

POZICIONIRANJE KORISNIKA U WLAN SISTEMIMA

Miloš Borenović¹, Aleksandar Nešković¹, Nataša Nešković¹, Đorđe Paunović¹
¹Elektrotehnički fakultet u Beogradu

Sadržaj: *U ovom radu razmatran je problem pozicioniranja u zatvorenom prostoru sa implementiranim IEEE 802.11g mrežnom infrastrukturom. Predstavljena su postojeća rešenja, a zatim je predloženo rešenje koje koristi informacije o nivoima snage signala na ulazu u prijemnik mobilnog klijent i treniranu veštačku neuralnu mrežu (u daljem tekstu Artificial Neural Networks - ANN). Prikazana je uporedna analiza nove metode i postojećih rešenja i pokazano da predložena tehnika pozicioniranja može uspešno da se primeni u realnim WLAN mrežama.*

Ključne reči: ANN, pozicioniranje, radio, WLAN.

1. Uvod

Sa razvojem servisa koji u obzir uzimaju i informaciju o poziciji korisnika (*location-aware computing*), rastu i naporu da se, istraživanjem novih tehnika određivanja pozicije, iz određene wireless tehnologije obezbedi maksimum lokacijski zavisnih informacija.

Bežične tehnologije kratkog dometa poput Radio-Frequency (RF) tehnologija (WLAN, Bluetooth, i RFID [1]), ultrazvuk i IrDA (*Infrared Data Association*) se mogu koristiti za određivanje pozicije u okruženjima u kojima pružaju radio-pokrivanje. U odnosu na *outdoor* tehnike, ove tehnologije pružaju veću preciznost određivanja pozicije, ali sa manjom oblašću pokrivanja.

U ovom radu, predstavljene su postojeće WLAN tehnike određivanja pozicije u *indoor* okruženju, a zatim je predložen nov način korišćenja veštačkih neuralnih mreža (*Artificial Neural Networks – ANN*) u cilju određivanja pozicije korisnika.

Rad je organizovan kroz pet poglavlja. U drugom delu su predstavljene WLAN tehnike i tehnologije određivanja pozicije u zatvorenom prostoru. U trećem delu predložen je novi pristup rešavanju pozicioniranja korišćenjem ANN kao i njegove performanse. Poređenje predložene tehnike i postojećih rešenja izvršeno je u delu četiri.

2. Postojeća rešenja za WLAN pozicioniranje

Tehnike određivanja pozicije korišćenjem WLAN mreža u infrastrukturnom režimu rada veoma su popularne. Razlozi za to su velika rasprostranjenost 802.11 mreža i činjenica da je u već postojećoj mreži moguće uspostaviti LBS (*Location Based Services*)

bez dodatnog ulaganja u hardverske komponente odnosno infrastrukturu. Postoji veliki broj pristupa pozicioniranju u WLAN mrežama. Sigurno, najviše pažnje posvećeno je pozicioniranju na osnovu nivoa snage signala na mestu mobilnog klijenta, ali postoje i drugi pristupi koji iziskuju dodatne hardverske komponente, a za uzvrat nude bolju preciznost i/ili kraće vreme implementacije sistema.

Pozicioniranje korišćenjem informacije o nivou signala na prijemu se u osnovi svodi na problem estimacije propagacionog slabljenja. Priroda problema predikcije propagacionog slabljenja u *indoor* okruženjima je izuzetno složena i zavisi od niza polaznih pretpostavki (tipa zgrade, konstrukcije zgrade i sl.) [2]. Čak i kada su poznati ovi osnovni parametri, teško je precizno estimirati propagaciono slabljenje. Za analizu se mogu koristiti determinističke i statističke metode. Većina metoda koje počivaju na RSSI (*Received Signal Strength Indication*) parametru se oslanja na statistički pristup. Uspostavljanje njihove funkcije može se grubo podeliti na *off-line* fazu, tj. fazu prikupljanja trening podataka i njihovog smeštanja u odgovarajuću bazu uzoraka, i fazu određivanja pozicija korisnika, tj. *on-line* fazu. U *on-line* fazi algoritam za određivanje pozicije vrši poređenje izmerenog vektora RSSI i vektora RSSI koji postoji u bazi podataka, i na osnovu korelisanosti vektora procenjuje poziciju mobilnog klijenta. Ovaj pristup određivanju pozicije u WLAN mrežama se najčešće, ali ne isključivo, naziva *Location Fingerprinting* metodom. Generalno, sam algoritam koji na osnovu trening podataka vrši procenu pozicije se može implementirati na različite načine.

Bal (Bahl) i Padmanaban (Padmanabhan), „RADAR“ projekat [3], izvršili su prvu detaljnu analizu mogućnosti upotrebe nivoa snage signala na prijemu za svrhe geolociranja u zatvorenim prostorima. Prema njihovom istraživanju, za potrebe pozicioniranja, mnogo je bolje koristiti RSSI nego SNR (*Signal to Noise Ratio*) parametar, jer RSSI parametar ima znatno veću zavisnost od lokacije na kojoj se korisnik nalazi. Predložena su i dva algoritma za određivanje pozicije korisnika. Prvi, empirijski, pored vektor RSSI određenog mobilnog klijenta, sa RSSI vektorima dobijenim na različitim lokacijama u *off-line* fazi i nalazi, po predefinisanoj metrići, lokaciju čiji RSSI vektor ima najmanju razliku u odnosu na vektor mobilnog klijenta (*Nearest Neighbor – NN*). U ovom slučaju korišćeno je euklidsko rastojanje između vektora, a razmatrana je i ekstenzija ovog algoritma u tom smislu što se procenjena pozicija ne poistovećuje sa jednom tačkom čiji RSSI vektor ima najmanje rastojanje, već može postojati više, k, „najbližih“ tačaka u čijoj se „sredini“ nalazi procenjena pozicija (kNN algoritam). Analize pokazuju da se za vrednosti $k = 2$, i $k = 3$ dobijaju bolji rezultati u odnosu na polaznu verziju algoritma, dok se ta prednost, za veće k , gubi. Drugi algoritam opisan u ovom radu podrazumeava jednostavan propagacioni model zasnovan na Rajsovom (Rice) raspodeli. Oba pristupa podrazumevaju minimum od tri radio-vidljiva AP. U sklopu merne kampanje izvršena su merenja na 70 lokacija. Na svakoj lokaciji merenja su vršena za četiri orientacije prijemnika i svako merenje je, radi usrednjavanja, ponovljeno 20 puta.

U cilju iskorišćenja maksimalne količine informacija iz prikupljenih RSSI vektora, predložen je Bajesov (Bayes) pristup problemu koji, prema [4], daje bolje rezultate od *Nearest Neighbor* algoritma. Naime, Bajesovo pravilo se može predstaviti kao:

$$p(l_t | o_t) = p(o_t | l_t) p(l_t) N, \quad (1)$$

gde je l_t lokacija u trenutku t , o_t obzervacija primljenih snaga signala (primljeni vektor RSSI) u trenutku t , dok je N normalizacioni faktor koji obezbeđuje da suma svih verovatnoća bude jedan. Drugim rečima, verovatnoća da se korisnik nalazi na lokaciji l pod uslovom da je primljen vektor snaga signala o , jednak je proizvodu verovatnoće da se na lokaciji l dobije vektor RSSI o , i verovatnoće da se korisnik uopšte nađe na lokaciji l . Proces određivanja pozicije se sada svodi na izračunavanje uslovne verovatnoće $p(l_t | o_t)$ za svaku lokaciju. Lokacija za koju je izračunata najveća uslovna verovatnoća je procenjena pozicija korisnika.

Da bi se sproveo navedeni postupak, neophodno je izračunati dve verovatnoće na desnoj strani jednačine (1). Prvi faktor, poznat i kao *likelihood* funkcija, se može izračunati na osnovu mape nivoa snage signala u svakoj lokaciji korišćenjem bilo kog pristupa koji će obezbediti funkciju gustine verovatnoće pojavljivanja obzervacije o za sve posmatrane lokacije. Što se tiče *apriori* verovatnoće $p(l)$, u najjednostavnijoj implementaciji se može pretpostaviti da je ona uniformno raspoređena po svim lokacijama. U sklopu merne kampanje izvršena su merenja na 70 lokacija. Kao i kod prethodne metode, na svakoj lokaciji merenja su vršena za četiri orijentacije prijemnika i svako merenje je ponovljeno 20 puta.

Jozef (Youssef) i Agrawala (Agrawala) [5], [6] su predstavili svoj projekat – „Horus“, koji je za cilj imao da obezbedi visoku preciznost i niske računske zahteve. Kako je snaga signala AP-a podložna varijacijama tokom vremena, autori su pokazali da autokorelacija između susednih odbiraka jačine signala od posmatranog AP može biti do 0.9. Oni predlažu autoregresivni model kojim bi se opisalo ovo ponašanje:

$$s_t = \alpha s_{t-1} + (1 - \alpha) v_t, \quad 0 \leq \alpha \leq 1, \quad (2)$$

gde je v_t proces šuma, a s_t stacionarni niz uzorka od posmatranog AP. Na osnovu ovog modela, varijansa ovako korelisanih uzorka je

$$\frac{1 + \alpha}{1 - \alpha} \sigma^2. \quad (3)$$

Tokom trening faze, procenjuje se vrednost α i smešta zajedno sa parametrima raspodele μ i σ , a tokom faze određivanja pozicije, Gausova raspodela se modifikuje odgovarajućom α vrednosti. Slično kNN algoritmu, Horus sistem procenjuje poziciju korisnika kao centar mase k lokacija sa najvećim verovatnoćama $p(i)$:

$$x = \frac{\sum_{i=1}^k p(i) x(i)}{\sum_{i=1}^k p(i)}. \quad (4)$$

Razlika u odnosu na kNN algoritam leži u činjenici da su lokacije ponderisane sa njihovim odgovarajućim verovatnoćama $p(i)$.

U cilju verifikacije ovog pristupa izvršena su merenja na 612 lokacija, a svako merenje je, radi usrednjavanja, ponovljeno 110 puta.

Batiti (Battiti) *et al.* [7] su prvi razmatrali upotrebu veštačkih neuralnih mreža u svrhu pozicioniranja u WLAN mrežama. Ovakav pristup ne zahteva detaljno poznavanje strukture i radio-karakteristika prostora u kome se pozicioniranje vrši, kao ni pozicija AP. Korišćena je *multilayer feedforward* mreža sa dva nivoa i *one-step secant* metodom treniranja neuralne mreže. Razmatrani su različiti brojevi jedinica u skrivenom nivou. S tim u vezi, nije primećena velika zavisnost performansi metode kada se broj jedinica u skrivenom nivou povećavao preko optimalnog broja. Za verifikaciju ovog modela izvršena su merenja na 56 lokacija, a svako merenje je, radi usrednjavanja, ponovljeno 100 puta.

Posebno treba istaći da usrednjavanje primljenog vektora RSSI u toku *on-line* faze drastično povećava latentnost metode pa bi metoda, dobijena na ovaj način, imala isuviše spor odziv za upotrebu u većini LBS. S obzirom da sve predstavljene metode zahtevaju minimum od tri radio-vidljiva AP, kao i veliki broj merenja radi usrednjavanja, može se zaključiti da predstavljene tehnike ne zadovoljavaju osnovne uslove za upotrebu u najvećem broju realnih sistema.

3. Novi pristup rešavanju pozicioniranja u realnom WLAN okruženju korišćenjem ANN

a) Prikupljanje podataka za treniranje ANN

Izbor prostora u kome su vršena merenja je obavljen sa velikom pažnjom. S obzirom da je ovaj rad sproveden kao studija implementacije tehnike pozicioniranja u realnom slučaju, osnovni kriterijumi koje je prostor trebalo da zadovolji bili su sledeći: da poseduje dovoljno velike dimenzije tako da implementacija tehnike pozicioniranja ove klase tačnosti ima smisla, da broj i raspored AP podleže optimalnom radio-planiranju s aspekta usluga transporta podataka (a ne LBS), i da broj i raspored prostorija, kao i konstrukcija prepreka budu takvi da omoguće ispoljavanje što većeg broja efekata radio-prostiranja.

Za prostor u kome su izvršena merenja izabrano je prizemlje zgrade Tehničkih fakulteta u Beogradu. Ovaj prostor je dimenzija 147.1 m x 66.1 m, sa više od 80 prostorija. ESS (*Extended Service Set*) se sastoji od osam AP planski postavljenih tako da se ostvari optimalno radio-pokrivanje prostora sa stanovišta bežičnog pristupa Internetu. Svaki AP pokriva površinu od preko 1000 m². Prostor odlikuje izuzetno velika dinamika signala od preko 80 dB.

Prikupljanje mernih rezultata se sastojalo od niza eksperimenata koji su ponavljeni na različitim, pseudoslučajno izabranim, lokacijama u merenom prostoru. Mernu aparaturu je činio prenosivi računar opremljen Cisco Aironet 802.11a/b/g *Cardbus AIR-CB21AG-E-K9* adapterom i odgovarajućim softverom. Orientacija prijemnika prilikom merenja je takođe birana slučajno. Pri svakom merenju beležena je informacija o nivou signala od svakog radio-vidljivog AP i pozicija na kojoj je merenje izvršeno. Zabeleženi podaci o nivou primljenog signala (elementi RSSI vektora) su mogli da imaju vrednost iz opsega od -100 dBm do -40 dBm (dinamički opseg mernog prijemnika). Pre procesa merenja izvršena je digitalizacija tlocrta merenog prostora. Pozicija eksperimenta je beležena ručno – obeležavanjem na digitalizovanom tlocrtu, a nivoi signala su direktno upisivani u tekstualni fajl korišćenjem Cisco Site Survey programa. Tačnost pozicioniranja u fazi prikupljanja podataka je iznosila 0.1 m.

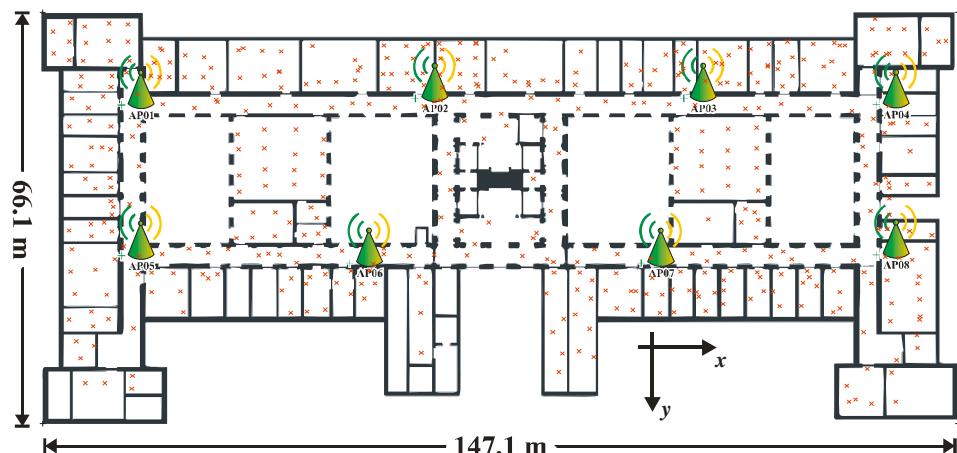
Tokom merne kampanje u trajanju od osam dana izvršena su merenja na 433 lokacije. Tlocrt prostora, pozicije AP kao i pozicije na kojima su vršena merenja prikazane su na Sl. 1.

Posebno je razmatrana i ponovljivost rezultata merenja. Ako se ima na umu da se sve tehnike određivanja pozicije zasnivaju na postojanju korelacije između određenih veličina merenih na istim lokacijama, nije teško zaključiti da su ponovljivost rezultata merenja i preciznost tehnike u direktnoj proporciji. U svrhu kvantifikovanja ponovljivosti merenja, na određenom broju već izmerenih lokacija su ponovo izvršena merenja. Ponovljivost je ocenjena sa tri parametra: verovatnoćom da će podskup vidljivih AP pri ponovljenom merenju biti isti kao i pri prvom merenju ($P_{\Omega_1 = \Omega_2}$), srednjom apsolutnom razlikom nivoa primljenog signala od istog AP (η) i standardnom devijacijom srednje apsolutne razlike (σ). Dobijeni rezultati sumirani su u Tabeli 1.

Parametar	$P_{\Omega_1 = \Omega_2}$ [%]	η [dB]	σ [dB]
Vrednosti	20	5.12	4.13

Tabela 1. Ponovljivost rezultata merenja ($P_{\Omega_1 = \Omega_2}$ - verovatnoća da će podskup vidljivih AP pri ponovljenom merenju biti isti kao i pri prvom merenju, η - srednja apsolutna razlika nivoa primljenog signala od posmatranog AP, σ - standardna devijacija srednje apsolutne razlike nivoa primljenog signala)

Vrednosti prikazane u Tabeli 1. ukazuju da je ponovljivost rezultata merenja skromna što, u velikoj meri ograničava tačnost pozicioniranja (bez obzira na primenjenu metodu).



Slika 1. Tlocrt prostora, pozicije AP i pozicije na kojima su vršena merenja (crvenim „x“ simbolima označene su pozicije na kojima su vršena merenja, a zelenim „+“ simbolima su označene pozicije AP)

b) Struktura ANN

S obzirom na funkciju koju mreža treba da obavlja i, što je možda i bitnije, na samu prirodu problema, zaključeno je da adaptivne neuralne mreže sa više nivoa (*multilayer feedforward network*) i pravilom učenja sa propagacijom greške unazad (*error backpropagation*) imaju značajne prednosti u odnosu na ostale strukture ANN [8]. Izbor spoljnog interfejsa ANN, odnosno broj neuronskih jedinica u ulaznom i izlaznom stepenu, je direktno uslovljen brojem AP sa jedne strane, odnosno dimenzijom prostora u kome se pozicioniranje vrši, sa druge. Izabrana ANN ima osam neuronskih jedinica u ulaznom stepenu, pri čemu svakoj neuronskoj jedinici odgovara jedan AP, i dve neuronske jedinice u izlaznom stepenu – po jedna za svaku dimenziju prostora (dovoljno dobra aproksimacija je dvodimenzionalni prostor).

Izabrana struktura mreže sa više nivoa podrazumeva mogućnost postojanja jednog ili više skrivenih slojeva. Broj skrivenih slojeva, kao i broj neuronskih jedinica u tim slojevima čine unutrašnju strukturu ANN. Ne postoji egzaktan metod za određivanje optimalne unutrašnje strukture ANN [8]. Postoje algoritmi za redukciju nepotrebnih elemenata mreže, čime se, polazeći od namerno predimenzionisane strukture mreže, iterativno približava optimalnom rešenju. Ipak, s obzirom na kompleksnost takve procedure i na činjenicu da je jedan od ciljeva ove metode jednostavnost, prihvaćen je poznat stav [9] da prvi skriveni sloj treba da ima veći broj neuronskih jedinica u odnosu na ulazni stepen radi kvantifikacije i grupisanja ulaznih informacija na manje „porcije“. Broj neuronskih jedinica sledećih skrivenih slojeva treba da se smanjuje i konvergira ka broju neuronskih jedinica poslednjeg sloja (izlaznog stepena). Imajući ovo u vidu, izabrana je struktura ANN prikazana koja se sastoji od ulaznog sloja, tri skrivena sloja i izlaznog stepena. Slojevi redom, od ulaza ka izlazu, imaju 8, 15, 9, 5 i 2 neuronske jedinice.

Zbog velikog broja ugrađenih funkcija za kreiranje, inicijalizaciju, treniranje i simulaciju ANN, kao i pogodnosti koje nudi kada je u pitanju obrada ulaznih podataka i rezultata, za implementaciju je izabrano Matlab softversko okruženje. Kao posledica činjenice da svakom merenju na ulazu u ANN mora da odgovara vektor od osam ulaznih podataka i da je na jednoj lokaciji najčešće vidljivo svega jedan do dva AP, informacija da neki AP nije radio-vidljiv kodirana je sa -105 dBm . Nakon što su vektori dobijeni postupkom merenja dopunjeni na opisan način, formirane su dve matrice dimenzija 433×8 i 433×2 , pri čemu prva matrica predstavlja izmereni vektor RSSI parametara, a druga pozicije na kojima su vršena odgovarajuća merenja. Za proces treniranja ANN izabrana je ugrađena Matlab funkcija *train* sa adaptivnom brzinom učenja (*learning rate*). Korišćena funkcija se ponaša na sledeći način: ukoliko se performanse mreže, prilikom jednog ciklusa (epohe) treniranja, približavaju zadatoj vrednosti, brzina učenja se povećava, dok se, ako se performanse mreže u toku jedne epohe suviše udalje od zadate vrednosti, brzina učenja smanjuje, a promena koja je načinjena u poslednjoj epohi se anulira.

c) Proces treniranja ANN

U cilju određivanja optimalnih parametara funkcije treniranja mreže, kao i optimalne dužine treniranja za konkretnu primenu, skup merenja je, uniformnim odabirom, podeljen na dva podskupa u odnosu 10% - 90%, pri čemu je veći podskup korišćen za treniranje ANN, a manji za pobudivanje trenirane mreže, odnosno za

verifikaciju dobijenog modela. Da bi se verifikacija modela izvršila sa što većom pouzdanošću, takva podela skupa mernih podataka ponovljena je deset puta, pri čemu se vodilo računa da se merenja u skupu za verifikaciju modela ne ponavljaju. Dakle, dobijeno je deset skupova za treniranje mreže i odgovarajućih deset skupova, sa ukupno 433 merenja, za verifikaciju performansi ANN.

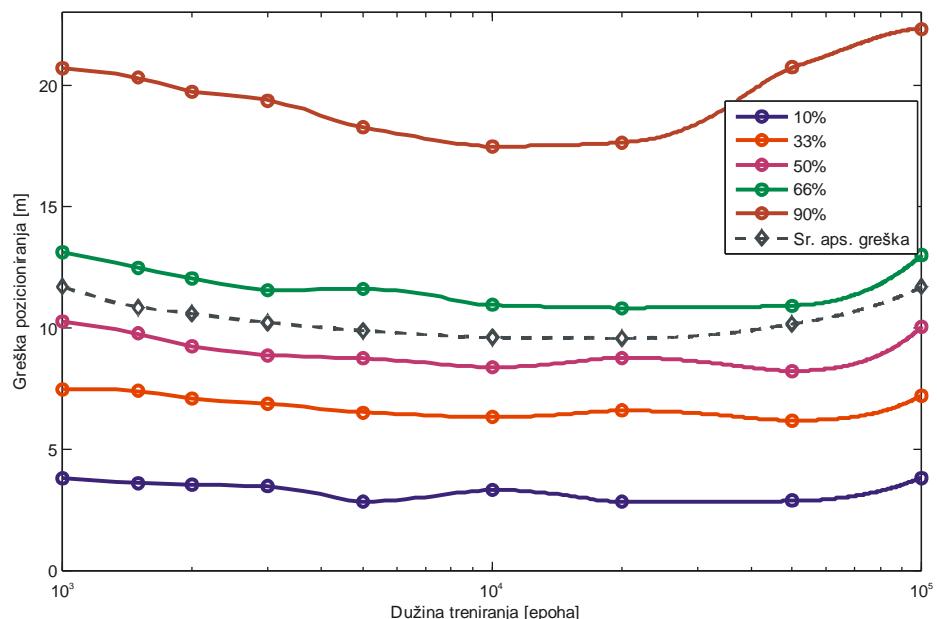
Ocenjivane su performanse veštačke neuralne mreže za dužine treniranja od 1000, 1500, 2000, 3000, 5000, 10000, 20000, 50000 i 100000 epoha.

d) Analiza tačnosti modela

Trenirana veštačka neuralna mreža, kao model za pozicioniranje korisnika, je verifikovana korišćenjem skupa od ukupno 433 merenja. Greška pozicioniranja u zavisnosti od dužine treniranja je predstavljena na Sl. 2. Parametar grafika su kvantili, odnosno verovatnoća da je greška pozicioniranja, za datu dužinu treniranja, manja od prikazane vrednosti, osim u slučaju sive isprekidane linije kojom je prikazana vrednost srednje apsolutne greške pozicioniranja.

Optimalna dužina treniranja ANN se može definisati kao „dno“ neke od krivih prikazanih na Sl. 1. Izbor krive čiji će se minimum posmatrati kao optimalna dužina treniranja ANN najviše zavisi od LBS koji se od mreže očekuju. Za najveći broj primena, dovoljno je optimizovati mrežu po kriterijumu minimuma srednje apsolutne greške.

Sa Sl. 2. se vidi da se minimalna srednja apsolutna greška pozicioniranja dobija za dužinu treniranja ANN od 20000 epoha. Vrednost srednje apsolutne greške u tom slučaju je 9.58 m.



Slika 2. Greška pozicioniranja u zavisnosti od dužine treniranja ANN (parametar grafika je pouzdanost, odnosno verovatnoća da je greška pozicioniranja, za datu dužinu treniranja, manja od prikazane vrednosti, osim u slučaju sive isprekidane linije kojom je prikazana vrednost srednje apsolutne greške pozicioniranja)

Usled velike razlike između dužine i širine posmatranog prostora, postoji potreba da se rezultati dobijeni verifikacijom predstavljenog modela razdvoje na X i Y osu (S1.1). Tako je dobijeno da je medijana greške pozicioniranja duž X ose (pri optimalno treniranoj mreži) 5.46 m, dok je medijana greške pozicioniranja duž Y ose 3.75 m. S obzirom da je preciznost metode znatno lošija duž X, nego duž Y ose posmatranog prostora može se zaključiti da je preciznost metode pozicioniranja, bez obzira na konstantnu gustinu postavljanja AP, lošija u prostorima većih dimenzija. Dakle, performanse metode pozicioniranja treba posmatrati i kao funkciju veličine prostora u kome su implementirane.

4. Uporedna analiza predstavljenog modela i ostalih postojećih rešenja za određivanje pozicije u WLAN mrežama

U skladu sa razmatranjima o zavisnosti preciznosti metode pozicioniranja od veličine prostora u kome je metoda implementirana, dolazi se do ideje da bi se za poređenje mogao koristiti izvedeni parametar koji bi imao za cilj da izvrši „normalizaciju“ tehnika pozicioniranja u odnosu na veličinu prostora u kome je ona implementirana i testirana.

Kao dodatni parametar upotrebljen je odnos između medijane greške pozicioniranja i maksimalne greške pozicioniranja u datom prostoru. Pod maksimalnom greškom pozicioniranja se podrazumeva srednja greška pozicioniranja u tom prostoru pod uslovom da tehnika pozicioniranja nema nikakve ulazne informacije. Biće pretpostavljeno da je prostor u kome je metoda implementirana pravougaonog oblika i da je pozicija korisnika dvodimenzionala, uniformno raspodeljena, slučajna promenljiva.

Može se pokazati da je srednja absolutna razlika dve slučajne promenljive sa uniformnom raspodelom na intervalu 0,1 jednaka 1/3.

Dakle, ako se dimenzije posmatranog pravougaonog prostora obeleže sa a i b , maksimalna vrednost greške pozicioniranja, $Err(a,b)$, je data sa

$$Err(a,b) = \frac{1}{3} \sqrt{a^2 + b^2}. \quad (5)$$

U Tabeli 2. dat je uporedni prikaz parametara najvažnijih postojećih tehnika pozicioniranja u WLAN mrežama opisanih u odeljku 2 i ovde predstavljenog novog modela.

Može se zaključiti da najbolje performanse u pogledu preciznosti pruža tehnika pozicioniranja korišćenjem ANN koju su isprobali Batiti *et al.* [7]. Kada se posmatra isključivo preciznost, metoda koja je predstavljena u ovom radu, zaostaje za drugim postojećim rešenjima.

Cilj rada bio je da definiše, implementira i da ocenu tehnike određivanja pozicije korisnika u realnim uslovima. Naime, ostale postojeće metode često imaju uslove koje je teško ispuniti u realnim sistemima. Tako sve ostale tehnike zahtevaju minimum od tri radio-vidljiva AP, a često je taj broj bio i dosta veći, dok je za tehniku koja je predstavljena u ovom radu broj prosečno radio-vidljivih AP pri merenjima bio 2.27, a u više od 50% merenja bio je radio-vidljiv samo jedan AP. Da bi se izabrala optimalna metoda, sa stanovišta upotrebljivosti u realnim sistemima, predložene tehnike su upoređene i na osnovu izvedenih parametara poput broja lokacija po m^2 i odnosa maksimalne greške i medijane. Ovi izvedeni parametri imaju za cilj da koliko-toliko

postave sve tehnike u istu ravan sa aspekta upotrebljivosti u realnim sistemima, kako bi se, za te uslove, mogla izabrati optimalna metoda.

Kada se posmatra odnos maksimalne greške i medijane, najpovoljniju vrednost ima HORUS, a neznatno lošiju vrednost ima tehnika predstavljena u ovom radu. Sledi: RADAR (*fingerprinting* pristup), ANN (Batiti *et al.*), Bajesov pristup i, konačno, RADAR (deterministički pristup).

Parametar	Tehnika RADAR	Bajesova	Horus	ANN Batiti	ANN predloženi model
Dimenziije prostora [m]	43.5 x 22.5	25 x 15	15 x 36	20 x 15	144.1 x 66.1
Površina prostora [m ²]	978.75	375	312	300	8500
Broj AP	3	5	14	3	8
m ² po AP	326.25	75	22.29	100	1062.5
Potreban broj AP za površinu prostora u kome je vršena verifikacija predloženog modela	26	113	381	85	8
Broj lokacija na kojima su izvršena merenja	70	132	612	56	433
Broj orijentacija prijemnika na svakoj lokaciji	4	4	1	1	1
Broj lokacija po m ²	0.215	0.352	1.96	0.187	0.051
Medijana [m]	3 / 4.3*	2	2	1.69	8.4
Maksimalna greška [m]	16.32	9.72	13	8.33	52.85
Odnos maksimalna greška / medijana	5.44 / 3.8*	4.86	6.5	4.93	6.29

* prva vrednost je za *fingerprinting*, a druga za deterministički pristup

Tabela 2. Uporedni prikaz parametara WLAN tehnika pozicioniranja

Sa druge strane, napor uložen u prikupljanje trening podataka, odnosno skupa otisaka (ukupan broj merenja po m²), daleko je najmanji kod metode koja je ovde predstavljena (0.051 merenje po m²). Sve ostale metode imaju daleko veću gustinu merenja, a to je najviše izraženo kod HORUS tehnike. Ilustracije radi, za implementaciju HORUS tehnike, sa nepromjenjom gustinom AP i merenja, u prostoru u kome je implementirana tehnika predstavljena u ovom radu, bilo bi potrebno više od 380 AP i prikupljanje više od 1800000 merenja.

5. Zaključak

U okviru WLAN tehnologije, bolje performanse u pogledu preciznosti pružaju statističke metode. Prema prikazanim istraživanjima donja granica srednje apsolutne greške pozicioniranja kod determinističkih metoda je između 3 i 4 m, dok je ta granica kod statističkih metoda ispod 2 m. Kod statističkih metoda, glavni kompromis je između preciznosti tehnike i „cene“ prikupljanja trening podataka. Performanse postojećih tehnika su najčešće dobijene bez obzira na vreme utrošeno na prikupljanje trening skupa podataka jer su prostori u kojima je određena tehnika razmatrana to, svojom površinom, dopuštali. Dakle, te performanse treba posmatrati kao maksimalne dostižne, ali ne i optimalne. Sa druge strane, termin „optimalno“ treba posmatrati ne samo u odnosu na

vreme utrošeno na prikupljanje trening skupa podataka, već i kroz prizmu zahtevanih LBS.

Od prikazanih metoda u okviru WLAN tehnologije, veštačke neuralne mreže kao algoritam za pozicioniranje nude najbolji odnos između preciznosti tehnike i vremena utrošenog na prikupljanje mernih podataka.

Performanse predstavljene metode u pogledu preciznosti nisu superiorne. Ipak, sve druge predstavljene metode testirane su u uslovima koji nisu bliski realno očekivanim. Naime, sama veličina prostora kod tih metoda često umanjuje vrednost implementacije LBS, a i ekonomski aspekti (broj potrebnih AP, vreme potrebno za merenja) najčešće nisu uopšte uzimani u obzir. Imajući to u vidu, izvršena je normalizacija u odnosu na veličinu okruženja u kome je tehnika implementirana, gustini AP, kao i gustini merenja. Normalizovani parametri ukazuju na to da se performanse tehnike pozicioniranja predstavljene u ovom radu nalaze u samom vrhu u pogledu normalizovane preciznosti. Pritom su gustina AP i merenja daleko najpovoljnije. Na ovaj način, predstavljena tehnika se zaista može u realnim uslovima posmatrati kao optimalan izbor za tehniku pozicioniranja u *indoor* okruženjima.

Određivanje pozicije predstavljenom ANN tehnikom se može unaprediti na više načina. Ulazi u ANN bi mogli biti prošireni tako da podrže i SNR vrednosti od radio-vidljivih AP, pošto i šum sadrži lokacijski zavisne informacije. Sa druge strane, izlazi iz ANN bi mogli biti dopunjeni brojem i vrstom (hodnik, velika prostorija, mala prostorija, itd.) prostorije u kojoj se korisnik nalazi. Tako bi se, posredno, kroz proces treniranja mreže, u ANN ugradila dodatna informacija o strukturi prostora u kome se određivanje pozicije vrši i mreža bi mogla biti optimalnije podešena.

Literatura

- [1] Walke, B., "Mobile Radio Networks", John Wiley&Sons, Ltd. 2000.
- [2] A. Nešković, N. Nešković, Đ. Paunović, "Indoor Electric Field Level Prediction Model Based on the Artificial Neural Networks", IEEE Communications Letters, vol. 4, No. 6, June 2000.
- [3] Bahl, P. Padmanabhan, V.N., "RADAR: an in-building RF-based user location and tracking system", INFOCOM 2000. Volume: 2, On page(s): 775-784 vol.2, Tel Aviv, Israel
- [4] B. Li, J. Salter and C. Rizos, "Indoor Positioning Techniques Based on Wireless LAN" in AusWireless '06, Sydney, March 2006.
- [5] Youssef, M. and Agrawala, A., "The Horus WLAN Location Determination System", Int. Conf. on Mobile Systems, Applications And Services, 2005, pages 205–218.
- [6] K. Eckert, "Overview of Wireless LAN based Indoor Positioning Systems", Mobile Business Seminar, University of Mannheim, Germany, Dec. 14, 2005.
- [7] R. Battiti, T. L. Nhat, A. Villani, "Location-aware Computing: A Neural Network Model For Determining Location in Wireless LANs", Feb. 2002, Technical Report # DIT-02-0083
- [8] Hasoun H. M., „Fundamentals of Artificial Neural Networks”, Massachusetts Institute of Technology, 1995.
- [9] Shang Y., Wah W. B., „Global Optimization for Neural Network Training”, COMPUTER, IEEE Computer Society, pp. 45-56, March 1996.

Abstract: This paper presents an in-depth analysis of indoor positioning techniques utilized in IEEE 802.11g networks. The existing techniques for WLAN based networks are analysed. Afterwards, the novel approach applying the use of artificial neural network for WLAN positioning was presented. The obtained positioning technique was compared against the known solutions and was shown to have substantial advantages for real case of general purpose use.

Keywords: ANN, positioning, radio, WLAN.

POSITIONING IN WLAN NETWORKS

Miloš Borenović, Aleksandar Nešković, Nataša Nešković, Đorđe Paunović