

Primjena Bluetooth detektora u analizi prometnog toka i anomalija izazvanih pandemijom CoVID-19

Mario Muštra¹, Niko Jelušić, Dominik Cvetek

¹ suradnik Akademije tehničkih znanosti Hrvatske u Odjelu komunikacijskih sustava, zaposlen na Fakultetu prometnih znanosti Sveučilišta u Zagrebu

Sažetak: *Bluetooth detektori prometnog toka su uređaji koji služe za prikupljanje informacija o kretanju vozila i pješaka kroz prometnu mrežu. Omogućavaju detekciju i praćenje vozila i pješaka koji posjeduju neki aktivni Bluetooth uređaj. Zbog načina rada postiže se visok stupanj anonimnosti prikupljenih podataka. U radu je prikazan sustav za detekciju vozila i određivanje vremena putovanja temeljen na Bluetooth i radarskom detektoru, pomoći kojeg je moguće dobivanje statistički utemeljene informacije o broju vozila i drugih sudionika u prometu. Razmotrena je značajnost Bluetooth signala kao markera pri određivanju stanja prometne mreže i prikazani su statistički pokazatelji koji omogućavaju određivanje parametara prometnog toka. Prikazani su rezultati za jednu mjernu lokaciju u gradu Zagrebu tijekom 2019. i 2020. godine iz kojih je vidljiv utjecaj pandemije CoVID-19 na prometno opterećenje, uz dodatne specifičnosti uzrokovane potresom koji je pogodio zagrebačko područje u ožujku 2020. godine.*

Ključne riječi: *Bluetooth detektor, radarski detektor, prometni tok, CoVID-19.*

1. Uvod

Prometno zagušenje predstavlja sve veći problem s kojim se susreću svi, od prometnih planera i ljudi zaduženih za upravljanje prometnim tokom, do prosječnih građana koji su korisnici prometnog sustava. S obzirom na porast učestalosti zagušenja, pokušavaju se pronaći različiti načini za njegovo smanjivanje i izbjegavanje. U većini velikih gradova u svijetu, mobilnost stanovnika je, uslijed zagušenja, narušena i velik napor se ulaže u redukciju tog problema. Pojava zagušenja karakterizirana je manjim brzinama kretanja vozila, duljim vremenima putovanja do nekog odredišta, nesigurnosti dolaska u očekivano vrijeme i dugim redovima čekanja [1]. Zagušenje

je problem koji se može sagledavati kao nelinearna funkcija, pri čemu se nelinearnost očituje u tome da približavanjem maksimalnom kapacitetu neke prometnice, mala pozitivna promjena volumena prometa uzrokuje mnogo značajnija prometna zagušenja [2]. Uobičajeno je da se takva zagušenja u gradovima događaju periodički, posebice s periodom od jednog dana, gdje na povećanje zagušenja najviše utječu migracije stanovnika povezane s dolascima na posao i odlascima s posla. Osim dnevnih periodičkih migracija, važno je napomenuti kako postoje i tjedne ili godišnje migracije, često povezane s dobom godine i sličnim rasporedom godišnjih odmora, odnosno trajanjem školskih godina. Uslijed periodičkih zagušenja, dolazi do pojave tzv. uskih grla, čija zajednička osobina je postojanje veće potražnje od raspoloživih resursa, odnosno kapaciteta prometnice. Razlozi njihove pojave ne moraju nužno biti samo povećanje potražnje za kapacitetom uslijed potrebe za migracijom, nego razlog može biti i loše optimiran signalni plan semafora. U posljednje vrijeme, posebno razvojem metoda strojnog učenja i dubinske analize podataka, razvijen je velik broj metoda koje koriste različite ulazne parametre za predviđanje prometnog toka [3], [4], što pokazuje interes istraživačke zajednice za rješavanje ovog problema. Neperiodička zagušenja, s druge strane, mogu imati mnogo izvora, pretežno slučajne naravi, poput prometnih nesreća, kvarova na vozilima, popravaka prometnica ili posebnih događaja koji uzrokuju promjenu odvijanja prometa na nekoj prometnoj površini [5]. U neperiodička zagušenja možemo ubrojiti i ona koja nastaju uslijed djelovanja prirodnih katastrofa, poput potresa. Analizom ponašanja prometa u takvim slučajevima dolazimo do ključnih pokazatelja sposobnosti prometne mreže da omogući kvalitetno odvijanje prometa. Lin i sur. [6] analizirali su regionalni prometni tok u visoko naseљenom području prilikom požara. U svom radu razvili su matematički model, koji su provjerili eksperimentalnom analizom uporabom simulacijskog programa VISSIM, i kojim su željeli utvrditi duljinu trajanja pojedinih uzoraka prometnog toka kojim se može dobro opisati zagušenje uslijed iznenadne katastrofe. Othman i Hamid [7] analizirali su utjecaj poplave na izbor puta, tj. rute, kojom bi se trebao odvijati promet. Uporabom geografskih informacijskih sustava (GIS) i mogućnosti da u njima zapisani entiteti sadrže prostorne i atributne informacije, simulirali su sustav odgovora na poplavu u vidu evakuacijskog plana. Shao i sur. [8] predložili su metodu za optimizaciju prometa u urbanoj prometnoj mreži, nakon što se dogodi nepredviđena katastrofa, s ciljem boljeg iskorištenja kapaciteta prometne mreže zbog novonastalih promjena. Fan i Tangqing [9] te Design i sur. [10] bavili su se analizom i optimizacijom prometa u slučaju potresa i potrebe za djelovanjem različitih hitnih službi. Zbog potrebe za žurnim djelovanjem i panike koja se stvara kod opće populacije, dolazi do velikih zagušenja koja onemogućavaju pravovremen i kvalitetan rad službi koje se moraju naći na terenu u trenucima neposredno nakon potresa. Pristup kojim se takav problem može ublažiti je razvoj posebno dizajniranog upravljanja u incidentnim situacijama, što uključuje tehnološki razvoj samog upravljačkog sustava te protokole postupanja u incidentnim situacijama. Pandemija CoVID-19, uzrokovanja koronavirusom SARS-CoV-2, može se u nekom dijelu promatrati kao prirodna katastrofa, ali obilježja prometnog toka uslijed te katastrofe su posve drugačija od uobičajenih za

katastrofe. Sve zemlje u svijetu predložile su uvođenje različitih mjeru za suzbijanje širenja virusa, koje su se kroz vrijeme pandemije mijenjale i utjecale na vrlo veliku fluktuaciju u prometnom opterećenju, kako urbanih, tako i ruralnih te magistralnih prometnica. Posljedično ograničenju kretanja, značajno su smanjena zagušenja zbog smanjenja broja vozila. Analitička kompanija INRIX provela je analizu kretanja u vrijeme pandemije CoVID-19 u SAD-u te su naveli kako je došlo do smanjenja prometa osobnih vozila za 46%, dok je pad teretnog prometa iznosio 13% [11].

U ovom radu prikazan je postupak izrade i specifikacija kombiniranog detektora prometnog toka, koji se sastoji od detektora Bluetooth signala i radarskog detektora koji omogućavaju detekciju vozila, njihove brzine i identiteta koji nije poveziv sa stvarnim identitetom osobe ili putnika koji posjeduje neki Bluetooth uređaj. Posebna analiza prometnih parametara data je za vrijeme neposredno nakon potresa koji je pogodio zagrebačko područje 22. ožujka 2020. godine. Prikazane su brzina i volumen prometa iz kojih je vidljivo vrlo značajno povećanje volumena i smanjenje brzine uzrokovano panikom i napuštanjem domova velikog broja ljudi te straha koji je rezultirao da se mnogi bolje osjećaju u vozilima kojima su pokušali napustiti sami centar grada. Prikupljanje podataka o prometnim tokovima, u ovakvim posebnim situacijama, dragocjeno je sa stajališta razvoja samih upravljačkih sustava te razvoja protokola upravljanja u incidentnim situacijama.

Rad je podijeljen u 5 poglavlja, od kojih u drugom poglavlju donosimo konstrukciju i specifikaciju detektora te sposobnosti statističke analize uporabom tog detektora. Treće poglavlje donosi analizu prometnog toka i udjela vozila koja posjeduju Bluetooth uređaj u ukupnom broju uzorkovanih vozila. Četvrti poglavlje prikazuje analizu prometnog toka uslijed pandemije CoVID-19 i potresa koji je pogodio zagrebačko područje u proljeće 2020. godine. Peto poglavlje donosi zaključke i smjernice za buduće istraživanje.

2. Dizajn detektorskog sustava prometnog toka

Detektor prometnog toka sastoji se od detektora Bluetooth signala i radarskog detektora te autonomnog sustava napajanja koji omogućava postavljanje detektora nezavisno od elektroenergetske infrastrukture. U ovom poglavlju bit će prikazane pojedine komponente sustava.

2.1 Bluetooth detektor

Kod detektora prometala, možemo izdvojiti dvije osnovne kategorije, u pogledu informacija koje detektor pruža korisniku, a to su detektori koji mogu samo detektirati

prometalo i detektori koji pružaju dodatne informacije na osnovi kojih se prometalo može identificirati. Bluetooth detektori omogućuju upravo tu dodatnu funkciju, a to je jednoznačna identifikacija detektiranog uređaja, bez zadiranja u privatnost korisnika, odnosno izravne detekcije identiteta. Za prikupljanje podataka korištenih u ovom radu, postavljeni su Bluetooth detektori proizvođača Trafficnow, DeepBlue Model R, slika 1.



Slika 1: Bluetooth detektor,
Trafficnow DeepBlue
Model R.

Navedeni uređaj omogućava detekciju Bluetooth uređaja koji se nalaze u njegovom detekcijskom području, koje ovisi o snazi samih uređaja, vremenskim uvjetima i dijagramu zračenja korištenih antena. Osim Bluetooth signala, uređaj može detektirati i signal lokalnih bežičnih mreža (Wi-Fi), te ima ugrađene module za samolociranje putem GPS-a i komunikaciju putem 2G/3G mobilne mreže. Identifikacija detektiranog uređaja ostvaruje se čitanjem MAC-(*Media Access Control*) adrese koja je jedinstvena za svaki uređaj opremljen Bluetooth primopredajnikom. MAC adresa sastoji se od 48 bitova na osnovi kojih je moguće identificirati proizvođača uređaja i tako dobiti dodatne informacije o detektiranom uređaju. Velika prednost ovakve detekcije je mogućnost praćenja kretanja uređaja u slučaju da je na nekom području instalirana mreža ovakvih detektorova. Takvi podaci omogućavaju stvaranje izvorišno-odredišnih matriča, koje su ključne za dobivanje informacije o odvijanju prometa na promatranom području. Primjer podataka prikupljenih ovim detektorom prikazan je tablicom 1.

Tablica 1: Primjer zapisa prikupljenih Bluetooth detektorom

Vremenska oznaka	MAC adresa	Prvi dio MAC adrese	Tip uređaja	RSSI, [dBm]
1552565883	48:A9:D2:EF:9C:98	48:A9:D2	340408	-84
...				
1568632271	00:07:80:0A:F8:D3	00:07:80	001F00	-27
1568646506	FC:19:10:AA:27:A3	FC:19:10	5A0204	-88
1568672331	9C:8D:7C:C0:55:1C	9C:8D:7C	340408	-62

2.2 Radarski detektor

Radarski detektori tipa FMCW (*Frequency Modulated Continuous Wave*), tj. detektori koji koriste frekvencijski modulirani signal s kontinuiranim zračenjem, omogućavaju prikupljanje podataka o brzini vozila, volumenu prometnog toka te klasifikaciju vozila. U ovom istraživanju korišteni su detektori su proizvođača Houston Radar, model Speedlane, slika 2.



Slika 2: Radarski detektor, Houston Radar Speedlane.

Navedeni radarski detektor radi u Ka frekvencijskom području, oko frekvencije od 24 GHz, a detekcija se obavlja pomoću dvostrukog dvodimenzijskog antenskog niza, postavljenog pri lijevom i desnom rubu detektora, slika 3. Ovakvo izvedeni detektor omogućava ne samo detekciju vozila na principu promjene u odjeku odaslanog signala, nego i detekciju duljine te brzine vozila, zbog postajanja dva odašiljačko-prijamnička dijela. Osim toga, moguća je i detekcija smjera u kojem vozilo putuje te konfiguriranje detekcijskih zona do 8 prometnih traka ako je omogućena dovoljna visina i udaljenost od ruba prometnice za postavljane.

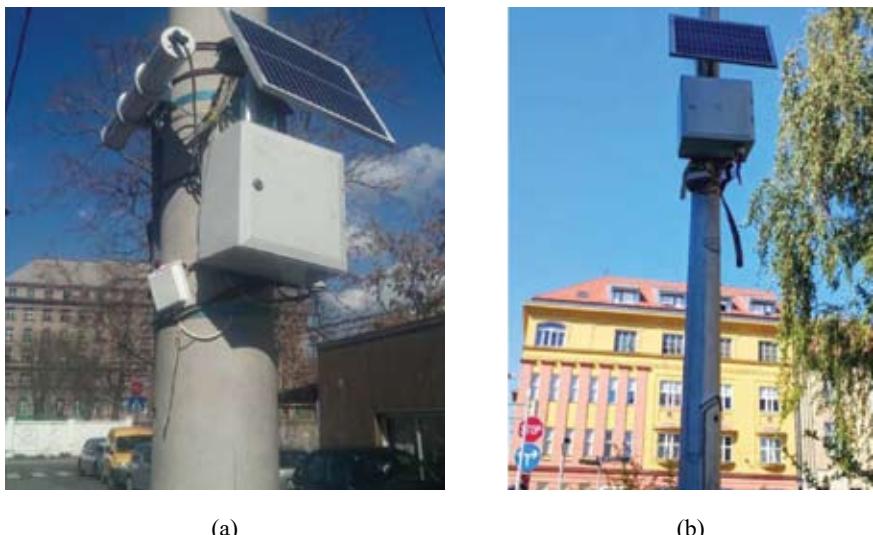


Slika 3: Antenski niz radarskog detektora Houston Radar Speedlane, (c) Houston Radar LLC.

2.3 Detektorski sustav

Do sada navedeni detektori vozila i uređaja koriste potpuno različite tehnologije detekcije i pružaju različitu vrstu informacije. Kombinacijom dobivenih informacija moguće je ostvariti vrlo napredan sustav, koji nam može dati vrijedne informacije o prometnom toku, vrsti vozila i donekle navikama sudionika u prometu za korišteњe pojedine tehnologije. Objedinjavanjem Bluetooth i radarskog detektora možemo dobiti informaciju o protoku vozila, klasifikaciji s obzirom na gabarite i trenutačnoj

brzini vozila, udjelu prometala opremljenih uređajem koji koristi Bluetooth te vremenu putovanja između dviju točaka u prometnoj mreži na kojima se nalaze Bluetooth detektori. Kako bi sustav bio funkcionalan tijekom cijelog dana i svaki dan u tjednu, potrebno mu je osigurati napajanje, koje može biti izvedeno spajanjem na elektroenergetsku mrežu ili, kao u navedenom slučaju, neovisno. Neovisno napajanje sastoji se od fotonaponskog sustava, tj. fotonaponskog panela, kojim se puni akumulatorska baterija preko kontrolera za regulaciju napona. Takav sustav, ako je ispravno dimenzioniran, može pružiti potpunu autonomiju za višemjesečni rad. Navedeni sustav postavljen je u Zagrebu na Miramarskoj cesti s jedne i druge strane podvožnjaka, pri čemu je sustav s južne strane podvožnjaka opremljen Bluetooth i radarskim detektrom, slika 4 (a), a sa sjeverne strane podvožnjaka samo Bluetooth detektorom, slika 4 (b), opisanima u ovom poglavlju.

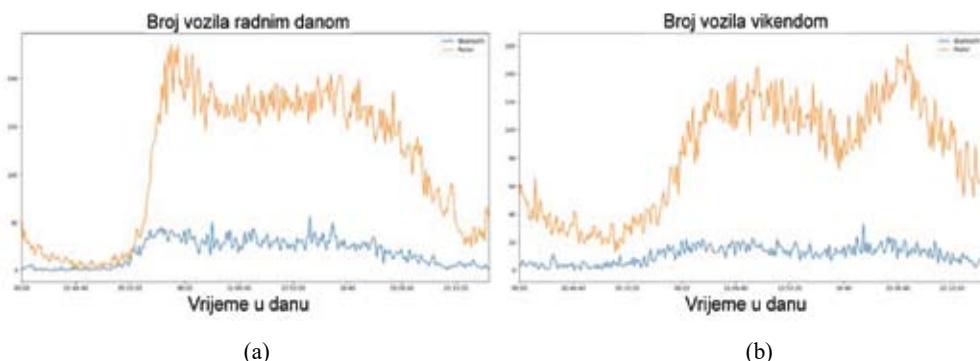


Slika 4: (a) Bluetooth i radarski detektor postavljen u Miramarskoj cesti u Zagrebu južno od podvožnjaka; (b) Bluetooth detektor postavljen u Miramarskoj cesti u Zagrebu, sjeverno od podvožnjaka.

3. Analiza udjela vozila koja posjeduju aktivan Bluetooth uređaj i prometnog toka

U prethodnom poglavlju opisan detektorski sustav, koji se sastoji od radarskog i Bluetooth detektora, omogućava detekciju vozila mjeranjem odjeka signala od refleksivnog (metalnog) objekta te detekciju Bluetooth uređaja. Ova sposobnost je iznimno važna jer omogućava dobivanje informacije o statističkoj značajnosti Bluetooth signala kao markera za određivanje parametara prometnog toka [13]. Važno je napomenuti kako Bluetooth detektor ne može razlikovati stacionarni i pokretni

izvor signala te pješake od vozila, što ga čini donekle neprikladnim za ovu primjenu, detekcije u urbanom području, jer je obilježje urbanog prometa upravo mješavina različitih tipova vozila i pješaka. Kako bismo izdvojili detekcije isključivo vozila, koja jesu ili nisu opremljena aktivnim Bluetooth uređajem, bilo je potrebno postaviti još jedan Bluetooth detektor na bliskoj lokaciji, ali dovoljno dalekoj, kako Bluetooth detektori ne bi istovremeno detektirali isti Bluetooth uređaj, tj. da im se detekcijske zone ne preklapaju. Takva konfiguracija detektora pomaže pri naknadnom filtriranju podataka tj. omogućava "uklanjanje" uređaja koja se ne nalaze u vozilima, npr. pješaka koji se kreću sporije od kretanja na prometnici. Mjerjenje kojim smo dobili udio vozila opremljenih Bluetooth uređajem u ukupnom broju vozila provedeno je u ožujku 2019. godine i dalo je rezultat od 12,19% vozila koja imaju uključen Bluetooth uređaj tijekom radnih dana i 10,00% vozila tijekom vikenda. Rezultat detekcija radara i Bluetooth uređaja prema 15-minutnim intervalima za ta dva slučaja prikazan je slikama 5 (a) i 5 (b), [12].



Slika 5: (a) Broj detektiranih vozila Bluetooth (plavo) i radarskim (narančasto) detektorom za tipični radni dan u 15-minutnim intervalima; (b) Broj detektiranih vozila Bluetooth (plavo) i radarskim (narančasto) detektorom za tipični dan vikenda u 15-minutnim intervalima.

3.1 Uporaba Bluetooth detektora kao točkastog detektora

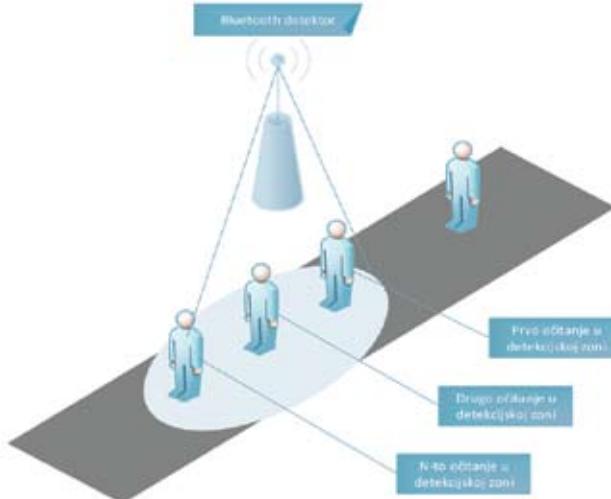
Analizom udjela vozila opremljenih aktivnim Bluetooth uređajem, može se zaključiti kako se dobivaju podaci koji su stabilni u vremenu i kao takvi su dobar pokazatelj stanja prometne mreže, odnosno dijela prometne mreže koji promatramo. Bluetooth detektori su učinkoviti ako ih je postavljeno mnogo jer omogućavaju računanje vremena putovanja između različitih točaka u prometnoj mreži. Kako bi ispitali mogućnost uporabe Bluetooth detektora kao točkastog detektora, kojim možemo definirati prometno zagušenje, potrebno je uvesti pojam vremena zadržavanja u detekcijskoj zoni.

$$T_z = T_{\text{postjedna detekcija}} - T_{\text{prva detekcija}} \text{ [s]}, \quad (1)$$

gdje je T_z vrijeme zadržavanja u detekcijskoj zoni, a jednako je razlici vremena u kojem su se dogodile posljednja i prva detekcija, slika 6. Osnovni prometni parametri kojima opisujemo prometni tok su volumen i zauzeće, pri čemu volumen definiramo kao:

$$q_T = \int_0^T q(t) \text{ [vozila/h]}, \quad (2)$$

pri čemu je q_T je volumen, odnosno ukupni broj vozila koji prolazi presjekom prometnice u definiranom vremenskom intervalu.



Slika 6: Primjer višestrukih detekcija pješaka ili sporog vozila u detekcijskog zoni Bluetooth detektora.

Zauzeće se definira kao dio vremena u kojem se na detekcijskoj zoni nalazi vozilo u odnosu na definirani vremenski interval, i vrijedi slijedeći izraz:

$$OCC = \frac{\sum tocc_i}{T}, \quad (3)$$

gdje je OCC zauzeće, $tocc_i$ je zauzeće uzrokovano i -tim vozilom, a T je definirani vremenski interval. Ako ovu jednadžbu prilagodimo za uporabu s Bluetooth detektrom i parametrima koje možemo mjeriti, dobivamo:

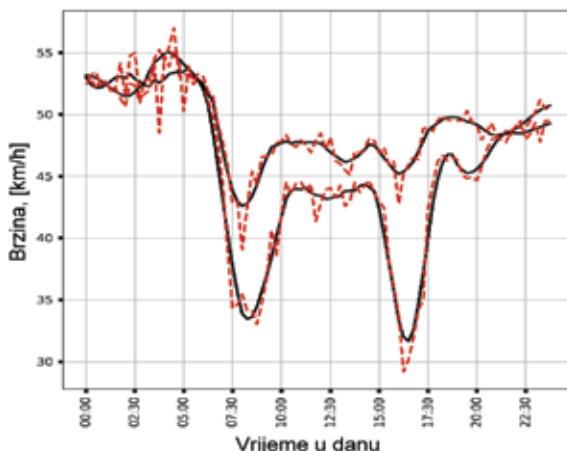
$$T_z = tocc_i = \frac{L_i + L_D}{v_i} \text{ [s]}, \quad (4)$$

gdje je L_i duljina i -toga vozila, L_D duljina detekcijske zone, a v_i brzina i -toga vozila. Srednju brzinu možemo izraziti kao:

$$\bar{v}_t = \frac{1}{n} \sum_{i=1}^n v_i \text{ [m/s]}. \quad (5)$$

3.2 Analiza prometnog toka uporabom Bluetooth detektora

Uporabom navedenih jednadžbi, dobivamo tzv. profile brzina koji pokazuju fluktuaciju u ostvarenoj brzini na nekom segmentu prometnice u vremenu. Vrijeme promatranja za dobivanje pojedinog usrednjjenog uzorka može biti proizvoljno pa se tako često koriste 5- i 15-minutni intervali. Primjer takvog profila brzina za prometnicu u gradu Zagrebu, posebno za ljetni period (gornja krivulja) i ostatak godine (donja krivulja) prikazan je slikom 7. Navedeni grafikon dobro prikazuje očekivano prometno opterećenje, koje rezultira manjim prosječnim brzinama, i možemo reći kako odgovara za velik dio prometnika u gradu Zagrebu i generalno urbanim mjestima s većom gustoćom naseljenosti.



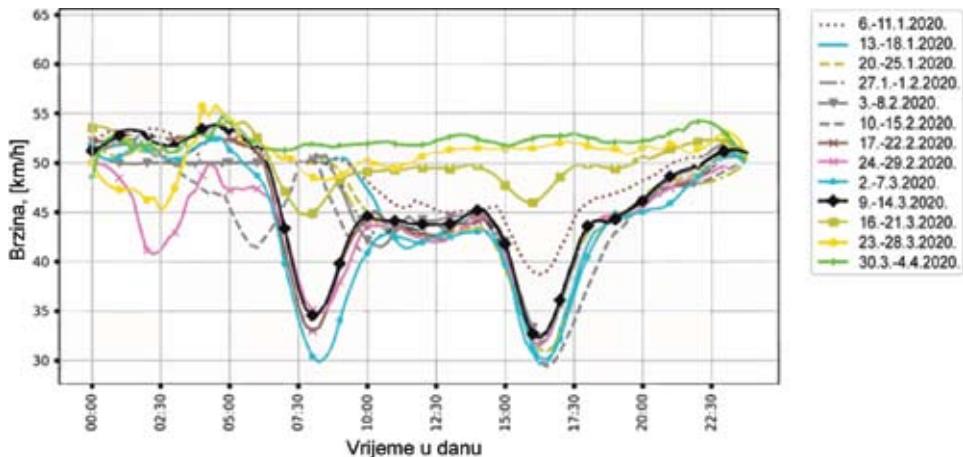
Slika 7: Primjer razlike u prosječnoj ostvarenoj brzini za ljetne mjesecе i ostatak godine u gradu Zagrebu, crvena krivulja pokazuje sirove podatke, a crna usrednjene.

U jutarnjim i popodnevnim satima dolazi do značajnog usporenenja izazvanog povećanom prometnom potražnjom zbog lokalnih migracija vezanih uz obavljanje posla. To je vrlo izraženo tijekom skoro cijele godine, izuzev u periodu kad većina stanovništva koristi godišnje odmore, a možemo reći da je to posebno izraženo od 15. srpnja do 15. kolovoza, kako ilustrira gornja krivulja grafikona sa slike 7.

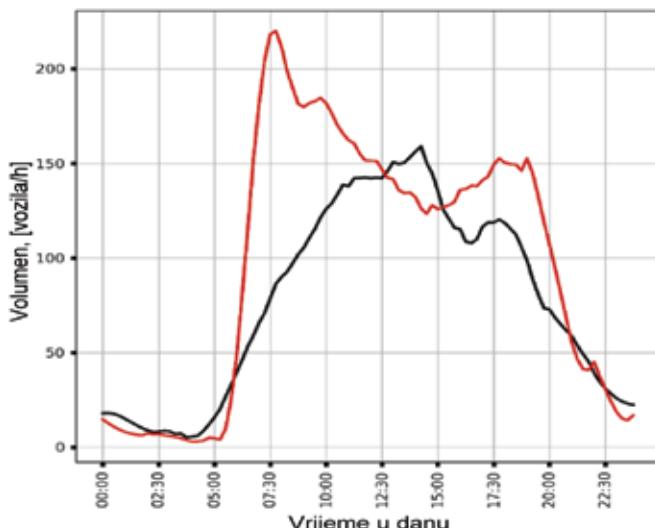
4. Analiza prometnog toka uslijed pandemije CoVID-19 i potresa

Postupnim uvođenjem ograničavanja kretanja i obustave obavljanja velikog broja djelatnosti, koje se počelo događati sredinom ožujka 2020. godine, a izazvanog širenjem bolesti CoVID-19, očekivano je bilo kako će se prometna potražnja smanjiti, a

time i dnevna fluktuacija prosječne brzine. Rezultat mjerena radarskim detektorom postavljenim na Miramarskoj cesti u Zagrebu, za period od siječnja do travnja 2020. godine, prikazan je slikom 8. Iz slike 8 vidljivo je kako su predviđanja smanjenja fluktuacije u brzini uslijed dnevnih migracija dobra, jer u periodu od sredine ožujka do kraja mjerena, odnosno sredine travnja, odstupanja između maksimalne i minimalne brzine gotovo ne postoje, tj. manja su od 5 km/h. Iz toga možemo zaključiti kako je volumen prometa manji ili graničan volumenu koji je ostvariv s obzirom na kapacitet prometnice bez smanjenja protoka.



Slika 8: Kretanje prosječne brzine usrednjene kroz 15-minutne intervale za period od siječnja do travnja 2020. godine.



Slika 9: Volumen prometa iskazan u broju vozila po satu na dan potresa (crvena krivulja) i dan prije potresa (crna krivulja).

Potres, koji je pogodio Zagreb i zagrebačko područje 22. ožujka 2020. godine, uzrokovao je značajno povećanje broja vozila koja su se našla na prometnici u to vrijeme. Rezultat je to panike i želje velikog broja stanovnika za odlaskom iz grada i životnih prostora, posebice u centru grada. Na slici 9 prikazan je utjecaj potresa na volumen prometa, izmјeren ranije opisanim detektorskim sustavom, postavljenim na Miramarškoj cesti u Zagrebu, gdje crvena krivulja pokazuje volumen prometa na dan potresa, a crna krivulja pokazuje volumen prometa dan prije potresa.

Kako je i vidljivo iz slike 9, unatoč tome što se potres dogodio u nedjelju, kad je očekivano još promet slabijeg intenziteta, zbog minimalnog broja poslovnih migracija, ukupni broj vozila koja su prošla ispred detektora Miramarškom cestom bio je iznimno velik i ostvareno zagušenje je jednako onom radnim danom u vrijeme jutarnjeg zagušenja, oko 8:00 sati, kako je vidljivo iz slike 5 (a). Umjesto očekivanih 50-ak vozila po satu, u to vrijeme cestovnim segmentom prolazilo je preko 200 vozila po satu.

Ovakvo ponašanje ljudi je očekivano i nije ga moguće sprječiti, kako su naveli mnogi autori radova navedenih u uvodnom poglavlju, ali postoje načini kako smanjiti potencijalne posljedice sličnih zagušenja putem upravljanja u incidentnim situacijama. Gledajući situacije u Zagrebu, razvoj i unapređenje prometne upravljačke infrastrukture, uključujući naravno centar za nadzor i upravljanje prometom, trebali bi biti jedan od prioriteta. Uporaba Bluetooth detektora, a posebno ako se kombiniraju s radarskim detektorima, postavljeni u dovoljnoj gustoći na gradskoj prometnoj mreži, omogućava dobru "sliku" prometnih tokova, a time osigurava temelje za suvremene načine automatskog upravljanja prometom, kojima bi se ublažila zagušenja. Nadalje, dovoljna gustoća Bluetooth detektora, omogućava stvaranje polazišno-odredišnih matrica, danas posebno poželjnih podataka o prometnim tokovima. Podaci dobiveni takvim detektorskim sustavima u incidentnim situacijama mogu biti korišteni za određivanje lokacije incidenta, za upravljanje signalizacijom, za upućivanje žurnih službi te za razne druge potrebne operacije.

5. Zaključci i smjernice istraživanja

U ovom radu prikazana su istraživanja o mogućnosti uporabe komunikacijske tehnologije za prikupljanje i analizu prometnih parametara. Može se zaključiti kako Bluetooth tehnologija omogućava, neinvazivno u pogledu privatnosti, prikupljanje podataka o kretanju korisnika te zauzeću prometnica. Unatoč relativno malom udjelu vozila opremljenih aktivnim Bluetooth uređajem u ukupnom broju vozila, moguće je prilično točno zaključiti kakvo je stanje prometnog toka na pojedinom mjernom

mjestu kroz vrijeme zadržavanja detektiranog Bluetooth uređaja u detekcijskoj zoni. Na osnovi detekcije jedinstvenog obilježja svakog uređaja, MAC adrese, moguće je pratiti kretanje uređaja u mreži osjetila (detektora), mjeriti vremena putovanja i stvarati polazišno-odredišne matrice. Na osnovi takve "slike" prometnih tokova, može se procijeniti gdje dolazi do potrebe za intervencijama, bilo u smislu infrastrukturnih zahvata ili načina upravljanja primjerice, automatsko predlaganje alternativnih ruta putem promjenjivih prometnih znakova ili telekomunikacijskim sustavom.

Složenim sustavom, koji omogućava istovremenu uporabu Bluetooth i radarskog detektora, analizirali smo odstupanja u prometnom toku za vrijeme dvaju vrlo značajnih, ali s prometnog stajališta, posve različitih događaja: pandemije CoVID-19 i značajnog potresa. Prikazani rezultati potvrđuju očekivanja i pokazuju kako je zatvaranje uzrokovanim pokušajem sprječavanja pandemije CoVID-19 utjecalo na prometnu sliku u centru Zagreba u smislu značajnog smanjenja opterećenja prometnica i smanjenja vremena putovanja u satima jutarnjeg i popodnevnog vršnog opterećenja. S druge strane, kratkotrajna katastrofa uzrokovana potresom, stvorila je velika prometna opterećenja, koja je vrlo teško izbjegći jer spadaju u nepredvidiva, ali se uporabom modernih komunikacijskih tehnologija usmјerenih ka detekciji kretanja korisnika može značajno smanjiti negativan utjecaj takvih katastrofa na prometna zagušenja.

Budućnost istraživanja u ovom području trebala bi biti vezana uz integraciju detektora prometnog toka te rješenja koja koriste komunikacijske tehnologije poput Bluetootha, bežičnih lokalnih mreža i mobilnih mreža vodeći pri tome naravno računa o privatnosti korisnika. Podaci dobiveni takvim integriranim sustavima dragocjeni su u automatskom upravljanju prometom, pri planiranju prometne infrastrukture, u upravljanju u incidentnim situacijama te raznim drugim suvremenim uslugama u prometu.

Literatura

- [1] Falcocchio, J. C. & Levinson, H. S.: *Road Traffic Congestion: A Concise Guide*, Springer Tracts Transp. Traffic, (2015)
- [2] Litman, T.: Transportation Cost and Benefit Analysis II - Congestion costs, *Victoria Transp. Policy Inst.*, (2016)
- [3] Pan, Z.; Liang, Y.; Wang, W.; Yu, Y.; Zheng, Y. & Zhang, J.: Urban traffic prediction from spatio-temporal data using deep meta learning, *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, str. 1720-1730, (2019), doi: 10.1145/3292500.3330884.
- [4] Guo, K.; Hu, Y.; Qian, Z.; Liu, H.; Zhang, K.; Sun, Y.; Gao, J. & Yin, B.: Optimized Graph Convolution Recurrent Neural Network for Traffic Prediction, *IEEE Trans. Intell. Transp. Syst.*, (2020), str. 1-12, doi: 10.1109/tits.2019.2963722.

- [5] Anbaroğlu, B.; Cheng, T. & Heydecker, B.: Non-recurrent traffic congestion detection on heterogeneous urban road networks, *Transp. A Transp. Sci.*, Vol. 11, izd. 9, str. 754-771, listopad (2015), doi: 10.1080/23249935.2015.1087229.
- [6] Lin, C.; Yu, Y. & Wu, D.: Traffic Flow Catastrophe Border Identification for Urban High-Density Area Based on Cusp Catastrophe Theory: A Case Study under Sudden Fire Disaster, *Appl. Sci.*, Vol. 10, izd. 9, (2020)
- [7] Othman, M. H. & Hamid, A. H. A.: Impact of Flooding on Traffic Route Choices, *SHS Web of Conferences*, EDP Sci., Vol. 2, str. 1-9, (2014)
- [8] Shao, Z.; Ma, Z.; Liu, S. & Lv, T.: Optimization of a Traffic Control Scheme for a Post-Disaster Urban Road Network, *Sustainability*, Vol. 10, izd. 68, (2018), doi: 10.3390/su10010068.
- [9] Fan, L. & Tangqing, L.: Study on Optimization of Earthquake Transportation Emergency Management, *Proc. 7th Int. Conf. Innov. Manag.*, str. 1858-1863, (2010)
- [10] Design, L.; Otsuka, R. P.; Work, D. B. & Song, J.: Estimating post-disaster traffic conditions using real-time data streams, *Structure and Infrastructure Engineering 12*, Vol. 8, (2016), str. 904-917, doi: 10.1080/15732479.2015.1054293.
- [11] Pishue, B.: COVID-19's Impact on Freight: An Analysis of Long-Haul Freight Movement During a Pandemic, *INRIX Research*, (2020)
- [12] Cvetek, D.; Bojić, V.; Jelušić, N. & Muštra, M.: Initial Bluetooth Probe Vehicle Penetration Rate Analysis: a Case Study in the City of Zagreb, *International Scientific Conference: Science and Traffic Development: Next Generation Transport Industry Innovations*, (2019)
- [13] Cvetek, D.; Muštra, M.; Jelušić, N. & Abramović, B.: Traffic Flow Forecasting at Micro-Locations in Urban Network using Bluetooth Detector, *Proceedings Elmar - International Symposium Electronics in Marine*, str. 57-60, (2020), doi: 10.1109/ELMAR49956.2020.9219023.