

Analiza načina treniranja veštačke neuralne mreže za potrebe pozicioniranja u zatvorenom prostoru

Vesna Glavonjić

(mentor: profesor dr. Aleksandar M. Nešković)

Sadržaj — U radu se diskutuje način treniranja veštačke neuralne mreže u svrhu preciznijeg pozicioniranja mobilnog korisnika u zatvorenom prostoru. Prikazani su rezultati eksperimenata vršenih nad ANN mrežom, u zavisnosti od načina predprocesiranja ulaznih parametara.

Ključne reči — ANN, mobilni sistemi, pozicioniranje, treniranje ANN mreže, WLAN.

I. UVOD

KOD preciznog pozicioniranja na otvorenom prostoru, primat imaju tehnologije zasnovane na satelitskom prijemu (kao što je GPS), dok u zatvorenom prostoru još uvek ne postoji jedinstveno rešenje za ovaj problem. Razlog je taj što performanse tehnologija na otvorenom ne zadovoljavaju zahteve servisa u zatvorenom prostoru. Zato se za pozicioniranje unutar zatvorenog prostora koriste kratkodometne bežične tehnologije kao što su *Wireless Local Area Network* (WLAN) [1], *Bluetooth* [2], *Radio Frequency Identification* (RF-ID) [3] i *indoor GPS* [3]. Sistemi koji se zasnivaju na ovim tehnologijama koriste korisničku lokaciju kao osnovu za razne aplikacije i servise, pa se još nazivaju i „*Location-Based Services*“ (LBS) [4].

Zahvaljujući naglom porastu korisnika i infrastrukturnih mrež WLAN tehnologije i činjenici da se veliki broj LBS sistema može ugraditi u već postojeću bežičnu lokalnu mrežu bez potrebe uvođenja dodatne infrastrukture, WLAN tehnike za pozicioniranje predstavljaju veoma čest predmet današnjih istraživanja. Usled toga, u radu je razmatrana upravo WLAN tehnologija.

Za WLAN okruženje uzeta je najpopularnija situacija, i to kada se WLAN mreža oslanja na indikaciju primljene snage signala (*Received Signal Strength Indication*, RSSI) [5]. S obzirom na činjenicu da RSSI vrednosti u značajnoj meri zavise od prostorne orientacije klijenta, za potrebe ovog rada, RSSI podaci su mereni na ulazu u prijemnik i to tako što su se na svakoj referentnoj tački (*Reference Point*, RP) merile 4 vrednosti – po jedna vrednost za svaki od četiri pravca dolaznog signala (sever, istok, zapad, jug). Ovako prikupljeni podaci su korišćeni za potrebe rada

veštačke neuralne mreže (*Artificial Neural Network*, ANN) [6], i to tako što su najpre predprocesirani a potom dovedeni na ulaz ANN mreže. Veštačke neuralne mreže su u WLAN sistemu korišćene za potrebe pozicioniranja zbog višestrukih prednosti – nema insistiranja na detaljnem poznavanju strukture unutrašnjeg prostora, propagacionih karakteristika niti položaja pristupnih tačaka (*Access Point*, AP).

Izmereni podaci u obliku RSSI vektora (skup RSSI vrednosti za svaki AP) se na ulaz ANN mreže mogu dovesti na više različitih načina: kao “sirovi” podaci pri čemu se ne vodi računa o prostornoj orientaciji klijenta (za svaku lokaciju postoje 4 RSSI vrednosti) i/ili kao usrednjeni podaci (svakoj lokaciji odgovara samo jedna, usrednjena RSSI vrednost). U okviru ovog rada sprovedena je analiza četiri načina predprocesiranja RSSI vrednosti sa stanovišta njegovog uticaja na tačnost pozicioniranja.

U narednom poglavlju date su osnovne karakteristike WLAN okruženja u kome je sprovedena analiza. Potom su objašnjeni algoritam, tehnika i struktura primenjene ANN mreže. U četvrtom poglavlju prodiskutovan je način treniranja mreže u Matlab okruženju, dok peto poglavlje sadrži komparativnu analizu rada ANN mreže u zavisnosti od načina predprocesiranja ulaznih parametara. U šestom je dat kratak zaključak analize.

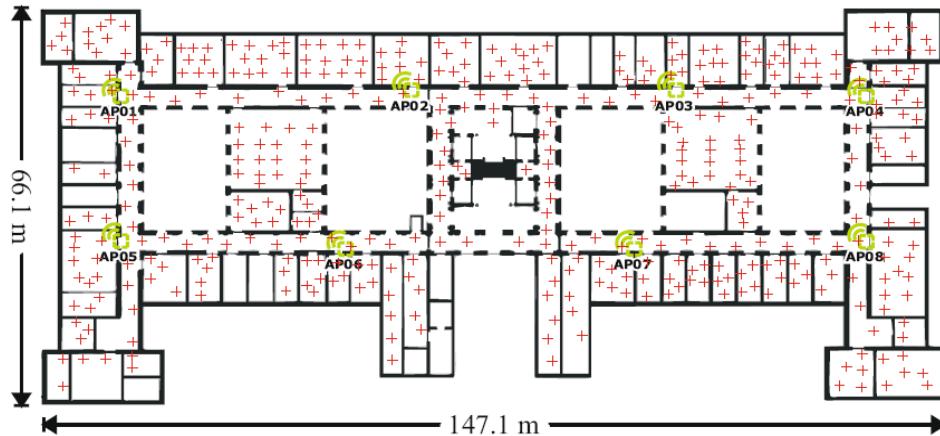
II. WLAN OKRUŽENJE

Za WLAN okruženje 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. Prostorije su dimenzija od 5 m² pa sve do nekoliko stotina m². WLAN sistem formira osam pristupnih tačaka AP, planski postavljenih tako da se ostvari optimalno radio-pokrivanje. Svaki AP pokriva površinu od preko 1000 m², tako da ovaj prostor odlikuje izuzetno velika dinamika signala od preko 80 dB.

Celokupno merenje se sastojalo od eksperimenata vršenih na ukupno 403 gotovo uniformno raspoređenih referentnih tačaka – RP (slika 1). Na svakoj RP, RSSI uzorci su prikupljeni u četiri ortogonalna pravca prijemnika (sever, istok, zapad, jug), tako da je ukupan broj izmerenih (sirovih) podataka 1612.

Vesna M. Glavonjić, student Elektrotehničkog fakulteta u Beogradu, Bulevar kralja Aleksandra 73, 11120 Beograd, Srbija (telefon: +381-64-2181263, e-mail: vesna.glavonovic@gmail.com)

Aleksandar M. Nešković, Elektrotehnički fakultet u Beogradu, Bulevar kralja Aleksandra 73, 11120 Beograd, Srbija (telefon: +381-64-1115983, e-mail: neshko@ef.rs)



Slika 1. Poprečni presek prizemlja zgrade Tehničkih fakulteta sa označenim pozicijama RP-ova i AP-ova
(pozicije AP-ova označene su zelenim simbolima)

III. PRIMENA ANN MREŽE ZA POTREBE POZICIONIRANJA

A. Tehnika pozicioniranja

U zavisnosti od mesta na kome se vrši, određivanje pozicije mobilnog korisnika u WLAN mrežama može biti:

1. na strani mreže („*network-based*“)
2. na strani korisnika („*client-based*“)

Način na koji je merna kampanja bila sprovedena bio je povod za razmatranje „*client-based*“ tehnike. Ipak, treba napomenuti da je praktično svejedno koja od dve tehnike je primenjena u dатој situaciji – jedina razlika je u tome što bi se kod „*network-based*“ rešenja umesto prikupljanja korisničkih RSSI uzoraka na mestu klijenta, korisnički RSSI uzorci za svaki RP uzimali na AP-ovima.

Uzimajući u obzir pristup koji se koristi da bi se odredila lokacija korisnika, WLAN tehnike za pozicioniranje se kategorizuju kao:

1. „*model-based*“
2. „*fingerprinting*“
3. „*hybrid techniques*“

Kod WLAN mreža najčešće se koristi „*fingerprinting*“ tehnika [7], koja sadrži dve faze: „*off-line*“ i „*on-line*“. U „*off-line*“ fazi, skup prikupljenih RSSI „otiska“ („*fingerprints*“) se koristi za treniranje (tj. „učenje“) mreže. U „*on-line*“ fazi, trenirana mreža sprovodi proces određivanja lokacije korisnika. Korišćenje veštačkih neuralnih mreža, kao što je ranije napomenuto, ne zahteva detaljno poznavanje pozicija AP-ova, kao ni detalje o prostoru u kome je tehnika pozicioniranja implementirana, pa je stoga ovaj pristup pogodan.

B. Struktura ANN mreže

Pre pristupanja procesu merenja i rešavanju problema pozicioniranja bilo je potrebno posvetiti pažnju izboru optimalne strukture ANN mreže. Problem pozicioniranja se može svrstati u grupu statičkih problema, tj. slučajeva gde se za zadati skup ulaznih parametara očekuje jednoznačna vrednost na izlazu. Pritom, u ovom problemu, za zadati broj ulaznih parametara treba odrediti vrednost tačno dva izlazna parametra odnosno dve koordinate korisnika, (treća koordinata se ne uzima u obzir jer je prostor u kome funkcioniše WLAN sistem u jednom

nivou). Imajući to na umu, pomenutom problemu po strukturi najviše odgovara „*feedforward*“ tip neuralne mreže, upravo zbog svoje statičke prirode. Stoga značajne prednosti u odnosu na ostale strukture ANN mreže, imaju adaptivne neuralne mreže sa više nivoa (*multilayer feedforward network*) i pravilom učenja sa propagacijom greške unazad (*error backpropagation*) [6], koje su i primenjene u radu.

Izbor spoljnog interfejsa ANN mreže, odnosno broj neuronskih jedinica [6] u ulaznom i izlaznom stepenu, direktno je uslovljen brojem AP sa jedne strane, odnosno dimenzijom prostora u kome se pozicioniranje vrši, sa druge. Dakle, uzimajući u obzir konkretan slučaj, izabrana ANN mreža 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 (kao što je već navedeno, WLAN sistem se nalazi u jednom nivou, pa se dimenzija visine ne razmatra).

Izabrana struktura mreže sa više nivoa podrazumeva mogućnost postojanja jednog ili više skrivenih slojeva. Kod unutrašnje strukture ANN mreže mora da se poštuje pravilo 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 izlaznog stepena. Imajući ovo u vidu, izabrana unutrašnja struktura ANN mreže se sastoji od tri skrivena sloja pri čemu slojevi redom imaju 15, 9 i 5 neuronskih jedinica.

IV. TRENIRANJE ANN MREŽE

Simulacija rada veštačke neuralne mreže na osnovu prikupljenih RSSI podataka izvršena je u softverskom okruženju Matlab [8] i to zbog velikog broja olakšica kao što su: ugrađene funkcije za kreiranje, inicijalizaciju, treniranje i simulaciju ANN mreže, kao i pogodnosti koje nudi kada je u pitanju obrada ulaznih podataka i rezultata.

Mreža je trenirana po principu *backprop* algoritma „*Scaled Conjugate Gradient*“ [9]. Ovaj algoritam je korišćen prvenstveno zbog svoje numeričke efikasnosti pri radu sa velikim brojem podataka. Transfer funkcija svih

nivoa osim poslednjeg je *tan-sigmoid* funkcija [9] (koristi se zbog mogućnosti diferencijabilnosti i kao graničnik izlaznih podataka na vrednosti u opsegu [-1,1]), dok je transfer funkcija poslednjeg nivoa linearna funkcija (gde izlazne vrednosti nisu ograničene na određeni interval).

Tokom treniranja ANN mreže, bilo je neophodno obaviti proces kros-validacije (*cross-validation*) [6] u cilju optimalnog treniranja. S tim u vezi, ulazni podaci su podeljeni u tri grupe:

1. „*training*“ skup sadrži 60% ulaznih podataka i na osnovu njega se vrši podešavanje internih parametara mreže,
2. „*validation*“ skup sadrži 20% ulaznih podataka koji služe za pravovremeno zaustavljanje procesa treniranja kako bi se sačuvala osobina generalizacije,
3. „*test*“ skup sadrži preostalih 20% ulaznih podataka, koji služe za konačnu proveru utreniranosti mreže na nezavisnom skupu podataka.

Na osnovu ove tri grupe vršeno je treniranje ANN mreže, pri čemu su vrednosti ulaznih podataka najpre skalirane na opseg [-1,1].

Po završetku treniranja, za obučenu mrežu određena je greška pozicioniranja. Tom prilikom, određivani su standardni statistički parametri – srednja greška, srednja kvadratna greška, standardna devijacija, greška 95% (greška koja obuhvata 95% vrednosti), i medijan.

V. ANALIZA ČETIRI ANN MREŽE SA RAZLIČITIM PREDPROCESIRANJEM ULAZNIH VREDNOSTI

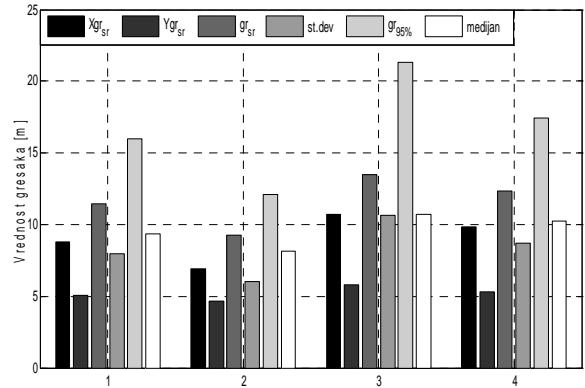
A. ANN mreža sa „sirovim“ parametrima

U okviru ovog pristupa nije uzeta u obzir prostorna orijentacija klijenta. Drugim rečima, klijent nasumično bira svoju orijentaciju (samo jednu). Iz tog razloga izabrano je da se mreža obučava za sva četiri moguća slučaja (koji se posmatraju nezavisno). Na taj način se, za treniranje mreže uzimaju izmerene ulazne vrednosti bez dopunskega predprocesiranja (u tzv. „sirovom“ obliku). Opisan pristup korišćenja ANN mreže je dao prosečne rezultate – greška nije ni najveća ni najmanja među četiri analizirana slučaja (slika 2). Ovako trenirana mreža može da se pohvali dobrim performansama s obzirom na činjenicu da je broj ulaznih podataka veliki.

B. ANN mreža sa usrednjениm parametrima – tip 1

Ovaj pristup se od prethodnog razlikuje po načinu obrade ulaznih podataka – ovde se za svaku lokaciju koriste usrednjene vrednosti, tj. za svaku RP postoji jedna vrednost nastala usrednjavanjem vrednosti RSSI signala za sve četiri orijentacije. To znači da je prostorna orientacija klijenta uzeta u obzir, na taj način što se sva četiri slučaja uzimaju kao jednakovo verovatna. Naime, upravo pomenuta situacija približno odgovara slučaju u kome bi se klijent pre estimacije svoje pozicije okrenuo oko svoje ose i izmerio usrednjene vrednosti RSSI.

Ovako trenirana mreža je dala optimalne rezultate (slika 2).



Slika 2. Poređenje funkcija grešaka za sve četiri vrste mreža.

C. ANN mreža sa usrednjenim parametrima – tip 2

I ovde se, kao i u prethodnom slučaju, u delu obučavanja mreže pojavljuju usrednjene ulazne vrednosti (za sve četiri orientacije). Razlika je jedino što se za „*test*“ skup uzimaju „sirovi“ parametri mreže iz slučaja A), na taj način što za svaku referentnu tačku RP koja pripada „*test*“ skupu postoje četiri pravobitno izmerene („sirove“) RSSI vrednosti, umesto jedne usrednjene. Praktično, ovakav pristup podrazumeva da se obučavanje sprovodi za usrednjene vrednosti, dok u primeni korisnik ne menja svoju orientaciju.

Funkcije grešaka ovog pristupa (slika 2) razlikuju se od prethodnog – one su veće od vrednosti grešaka u prethodnom slučaju. Ovo je i razumljivo s obzirom na činjenicu da se u okviru prethodnog pristupa koriste urednjene vrednosti za svaku RP, dok takvog usrednjavanja u ovom pristupu nema. Naravno, prethodni pristup zahteva kompleksniju proceduru koju korisnik treba da sproveđe tokom pozicioniranja.

D. ANN mreža sa „četvorkama“

Pristup sa „četvorkama“ koristi „sirove“ podatke (kao i pristup iz slučaja A)), ali su ovde drugačije raspoređene vrednosti u okviru „*training*“, „*validation*“ i „*test*“ skupa. Naime, kod ovog pristupa jedna lokacija sa sva četiri RSSI vektora (za svaku orijentaciju) dodeljena je istom skupu. Osnovna ideja ovog pristupa je da se u fazi formiranja modela koriste podaci prikupljeni na određenom broju RP, dok bi se određivanje pozicije radilo na drugim lokacijama.

Ovako trenirana mreža dala je veoma loše rezultate, jer je ovde tokom kros-validacije isključena mogućnost generalizacije podataka – umesto da jedna od četiri vrednosti iste lokacije pripadne „*validation*“ skupu, druga „*test*“ skupu, a preostale 2 „*training*“ skupu, ovde cela lokacija pripada isključivo jednom skupu. Zbog toga ova mreža daje lošije vrednosti (slika 2) u odnosu na mrežu sa sirovim parametrima, a takođe i u odnosu na mrežu sa usrednjениm parametrima tip 1.

TABELA 1: FUNKCIJE GREŠAKA ZA „TEST“ SKUP ZA SVE ČETIRI ANN MREŽE

„test“ skup	X_{sr_gr} [m]	Y_{sr_gr} [m]	gr_{sr} [m]	gr_{sr_kv} [m ²]	σ_s [m]	$\sigma_{95\%}$ [m]	medijan [m]
Sirovi podaci	8,7884	5,096	11,4349	194,7202	7,9977	15,9955	9,3182
Usrednjeni podaci tip1	6,9273	4,6238	9,247	121,8716	6,0303	12,0607	8,1715
Usrednjeni podaci tip2	10,726	5,7561	13,4512	294,3989	10,6519	21,3038	10,7587
Četvorke	9,8179	5,2614	12,3357	228,2189	8,7207	17,4414	10,2125

(X_{sr_gr} - absolutna srednja greška po X osi, Y_{sr_gr} - absolutna srednja greška po Y osi, gr_{sr} - srednja greška, gr_{sr_kv} - srednja kvadratna greška, σ_s - standarna devijacija, $\sigma_{95\%}$ - greška 95%, medijan)

E. Poređenje vrednosti grešaka za sva četiri pristupa

U ovom poglavlju predstavljene su dobijene vrednosti grešaka za sva četiri prethodno analizirana postupka predprocesiranja ulaznih vrednosti.

Ako se uporedi kolona za srednju grešku, vidi se da je vrednost najveća za mrežu sa usrednjениm parametrima tip 2 ($gr_{sr} = 13,4512$ m). Kao što je već rečeno, tu se i očekuje visoka vrednost greške, jer „test“ skup sadrži „sirove“ parametre, dok druga dva skupa poseduju usrednjene podatke. Očigledno je da zajedničko korišćenje „sirovnih“ i usrednjениh parametara pri obučavanju iste mreže, prouzrokuje veću varijabilnost rezultata. Preostale greške ovog pristupa takođe idu u prilog činjenici da je pristup sa usrednjениm parametrima tip 2 najneprecizniji pri rešavanju problema pozicioniranja.

Što se tiče pristupa sa „četvorkama“, on se po veličini grešaka nalazi odmah iza pristupa sa usrednjениm parametrima tip 2. Naime, ranije je pokazano da se kod ovog pristupa gubi osobina generalnosti, jer se za formiranja modela ANN mreže koriste podaci sa jednog broja RP, dok se određivanje pozicije (korišćenjem „test“ skupa) vrši pomoću drugih lokacija.

Pristup sa usrednjениm parametrima tip 1 je pokazao bolje rezultate u odnosu na pristup sa sirovim parametrima. Ova činjenica dovodi do zaključka da se ANN mreža najefikasnije trenira za slučaj kada svaka merna pozicija poseduje jednu, isključivo usrednjenu vrednost RSSI podataka. Odatle sledi da ANN mreža pokazuje stabilniji rezultat kada se prostorna orientacija klijenta uzme u obzir pri obučavanju, ali i pri korišćenju mreže. Pri tome, moramo uzeti u obzir i činjenicu da iako daje optimalne rezultate, ovaj pristup zahteva dosta kompleksnu proceduru koju korisnik treba da sproveđe tokom pozicioniranja.

VI. ZAKLJUČAK

Nad definisanom i realizovanom ANN mrežom u programskom okruženju Matlab, izvršeno je više eksperimenata u zavisnosti od načina predprocesiranja ulaznih parametara. Optimalne rezultate kod problema pozicioniranja dala je mreža koja na svakoj mernoj poziciji sadrži usrednjene RSSI vrednosti i koja na taj način vodi računa o prostornoj orientaciji mobilnog klijenta. Analize

ovih eksperimenata navode na zaključak da veštačke neuralne mreže pokazuju stabilniji rezultat prilikom korišćenja usrednjениh podataka, dok „sirovi“ parametri iskazuju osobinu veće varijabilnosti. Pored ovog, postoje i drugi načini rešavanja problema pozicioniranja (primenom različitih sistema: *Bluetooth*, RF-ID...), ali oni predstavljaju temu posebnih istraživanja.

LITERATURA

- [1] P. Prasithsangare , P. Krishnamurthy , P.K. Chrysanthis, “On indoor position location with wireless LANs”, 13th IEEE International Symposium on Personal, Indoor, and Mobile Radio Communications, PIMRC 2002.
- [2] Bill R, Cap C, Kofahl M, Mundt T, “Indoor and Outdoor Positioning in Mobile Environments”, published in: Annals of GIS, Volume 10, Issue 2 December 2004, pp. 96.
- [3] George M. Giaglis, Ada Pateli, Kostas Fouskas, Panos Kourouthanassis and Argiris Tsamakos, “On the Potential Use of Mobile Positioning Technologies in Indoor Environments”, 15 Bled Electronic Commerce Conference, Bled, Slovenia, June 17 - 19, 2002, pp 418-420.
- [4] Miloš N. Borenović, Aleksandar M. Nešković, “Positioning in WLAN environment by use of artificial neural networks and space partitioning”, Springer, 2009.
- [5] Kamran Sayrafian-Pour , Julio Perez, “Robust Indoor Positioning Based on Received Signal Strength” The Second International Conference on Pervasive Computing and Applications, ICPCA07, Birmingham, UK, July 26-27, 2007.
- [6] Mohamed H. Hassoun, “Fundamentals of Artificial Neural Networks”, MIT Press 1995.
- [7] Binghao Li , James Salter , Andrew G. Dempster and Chris Rizos, “Indoor Positioning Techniques Based on Wireless LAN” 2008.
- [8] Howard Demuth, Mark Beale, Martin Hagan, “Neural Network Toolbox™ 6 User’s Guide”, The MathWorks, Inc., 2010.
- [9] Vesna Glavonjić, „Veštačke neuralne mreže u funkciji predikcije za pozicioniranje“, Diplomski Rad, Elektrotehnički fakultet u Beogradu, jul 2010

ABSTRACT

The paper concerns four different training methods of artificial neural network in order to define the most precise indoor positioning of mobile client. The results of analysis are shown, depending on the way the input parameters were preprocessed.

ANALYSIS OF THE TRAINING METHODS OF ARTIFICIAL NEURAL NETWORK FOR INDOOR POSITIONING

V. M. Glavonjić, professor A. M. Nešković