreža, čime je moguće obezbediti veću dostupnost sistema za pozicioniranje, a mobilnim (korisničkim) terminalima nisu neophodni dodatni radio-interfejsi za potrebe pozicioniranja, čime se smanjuje i cena sistema.

U okviru ovog rada predstavljena su dva modela za određivanje inicijalne pozicije mobilnog korisnika u zatvorenom prostoru, na osnovu nivoa signala (*Received Signal Strength*, RSS) GSM baznih stanica koje mobilni terminal izmeri na svojoj trenutnoj lokaciji. Iako je za potrebe razvoja oba modela za pozicioniranje korišćena infrastruktura GSM mreže, predstavljene metodologije mogu se primeniti i u slučaju drugih savremenih PLMN mreža, poput UMTS (*Universal Mobile Telecommunications System*) i LTE (*Long Term Evolution*) mreže. Naime, proces merenja nivoa signala okolnih baznih stanica i slanja izveštaja sa izmerenim RSS vrednostima predstavlja standardnu proceduru u svim savremenim PLMN mrežama.

Određivanje lokacije u prostoru na osnovu izmerenih RSS vrednosti predstavlja izrazito složen zadatak, pogotovo u slučaju kompleksnih *indoor* okruženja u kojima dolazi do pojave niza različitih radio-propagacionih efekata. Ovi efekti su posebno izraženi u slučaju kada se radio izvori (tj. bazne stanice, BS) nalaze izvan razmatranog objekta, što je najčešće slučaj u PLMN mrežama. Iz tog razloga, u radu je primenjen jedan od najčešće korišćenih pristupa kod *indoor* pozicioniranja, koji se sastoji iz kreiranja prostorne mape izmerenih radio signala (tzv. radio mape) za *indoor* okruženje od interesa i primene neke od *fingerprinting* tehnika [2-3]. Konkretno, razmatrane su dve *fingerprinting* tehnike: metod k

najbližih suseda (*k Nearest Neighbours*, kNN) [8-9] i veštačke neuralne mreže (*Artificial Neural Networks*, ANN) [10].

kNN metod važi za najjednostavniju *fingerprinting* tehniku sa stanovišta implementacije jer ne zahteva prethodno treniranje modela. S druge strane, ANN mreže, koje se smatraju i optimizacionom tehnikom, poznate su po dobrim rezultatima pri rešavanju nelinearnih problema [10]. Primene kNN i ANN algoritma za potrebe *indoor* pozicioniranja mobilnih korisnika PLMN mreža, razmatrane su u okviru [11-13] i [14], respektivno. Međutim, razmatrani kNN i ANN modeli implementirani su na *indoor* okruženjima različitih struktura, veličina i sa različitim gustinom mernih tačaka, što onemogućava ravnopravno poređenje njihovih performansi. U cilju omogućavanja adekvatnog poređenja postignute tačnosti pozicioniranja ova dva pristupa, u okviru ovog rada izvršena je implementacija kNN i ANN modela za isto *indoor* okruženje, tačnije za slučaj prizemlja zgrade Elektrotehničkog fakulteta u Beogradu. Pritom, korišćena je infrastruktura svih raspoloživih GSM mreža u okruženju: MTS, VIP i Telenor.

Opšti pregled metode *k* najbližih suseda i veštačkih neuralnih mreža dat je u drugom poglavlju. Praktična realizacija kNN i ANN modela za pozicioniranje opisana je u trećem poglavlju, dok su analiza i poređenje rezultata dobijenih verifikacijom predloženih modela dati u četvrtom poglavlju. Zaključak je iznet u petom poglavlju.

II. FINGERPRINTING TEHNIKE: KNN I ANN

Fingerprinting predstavlja najčešće korišćen metod kod *indoor* pozicioniranja [2], jer ne zahteva LOS (*Line of Sight*) uslove propagacije radio talasa, kao ni modelovanje specifičnih radio-propagacionih efekata koji se mogu javiti u nekom *indoor* okruženju. *Fingerprinting* tehnike se sastoje iz dve faze: *offline* i *online*.

Offline faza podrazumeva kreiranje radio mape nekog prostora merenjem odabranih parametara radio signala u određenom broju mernih (referentnih) tačaka. Parametri radio signala izmerenih u nekoj referentnoj tački, formiraju *fingerprint* (tj. „otisak“) tačke i zajedno sa njenim koordinatama dodaju se u bazu *fingerprint*-a. Za potrebe *indoor* pozicioniranja, *fingerprint*-i se najčešće formiraju merenjem nivoa radio signala tj. RSS vrednosti. Izgled *fingerprint*-a formiranog u *i*-toj referentnoj tački prikazan je u jednačini (1), dok je izgled jednog elementa *fingerprint* baze (sa dodeljenim *x* i *y* koordinatama) dat u okviru jednačine (2):

$$\overline{RSS}_i = [RSS_{i,1}, RSS_{i,2} \dots RSS_{i,n}], \quad (1)$$

$$\overline{RSS}_{DBi} = [x_i, y_i | RSS_{i,1}, RSS_{i,2} \dots RSS_{i,n}]. \quad (2)$$

Element $RSS_{i,j}$ predstavlja RSS vrednost koja potiče od *j*-tog radio izvora (BS), a koja je izmerena u *i*-toj referentnoj tački. Parametar *n* predstavlja ukupan broj radio izvora detektovanih u okviru razmatranog *indoor* okruženja.

U opštem slučaju, *offline* faza obuhvata i proces treniranja modela, tokom koga model, koristeći podatke iz *fingerprint*

baze, „uči“ nelinearnu relaciju koja postoji između poznatih skupova ulaznih podataka (RSS vrednosti) i izlaznih podataka (prostornih koordinata).

U okviru *online* faze, model za pozicioniranje koristi prethodno naučenu relaciju da estimira nepoznate prostorne koordinate, na osnovu RSS vrednosti izmerenih na trenutnoj lokaciji mobilnog korisnika.

A. Metod *k* najbližih suseda - kNN

Osnovna prednost kNN algoritma jeste u tome što osim formiranja *fingerprint* baze, ne zahteva prethodno treniranje modela, što ga čini jednostavnim za implementiranje.

Online faza kNN metode podrazumeva formiranje *fingerprint*-a sa RSS vrednostima izmerenim na nepoznatoj lokaciji korisnika korišćenjem jednačine (1) i poređenje datog *fingerprint*-a sa svim ostalim elementima iz *fingerprint* baze. kNN algoritam nalazi *k* najbližih suseda, odnosno *k* elemenata baze koji su najbliži *fingerprint*-u uzetom na nepoznatoj lokaciji korisnika. Sličnost dva *fingerprint*-a u domenu radio signala, tj. „rastojanje“ između dva *fingerprint*-a, mogu se proračunati korišćenjem različitih metrika. U okviru ovog rada, kao metrika korišćeno je Euklidsko rastojanje:

$$L_{m,i} = \sqrt{\left(\sum_{j=1}^n |RSS_{m,j} - RSS_{DBi,j}|^2 \right)}, \quad (3)$$

gde $L_{m,i}$ je rastojanje između *fingerprint*-a formiranog na nepoznatoj poziciji korisnika (označenom sa *m*) i *i*-tog elementa iz *fingerprint* baze. Nakon nalaženja *k* najboljih poklapanja u bazi, trenutna pozicija mobilnog korisnika dobija se usrednjavanjem koordinata *k* odabranih suseda:

$$x_m = \frac{\sum_{i=1}^k x_i}{k}, \quad y_m = \frac{\sum_{i=1}^k y_i}{k}. \quad (4)$$

Iako kNN algoritam ne zahteva učenje nelinearne relacije koja postoji između izmerenih RSS vrednosti i prostornih koordinata, pre *online* faze neophodno je odrediti optimalnu vrednost parametra *k*. Odabir optimalne vrednosti *k* vrši se testiranjem modela za različite vrednosti *k* na nezavisnom podskupu elemenata iz *fingerprint* baze, a za optimalnu vrednost uzima se ona koja obezbeđuje minimalnu srednju vrednost greške pozicioniranja na izdvojenom test skupu.

B. Veštačke neuralne mreže - ANN

ANN mreže se mogu definisati kao strukture za procesiranje informacija, koje se sastoje iz određenog broja međusobno povezanih elemenata za procesiranje (neurona ili perceptrona) koji rade zajedno na rešavanju određenog problema. ANN mreže pripadaju grupi optimizacionih algoritama za pronalaženje opštih relacija u skupovima podataka i poznate su po dobrim rezultatima pri rešavanju različitih nelinearnih problema [10].

Sa stanovišta problema pozicioniranja, ANN mreže mogu se svrstati u *fingerprint* tehnike. U okviru *offline* faze, tj. procesa treniranja, ANN mreže „uče“ relaciju koja postoji između izmerenih RSS vrednosti i prostornih koordinata, koristeći elemente *fingerprint* baze kao primere za učenje. Kreiranje i treniranje neuralne mreže je dosta složen proces koji podrazumeva određivanje strukture neuralne mreže (tip strukture, broj slojeva, broj neurona po slojevima, itd), odabir trening funkcije i njenih parametara, odabir transfer funkcija neurona, definisanje kriterijuma za optimalno istreniranu mrežu, itd.

Nakon završenog procesa učenja, u *online* fazi, istrenirana ANN mreža koristi kao ulazne podatke RSS vrednosti izmerene na trenutnoj poziciji mobilnog korisnika, kako bi izvršila estimaciju njegovih prostornih koordinata. I pored relativno zahtevnog procesa treniranja, ANN mreže karakteriše brza *online* faza, što ih čini pogodnim za korišćenje u slučaju *real-time* aplikacija, kao što je pozicioniranje mobilnih korisnika.

III. REALIZACIJA MODELA ZA INDOOR POZICIONIRANJE

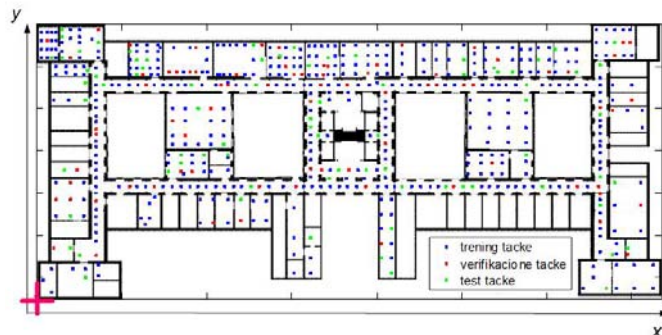
Modeli za *indoor* pozicioniranje, predloženi u ovom radu, realizovani su za nivo prizemlja zgrade Elektrotehničkog fakulteta u Beogradu, dimenzija 147 m x 66 m. Razmatrano *indoor* okruženje čini oko 80 manjih celina: učionice, amfiteatri, kancelarije i dugački hodnici, kao i 4 atrijuma koja se nalaze u centralnom delu objekta (Sl. 1). Odabrano *indoor* okruženje ispunjava osnovne uslove u vidu dovoljno velikih dimenzija i kompleksne unutrašnje strukture sa različitim tipovima prostorija, kako bi tačnost pozicioniranja predloženih modela mogla biti u potpunosti ispitana i pri složenim radio-propagacionim efektima.

A. Prikupljanje podataka i formiranje fingerprint baze

Za prikupljanje RSS vrednosti u posmatranom *indoor* okruženju korišćen je mrežni skener *Radio Network Analyzer Rohde&Schwarz TSMQ* (R&S[®]TSMQ). R&S[®]TSMQ ima mogućnost skeniranja celokunog GSM 900 MHz i GSM 1800 MHz opsega, kao i dekodovanja sistemskih informacija tipa 1, 2, 3 i 4 sa BCCH (*Broadcast Control Channel*) kanala. Preuzimanje izmerenih RSS vrednosti ostvareno je korišćenjem laptopa opremljenog „R&S Romes v4“ soferom. Merenje je izvršeno u 581 tački. Pri tom, detektovano je 175 BCCH kanala, koji pripadaju GSM ćelijama tri mobilna operatora u Srbiji: MTS, Telenor i VIP. Usled nedostupnosti GPS-a, prostorne koordinate mernih tačaka određene su ručno, korišćenjem laserskog daljinomera. Za svaku mernu tačku, njene x i y koordinate definisane su relativno u odnosu na poziciju referentne tačke, označene sa „+“ na Sl. 1.

Po uzoru na jednačinu (2), za svaku tačku kreiran je element u *fingerprint* bazi koji se sastoji iz (x,y) koordinata i RSS vrednosti (RxLev parametara) izmerenih na 175 BCCH kanala. Usled različitih radio-propagacionih uslova, nije bilo moguće detektovati svih 175 GSM ćelija u svakoj mernoj tački. Stoga,

na mesto nepostojećih RSS vrednosti u nekom *fingerprint*-u, koje pripadaju GSM ćelijama koje nisu detektovane u posmatranoj mernoj tački, uneta je vrednost praga od -110dBm. Na kraju, *fingerprint* baza je podeljena na tri nezavisna skupa: trening (referentni), test i verifikacioni skup, formiranih od 70%, 15% i 15% slučajno odabranih mernih tačaka, respektivno (Sl. 1).



Slika1. Prizemlje zgrade Elektrotehničkog fakulteta sa mernim tačkama.

B. Realizacija kNN modela

kNN model je imlementiran u MATLAB okruženju, koristeći algoritam opisan u Poglavlju II.

Performanse kNN modela su testirane za različite vrednosti parametra k (od 1 do 10), sa ciljem pronalaženja vrednosti koja će rezultovati najmanjom srednjom greškom pozicioniranja na prethodno izdvojenom test skupu. Greška pozicioniranja (*distance error*, DE) definisana je kao Euklidsko rastojanje između stvarne i estimirane pozicije tačke iz test skupa. Za korišćeni test skup, najbolje performanse kNN modela dobijene su za vrednost $k=1$. Performanse kNN modela su potom verifikovane koristeći nezavisan verifikacioni skup tačaka, a rezultati su dati u Poglavlju IV.


C. Realizacija ANN modela

ANN model je imlementiran u MATLAB okruženju, koristeći *Neural Networks Toolbox*.

Uzimajući u obzir prirodu problema, odabrana je *multilayer feedforward* neuralna mreža sa propagacijom greške unazad (*error backpropagation*) [10]. Broj ulaza neuralne mreže odgovara broju RSS vrednosti u *fingerprint*-u (175), dok izlaz modela predstavlja x i y koordinate. Pored ulaznog i izlaznog sloja, *multilayer feedforward* neuralna mreža može imati jedan ili više skrivenih (*hidden*) slojeva sa proizvoljnim brojem neurona. Kako ne postoji egzaktna analitička metoda za određivanje unutrašnje strukture neuralne mreže, u radu je korišćen pristup da prvi skriveni sloj ima više neurona nego što postoji ulaza u ANN mrežu, kako bi se omogućilo raščlanjivanje ulazne informacije na više manjih segmenata [15]. U svakom sledećem skrivenom sloju broj neurona se smanjuje linearno, konvergirajući ka broju izlaza. Struktura imlementiranog ANN modela prikazana je na Sl. 2. Posmatrana ANN mreža se sastoji iz ulaznog sloja, 4 skrivena sloja i izlaznog sloja. Broj neurona po slojevima (od ulaznog ka

izlaznom sloju) iznosi 175, 260, 65, 16, 4, 2. Za potrebe treniranja korišćena je *triangda* funkcija (*gradient descent training function with an adaptive learning rate*) [10], sa inicijalnom vrednošću brzine učenja (*learning rate*) od 0.1. Svi neuroni su implementirani sa *hyperbolic tangent sigmoid* transfer funkcijom, osim neurona izlaznog sloja koji koriste linearnu transfer funkciju. Kao kriterijumska funkcija za analizu performansi neurone mreže korišćena je srednja kvadratna greška (*mean squared error*, MSE).

Nakon završenog procesa treniranja i testiranja modela, performanse ANN modela za pozicioniranje su verifikovane korišćenjem nezavisnog verifikacionog skupa (istog kao u slučaju kNN modela), a rezultati su dati u Poglavlju IV.



Slika 2. Struktura *multilayer feedforward* ANN mreže.

IV. ANALIZA PERFORMANSI KNN I ANN MODELA ZA INDOOR POZICIONIRANJE

U okviru ovog poglavlja izvršena je analiza i poređenje performansi kNN i ANN modela za *indoor* pozicioniranje, sa stanovišta vrednosti greške pozicioniranja (*distance error*, DE). Kao što je već napomenuto, za verifikaciju oba modela korišćen je identičan skup tačaka, nezavisan od skupova korišćenih za treniranje i testiranje modela. Rezultati verifikacije ova dva modela dati su u Tabeli 1.

U slučaju kNN modela, osim rezultata dobijenih za optimalno k ($k=1$), prikazani su rezultati dobijeni i za ostale vrednosti parametra k , kako bi se izvršila analiza ponašanja vrednosti greške pozicioniranja u zavisnosti od broja najbližih suseda koji se koriste pri estimaciji pozicije.

Dobijen rezultat, da je najbolje koristiti samo najbližeg suseda (tj. najbližu referentnu tačku) pri estimaciji nepoznate pozicije ($k=1$), može se objasniti kao posledica kompleksne unutrašnje strukture posmatranog *indoor* okruženja, koje uslovljava pojavu niza različitih radio-propagacionih efekata. Ovi efekti mogu prouzrokovati veliku razliku u nivoima radio signala koji se mere u prostorno bliskim tačkama, ali i obrnuti slučaj, da su dve prostorno udaljene tačke slične u domenu radio signala koji se detektuju u njima. Stoga, u ovakvom tipu složenog *indoor* okruženja, korišćenje većeg broja suseda (referentnih tačaka) pri estimiranju nepoznate pozicije može degradirati tačnost modela za pozicioniranje. S druge strane, u slučaju uzimanja u obzir samo jednog suseda, problem može nastati pri pogrešnoj proceni najbližeg suseda, što može rezultovati određenim brojem dosta velikih vrednosti grešaka pozicioniranja. Uzimanjem u obzir većeg broja suseda ($k>1$) smanjuje se ovakav tip greške, što se može videti kroz smanjenje maksimalne vrednosti greške pozicioniranja (MAX DE) u Tabeli 1.

Na osnovu sprovedene analize, može se zaključiti da kNN model za pozicioniranje obezbeđuje dosta dobre performanse

sa stanovišta tačnosti pozicioniranja (srednja vrednost greške pozicioniranja od 9.3m i medijanska vrednost greške pozicioniranja od 4.5m). Dodatno, velika prednost modela ogleda se u jednostavnosti njegove imlementacije. Međutim, pokazalo se da na određivanje optimalnog broja suseda, osim gustine referentnih tačaka u posmatranom prostoru, značajno utiče i „stabilnost“ radio-propagacionih uslova u datom *indoor* okruženju. Odnosno, u slučaju kompleksnih *indoor* okruženja sa prostorijama različitih veličina, hodnicima, itd., optimalan broj suseda može značajno varirati od tačke do tačke.

TABELA I. REZULTATI VERIFIKACIJE KNN I ANN MODELA ZA POZICIONIRANJE..

	Srednja DE [m]	Standardna devijacija [m]	Medijanska DE [m]	67% DE ⁺ [m]	95% DE ⁺ [m]	MIN DE [m]	MAX DE [m]
kNN							
k=1	9.3	11.8	4.5	7.6	30.2	1.7	73.4
k=2	10.3	12.8	6.2	8	37	0.3	73.4
k=3	10.2	12.1	5.5	9.4	47.6	0.7	58.4
k=4	10.5	11.6	6.8	9.4	38.4	0.5	58.4
k=5	11.03	11.2	7.3	10.7	34.4	0.9	55.61
k=6	10.8	10.8	6.4	9.2	34.4	0.1	47.7
k=7	10.8	10.6	7.4	9.4	36.5	0.6	53.5
k=8	10.6	10.3	7.6	9.8	35.7	1.1	50.1
k=9	10.7	10.2	7.8	10.5	34.6	0.2	52.7
k=10	10.5	9.5	10.5	10.4	34.3	0.8	47.1
ANN							
	11.9	9.02	8.7	12.7	30.4	1.2	43.9

⁺ 67th percentile distance error
⁺ 95th percentile distance error

Na osnovu rezultata prikazanih u Tabeli 1, može se zaključiti da je implementirani ANN model pokazao nešto lošije performanse sa stanovišta vrednosti greške pozicioniranja, u odnosu na kNN model. Razlog lošijih performansi može se objasniti kao posledica velikih dimenzija ulaznog vektora (175 ulaznih parametara), što otežava proces treniranja i nalaženja opšte relacije koja postoji između izmerenih RSS vrednosti i prostornih koordinata. Međutim, kako ne nose RSS vrednosti svih 175 GSM ćelija istu količinu informacija o prostoru (npr. pojedine GSM ćelije su bile radio-vidljive u svega par tačaka), broj ulaznih parametara mogao bi se redukovati odabirom GSM ćelija koje su relevantne za proces pozicioniranja i na taj način smanjiti kompleksnost optimizacionog problema. Ipak, definisanje kriterijuma za određivanje relevantnih radio izvora u okruženju, čije RSS vrednosti nose u sebi najviše informacija o posmatranom prostoru, su predmet budućeg istraživanja.

S druge strane, na osnovu dobijenih rezultata može se zaključiti da ANN model ima dobra generalizaciona svojstva, što se ogleda u znatnom smanjenju maksimalne vrednosti greške pozicioniranja u odnosu na kNN model (maksimalna DE je redukovana za oko 30m).

V. ZAKLJUČAK

U okviru ovog rada realizovana su dva modela za *indoor* pozicioniranje mobilnih korisnika, koja koriste izmerene RSS vrednosti obližnjih GSM ćelija da odrede prostorne koordinate trenutne pozicije mobilnog korisnika. Prvi model realizovan je korišćenjem metode k najbližih suseda, a drugi korišćenjem

neuralne mreže.

kNN model pokazao je dosta dobre performanse u pogledu vrednosti greške pozicioniranja (srednja vrednost greške pozicioniranja od 9.3m i medijanska vrednost greške pozicioniranja od 4.5m). Dodatno, kNN metod ne zahteva prethodno treniranje modela za pozicioniranje, što predstavlja i najveću prednost datog pristupa u odnosu na neuralne mreže. Međutim, pokazalo se da u slučaju kompleksnih *indoor* okruženja optimalan broj suseda, koji se koriste za estimaciju nepoznate pozicije, može značajno varirati od tačke do tačke, što u pojedinim slučajevima može rezultovati relativno velikom vrednošću greške pozicioniranja.

S druge strane, ANN model, pokazao je dobra generalizaciona svojstva, koja se ogledaju u znatnom smanjenju maksimalne vrednosti greške pozicioniranja u odnosu na kNN model (maksimalna DE je redukovana za oko 30m). Dalje unapređenje performansi ANN modela biće usmereno ka smanjenju kompleksnosti optimizacionog problema, kroz izdvajanje relevantnih GSM ćelija na osnovu čijih će se RSS vrednosti vršiti estimacija prostornih koordinata.

Oba modela za *indoor* pozicioniranje realizovana u ovom radu zasnivaju se na korišćenju infrastrukture GSM mreže, što im daje veliki potencijal u pogledu dostupnosti. Dodatno, obe metode se mogu primeniti i u slučaju drugih savremenih PLMN mreža.

LITERATURA

- [1] R. Filjar, G. Jezic, M. Matijasevic, "Location-Based Services: A Road Towards Situation Awareness", *The Journal of Navigation*, vol.61, pp. 573–589, 2008.
- [2] H. Lui, H. Darbi, P. Banerjee and J. Liu. "Survey of Wireless Indoor Positioning Techniques and Systems". *IEEE Trans on Systems, Man and Cybernetics*. 37(6), pp. 1067-1080, 2007.
- [3] Y. Gu, A. Lo, I. Niemegeers. "A survey of indoor positioning systems for wireless personal networks". *IEEE Communication Surveys and Tutorials*. 11(1), pp. 13 – 32, 2009.
- [4] A. Kushki, K.N. Plataniotis, A.N. Venetsanopoulos. "Kernel-Based Positioning in Wireless Local Area Networks", *IEEE Trans on Mobile Computing* 6(6), pp. 689 – 705, 2007.
- [5] M. Borenovic, A. Neskovic. "Positioning in WLAN environment by use of artificial neural networks and space partitioning". *Annals of Telecommunication*. 64(9-10), pp. 665-676, 2009.

- [6] C. T. Huang, C.H. Wu, Y.N. Lee, J.T. Chen. "A Novel Indoor RSS-Based Position Location Algorithm Using Factor Graphs". *IEEE Trans on Wireless Communications*. 8(6), pp. 3050 – 3058, 2009.
- [7] A. Gaber and A. Omar. "A Study of Wireless Indoor Positioning based on Joint TDOA and DOA Estimation Using 2-D Matrix Pencil Algorithms and IEEE 802.11ac". *IEEE Trans on Wireless Communications*. DOI: 10.1109/TWC.2014.2386869, 2015.
- [8] T.M. Cover, P.M. Hart. "Nearest Neighbour Pattern Classification". *IEEE Trans. on Information Theory*, 13, pp. 22-27, 1967.
- [9] N. Bhatia, Vandana. "Survey of Nearest Neighbor Techniques". *International Journal of Computer Science and Information Security*, 8(2), pp. 302-305, 2010.
- [10] M.H. Hassoun. *Fundamentals of artificial neural networks*. MIT press. 1995.
- [11] A. Varshavsky, E. de Lara, J. Hightower, A. LaMarca and V. Otsason. "GSM-Indoor localization". *Pervasive and Mobile Computing*. 3(6), pp. 698–720, 2007.
- [12] B.D.S. Lakmali and D. Dias. "Database Correlation for GSM Location in Outdoor & Indoor Environments", *4th International Conference on Information and Automation for Sustainability (ICIAFS 2008)*, 2008, pp 42-47.
- [13] U. Birkel and M. Weber. "Indoor localization with UMTS compared to WLAN", *International Conference on Indoor Positioning and Indoor Navigation*, Sydney, 2012, DOI:10.1109/IPIN.2012.6418933.
- [14] M. Stella, M. Russo, and D. Begušić. "GSM-Based Approach for Indoor Localization", *World Academy of Science, Engineering and Technology*, 7, pp. 158-162. 2013.
- [15] Y. Shang, WB Wah. "Global optimization for neural network training". *Computer*, 29(3), pp. 45–55, 1996.

ABSTRACT

In this paper, two models for mobile user indoor positioning, based on k Nearest Neighbours (kNN) method and Artificial Neural Networks (ANN), are presented. The proposed models are based on the use of the infrastructure of ubiquitous GSM (Global System for Mobile Communications) networks. Positioning models implementation and accuracy verification were done using field data collected within the ground floor of the Technical Schools' building, University of Belgrade. kNN model has achieved median positioning error of 4.5m, while ANN approach has shown better performance regarding the reduction of large-size positioning errors.

IMPLEMENTATION AND COMPARATIVE ANALYSIS OF MOBILE GSM USER INDOOR POSITIONING MODELS BASED ON KNN AND ANN

M. Petrić, A. Nešković, N. Nešković