

Predviđanje kretanja korisnika u lokacijski zavisnim uslugama

Marin Vuković

Zavod za telekomunikacije

Fakultet elektrotehnike i računarstva

Sveučilište u Zagrebu

marin.vukovic@fer.hr

Sažetak—Stalan razvoj bežičnih komunikacija, Interneta i pokretnih uređaja dovode do pojave nove generacije lokacijski zavisnih usluga. Poznavanje i korištenje konteksta korisnika prilikom pružanja usluge je osnova razvoja lokacijskih usluga. Poznavanjem kretanja korisnika i predviđanjem budućih lokacija moguće je nadograditi kontekst i na taj način povećati kvalitetu postojećih usluga, ali i omogućiti nove usluge koje bez predviđanja kretanja nisu moguće. U radu su predstavljene postojeće lokacijske usluge te prednosti koje bi predviđanje kretanja uvelo u iste. Pojašnjena je motivacija za uvođenje predviđanja kretanja i opisane su razvijene metode za predviđanje kretanja temeljene na vjerojatnosnim modelima i umjetnim neuronским mrežama.

Ključne riječi—Lokacijski zavisne usluge, kontekst, predviđanje kretanja.

I. UVOD

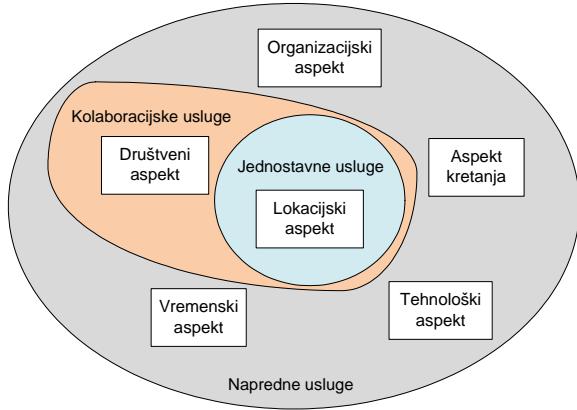
Stalan razvoj bežičnih komunikacija, Interneta i pokretnih uređaja, te njihova međusobna konvergencija, doveli su do pojave nove generacije lokacijski zavisnih usluga [24]. Kako je osnovno polazište ovakvih usluga lokacijska informacija, evolucija lokacijskih usluga je dijelom potaknuta i razvojem preciznijih metoda pozicioniranja. Mnoštvo postojećih usluga korisniku pruža informacije ovisno o trenutnoj lokaciji, no novije usluge lokaciju nadograđuju dodatnim znanjem o korisniku - poznavanjem konteksta korisnika. Kod lokacijski zavisnih usluga trenutna lokacija je temeljni aspekt konteksta korisnika uz, primjerice, društveni, organizacijski, tehnološki ili vremenski aspekt [37]. Tako, primjerice, korisnik može imati različite zahtjeve na istoj lokaciji ovisno o vremenu dana ili osobama koje su u blizini. Na usluzi je da prepozna i kontekst korisnika kako bi mu mogla pružiti odgovarajuću informaciju. Podskup lokacijskih usluga koje uzimaju u obzir kontekst nazivaju se kontekstno-svjesne usluge (*context-aware services*) [9]. Poznavanje konteksta korisnika u određenoj mjeri omogućuje predviđanje kretanja koje u lokacijske usluge unosi niz prednosti, omogućavajući nove usluge s naprednim funkcionalnostima. Najjednostavniji primjer prednosti usluge s predviđanjem u odnosu na uslugu bez predviđanja jest da usluga koja "zna" gdje će se korisnik nalaziti u određeno vrijeme može bolje pripremiti sadržaj namijenjen budućoj lokaciji, jer za to ima više vremena, za razliku od usluge koja sadržaj mora pripremiti i dostaviti u stvarnom vremenu, ako je isti vezan uz trenutnu lokaciju korisnika.

Smatramo da je predviđanje kretanja jedan od glavnih čimbenika koji mogu povećati kvalitetu postojećih usluga te omogućiti nove, napredne lokacijske usluge. Iz tog je razloga svrha ovog rada dati pregled metoda za predviđanje kretanja korisnika, te pokazati kako lokacijske usluge koriste, ili bi mogle koristiti, predviđanje u svrhu povećanja kvalitete usluge. U drugom poglavljju su prikazane postojeće lokacijske usluge, razvrstane po složenosti, te su navedene prednosti primjene predviđanja kod tih usluga. Treće poglavljje pokazuje moguće primjene i motive za uvođenje predviđanja, koje ne moraju biti vezane isključivo uz lokacijske usluge. Konačno, u četvrtom i petom poglavljju se opisuju konkretne metode kojima se predviđa kretanje korisnika. Četvрто poglavljje se bavi metodama zasnovanim na parametrima kretanja korisnika, a u petom poglavljju su predstavljene metode čije je predviđanje temeljeno na znanju o prethodnom kretanju korisnika.

II. LOKACIJSKI ZAVISNE USLUGE

Lokacijske usluge nove generacije više ne koriste samo trenutnu lokaciju korisnika kao glavno sredstvo za pružanje usluge, nego grade znanje o korisniku na različite načine, sa ciljem da usluga bude u mogućnosti prepoznati korisnički kontekst. Kontekst je definiran kao "*bilo koja informacija koja se može iskoristiti kako bi opisali stanje u kojem se entitet nalazi*" [13]. Kao što smo već naveli, kontekst može imati više aspekata kao društveni, organizacijski ili lokacijski aspekt. Iz navedenog je očito da samo jedan od ovih aspekata ne može graditi kontekst koji će biti upotrebljiv i zato je čistu lokacijsku informaciju potrebno proširiti dodatnim znanjem o korisniku. Temeljno obilježje lokacijskih usluga je lokacijski aspekt, odnosno lokacijska informacija, koju usluga može dobiti različitim metodama, a međusobno se razlikuju prema preciznosti i potrebnoj mrežnoj infrastrukturi. Važnost ostalih aspekata ovisi o traženoj funkcionalnosti usluge, a informacije svojstvene tim aspektima se najčešće prikupljaju senzorskim mrežama, praćenjem navika korisnika, pa i intervencijama od strane samog korisnika.

U svijetu postoji mnoštvo lokacijskih usluga kao i kriterija po kojima se razlikuju. Kako je težište ovog rada orijentirano naprednjim uslugama koje ovise o korisniku, odnosno poznavaju kontekst, odlučili smo se za podjelu prema složenosti usluga, sličnu kao kod [36] i [4], ali po složenosti u smislu poznavanja



Slika 1. Podjela usluga prema poznavanju korisničkog konteksta

korisničkog konteksta. Ovakva podjela je prikazana na slici 1. Prema tome, usluge mogu biti:

- Usluge bez poznavanja korisničkog konteksta (Jednostavne usluge)
- Usluge sa naglašenim društvenim aspektom korisničkog konteksta (Kolaboracijske usluge)
- Usluge sa poznavanjem više aspekata konteksta (Napredne lokacijske usluge)

A. Jednostavne usluge

Jednostavne lokacijske usluge informaciju koju pružaju korisnicima zasnivaju samo na temeljnom aspektu korisničkog konteksta - lokacijskom. Primjer ovakve usluge jest usluga koja pozive naplaćuje ovisno o lokaciji korisnika. Operatori pokretnе mreže koriste takvu uslugu kako bi korisnicima, primjerice, omogućili jeftinije pozive iz ureda nego iz mjesta stanovanja [52]. Možda i najpoznatija lokacijska usluga je usluga lociranja korisnika pri hitnom pozivu na broj 112. Česte su primjene lokacijskih usluga u turizmu, gdje aplikacija na pokretnom uređaju zamjenjuje turističkog vodiča. Usluge te vrste su *CyberGuide*, koja turistima pruža informacije vezane uz njihovu lokaciju i orientaciju u prostoru ([31]), te *CityMap* koja turistima na pokretnom uređaju prikazuje njihovu lokaciju na karti, te im po potrebi nudi informacije o obližnjim hotelima, restoranima i slično [5]. Lokacijske usluge ne moraju nužno biti namijenjene samo otvorenim prostorima, pa postoje i usluge kao *C-Map*, koja vodi korisnike kroz izloške u muzejima [4]. Kao i ostale lokacijske usluge, i najjednostavnije se međusobno razlikuju po preciznosti lociranja korisnika, koja ovisi o namjeni usluge. Jasno je da, primjerice usluga *C-Map* mora biti vrlo precizna u lociranju kako bi mogla pružiti odgovarajuću informaciju posjetiteljima muzeja, no neke usluge ne zahtijevaju visoku razinu preciznosti, kao primjerice usluga opisana u [55]. U toj se usluzi korisnicima dostavljaju informacije o vremenskoj prognozi i stanju na cestama, a korisnička lokacija je određena čelijom u kojoj se korisnik nalazi. Prema tome, možemo zaključiti da preciznost lociranja ovisi o namjeni usluge i sadržaju koji treba dostaviti. Navedenim uslugama je zajedničko da imaju predefiniran

sadržaj koji odgovara pojedinoj lokaciji, ali uopće ne ovisi o profilu korisnika.

Možemo uočiti prednosti koje bi postojanje mogućnosti predviđanja uvelo u navedene usluge. Kada bi bilo koja od ovih usluga imala mogućnost predviđanja, najmanja prednost bi bila što bi sadržaj mogla pripremiti unaprijed, čime bi bila osigurana stvarnovremenska dostava sadržaja. Daljnje prednosti ovise o namjeni usluge, pa tako kod navedenih turističkih usluga možda predviđanje kretanja nema neku jasnu primjenu, ali bi, primjerice, moglo uvelike pridonijeti kvaliteti usluge opisane u [55]. Kada bi takva, i slične jednostavne usluge, mogle predvidjeti buduće lokacije korisnika, mogle bi unaprijed dostaviti sadržaj vezan uz buduće lokacije, što bi bilo korisno ako se korisniku dostavljaju, kao u usluzi, informacije o stanju u prometu.

B. Kolaboracijske usluge

Kolaboracijske lokacijske usluge su možda i najraširenije lokacijske usluge, a u pravilu uz lokacijski aspekt koriste i društveni. Naravno, to ne znači da neke od njih nemaju daleko naprednije znanje o korisniku kojim bi zapravo pripadale skupini naprednih usluga, ali su posebno izdvojene upravo zbog naglašenog društvenog aspekta i temeljima u suradnji korisnika usluge. Kolaboracijskih usluga ima jednostavnijih i složenijih, a njihova složenost ovisi o količini znanja o korisniku ili korisnicima usluge. Primjer jednostavne kolaboracijske usluge jest *Augmented Reality* [48] u kojoj korisnici fizičkim lokacijama pridjeljuju digitalan sadržaj u obliku slika ili glasovnog zapisa, koji se pohranjuje, nakon čega ga ostali korisnici usluge mogu pregledavati kada se nađu na istoj lokaciji. Nešto naprednija usluga je "*Location-aware event planner*" [44], u kojoj je omogućena organizacija događaja ovisno o lokaciji korisnika usluge i lokacijama osoba koje je korisnik označio kao prijatelje. Kod te je usluge, uz lokacijski, bitan i društveni aspekt konteksta korisnika, koji on gradi vlastitom intervencijom - označavanjem pojedinaca kao prijatelja. Primjeri kako lokacijska informacija može donijeti dodatnu vrijednost su lokacijski zavisne igre "*Can you see me now?*" Sveučilišta u Nottinghamu [6] i "*Human pacman*" [10]. Napredna kolaboracijska usluga je *Social Net*, opisana u radu [53], kojom se pokušava povezati ljudi sa sličnim interesima. Za svakog korisnika usluge se zapisuje kretanje u određenom vremenskom intervalu nakon čega se uzorci kretanja korisnika uspoređuju. Glavno načelo usporedbe i zaključivanja je blizina dvaju ili više korisnika, te vremenski interval u kojem su korisnici bili unutar definiranog radiusa.

I kod kolaboracijskih usluga možemo uočiti prednosti uvođenja predviđanja kretanja. Većina opisanih usluga se zasniva na informacijama koje korisnik prethodno upisuje ili ih mreža uočava, i na taj način se gradi mreža poznanika. No, predviđanjem kretanja bi uveli dodatnu kvalitetu u uslugu, jer bi se korisnika moglo unaprijed obavijestiti da će, primjerice sutra u određeno vrijeme biti blizu određenog prijatelja. Ovakva funkcionalnost je moguća jedino ako se može predvidjeti kretanje i korisnika i prijatelja.

C. Napredne lokacijske usluge

U napredne usluge smo uvrstili usluge koje poznaju više aspekata korisničkog konteksta. Usluga sa potencijalnom širokom primjenom je "comMotion", u kojoj korisnik posjeduje agenta čiji je zadatak uočiti česte lokacije na kojima se korisnik zadržava [36]. Nakon što agent "nauči" česte lokacije korisnik može lokacijama dodijeliti zadaće, a uloga agenta je podsjećati korisnika na definirane zadaće kada se korisnik nađe na određenoj lokaciji. Međutim, ova usluga nema mogućnost predviđanja kretanja korisnika, pa će korisnik biti obaviješten o svojim zadaćama tek kada dođe na zadanoj lokaciju, što se može pokazati lošim ako korisnik putuje većom brzinom (automobilom, javnim prijevozom) i upravo prolazi kroz lokaciju. Funkcionalnost usluge bi bila bolja kada bi se korisnika o zadaćama obavijestilo prije dolaska na lokaciju. Općenito, kod ove i sličnih usluga, predviđanje kretanja bi se moglo koristiti u svrhu podsjećanja korisnika na neke zadatke, događaje i slično. Zanimljiva je i primjena predviđanja kretanja na usluge koje se bave pojmom "inteligentno ometanje". Taj pojam podrazumijeva poznavanje konteksta korisnika u kojem ga se smije ili ne smije ometati, primjerice uključivanjem alarma na pokretnom uređaju, pozivima ili porukama. U radu [20] je izloženo kako je vrlo teško sigurno odrediti kada se korisnika smije a kada ne smije ometati. Međutim, kada bi se moglo utvrditi kada korisnika ometati a kada ne, predviđanjem kretanja bi korisnika mogli upozoravati da ugasi ili stiša pokretni uređaj. Također, kada bi korisnik napustio određenu lokaciju definiranu za neometanje, sustav bi to mogao zabilježiti i, primjerice, obavijestiti korisnika o propuštenim pozivima u vremenu nedostupnosti.

III. MOTIVI I PRIMJENE PREDVIĐANJA KRETANJA KORISNIKA

U prethodnim poglavljima je bilo govora o lokacijskim uslugama, koje smo podijelili po složenosti. Utvrđeno je da složenost pridonosi kvaliteti i korisničkom dojmu, a isti su uvjetovani poznavanjem konteksta korisnika. Smatramo da predviđanje kretanja u lokacijskim uslugama može itekako pridonijeti kvaliteti, odnosno poznavanju konteksta korisnika, pa smo se orijentirali upravo na predviđanje kao sredstvo za poboljšanje kvalitete usluge. Predviđanjem kretanja u uslugu se uvodi mogućnost proaktivnog djelovanja; usluga može unaprijed odrediti što i kada će korisnik htjeti, u odnosu na reaktivno djelovanje klasičnih usluga [37]. U narednim poglavljima će biti opisane metode predviđanja kretanja i postojeće primjene. Naime, iako u okviru ovog rada govorimo o lokacijskim uslugama, predviđanje kretanja ima još jednu značajnu i rašireniju primjenu. Prema tome, primjene možemo podijeliti na:

- Predviđanje kretanja u lokacijskim uslugama
- Predviđanje kretanja s ciljem smanjivanja troškova upravljanja lokacijom

Iako se ovaj rad bavi primjenom predviđanja kretanja na lokacijski zavisne usluge, najčešća primjena predviđanja ima cilj smanjiti troškove upravljanja lokacijom i najviše radova je

napravljeno upravo na tom području. Iako navedene primjene nemaju bitnih razlika u funkcionalnosti, uočeno je kako se bitno razlikuju u lokacijskoj informaciji s kojom raspolažu, što je i očekivano. Naime, lokacijske usluge u pravilu raspolažu s preciznjom lokacijskom informacijom, jer korisnik, primjerice, može koristiti GPS navigaciju. S druge strane, primjena predviđanja u svrhu smanjivanja troškova upravljanja lokacijom nema toliko preciznu lokacijsku informaciju jer se najčešće oslanja samo na mrežne resurse. Zato se kod potonje primjene rukuje s lokacijskom informacijom reda veličine lokacijskog područja LA (*Location area*), ćelije (CID - *Cell identification*), ili nešto manje u slučaju da mreža ima mogućnost faktorizacije ćelije ili triangulacije OTD metodom (*Observed Time Differential*). Kako predviđanje u svrhu smanjenja troškova ne spada u temu ovog rada, motivacija za takva istraživanja će biti samo ukratko pojašnjena, dok će metode biti detaljnije razrađene jer se po funkcionalnosti ne razlikuju od metoda za predviđanje kod lokacijskih usluga.

A. Predviđanje kretanja u lokacijskim uslugama

Spomenuli smo da je razlika među primjenama u preciznosti lokacijske informacije, ali bitno je napomenuti da je, analogno preciznosti lokacijske informacije, i predviđena lokacija preciznija. Naime, ako usluga raspolaže sa GPS (*Global Positioning System*) pozicijom korisnika onda će najčešće predvidjeti i buduću lokaciju sličnom preciznošću. Još jedna razlika između dviju navedenih primjena jest u načinu na koji se predviđanje ostvaruje. U narednom poglavljju ćemo razmotriti metode predviđanja, od kojih su neke općenitije a neke specifične korisniku. U svrhu predviđanja kretanja kod lokacijskih usluga se najčešće koriste metode koje su specifične korisniku, a to su metode koje se baziraju na "znanju" koje je prethodno naučeno praćenjem kretanja korisnika i uočavanjem regularnosti. Nasuprot tome, kod predviđanja u svrhu smanjenja troškova, koriste se i manje precizne metode koje mogu biti primjenjive na grupu korisnika sa sličnim kretanjem. Ovakav pristup je osmišljen zbog velikog broja korisnika, no preciznost predviđanja je u ovom slučaju nešto niža nego kod metoda namijenjenih jednom korisniku.

B. Predviđanje kretanja s ciljem smanjivanja troškova upravljanja lokacijom

U pokretnim mrežama kod dolaznog poziva mreža mora znati gdje taj poziv treba usmjeriti, odnosno mora znati gdje se korisnik kojem je poziv namijenjen nalazi. Proces utvrđivanja lokacije korisnika se naziva upravljanje lokacijom (*Location management*), a sastoji se od dvije osnovne faze: osvježavanje lokacije korisničkog terminala i dostava poziva [45]. Općenito, pokretna mreža se sastoji od ćelija koje su definirane vlastitom baznom stanicom BTS (*Base transceiver station*) i područjem oko bazne stanice. Skup baznih stanica unutar jednog BSC-a (*Base station controller*) čini lokacijsko područje LA, odnosno RA (*Routing area*). Prilikom dolaznog poziva, registar korisnika HLR (*Home location register*) zna u području kojeg VLR-a (*Visitor location register*) se nalazi korisnik, a VLR zna u području kojeg MSC-a (*Mobile switching center*) bi korisnik

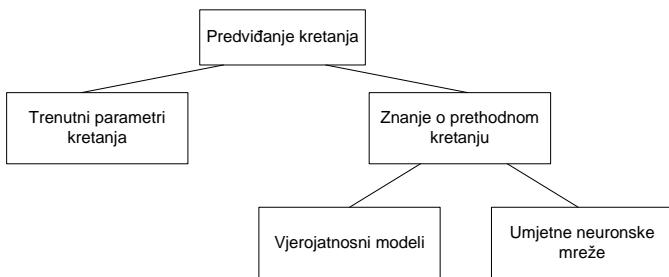
trebao biti [14]. No, bez dodatnih mehanizama, MSC nema informaciju u kojoj je ćeliji korisnik. Najjednostavniji način pronalaženja korisnika jest da ga se traži u svim ćelijama nadležnog MSC-a, što se pokazalo iznimno skupim u smislu iskorištavanja mrežnih resursa [12]. Mrežni resursi bi bili najbolje, odnosno minimalno, iskorišteni kada bi mreža znala točnu lokaciju korisnika, što bi se moglo postići redovnim osvježavanjem zapisa o lokaciji (*update*). Tada bi korisnik, odnosno njegov pokretni uređaj, svaki put kada promijeni ćeliju trebao o tome obavijestiti nadležni registar. Naravno, i ovo će generirati puno prometa i ponovno povećati zauzetost mrežnih resursa [32]. Iz navedenih razloga se uvode metode kojima bi se moglo predvidjeti kretanje, za ovu primjenu najčešće, grupe korisnika.

IV. METODE ZA PREDVIĐANJE KRETANJA KORISNIKA

Prema [47]) postoje dva koncepta predviđanja kretanja, koji se razlikuju posjedovanjem znanja o korisniku:

- Predviđanje kretanja na osnovu trenutnih parametara kretanja
- Predviđanje kretanja na osnovu prethodnog kretanja

Predviđanje kretanja korištenjem trenutnih parametara kretanja podrazumijeva predviđanje u stvarnom vremenu, bez prethodnog znanja o korisniku. Znanje o korisniku je, naprotiv, osnova predviđanja kretanja kod drugog koncepta. Uz njih, postoje i hibridna rješenja koja su dosta rijetka, a predviđanje ostvaruju prethodnim znanjem o korisniku potpomognutim sa trenutnim kretanjem korisnika. Podjela metoda za predviđanje kretanja prikazana je na slici 2, a po toj hijerarhiji će biti i opisana u narednom tekstu, gdje će biti prikazane neke od metoda koje se temelje na ovim konceptima.



Slika 2. Podjela metoda za predviđanje kretanja

A. Predviđanje kretanja na osnovu trenutnih parametara kretanja

Kod metoda predviđanja kretanja korištenjem trenutnih parametara kretanja pretpostavlja se da mreža ima mogućnost očitavanja parametara kretanja korisnika kao što su brzina i smjer. Jedan primjer ove metode prikazan je u [21], gdje se očitavaju trojke (*brzina, udaljenost, smjer*) u realnom vremenu i na osnovu proračuna se predviđa odredište korisnika. Slična metoda se koristi i u [18], gdje se predviđanje radi u svrhu rezervacije kanala. Pri tome je bitno i vrijeme dolaska korisnika u buduću ćeliju, kako bi se resursi mogli rezervirati, pa se, uz odredišnu ćeliju, predviđa i interval u kojem se

očekuje da korisnik uđe u sljedeću ćeliju. Nešto složenija metoda je prikazana u [11]; ovdje se prepostavlja da se korisnik kreće ulicom i ima GPS uređaj koji šalje podatke sustavu za predviđanje. Zbog prepostavke da se korisnik kreće ulicom je moguće preciznije predviđanje lokacije jer korisnik nema puno mogućih smjerova kojima se može kretati. No, u slučaju da se korisnik ne kreće ulicom, predviđanje može imati veliku pogrešku. Svakoj ćeliji je dodijeljena karta pripadajućih ulica na kojoj se predviđanje temelji pa sustav na osnovu dvije prethodne lokacije u definiranom vremenskom periodu zaključuje kuda se korisnik kreće i predviđa odredište. Ova metoda spada u kategoriju RTB (*Road topology based*) metoda, kojima je zajedničko da predviđanje vrše na temelju topologije ulica, čime ograničavaju kretanje korisnika i time pojednostavljaju samo predviđanje. Naravno, manu ove i sličnih metoda, kao u [56] i [57] je u tome što se kretanje ne može predvidjeti ako se korisnik ne kreće ulicom.

Korištenje trenutnih parametara kretanja za predviđanje ima svojih prednosti i mana. Glavna prednost je to što sustav ne mora znati ništa o korisniku unaprijed, pa nije potrebno ni dugotrajno skupljanje podataka o korisniku, što ih čini bitno jednostavnijima od metoda zasnovanih na poznavanju prethodnog kretanja korisnika. Najveći nedostatak takvih metoda jest što ne mogu predvidjeti kretanje za duži vremenski interval nego mogu predvidjeti samo sljedeću lokaciju, s obzirom da nemaju nikakvo znanje o korisniku. Drugi nedostatak jest što pretpostavljaju da mreža ima mogućnost očitavanja smjera i brzine što ne mora biti slučaj. Da bi mreža mogla mjeriti brzinu i smjer korisnika potrebno je ugraditi dodatne elemente u pristupnu mrežu, koji se općenito nazivaju entiteti za mjerenje lokacije LMU (*Location measurement units*). Uvođenje dodatnih entiteta u pokretnu mrežu može biti skupo, a i mreža se dodatno opterećuje, pa je upitna isplativost takve investicije. Posljednji nedostatak ovakvih metoda se pokazuje u obradi podataka i proračunu koji mogu biti vremenski dugotrajni, što može biti kritično zbog činjenice da se predviđanje izvodi u stvarnom vremenu.

B. Predviđanje kretanja na osnovu prethodnog kretanja

Predviđanje kretanja na osnovu prethodnog kretanja podrazumijeva "znanje" o prethodnom kretanju. Većina postojećih metoda se bazira na ovom konceptu, pa tako i postoji najviše različitih pristupa učenju o kretanju korisnika. Osnovna postavka ovog koncepta je regularnost kretanja korisnika: "*Kretanje korisnika je regularno ako se ponavlja u određenom vremenskom intervalu*" [24]. Ako se korisnik ne kreće regularno, nije moguće predvidjeti buduće lokacije sa dovoljnom sigurnošću. Ipak, nekoliko studija o kretanju korisnika pokazalo je da većina korisnika pokazuje određenu razinu regularnosti u kretanju [50] [27] [51] [41]. Tako je, primjerice, u [50] praćeno kretanje korisnika tijekom 6 tjedana i zaključeno je da većina korisnika ima naviku ići istim putem između dviju lokacija u visokih 70 posto slučajeva. Kako se svi korisnici ne kreću regularno u istoj mjeri, mnoge usluge definiraju klase korisnika prema regularnosti kretanja. Tako, primjerice, autori [45] i [43] korisnike dijele u tri

skupine: na one za koje se kretanje može predvidjeti s visokom vjerojatnošću, na one čije se kretanje u većini slučajeva može predvidjeti i na one čije se kretanje ne može predvidjeti s dovoljnom sigurnošću da bi bilo upotrebljivo.

V. PREDVIĐANJE KRETANJA NA OSNOVU PRETHODNOG KRETANJA

Metode bazirane na ovom konceptu se obično provode u dvije faze: prva je skupljanje uzoraka kretanja i interpretacija, a druga predviđanje. Skupljanje uzoraka se izvodi na nekoliko načina - zapise o kretanju može pohranjivati mreža, pokretni uređaj ili vanjski poslužitelj. No, najvećim izazovom se pokazala interpretacija skupljenih uzoraka, i upravo u tome je najveća razlika postojećih metoda zasnovanih na ovom konceptu. Pravilnom interpretacijom uzorka stječe se znanje koje se zatim može primijeniti na predviđanje kretanja, koje također može biti izvedeno na nekoliko načina a uglavnom ovisi o načinu interpretacije uzorka. Termin "analiza" i "interpretacija" uzorka koje koristimo u kontekstu predviđanja kretanja pripadaju problematici dubinske analize podataka (*Data mining*). Dubinska analiza podataka je područje sa širokom primjenom, a glavno obilježje metoda ovog područja jest mogućnost izdvajanja bitnih podataka iz velike količine podataka. Iz tog razloga mnoge metode iz područja dubinske analize podataka, s različitom prvotnom namjenom, mogu biti primjenjene na analizu uzorka kretanja. Metode za analizu i interpretaciju uzorka te predviđanje kretanja se mogu temeljiti na:

- Vjerojatnosnim modelima
- Umjetnim neuronskim mrežama

U natavku ćemo pokazati neke od metoda i njihov pristup interpretaciji uzorka i predviđanju.

A. Vjerojatnosni modeli

Mnogi istraživači zapisane uzorke analiziraju i interpretiraju vjerojatnosnim modelima. Pod vjerojatnosnim modelima podrazumijevamo sve metode koje nisu temeljene na umjetnim neuronskim mrežama, a najčešće se temelje na statističkoj analizi snimljenih uzorka. Kada se uoče vjerojatnosti kretanja korisnika pomoću njih se najčešće grade matrice prijelaza ili Markovljevi lanci.

Jedan od tipičnih primjera vjerojatnosnih modela je opisan u [24]. Ovdje se gradi matrica vjerojatnosti čije vrijednosti $P(R1|R2)$ predstavljaju vjerojatnost prelaska korisnika na lokaciju $R2$ ako se nalazi na lokaciji $R1$, slično kao i kod [49]. Navedena metoda se koristi za RTB usluge, opisane u prethodnom poglavljju, koje podrazumijevaju kartu cesta, pa $R1$ i $R2$ zapravo predstavljaju moguće smjerove, a ne lokacije. Pozicija korisnika se određuje GPS uređajem pa je pozicioniranje vrlo precizno što je logično obzirom da je potrebno prepoznati kojom ulicom se korisnik kreće. Predviđanjem smjerova po ulicama je metoda bitno pojednostavljena, ali se isti model može proširiti i na lokacije, s tim da bi tada matrica prijelaza bila znatno veća, što bi moglo utjecati na brzinu predviđanja i složenost cijele metode. Nakon popunjavanja matrice prijelaza, usluga može predviđati kretanje korisnika, koje je dobro

osmišljeno. Očitava se trenutna lokacija korisnika, prosječna brzina kretanja i smjer, a predviđanje se radi za vremenski interval koji ovisi o brzini korisnika, na način da će interval biti veći ako se korisnik kreće brže. Time je smanjen broj mogućih destinacija korisnika, jer se iz karte cesta može zaključiti do kojeg najdaljeg odredišta korisnik može stići u definiranom intervalu. No, kod ove metode se razmatraju osnovni parametri kretanja - brzina i smjer, dok se o kontekstu korisnika ne zna ništa drugo. Zato je metoda naknadno proširena uvođenjem dodatnog znanja o korisniku u predviđanje [30]. Sada se prilikom predviđanja uzimaju u obzir vrijeme i dan kretanja, kako bi se poboljšalo predviđanje koje, između ostalog, može ovisiti i o vremenu dana (kretanje na posao i s posla), te o danu u tjednu (različiti putovi tijekom radnog dana i vikenda).

Metoda opisana u [4] radi sa GPS podacima kao i prethodno opisana ali predviđa lokacije i ne koristi kartu cesta. Posebnost ove metode je da GPS poziciju korisnika preslikava na određenu lokaciju; s tim da je svaka lokacija krug radijusa pola milje (oko 800 metara). Na taj način se omogućuje predviđanje lokacija a ne GPS koordinata. Po našem mišljenju, GPS koordinate bi bilo izrazito teško predvidjeti, s obzirom na količinu podataka i nesigurnost predviđanja uzrokovanu preciznošću GPS sustava, tako da je preslikavanje koordinata na lokacije dobra ideja. Nadalje, metodom se određuju najčešće lokacije, odnosno skupine GPS koordinata (*clusters*), kojima se pridjeljuje značenje - primjerice: dom, fakultet i slično. U terminologiji ove usluge takve lokacije se nazivaju podlokacije (*sublocations*). Nakon toga se računaju vjerojatnosti prelaska između lokacija, odnosno podlokacija, i izvode se Markovljevi lanci prvog (za dvije lokacije) i drugog reda (za tri uzastopne lokacije). Autori smatraju da nema potrebe za lancima višeg reda jer u zapisanim kretanjima najčešće nema puno takvih prijelaza sa dovoljno visokom vjerojatnošću. Problem kod ove metode jest određivanje optimalnog radijusa lokacije; pola milje je dovoljno malo za potrebe predviđanja kretanja, primjerice, na razini grada, ali je daleko previše za predviđanje lokacija na sveučilišnom kampusu.

Postoje mnogi primjeri primjene dubinske analize podataka na predviđanje kretanja korisnika [59]. Tako [17] uvodi novi pojam: BBS (*behavior-based strategy*). BBS je metoda kojom se želi smanjiti količina prometa prilikom dolaska poziva (*paging*), pomoću predviđanja kretanja. Princip predviđanja je sličan ostalim uslugama iz ovog područja: u zapisima o kretanju se uočava regularnost na temelju koje sustav predviđa u kojem području će se korisnik nalaziti da bi mu mogao dodijeliti resurse. Metoda opisana u [59] radi na sličnom principu, ali ne predviđa buduće lokacije, nego samo kretanje, odnosno prijelaze između cilja. Ovdje su autori nadogradili vlastite modele opisane u [1] i [2], koji su predviđali korisnički pristup pokretnom Internetu i dokumentima, kako bi mreža mogla unaprijed rezervirati ili čak lokalno pohraniti stranice ili dokumente koje će korisnik pregledavati u skoroj budućnosti. Taj model je proširen mogućnošću predviđanja kretanja korisnika, na način da su, uz uzorke spajanja na Internet i dohvatanja stranica, u analizu uključene i lokacije na kojima se korisnici nalaze u trenutku dohvatanja stranica. Analiza

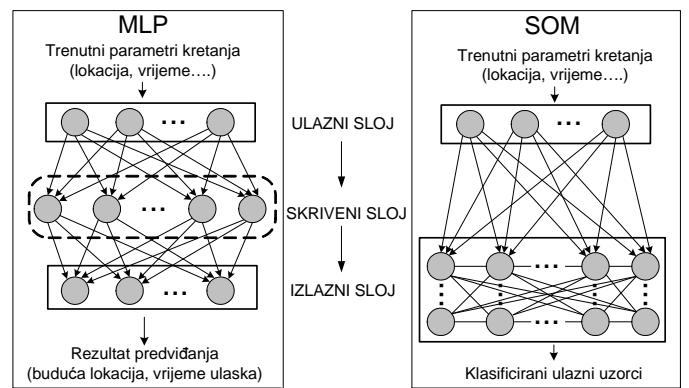
prikupljenih uzoraka se temelji na mehanizmu "sequential pattern mining" koji je detaljno opisan u [46], a najčešće se koristi za analizu podataka pohranjenih u zapisima web sjedišta [22], [39], [60]. Autori su u [54] izložili vlastiti algoritam *SMAP-Mine*, sa sličnom funkcionalnošću kao kod prethodno opisane metode. Ovdje se sekvencijalni uzorci nazivaju "sequential mobile access patterns" (SMAP), iz kojih se analizom dobivaju SMAP uzorci sa visokom vjerojatnošću pojavljivanja ili FSMAP (od "frequent SMAP"). Uzorcima FSMAP se gradi stablo kojem grane predstavljaju prijelaze između lokacija, po vjerojatnosti prijelaza uočenoj u analizi uzorka. Na sličnoj funkcionalnosti se temelji metoda opisana u [12]; ovdje se također gradi stablo, s granama čije težine odgovaraju vjerojatnostima prelaska u određeno lokacijsko područje. Model je hijerarhijski jer stablo preslikava topologiju mreže, odnosno hijerarhiju mrežnih entiteta HLR, MSC i ćelija. Tako primjerice težina grane između MSC-a i ćelije odgovara vjerojatnosti da korisnik prijeđe u tu ćeliju dok je u području nadležnog MSC-a.

Zanimljiv pristup predviđanju kretanja prikazan je u [7]. Autori ukazuju na analogiju informacije u poruci i informacije u zapisu o kretanju korisnika, pa se metode za analizu količine informacije poruke primjenjuju na zapise o kretanju. Ideja autora je kretanje korisnika gledati kao poruku, s tim da slijedne lokacije čine niz slova koja odgovaraju svakoj lokaciji. No, najveći doprinos ove metode jest korištenje kompresije. Metoda kojom se poruka komprimira mora moći predvidjeti buduće znakove u poruci kako bi bila u stanju izvršiti kompresiju. Ako sadržaj poruke odgovara lokacijama, kao što je ovdje slučaj, analizom komprimirane poruke moguće je predvidjeti kretanje korisnika; to će biti oni nizovi znakova koji se najčešće pojavljuju u nekomprimiranoj poruci, odnosno oni posebno istaknuti u komprimiranoj poruci. Sličan pristup koriste autori u metodama opisanim u [32] i [33], u kojima se bave problemom pronalaženja korisnika prilikom dolaznog poziva i/ili registracije. Zapis o kretanju korisnika se tretira kao rečenica koja se sastoji od uzastopnih lokacija identificiranih brojevima. Optimalnim kodiranjem te rečenice dobivaju se vjerojatnosti za pojedine lokacije, pa na taj način usluga može sa određenom vjerojatnošću pretpostaviti da će se korisnik nalaziti na određenoj lokaciji.

B. Umjetne neuronske mreže

Umjetne neuronske mreže se često primjenjuju u svrhu raspoznavanja uzorka pa su zato prikladne i za analizu uzorka prikupljenih zapisivanjem kretanja korisnika, čime se omogućuje predviđanje kretanja. Njihova glavna prednost je sposobnost razlučivanja odnosa između složenih uzorka, koje bi čovjek ili druga metoda teško mogli uočiti [45]. Umjetna neuronska mreža se, općenito, sastoji od ulaznog, skrivenog i izlaznog sloja, s tim da postoje arhitekture u kojima nema skrivenog sloja, ali i one kod kojih postoji više skrivenih slojeva. Svaki sloj se sastoji od neurona, osnovne građevne jedinice mreže, koji su međusobno povezani granama. Neuron radi na način da ulaznu funkciju x pretvara u vrijednost y prema nelinearnoj funkciji $F(X)$ [23], [19],

[29]. Kod sustava sa umjetnim neuronskim mrežama uvijek postoje dvije faze: učenje uzorka i primjena. Učenjem mreža uočava specifičnosti u svakom uzorku na temelju kojih ih međusobno razlikuje, a u fazi primjene klasificira uzorce. Postoji puno podjela neuronskih mreža, a u kontekstu ovog rada ih dijelimo na mreže sa nadgledanim učenjem i mreže sa nenadgledanim učenjem. Nadgledano učenje je učenje kod kojeg razvijatelj mreže u fazi učenja definira koji ulazi odgovaraju kojim izlazima mreže. Tada će mreža raditi na način da za definirani ulaz aktivira definirani izlaz. No, prednost umjetnih neuronskih mreža jest sposobnost generalizacije što znači da će spomenuta mreža davati izlaze i za uzorce koji nisu bili uključeni u učenje, ovisno o njihovoj sličnosti sa uzorcima uključenim u učenje. Primjeri mreža sa nadgledanim učenjem su MLP (multi-layer perceptron) i rekurentne arhitekture mreža. Nenadgledano učenje podrazumijeva da mreža sama definira izlaze, odnosno aktivira skupine neurona u izlaznom sloju ovisno o uzorku na ulazu. Ovakva mreža će za slične ulazne uzorke aktivirati bliske (susjedne) neurone, dok će za različite ulaze aktivirati potpuno različite neurone izlaznog sloja. Primjer arhitekture sa nenadgledanim učenjem jest samoorganizirajuća mapa ili SOM (self-organizing map). Nadgledano učenje se koristi kada znamo što želimo postići u smislu klasifikacije ulaznih uzorka, odnosno kada želimo stvoriti vlastite grupe uzorka. Nenadgledano učenje se najčešće koristi za razlikovanje ulaznih uzorka samo po njihovim karakteristikama, bez dodatne klasifikacije koju bi mogli uvesti u slučaju nadgledanog učenja. Na slici 3 su prikazane dvije najčešće korištene arhitekture umjetnih neuronskih mreža sa nadgledanim i nenadgledanim učenjem i njihovi tipični ulazi i izlazi kod primjene na predviđanje kretanja. Potrebno je naglasiti da, prilikom razvoja sustava s neuronskim mrežama, nije dovoljno odabratи arhitekturu mreže koja će se koristiti, nego je i vrlo bitno kako će se uzorci, prikupljeni iz stvarnog svijeta, preslikati na ulaz mreže i u kojoj će mjeri uzorci slični u stvarnom svijetu biti slični i neuronskoj mreži.



Slika 3. Primjeri mreža sa nadgledanim i nenadgledanim učenjem i njihovi tipični ulazi i izlazi kod primjene na predviđanje kretanja

Jedna od najpoznatijih i najcitatirajih metoda predviđanja kretanja neuronskom mrežom koristi nadgledano učenje,

odnosno MLP mrežu, a prikazana je u [45]. Autor, slično kao i [43], korisnike svrstava u tri kategorije prema regularnosti kretanja, te na temelju toga odlučuje da li je uopće moguće predviđjeti kretanje korisnika i s kojom vjerojatnošću. Nakon zapisivanja korisničkog kretanja, mreže se uče BP (*Backpropagation*) algoritmom za svaki dan u tjednu, i stvaraju se profili korisnika koji u ovom kontekstu podrazumijevaju navike u kretanju tokom jednog dana. Ako se korisnik, primjerice, svaki radni dan kreće jednakim putovima, a vikendom različitim, onda će za njega postojati dva profila. Nakon učenja, mreža predviđa u kojoj će cilji korisnik biti u koje vrijeme, tako da izlazi neuronske mreže predstavljajuće ciljeve, vjerojatnost i vrijeme u koje bi korisnik trebao biti u tim ciljama prema uzorcima iz faze učenja, uz ovisnost o profilu kretanja. Ciljana primjena ove metode jest smanjivanje troškova upravljanja lokacijom, što je opisano u trećem poglavljju. Autori rada [38] koriste vrlo sličnu metodu u svrhu predviđanja kretanja korisnika po kući, kako bi se mogla optimizirati potrošnja energije, a isti cilj ima i metoda opisana u [25]). Nešto drugačija je metoda opisana u [8]. Ovdje se za predviđanje kretanja također koristi umjetna neuronska mreža, ali se proces skupljanja podataka i uočavanja "čestih" lokacija provodi na pokretnom uređaju, koji nakon zapisivanja i analize kretanja podatke prosljeđuje sustavu za predviđanje temeljenom na neuronskoj mreži. Glavna zamjerka ovakvom pristupu je u činjenici da se kod složenih operacija oslanja na pokretni uređaj male procesorske snage i ograničene baterije.

Kako smo spomenuli, jedna od prednosti umjetnih neuronskih mreža je njihova mogućnost generalizacije. No, generalizacija ponekad može imati neželjene posljedice, ovisno o uzorcima koji se klasificiraju, pa se tako može dogoditi da mreža zaključi da su uzorci slični iako to zapravo u stvarnom svijetu nije. Kod prethodno opisane metode [45] je za učenje korišten BP algoritam, koji razvijatelju mreže ne daje mogućnost intervencije u raspodjelu izlaza, što može biti jedan od uzroka grešaka generalizacije. Iz tog razloga se uvodi Bayesov algoritam za učenje [28], kojim se može definirati koje su vrijednosti vjerojatnije od drugih, kako se na izlazu ne bi pojavilo nešto što nema smisla u stvarnom svijetu, primjerice nemoguć prijelaz u cilju koja uopće nije susjedna. Ako se prije faze učenja odredi planirana razdioba vjerojatnosti izlaza, i ta se razdioba uvede u mrežu, nakon učenja će izlazi odgovarati predefiniranoj razdiobi [24]. Time je moguće gotovo eliminirati pojavu neželjenih izlaza, odnosno izlaza koji u stvarnom svijetu nisu mogući. Metoda koja za učenje koristi ovaj algoritam je izložena u radu [3], a za raspodjelu vjerojatnosti je korištena Gaussova razdioba. Za predviđanje se koristi MLP mreža učena s Bayesovim algoritmom, s jednim skrivenim slojem. Za potrebe učenja mreže korištena je baza podataka o kretanjima korisnika razvijena u sklopu projekta *Reality Mining Project* na MIT-u, koja sadrži zapise o kretanju 100 stvarnih osoba u periodu od 4 mjeseca [41] [40]. Iz zapisa o kretanju su izdvojene lokacije korisnika u smislu ciljeva, te vrijeme i dan koji odgovaraju svakoj lokaciji. Ti podaci se koriste kao ulaz u mrežu, dok je izlaz mreže, odnosno rezultat predviđanja, sljedeća lokacija, odnosno cilj. Vremenski

interval predviđanja je 1 minuta, što je vrlo precizno za ovu namjenu. Testiranjem je utvrđeno da mreža ispravno predviđa u 60 posto slučajeva, no niski postotak treba pripisati vrlo visokoj vremenskoj preciznosti. Osim predviđanja kretanja korisnika, autori su razvili i metodu za predviđanje usluge koju će korisnik htjeti koristiti, a pod uslugama se podrazumijevaju poziv, SMS i podatkovna komunikacija. Ovdje je interval 1 sat, a preciznost je puno veća - mreža ispravno predviđa u visokih 93 posto slučajeva.

Kod opisa metoda vjerojatnosnim modelima spomenuli smo dvije metode koje za pozicioniranje korisnika koriste GPS podatke. Problem kod GPS podataka je, u smislu predviđanja, njihova preciznost; gotovo je nemoguće predvidjeti kretanje u smislu koordinata GPS sustava, jer ne možemo očekivati da će se korisnik uvjek kretati unutar radiusa od primjerice 10 metara, bez ikakve varijacije. Zato je GPS podatke potrebno preslikati na veće područje koje će imati smisla za svrhu predviđanja. Kod prethodno opisanih metoda lokacija je aproksimirana cestom [24] ili radijusom oko neke "česte" točke u kojoj se korisnik može nalaziti [4]. Autori [15] za svrhu grupiranja GPS koordinata koriste modificiranu SOM mrežu. SOM mreža je klasifikator koji preslikava beskonačni broj ulaznih uzoraka na konačan broj izlaznih uzoraka, gdje su izlazni uzorci reprezentirani aktiviranim skupinama neurona. Pri tome izlazni prostor može biti jedno ili dvodimenzionalan [16], a preslikavanje se provodi prema sličnosti ulaznih uzoraka. Princip je da koordinate pozicije na kojoj je korisnik dolaze na SOM mrežu, koja ih prema sličnosti klasificira u određeni dio dvodimenzionalnog SOM-a. Rezultat ovakvog pristupa je da će se zemljopisno bliske koordinate preslikati na iste ili vrlo bliske neurone u izlaznom sloju. No, kako je riječ o kretanju u vremenu, autori koriste modifikaciju SOM mreže - rekurentni SOM (RSOM) [26]. Prednost RSOM-a je da se izlazi aktiviraju ovisno o trenutnom ulazu ali i prethodnim ulazima, slično kao kod Jordan ili Elman učenja za neuronske mreže, čime je uspostavljena ovisnost budućih lokacija korisnika o prethodnim. Nakon određivanja šire lokacije RSOM-om, svakoj lokaciji pripada čvor u Markovljevom lancu prvog reda [58] te se predviđanje kretanja temelji na vjerojatnosti prijelaza između trenutne i susjednih lokacija. Ovdje opisana metoda je nadograđena mogućnošću "predviđanja namjere" korisnika [42]. Prema funkcionalnosti je sustav identičan prethodno opisanom, ali je obogaćen poznavanjem konteksta korisnika u smislu imena lokacija i radnji koje korisnik obavlja na značajnim lokacijama. Tako se ovdje predviđa namjera korisnika, jer su od prije poznate buduće lokacije, na koje se sada veže i radnja koju korisnik može obaviti na tim (budućim) lokacijama. U glavne nedostatke ove metode možemo svrstati nešto nižu preciznost predviđanja, iz razloga što prilikom predviđanja ne uzima u obzir vrijeme, dan ili profil kretanja korisnika. Najveći doprinos ove metode je inteligentno preslikavanje GPS podataka na šire lokacije pogodne za predviđanje, pri čemu je maksimalno iskorištena mogućnost generalizacije SOM, odnosno RSOM mreže.

Prethodno opisane metode su za predviđanje koristile MLP mreže te SOM za klasifikaciju kretanja. Možemo primijetiti da

se metode najčešće orijentiraju na predviđanje kretanja jednog korisnika. Uz to, ulazi su najčešće trenutna lokacija korisnika, s eventualno dodanim trenutnim vremenom, danom ili oznakom profila kojim su definirane navike kretanja korisnika. Informacija koju mreža daje na izlazu je gotovo uvijek sljedeća lokacija, s tim da neke metode nadograđuju funkcionalnost predviđanjem i vremena ulaska korisnika u buduću lokaciju, te uslugom koju će korisnik koristiti na toj budućoj lokaciji. No, kako pokretne mreže imaju velik broj korisnika bilo bi korisno kada bi mogli predvidjeti kretanje svih korisnika, što bi kod upotreba navedenih metoda zahtijevalo multipliciranje sustava na način da bi svaki korisnik imao vlastiti sustav za predviđanje koji bi mogao predvidjeti njegovo kretanje. Za broj korisnika pokretne mreže takvo rješenje bi bilo preskupo i presporo, pa postoje i metode koje predviđaju kretanje za grupu korisnika, kod kojih se korisnici grupiraju prema sličnosti u kretanju.

Metoda za predviđanje kretanja više korisnika prikazana je u radu [35]. Sustav za predviđanje se sastoji od jedne SOM mreže i više MLP mreža. Kako smo prethodno spomenuli, SOM mreže su pogodne za klasificiranje uzoraka bez intervencije razvijatelja mreže, odnosno spadaju u grupu mreža sa nenadgledanim učenjem. Predviđanje kretanja grupe korisnika je kod ove metode zamišljeno u dvije faze. Uzorci kretanja prvo dolaze na SOM mrežu koja ih klasificira aktivacijom odgovarajuće skupine neurona, koja odgovara određenom profilu kretanja korisnika. Dakle, svi slični ulazni uzorci će biti smješteni u istu skupinu u izlaznom sloju. Autori rada tako razlikuju 5 grupa, odnosno SOM mreža ima 5 skupina neurona, obzirom na navike u kretanju. Ovisno o grupi korisnika koja je aktivirana ulaznim uzorcima uzorci se šalju na jednu od 5 MLP mreža koje su zadužene za predviđanje kretanja, na način da svaka MLP mreža predviđa kretanje jedne grupe korisnika. MLP mreže su po funkcionalnosti i arhitekturi slične mrežama u prethodno opisanim metodama, ali je učena za više korisnika, sukladno pripadnosti grupi po navikama kretanja. U odnosu na prethodne metode, ovom metodom nije moguće postići preciznost predviđanja kao kod metoda koje su namijenjene jednom korisniku, ali su rezultati prihvativi s obzirom da se ovom metodom poslužuje više korisnika. Po našem mišljenju, 5 grupa korisnika je premalo za precizno predviđanje; SOM mreža bi trebala imati veći izlazni sloj kako bi mogla preciznije odvojiti grupe korisnika, što bi rezultiralo većim brojem MLP mreža u drugom sloju, ali i bitno preciznijim predviđanjem.

VI. ZAKLJUČAK

Stalan razvoj novih tehnologija pokreće evoluciju usluga u svim segmentima tržišta, pa tako i na tržištu pokretnih telekomunikacijskih usluga. Lokacijske usluge su svakako dio tog tržišta sa sve značajnjim udjelom. Od pojave prvih, jednostavnih ali i vrlo korisnih, lokacijskih usluga prošlo je dosta vremena tijekom kojeg su se korisnici postupno navikavali na lokacijske usluge. Danas je stanje bitno drukčije; korisnici su se navikli na dostupnost usluga i mnogi ih koriste u vlastitoj svakodnevničkoj životinji. Lokacijske usluge nikada nisu imale "killer

application" kao što je SMS usluga, i malo je vjerojatno da će je ikada imati, pa je korisnike moguće privući isključivo uslugom koja je kvalitetnija od ostalih.

U radu je pokazano kako predviđanje kretanja korisnika može doprinijeti podizanju kvalitete usluge. Težište rada je bilo na primjeni predviđanja u lokacijskim uslugama, ali je pokazano kako se predviđanje primjenjuje i u drugim područjima, zbog sličnosti metoda. Pokazano je da se predviđanje može temeljiti na trenutnim parametrima kretanja, bez poznavanja pravog korisničkog konteksta, ali mišljenja smo da je upravo poznavanje konteksta korisnika bitan faktor u kvaliteti usluge, pa prednost dajemo predviđanju temeljenom na povijesti kretanja korisnika, iz koje je analizom moguće izvesti korisne zaključke vezane uz kontekst korisnika. Analiza zapisa o kretanju je jedan od najvećih izazova u predviđanju kretanja temeljenom na prethodnom kretanju, jer je jedino ispravnom analizom moguće dobiti valjane zaključke o kontekstu korisnika. U radu je pokazano nekoliko metoda za analizu zapisa o prošlom kretanju i predviđanje budućeg kretanja, a dijelimo ih na metode temeljene na vjerojatnosnim modelima i umjetnim neuronskim mrežama. Umjetne neuronske mreže nam se čine najprikladnijima za analizu kretanja, zbog mogućnosti uočavanja regularnosti u velikim količinama podataka. Uz to, vrlo su prikladne i za predviđanje kretanja zbog mogućnosti generalizacije, koja osigurava pouzdan i predvidiv rad mreže i za uzorce kretanja koji se nisu pojavljivali u zapisima kretanja. Naime, analiza uzoraka kretanja može analizirati samo postojeće zapisane kretanje korisnika, no prilikom predviđanja se mogu pojaviti i uzorci koji se nisu nikada pojavili u zapisanom kretanju, ako se korisnik, primjerice, pojavi na nekoj novoj lokaciji. Ipak, umjetne neuronske mreže ne mogu graditi vjerojatnosne modele kretanja korisnika, pa smatramo da je rješenje u hibridnim modelima koji se temelje na neuronskim mrežama potpomognutim vjerojatnosnom analizom podataka.

Smatramo da je poznavanje i korištenje konteksta korisnika prilikom pružanja usluge osnova razvoja svih, pa tako i lokacijskih usluga. Jedino na taj način se može osigurati kvaliteta usluge koju će korisnici prihvati. Predviđanje kretanja uvjetovano je poznavanjem, minimalno, lokacijskog aspekta konteksta korisnika. No, znanje o budućim lokacijama ili kretnjama korisnika uvelike proširuje kontekst i omogućuje mnoštvo dodatnih funkcionalnosti koje su pokazane u radu. Iz tog razloga smatramo da je predviđanje kretanja omogućitelj nove generacije lokacijski zavisnih usluga te je kao takav dobro područje za nastavak istraživanja [34].

LITERATURA

- [1] Y. Manolopoulos A. Nanopoulos, D. Katsaros. Effective prediction of web user accesses: a data mining approach. *Proceedings of the WebKDD Workshop*, 2001.
- [2] Y. Manolopoulos A data mining algorithm for generalized web prefetching *IEEE Trans. Knowl. Data Eng.* 15 (5) (2003) 1155–1169. A. Nanopoulos, D. Katsaros. A data mining algorithm for generalized web prefetching. *IEEE Trans. Knowl. Data Eng.*, 15 (5):1155–1169, 2003.

- [3] Sherif Akoush and Ahmed Sameh. Mobile user movement prediction using bayesian learning for neural networks. In *IWCMC '07: Proceedings of the 2007 international conference on Wireless communications and mobile computing*, pages 191–196, New York, NY, USA, 2007. ACM.
- [4] D. Ashbrook. Learning significant locations and predicting user movement with gps. page 101, 2002.
- [5] J. Shankar P. Salmon S. Bottger B. Kreller, D. Carrega and " ACTS Mobile Communication Summit Rhodos Greece (1998). T. Kassing, "A Mobile-Aware City Guide Application. A mobile-aware city guide application. *ACTS Mobile Communication Summit*, 1998.
- [6] Steve Benford, Rob Anastasi, Martin Flintham, Adam Drozd, Andy Crabtree, Chris Greenhalgh, Nick Tandavanitj, Matt Adams, and Ju Row-Farr. Coping with uncertainty in a location-based game. *IEEE Pervasive Computing*, 02(3):34–41, 2003.
- [7] Amiya Bhattacharya and Sajal K. Das. Lezi-update: an information-theoretic framework for personal mobility tracking in pcs networks. *Wirel. Netw.*, 8(2/3):121–135, 2002.
- [8] Goutam Chakraborty. Efficient location management by movement prediction of the mobile host. In *IWDC '02: Proceedings of the 4th International Workshop on Distributed Computing, Mobile and Wireless Computing*, pages 142–153, London, UK, 2002. Springer-Verlag.
- [9] Guanling Chen and David Kotz. A survey of context-aware mobile computing research. Technical Report TR2000-381, Dept. of Computer Science, Dartmouth College, November 2000.
- [10] Adrian David Cheok, Kok Hwee Goh, Wei Liu, Farzam Farbiz, Siew Wan Fong, Sze Lee Teo, Yu Li, and Xubo Yang. Human pacman: a mobile, wide-area entertainment system based on physical, social, and ubiquitous computing. *Personal Ubiquitous Comput.*, 8(2):71–81, 2004.
- [11] Y. Hsueh D. Lee. A bandwidth reservation scheme based on road information for the next generation cellular networks. *IEEE Trans. Veh. Technol.*, 53(1):243–252, 2004.
- [12] Sajal K. Das and Sanjoy K. Sen. Adaptive location prediction strategies based on a hierarchical network model in a cellular mobile environment. *The Computer Journal*, 42(6):473–486, 1999.
- [13] A. Dey, G. Abowd, and D. Salber. A context-based infrastructure for smart environments. 1999.
- [14] EIA/TIA. Cellular radio telecommunication inter system operations. Technical report, IS-41, 1991.
- [15] Sang-Jun Han and Sung-Bae Cho. Predicting user's movement with a combination of self-organizing map and markov model. In *ICANN* (2), pages 884–893, 2006.
- [16] S Haykin. *Neural Networks, A Comprehensive Foundation*. Prentice-Hall, Englewood Cliffs, NJ, USA., second ed. edition, 1999.
- [17] J.T Horng C.Y. Ke H.K. Wu, M.H. Jin. Personal paging area design based on mobile's moving behaviors. *Proceedings of INFOCOM*, pages 21–30, 2001.
- [18] J. Hou and Y. Fang. Mobility-based call admission control schemes for wireless mobile networks. *Wireless Communications and Mobile Computing*, v1 i3:269–282, 2001.
- [19] W. Hu and T. Tan. A hierarchical self-organizing approach for learning the patterns of motion trajectories. *IEEE Trans. Neural Networks*, 15 (1):135–144, 2004.
- [20] James M. Hudson, Jim Christensen, Wendy A. Kellogg, and Thomas Erickson. "i'd be overwhelmed, but it's just one more thing to do": availability and interruption in research management. In *CHI '02: Proceedings of the SIGCHI conference on Human factors in computing systems*, pages 97–104, New York, NY, USA, 2002. ACM.
- [21] Mohammad Mahfuzul Islam, Manzur Murshed, and Laurence S. Dooley. New mobility based call admission control with on-demand borrowing scheme for qos provisioning. *ITCC '03: Proceedings of the International Conference on Information Technology: Computers and Communications*, page 263, 2003.
- [22] M. Levene J. Borges. Data mining of user navigation patterns. *Proceedings of the Workshop on Web Usage Analysis and User Profiling (WEBKDD'99)*, page 31–36., 1999.
- [23] H. Kim J. Go, G. Han and C. Lee. Multigradient: A new neural network learning algorithm for pattern classification. *IEEE Trans. Geoscience and Remote Sensing*, 39 (5):986–993, 2001.
- [24] Hassan A. Karimi and Xiong Liu. A predictive location model for location-based services. In *GIS '03: Proceedings of the 11th ACM international symposium on Advances in geographic information systems*, pages 126–133, New York, NY, USA, 2003. ACM.
- [25] Cory D. Kidd, Robert Orr, Gregory D. Abowd, Christopher G. Atkeson, Irfan A. Essa, Blair MacIntyre, Elizabeth D. Mynatt, Thad Starner, and Wendy Newstetter. The aware home: A living laboratory for ubiquitous computing research. In *CoBuild '99: Proceedings of the Second International Workshop on Cooperative Buildings, Integrating Information, Organization, and Architecture*, pages 191–198, London, UK, 1999. Springer-Verlag.
- [26] Varsta M. Heikkonen J. Koskela, T. and K. Kaski. Temporal sequence processing using recurrent som. In *Proceedings of Second International Conference on Knowledge-Based Intelligent Engineering Systems*, pages pp. 290–297., Adelaide, Australia, 1998.
- [27] B.P. Vijay Kumar and P. Venkataram. Prediction-based location management using multilayer neural networks. *Journal of Indian institute of science*, pages pp.7–21, 2002.
- [28] Jouko Lampinen and Aki Vehtari. Bayesian approach for neural networks – review and case studies. *Neural Netw.*, 14(3):257–274, 2001.
- [29] C. Lee and D. Landgrebe. Decision boundary feature extraction for neural networks. *IEEE Trans. Neural Networks*, 8:75–83., 1997.
- [30] Xiong Liu and Hassan A. Karimi. Location awareness through trajectory prediction. *Computers, Environment and Urban Systems*, 30(6):741–756, 2006.
- [31] Sue Long, Dietmar Aust, Gregory Abowd, and Chris Atkeson. Cyber-guide: prototyping context-aware mobile applications. pages 293–294, 1996.
- [32] Ignac Lovrek and Vjekoslav Sinkovic. Knowledge-based mobility management in all-mobile network. In *KES*, volume 2774 of *Lecture Notes in Computer Science*, pages 661–667. Springer, 2003.
- [33] Ignac Lovrek and Vjekoslav Sinkovic. Mobility management for personal agents in the all-mobile network. In *KES*, volume 3213 of *Lecture Notes in Computer Science*, pages 1143–1149. Springer, 2004.
- [34] D. Jevtic M. Vukovic, I. Lovrek. Predicting user movement for advanced location-aware services. In *15th International Conference on Software, Telecommunications and Computer Networks*, pages 1–5. SoftCOM 2007., 2007.
- [35] Kausik Majumdar and Nabanita Das. Mobile user tracking using a hybrid neural network. *Wirel. Netw.*, 11(3):275–284, 2005.
- [36] Natalia Marmasse and Chris Schmandt. Location-aware information delivery with commotion. *HUC '00: Proceedings of the 2nd international symposium on Handheld and Ubiquitous Computing*, pages 157–171, 2000.
- [37] R. Mayrhofer, H. Radi, and A. Ferscha. Recognizing and predicting context by learning from user behavior. *Radiomatics: Journal of Communication Engineering*, special issue on Advances in Mobile Multimedia, May 2004.
- [38] M. Mozer. The neural network house: An environment that adapts to its inhabitants. *Proceedings of the American Association for Artificial Intelligence*, 1998.
- [39] P.S. Yu M.S. Chen, J.S. Park. Efficient data mining for path traversal patterns. *IEEE Trans. Knowl. Data Eng.*, 2:209–221., 1998.
- [40] A. Pentland N. Eagle. Reality mining: Sensing complex social systems. In *Personal and Ubiquitous Computing*, pages 255–268., 2006.
- [41] A. Pentland N. Eagle and D. Lazer. Inferring social network structure using mobile phone data. (*in submission*), 2007.
- [42] Moon-Hee Park, Jin-Hyuk Hong, and Sung-Bae Cho. Two-stage user mobility modeling for intention prediction for location-based services. In *IDEAL*, pages 538–545, 2006.
- [43] Gregory P. Pollini and Chih-Lin I. A profile-based location strategy and its performance. *IEEE Journal on Selected Areas in Communications*, 15(8):1415–1424, 1997.
- [44] Zachary Pousman, Giovanni Iachello, Rachel Fithian, Jehan Moghazy, and John Stasko. Design iterations for a location-aware event planner. *Personal Ubiquitous Comput.*, 8(2):117–125, 2004.
- [45] Alejandro Quintero. A user pattern learning strategy for managing users' mobility in umts networks. *IEEE Transactions on Mobile Computing*, 4(6):552–566, 2005. Member-Alejandro Quintero.
- [46] R. Srikanth R. Agrawal. Mining sequential patterns. *Proceedings of the IEEE Conference on Data Engineering (ICDE 95)*, page 3–14, 1995.
- [47] Sherif Rashad, Mehmed Kantardzic, and Anup Kumar. User mobility oriented predictive call admission control and resource reservation for next-generation mobile networks. *J. Parallel Distrib. Comput.*, 66(7):971–988, 2006.
- [48] Y. Ayatsuka Rekimoto, J and K. Hayashi. Augment-a-ble reality: Situated communication through physical and digital spaces. *Proceedings of the International Symposium on Wearable Computing, IEEE*, 1998.
- [49] R.B. Narayan X.B.C. Petit S. Rajagopal, R.B. Srinivasan. Gps-based predictive resource allocation in cellular networks. *Proceedings of the*

- IEEE International Conference on Networks (IEEE ICON'02)*, pages 229–234, 2002.
- [50] S. Schönfelder. Some notes on space, location and travel behaviour. *Swiss Transport Research Conference*, 2001.
- [51] J. Scourias and T. Kunz. An activity-based mobility model and location management simulation framework. *Workshop on Modeling and Simulation of Wireless and Mobile Systems (MSWiM'99)*, 1999.
- [52] L.A. Stilp. Carrier and end-user application for wireless location systems. *Proceedings of SPIE*, 2602:119–126, 1996.
- [53] Michael Terry, Elizabeth D. Mynatt, Kathy Ryall, and Darren Leigh. *Social net: using patterns of physical proximity over time to infer shared interests*, pages 816–817. ACM, New York, NY, USA, 2002.
- [54] Lin K.W Tseng, V.S. Efficient mining and prediction of user behavior patterns in mobile web systems. *Information and Software Technology* 48, 6:357–369., 2006.
- [55] Marin Vukovic. Dostavljanje lokacijski zavisnog sadržaja pokretnim korisnicima. diploma, 2006.
- [56] H. Kim W. Soh. Qos provisioning in cellular networks based on mobility prediction techniques. *IEEE Comm. Magazine*, page 86–92, 2003.
- [57] H. Kim W. Soh. Dynamic bandwidth reservation in cellular networks using road topology based mobility predictions. *Proceedings of the IEEE INFOCOM 2004*, vol. 4:2766–2777, 2004.
- [58] W.L. Winston. *Operations Research: Applications and Algorithms*. Duxbury Press, Belmont, CA, 1994.
- [59] Gökhan Yavas, Dimitrios Katsaros, Özgür Ulusoy, and Yannis Manolopoulos. A data mining approach for location prediction in mobile environments. *Data Knowl. Eng.*, 54(2):121–146, 2005.
- [60] A.W.C. Fu Z. Chen. Linear time algorithms for finding maximal forward references. *Proceedings of the 2003 IEEE International Conference on Information Technology: Coding and Computing*, 2003.