

Detekcija ljudi u elektromagnetskom polju Wi-Fi signala

Krešimir Domazet

Fizički odsjek, Prirodoslovno-matematički fakultet, Bijenička 32, Zagreb

Ljudsko tijelo ima relativno visoku dielektričnu permitivnost u odnosu na vakuum zbog čega možemo očekivati da će elektromagnetsko polje u nekom prostoru biti različito ovisno o prisustvu ljudi. Cilj ovog seminara je odrediti prisutnost i broj ljudi u zatvorenoj prostoriji koristeći podatke o jačini Wi-Fi polja u određenim točkama unutar navedene prostorije. Ovo radimo statističkom analizom eksperimentalno dobivenih podataka, kao i metodama strojnog učenja. Pokazat ćemo da korištenjem navedenih metoda možemo postići vrlo visoku točnost određivanja prisustva, kao i broja ljudi u prostoriji.

I. UVOD

Krenemo li od Maxwellovih jednadžbi za prostor u kojem nema slobodnih naboja ni struja, jednostavnom manipulacijom možemo doći do valne jednadžbe za elektromagnetske valove:

$$\nabla^2 \mathbf{E} = \mu_0 \epsilon_0 \frac{\partial^2 \mathbf{E}}{\partial t^2} \quad (1)$$

$$\nabla^2 \mathbf{B} = \mu_0 \epsilon_0 \frac{\partial^2 \mathbf{B}}{\partial t^2} \quad (2)$$

gdje je: $v = \frac{1}{\sqrt{\epsilon_0 \mu_0}} = c$.

S druge strane u nekom dielektričnom materijalu će se valna jednadžba promjeniti za dodatni relativni faktor: $\mu = \mu_0 \mu_r$ i $\epsilon = \epsilon_0 \epsilon_r$, gdje sad vrijedi: $v = \frac{1}{\sqrt{\epsilon \mu}} = c$.

Možemo definirati indeks loma neke tvari n kao:

$$v = \frac{c}{n} \quad (3)$$

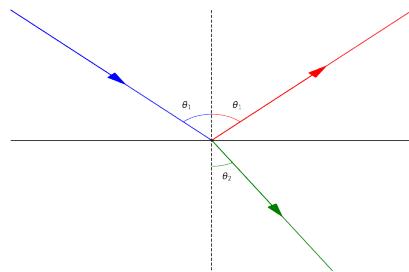
Na granici dva različita medija upadni elektromagnetski val će se djelomično transmitirati i djelomično reflektirati. Ova situacija prikazana je na slici 1. Kut refleksije jednak je kutu pod kojim je upadni val pao na granicu, dok za kut transmitiranog vala vrijedi Snellov zakon:

$$n_1 \sin \theta_1 = n_2 \sin \theta_2 \quad (4)$$

S obzirom na visoku dielektričnu permitivnost ljudskog tijela s obzirom na zrak na frekvencijama Wi-Fi polja, zbog refleksije i transmisije elektromagnetskih valova možemo očekivati promjenu polja u prostoru.

A. Wi-Fi

WiFi signal predstavlja elektromagnetsko zračenje u WiFi frekvencijskom području, otprilike na 2.4 MHz. Nama je cilj utvrditi prisustvo, odnosno točan broj ljudi u zatvorenom prostoru putem analize WiFi signala, bez da sudionici moraju posjedovati vlastiti WiFi uređaj. Dosadašnje Istraživanje primjene WiFi signala za brojanje ljudi je usmjereni pretežito u dva glavna smjera [1].

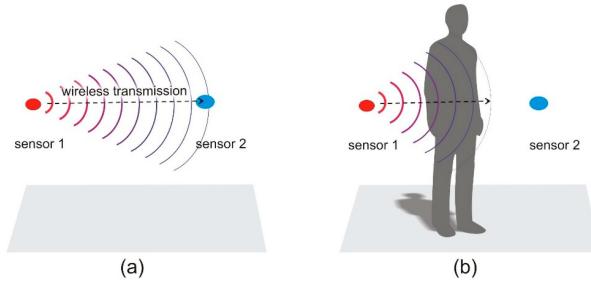


Slika 1. Refleksija i transmisija elektromagnetskog vala na granici dva medija

Prvi pristup koristi isključivo informacije o snazi signala na detektoru, odnosno Received Signal Strength Indicator (RSSI) vrijednost. S druge strane, drugi pristup koristi tzv. Channel State Information (CSI), koji pruža opsežniji opis signala, ali istovremeno predstavlja znatno kompleksniji izazov u praktičnom smislu. U ovom seminaru razmatrat ćemo isključivo RSSI vrijednost.

Pretpostavimo da imamo izvor i detektor Wi-Fi signala između kojih se nalazi čovjek, kao što je prikazano na slici 2. Ljudsko tijelo apsorbira upadno zračenje, zbog čega dolazi do efekta zasjenjenja, tj. izmjereni intenzitet zračenja na detektoru će biti manji nego bez prisustva čovjeka. S druge strane, ako se čovjek nalazi sa strane, izvan direktnе linije gledanja (line of sight), možemo očekivati povećan detektirani intenzitet uzrokovani refleksijom zračenja.

Naravno, ovo predstavlja pojednostavljenu sliku geometrijske optike, koja ne obuhvaća valne karakteristike WiFi zračenja kao ni moguće smetnje uzrokovane reflektiranjem zračenja od drugih površina u prostoriji. Detektori mjere sve moguće doprinose, koji su onda uključeni u analizu detektiranih signala. Za precizan teorijski prikaz sustava izvan domene geometrijske optike, potrebno je riješiti Maxwellove jednadžbe unutar određenog prostora, uzimajući u obzir vrlo komplikirane rubne uvjete i dielektrični odziv ljudskog tijela na WiFi zračenje. Ovaj postupak je netrivialan i procesorski zahtjevan,

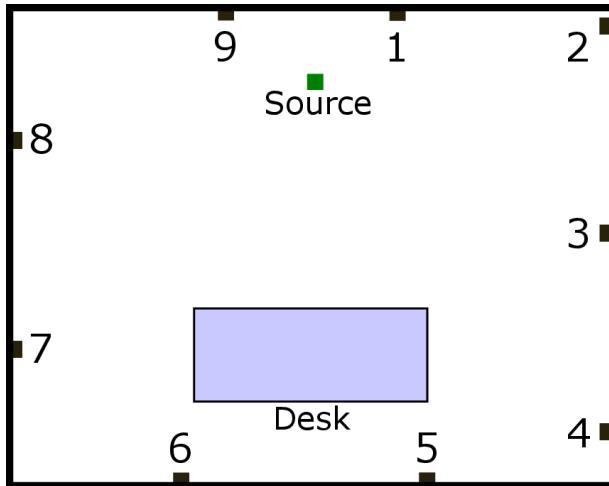


Slika 2. Efekt zasjenjenja [2]

dok pojednostavljena slika apsorpcije i refleksije u geometrijskoj optici može pružiti brzo rješenje za optimalno raspoređivanje izvora i detektora u određenom prostoru, s ciljem maksimizacije preciznosti pri dobivanju informacija iz WiFi signala.

B. Mjerena

Mjerena su izvedena u prostoriji veličine $4m \times 4.5m$, čiji je tlocrt prikazan na slici 3. U toj prostoriji se postavlja izvor WiFi signala i detektori WiFi zračenja. Mjerena su, kao što je već navedeno, provođena koristeći isključivo RSSI signale. Bitno je napomenuti da je moguće smjestiti izvor i detektore izvan same prostorije za mjerenu. U situaciji kada nema prisutnosti ljudi ili drugih pokretnih objekata, intenzitet zračenja koji se bilježi na detektorima ostaje konstantan, s određenim fluktuacijama (šumom) koje proizlaze iz mjernih instrumenata, a koji su standardni element svakog mjerena. Kada se u prostoriji nalazi jedna ili više osoba, bilo da stoje ili se kreću, intenzitet zračenja na detektorima mijenjan će se u odnosu na vrijednost šuma zbog refleksije i apsorpcije Wi-Fi zračenja.



Slika 3. Plan prostorije u kojoj su vršena mjerena

Cilj ovog seminara je izvlačenje informacija iz dobivenih podataka, odnosno vremenskih serija intenziteta, kako bi se utvrdilo (1) je li netko bio prisutan u prostoru gdje se vrše mjerena i (2) koliko ljudi je bilo prisutno. Različite metode mogu se koristiti za postizanje ovog cilja, uključujući statističke analize vremenskih serija s i bez prisutnosti ljudi, izgradnju prediktivnih modela, te primjenu metoda strojnog učenja gdje algoritam 'uči' na prethodno izmjerenim signalima kako bi u stvarnom vremenu prepoznao prisutnost ili odsutnost ljudi u prostoriji, te odredio broj ljudi u prostoriji ako ih ima.

U prostoriji u kojoj su se vršila mjerena nalazi se jedan izvor i devet detektora postavljenih uz unutarnje zidove prostorije kao što je prikazano na slici 3. Svi devet navedenih detektora su vršila mjerene intenzitete zračenja (RSSI vrijednost) otprilike 10 mjerena u sekundi. Podaci na kojima smo vršili analizu sadrže mjerena svih devet senzora u trajanju od pola sata za jednu, tri, pet, sedam i devet osoba, kao i nekoliko desetaka sati šuma, kada u prostoriji i u blizini prostorije nije bilo nikoga. Ljudi koji su bili u prostoriji za vrijeme mjerena su se kretali nasumično (ne brzo, ali ni jednoliko), te su također stajali ili radili nasumične pokrete. U tablici 1 se nalazi primjer dobivenih mjerena, specifično mjerena s jednom osobom u prostoriji, dok se na slici 4 nalazi graf koji prikazuje prvih deset sekundi mjerena s tablice.

Pri analizi podataka smo trebali odrediti koju duljinu vremenske serije koristiti. Imali smo na umu ideju da bi željeli unutar 20 sekundi odrediti prisutnost i broj ljudi u prostoru pokrivenom WiFi signalom. Naravno, odabir ovog intervala je posve proizvoljan i ovisi o specifičnoj primjeni.

Imamo vremenske serije od $T \approx 30$ minuta za svaki broj ljudi u prostoriji tijekom mjerena. Svaka vremenska serija u trajanju od $T \approx 30$ minuta podijeljena je na kratke vremenske intervale od $\tau = 20$ sekundi. Ovisno o cilju, svaka metoda ima svoju optimalnu vrijednost τ . Na ovaj način, iz jedne serije dobivamo $M = \text{floor}(\frac{T}{\tau})$ kraćih vremenskih serija. Cilj nam je odrediti ima li ljudi, i koliko ako ima iz nasumičnog vremenskog intervala od 20 sekundi.

II. REZULTATI

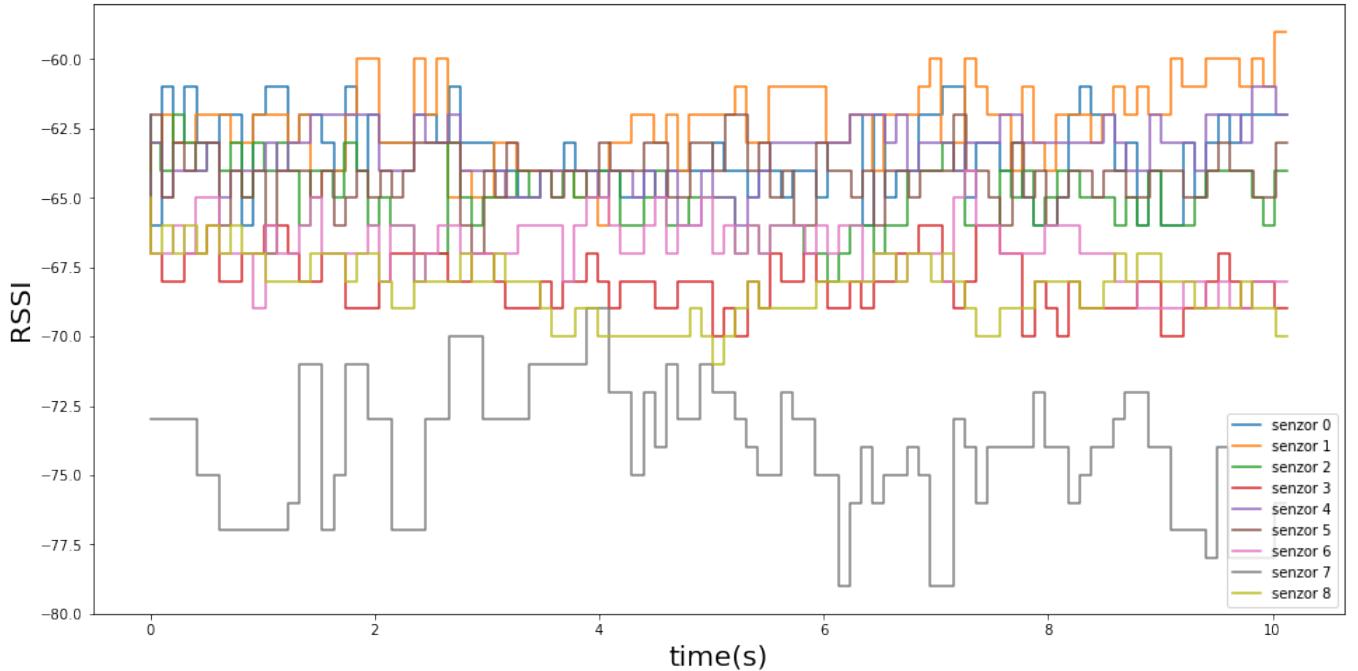
Problem ćemo pokušati riješiti analizom statističkih parametara detektiranog signala i metodama strojnog učenja, uključujući duboko učenje.

A. Statistička obrada parametara signala

Kada su ljudi prisutni u sobi i aktivno se kreću, njihovo prisustvo uzrokuje refleksiju i apsorpciju zračenja, što bi trebalo rezultirati većim fluktuacijama signala, vidljivim u standardnoj devijaciji signala. S druge strane, pozicija pojedinca utječe na srednju vrijednost signala tako

Time	RSSI	RSSI_2	RSSI_3	RSSI_4	RSSI_5	RSSI_6	RSSI_7	RSSI_8	RSSI_9
0.000000	-62	-64	-64	-65	-63	-65	-67	-73	-65
0.103295	-66	-63	-63	-67	-63	-62	-67	-73	-67
0.202423	-61	-62	-64	-68	-65	-65	-67	-73	-66
0.307754	-63	-63	-62	-68	-64	-63	-66	-73	-67
0.411594	-61	-63	-63	-67	-64	-64	-67	-73	-66
...
1194.120668	-60	-62	-67	-67	-61	-64	-66	-79	-71
1194.225522	-62	-61	-66	-66	-63	-64	-65	-72	-71
1194.331375	-61	-60	-66	-66	-61	-64	-67	-74	-72
1194.432060	-61	-61	-64	-66	-61	-64	-65	-76	-72
1194.533965	-62	-61	-65	-66	-62	-64	-65	-76	-70

Tablica I. Primjer podataka mjerena



Slika 4. Graf mjerena u intervalu od 10 sekundi

da refleksija povećava vrijednost signala, dok apsorpcija smanjuje. Stoga, prisustvo ljudi u sobi ima kompleksan utjecaj na srednju vrijednost signala.

Iz tog razloga ćemo za početak analizirati momente distribucije izmjerjenih signala kratkih vremenskih intervala (srednja vrijednost, standardna devijacija, skewness(zakrivljenost) i kurtosis) koji su definirani kao:

$$\mu \equiv \frac{1}{n} \left(\sum_{i=1}^n x_i \right) \quad (5)$$

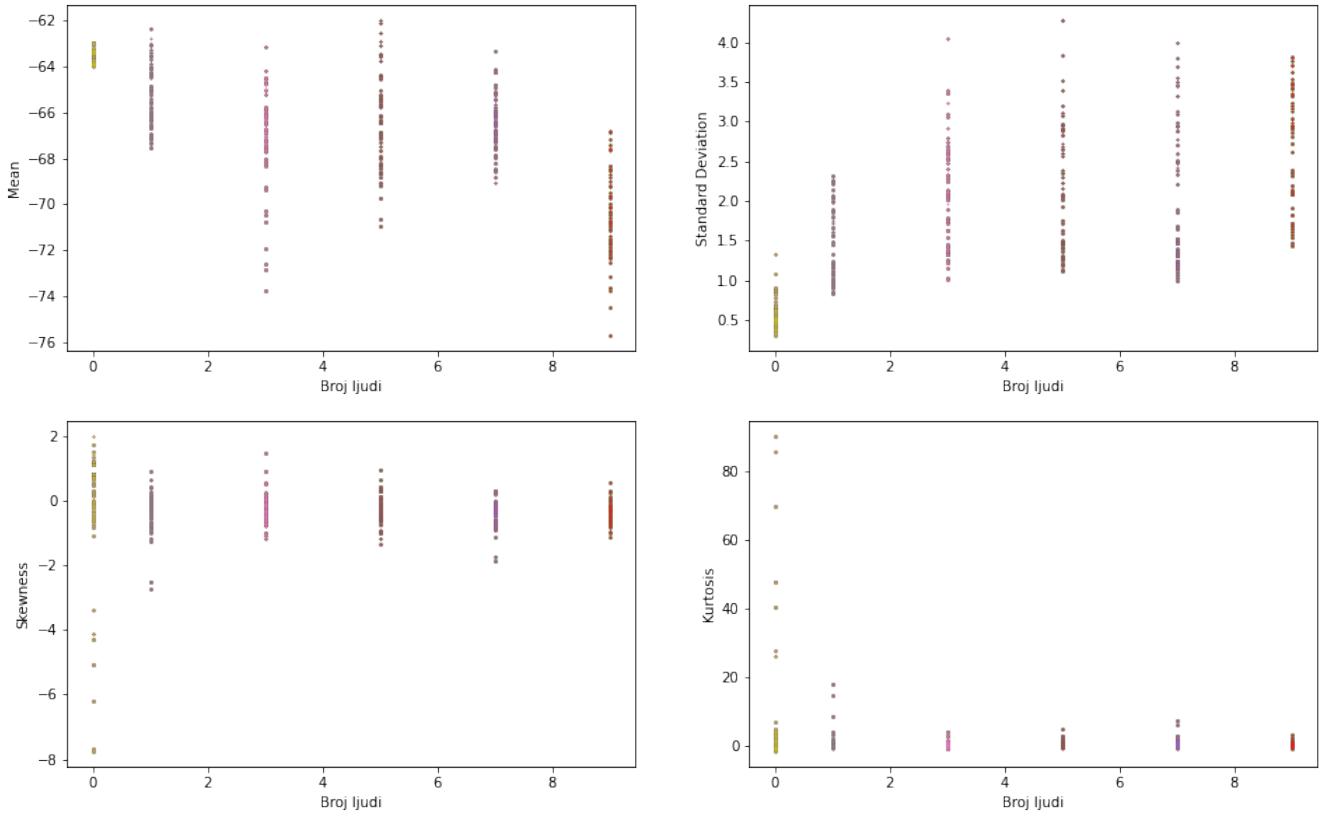
$$\sigma \equiv \sqrt{\text{E}[(X - \mu)^2]} \quad (6)$$

$$\tilde{\mu}_3 \equiv \text{E} \left[\left(\frac{X - \mu}{\sigma} \right)^3 \right] \quad (7)$$

$$\text{Kurt} \equiv \text{E} \left[\left(\frac{X - \mu}{\sigma} \right)^4 \right] \quad (8)$$

Na slici 5 se nalaze grafovi ovih vrijednosti za kratke vremenske seriju ovisnosti o broju ljudi. Radi kratkoće su prikazani samo rezultati jednog senzora. Možemo vidjeti kako se podatci donekle slažu s našim predviđanjem i čini se da bi analiza standardne devijacije mogla biti dobra ako u obzir uzmemos sve detektore, dok za problem brojanja ljudi ova metoda izgleda neupotrebljiva.

Predikcijski algoritam za odrediti ima li ljudi ili ne koristeći standardnu devijaciju šuma uzima kao ulazne podatke samo mjerena šuma. Nakon toga se za svaki detektor računa standardna devijacija šuma. Predikciju može vršiti svaki detektor posebno, pa ako više od određenog broja detektora detektira prisutnost ljudi u nekom vremenskom intervalu i i cijeli model detektira prisutnost



Slika 5. Graf ovisnosti momenata distribucije o broju ljudi za kratke vremenske serije

ljudi u tom intervalu. S druge strane možemo objediniti standardne devijacije svih detektora (npr. množenjem), pa usporediti tu standardnu devijaciju sa standardnim devijacijama novih, nepoznatih mjerena. U oba slučaja model predviđa da je netko u prostoriji ako je standardna devijacija veća od nekog faktora $f\sigma$. Na temelju konačnih rezultata odabran je faktor $f = 1.2$. Oba navedena algoritma imaju sličnu točnost, pa su radi kratkoće u tablici 2 prikazani samo rezultati drugog algoritma koji objedinjuje standardne devijacije svih detektora. Rezultati nisu loši, ali ipak nisu dovoljno dobri za praktičnu upotrebu.

cija detektora nezanemarivo utječe na točnost rezultata. Međutim, nije moguće odgovoriti kako lokacija detektora utječe na predikciju, osobito s obzirom na to da su različiti senzori bolji ili lošiji s obzirom na korištenu metodu (uključujući i one koje tek slijede). Za precizniju analizu utjecaja položaja detektora bi trebalo napraviti mjerena na većoj količini podataka kako bi se otklonio utjecaj stohastičke naravi korištenih algoritama.

B. Metode strojnog učenja

Broj ljudi	Broj točnih predviđanja	Udeo točnih predviđanja (%)
Without people	379 / 400	94.8
1 person	44 / 59	74.6
3 people	58 / 59	98.3
5 people	59 / 59	100.0
7 people	59 / 59	100.0
9 people	59 / 59	100.0

Tablica II. Točnost algoritma standardne devijacije

Također smo promotrili kako broj detektora utječe na preciznost rezultata. Ti rezultati nisu ovdje prikazani radi kratkoće. Pokazalo se da točnost ne opada značajno dok su aktivna tri ili četiri detektora, kao i da loka-

Kako bi odredili prisutnost i broj ljudi možemo koristiti i klasične klasifikacijske metode strojnog učenja. U ovom seminaru ćemo koristiti dva algoritma: K najблиžih susjeda (K nearest neighbours (KNN)) i Slučajna šuma (Random Forest). Za početak promotrimo ukratko kako ovi algoritmi funkciraju.

Algoritam KNN koristi skup podataka s oznakama tj. ciljnim vrijednostima klasifikacije te temelji svoje odluke na bliskosti podataka u prostoru značajki za definiranu metriku. Parametar K, određen unaprijed, predstavlja broj susjeda koji će se uzeti u obzir pri donošenju odluke. Kada algoritam kao input dobije novi, nepoznati primjer koji treba klasificirati, klasificira ga na temelju klasa kojima pripadaju njegovih K najблиžih susjeda prema defi-

niranoj metriči. U našem slučaju ulaz je vremenska serija mjerena RSSI signala devet detektora u trajanju od 20 sekundi. Metrika je jednostavna euklidska metrika točku po točku. (Radi ilustracije, u kontinuiranom slučaju bi to odgovaralo integralu apsolutne vrijednosti razlike dviju vremenskih serija).

Slučajna šuma je ansambl koji kombinira više stabala odlučivanja od kojih svako stablo donosi nezavisnu odluku, a konačna predikcija dobiva se "glasanjem" pojedinačnih stabala. Stablo odlučivanja temelji se na hijerarhijskom dovođenju odluka putem niza uvjeta. Počevši od korijena stabla, na svakom čvoru stablo vrši test na podskupu ulaznog seta podataka, a odgovor određuje daljnji put do sljedećeg čvora ili kraja stabla, gdje se donosi konačna odluka.

Algoritmi su trenirani na 80% podataka koji su podjeljeni u tri grupe radi unakrsne provjere (cross validation) kako bi se spriječila prenaučenost modela. Preostalih 20% podataka je onda na kraju korišteno kao test.

Pri određivanju prisutnosti ljudi oba algoritma su imala istu postotnu točnost. Na tablicama 3 i 4 su prikazane točnosti ova dva algoritma promatramo li podatke samo jednog senzora.

K najbližih susjeda	Srednja točnost unakrsne provjere (%)	Točnost na testnom setu (%)
Detektor 1	93.54	91.74
Detektor 2	66.87	62.81
Detektor 3	94.58	95.04
Detektor 4	93.13	95.04
Detektor 5	100.00	100.00
Detektor 6	90.83	95.87
Detektor 7	88.54	93.39
Detektor 8	97.50	98.35
Detektor 9	100.00	100.00

Tablica III. Točnost algoritma K najbližih susjeda za svaki detektor pri određivanju prisutnosti ljudi

Slučajna šuma	Srednja točnost unakrsne provjere (%)	Točnost na testnom setu (%)
Detektor 1	94.17	95.04
Detektor 2	97.08	95.87
Detektor 3	98.33	100.00
Detektor 4	95.83	98.35
Detektor 5	100.00	100.00
Detektor 6	97.50	97.52
Detektor 7	97.71	98.35
Detektor 8	98.33	98.35
Detektor 9	100.00	100.00

Tablica IV. Točnost algoritma Slučajna šuma za svaki detektor pri određivanju prisutnosti ljudi

Vidimo da algoritmi imaju visoku točnost čak i u slučaju samo jednog detektora. Kao što je i očekivano Slučajna šuma je preciznija od K najbližih susjeda zbog

loše odabrane metrike.

Ista dva algoritma smo upotrijebili za problem određivanja broja ljudi u prostoriji. U ovom slučaju K najbližih susjeda je imao točnost na testnom setu podataka od 94.21%, a Slučajna šuma 98.35%. Kao i u prošlom problemu, u tablicama 5 i 6 se nalaze preciznosti algoritama na temelju mjerjenja samo jednog senzora. Točnost algoritama pri rješavanju ovog problema je nezadovoljavajuća.

K najbližih susjeda	Srednja točnost unakrsne provjere (%)	Točnost na testnom setu (%)
Detektor 1	62.50	57.85
Detektor 2	59.17	53.72
Detektor 3	61.67	57.85
Detektor 4	82.71	82.64
Detektor 5	72.29	66.12
Detektor 6	66.46	68.60
Detektor 7	63.75	59.50
Detektor 8	67.29	66.12
Detektor 9	65.63	58.68

Tablica V. Točnost algoritma K najbližih susjeda za svaki detektor pri određivanju broja ljudi

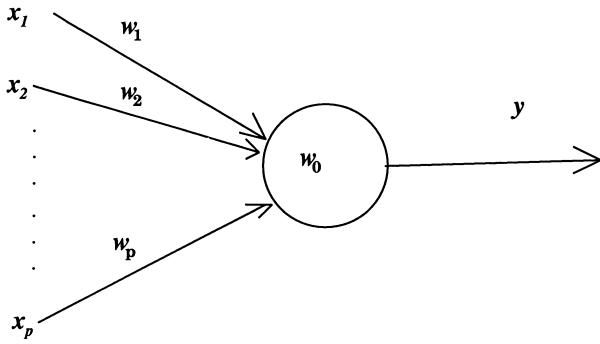
Slučajna šuma	Srednja točnost unakrsne provjere (%)	Točnost na testnom setu (%)
Detektor 1	66.04	61.98
Detektor 2	65.83	69.42
Detektor 3	68.33	69.42
Detektor 4	89.17	86.78
Detektor 5	74.58	72.73
Detektor 6	68.13	69.42
Detektor 7	69.38	66.94
Detektor 8	68.75	66.12
Detektor 9	70.42	63.64

Tablica VI. Točnost algoritma Slučajna šuma za svaki detektor pri određivanju broja ljudi

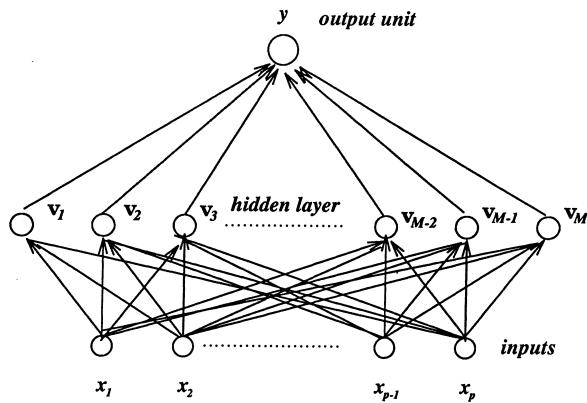
C. Metode dubokog učenja

Za početak ćemo opisati ukratko princip rada neuralnih mreža. Neuralne mreže su sofisticirani modeli strojnog učenja inspirirani strukturonim ljudskog mozga. Sastavljene su od neurona povezanih u slojeve. Svaka neuralna mreža ima ulazni i izlazni sloj, te određen broj skrivenih slojeva između. Neuron prima signale od povezanih neurona iz prethodnog sloja, računa linearnu kombinaciju s pripadnim težinama signala ulaznih neutrona, te djeluje na tako dobiven realni broj aktivacijskom funkcijom, što onda postaje ulaz za neurone u sljedećem sloju. Počevši od ulaznog sloja koji prima neobrađene podatke, ovaj proces se ponavlja sve do izlaznog sloja koji daje

konačni rezultat. izlazni rezultat se uspoređuje s točnim rješenjem pomoću prikladno odabrane funkcije gubitka (loss function). Proces učenja svodi se na računanje građivnika funkcije gubitka u odnosu na težine pojedinih veza među neuronima, te podešavanje tih težina prema lokalnom minimumu. Na slici 6 je prikazan shematski prikaz neurona. x_n predstavljaju ulaz neurona iz prethodnog sloja, w_n pripadne težine, w_0 intrinsičnu težinu samog neurona, a y izlaz neurona. Na slici 7 možemo vidjeti shemu spajanja neurona u neuralnu mrežu.



Slika 6. Shematski prikaz neurona [3]



Slika 7. Shematski prikaz neuralne mreže [3]

U prethodnom odjeljku objasnili smo princip funkcioniranja standardnih neuralnih mreža, a pri rješavanju našeg problema smo koristili dva posebna tipa neuralnih mreža: Konvolucijsku neuralnu mrežu (CNN) i LSTM (long short-term memory) mrežu.

CNN je oblik neuralne mreže koji sadrži konvolucijski sloj (u praksi se uz konvolucijski često koriste i sloj sažimanja (pooling layer) i sloj izravnavanja (flatten layer)). On se sastoji od određenog broja diskretnih funkcija (u kontekstu CNN-a filtera ili kernela) kojima konvoluiramo ulazne podatke čime dobijemo tzv. mapu značajki. Ovo je korisno kada su ulazni podatci prostorno zavisni, kao npr. fotografija. Dalje se mapa značajki šalje sloju sažimanja koji sažima ulaznu mapu koja se dalje prosljeđuje sloju izravnavanja koji reformatira po-

datke za sljedeći sloj mreže. Iako naš problem nije jedan od standardnih problema za koje se koriste konvolucijske mreže, u svakom vremenskom trenutku imamo ulazna mjerena detektora na specifičnim položajima. Ulazna funkcija koju konvoluiramo je niz od devet mjerena, što očekujemo da će dati bolji uvid u prostornu raspodjelu intenziteta zračenja, kao i bolju mogućnost klasifikacije.

Druzi tip mreže koji ćemo koristiti, LSTM, je rekursivna neuralna mreža dizajnirana za procesiranje sekvenčnih podataka. Ulazni podatci ove mreže su, dakle, nizovi podataka gdje svaki element odgovara specifičnoj točki u vremenu. Svaki takav element postaje ulaz jedne LSTM ćelije. Ćelije su povezane veličinom koja se naziva stanje ćelije, koje se pri prolasku kroz ćeliju slabim i linearnim interakcijama, što bi predstavljalo dugoročno pamćenje modela. Ćelije su također povezane skrivenim stanjem koje predstavlja kratkoročno pamćenje. Prvi korak u jednoj iteraciji LSTM mreže je zaboravljanje stanja ćelije, koje je definirano kao linearna kombinacija ulaza i skrivenog stanja nakon djelovanja sigmoid aktivacijske funkcije. Drugi korak je određivanje što dodati u navedeno stanje ćelije, što je definirano umnoškom linearnih kombinacija ulaza i skrivenog stanja nakon djelovanja različitih aktivacijskih funkcija, čime se dobije konačno stanje ćelije. Konačno, skriveno stanje i konačni output se određuju kao i kod neurona standardne neuralne mreže uz multiplikativni doprinos stanja ćelije. S obzirom na to da naš problem ima vremensku ovisnost, LSTM se čini kao dobar odabir arhitekture neuralne mreže.

Osim ova dva modela koristili smo i model koji je ujedno i konvolucijska i LSTM neuralna mreža. Uz podatke svih devet detektora su sva tri modela imala sto postotnu točnost. Iako nema razloga koristiti CNN u slučaju analize podataka samo s jednog senzora, to smo ovdje učinili radi potpunosti. Rezultati za pojedine detektore su prikazani u tablici 7. Vidimo da sa sva tri modela možemo postići visoku preciznost i u slučaju jednog detektora, ali rezultati značajno ovise o položaju detektora.

Detektor	CNN (%)	LSTM (%)	LSTM-CNN (%)
1	90.91	91.74	91.74
2	96.69	97.52	97.52
3	99.17	98.35	97.52
4	97.52	90.91	97.52
5	100.0	100.0	100.0
6	98.35	97.52	96.69
7	96.69	97.52	97.52
8	100.0	100.0	100.0
9	100.0	100.0	100.0

Tablica VII. Točnost neuralnih mreža na testnom setu

Za kraj smo ove modelne upotrijebili i za određivanje broja ljudi. Rezultati su prikazani u matricama ispod. Stupci matrica odgovaraju predviđenim klasama, a redci stvarnim. Dakle, broj u i-tom stupcu i j-tom retku nam daje informaciju koliko je model vremenskih serija klase j svrstao u klasu i. Možemo primijetiti da su algoritmi čak

i u slučaju pogreške klasifikacije vremenske serije svrstali tu seriju u susjednu klasu.

CNN točnost: 98.35%

$$\begin{bmatrix} 62 & 0 & 0 & 0 & 0 & 0 \\ 0 & 7 & 0 & 0 & 0 & 0 \\ 0 & 0 & 12 & 0 & 0 & 0 \\ 0 & 0 & 1 & 11 & 0 & 0 \\ 0 & 0 & 0 & 0 & 12 & 1 \\ 0 & 0 & 0 & 0 & 0 & 15 \end{bmatrix}$$

LSTM točnost: 97.52%

$$\begin{bmatrix} 62 & 0 & 0 & 0 & 0 & 0 \\ 0 & 7 & 0 & 0 & 0 & 0 \\ 0 & 0 & 10 & 2 & 0 & 0 \\ 0 & 0 & 1 & 11 & 0 & 0 \\ 0 & 0 & 0 & 0 & 13 & 0 \\ 0 & 0 & 0 & 0 & 0 & 15 \end{bmatrix}$$

LSTM-CNN točnost: 97.52%

$$\begin{bmatrix} 62 & 0 & 0 & 0 & 0 & 0 \\ 0 & 7 & 0 & 0 & 0 & 0 \\ 0 & 0 & 10 & 2 & 0 & 0 \\ 0 & 0 & 0 & 12 & 0 & 0 \\ 0 & 0 & 0 & 0 & 13 & 0 \\ 0 & 0 & 0 & 1 & 0 & 14 \end{bmatrix}$$

Radi potpunosti smo pomoću navedenih modela odrediti broj ljudi s podatcima samo jednog senzora, ali rezultati, koji su očekivano loši, su prikazani u tablici 8.

Detektor	CNN (%)	LSTM (%)	LSTM-CNN (%)
1	64.46	57.85	62.81
2	66.12	59.50	71.90
3	70.25	62.81	70.25
4	85.95	77.69	76.86
5	64.46	60.33	66.94
6	65.29	60.33	60.33
7	70.25	63.64	73.55
8	66.12	62.81	64.86
9	61.16	57.02	58.68

Tablica VIII. Točnost neuralnih mreža za problem brojanja ljudi s jednim senzorom

III. ZAKLJUČAK

Elektromagnetsko polje Wi-Fi signala u prostoru se mijenja s prisustvom ljudi. Te promjene je moguće detektirati mjerjenjem intenziteta, te time odrediti imaju li ljudi i koliko.

Metoda bazirana na standardnoj devijaciji signala nije se pokazala potpuno uspješnom, ali je prednost te tehnike jednostavnost i činjenica da su potrebni samo signali bez prisutnih ljudi, tj. šum za kalibraciju. Iako u ovoj analizi

nije funkcionala, možda bi bila pogodna za uporabu u prostorijama drugačijeg rasporeda.

Algoritmi K najbližih susjeda i Slučajna šuma su se pokazali odličnim za detekciju prisustva ljudi ako uzmememo u obzir podatke svih detektora, a i za pojedinačne detektore su imali neloše rezultate, koji bi se vjerojatno mogli dodatno poboljšati boljim odabirom samih algoritama, kao i njihovih parametara. Za određivanje broja ljudi s podatcima svih detektora ova dva algoritma su imala visoku, ali ne sto postotnu točnost, dok za pojedinačne detektore nisu bili uspješni.

Neuralne mreže koje smo koristili su sve imale otprilike jednak dobre rezultate. Sva tri modela daju sto postotnu točnost za utvrđivanje prisustva ljudi s podatcima svih detektora, dok su za pojedinačne detektore imali rezultate slične onima K najbližih susjeda i Slučajne šume. Za utvrđivanje broja ljudi su neuralne mreže imale vrlo visoku točnost, ali samo u slučaju s podatcima svih detektora.

U budućnosti bi trebalo detaljnije istražiti kako položaj i broj detektora utječe na rezultate, kao i napraviti slike testove gdje je u nekom vremenskom intervalu broj ljudi u prostoriji promjenjiv.

-
- [1] J. Liu, H. Liu, Y. Chen, Y. Wang, and C. Wang, Wireless sensing for human activity: A survey, *IEEE Communications Surveys Tutorials* **PP**, 1 (2019).
 - [2] Januszkiewicz, Analysis of human body shadowing effect on wireless sensor networks operating in the 2.4 ghz band, *Sensors* **18**, 10.3390/s18103412 (2018).
 - [3] B. Cheng and D. M. Titterington, Neural Networks: A Review from a Statistical Perspective, *Statistical Science* **9**, 2 (1994).