Mjerenje parametara prometnih tokova primjenom Bluetooth tehnologije

Bojić, Vedran

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:695039

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

Vedran Bojić

Mjerenje parametara prometnih tokova primjenom Bluetooth tehnologije

DIPLOMSKI RAD

Zagreb, 2019.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 19. ožujka 2019.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Telematička sučelja**

DIPLOMSKI ZADATAK br. 4988

Pristupnik: **Vedran Bojić (0135226803)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Inteligentni transportni sustavi

Zadatak: **Mjerenje parametara prometnih tokova primjenom Bluetooth tehnologije**

Opis zadatka:

U prvom dijelu rada potrebno je dati kratki pregled parametara prometnih tokova, njihovu uporabu u ITS sustavima i pregled tehnologija koje omogućavaju njihovo mjerenje odnosno prikupljanje podatka. Poseban osvrt treba napraviti na značajke "Bluetooth" tehnologije. U praktičnom dijelu rada potrebno je korištenjem "Bluetooth" detektora i radarskih detektora izmjeriti udio vozila koja sadrže aktivne "Bluetooth" uređaje. U završnom dijelu rada potrebno je procijeniti mogućnosti primjene "Bluetooth" tehnologije za prikupljanje podataka o prometnim tokovima.

Mentor:

izv. prof. dr. sc. Niko Jelušić

Predsjednik povjerenstva za diplomski ispit:

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

DIPLOMSKI RAD

Mjerenje parametara prometnih tokova primjenom Bluetooth tehnologije

Measurement of traffic flow parameters using Bluetooth technology

Mentor: izv. prof. dr. sc. Niko Jelušić

Student: Vedran Bojić, 0135226803

Zagreb, rujan 2019.

Mjerenje parametara prometnih tokova primjenom Bluetooth tehnologije

SAŽETAK

Inteligentni Transportni Sustav u prometu se uvelike oslanjaju na prikupljene podatke o parametrima prometnog toka. U svrhu prikupljanja podataka koriste se različite tehnologije među koje spada i Bluetooth tehnologija. Bluetooth je telekomunikacijski standard koji se koristi za razmjenu podataka između elektroničkih uređaja radiokomunikacijom kratkog dometa. On kao takav ne prikuplja podatke o prometu, već ima mogućnost otkrivanja Bluetooth uređaja unutar vozila u prometnom toku. Bluetooth detektor omogućava jednostavnu identifikaciju Bluetooth uređaja u raznim točkama prometne mreže čime se dobiva pristup podacima potrebnim za izračun parametara prometnih tokova. Time je omogućena izrada polazišno-odredišnih matrica kao i dobivanje podataka o vremenu putovanja. Da bi se utvrdio udio vozila sa Bluetooth uređajima, provedeno je istraživanje. Prema dobivenim podacima, može se zaključiti da se Bluetooth tehnologija može primijeniti kao relevantni izvor podataka.

KLJUČNE RIJEČI: Inteligentni transportni sustavi; Bluetooth tehnologija; prikupljanje podataka; parametri prometnog toka.

Measurement of traffic flow parameters using Bluetooth technology

SUMMARY

Intelligent Transportation Systems mostly rely on collected traffic flow data. In order to collect such data, various technologies are used, one of which is Bluetooth technology. Bluetooth is a telecommunication standard which is used for data exchange between electronic devices using short-range radiocommunication. As such, Bluetooth detectors do not collect traffic flow data, however they detect Bluetooth devices within vehicles. Bluetooth technology can identify vehicles containing Bluetooth devices at various points in the traffic network. This enables collection of data which can be used for creation of OD matrices and to calculate travel times. For the purpose of establishing the Bluetooth vehicle penetration rate, a field research has been performed. According to the collected data, the conclusion is that Bluetooth technology can be applied as a relevant data source.

KEY WORDS: Intelligent transport systems; Bluetooth technology; data collection; traffic flow parameters.

Sadržaj

1. Uvod 1

2. Parametri prometnih tokova i njihova upotreba 3

2.1 Osnovni parametri prometnog toka 3

2.1.1 Protok 4

2.1.2 Gustoća prometnog toka 5

2.1.3 Brzina prometnog toka 6

2.1.3.1 Srednja prostorna brzina prometnog toka 7

2.1.3.2 Srednja vremenska brzina toka 7

2.1.3.3 Brzina prometnog toka s obzirom na vrste prometnih tokova 8

2.1.4 Interval slijeđenja vozila 9

2.1.5 Razmak slijeđenja vozila 10

2.1.6 Ostali parametri prometnog toka za potrebe ITS-a 10

2.2 Uloga parametara u upravljanju 12

2.3 Prometni parametri kao pokazatelji kvalitete 13

3. Pregled tehnologija za prikupljanje podataka i mjerenje parametara prometnog toka 14

3.1 Detektori prometnog toka 15

3.1.1 Intruzivni detektori prometnog toka 15

3.1.1.1 Induktivna petlja 16

3.1.1.2 Magnetski detektori 17

3.1.1.3 Piezoelektrički detektori 18

3.1.2 Neintruzivni detektori prometnog toka 19

3.1.2.1 Pasivni infracrveni detektori 20

3.1.2.2 Aktivni infracrveni detektor 21

3.1.2.3 Radarski detektori 21

3.1.2.4 Pasivni zvučni detektor 23

3.1.2.5 Ultrazvučni detektori 24
3.1.2.6 Videodetektori 25
3.2 Pokretna osjetila 26
3.2.1 Pokretna osjetila sa GNSS lociranjem – FCD 26
3.2.2 Lociranje resursima pokretnih ćelijskih mreža 28
3.2.3 Automatska identifikacija 28
4. Bluetooth tehnologija 30
4.1 Bluetooth standard i klase uređaja 30
4.2 Bluetooth protokoli i otkrivanje uređaja 31
4.3 Bluetooth detektori 34
4.4 Istraživanja sa primjenom Bluetooth tehnologije u prometu 36
5. Mjerenje udjela vozila koja se mogu detektirati bluetooth detektorom 40
5.1 Mjerene veličine 40
5.2 Oprema za mjerenje 41
5.3 Lokacija mjerenja 44
5.4 Rezultati mjerenja i analiza rezultata 45
6. Procjena mogućnosti primjene Bluetooth detektora za prikupljanje podataka o prometnim tokovima 50
7. Zaključak 52
Literatura 54
Slike 56
Tablice 57

1. Uvod

Tehnologije za prikupljanje podataka o prometnim tokovima, neophodne su za primjenu Inteligentnih Transportnih Sustava. Postoje razne vrste tehnologija od detektora prometnog toka, pokretnih osjetila do bežičnih tehnologija poput Bluetooth-a. Primjenom Bluetooth tehnologije, mogu se dobiti neki korisni podaci poput P-O (polazišno-odredišnih) matrica, kao i podaci o vremenu putovanja vozila. Bluetooth je međunarodno priznat standard za razmjenu informacija između elektroničkih uređaja u kratkom dometu i uređaji koji koriste Bluetooth tehnologiju su vrlo rasprostranjeni i često se koriste. Bluetooth detektori prometnog toka mogu zabilježiti jedinstvene (MAC) adrese Bluetooth uređaja te se takvi podaci mogu primijeniti za daljnju analizu prometnih tokova. Kvaliteta informacije ovisi o broju i gustoći Bluetooth uređaja u prometu.

Ovaj diplomski rad sastoji se od 6 poglavlja. Prvo poglavlje pod nazivom „Prometni parametri i njihova uporaba“ opisuje što su to prometni parametri, koji su to parametri koji se koriste za analizu prometnih tokova, kakva je njihova uloga u upravljanju te koji su pokazatelji kvalitete u prometu.

Drugo poglavlje odnosi se na pregled tehnologija koje se koriste za prikupljanje podataka o prometnim tokovima. Opisano je što su to detektori prometnog toka i pokretna osjetila te su ukratko opisane tehnologije koje se koriste za prikupljanje podataka.

Treće poglavlje se odnosi na Bluetooth tehnologiju. Opisano je što je Bluetooth tehnologija te su navedene klase Bluetooth uređaja. Navedeni su osnovni protokoli koje koristi Bluetooth tehnologija i detaljnije opisan protokol za otkrivanje Bluetooth uređaja. Također je opisan način rada Bluetooth detektora prometnog toka.

U četvrtom poglavlju opisano je istraživanje koje je provedeno u sklopu diplomskog rada. Opisana je oprema koja se koristila u istraživanju, lokacija istraživanja kao i konačno rezultati i analiza prikupljenih podataka.

Peto poglavlje se odnosi na prednosti i nedostatke takve tehnologije. Navedeni su parametri koje se može izračunati iz dobivenih podataka kao i diskusiju rezultata dobivenih u prijašnjem poglavlju.

Posljednje poglavlje se sastoji od zaključka. Ukratko je sumiran cijeli rad te dana konačna procjena o korisnosti Bluetooth tehnologije te o njenom potencijalu.

2. Parametri prometnih tokova i njihova upotreba

2.1 Osnovni parametri prometnog toka

Za opis prometnih tokova koriste se veličine koje se nazivaju parametri prometnog toka. Parametri prometno toka predstavljaju osnovne mjerljive veličine koje svojim vrijednostima opisuju stanje prometnog toka. Oni se mogu koristiti kao upravljačke veličine, kao pokazatelji kvalitete usluge ili kao pokazatelji učinkovitosti, odnosno mogu služiti za evaluaciju upravljanja ili primijenjenih mjera za unaprjeđenje prometnog sustava. Osnovni pokazatelji za opisivanje prometnih tokova su [1]:

- Protok vozila q (voz/h),
- Gustoća prometnog toka g (voz/km),
- Brzina prometnog toka v (m/s),
- Vrijeme putovanje vozila u toku t (s),
- Jedinično vrijeme putovanja vozila u toku,
- Vremenski i prostorni interval slijeđenja vozila u toku th (s),
- Razmak slijeđenja vozila u toku sh (m).

Osim navedenih 7 osnovnih pokazatelja prometnih tokova, postoje i ostali parametri koji se prikupljaju za potrebe ITS-a (inteligentni transportni sustavi)[2]:

- Prisutnost vozila – zaustavljenog,
- Prisutnost vozila – vozilo u prolazu,
- Duljina reda,
- Profil prilaznog toka,
- Volumen prometa,
- Prometni zahtjevi,
- Propusnost,
- Zauzeće,
- Kašnjenje na dionici,
- Kašnjenje na raskrižju,

- P-O podaci prometne mreže,
- P-O podaci raskrižja,
- Klasifikacija dimenzije,
- Klasifikacija masa te,
- Funkcijska klasifikacija.

Ispisani parametri prometnog toka su oni za kojima postoji potražnja od strane ITS-a.

2.1.1 Protok

Protok vozila se odnosi na broj vozila koja prođu kroz promatrani presjek prometnice u jedinici vremena u jednom smjeru za jednosmjerne prometnice ili u oba smjera za dvosmjerne prometnice. Osnovna jedinica kojom se iskazuje protok vozila je broj vozila u jednom satu (voz/h). U praksi se koriste i veće vremenske jedinice od jednog sata, kao što je dan (voz/24h). Također se mogu koristiti i vremenske jedinice manje od jednog sata (voz/min), (voz/s).

S gledišta realnih tokova, ovisno o načinu promatranja u odnosu na prostor razlikuju se protok vozila na presjeku ceste i protok vozila na dionici ceste. Protok vozila na presjeku dijela ili dionice ceste predstavlja protok koji se ostvaruje na promatranom presjeku dijela ili dionice ceste u jedinici vremena. [1]

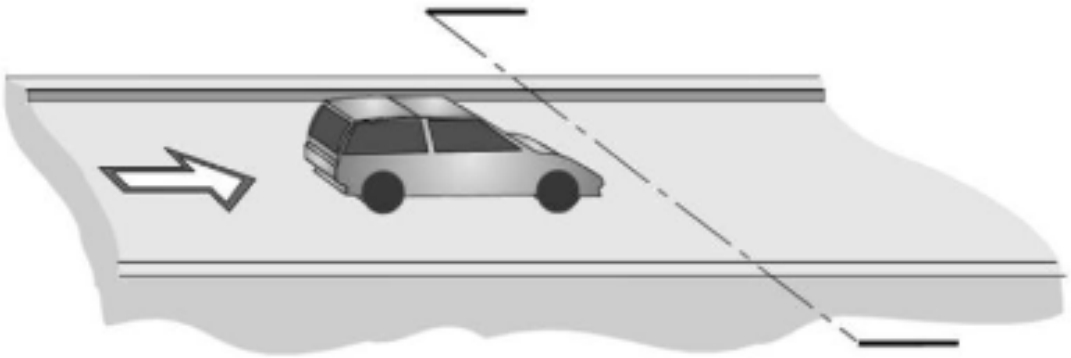

Slika 1 Protok vozila na presjeku ceste

Izvor: [3]

Na Slika 1 prikazan je protok vozila na presjeku ceste.

S druge strane, protok vozila na dionici ceste predstavlja aritmetičku sredinu protoka na n presjeka na dijelu ili prometnoj dionici gdje je broj presjeka beskonačan. Dolje prikazano na Slika 2 je protok vozila na dionici ceste.

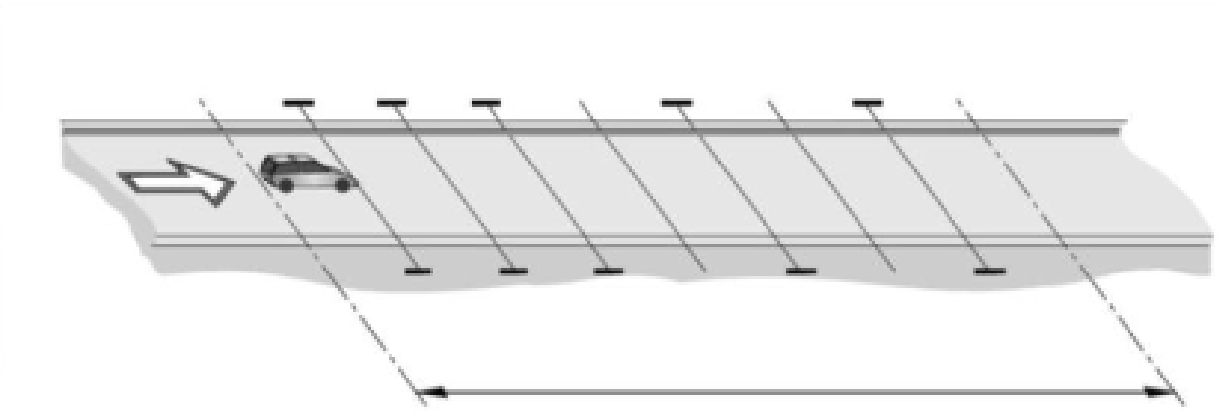

Slika 2 Protok vozila na dionici ceste

Izvor: [3]

Osnovni simbol za označavanje protoka je q (voz/h). Također, koriste se i simboli PGDP (prosječni godišnji dnevni promet, voz/dan), PDP (prosječni dnevni promet, voz/24) te DP (dnevni promet, Voz/24h). [1]

2.1.2 Gustoća prometnog toka

Gustoća prometnog toka se odnosi na broj vozila (ili pješaka) koji zauzimaju promatranu duljinu traka ili ceste u određenom trenutku. Pojam gustoće vezan je prostorno za odsjek ili prometnu dionicu, a vremenski za trenutno stanje.

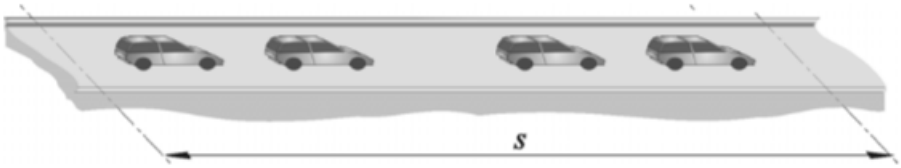

Slika 3 Gustoća prometnog toka

Izvor: [1]

Na Slika 3 je prikazano kako se mjeri gustoća prometa. S predstavlja duljinu promatrane dionice ceste u određenom trenutku te se zbraja broj vozila N na promatranoj dionici. Budući da gustoća predstavlja broj vozila po jedinici dužine promatranog odsjeka u trenutku promatranja jedinica kojom se izražava gustoća g je voz/km.[1]

2.1.3 Brzina prometnog toka

Brzina prometnog toka je srednja brzina svih vozila koja sudjeluju u promatranom prometnom toku. Brzina je važan parametar pri određivanju kvalitete prometne usluge. Kod proračuna se najčešće koristi prosječna brzina putovanja jer se jednostavno računa analizom kretanja vozila u prometnom toku i najviše je statistički relevantna u odnosu na druge varijable. Prosječna brzina putovanja određuje se dijeljenjem promatrane duljine dionice ceste s prosječnim vremenom putovanja vozila u prometnom toku. Vrijeme putovanja uključuje i vrijeme stajanja uzrokovanih zastojima u prometnom toku.

Ovisno o načinu na koji se promatra protok u odnosu na prostor i vrijeme, te s obzirom značenja pojmova protoka vozila i gustoće toka, u teoriji prometnog tok su uspostavljena dva pojma za definiranje brzine prometnog toka kao odgovarajuće srednje vrijednosti brzina svih vozila koja čine promatrani prometni tok, a to su[1]:

a) Srednja prostorna brzina toka (V_s), koja je analogno gustoći prostorno vezana za odsjek puta (S), a vremenski za trenutak.
b) Srednja vremenska brzina toka (V_t), koja je analogno protoku vozila prostorno vezana za presjek puta, a vremenski za period promatranja (T).

2.1.3.1 Srednja prostorna brzina prometnog toka

Srednja prostorna brzina prometnog toka predstavlja aritmetičku sredinu trenutnih brzina svih vozila u prometnom toku na promatranom odsjeku puta. U stručnoj literaturi se ova brzina naziva i srednja trenutna brzina.

Srednja prostorna brzina toka, s gledišta prostornog promatranja predstavlja brzinu na dionici ceste, a s gledišta vremenskog promatranja predstavlja trenutnu brzinu to.

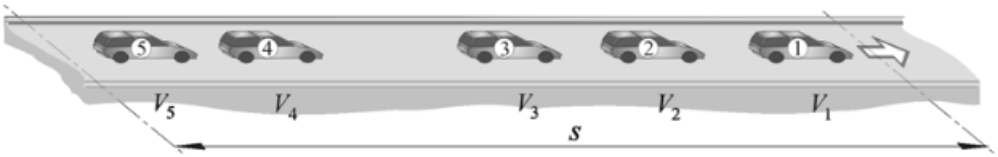

Slika 4 Srednja prostorna brzina prometnog toka

Izvor: [1]

Na Slika 4 prikazana je srednja prostorna brzina prometnog toka gdje $V_1 - V_5$ predstavljaju brzine pojedinih vozila, a S predstavlja neku promatranu dionicu ceste.

U stručnoj literaturi, mjerenje srednje prostorne brzine često se naziva trenutno promatranje na odsjeku puta.[1]

2.1.3.2 Srednja vremenska brzina toka

Srednja vremenska brzina prometnog toka predstavlja aritmetičku sredinu brzina svih vozila u prometnom toku koja prolaze kroz promatrani presjek puta, u određenom periodu vremena.

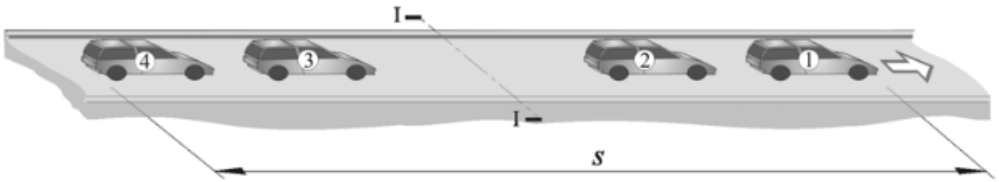

Slika 5 Srednja vremenska brzina toka

Izvor: [1]

Na Slika 5 prikazana je srednja vremenska brzina toka gdje brojevi 1-4 označavaju vozila, a I označava promatrani presjek dionice ceste.[1]

2.1.3.3 Brzina prometnog toka s obzirom na vrste prometnih tokova

Ovisno o uvjetima kretanja vozila u prometnom toku te s obzirom na stupanj interakcijskog utjecaja pri približno idealnim prometnim i putnim uvjetima, srednja prostorna i srednja vremenska brzina prometnog toka dobivaju sljedeće nazive[1]:

1. Brzina slobodnog toka - vezana je za slobodan tok i podrazumijeva da se sva vozila u prometnom toku na promatranom odsjeku kreću u identičnim ili bliskim uvjetima kretanja koja odgovaraju kretanju pojedinačnih vozila na dotičnom odsjeku V_si V_t.
2. Brzina normalnog toka - (stabilan, polustabilan i nestabilan); pojam brzine normalnog toka vezan je za stabilan, polustabilan i nestabilan prometni tok u kome na uvjete kretanja vozila djeluje i interakcija između vozila u toku V_si V_t.
3. Brzina zasićenog toka - predstavlja brzina pri kapacitetu; vezana je uz zasićen prometni tok u kome se sva vozila kreću uz potpuno ili približno potpuno djelovanje interakcije između vozila u toku. U uvjetima zasićenog toka sva vozila se kreću približno istom brzinom, što znači da ne postoji gotovo nikakva kvantitativna razlika između srednje prostorne i srednje vremenske brzine prometnog toka.
4. Brzina forsiranog (prisilnog) toka - pojam brzine forsiranog toka vezan je za prisilan prometni tok. U uvjetima forsiranog (prisilnog) toka vozila se kreću približno istom brzinom koja, promatrana u prostoru i vremenu.

2.1.4 Interval slijeđenja vozila

Interval slijeđenja vozila th predstavlja vrijeme između prolaska dva uzastopna vozila kroz zamišljeni presjek promatranog odsjeka puta (čeoni prolazak vozila).

Sa stajališta realnih prometnih tokova te ovisno o načinu promatranja toka u odnosu na prostor i vrijeme razlikuje se[1]:

a) interval praćenja pojedinačno za N vozila koja u periodu vremena T prođu promatrani presjek (odsjeka ili dionica) puta,
b) srednju vrijednost intervala praćenja na promatranom presjeku puta za N vozila u vremenu T,
c) interval slijeđenja na dionici puta, kao aritmetički prosjek srednjih vrijednosti intervala praćenja na m promatranih presjeka puta u vremenu T.

Interval praćenja vozila na presjeku puta predstavlja vrijeme prolaska prednjeg kraja uzastopnih vozila preko promatranog presjeka puta. Interval praćenja na odsjeku ili dionici puta predstavlja aritmetičku sredinu intervala praćenja na n - presjeka odsjeka ili dionice za promatrani prometni tok. Osnovna jedinica za iskazivanje praćenja vozila je sekunda.

Interval praćenja vozila ima veliki značaj za opisivanje uvjeta odvijanja prometa na cestama, ne samo kao osnovni pokazatelj za teorijska uopćavanja međuovisnosti u prometnom toku, već i u inženjerskoj praksi kao osnovni indikator kvaliteta prometnog toka.[1]

Slika 6 Interval slijeđenja

Izvor: [4]

Na slici 6. prikazano je kako se mjeri interval slijeđenja između dva vozila.

2.1.5 Razmak slijeđenja vozila

Razmak slijeđenja vozila predstavlja prostorni razmak između dva uzastopna vozila u prometnom toku i najčešće se označava sa S_h, a izražava u metrima. Sa stajališta realnih prometnih tokova na odsjeku puta razmak u praćenju predstavlja srednju vrijednost svih razmaka praćenja između uzastopnih vozila u određenom toku na promatranom odsjeku ili dionici puta. Razlikuju se[1]:

a) Udaljenosti između pojedinih vozila u prometom toku koja su se našla u određenom trenutku na promatranom odsjeku ili dionici puta; S_{hi}, gdje je i = 1,2,....n.
b) Srednja vrijednost trenutnih razmaka između svih vozila u prometnom toku koja su se našla u određenom trenutku na promatranom odsjeku ili dionici puta S_h.
c) Aritmetički prosjek m-srednjih trenutnih razmaka utvrđenih na promatranom odsjeku u periodu vremena T.

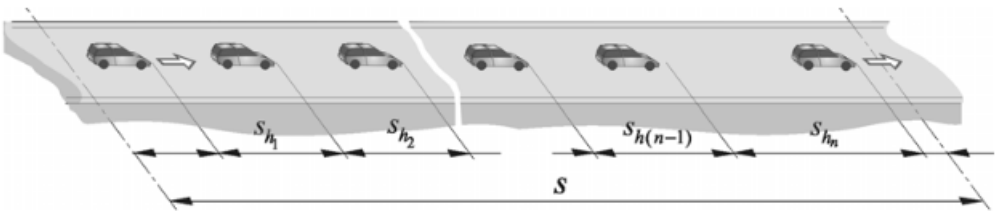

Slika 7 Razmaci u slijeđenju vozila

Izvor: [1]

Na slici 7. prikazani su razmaci u slijeđenju vozila S_{hi} na nekoj dionici ceste S.

Udaljenost između vozila se, za razliku od razmaka slijeđenja, prikazuje kao razmak između stražnjeg kraja prvog vozila i prednjeg kraja vozila koje slijedi.[1]

2.1.6 Ostali parametri prometnog toka za potrebe ITS-a

Prisutnost zaustavljenog vozila (P_Z) predstavlja vozilo koje se nalazi na određenoj prometnoj površini i miruje tijekom vremenskog intervala T. Prisutnost vozila označava se logičkom 0 kada nema zaustavljeno vozilo ili logičkom 1 kada postoji zaustavljeno vozilo, tijekom intervala T.

Prisutnost vozila u prolazu (P_P) javlja da vozilo prolazi određenom prometnom površinom ili presjekom prometnice u nekom trenutku t. Također se prikazuje logičkom 0 kada ne postoji vozilo u prolazu ili logičkom 1 kada postoji vozilo u prolazu, u određenom vremenskom trenutku t.

Duljina reda (R_q) predstavlja broj vozila koja se nalaze u redu čekanja, npr. na prilazu raskrižju ili rampi. Mjerna jedinica je broj vozila u redu ili duljina reda u metrima (m).

Profil prilaznog toka (P_T) je broj vozila u skupini vozila koja se kreće i približava raskrižju. Mjerna jedinica je broj vozila u redu ili duljina reda u metrima (m).

Prometni zahtjevi (Z_p) predstavljaju broj vozila koja žele upotrijebiti određenu dionicu prometnice u određenom intervalu. Mjerna jedinica je broj vozila po satu, minuti ili danu (voz/h, voz/min, voz/dan).

Propusnost (p_q) predstavlja prijeđene vozilo-kilometre za zadanu duljinu prometnice i za zadani vremenski period. Mjerna jedinica je $\frac{voz \times km}{h}$.

Zauzeće (O) predstavlja dio vremena koji protekne od trenutka kada čelni dio vozila prelazi početak detekcijske zone, do trenutka kada stražnji kraj napušta detekcijsku zonu te se definira za neki vremenski interval T i izražava u postocima (%).

Kašnjenje na dionici (t_d) ili vrijeme putovanja na dionici je vrijeme potrebno da vozilo prijeđe određenu udaljenost na prometnoj mreži, a mjeri se u sekundama, minutama ili minutama po kilometru (s, min, min/km).

Kašnjenje na raskrižju (t_k) je vrijeme koje protekne od trenutka prilaza vozila raskrižju do trenutka napuštanja raskrižja. Mjeri se u sekundama ili minutama (s, min).

P-O podaci prometne mreže opisuju kretanje vozila u smislu smjera i puta, a prikazuju se P-O matricom (volumeni prometa).

P-O podaci raskrižja pokazuju volumene prometa po smjerovima kretanja, a prikazuju se P-O matricom (volumena prometa).

Klasifikacija dimenzije je za određivanje vozila prema duljini L, širini š te visini h.

Klasifikacija mase je za određivanje vozila prema masi.

Funkcijskom klasifikacijom se vozila dijele na osobna vozila, vozila javnog prijevoza te razne javne službe.[2]

2.2 Uloga parametara u upravljanju

Prikupljanje parametara prometnog toka ima bitnu ulogu u upravljanju raskrižjima. Na primjer, vremenski ustaljeno upravljanje pojedinačnim prometnim raskrižjem podrazumijeva unaprijed definirane signalne planove i slijed izmjene signalnih planova. Takvu vrstu upravljanja karakterizira fiksna duljina ciklusa i faza te fiksni broj i slijed faza signalnog plana. Signalni planovi se mijenjaju prema unaprijed utvrđenom vremenskom planu, primjerice ovisno o dobu dana, kako bi se signalni plan prilagodio promjenama prometnog opterećenja. Potrebno je prikupiti podatke o prometnom opterećenju, u svrhu izrade projekta signalnih planova. U tim situacijama mogu se koristiti detektori te se njihova primjena prvenstveno svodi na prikupljanje podataka o volumenu prometa na glavnom prometnom pravcu i sporednim prometnim pravcima. Za stvaranje kvalitetnijih signalnih planova i njihova vremenskog slijeda, potrebni su mikroskopski P-O podaci.

Bez podataka o parametrima prometnog toka, bilo bi teško napraviti kvalitetan signalni plan za raskrižje te bi bila veća mogućnost pojave zagušenja i dugih repova čekanja. Isto vrijedi i za upravljanje prometom na određenom potezu kao i na upravljanje mrežom. Bez adekvatnih podataka o prometnom toku na određenom potezu, zeleni val ne bi mogao funkcionirati, dok se prilikom izračuna signalnog plana za zatvorenu mrežu sva raskrižja moraju uzeti u obzir, a to znači puno veća potreba za točnim informacijama o parametrima pojedinih tokova.[2]

2.3 Prometni parametri kao pokazatelji kvalitete

Kvaliteta usluge (engl. LOS – *Level of Service*) definirana je kao kvalitativna mjera koja odražava percepciju korisnika glede kvalitetne usluge, komfora, i praktičnosti. Promjena u bilo kojoj od određenih skupina parametara, sudionici u prometu izravno doživljavaju kao promjenu kvalitete usluge. Pomoću tih parametara može se izraziti kvaliteta usluge koju nudi prometni sustav. Među neke od pokazatelja kvalitete usluge spadaju: trenutačna brzina, srednja vremenska brzina, srednja prostorna brzina, gustoća, zauzeće, kašnjenja i zaustavljanja.

S obzirom na to da da brzina prikazuje promjenu položaja prometnih entiteta u vremenu, ona je prirodni pokazatelj stupnja kvalitete odvijanja prometa. Kao takve se promatra s dva gledišta: s makroskopskog i s mikroskopskog. S makroskopskog gledišta pokazatelj je učinkovitosti upravljačkog sustava, dok je s mikroskopskog gledišta, kao brzina pojedinog vozila, izravno povezana sa zadovoljstvom korisnika prometnog sustava, odnosno njegovim dojmom stupnja usluge.

Gledajući gustoću prometa na autocesti s više trakova, definiraju se i osnovni stupnjevi usluge od A do F te i vrsta toka. Prema tome, stupanj usluge A predstavlja slobodan tok gdje je velika sloboda izbora brzine i manevriranja u prometnom toku, a stupanj usluge F predstavlja zagušenje prometnog toka i formiranje repova čekanja.

Također, još jedan od pokazatelja može biti kašnjenje vozila na signaliziranom raskrižju. Kao i za prijašnji slučaj, stupnjevi usluge su od A do F. Stupanj usluge A predstavlja raskrižje s vrlo malo kašnjenja te se većina vozila ne zaustavlja, dok stupanj usluge F predstavlja stanje neprihvatljivo za većinu vozača s kašnjenjem vozila preko 60 s.[2]

3. Pregled tehnologija za prikupljanje podataka i mjerenje parametara prometnog toka

Unaprjeđenje postojeće prometne mreže je neophodno zbog kontinuiranog porasta količine prometa, kao i ograničenog prostora za izgradnju daljnje prometne infrastrukture. Alternativa izgradnji nove i skupe prometne infrastrukture dolazi u vidu implementacije novih strategija koje promoviraju efikasnije načine iskorištenja postojeće prometne infrastrukture. Takve strategije se sve češće primjenjuju u sklopu ITS-a, a koji imaju za glavne ciljeve smanjiti vrijeme putovanja, kašnjenje i učestalost zagušenja, kao i povećanje sigurnosti i smanjenje ispušnih plinova. ITS koji primjenjuje elektronički nadzor, komunikaciju, kao i prometne analize, koristi određene tehnologije kojima pomaže korisnicima i upraviteljima prometnog sustava.[5]

Prikupljanje podataka o prometu je jedan od najbitnijih preduvjeta za analizu, a zatim i unaprjeđenje postojećeg stanja u prometu. S razvojem tehnologije, dolazi se i do brojnih novih načina prikupljanja podataka o prometu te koji pomažu pri mjerenju parametara prometnog toka. Tehnologije koje se koriste za prikupljanje podataka o prometnim tokovima mogu se podijeliti na sljedeći način[2]:

- Detektori prometnog toka,
- Pokretna osjetila,
- Bežične tehnologije kratkog dometa.

U svrhu što boljeg prikupljanja podataka, kao i dobivanje najraznovrsnijih informacija o prometu i sudionicima, gore navedene tehnologije se koriste individualno ili u kombinaciji s drugim tehnologijama, a sve s ciljem postizanja točnijih i korisnijih podataka na temelju kojih se, uz analizu i adekvatna rješenja, može unaprijediti postojeći prometni sustav.

3.1 Detektori prometnog toka

U sklopu tehnologija koje se koriste u prometu, a vezanih za prikupljanje podataka i mjerenje parametara prometnog toka koriste se dva osnovna pojma: detektor i senzor. Detektorom se naziva tehnologija pomoću koje se samo može otkriti prisutnost vozila. S druge strane, pojam senzor predstavlja hardver i prateći softver koji može prepoznati prisutnost vozila i pretvoriti tu informaciju u podatke o prometnom toku. Dok se u stručnoj literaturi najčešće koristi izraz detektor prometnog toka, ispravnije je tehnologije koje se koriste za prikupljanje podataka o prometnom toku nazvati senzorima prometnog toka. Osim što imaju mogućnost otkrivanja vozila u prometnom toku, prikupljaju i čitav niz podataka o prometnom toku. Međutim, u daljnjem tekstu, koristit će se izraz detektor prometnog toka zato što se u većini literature koristi takav naziv.[5]

Detektori prometnog toka se mogu klasificirati u dvije osnovne kategorije: intruzivni i neintruzivni.

3.1.1 Intruzivni detektori prometnog toka

Intruzivni detektori prometnog toka su oni koju su ugrađeni u samu cestu. Oni imaju visoku točnost, ali isto tako imaju i visoke troškove ugradnje i održavanja. U suštini, intruzivni detektori se mogu podijeliti na[2]:

1. Induktivne petlje
2. Magnetske detektore
3. Piezoelektričke detektore

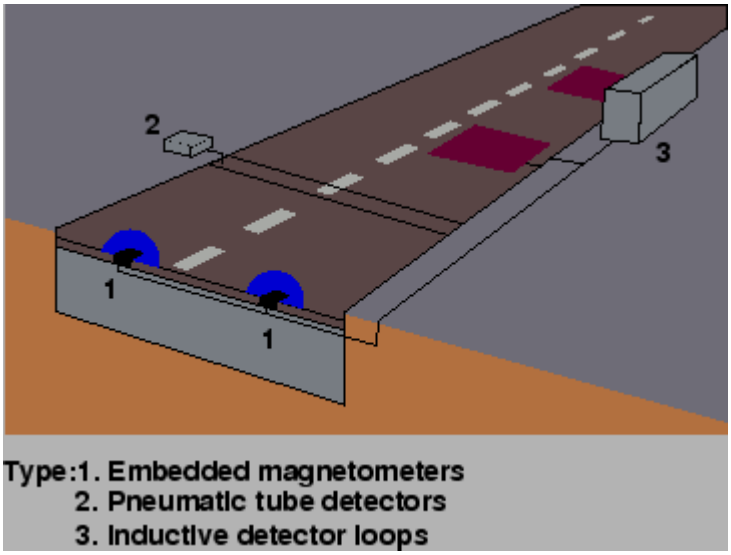

Slika 8 Intruzivni detektori: 1. magnetometar, 2. piezoelektrički detektor, 3. induktivna petlja

Izvor: [6]

Na gore navedenoj slici 8. prikazane su 3 osnovne vrste intruzivnih detektora prometnog toka te gdje se postavljaju na presjeku ceste.

Glavna prednost intruzivnih detektora je zrelost takve tehnologije. Intruzivni detektori se uvelike koriste, takva tehnologija je već naširoko implementirana i ima visoku razinu točnosti u otkrivanju prisutnosti vozila. Ali, kao što je već ranije spomenuto, postavljanje takvih detektora je skupo, prilikom postavljanja samih senzora dolazi do ometanja i usporavanja prometa, potrebno je održavanje i česti popravci. [7]

3.1.1.1 Induktivna petlja

Induktivna petlja (engl. *Inductive loop detector*) je najčešće korišten detektori u svrhu upravljanja prometom. Veličina i oblik induktivne petlje se razlikuju ovisno svrsi detekcije (npr. automobili, manja vozila i bicikli, duža vozila i kamioni, detektiranje repova čekanja na silasku s autoceste, brojanje vozila, te sigurnosna primjena koja zahtjeva kontrolu brzine).[5]

Induktivna petlja funkcionira kao što joj i samo ime govori na temelju indukcije ili pobude. Induktivna petlja se sastoji od tri osnovna elementa. Jedan element je žica u petlji koja je postavljena unutar kolnika te preko koje vozila prolaze. Drugi element je kontrolni uređaj (ili

elektronička jedinica) koji je postavljen uz kolnik te treći element je kabel koji povezuje vodiče petlje s elektroničkom jedinicom. Žica unutar same petlje je induktivni element u oscilirajućem strujnom krugu i pokreče ju elektronička jedinica na frekvencijama između 10 i 50 kHz. Kada vozilo pređe preko petlje ili se zaustavi na petlji, induktivitet u petlji pada. Uzrok pada su vrtložne struje koje inducira metalno vozilo, a njihov magnetski tok je suprotan smjeru magnetskog toka petlje. Rezultat je smanjenje ukupnog toka, a time i smanjenje induktiviteta. Sa smanjenjem induktiviteta u petlji, šalje se signal elektroničkoj jedinici koja registrira prisutnost ili prolazak vozila. Induktivne petlje mogu otkriti prisutnost vozila, prolazak vozila, mogu brojati broj vozila koji je prošao kao i zauzetost prometne trake. Iako direktno ne mogu mjeriti brzini, postavljanjem takozvane klopke se može mjeriti vrijeme prolaska vozila između dvije petlje na unaprijed definiranim udaljenostima. Na osnovu udaljenosti i vremena između dviju pobuda se može dobiti brzina vozila.

Standardne dimenzije induktivnih petlji uključuju od 1.5 m x 1.5 mm do 1.8 m x 1.8 m za četvrtaste petlje, 1.8 m promjer za okrugle petlje, te pravokutne sa 1.8 m širine i promjenjive duljine. Četveropolna petlja se koristi za bolju detekciju motocikla i bicikla. S urezima na rubovima se pojačava snaga elektromagnetskog polja u središtu petlje te se time smanjuje utjecaj vozila iz susjednih traka. Petlje u obliku dijamanta također poboljšavaju detektiranje motociklista proširivanjem polja do rubova trake gdje motocikli povremeno voze.

Najveći broj kvarova induktivnih petlji se odnosi na kolnik loše kvalitete, samo postavljanje petlje unutar kolnika te česti radovi na mjestu gdje je postavljena petlja.[5]

3.1.1.2 Magnetski detektori

Magnetski detektori su pasivni uređaji koji detektiraju promjene zemljinog magnetskog polja uzrokovane prolaskom vozila. Prisutnost vozila uzrokuje magnetsku anomaliju poznatu i kao magnetska sjena vozila. Postavljeni su unutar kolnika ili na kolniku. Postoje dvije vrste magnetskih detektora [5]: magnetski detektor s ispitnom zavojnicom i magnetometar.

Magnetski detektor s ispitnom zavojnicom detektira promjene u vertikalnim i horizontalnim komponentama zemljinog magnetskog polja izazvano željeznim svojstvima metalnih vozila.

Magnetski detektor s ispitnom zavojnicom sastoji se od sonde, spojnog kabela i elektroničke jedinice. Sonda magnetskog detektora s ispitnom zavojnicom je cilindričnog oblika. Ona se postavlja ispod površine kolnika, okomito na smjer prometnog toka. Sonda se postavlja isključivo na području slobodnog prometnog toka na dovoljnoj udaljenosti od zaustavne crte jer ne može detektirati zaustavljeno vozilo ili sporo vozilo. Uvjet detekcije vozila je da napon koji mora postići je veći od određene razine inače se vozilo neće registrirati. Snaga impulsa koji generira zavojnica je veća ako vozilo izaziva veći poremećaj u magnetskom polju, odnosno što brže vozilo prolazi i što je bliže sondi.

Magnetski detektori s ispitnom zavojnicom su jeftini, jednostavni i robusni uređaji koji su pogodni za uporabu gdje je površina kolnika loša ili oštećena, te gdje nije preporučljivo površinu kolnika rezati ili bušiti. Prilikom postavljanja detektora treba obratiti posebnu pažnju na vodove jer prigušenje signala u spojnom vodu ili utjecaj drugih vodova mogu uzrokovati pogreške pri detekciji. Robusnost sonde te pravilno izvedeno postavljanje i spajanje rezultiraju izrazito dugim radnim vijekom.

Magnetometar detektira otisak vozila tako što mjeri smetnje u linijama magnetskog polja induciranih promjenama u zemljinom magnetskom polju izazvane mobilnim željeznim svojstvima metalnih vozila. Magnetometarska sonda je tipično valjkastog oblika i postavlja se u rupu izbušenu u kolniku Slično kao i kod magnetskog detektora s ispitnom zavojnicom, magnetometri generiraju napon kada feromagnetski predmet utječe na zemljino magnetsko polje.

Većina magnetskih detektora ne detektira zaustavljena vozila s obzirom na to da bi se vozilo trebalo kretati ili nekako utjecati na promjenu svojih karakteristika kroz neko vrijeme. Ali zato više magnetskih detektora mogu biti postavljeni da bi se generirali podaci o prisutnosti vozila.[5]

3.1.1.3 Piezoelektrički detektori

Kada vozilo prijeđe preko detektora, ono stvori pritisak unutar detektora. Taj pritisak utječe na piezoelektrički materijal koji potom generira napon proporcionalan sili odnosno

težini vozila. Senzorski element piezoelektričkog detektora izrađuje se u obliku koaksijalnog kabela ili nagazne površine. Postoje dvije klase piezoelektričnih detektora. Klasa I detektira broj osovina i daje podatak o težini. Klasa II samo detektira prelazak osovine, stoga može klasificirati vozila samo prema broju osovina. Piezokabel je građen kao koaksijalni kabel te se sastoji od metalne jezgre, piezoelektričnog materijala i metalnog omotača.

Piezoelektrični detektori mogu davati podatke o intenzitetu prometa, klasifikaciji na osnovi brojenja osovina, o težini vozila, o brzini vozila. Mjerenje brzina zahtjeva barem dva senzorska elementa.

Kao i kod induktivne petlje, kvaliteta prometna površine utječe na vjerojatnost kvarova i životni vijek piezodetektora. Propadanje prometne površine i pojava nabiranja mogu smanjiti točnost glede mjerenja težine. Nabiranje i neravnine na prometnoj površini prije mjesta gdje je postavljen piezosenzor uzrokuju pulsirajući pritisak guma vozila na podlogu pa ako se piezodetektor koristi u svrhu detekcije, rezultat može biti i izostanak detekcije ili pogrešna klasifikacija prema broju osovina.[2]

3.1.2 Neintruzivni detektori prometnog toka

Neintruzivni detektori prometnog toka ili njihov senzorski element postavljaju se na stupove pokraj prometnice ili konzole iznad prometnice. Takvi detektori mogu detektirati parametre vozila poput brzine vozila i zauzeća, ali su skupi i podložni vremenskim neprilikama. Neintruzivni detektori mogu se podijeliti na[2]:

1. Pasivni infracrveni detektor
2. Aktivni infracrveni detektor
3. Radarski detektor
4. Pasivni zvučni detektor
5. Ultrazvučni detektor
6. Videodetektor

Neintruzivni detektori pružaju brojne mogućnosti intruzivnih senzora s manje poteškoća koje imaju intruzivni senzori, ali već kao što je ranije spomenuto vremenske neprilike poput

snijega, kiše i magle između ostalih mogu utjecati na njih. Neintruzivni senzori su uočljiviji vozačima te mogu iz toga razloga izazvati različite i brže reakcije vozača poput usporavanja vozila i korištenja prave prometne trake po prepoznavanju uređaja.[7]

3.1.2.1 Pasivni infracrveni detektori

Senzorski elementi infracrvenih detektora osjetljivi su na zračenje u infracrvenom području elektromagnetskog spektra. Sustavom optike, energija zračenja usmjeruje se na osjetljiv materijal, koji primljenu energiju pretvara u električki signal. S obzirom na razlučivost, postoje neslikovni i slikovni detektori. Neslikovni detektor ima najviše do pet odvojenih energetskih elemenata, dok slikovni ima dvodimenzionalno polje infracrveno osjetljivih elemenata (piksela) i stvara sliku u infracrvenom području.[2]

Svaki objekt koji nije na temperaturi apsolutne nule (0 K) zrači u infracrvenom području elektromagnetskog spektra (emitira termalno zračenje). Zračena snaga objekta ovisi o površini objekta, veličini i strukturi. Pasivni detektor reagira na promjene energije zračenja. Ulaskom vozila u detekcijsku zonu, mijenja se energija zračenja zbog promjene temperature u vidnom polju detektora, a dolazi i do promjene reflektirane energije okoline. Detekcijska zona detektora je određena konstrukcijom optike.

Neslikovni pasivni infracrveni detektor s jednom detekcijskom zonom može detektirati prolaz i prisutnost vozila, odnosno može davati podatke o volumenu prometa i zauzeću detekcijske zone. Detektor s više energetski osjetljivih elemenata, odnosno više detekcijskih zona, uz analizu pojedinih signala, osim intenziteta i zauzeća može davati podatke o duljini vozila i brzini.

Senzorski piroelektrički element osjetljiv je na daleko infracrveno zračenje 8-14 μm. U tom području sposobnost detekcije ne ovisi o uvjetima osvjetljenja ili boji objekta. Kiša i velika vlaga uzrokuju porast temperature okoline što može rezultirati slabljenjem signala. Neželjene signale može izazvati i odbljesak sunca. Izrazito loše vrijeme, gusta magla, gusti snijeg, mogu raspršiti ili apsorbirati energiju prije nego što je uhvati otvor detektora.

Infracrveni detektori postavljaju se iznad prometnice ili sa strane prometnice. Kao nosiva konstrukcija mogu poslužiti konzole lanterni, stupovi rasvjete ili drugi objekti.[2]

3.1.2.2 Aktivni infracrveni detektor

Aktivni infracrveni detektori poznati su i pod nazivom Laser Radar detektori. Oni se sastoji od odašiljačkog i prijamnog dijela. Odašiljački dio šalje kratke impulse elektromagnetskih valova u bliskom infracrvenom području, a prijemni dio prima reflektirane impulse. Odašiljački dio sastoji se od izvora zračenja, optike i pripadne elektronike koja upravlja stvaranjem infracrvenih zraka. Elektronika, odnosno generator takta šalje start impuls modulu izvora zračenja. Kao izvor se može koristiti LED (engl. *light-emitting diode*) dioda ili LASER (engl. *light amplification by stimulated emission of radiation*) dioda. Aktivni infracrveni detektori sadrže preciznu mehaniku i optiku te iz tog razloga spadaju u najskuplje detektore.[2]

Višestruka zraka aktivnog infracrvenog detektora omogućuje mjerenje brzine, uz uvjet poznate geometrije (pozicija detektora, kut zraka, visina postavljanja, itd.). Također suvremeni aktivni infracrveni detektori koji generiraju trodimenzionalnu sliku objekta imaju mogućnost klasifikacije u 11 kategorija vozila. Detektor još može davati podatke o prisutnosti, volumenu i zauzeću.

Blisko infracrveno zračenje slabije prodire kroz maglu, kišu i snježne padaline od dalekog infracrvenog pa se iz tog razloga detekcijska zona aktivnog infracrvenog detektora nalazi u blizini detektorskog elementa.

Kao i u slučaju pasivnih infracrvenih detektora, i aktivni infracrveni detektori postavljaju se iznad prometne površine, na konzole, stupove rasvjete ili druge objekte.[2]

3.1.2.3 Radarski detektori

Princip rada radarskih detektora se zasniva na odašiljanju radiovalova mikrovalnog područja i prijemu povratnog signala (reflektirani radiovalovi od objekata). Frekvencijsko područje radiovalova primjenjivo za radare je od 3 MHz do 300 GHz. Vozilo će se detektirati ako je primljena snaga povratnog signala dovoljno velika, odnosno ako je gustoća snage povratnog signala na mjestu prijama dovoljno velika. Prednost radarskih detektora ogleda se u tome što radiovalovi X frekvencijskog pojasa radiovalova prodiru kroz, kišu, maglu i snijeg. Također, na točnost ne utječe osvjetljenje (dan, noć), a ni prijelazi doba dana kao ni temperatura okoline i objekata.

Dvije su osnovne vrste radara[2]:

- Radar s kontinuiranim odašiljačkim signalom (engl. *CW Doppler radar - Continuous Wave Doppler Radar*)
- Radar s frekvencijskim moduliranim odašiljačkim signalom (engl. *FMCW radar – Frequency Modulated Continuous Wave radar*)

Doppler radar s kontinuiranim odašiljačkim signalnom, predajnom antenom zrači radiovalove konstantne frekvencije prema području u kojemu se želi detektirati vozilo. Prijamna antena prima reflektirane valove od vozila. Prema Dopplerovom efektu frekvencija primljenoga reflektiranog signala se povećava u odnosu na odaslani signal ako se vozilo približava. Prema Dopplerovom efektu, frekvencija primljenoga reflektiranog signala se povećava u odnosu na odaslani signal ako se vozilo približava, odnosno frekvencija primljenog signala se smanji ako se vozilo udaljava.

Ovisno o poziciji na kojoj je postavljen, Doppler radar s kontinuiranim odašiljačkim signalnom može detektirati brzinu i prolaz vozila. S većom detekcijskom zonom mogu služiti u funkciji najave vozila, odnosno u određivanju ukupnog volumena prometa. Ne mogu detektirati zaustavljeno vozilo jer je za detekciju potrebna neka minimalna brzina (5-8 km/h).

Radarski detektor s frekvencijski moduliranim odašiljačkim signalom odašilje radioval čija se frekvencija mijenja po linearnoj funkciji vremena unutar nekog radnog frekvencijskog pojasa. Udaljenost objekta koji se nalazi u detekcijskoj zoni dobiva se mjerenjem vremena proteklog od odašiljanja signala do primitka povratnog signala. Budući da FMCW radarski detektor mjeri udaljenost od detektora do objekta, može se dobiti i podatak o prisutnosti vozila u detekcijskoj zoni. Brzina se može dobit pomoću Dopplerovog frekvencijskog pomaka ili

pomoću nekoliko detekcijskih zona. S više senzorskih elemenata može se dobiti i informacija o duljini repa čekanja. Osim gore navedenih parametara, FMCW detektor može i davati podatke o zaustavljenom vozilu, volumenu prometa, zauzeću te ograničeno klasificirati vozila.[2]

3.1.2.4 Pasivni zvučni detektor

Pasivni zvučni detektori koriste zvučne valove za dobivanje podataka o parametrima prometnog toka. Oni primaju i analiziraju zvučne valove koje proizvodi prometni sustav te hvataju zvučne valove čujnog područja generirane vozilima. Primarni izvor zvučnih valova je buka nastala trenjem guma vozila s površinom prometnice. Stoga je poželjno postavljanje pasivnih zvučnih detektora pokraj prometnice, kako bi polje mikrofona bilo usmjereno upravo na gume vozila, a pri manjim brzinama, zvučni detektori slušaju i zvuk koji proizvode motori. Frekvencijsko područje zvučnih valova koje prima pasivni zvučni detektor načelno se nalazi između 8 kHz i 15 kHz.[2]

Detektorski element sastoji se od dvodimenzionalnog polja usmjerenih mikrofona. Dimenzije i oblik detekcijske zone određuju konfiguracija polja mikrofona, parametara mikrofona i položaj polja u prostoru. Ulaskom vozila u područje detekcije dolazi do porasta gustoće snage zvučnih valova i do promjena u signalu generiranom poljem mikrofona. Algoritmi obrade signala prepoznaju promjene u signalu i generira se signal prisutnosti vozila. Pad gustoće snage zvučnih valova ispod neke granične značit će da je vozilo izašlo iz područja detekcije. Zvučni valovi koji dolaze izvan područja detekcije se prigušuju.

Pasivnim zvučnim detektorom mogu se dobiti podaci o volumenu prometnog toka, zauzeću, brzini i klasifikaciji prometnog toka. Brzina se može dobiti pomoću brzinske klopke, s time da onda postoji više detekcijskih zona, ili na osnovu pretpostavljene duljine vozila i izmjerenog podatka o zauzeću. Klasifikacija vozila pasivnim zvučnim detektorom je ograničena. Mogu se prepoznati osobna vozila, laka teretna vozila i teška teretna vozila. Klasifikacija vozila zasniva se na usporedbi zvukova, tj. odgovarajućih signala, koje generira vozilo u prolazu i skupa poznatih zapisa različitih kategorija vozila.

Na točnost detektora utječu pojave koje djeluju na propagaciju zvučnih valova poput jakog vjetra, kiše i gustog snijega. Osim toga, ako vozila iz susjednog traka proizvode jaku buku može doći do pogrešne detekcije. U uvjetima velike gustoće prometnog toka i male brzine dolazi do degradacije kvalitete dobivenih podataka.[2]

3.1.2.5 Ultrazvučni detektori

Ultrazvučni detektori, odašilju zvučne valove frekvencija između 25 kHz i 50 kHz, odnosno ultrazvuk. Ultrazvučni valovi reflektiraju se od objekta koji se nalazi u detekcijskoj zoni, hvataju i analiziraju detektorom. Ultrazvučni detektori postavljaju se iznad prometnice ili pokraj prometnice. Postoje pulsni ultrazvučni detektori i detektori s kontinuiranim odašiljačkim ultrazvučnim valom.

Detektori s kontinuiranim odašiljačkim ultrazvučnim valom služe uglavnom za mjerenje brzine. Mjerenje brzine temelji se na Dopplerovu efektu, a primjenjuju se za mjerenje brzine na autocestama, dok za urbanu sredinu s gustim prometom, velikim brojem zaustavljanja i čekanja u repu nisu pogodni.

Pulsni ultrazvučni detektori emitiraju kratke sekvence ultrazvučnog vala trajanja od 0,02 ms do 2,5 ms s vremenskim razmakom od 33 ms do 170 ms. S ciljem detekcije vozila u detekcijskoj zoni mjeri se vrijeme potrebno ultrazvučnom valu da prijeđe put od detektora do detekcijske zone te natrag do detektora. Ultrazvučnom valu koji se reflektira od vozila potrebno je kraće vrijeme da prevali navedeni put, nego ako se reflektira od prometnice. Stoga primljena sekvencija ultrazvučnog vala unutar detekcijskog intervala znači da se vozilo nalazi u detekcijskoj zoni. Primljeni ultrazvučni val pretvara se u električki signal i analizira u detektorskoj jedinici, koja se nalazi u istom kućištu ili smještena u signalnom uređaju.

Ultrazvučni detektori mogu davati podatke o volumenu, prisutnosti vozila, zauzeću, klasifikaciji i brzini. Brzina se dobiva brzinskom klopkom, odašiljanjem dvaju ultrazvučnih valova pod različitim kutovima s ciljem dobivanja dviju detekcijskih zona. Mjerenjem vremena koje je vozilu potrebno da prijeđe udaljenost između dviju detekcijskih zona dobiva se brzina.

Na točnost dobivenih podataka ultrazvučnih detektora mogu utjecati promjene temperature i jaka strujanja zraka zbog vjetra ili prolaska velikih vozila.[2]

3.1.2.6 Videodetektori

Uobičajeni naziv za videodetektor odnosno sustav za snimanje i obradu slike, kojim se dobivaju podaci o parametrima prometnog toka. Videodetektor se sastoji od jedne ili više kamera, mikroprocesora za obradu slike te programa za interpretaciju slike i izvlačenje podataka o parametrima prometnog toka.[2]

Videozapis koji snima kamera sastoji se od niza slika ili okvira (engl. *frame*). Detekcija vozila koja je osnova za dobivanje ostalih podataka o parametrima prometnog toka temelji se na detekciji promjene u skupini ili skupinama piksela (elemenata slike) između slijednih okvira.

Postoji nekoliko pristupa obradi slike i ekstrakciji prometnih podataka: Tripline, CLT (*Closed Loop Tracking*) i DAT (*Data Association Tracking*). Tripline pristup dopušta korisniku definiranje konačnog broja linearnih geometrijskih detekcijskih zona (npr. linije i pravokutnici) u kojima se detektira vozilo. Podaci o brzini mogu se dobiti na osnovi mjerenja vremena i poznate udaljenosti između detekcijskih zona. CLT je proširenje Tripline postupka koje omogućuje detekciju vozila na većoj prometnoj površini. CLT mogu se dobiti dodatni podaci o trajektoriji vozila, poput promjene prometnog traka, skretanja u zabranjeni smjer i dr. Data Association Tracking pristup omogućuje dobivanje podataka o vremenu boravka na dionici, P-O podatke (unutar vidnog polja kamere). Vozilo se identificira izdvajanjem jedinstvene povezane skupine piksela. Ta karakteristična skupina piksela izdvaja se analizom gradijenta osvjetljenja i morfologije. Analizom gradijenta utvrđuju se rubovi pojave, a analizom morfologije se dobiva kombinacija svojstava i dimenzija koja karakterizira pojavu. Povezivanjem više kamera moguće bi bilo dobiti i podatke o vremenu putovanja na dionicama te P-O podatke za područje pokriveno kamerama.

Na degradaciju svojstava videodetektora, odnosno točnost dobivenih podataka utječe više pojava: sjene, promjena osvjetljenja, refleksija, loše vremenske prilike, njihanje ili pomaci kamere zbog vjetra ili nekoga drugog uzroka. Kako su te pojave neizbježne ali i očekivane,

razvijaju se dodatni algoritmi u obradbi slike koji smanjuju utjecaj tih pojava, primjerice: algoritam stabilizacije slike, algoritam koji uzima u obzir određivanje položaja sunca, algoritam eliminacije noćne refleksije, detekcija gubitka kontrasta, prilagodba detekcije dobu dana.[2]

3.2 Pokretna osjetila

Osnovna ideja pokretnih osjetila je da vozila koja se kreću po prometnoj mreži i sastavni su dio prometnog toka prikupljaju i šalju podatke. Zahtjev koji treba biti ispunjen kod pokretnih osjetila je poznavanje pozicije vozila u određenim vremenskim trenucima. Glede toga načelno se sustav s pokretnim osjetilima može ostvariti na tri načina[2]:

- Identifikacijom vozila u određenim točkama mreže
- Lociranjem vozila resursima ćelijskih mreža
- Lociranjem vozila GNSS modulom u vozilu

Identifikacija vozila u određenim točkama je prvi način praćenja vozila na prometnoj mreži te je poznat pod kraticom AVI (engl. *Automatic Vehicle Identification*), dok se za lociranje vozila resursima ćelijskih mreža i GNSS modulom u vozilu koristi kratica AVL (engl. *Automatic Vehicle Location*). AVI identificira vozilo u fiksnim točkama mreže, a izvor podataka je vozilo koje se kreće i koje može biti identificirano na različitim točkama mreže te predati podatke o tome što se dogodilo između tih fiksnih točaka. Što se AVL tiče, najčešći termin koji se koristi u stručnoj i znanstvenoj literaturi je FCD (engl. *Floating Car Data*). Pod pojmom FCD-a uglavnom se podrazumijeva korištenje GNSS-a, tj. pokretno osjetilo opremljeno modulom za satelitsku navigaciju i lociranje te modulom za komunikaciju. Ako pokretno osjetilo nije vozilo, već „pametni“ telefon, tada se često koristi naziv FPD (engl. *Floating Phone Data*).

3.2.1 Pokretna osjetila sa GNSS lociranjem – FCD

Pokretno osjetilo, tj. vozilo, opremljeno je samo modulom koji omogućava lociranje vozila i modulom za komunikaciju. Podatke koje prikuplja takvo vozilo, odnosno odgovarajuća oprema, šalju se u centralno mjesto za obradu podataka. Umjesto izraza pokretna osjetila s

GNSS lociranjem u literaturi se najčešće koristi kratica FCD, te će se tako koristiti i u ovom diplomskom radu.

Kao pokretna osjetila, najčešće se koriste vozila koja su dio neke flote vozila poput vozila javnog gradskog prometa (JGP), taksi službe i vozila za distribuciju robe. Takva vozila već su opremljena dodatnim OBU (engl. *On Board Unit*) uređajem koji sadrži navigacijski i komunikacijski mogula, a služi za stalno praćenje vozila i komunikaciju s centrom.[2]

Sustav za prikupljanje podataka temeljen na pokretnim osjetilima, tj. FCD sustav, temelji se na više podsustava različitih tehnologija. Osnovne podatke u prostornoj i vremenskoj poziciji vozila generira GNSS modul. Komunikacijski modul u vozilu putem bežične komunikacijske mreže šalje poruke u centar za obradu podataka. Da bi se mogle obraditi i prezentirati lokacijski bazirane informacije nužan je GIS (Geografski Informacijski sustav) s pripadnim prometnim slojem. Informacije o stanju prometne mreže mogu biti iskorištene za razne namjene: upravljanje, informiranje sudionika u prometu, logističke potrebe i dr.

Osnovni podaci koje bilježe i šalju pokretna osjetila su identifikacijska oznaka vozila (ID vozila), prostorna pozicija (koordinate vozila) i trenutak zabilježene prostorne pozicije, tj. vremenska oznaka (engl. *Time Stamp*). U osnovne podatke, često je uključena i trenutačna brzina vozila te smjer vozila u odnosu na sjever. Udio FCD vozila u ukupnom broju vozila u prometnom toku i učestalost slanja poruka glavni su faktori koji određuju kvalitetu FCD podataka. Što je udio FCD vozila veći i što je učestalost poruka veća, to se točnije može odrediti stanje prometa.

Korištenjem FCD podataka moguće je estimirati vrijeme putovanja i brzine između dvije točke na mreži, vrijeme putovanja i brzinu vozila na linkovima, tj. segmentu prometnice te stanje prometne mreže, odnosno stupanj zagušenja. Ako je učestalost poruka i udio vozila dovoljno velika, moguće je detektirati zagušenja i incidentne situacije u stvarnom vremenu, estimirati duljine repova čekanja i kašnjenja na raskrižjima te doprinijeti određivanju P-O matrica.

Prednosti korištenja FCD-a su u mogućnosti pokrivanja velikog prostora i određivanja stanja čitave prometne mreže, niski troškovi, kvalitetni podaci ukoliko je dovoljan udio FCD vozila, pogodni su za prikupljanje podataka u urbanim područjima, nema utjecaja vremenskih prilika i redundancija što znači da ispadanje jednog pokretnog osjetila ne utječe bitno na kvalitetu rezultata. Nedostatak je zahtjevnost obrade podataka, još je u fazi istraživanja i razvoja, puno

je pitanja vezano za zaštitu privatnosti, troškovi prijenosa poruka mogu biti veliki te zahtjeva usklađivanje raznih interesnih skupina.[2]

3.2.2 Lociranje resursima pokretnih ćelijskih mreža

Za prikupljanje podataka koje uključuje lociranje vozila na cestovnoj mreži uz pomoć lociranja resursima pokretnih ćelijskih mreža koriste se i engleski nazivi *Floating Cellular Data* i *Cellular Floating Car Data* ili skraćeno CFCD. Kratica FPD se može odnositi na ovakav način prikupljanja podataka, iako se pod FPD-om češće smatra „pametni" telefon s GNSS modulom koji šalje poruke o poziciji. Lociranje mobilnih stanica, odnosno praćenje mobilnih stanica u ćelijskoj mreži je sastavni i nužni dio usluge ćelijske mreže. Da bi se omogućila mobilnost korisnika potrebno je da mobilni sustav prepoznaje o kojoj se mobilnoj stanici radi i gdje se mobilna stanica nalazi, a to znači identifikacija i lokacija. Za razliku od FCD-a, kod CFCD-a svaka mobilna stanica na mreži može sudjelovati u prikupljanju podataka. Ako se uzme u obzir udio korisnika s mobilnim telefonima, očito je da skup podataka vrlo brzo može postati golem, posebice u urbanim područjima. Kao i kod FCD-a, kod CFCD-a temeljna informacija upotrebljiva za određivanje stanja prometa je vrijeme putovanje između pozicija na kojima je locirana mobilna stanica.[2]

Lociranje vozila, tj. mobilnih stanica, u ćelijskim mrežama ostvaruje se uporabom postojećih resursa ili njihovom hardverskom i softverskom nadogradnjom. Prednost je što tada nije potreban sustav za lociranje vozila. Također, lociranje u celularnim mrežama može se izvesti tako da sva potrebna mjerenja obavlja mreža (engl. *Network-based*), bez ikakvog posebnog sudjelovanja ili nadogradnje samih mobilnih stanica.

Lociranje može biti zasnovano na identifikaciji ćelije (engl. *Cell-IDentification*), na određivanju kuta dolaska signala (engl. *Angle of Arrival - AoA*) ili na mjerenju vremena razlike dolaska signala (engl. *Time Difference of Arrival – TDOA*).

3.2.3 Automatska identifikacija

Automatska identifikacija vozila ili AVI uključuje tehnologije kojima se vozilo može identificirati ili prepoznati na nekoj kontrolnoj točci mreže te se može utvrditi „privremeni“ ili „stalni“ identitet. Pri tome se identifikacija može temeljiti na detekciji dodijeljenog identifikatora, prepoznavanju značajki ili uspostavljenoj komunikaciji između opreme vozila i opreme fiksne infrastrukture.[2]

Kod prikupljanja podataka, nije bitna identifikacija vozila u smislu otkrivanja „pravog“ identiteta vozila, već je bitna ustanoviti da se određeno vozilo pojavilo na različitim kontrolnim točkama u mreži. Cilj je identificirati vozilo u jednoj kontrolnoj točci te potom ponovno identificirati isto vozilo na nekoj drugoj kontrolnoj točci. Pod automatsku identifikaciju spadaju: bluetooth, radio-frekvencijska identifikacija i automatsko prepoznavanje registarskih tablica. Budući da je korištenje bluetooth detektora i bluetooth tehnologija glavni fokus rada, on će biti pobliže opisan u kasnijem dijelu diplomskog rada.

Radio-frekvencijska identifikacija ili RFID (engl. *Radio Frequency Identification*) odnosi se na tehnologiju koja u procesu automatske identifikacije koristi radiovalove za prijenos informacije. Pri tome, fizičkom objektu koji je predmet automatske identifikacije dodijeljen je identifikator prema nekom standardu. Takva tehnologija omogućava prikupljanje podataka s velikog broja pokretnih objekata u cilju praćenja, brojanja i sortiranja objekata prema potrebama određene aplikacije. Primjena RFID tehnologije je danas vrlo raširena te se ona koristi u raznim područjima: logistika, sigurnosne potrebe, kontrole pristupa, u prometu za naplatu cestarine, praćenje životinja i dr.[2]

Automatsko prepoznavanje registarskih tablica ili ANPR (engl. *Automatic Number Plate Recognition System*) tehnološki gledano uključuje tri bitna dijela: tehnologiju za dobivanje kvalitetne slike, obradu slike odnosno pripadnu programsku podršku i manipulaciju podacima kako bi se omogućila uporaba informacija za razne aplikacije. Programska podrška za obradu slike „pametni“ je dio sustava i počiva na sofisticiranim algoritmima. Načelno se proces ekstrakcije informacije o registarskoj tablici može rastaviti na niz slijednih postupaka od prvog koraka hvatanja slike, do obrade, izdvajanja registarske tablice, segmentacije znakova, prepoznavanja znakova do krajnjeg izlaznog niza znakova. Komercijalni ANPR sustavi koriste se već desetke godina i to u nizu aplikacija: rukovođenje parkirališta, sankcioniranje prometnih prekršaja, otkrivanje ukradenih vozila, naplata cestarine, kontrola pristupa i prolaza i dr.[2]

4. Bluetooth tehnologija

4.1 Bluetooth standard i klase uređaja

Bluetooth je telekomunikacijski standard koji se koristi za razmjenu podataka između elektroničkih uređaja radiokomunikacijom kratkog dometa. Veza preko Bluetooth-a podrazumijeva da povezani uređaji posjeduju primo-predajnike. Bluetooth bežična tehnologija danas se nalazi u gotovo svim pametnim telefonima, računalima, tabletima, pomoćnom hardveru koji ide uz takve uređaje poput miševa, slušalica, zvučnika, a sve češće i u vozilima u obliku radiouređaja, navigacijskih uređaja, itd.[2]

Bluetooth tehnologija koristi ISM (engl. *Industrial, Scientific and Medical*) nelicenciranih pojaseva radio spektra. ISM pojasevi su slobodni pojasevi radijskih frekvencija za industrijsku, znanstvenu i medicinsku uporabu. Bluetooth tehnologija u ISM pojasu radi u frekvencijskom rasponu od 2.402 do 2,483 GHz. To područje je podijeljeno na 79 kanala s razmakom od 1 MHz. Bluetooth uređaji koriste tehniku zvanu skokovita promjena frekvencije (engl. *adaptive frequency hopping* - AFH) gdje predajnik i prijemni razmjenjuju paket podataka na jednoj frekvenciji, a zatim se skokovito prelazi na drugu frekvenciju kako bi se razmijenio sljedeći paket podataka. Taj proces se ponavlja dok se ne pošalju svi podaci. Slučajno skokovita frekvencija u Bluetoothu se mijenja i do 1600 puta u sekundi. Ova tehnika pruža visoku otpornost na moguće smetnje zbog prisustva drugih uređaja koji rade u ISM pojasu.[8]

Postoje tri osnovne klase Bluetooth uređaja s obzirom na definiranu maksimalnu izlaznu snagu, a time i domet.

	Maksimalna izlazna snaga (dBm)	**Maksimalna izlazna snaga (W)**	**Približni maksimalni domet**
Klasa 1	20 dBm	100 mW	100 m
Klasa 2	4 dBm	2.5 mW	20 m
Klasa 3	0 dBm	1 mW	10 m
BLE	10 dBm	10 mW	50-100 m

Slika 9 Približni dometi Bluetooth uređaja

Izvor: [2]

Na slici 9. su prikazane 3 osnovne klase Bluetooth uređaja uz dodatak četvrte klase Bluetooth Low Energy (BLE) koja ima vrlo nisku potrošnju energije. Iskazane su maksimalne snage u dBm i W te približni maksimalni dometi.

Bluetooth uređaji stvaraju komunikacijske mreže poznate kao pikomreže (engl. *piconet*) koje su bežične veze kratkog dometa. Takve mreže na zahtijevaju nikakvu formalnu infrastrukturu da bi se uspostavila veza. Do 8 Bluetooth uređaja se može spojiti na bilo koju pikomrežu te se jedan uređaj istovremeno može spojiti na sedam drugih Bluetooth uređaja unutar pikomreže. Uređaj koji je prvi pokrenuo mrežu je tzv. *master* uređaj, dok su preostali uređaji koji se spoje na njega tzv. *slave* uređaji. Svaki od uređaja ima svoju vlastitu MAC (engl. *media access control*) adresu, koja je 48-bitna adresa fizičkog sloja, a sastoji se od 12 heksadecimalnih znakova u šest okteta. MAC adrese postavljaju se od strane Instituta inženjera elektrotehnike i elektronike (engl. *Institute of Electrical and Electronics Engineers – IEEE*) i sastoje se od dva dijela. Prvi dio je unikatni organizacijski identifikator (engl. *Organizationally Unique Identifier – OUI*) koji se sastoji od prva tri okteta (24 bita) i ekvivalent je unikatnom globalnom identifikatoru koji se može otkupiti od IEEE. Preostalih šest heksadecimalnih znakova dodjeljuje proizvođač Bluetooth uređaja.[8]

Da bi se smanjile smetnje od drugih bežičnih i mikrovalnih uređaja, Bluetooth uređaji prenose poruke na pseudo nasumičnom nizu raznih frekvencija i pri tome otkriva zauzete frekvencije koje koriste drugi uređaji i izbjegavaju ih u budućim prijenosima i, kao što je već spomenuto ranije, ovaj proces se zove skokovita promjena frekvencije. Unutar pikomreže, *master* i *slave* uređaji sinkroniziraju niz frekvencija koje razmjenjuju tako da mogu jednostavno održavati međusobnu vezu. To se odvija koristeći sinkronizaciju skokovite frekvencije (engl. *Frequency Hopping Synchronization – FHS*). Sinkronizacija se temelji na tome da *slave* uređaj bazira svoj skokoviti niz na MAC adresi i vremenu *master* uređaja po uspostavi veze.[8]

4.2 Bluetooth protokoli i otkrivanje uređaja

Bluetooth uređaji automatski detektiraju druge Bluetooth uređaje u blizini i povezuju se s njima. Postoji više načina povezivanja Bluetooth uređaja. Povezivanje samo dva Bluetooth uređaja se zove *point-to-point*, gdje je jedan uređaj nadređeni (engl. *master*), a drugi podređeni (engl. *slave*). U daljnjoj literaturi će se koristit engleski nazivi. Više Bluetooth uređaja mogu formirati minijaturnu računalnu mrežu kojoj se mogu pridruživati drugi uređaji ili isto tako uređaji mogu napuštati tu mrežu.[2]

Da bi se omogućila uspostava veze između Bluetooth uređaja postoje brojni protokoli. Protokol predstavlja dogovor između dvije jedinice o načinu međusobne komunikacije, odnosno određeni skup pravila o formatu i značenju paketa ili poruka koje se razmjenjuju između procesa istog sloja.

Da bi se bilo koji uređaj mogao kvalificirati kao Bluetooth uređaj, mora koristiti 7 osnovnih protokola[9]:

1. Radio protokol
2. Protokol osnovnog pojasa
3. Link Management Protocol (LMP)
4. Host Controller Interface (HCI)
5. Logical Link Control and Adaptation Layer Protocol (L2CAP)
6. Radio Frequency Communication Protocol (RFCOMM)
7. Service Discovery Protocol (SDP)

Gore navedeni protokoli imaju različite uloge poput slanja i primanja podataka, kontrole ispravljanja grešaka, kontrole paketa, kontrole linkova, podešavanja veza, provjere autentičnosti i komunikacije između protokola više i niže razine, itd. U sklopu ovog diplomskog rada, najbitniji protokol je posljednji, SDP protokol. Njime se omogućava otkrivanje i uspostavu veze između 2 ili više Bluetooth uređaja. [9]

Postoje 3 osnovna Bluetooth stanja, a njihovi nazivi na engleskom jeziku su: *standby, connection* i *park*. Postoji još 7 osnovnih Bluetooth podstanja u koje spadaju: *page, page scan, inquiry, inquiry scan, master response, slave response* i *inquiry response*. S obzirom da se engleski nazivi učestalo koriste u stručnoj literaturi, tako će se i u daljnjem tekstu ovog rada koristiti engleski nazivi. Podstanja *page, page scan, master response, slave response* se koriste

u procesu povezivanja s drugim Bluetooth uređajima, dok se podstanja *inquiry, inquiry scan* i *inquiry response* koriste u procesu otkrivanja uređaja i ne zahtijevaju povezivanje uređaja.[8]

Da bi se identificirala MAC adresa i vrijeme drugog Bluetooth uređaja, *master* uređaj mora biti u podstanju *inquiry* dok, a potencijalni *slave* uređaj mora biti u podstanju *inquiry scan*. Od 79 kanala koji se koriste, u 32 kanala, koji su takozvani *wake-up* kanali, *master* uređaj kontinuirano odašilje *inquiry* pakete koji sadrže *inquiry* pristupni kod (engl. *Inquiry Access Code - IAC*). Pristupni kod može biti opći (*GIAC – General Inquiry Access Code*) gdje se traži bilo kakav Bluetooth uređaj, neovisno o klasi. Može biti i namjenski pristupni kod (*DIAC – Dedicated Inquiry Access Code*) gdje se traži specifična vrsta Bluetooth uređaja. Prilikom podstanja *Inquiry scan,* potencijalni slave uređaj traži da li se emitira IAC od potencijalnog *master* uređaja. Trajanje jednog *Inquiry scan* podstanja iznosi približno 2.56 sekundi ili manje. Stoga, svakih 2.56 sekundi ili manje, slave uređaj će provoditi *Inquiry scan* podstanje, dok *master* uređaj konstantno u *inquiry* podstanju, osim ako već procesira vezu s drugim *slave* uređajem.

Prije uspostave veze u pikomreži, *master* i potencijalni *slave* uređaji nisu sinkronizirani te *master* uređaj ne zna kada i u kojem wake-up kanalu će se potencijalni *slave* uređaj nalaziti. Iz tog razloga, *master* uređaj mora emitirati isti *inquiry* paket preko različitih kanala dok iščekuje odgovor potencijalnog *slave* uređaja. Frekvencija *master* uređaja u skokovitom nizu se određuju po satu *master*-a i mijenja se svakih 1.28 sekundi. Niz u skokovitoj frekvenciji se dijeli na dva niza, odnosno u stručnoj literaturi se koristi naziv *train* te će se u daljnjem tekstu koristiti taj pojam. Dva *train*-a pokrivaju svaki po 16 od ukupno 32 *wake-up* kanala. Jedan *train* frekvencija može pokriti 16 kanala, a jedan termin (engl. *time slot*) je jednak 1/1600 sekundi. Stoga, vrijeme potrebno da se ispuni jedan *train* je 10 milisekunda, s maksimalnim brojem skokova u frekvenciji od 3200 skokova po sekundi (skok/s) tijekom podstanja *inquiry*. *Master* uređaj svaki *train* ponavlja barem 256 puta tijekom podstanja *inquiry*. Također, svaki *train* će odraditi dvije iteracije kroz svojih 16 kanala. Ukupno vrijeme trajanje podstanja *inquiry* može iznositi do 10.24 sekunde, ovisno o tome kada će *slave* uređaj primiti paket *master* uređaja kojim se uređaji međusobno otkrivaju.

Kada potencijalni *slave* uređaj primi *inquiry* paket, *slave* uređaj će napustiti podstanje *inquiry scan* i ući u podstanje *inquiry response*. *Slave* uređaj privremeno ulazi u stanje *standby* prije nego pošalje FHS paket natrag *master* uređaju. Nakon primanja *inquiry* paketa, *slave* uređaj

mora privremeno pauzirati sa skeniranjem i u trajanju između 0 i 639.375 milisekundi. Razlog pauze je sprječavanje sudara paketa kod višestrukih uređaja koji mogu primiti *inquiry* paket u isto vrijeme. Nakon izlaska iz stanja standby i povratka u inquiry response podstanje, slave uređaj vraća FHS paket master uređaju te pomiče fazu sata za 1.

Master uređaj ne potvrđuje primanje FHS paketa, ali *slave* uređaj će i dalje nastaviti izmjenjivati podstanja *inquiry scan* i *inquiry response* sve dok god *slave* uređaji budu primali pakete od *master* uređaja u podstanju *inquiry*.

Kada se dva uređaja međusobno otkriju, moguće je formirati vezu za komunikaciju i prijenos podataka između uređaja. Da bi se veza formirala, master i *slave* uređaj moraju proći kroz *page* proces. Budući da za diplomski rad veza između uređaja nije potrebna već je samo potrebno otkriti uređaj, u daljnjem radu se neće spominjati podstanje *page*.[8]

4.3 Bluetooth detektori

Osnovni sustav za prikupljanje podataka pomoću Bluetooth tehnologije sastoji se od Bluetooth detektora, host računala za prihvat i obradu podataka i komunikacije. Bluetooth detektor se postavlja na stupove pokraj prometnice, detektira Bluetooth uređaje koji prolaze, sprema podatke i šalje ih dalje. Bluetooth detektor sadržava sljedeće funkcijske dijelove[2]:

- Bluetooth primopredajnik koji šalje informacije prema Bluetooth uređajima i prima informacije od njih
- Antenu koja može takve izvedbe da se povećanju detekcijske sposobnosti i domet detekcije, ili da se zona pokrivanja Bluetooth detektora ograniči na manje područje od interesa
- Računalo koje procesira informacije, gdje primjerice mogu biti uključeni postupci čišćenja dupliciranih podataka ili procedure za povećanje zaštite privatnosti
- Izvor napajanja ili priključak za napajanje
- Kućište i opremu za montažu

Bluetooth detektori stalno skeniraju okolni prostor u potrazi za aktivnim Bluetooth uređajima. Svaki Bluetooth uređaj (koji se nalazi u pripremnom stanju za odgovor) odgovorit će na upit

detektora s jedinstvenom MAC adresom i sinkronizacijskom informacijom. Ako se Bluetooth uređaj putem MAC adrese identificira na dvije kontrolne točke gdje se nalaze Bluetooth detektori, uz poznatu udaljenost između kontrolnih točki i vremenske oznake može se pretpostaviti vrijeme putovanja i brzina.

Osim MAC adrese i vremenske oznake u zapisu Bluetooth detektora nalazi se i naziv Bluetooth uređaja, tip uređaja (engl. *Class of Device - CoD*), zabilježena razina snage koja se izražava indikatorom RSSI (engl. *Received Signal Strength Indicator*). CoD podaci sadrže informaciju o kakvom uređaju se radi (pametni telefon, slušalica, računalo, LAN), što donekle može pomoći u određivanju o da li se radi o vozilima ili pješacima. Vrijednost indikatora RSSI u dBm izmjerena Bluetooth detektorom (apsolutna razina snage primljenog signala u odnosu na referentnu vrijednost od 1mW) u relaciji je s udaljenosti Bluetooth uređaja od Bluetooth detektora. Što je udaljenost veća, signal je slabiji i vrijednost RSSI pada. Izračun udaljenosti između detektora i uređaja koji se detektira na osnovi RSSI vrijednosti ovisi o više faktora: klasi uređaja, gdje se uređaj nalazi, utjecaju okoline. U zapisu se može nalaziti i oznaka proizvođača uređaja.

Podaci s Bluetooth detektora dostavljaju se putem komunikacijske mreže na host računalo. Sama komunikacija i povezanost Bluetooth detektora može biti izvedena na više načina. Svaki Bluetooth detektor samostalno šalje podatke na host računalo ili, primjerice, samo je jedan Bluetooth detektor u grupi detektora povezan na TK mrežu i prosljeđuje podatke od drugih s kojima je povezan nekom bežičnom tehnologijom kraćeg dometa (npr. ZigBee). Na host računalu spremaju se i obrađuju MAC adrese i vremenske pozicije od svih Bluetooth detektora.

Kod Bluetooth detektora postoji moguća pogreška određivanja pozicije vozila koja je ovisna o zoni pokrivanja Bluetooth detektora. Što je zona pokrivanja veća, veća je i pogreška. Nakon obrade podatka za određenu rutu (ili linkove) mogu se odrediti prosječna vremena putovanja u ovisnosti o dobu dana. Uz poznate povijesne podatke usporedbom trenutačnog vremena putovanja može se zaključivati kakvo je trenutačno stanje prometnog toka.

Korištenjem Bluetooth tehnologije mogu se dobiti prilično točni podaci o vremenu putovanja i srednja brzina na segmentima prometnice. Isto tako se mogu dobiti P-O podaci. Najveća prednost korištenja Bluetooth detektora je u vidu velike rasprostranjenosti (udjela) Bluetooth

uređaja, velikoj vjerojatnosti detekcije Bluetooth uređaja od strane Bluetooth detektora te relativno niske cijene potrebnog hardware-a.

Nedostatak Bluetootha su problemi s čišćenjem podataka zbog višestruke detekcije. Također, Bluetooth detektor ima područje pokrivanja reda veličine od nekoliko desetaka metara pa do 100 metara (pod uvjetom da antene nisu ciljano usmjerene na manje područje) i stoga će se dešavati detekcije svih uređaja u tom području. Problem je što se ne može razlikovati gdje se uređaj nalazi, odnosno da li pripada pješaku, biciklistu ili je u vozilu. Ovisno i o veličini zone pokrivanja detektora, lociranje ima relativno veliku pogrešku.[2]

4.4 Istraživanja sa primjenom Bluetooth tehnologije u prometu

Bluetooth tehnologija postala je jedna od korištenijih metoda za prikupljanje prometnih podataka za razne primjene u prometu. Većina prijašnjih istraživanja se fokusirala na primjenu Bluetooth tehnologije za prikupljanje podataka i analizu vremena putovanja na autocestama[10, 11, 12, 13] i na arterijskim cestama [14, 15, 16].

Prema Youngu [10], praćenje prometa primjenom Bluetooth tehnologije omogućava anonimno prikupljanje podataka visoke kvalitete o vremenu putovanja. Prikupljanjem MAC adresa na dvije različite lokacije omogućava prikupljanje točnih podataka o vremenu putovanja, bez uobičajenih problema povezanih za privatnost u takvim sustavima prikupljanje podataka. Procjenjuje se da je 500 do 2500 puta ekonomičnije prikupljati podatke na ovaj način nego što bi bilo primjenom testnih vozila.

KMJ Consulting [11] su proveli istraživanje o procjeni mogućnosti korištenja Bluetooth tehnologije za prikupljanje podataka o vremenu putovanja. Korištena Bluetooth tehnologija je BlueTOAD, dok su se za usporedbu korisnosti Bluetooth tehnologije koristila E-ZPass čitaći oznaka koji predstavljaju ekvivalent Elektroničke naplate cestarine (ENC) u Hrvatskoj. Provedeno istraživanje je pokazalo da oko 4% vozila koristi Bluetooth tehnologiju te da su izmjerena vremena putovanja korištenjem BlueTOAD-a i E-ZPass-a približno jednaka, dok je cijena primjene BlueTOAD iznosila oko trećinu cijene korištenja E-ZPass čitaća oznaka. Isto tako, prednost je jednostavnost postavljanja i primjene BlueTOAD tehnologije.

Martchouk [12] je u svom izvještaju pisala o istraživanju vremena putovanja i analizi podataka između dva segmenta državne ceste 69 u Indianapolisu. Zaključak istraživanja je bio da se Bluetooth tehnologija može primijeniti za prikupljanje i analizu podataka o vremenu putovanja, kao i dopunjavanje podataka iz već postavljenih mikrovalnih senzora. Korištenjem 3 statistička modela, uspostavila je vezu između vremena putovanja i poznatih prometnih parametara, kao i mogućnost predviđanja prosječnog vremena putovanja i varijabilnosti vremena putovanja s umjerenom točnosti.

U svom članku [13], Kim je usporedio različite tehnologije za prikupljanje podataka o vremenu putovanja. Prikupljeni su podaci pomoću TRANSMIT čitača, Bluetooth detektora i INRIX sustava dok je tehnologija s kojom su se uspoređivali dobiveni podaci GPS navigacija ugrađena u vozila i CO-Pilot sustav. Zaključak istraživanja je da su u usporedbi drugim tehnologijama, Bluetooth podaci najbliži GPS podacima, ali isto tako da je ubuduće potrebno analizirati Bluetooth podatke i detekcije pod različitim uvjetima u prometu, vremenskim promjenama, geometriji i udaljenosti između detektora.

Malinovskiy je u svom radu [14] pisao o Bluetooth baziranom sustavu MACAD (*Media Access Control Address Detection*) koji je korišten za očitavanje MAC adresa i uparivanje da bi se dobili podaci o vremenu putovanja. Uspoređivao je MACAD sa ALPR (*Automatic License Plate Recognition*) sustavom te došao do zaključka da su približno jednaki podaci dobiveni u oba sustava. MACAD sustav je imao znatno manje očitanja (4-10 %)nego što je moguće dobiti sa ALPR sustavnom, ali su podaci i dalje bili u dovoljnoj količini da bi bili u mogućnosti prikazati stanje u prometu. MACAD sustav se može koristiti za mjerenje vremena putovanja kao alternativa ALPR sustavu, uz znatno manje troškove i jednostavnije postavljanje opreme. Također, Malinovskiy je zaključio da je MACAD sustav korisniji za kraće dionice, zbog porasta broja grešaka u većim detekcijskim zonama, te preporučio da se smanje detekcijske zone.

Brennan [15] je istraživao rješavanje problema kod prikupljanja Bluetooth podataka na duže vremenske periode te uparivanje MAC adresa da bi se moglo izmjeriti vrijeme putovanja vozila. Jedan od problema s kojim se morao nositi su višestruka očitanja MAC adresa istog vozila unutar iste detekcijske zone. Osim toga, istraživao je utjecaj postavljanja detektora, odnosno antene detektora na različite visine.

Vo je u svom radu [16] istraživao mogućnost mjerenja vremena putovanja na arterijskim cestama primjenom Bluetooth detektora, kao i procjenu točnosti dobivenih podataka. Za provjeru točnosti podataka, rezultati mjerenja su uspoređeni s podacima dobivenim od GPS uređaja unutar vozila. Isto tako uspoređivao se stupanj detekcije u bližoj i daljoj traci prometnice.

Bluetooth tehnologija je također predložena da se koristi za predviđanje vremena putovanja za primjenu u naprednim sustavima informiranja putnika (engl. *Advanced Traveller Information System – ATIS*)[17] i naprednim sustavima upravljanja prometom (engl. *Advanced Traffic Management Systems - ATMS*)[18].

Staszcuk i McGowen su u svom izvješću [17] pisali o naprednim sustavima informiranja putnika te prikupljanju podataka za takve sustave. Jedna od metoda prikupljanja podataka je primjenom Blufax jedinice koja koristi Bluetooth tehnologiju za detekciju MAC adresa Bluetooth uređaja unutar vozila u prometu. Takav sustav je bilježio veliku točnost u mjerenju vremena putovanja vozila, a kao problem za dugoročna mjerenja se pokazalo napajanje koje je trebalo mijenjati svakih nekoliko dana. Zaključeno je da se ovakvi sustavi mogu koristiti za prikupljanje podataka o prometu te primjenu u ATIS-u.

Barcelo [18] je istraživao mogućnost prikupljanja podataka korištenjem Bluetooth tehnologije za primjenu u naprednim sustavima upravljanja prometom. Zaključio je da je Bluetooth tehnologija dovoljno napredovala da bi mogla izmjeriti kvalitetne podatke o prosječnoj brzini i vremenu putovanja između više detektora. Takvi detektori se već koriste u na autocesti AP-7 u Španjolskoj, između Barcelone i granice s Francuskom. Također, primjenom Kalmanovog filtera, moguće je predvidjeti vremena putovanja vozila.

Osim za vrijeme putovanja, Bluetooth se također koristio za prikupljanje podataka za polazišno-odredišne matrice[19, 20], uključujući procjenu izbora rute vozača s obzirom na zatvorene ceste i službene i neslužbene obilaznice[21].

U [19], Quayle i Koonce su usporedili Bluetooth tehnologiju s GPS podacima da ustanove točnost Bluetooth podataka. Proveli su istraživanje na signaliziranoj cesti u predgrađu u periodu od 27 dana. Zaključili su da primjena Bluetooth tehnologije donosi velike mogućnosti u inteligentnim transportnim sustavima poput uvođenja *ramp meteringa*, davanja prioriteta određenim modovima transporta, adaptivne kontrole signalnih planova, kao i mogućnost

izrade polazišno-odredišnih matrica i prikupljanja podataka o brzini vozila i vremenu putovanja.

Thouglava, Antonovs, Bingham i Hill su u svom radu [20] istražili mogućnost izrade polazišno-odredišnih matrica primjenom Bluetooth tehnologije. Osnovna ideja je da dok se induktivne petlje i video detektori mogu koristiti za mjerenje protoka, pomoću Bluetooth tehnologije bi ustanovili kretanje stanovnika, kao i vremena putovanja unutar grada Worcester.

Hainen [21] je istraživao mogućnost primjene podataka prikupljenih korištenjem Bluetooth tehnologije da bi ustanovile promjene u prometu prilikom neočekivanog zatvaranja mosta. Bluetooth tehnologija je uspješno korištena da bi se procijenila vremena putovanja na četiri alternativne rute. Također, osnovnom analizom podataka kada su se pojavljivali povremeni zastoji došlo se do zaključka da su zastoji zbog lokalnog prometa, a ne zbog zatvaranja mosta. Također, primjenom Bluetooth tehnologije ustanovljeno je da je samo 9% vozača putovalo službenom obilaznicom, 20% hibridnom rutom službene i neslužbene rute, 57% vozača je koristilo lokalnu rutu, dok je 14% vozača je koristilo neslužbenu rutu. Time se zaključilo da je moguće otkriti odabir rute vozača za obilazak.

5. Mjerenje udjela vozila koja se mogu detektirati bluetooth detektorom

5.1 Mjerene veličine

Glavni zadatak ovog diplomskog rada je ispitati mogućnost korištenja Bluetooth detektora u Zagrebu, odnosno izmjeriti udio vozila koje sadrže Bluetooth uređaje, u odnosu na ukupni broj vozila u prometu.

Detektor konstantno skenira svoje okruženje u potrazi za aktivnim Bluetooth uređajima. Uspješna detekcija podrazumijeva identificiranje uređaja pomoću jedinstvene MAC adrese. Osim MAC adrese, detektori mogu primaju i dodatne informacije poput vremena očitanja, naziva uređaja, tipa uređaja te snage primljenog signala. Na slici 10 su prikazani neki od zapisa dobivenih korištenjem Bluetooth detektora.

Vremenska oznaka	**Prvi dio MAC adrese**	**MAC adresa**	**Tip uređaja**	**RSSI [dBm]**
1549358265	a8:7d:12	a8:7d:12:c8:a8:94	5a020c	-60
1549358266	7e:3c:46	7e:3c:46:05:51:40	5a020c	-68
1549358275	f8:95:ea	f8:95:ea:12:29:ad	7a020c	-53
1549358276	48:5a:b6	48:5a:b6:f0:a5:d8	3e010c	-66

Slika 10 Primjer dobivenih podataka sa Bluetooth detektora

Korištenjem Bluetooth detektora mogu se dobiti podaci poput vremena putovanja, P-O matrica i brzine. Da bi se dobili navedeni podaci, potrebno je koristiti dva ili više Bluetooth detektora, ali postoje i drugi podaci koji se mogu dobiti korištenjem jednog Bluetooth detektora.

Broj detekcija ($N_{detekcije}$) predstavlja koliko puta (k) je uređaj ili vozilo identificirano putem svog jedinstvenog identifikator, odnosno MAC adrese unutar jedne detekcijske zone, a dobiva se korištenjem formule (1). Uobičajeni naziv na engleskom je *Number of Hits*, ali tu je upotrijebljen navedeni prijevod. Ako uređaji ili vozila provedu više vremena unutar detekcijske zone, pojavit će se višestruka očitanja iste MAC adrese.[22]

$$N_{detekcije} = \sum_{i=1}^{k} MAC\ adresa_i\ [detekcije] \quad (1)$$

Bluetooth vrijeme zadržavanja (dwT) računa se pomoću formule (2) te predstavlja vrijeme potrebno da Bluetooth uređaj prođe kroz detekcijsku zonu Bluetooth detektora. Definira se kao vrijeme između prvog i posljednje detekcije praćenog uređaja (N) u definiranom intervalu T.[22]

$$dwT = \sum_{i=1}^{N} (T_{posljednja\ detekcija} - T_{prva\ detekcija})\ [s] \quad (2)$$

Prosječno vrijeme putovanja (TT_{BT}) između točaka A i B tijekom vremenskog perioda P, gdje n predstavlja broj opažanja tijekom perioda P. U dolje navedenoj formuli (3) je prikazano kako se može izračunati prosječno vrijeme putovanja. [22]

$$TT_{BT}(P) = \frac{\sum_{i}^{nP} (t_{i,B} - t_{i,A})}{n_P}\ [s] \quad (3)$$

5.2 Oprema za mjerenje

Doppler radar detektor s kontinuiranim odašiljačkim signalom (engl. Frequency Modulated Continuous Wave Radar) je korišten za brojanje ukupnog prometa na dionici te im i mogućnost mjerenja brzine vozila. Proizvođač je Houston Radar, a model Houston Radar

SpeedLane Pro. On radi na frekvenciji od 24 GHz u k-spektru. Ovaj radar je posebno izrađen da bi bio prenosiv za stalno prikupljanje prometnih podataka. Na niže postavljenoj slici 11 prikazan je radar koji se koristio u istraživanju.[23]

Slika 11 Radar korišten prilikom istraživanja

Izvor: [23]

Kao Bluetooth detektor se koristio DeepBlue Sensor v2t R-Model od tvrtke trafficnow® prikazan na slici 12. DeepBlue Sensor otkriva sve vrste Bluetooth uređaja u dometu od 500 metara sa -104 dB osjetljivosti prijamnika te radi u širini frekvencijskog područja k od 24 GHz. Detektor je pogodan za korištenje u većim urbanim sredinama s gustom naseljenosti ili na raskrižjima.

Slika 12 Bluetooth detektor korišten u istraživanju

Izvor: [24]

Također, u istraživanju je korištena *flat patch* antena proizvođača L-com, modela RE09P za povećavanje dometa s povećanjem od 8 dBi. Antena se može koristiti u zatvorenom, kao i na otvorenom u ISM širini frekvencijskog područja od 2.4 GHz, uključujući IEEE 802.11b i 802.11g, Bluetooth i za javnu bežičnu mrežu. Na slici 13 prikazan je primjerak antene korištene u istraživanju.

Slika 13 Antena korištena u istraživanju

Izvor: [25]

Osim gore navedene opreme, u istraživanju je za napajanje korištena baterija sa solarnim napajanjem bez eksternog izvora energije. Fotonaponski sustav sadrži solarni panel, bateriju, odnosno jedinicu za napajanje te kontroler napajanja.

Slika 14 Oprema za mjerenje postavljena na rasvjetnom stupu u Miramarskoj ulici

Na slici 14 prikazana je jedna od lokacija na kojoj je postavljena oprema. Na slici je kućište unutar kojeg se nalazi napajanje, kontroler napajanja kao i Bluetooth detektor. Iznad kućišta je solarni panel kojemu je cilj osigurati stalnu opskrbu energijom koja je potrebna za funkcioniranje opreme. Samo kućište za cilj ima zaštiti opremu od mogućih padalina i drugih vremenskih uvjeta koji bi mogli oštetiti opremu.

5.3 Lokacija mjerenja

Mjerenje se provodilo u Zagrebu sa sjeverne i južne strane nadvožnjaka u Miramarskoj ulici. Oprema je postavljenja na dva rasvjetna stupa sa svake strane nadvožnjaka. Na južnoj strani postavljeni su radar detektor prometnog toka i Bluetooth detektor dok je sa sjeverne strane postavljen samo Bluetooth detektor.

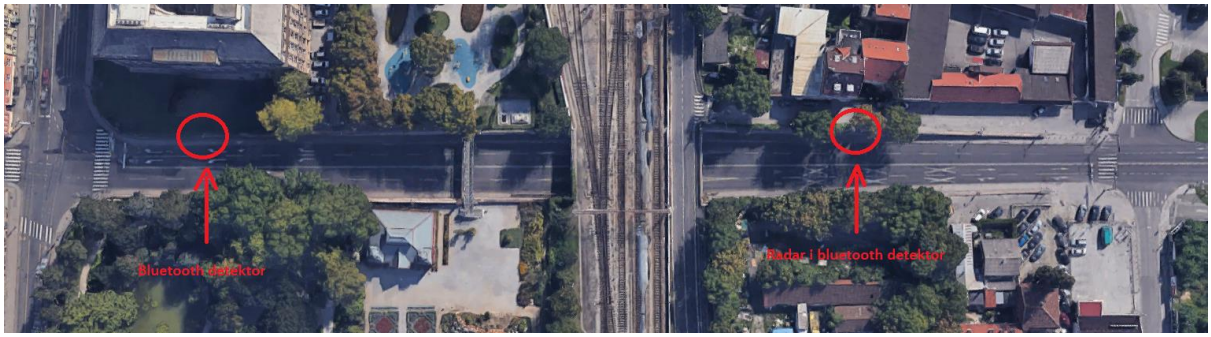

Slika 15 Dionica Miramarske ulice na kojoj je provedeno istraživanje

Izvor slike: [26]

Na gore prikazanoj slici 15 se nalazi dionica na kojoj je provedeno istraživanje. Označene su i lokacije mjerenja gdje je s lijeve strane slike postavljen samo Bluetooth detektor, dok su s desne strane slike postavljeni Bluetooth detektor, kao i radar pomoću kojeg se prikupljao ukupni promet na navedenoj dionici.

5.4 Rezultati mjerenja i analiza rezultata

Prilikom istraživanja prikupljeno je ukupno 84,767 očitanja pomoću Bluetooth detektora te je nakon filtriranja korišteno 5476 5-minutnih intervala, od kojih će neki biti i prikazani u daljem diplomskom radu. Istraživanje se provodilo tijekom ožujka 2019. godine. U periodu od 14. ožujka u 15:00 sati do 15. ožujka u 15:00 sati prikupljeno je 4,167 unikatnih MAC adresa. U drugom periodu mjerenja od 23. ožujka u 00:00 do 26. ožujka u 00:00 sati prikupljeno je 4,763 unikatnih MAC adresa.

Dani	**Od četvrtka do petka**	**Subota**	**Nedjelja**
Broj vozila (N)	32,379	23,874	17,207

Tablica 1 Broj vozila za radne i neradne dane

Na Tablica 1 prikazani su podaci o broju vozila za radne i neradne dane prikupljene koristeći radar. Unatoč očekivanom padu broja vozila tijekom vikenda, podaci pokazuju da su dobiveni podaci približno jednaki za radne i neradne dane. Na slikama 16, 17 i 18 prikazana je usporedba podataka između ukupnog broj vozila izmjerenog korištenjem radara i udjela vozila s Bluetooth uređajem u ukupnom prometu.

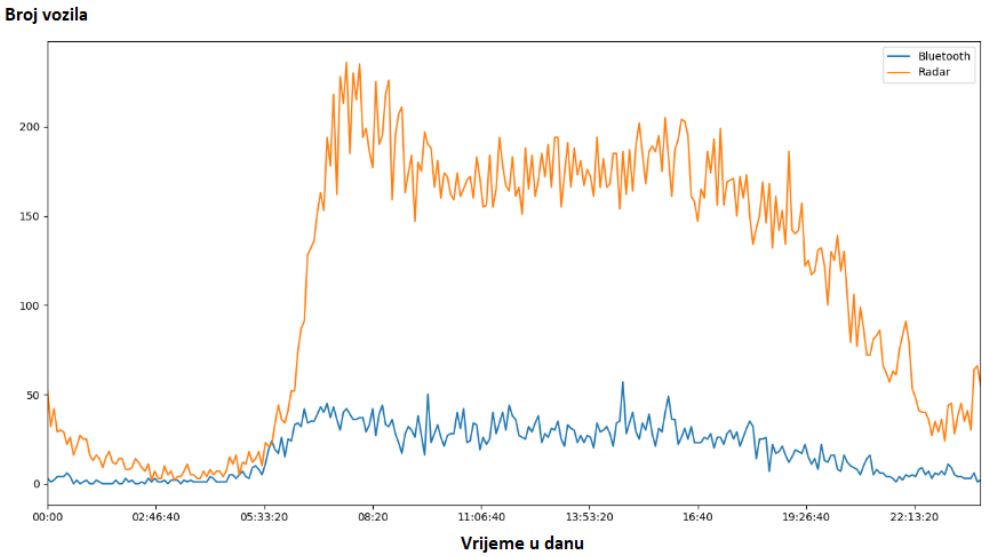

Slika 16 Broj vozila u 5-minutnim intervalima izmjeren korištenjem Bluetooth-a i radara za period od četvrtka do petka

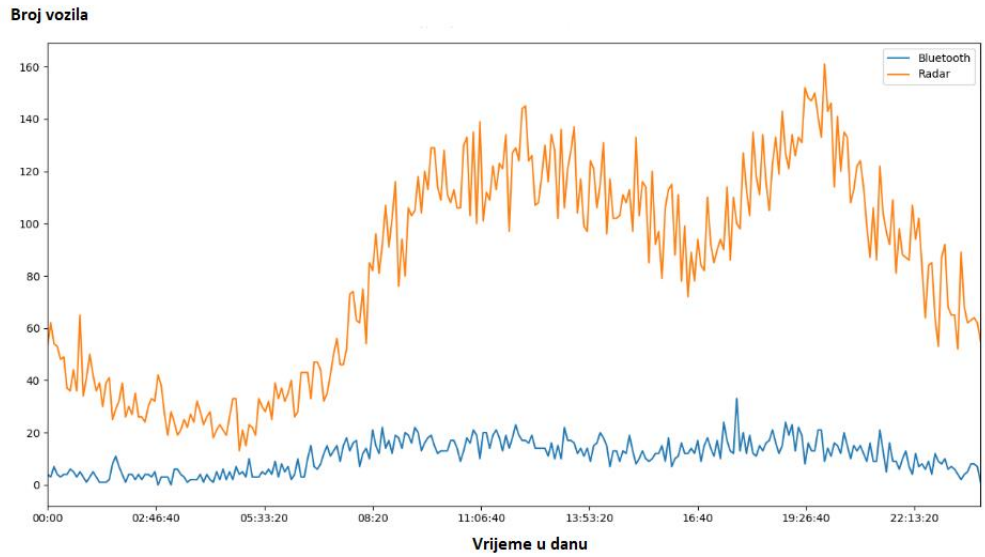

Slika 17 Broj vozila u 5-minutnim intervalima izmjeren korištenjem Bluetooth-a i radara u subotu

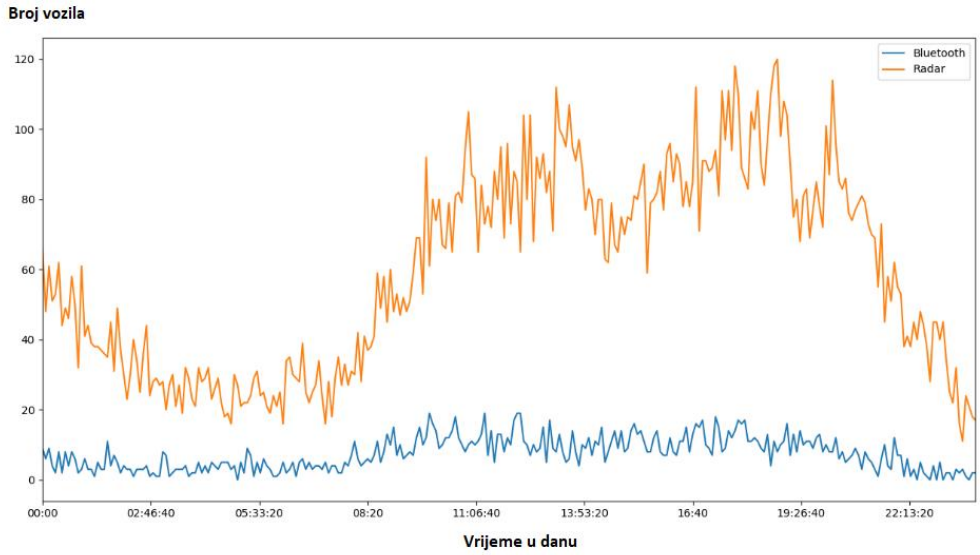

Slika 18 Broj vozila u 5-minutnim intervalima izmjeren korištenjem Bluetooth-a i radara u nedjelju

Sa slika 16, 17 i 18 vidljivo je da je velika razlika u broju očitanja između Bluetooth i radar detektora, što je i očekivano. Takvi rezultati su očekivani s obzirom na to da radar detektor ima za cilj očitati sva vozila koja prolaze kroz detekcijsku zonu, dok Bluetooth detektor samo hvata podatke od vozila koja sadrže aktivne Bluetooth uređaje.

Za filtriranje Bluetooth podataka sa slika 16, 17 i 18 korištena je Tukey-eva metoda ograda te pravilo medijana.

Tukey-eva metoda može se koristiti za eliminiranje podatka koji imaju prevelika odstupanja te se time dobivaju točniji podaci. U tukey-evoj metodi ograda, postavljaju se takozvane ograde te se svi podaci izvan postavljenih ograda eliminiraju. Prije postavljanja ograda potrebno je pronaći medijan, prvi i treći kvartil svih vrijednosti te potom izračunati interkvartilni raspon. Prvi kvartil Q1 predstavlja vrijednosti do 25% ispod vrijednosti medijana, dok treći kvartil Q3 predstavlja vrijednosti do 25% iznad vrijednosti medijana. Interkvartilni raspon IQR se računa prema formuli (4) na sljedeći način:

$$IQR = Q3 - Q1 \tag{4}$$

Tukey-eve ograde filtriraju podatke izvan raspona koji se dobije prema formuli (5):

$$[Q1 - k \times IQR,\ Q3 + k \times IQR], \tag{5}$$

za neku ne-negativnu konstantu k.

Prema Tukey-u, vrijednost k=1.5 predstavlja manje raspršenu distribuciju vrijednosti i naziva se unutarnja ograda, dok vrijednost k=3 predstavlja podatke koji su u znatnom ekstremu i zovu se vanjske ograde.

Eliminirani podaci predstavljaju ekstremne vrijednosti s prevelikim brojem očitanja te se tako uklanjaju detekcije uređaja koji se konstantno očitavaju unutar detekcijske zone Bluetooth detektora, a u to mogu spadati zaustavljeni pješaci, biciklisti, parkirana vozila s aktivnim Bluetooth uređajem, kao i aktivni Bluetooth uređaji unutar obližnjih građevina, a kojima signal ulazi u detekcijsku zonu Bluetooth detektora.[22]

Osim tukey-eve metode, korišteno je i pravilo medijana. Medijan je manje osjetljiv na veća odstupanja aritmetičke sredine te predstavlja centralnu vrijednost, odnosno sredinu distribucije. Kada se podaci poredaju po redu, medijan predstavlja vrijednost koja se nalazi točno u središtu poretka, a računa se na primjenom formule (6):

$$Q2 = \begin{cases} \left\{\frac{(n+1)}{2}\right\}, & ako\ je\ n\ neparan\ broj \\ \frac{\left[\left\{\frac{n}{2}\right\} + \left\{\frac{n}{2}+1\right\}\right]}{2}, & ako\ je\ n\ paran\ broj \end{cases} \tag{6}$$

Prema pravilu medijana, podaci se filtriraju izvan raspona koristeći formulu (7):

$$[-Q2 - 2.3 * IQR,\ Q2 + 2.3 * IQR] \tag{7}$$

Nakon što su primijenjene dvije navedene metode filtriranja, u sljedećoj tablici su prikazani dobiveni rezultati.

Metoda filtriranja	Četvrtak i petak	Subota	Nedjelja
Tukey-eva metoda k=1.5	12.19%	10.43%	10.00%
Tukey-eva metoda k=3	12.5%	11.2%	10.77%
Pravilo medijana	12.19%	10.43%	10.00%

Tablica 2 Udio Bluetooth uređaja u ukupnom prometu

Iz Tablica 2 vidljivo je da je udio vozila s aktivnim Bluetooth uređajem u ukupnom prometu između 10 i 12.5%. Razlika u udjelu Bluetooth uređaja u promatranom periodu je samo 2.5% te se može zaključiti da je udio Bluetooth uređaja konstanta te nema velikih odstupanja unutar tjedna, neovisno o tome radi li se o radnom ili neradnom danu.

Problem s Tukey-evom metodom za k=1.5 i za pravilo medijana je da uklanjaju uzastopne detekcije istog uređaja kada se uređaj očita vise od 6 puta. To znači da kada se uređaji nalaze u detekcijskoj zoni više od jedne minute, ne uzima ih se u obzir kao vozilo te ih se eliminira iz rezultata. Ukoliko bi u prometu došlo do zagušenja te bi se vozila zadržala u detekcijskoj zoni duže od minute, detektirana vozila bi ovom metodom filtriranja bila eliminirana kao ekstremna vrijednost. Također, potrebno je prepoznati uzorak biciklista i pješaka da bi se njih moglo ukloniti iz konačnih rezultata. To bi se moglo riješiti korištenjem više Bluetooth detektora, kao i metode klasteriranja da bi se mogao preciznije odrediti način putovanja unutar detekcijske zone.

6. Procjena mogućnosti primjene Bluetooth detektora za prikupljanje podataka o prometnim tokovima

Prikupljanje podataka bazirano na Bluetooth tehnologiji ima neke vrlo korisne mogućnosti poput mjerenja parametara poput vremena putovanja, srednje brzine vozila kao i za izradu P-O matrica.

Brojna istraživanja su provedena s ciljem testiranja mogućnosti Bluetooth tehnologije. Bluetooth tehnologija se najčešće koristila u svrhu prikupljanja i analize podataka o vremenu putovanja na autocestama i na arterijskim cestama. Nerijetko je uspoređivana s drugim tehnologijama poput E-ZPass, INRIX i TRANSMIT čitača te su rezultati učestalo pokazivali isplativost primjene Bluetooth-a s obzirom na to da je Bluetooth tehnologija jeftinija nego neke druge metode prikupljanja podataka, vrlo je pouzdana te jednostavna za postavljanje.

Određeni autori su predložili da se Bluetooth tehnologija primijeni u prikupljanju podatak za napredne sustave informiranja putnika kao i u naprednim sustavima upravljanja prometom. Mogućnost izrade polazišno-odredišnih matrica iz dobivenih podataka, kao i velika točnost podataka čine Bluetooth vrlo poželjnom.

Prednost Bluetooth tehnologije za prikupljanje podataka nalazi se u velikoj rasprostranjenosti, odnosno udjelu Bluetooth uređaja u prometu. Bluetooth uređaji imaju i veliku vjerojatnost detekcije od strane Bluetooth detektora. Još jedna prednost je relativno niska cijena potrebnog hardware. Bluetooth uređaji su neintruzivni, te je postavljanje takvog uređaja jednostavno i ne zahtijeva dodatne troškove poput primjerice ugrađivanja induktivne petlje.

Provedeno istraživanje je pokazalo da broj vozila s Bluetooth uređajem iznosi 10-12.5%, neovisno o tome da li se radi o radnom ili neradnom danu. Prema različitim izvorima, 2-10% [18, 27, 28] Bluetooth uređaja je dovoljan udio da bi se podaci mogli koristiti za daljnju analizu i upravljanje u prometu.

Najveći problem kod primjene Bluetooth tehnologija je čišćenje podataka, odnosno višestruke detekcije iste MAC adrese. Također, Bluetooth detektori mogu imati domet od nekoliko desetaka metara pa do 100 m te ako se ne koriste antene koje su ciljano usmjerene na manje područje, događat će se detekcije svih uređaja u tom području. Problem je i što se ne može

razlikovati gdje se Bluetooth uređaj nalazi. Iako je cilj očitati uređaje koji se nalaze u vozilima u prometu, događat će se i detekcije uređaja koje imaju i biciklisti i pješaci te je potrebno pronaći adekvatnu metodu čišćenja takvih podataka.

Bluetooth tehnologija kao takva ima svoje prednosti i nedostatke, ali se definitivno može koristiti za bolju analizu i unaprjeđenje prometnog sustava. Potrebno je poboljšati i unaprijediti metode čišćenja podataka, ali s obzirom na cijenu i rasprostranjenost uređaja, kao i svakodnevni porast u broju uređaja koji koriste Bluetooth tehnologiju od raznih slušalica, tableta, pametnih satova i dr., Bluetooth detektori bi trebali imati izraženiju ulogu u budućnosti.

7. Zaključak

Prikupljanje informacija o parametrima prometnog toka potrebno je za optimizaciju prometnog sustav. Mogu se prikupljati parametri poput brzine i gustoće prometnog toka, duljine repova čekanja, zauzeća i brojnih drugih. Pomoću njih možemo procijeniti stanje prometnih tokova kao i kvalitetu pružene usluge. Da bi se prikupili podaci, razvijene su različite tehnologije poput induktivnih petlji, infracrvenih detektora pa do bežičnih tehnologija poput FCD-a i Bluetootha.

Bluetooth je telekomunikacijski standard koji se koristi za razmjenu podataka između elektroničkih uređaja radiokomunikacijom kratkog dometa. Bluetooth tehnologija je vrlo rasprostranjena i danas se nalazi u gotovo svim pametnim telefonima, računalima, tabletima kao i u raznoraznom pomoćnom hardveru poput miševa, slušalica, a sve češće i u vozilima u obliku navigacijskih uređaja, radiouređaja i sl. Iz tog razloga postoji veliki potencijal za prikupljanje podataka o vozilima unutar kojih se primjenjuje takva tehnologija.

Svrha rada bila je izmjeriti udio vozila koja sadrže aktivne Bluetooth uređaje u odnosu na ukupan broj vozila na promatranoj dionici. Primjenom radar detektora prometnog toka za mjerenje ukupnog broja vozila u prometu i Bluetooth detektora, ustanovljeno je da je udio vozila koje sadrže Bluetooth uređaj 10-12.5%, što pokazuje konzistentnost podataka u mjerenom periodu. Korištenjem Bluetooth detektora moguće je dobivanje parametara poput srednje brzine vozila, vremena putovanja, a s obzirom na to da Bluetooth detektori imaju mogućnost prepoznavanja uređaja putem MAC adresa, mogu se izrađivati i P-O matrice, te dobiti informacije o rutama putovanja vozila.

Bluetooth tehnologija se pokazala kao vrlo korisnom za prikupljanje određenih parametara o prometnom toku, dok ubuduće treba istražiti i unaprijediti metode čišćenja podataka da bi se eliminirale detekcije pješaka i biciklista. Brojna istraživanja su prikazala da Bluetooth tehnologija ima mnoge prednosti u odnosu na druge tehnologije te da je točnost dobivenih podataka približno jednaka drugim tehnologijama koje su skuplje.

Bluetooth tehnologija je obećavajuća zbog jednostavnosti postavljanja, načina prikupljanja podataka te konačno i velike dostupnosti i rasprostranjenosti uređaja koji koriste Bluetooth tehnologiju. Uz određena poboljšanja u metodama čišćenja podataka, Bluetooth detektori kao tehnologija za prikupljanje podataka o parametrima prometnog toka ima veliki potencijal.

Literatura

[1] Dadić I., Kos G., Ševrović M. Teorija prometnog toka. Zagreb: Fakultet Prometnih Znanosti; 2014.

[2] Jelušić, N. Nastavni materijali kolegija: Telematička sučelja, 2017.

[3] Šurdonja S., Nežić D. Mikrosimulacijski model proračuna kružnog raskrižja. Rijeka: Građevinski fakultet, 2015.

[4] Bošnjak I., Badanjak D. Osnove prometnog inženjerstva. Zagreb: Fakultet Prometnih Znanosti; 2015.

[5] Klein L. A. Sensor Technologies and Dana Requirements for ITS, Artech House, Boston, London, 2001.

[6] The National Programme on Technology Enhanced Learning (NPTEL). Preuzeto sa: https://nptel.ac.in/courses/105101008/525_AutoLoop/point1/point.html [Pristupljeno: kolovoz 2019.]

[7] ResearchGate. Preuzeto sa: https://www.researchgate.net/publication/324552482_Sensor_Technologies_for_Intelligent_Transportation_Systems [Pristupljeno: kolovoz 2019.]

[8] Box S. (2003) Arterial roadway traffic dana collection using Bluetooth technology, Master thesis, Atlanta, Georgia Institute of technology

[9] Chadha S. S., Singh M., Prdeshi S. K. Bluetooth Technology: Principle, Applications and Current Status, International Journal of Computer Science & Communication. 2013;4(2):16-30.

[10] Young S. Bluetooth Traffic Monitoring Technology - Concept of Operation & Deployment Guidelines, University of Maryland - Center for Advanced Transportation Technology, 2008.

[11] KMJ Consulting. Bluetooth Travel Time Technology Evaluation - Using the BlueTOAD, KMJ Consulting, Inc., Haverford, PA, 2010.

[12] Martchouk M., Mannering F. Analysis of Travel Time Reliability on Indiana Interstates, Purdue University, 2009.
[13] Kim K., et al. Evaluation of Technologies for Freeway Travel Time Estimation: A Case Study of I-287 in New Jersey, Transportation Research Board 2011 Annual Meeting, Washington, D.C., 2011.
[14] Malinovskiy Y., et al. Investigation of Bluetooth-Based Travel Time Estimation Error on a Short Corridor, 90th Annual Transportation Research Board Meeting, Washington, D.C., 2011.
[15] Brennan T. M., et al. Influence of Vertical Sensor Placement on Data Collection Efficiency from Bluetooth MAC Address Collection Devices, Journal of Transportation Engineering. 2010;136(12): 1104-1109.
[16] Vo T. (2011) An Investigation of Bluetooth Technology for Measuring Travel Times on Arterial Roads: A Case Study on Spring Street, Master Thesis, Atlanta, Georgia Institute of Technology.
[17] Staszcuk J., McGowen P. Deploying Portable Advanced Traveler Information Systems: Redding Deployment Evaluation, Western Transportation Institute, Berkeley, CA, 2009.
[18] Barceló J., et al. Travel Time Forecasting and Dynamic OD Estimation in Freeways Based on Bluetooth Traffic Monitoring, 89th Transportation Research Board 2010 Annual Meeting, Washington, D.C, 2009.
[19] Quayle S., Koonce P. Arterial Performance Measures using MAC Readers - Portland's Experience, North American Travel Monitoring Exposition & Conference, Washington, D.C., 2010.
[20] Thogulava H., Antonovos V., Bingham S., Hill M. (2015) Developing origin-destination matrices using Bluetooth data for strategic transport models, European Transport Conference 2015, Frankfurt, Germany, 2015
[21] Hainen A. M., et al. Estimating Route Choice and Travel Time Reliability using Field Observations of Bluetooth Probe Vehicles, Transportation Research Board 2011 Annual Meeting, Washington, D.C., 2011.
[22] Cvetek D., Bojić V., Jelušić N., Muštra M. Initial Bluetooth probe vehicle penetration rate analysis: A case study in the city of Zagreb. Zagreb: International Scientific Conference "Science and Traffic Development", Opatija, 2019. Preuzeto sa:

https://bib.irb.hr/datoteka/1000404.Cvetek-Boji-Jelui-Mutra_pross_version.pdf
[Pristupljeno: kolovoz 2019.]

[23] Houston radar. Preuzeto sa: https://houston-radar.com/products/radar-data-collectors/speedlane-pro-multi-lane-radar/ [Pristupljeno: kolovoz 2019.]

[24] Deepbluesensor. Preuzeto sa: http://deepbluesensor.com/portfolio/deepblue-r-model/ [Pristupljeno: kolovoz 2019.]

[25] L-com. Preuzeto sa: http://www.l-com.com/wireless-antenna-24-ghz-8-dbi-flat-patch-antenna-4ft-sma-male-connector [Pristupljeno: kolovoz 2019.]

[26] Google Maps. Preuzeto sa: https://www.google.com/maps/@45.8042604,15.9739652,310a,35y,85.75h,1.73t/data=!3m1!1e3 [Pristupljeno: kolovoz 2019.]

[27] Pourhassan K. *How Reliable Is the Bluetooth-Based Origin-Destination Data?*, The Conference of Australian Institutes of Transport Research (CAITR), Adelaide, Australia, 2016

[28] Sintonen H. Bluetooth Based Travel Time Estimation. Finnish Transport Agency, Traffic Management. Helsinki 2012. Research reports of the Finnish Transport Agency 48/2012.

Slike

Slika 1 Protok vozila na presjeku ceste 4
Slika 2 Protok vozila na dionici ceste 5
Slika 3 Gustoća prometnog toka 6
Slika 4 Srednja prostorna brzina prometnog toka 7
Slika 5 Srednja vremenska brzina toka 8
Slika 6 Interval slijeđenja 9
Slika 7 Razmaci u slijeđenju vozila 10
Slika 8 Intruzivni detektori: 1. magnetometar, 2. piezoelektrički detektor, 3. induktivna petlja 16
Slika 9 Približni dometi Bluetooth uređaja 30
Slika 10 Primjer dobivenih podataka sa Bluetooth detektora 40

Slika 11 Radar korišten prilikom istraživanja 42
Slika 12 Bluetooth detektor korišten u istraživanju.....42
Slika 13 Antena korištena u istraživanju 43
Slika 14 Oprema za mjerenje postavljena na rasvjetnom stupu u Miramarskoj ulici 44
Slika 15 Dionica Miramarske ulice na kojoj je provedeno istraživanje.....45
Slika 16 Broj vozila u 5-minutnim intervalima izmjeren korištenjem Bluetooth-a i radara za period od četvrtka do petka 46
Slika 17 Broj vozila u 5-minutnim intervalima izmjeren korištenjem Bluetooth-a i radara u subotu 46
Slika 18 Broj vozila u 5-minutnim intervalima izmjeren korištenjem Bluetooth-a i radara u nedjelju 47

Tablice

Tablica 1 Broj vozila za radne i neradne dane 45
Tablica 2 Udio Bluetooth uređaja u ukupnom prometu.....49

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu diplomskog rada pod naslovom **Mjerenje parametara prometnih tokova primjenom Bluetooth tehnologije** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 5.9.2019 Vedran Bojić
(potpis)