

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

ZAVRŠNI RAD

**PAMETNO RJEŠENJE PROMETNIH GUŽVI U
SPLITU**

Mentor:

prof.dr.sc. Željko Garača

Student:

Marko Marković

Split, kolovoz 2019.

SADRŽAJ

1	UVOD.....	1
1.1	Definicija problema.....	2
1.2	Metode rada	3
1.3	Cilj rada.....	3
2	TREKUTNO STANJE PROMETNICA	4
2.1	Dosadašnja tehnologija	4
2.2	Anketa: Nezadovoljstvo trenutnim stanjem prometnica	5
2.3	Postojeća rješenja	8
3	OSMIŠLJAVANJE I OPISIVANJE SUSTAVA.....	12
3.1	Glavno računalo	13
3.2	Povezivanje sustava	17
3.3	Raskrižja	18
3.4	Senzorno upravljčke jedinice	19
3.5	Funkcioniranje sustava.....	20
3.6	Rezultati istraživanja	26
4	ZAKLJUČAK	29
	LITERATURA	31
	SAŽETAK.....	32
	SUMMARY	33

1 UVOD

Kroz dvadeseto stoljeće dogodio se niz otkrića važnih izuma koji su promijenili tijek razvoja civilizacije čovječanstva. Jedan od najvažnijih izuma bio je izum mikroprocesora koji je omogućio eksponencijalan razvoj računala te ga je masovna proizvodnja, a time i pad cijene, učinila dostupnim apsolutno svima. Drugi važan izum definitivno je motor sa unutrašnjim sagorijevanjem te pojava prvih automobila, kao i drugih oblika prijevoznih sredstava. Navedeni izumi omogućili su povezivanje ljudi na globalnoj razini, kako u fizičkom, tako i u virtualnom smislu. Procesima interakcije i integracije na svjetskoj razini, koje zajedničkim imenom nazivamo globalizacijom, bio je jedan od glavnih pokretača razvoja kroz 20. stoljeće. Na taj način oblikovan je svijet kakav danas poznajemo. Sektori poput gospodarstva, poljoprivrede, industrije i energetike između ostalih, naslonjeni su na razvoj tehnologije i globalizaciju. Veći razvoj donio je specifične probleme. Velika industrijska i poslovna središta su postala još naseljenija. Sve veće su migracije prema takvim mjestima. S novim djelatnostima otvorila su se brojna nova radna mjesta zbog kojih dolazi do porasta stanovništva, te se tako javio jedan od ključnih problema današnjice - u prometu velikih gradova.

Internet stvari relativno je nova tehnologija koja još pronalazi svoj put u implementaciji u svakodnevni život, ali s obzirom na to kada se pojavila u široj javnosti zasad je itekako prihvaćena, kako sa poslovne strane velikih kompanija, tako i sa strane običnog stanovništva. Sama priča o Internetu stvari nije započela u 21. stoljeću, započela je puno prije. Američko Ministarstvo obrane je 1969. godine započelo projekt „ARPANET” koji je trebao povezati nekoliko računala u SAD-u. Zanimljivost tog projekta proizlazi upravo u njegovom ključnom faktoru koji je zaslužan je za razvoj i društvo kakvo poznajemo danas. „ARPANET“ je bio modularan i njegov uspjeh leži u tome da može nastaviti rad čak i ako su dijelovi komunikacijskog kanala uništeni. Taj uspješni projekt prva je prava preteča interneta kakvog danas poznajemo. Jedan od najvećih problema koji se javio bio je način adresiranja računala na mreži radi razmjene podataka, kao i povezivanje sa drugim mrežama. Osmišljavanjem i primjenom TCP/IP protokola uklonjene su sve prepreke u komunikaciji računala te se tako rodio univerzalni “jezik” interneta. Internet, koji zovemo još i „mreža svih mreža“, gomila je računala raspodijeljenih širom cijeloga svijeta povezanih preko raznih komunikacijskih kanala. Tom mrežom omogućena je neometana komunikacija na globalnoj razini. Razvoj samoga WEB-a samo je ubrzao već započeti proces umrežavanja te je svakim danom

sve veći broj umreženih računala omogućio dohvaćanje zabilježenog znanja kao i neometane zabave iz udobnosti vlastitoga doma. Razvojem tehnologije i bržim prijenosom podataka razvijaju se i nove ideje za primjenu Interneta. Prvi je jednu takvu ideju iznio Kevin Ashton te je u svojoj knjizi „How to Fly a Horse“(2015) rekao sljedeće: „Ako i kada budemo imali računala koja će znati sve o svim objektima koji nas okružuju i ako će moći skupljati podatke bez naše pomoći, tada ćemo moći smanjiti potrošnju energije, troškove života i općenito unaprijediti kvalitetu života. Znat ćemo kada određeni objekt (stvar) treba zamijeniti, popraviti ili ukloniti.” U posljednjih nekoliko godina pojavila se mogućnost koju nitko nije očekivao, umrežavanje svakodnevnih objekata poput kućanskih pomagala , automobila, kompletnih kućanstava, zgrada itd. Taj pojam nazivamo „internetom stvari“. Prema Sinkoviću (2015) “ IoT je kolekcija ili skup stvari (objekata ili uređaja) koji su dizajnirani da bi bili upravljani te da bi pružali informacije bežičnom vezom preko interneta koristeći najčešće mobilnu aplikaciju za nadzor ili upravljanje”. Iz same definicije možemo uvidjeti da “IoT” nije samo ograničen na kućanske objekte, već je namijenjen i na umrežavanje velikih sustava. Ako takvu tehnologiju primijenimo na problem, dobivamo pametno rješenje za gotovo sve postojeće probleme. Ukoliko se pak u takvu tehnologiju implementiraju neki od najnovijih trendova u svijetu tehnologije kao što su: 5G mreže, umjetna inteligencija ili deep learning tehnike, sasvim sigurno možemo pronaći rješenja i za nadolazeće prepreke.

1.1 Definicija problema

Svi veliki gradovi imaju isti problem bez obzira na kojem su dijelu svijeta locirani, a to su prometne gužve. Osim što stvaraju ogromne ekonomske gubitke kroz oportunitetni trošak vremena provedenog u gužvi, ponekad su i iznimno stresne. Rast gradova znači i sve veći broj stanovništva koje svakodnevno treba doći sa jednog mjesta na drugo, većinom radi posla. Rastom broja stanovnika razmjerno rastu i gužve, a s njima problemi, neovisno mjere li se duljinom u kilometrima ili prema vremenu provedenim za volanom. Ukoliko je industrijsko i poslovno središte također i svjetska turistička destinacija, razmjeri pogoršanja problema u prometu su ogromni, naročito u “sezonskim” mjesecima za turizam. Sve opisane karakteristike mogu se pronaći na primjeru grada Splita.

Split je ogromno turističko središte u koje se priljeva ogroman broj inozemnih turista u ljetnim mjesecima. Split je isto tako regijsko središte Splitsko-dalmatinske županije, te u Split svakodnevno migrira ogroman broj radnika i studenata iz okolnih gradova i mjesta. Uz takva

središta redovito su vezani problemi prijevoza i prometa. Svakodnevna migriranja u Split, kao i iz Splita, stvaraju ogromne gužve na svim važnijim prometnicama. Zbog sve duže turističke sezone i rasta broja radnih mjesta u Splitu, teško je izdvojiti razdoblje u godini u kojem gradnja potrebne infrastrukture ne bi uvelike ometala svakodnevne poslove i narušavala kvalitetu života ljudi. Manjak infrastrukture dovodi do sagledavanja alternativnih rješenja za opisani problem. Jedno od rješenja jest uvođenje pametnih tehnologija i implementacija istih u prometnice i promet.

1.2 Metode rada

Ovaj rad istražiti će dostupne moderne tehnologije koje se mogu implementirati u ovakav projekt. Sagledat će se već pronađena rješenja koja su u primjeni u nekim većim svjetskim gradovima. Ukazat će na probleme i greške u već uvedenoj tehnologiji koja se primjenjuje u Splitu u sklopu problema gužvi. Pomoću anketa, pokušat će se dobiti odgovor na pitanje u kojoj mjeri gužve ometaju svakodnevni život i da li je moguće implementirati ovakvu tehnologiju među stanovništvom.

1.3 Cilj rada

Cilj rada jest osmisliti sustav koji bi mogao implementirati moderne tehnologije i na taj način riješio ili bar ublažio velike prometne gužve. Takav sustav mora implementirati umjetnu inteligenciju kao glavni pokretač te osigurati sigurnost svih sudionika u prometu.

2 TRENUTNO STANJE PROMETNICA

2.1 Dosadašnja tehnologija

Internet stvari nikako nije nova tehnologija, kao što je već navedeno takvi sistemi postoje svugdje u svijetu, od kućanstava i korištenja kućanskih uređaja, olakšavanja svakodnevnih zadaća ili poboljšavanja kvalitete života općenito, do korištenja takvih sistema u velikim tvornicama zbog ubrzavanja procesa poslovanja ili razvrstavanja. Ipak, nije svaki sistem IoT-a isti. Neke vrste koriste samo korisničko upravljanje te ne rade apsolutno ništa van onoga što im korisnik naredi. Neke druge, modernije vrste imaju samostalan sustav upravljanja i odlučivanja koji se očituje kroz korištenje umjetne inteligencije.

Zbog se toga i već postojeći sustav upravljanja prometom u Splitu može nazvati internetom stvari. On se sastoji od sustava semafora koji se dijele na dva dijela: semafori za zapadni dio grada te semafori za istočni dio grada. Između njih stoji Dubrovačka ulica koja služi kao granica. Sukladno tome svjetlosna signalizacija u prometu kontrolira se pomoću dva povezana sustava. Jedan sustav nabavljen je 2000. godine, a drugi, stariji sustav nabavljen i izgrađen je davne 1979. godine. Iako je kroz posljednjih 10 godina urađeno mnogo modifikacija na samim sustavima upravljanja, same jezgre ostale su iste. Upravo to predstavlja ogroman problem za rastući promet na splitskim ulicama. Sami sustavi su nadograđeni kroz posljednjih nekoliko godina, te je tvrtka “Peek” jedna od brojnih tvrtki koja je vršila modifikacije na sustavima, koje su i naveli na svojim službenim stranicama.

Izvođenje radova preprogramiranja i nadogradnje semaforskih uređaja od raskrižja “Poljička – Zbora narodne garde” do raskrižja “Poljička – B. Bušića”:

- Izvođenje radova preprogramiranja i nadogradnje 15 semaforskih uređaja na području grada
- Projekt davanja prioriteta vatrogasnim vozilima u Splitu
- Izvođenje radova postavljanja semaforske opreme na školskom prometnom poligonu

Ovakvim modifikacijama neki problemi su riješeni, no mogu se učiniti još veći koraci prema optimizaciji stanja u prometu. Konstantne gužve u određenim razdobljima dana, mjeseca i godine ukazuju da ima mnogo nedostataka koji se trebaju ukloniti kako bi se promet u Splitu rasteretio, poboljšao i učinio sigurnijim.

2.2 Anketa: Nezadovoljstvo trenutnim stanjem prometnica

Provedena je anketa o mišljenju stanovnika o stanju na prometnicama u Splitu, te su rezultati pokazali sljedeće:

Provedena je anketa o općem zadovoljstvu ljudi sa stanjem na prometnicama i cestama u Splitu. Sadržavala je 21 pitanje te se prva polovica pitanja odnosila na trenutno stanje na prometnicama i razinom nezadovoljstva trenutnom situacijom u prometu. U drugoj se polovici ispitalo poznavanje i spremnost na prihvaćanje novih pametnih tehnologija.

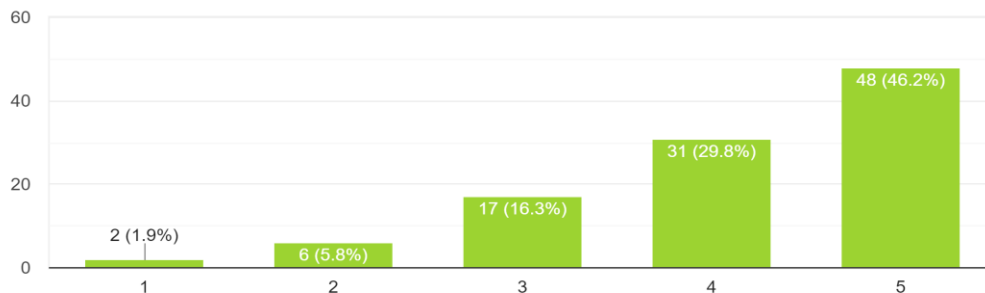
Anketa je provedena na užem području grada Splita i u Zračnoj luci Split, a sudjelovala su ukupno 104 ispitanika u razdoblju od 23.7.2019. do 1.8.2019. Ispitanici su bili podijeljeni prema njihovom načinu sudjelovanja u prometu te su se ispitanici mogli izjasniti kao: vozači osobnih automobila, vozači motocikla, vozači bicikla, pješaci i korisnici javnog prijevoza.

Više od 70% ispitanika su vozači motornih vozila; na tu skupinu prometne gužve imaju najveći utjecaj tako da je njihovo mišljenje od velikog značaja. Iako su vozači osobnih automobila i motocikla izravni sudionici u prometu, ne može se odbaciti mišljenja pješaka, biciklista i korisnika javnog prijevoza kao nerelevantna, već je nužno promatrati sve odgovore.

Rezultati ankete su pokazali da je trenutno stanje na prometnicama u Splitu iznimno ne zadovoljavajuće. Podaci govore da se više od 76% ispitanika iznimno često i često susreće sa gužvama na prometnicama (*Slika1*).

Koliko se često susrećete s gužvama na prometnicama u Splitu?

104 responses




Slika1. Grafikon o susretanju prometnih gužvi u Splitu

Izvor: Izračun autora

Najčešće se radi o gužvama u ljetnim mjesecima u kojima, osim stanovnika i svakodnevnih migranata zbog posla, u grad dolazi i ogroman broj turista. Veliki dio ispitanika smatra da je osim loših cesta i loše signalizacije prenapučenost (73,5% ispitanika) glavni uzrok problema. Grafikon po mjesecima jasno pokazuje povezanost gužvi sa turističkom sezonom (Slika2).

U kojim se mjesecima najčešće susrećete s gužvama u Splitu? (višestruki odabir)

104 responses



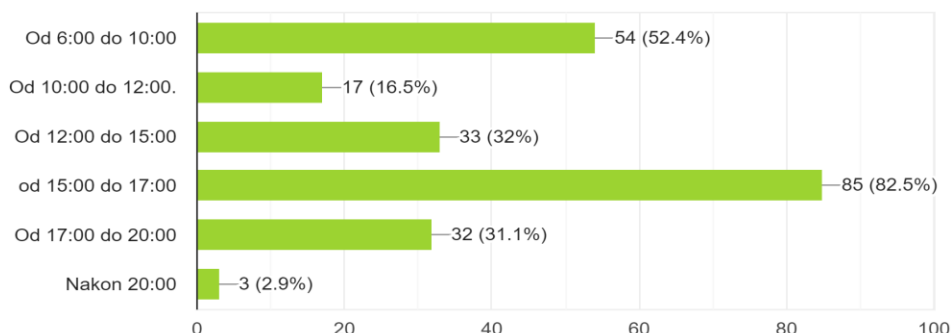
Slika2. Grafikon prometnih gužvi

Izvor: Izračun autora

Osim godišnje sezonalnosti, na temelju rezultat primjećuje se i dnevnu sezonalnost tj. određeno doba dana kada se stvaraju prometne gužve. Statističkom metodom korelacije utvrđeno je da se, ako se za vremenski period promatranja uzme jedan dan, prometne gužve uvelike povezuju s brojem ljudi koji u Split svakodnevno migriraju zbog posla, obavljanja neke djelatnosti ili obrazovanja.

U koje se vrijeme susrećete s najvećim gužvama u Splitu? (višestruki odabir)

103 responses



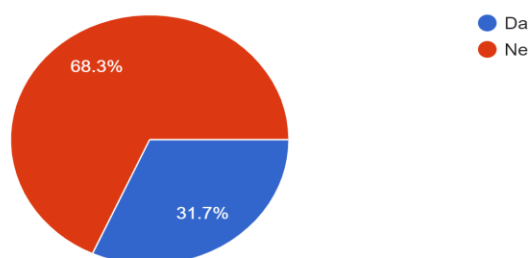
Slika3. Grafikon koji prikazuje vremenska razdoblja u kojima su prometne gužve najčešće

Izvor: Izračun autora

Zbog toga se prometne gužve javljaju najviše u razdobljima od 6 sati ujutro do 10 sati ujutro, kada se dešava priljev stanovništva prema gradu, te od 12 sati do 15 sati kada se dešava odljev stanovništva van grada (Slika3).

Jeste li upoznati s nekim od načina rješavanja prometnih gužvi u Splitu?

104 responses



Slika4. Grafikon poznavanja načina za rješavanje prometnih gužvi

Izvor: Izračun autora

Na pitanje “Da li bi se stanje u prometu moglo poboljšati?” čak je 77,7% stanovnika dalo potvrđan odgovor, ali samo je 31% stanovništva znalo navesti neki način za rješavanje prometnih gužvi.

Najčešće dani odgovori na pitanje: “Jeste li upoznati sa nekim od načina rješavanja gužvi i ako jeste navedite kojim?!” (*Slika4*) bili su “kružni tok” i “preusmjeravanje prometa”, što je postala stalna praksa u ljetnim mjesecima.

Anketa je pokazala da je velik dio stanovništva nezadovoljan trenutnim stanjem, ali očekuje promjene na bolje. Najveći problemi javljaju se na glavnim prometnicama grada Splita: Vukovarskoj, Poljičkoj i Ulici Domovinskog rata, kao i samom centru grada. Na osnovi rezultata može se zaključiti da bi sam sustav trebao najviše infrastrukture upravo na tim dijelovima.

Drugi dio ankete odnosi se na mišljenje i znanje o modernim tehnologijama za rješavanje prometnih gužvi te je odrađen sa istim ispitanicima. Rezultati tog dijela ankete biti će objašnjeni i obrađeni u drugom dijelu rada koji je direktno vezan na rezultate.

2.3 Postojeća rješenja

U svijetu postoje različite ideje o rješavanju problema gužvi, od kojih su neke već u širokoj primjeni. Koncept skraćivanja vremena čekanja na semaforu nastao je kada i prva gužva uzrokovana unaprijed programiranim signalima. Bili su programirani da na određeno vrijeme drže određeno svjetlo bez ikakvog kontakta sa vanjskim svijetom. Napretkom tehnologije omogućeno je detaljnije programiranje semafora na nekoliko vremenskih zona. Jedna takva tehnologija se još uvijek koristi u Splitu, te su Splitski semafori programirani na četiri vremenske zone: jutarnja, poslijepodnevna, večernja i noćna zona. Uz programiranje na vremenske zone, sve češće su se koristile i zavojnice koje su elektromagnetskim poljem otkrivale postojanje automobila na semaforu. Za sam promet to je bilo jedno od najvećih otkrića, jer se na taj način semafor samostalno regulirao ovisno o tome postoji li automobil koji čeka zeleno svjetlo.

Korak u pravom smjeru napravljen je u Njemačkom gradu Darmstadtu koji već nekoliko godina koristi moderan sustav kontroliranja semafora. Grad relativno blizu Frankfurta upada u glavnu industrijsku zonu oko rijeke Rajne. Poput ostalih gusto napučenih gradova i ovaj grad se bori sa konstantnim gužvama. Gradske vlasti odlučile su stati na kraj kilometarskim kolonama te su unajmile tvrtku “FLIR” za pronalaženje optimalnog rješenja. Problemu je tvrtka pristupila koristeći moderne infracrvene kamere. Zaobišli su kompletan dosadašnji sustav sa ugrađenim zavojnicama i radarima, te se cijeli sustav, nazvan FLUX (*Slika5*), oslanja samo i isključivo na videokamere. Takav je sustav olakšao postavljanje i gradnju infrastrukture jer se kamera može jednostavno postaviti na svaki postojeći semafor, a sustav se spaja na već izgrađenu infrastrukturu. Uz

programsku podršku koja može raspoznati pješake i bicikliste, unaprijed se osigurava maksimalna sigurnost za sve sudionike u prometu zbog toga što smanjuje trajanje i veličinu prometnih gužvi. Za ovaj rad kod ovog sustava najvažnija i najzanimljivija stvar je ta što se sve obavlja automatski. Uz pomoć kamera i “zona detekcije” detektira se gužva za vrijeme njenog nastanka, te automatski pali, gasi ili mijenja trajanje svjetala prometne signalizacije.

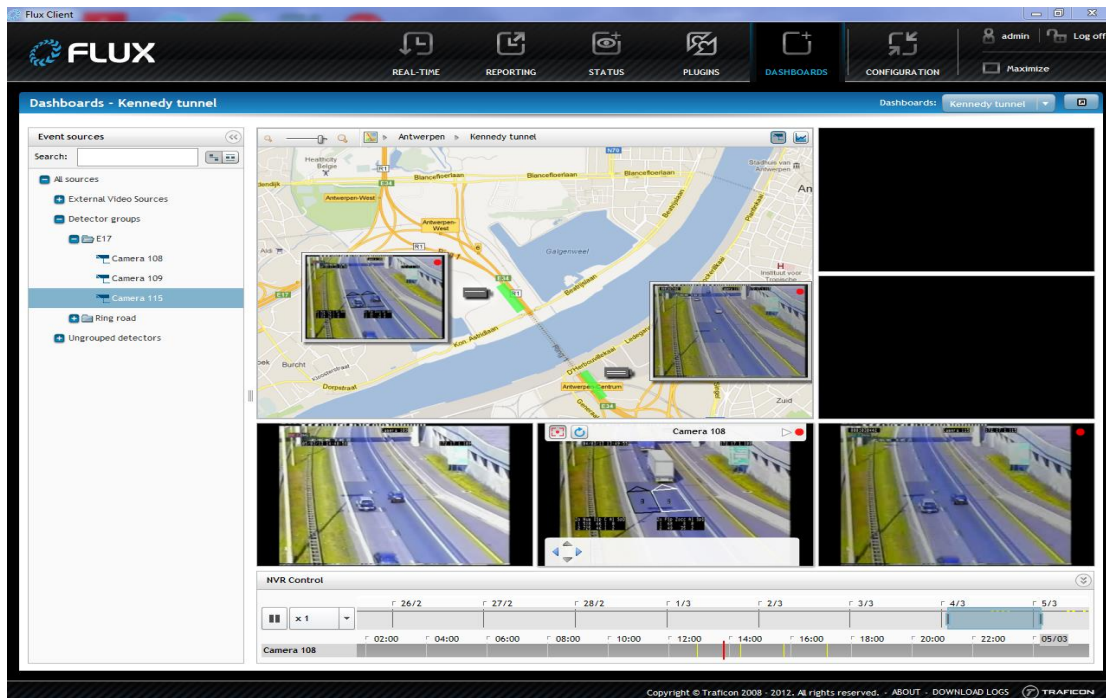


Slika5. Računalni vid sustava FLUX u Darmstadtu

Izvor: Flir.com (<https://www.flir.com/discover/traffic/roads-tunnels/smart-traffic-management-in-the-city-of-darmstadt/>)

Ovisno o veličini zone detekcije, sustav čak može raspoznati veličinu automobila te odrediti vrijeme potrebno vozilu da prođe kroz prometno raskrižje. Uz to, očitava pješake i bicikliste ,te pronalazi najbolji trenutak za siguran prijelaz preko pješačkog prijelaza, ovisno o količini automobila na cesti (Slika6). Na taj način smanjuje se vrijeme čekanja, a istovremeno povećava sigurnost na prometnicama. Ono što u implementaciji nedostaje jest umjetna inteligencija te sustav učenja. Ovakav sustav reagira samo na trenutačnu, postojeću situaciju, bez mogućnosti predviđanja ili bilo kakvog dugoročnog organiziranja. Ne može predvidjeti prometnu gužvu u budućnosti, već samo reagira na već postojeću gužvu. Za bilo kakvo “inteligentno” upravljanje sustavom zadužen je čovjek, trebala bi jedna ili više osoba koje bi manualnim upravljanjem kontrolirale prometnu gužvu. Zbog toga su ograničene situacije u kojima takav način upravljanja prometom možemo nazvati odličnim. Najveći problem jest mogućnost ljudske pogreške, u slučaju da čovjek koji

kontrolira sustav previdi neku situaciju, ili pak zaboravi kontrolirati najvažnija raskrižja. Pogreške nastale previđanjem ili zaboravom bile bi apsolutno nemoguće u sustavu sa umjetnom inteligencijom.



Slika6. Sustav FLUX

Izvor: Flir.com (<https://www.flir.com/discover/traffic/roads-tunnels/smart-traffic-management-in-the-city-of-darmstadt/>)

Sustav koji je dosta sličan sustavu zamišljenom u Splitu je sustav City Brain koji je implementiran u gradu Hangzhou, u Kini. Sustav City Brain razvija kompanija “Alibaba Cloud”. Taj je sustav započeo sa prometom i reguliranjem samog prometa te je implementiran u gotovo 1400 semafora na svim važnijim raskrižjima u gradu. Uz korištenje kamera i senzora, u sustav se bilježe i podatci iz mobilnih telefona ljudi koji se kreću tim gradom, kao i slike satelita. Upravo zbog načina prikupljanja podataka prema kojima funkcionira mnogo je kompleksniji od bilo kakvog sustava dosad osmišljenog. Svi su uređaji na neki način povezani na internet te koriste Cloud Computing za funkcioniranje. Podaci se šalju u oblak razvijen od kompanije Alibaba gdje se obrađuju, nakon čega oblak uređajima vraća povratne informacije i upute za funkcioniranje. Svi uređaji komuniciraju putem direktne veze s glavnim računalom te direktno dobivaju povratne informacije


što ovaj sustav čini puno složenijim od zamišljenog sustava koji bi se primijenio u gradu Splitu. Korištenje ovakvog sustava se nije ograničilo samo na promet u Hangzhou, već se širi i na ostalu infrastrukturu. Grad će ubrzo u potpunosti funkcionirati uz pomoć Oblaka, od opskrbe električnom energijom i vodom, do škola i državnih ustanova. Postavlja se pitanje: što bi se dogodilo s ovim sustavom ukoliko se oblak ugasi?

Korištenjem tehnologije Interneta stvari u Splitu želimo kreirati sustav koji preuzima pojedine osobine iz oba navedena sustava: CityBrain u Kini i Flux u Njemačkoj. Cilj je upotrebom centralnog računala povezati kompletan grad i učiniti ga jednim internetskim entitetom, a uz pomoć umjetne inteligencije i Cloud Computinga riješiti gužve u gradu. Primjenom pametnih raskrižja kao u Darmstadtu ona bi samostalno funkcionirala uz pomoć kamera i senzora na samim raskrižjima.

3 OSMIŠLJAVANJE I OPISIVANJE SUSTAVA

Prateći primjer iz Huangzhoa cilj je razviti inteligentni sustav koji bi riješio probleme gužvi u gradu Splitu. Takav bi sustav koristio moderne tehnologije i umjetnu inteligenciju da bi olakšao kretanje prometa, optimizirao čekanja i zastoje te preusmjerio sve sudionike u prometu koje je moguće preusmjeriti. Sustav bi se trebao sastojati od nekoliko glavnih dijelova, a svaki bi od dijelova trebao imati svoje komponente.

Glavni sustav sastojao bi se od centralnog, glavnog računala koje je mozak cijelog sustava. Takvo računalo obavlja većinu posla i koordinira svim ostalim manjim računalima na raskrižjima. Glavno računalo je povezano s računalima na raskrižjima putem visokofrekvencijskih kanala, te od raskrižja dobiva informacije u obliku video prijenosa. Uz pomoć računalnog vida i umjetne inteligencije prepoznaje situaciju na samoj prometnici. Računalo koristi senzore i kamere postavljene na svim semaforima u raskrižju, kao i podatke dobivene od korisnika sustava. Pomoću pribavljenih podataka pronašlo bi najbolje rješenje za bolju protočnost prometnica, bilo da se radi o mijenjanju trajanja signalnih tijela na raskrižjima ili preusmjeravanju dijela sudionika prometa na alternativne rute.



Slika7. Slika osmišljenog sustava

Izvor: Prikaz autora

Osim centralnog računala, ovakav sustav mora imati i senzorno-upravljačke kutije na svim važnijim raskrižjima. Takve kutije funkcionirale bi kao mali zasebni sustavi s ugrađenom automatskom kontrolom raskrižja. Svi bi se principi i pravila primjenjivala kao i u cjelokupnom sustavu, no na manjoj skali, skali jednog raskrižja (*Slika7*).

Upravljačka kutija upravlja raskrižjem, točnije svim semaforima na raskrižju. To radi uz pomoć algoritama ugrađenih u sustav, te može samostalno prepoznavati stanje prometa, i sukladno danim smjericama kontrolirati semafore na samom raskrižju. Takvo samostalno funkcioniranje raskrižja mora biti omogućeno zbog sigurnosti prometnica. Postavlja se pitanje, što bi se dogodilo kada bi glavno računalo, koje je mozak cijelog sustava, iz nekog razloga prestalo funkcionirati. Cjelokupni grad bi ostao u prometnom kolapsu. Zbog toga treba postojati pričuvni sustav koji imitira ponašanje sustava Flux iz Darmstadta.

Senzorno upravljačke jedinice bit će povezane s glavnim računalom kojem će moći slati sve važne informacije, kao i primati upute od glavnog računala. One bi imale ogromnu korist od korištenja 5G mreža, zbog iznimne količine i učestalosti informacija koje kruže sustavom. Postavljanje kamera na raskrižja, kao i na prometnice u neposrednoj blizini, bilo bi ključno. Uz pomoć računalnog vida mogla bi se utvrditi količina automobila koja se trenutno kreće prometnicom te o tome obavijestiti centralno računalo koje bi na temelju svih zaprimljenih podataka imalo sliku tijeka i kretanja prometa na velikoj skali cijeloga grada.

Još jedna važna komponenta kod ovakvog sustava bili bi zaslone. Zaslone postavljen uz semafor pružao bi informacije vozačima o stanju u prometu na prometnicama u čiji se promet uključuju. Najvažnija zadaća zaslona bilo bi preusmjerenje prometa na druge prometnice na kojima je gužva manja. To je razlog zbog kojeg bi zaslone bili postavljeni neposredno prije samog problematičnog raskrižja, ili bi pak prikazivali upute za preusmjerenje na sljedećem raskrižju, ovisno o važnosti prometnice.

3.1 Glavno računalo

Prema Kordiću (2019) “Glavno ili Središnje računalo, popularno zvano “mainframe” je računalo posebnih mogućnosti, a koriste ga veliki pravni subjekti, ponajviše velike organizacije. Najčešće su to zrakoplovne tvrtke, visokoznanstvene ustanove, porezne i ine financijske ustanove i slično. Zadaća im je izvršavati vrlo zahtjevne i složene obrade podataka. Za razliku od običnih računala,

središnja računala rade cjelodnevno, ne prekidajući nikad svoj rad, svakog dana, bez obzira na praznike i neradne dane.”

Zadaća središnjeg računala u ovakvoj primjeni je malo drugačija, ali su i dalje potrebne glavne karakteristike takvog računala: izvršavanje složenih i zahtjevnih obrada podataka bez prekidanja svog rada i u što kraćem vremenu.

Mainframe računalo koje bi se koristilo u zamišljenoj tehnologiji treba imati i umjetnu inteligenciju, koja je preduvjet za “pametno” rješavanje problema. Umjetna inteligencija (UI) jest sposobnost digitalnog računala ili računalno-kontroliranog robota da izvodi zadaće obično povezane uz inteligentna bića.

Umjetna inteligencija iz godine u godinu napreduje na svim područjima, od zdravstvene skrbi do korištenja u poljoprivredi, no jako se malo koristi u prometu. U ovoj primjeni umjetna inteligencija ima iznimne predispozicije da bude ključna za rješavanje kompliciranog problema. Cilj umjetne inteligencije je stvoriti sisteme koji mogu funkcionirati samostalno i stabilno te na taj način kopirati ljudski mozak i ponašanje. Ljudi mogu pričati i prepoznavati govor, umjetna inteligencija se uz pomoć statističkog učenja trenira za raspoznavanje govora. Ljudi mogu vidjeti objekte i slike oko sebe, računalo se pokušava naučiti da mogu vidjeti i raspoznavati svijet oko sebe. Ovo područje u umjetnoj inteligenciji zove se računalni vid. Za umjetnu inteligenciju posebno je bitno strojno učenje. Računala su iznimno dobra u prepoznavanju uzoraka zbog mogućnosti obrade velike količine podataka. Umjetna inteligencija i strojno učenje bazira se na prepoznavanju uzorka u dobivenim podacima. Napredak u ovoj znanosti dogodio se u proteklom desetljeću i otvorio mogućnosti primjene umjetne inteligencije u sve većem broju djelatnosti i sfera ljudskog života. Razvojem neuronskih mreža koje kopiraju rad ljudskog mozga, došlo je do razvoja dubokog učenja, učenja pomoću algoritama. Takvo učenje drastično je poboljšalo računalni vid kao i shvaćanje uzoraka i stvaranje odluka na temelju uzorka, pa sada računala mogu sa lakoćom raspoznavati objekte, razlikovati slične objekte i razumjeti slijed kretanja objekata. Deep learning tehnike pomogle su računalima da predviđaju budućnost i shvaćaju prošlost uz ogromne količine sigurnosti. Problem kod dubokog učenja je ogromna količina podataka koju računala moraju obraditi da bi učila. Ukoliko računalo nema dovoljnu količinu podataka za obradu, deep learning tehnike nisu primjenjive i krajnje su nesigurne.

Kod zamišljenog sustava za rješavanje prometnih gužvi, duboko učenje je iznimno važno. Ljudi se već godinama trude prepoznati uzroke iznenadnih gužvi i nepravilnosti u kretanju prometa.

Računalo s konvolucijskim mrežama i dubokim učenjem sposobno je razmišljati dublje i nepravilnije od bilo kojeg ljudskog mozga te zbog toga sa lakoćom otkriva uzorke u ponovljenim slučajevima. Ti uzorci su najbitniji za učenje glavnog računala i pretpostavkama o kretanju prometa u budućnosti.

Korištenje umjetne inteligencije za ovu tehnologiju očitovao bi se i u korištenju računalnog vida za interakciju računala sa stvarnim svijetom. Računalni vid je područje koje obuhvaća metode za stjecanje, obrade, analiziranja i razumijevanja slike i, općenito, višedimenzionalnih podataka iz realnog svijeta u cilju dobivanja numeričkih ili simboličkih informacija. Računalo ima specifičan način gledanja i prepoznavanja koji se sa odmakom tehnologije također poboljšava. Računalni vid je nekad bio isključivo ograničen na već unesene podatke i korištenje "kernela" za raspoznavanje razlika između piksela. Na taj način računalni vid je mogao raspoznavati jednostavne stvari. Strojnim učenjem i poboljšanjem algoritama računalni vid se razvijao sve više, pogotovo kada je pokrenut projekt Google Cloud koji je poslužio kao ogromna baza podataka za strojno učenje i pružanje gotovih rješenja. Posebno se počeo razvijati kada su se razvile neuronske mreže i koncept dubokog učenja. Takvo učenje ne obuhvaća zadane jednadžbe po kojima računalo mora prepoznavati, ono daje računalu mogućnost stvaranja vlastitih jednadžbi i učenja uz pomoć samostalnog rada.

Opisana umjetna inteligencija i računalni vid računalu, koje bi se koristilo u ovom sustavu, daju mogućnost gledanja i razumijevanja svega što se događa na prometnicama. Računalni vid prepoznaje sve sudionike u prometu i smjer njihovog kretanja na uskom području. Glavno računalo zaprima sve informacije te na temelju dobivenih informacija radi procjene o prometnosti. Samom bi se računalu zadale zone detekcije i prepoznavanja. Postavljena kamera na raskrižju uz pomoć tehnologije računalnog vida prepoznaje stanje istog, uči o prednosti prolaska i sudionicima u prometu te zaprima informacije iz zona detekcije. Zone detekcije su kvadranti u videokrugu kamere u kojima se kreću sudionici u prometu. Prepoznavanje automobila, kao i njihovog broja, te raspoznavanje biciklista, motorista i pješaka omogućuje glavnom računalu da razumije što se događa na samom raskrižju i poveže to sa saznanjima s okolnih raskrižja. Ukoliko glavno računalo vidi zastoj i mnoštvo automobila koji čekaju na raskrižju, propustit će te automobile prve kroz raskrižje. Isto će napraviti i s propuštanjem pješaka, ako i samo ako je ta odluka sigurna te nije u sukobu sa osnovnim pravilima po kojima promet funkcionira. Svaka situacija se bilježi kako bi računalo učilo i u budućnosti korigiralo svoje ponašanje u cilju smanjivanja prometnih gužvi.

Zahvaljujući velikoj mreži uparenih raskrižja i mogućnosti spajanja na mobilne telefone sudionika u prometu, ukoliko je dano odobrenje, bogat izvor informacija je dodijeljen glavnom računalu. Sve te informacije ulaze u izračun reguliranja prometa u Splitu. Na taj način glavno računalo zna na kojim je raskrižjima najveća gužva, a uz pomoć prijašnjeg iskustva i umjetne inteligencije može pretpostaviti daljnju putanju određenog postotka automobila. Sukladno toj putanji može promijeniti trajanje zelenog ili crvenog svjetla na sljedećem raskrižju.

Glavno računalo treba imati sezonsku i dnevnu komponentu. Umjetna inteligencija trebala bi se pobrinuti za to da računalo pretpostavlja da će u određeno doba dana postojati velika kretanja prometa prema Splitu i van Splita. Najgore prometne gužve se javljaju rano ujutro u vrijeme kada ljudi idu na posao i rano popodne kada se ljudi vraćaju sa posla. Takva dnevna ciklička komponenta u prometu mora biti pretpostavljena i naučena od strane računala kako bi samo računalo moglo organizirati promet s najvećim mogućim protokom u tim razdobljima dana. Rasterećenje prometnica i dobra organizacija potrebna je i ljeti, u mjesecima kada u grad dolazi mnogo turista. Zbog toga sezonska komponenta također je iznimno važna za funkcioniranje sustava. Iako bi takve stvari glavno računalo moglo naučiti samo kroz određeno razdoblje, za učenje umjetnom inteligencijom potrebno je određeno vrijeme pa je bolja opcija da se komponente u sistem unesu ručno kao pretpostavke. Naknadno korigiranje bilo bi moguće, i to od strane računala koje je dobilo nova saznanja preko vremena. Na taj način izbjegle bi se gužve u trenucima kada se računalo tek prvi put sretne s opisanom situacijom.

Iznimno je važno i da računalo zna planirane rute vozila u prometu. U slučaju da je glavnom računalu takva informacija dostupna ono može preusmjeriti dio prometa na prometnice koje nisu blokirane automobilima te na taj način rasteretiti glavne prometnice. Nažalost, jako je teško pretpostaviti krajnje odredište određenog vozila. Moguće je dati zadatak glavnom računalu da pamti registarske oznake sudionika u prometu, kao i uobičajene rute i destinacije kojima se ta vozila kreću. No, takvo praćenje ulazi duboko u privatnost ljudi i narušava je. Zbog toga se ostavlja mogućnost praćenja prometa satelitom ili povezivanje sudionika u prometu sa glavnim računalom. Optimalno rješenje bilo bi voljno povezivanje sudionika u prometu putem mobilnih telefona. Ukoliko se korisnicima ostavi mogućnost preuzimanja aplikacije povezane na sustav, rezultati samog sustava bit će još bolji.

Aplikacija bi bila napravljena tako da bi glavnom računalu slala informacije o lokaciji korisnika, vremenu provedenom u putu i korisnikovoj destinaciji. Na taj način sustav može za svakog

korisnika odrediti određenu rutu na kojoj je najmanji promet i putem koje će na svoju destinaciju doći najbržim mogućim putem. Sve informacije o prometu, gužvama i problemima na cesti, mogle bi biti slane direktno na korisnikov mobilni uređaj te prikazane u obliku interaktivne karte s naznačenim gužvama, kao i označenim rutama za preusmjeravanje.

3.2 Povezivanje sustava

Za funkcioniranje mainframe računala potrebna je iznimna količina podataka i njihova obrada u što kraćem vremenu. Samo prijenos video slike sa kamera na normalnoj rezoluciji od 480p može potrošiti i do 560 megabajta podataka po satu, dok se za neke veće definicije i bolje rezolucije videa, koje bi bile potrebne za opisani sustav, može koristiti i do više gigabajta prometa po satu. Svako raskrižje ima nekoliko kamera te bi svaka od tih kamera morala prenositi sliku glavnom računalu. Dosadašnja tehnologija ne omogućava nesmetan prijenos tolike količine podataka bez iznimnih financijskih i infrastrukturnih ulaganja u žičane mreže. Zbog toga se pomoć treba tražiti u novim tehnologijama prijenosa podataka: 5G mrežama. 5G mreže su relativno nov i nepoznat pojam čije je razumijevanje olakšao Krešimir Blažev u svom članku (2019): “Terminom 5G označava se peta generacija mobilnih telekomunikacijskih mreža s pripadajućom infrastrukturom i uređajima. Glavne karakteristike su im novi skok u brzinama prijenosa podataka i mogućnost većeg broja povezanih uređaja. Vremenom bi se mreže trebale dodatno razvijati i povećati brzine, a ponuda podržanih uređaja će se proširiti i na niže cjenovne razrede, a možda i na širi spektar uređaja.”

5G mreže ne funkcioniraju na način kao dosadašnje mobilne mreže. Takve mreže oslanjaju se na tehnologiju milimetarskih valova i nano-prekidača kao i mogućnost stvaranja signala usmjerenog prema korisniku. Takva tehnologija omogućuje korištenje visokih frekvencija za prijenos podataka. Do sada su se za prijenos podataka koristile mobilne mreže četvrte generacije koje su radile na frekvencijama do 2.4 gigaherca. Takve mreže su pratile razvoj tehnologije i bile su dostatne za sve potrebe dosadašnjeg stanovništva. 5G mreže se stvaraju za upotrebu u budućim tehnologijama i omogućuju spajanje mnoštva uređaja na istu mrežu kao i veće brzine prijenosa podataka. Zbog svog rada na frekvencijama od 2.5 gigaherca sve do 95 gigaherca pružaju mogućnosti prijenosa i do 10 gigabajta u sekundi. No veliki nedostatak 5G mreže je definitivno domet. Visokofrekvencijska mreža ne može putovati tako daleko kao obična 4G mreža niti može prodirati kroz građevine, zbog čega je takvoj mreži potrebno mnogo više infrastrukture da bi

funkcionirala. Mikro ćelije i mikro odašiljači su dio infrastrukture koji će odigrati važnu ulogu i u razvoju 5G mreže i u razvoju projekta pametnog prometa.

Mikro ćelije služe kao dvosmjerne antene koje u isto vrijeme mogu primiti i slati 5G signal. Služe kao mali ruteri koji ponavljaju 5G signal i postavljeni su na više lokacija na kraćoj udaljenosti. Ovakve antene koriste tehnologiju nanoprekidača uz pomoć kojih na istoj frekvenciji može nesmetano funkcionirati velika količina 5G uređaja, kao i tehnologiju usmjerenog signala uz pomoć koje svi uređaji u prometu dobivaju zraku signala izravno od odašiljača. Na taj način rješava se problem dometa i sukoba signala te se dobiva iznimno dobar, čvrst i brz prijenos podataka.

5G tehnologija idealna je u ovoj primjeni jer bi brzina prijenosa podataka prema računalu i obrnuto bila čak i veća od potrebne. Mreža je dovoljno brza i jaka da pokrije sva važnija raskrižja u Splitu i da može prenositi video prijenos nekoliko kamera sa svakog raskrižja. Brzina prijenosa slike je iznimno velika te je na taj način bilo kakva latencija dovedena gotovo na nulu. Informacije s raskrižja i prometnica šalju se glavnom računalu u stvarnom vremenu te bi upute bile poslane natrag raskrižju. Ovakva tehnologija ostavlja malo mjesta za zamjenu drugim tehnologijama. Također, postavljanje antena na prometnicama u Splitu omogućuje razvijanje infrastrukture potrebne za široku primjenu ove tehnologije u komercijalne svrhe. Na taj se način ostavlja mogućnost sufinanciranja izgradnje infrastrukture od strane vodećih telekomunikacijskih tvrtki u Hrvatskoj.

3.3 Raskrižja

Zadnji dio samoga sustava koji bi činio cjelinu upravo su raskrižja. “Raskrižja se mogu opisati kao točke u cestovnoj mreži u kojima se povezuju dvije ili više cesta, a prometni tokovi se spajaju, razdvajaju, križaju ili prepliću.” Legac (2008). Raskrižja su mjesta od iznimne važnosti, što govori i definicija samog raskrižja, a također su i mjesta na kojima se stvaraju prometne gužve i prometni čepovi. Regulacija prometa na raskrižjima se obavlja uz pomoć prometnih znakova kao i uz pomoć prometne signalizacije. Takva regulacija važna je za sigurnost, ali je često spora i nije optimizirana zbog čega se stvaraju prometne gužve i kolapsi. Godinama se težilo optimiziranju i stvaranju što boljeg sustava na raskrižjima da bi se gužve smanjile, ali zbog stalne promjenjivosti i oscilacija u prometu, takav je sustav gotovo nemoguće napraviti. Zbog toga se u ovom radu pristupa stvaranju adaptivnog i samostalnog sustava koji bi sam sebe kontrolirao i unapređivao s vremenom.

Iako je glavno računalo mozak cijelog sustava, raskrižja su mjesta gdje bi sustav trebao doprinijeti i stvoriti razliku, te se njima treba posebno posvetiti u ovom radu, oni su od najveće važnosti. Zbog nemogućnosti izgradnje infrastrukture u smislu samih prometnica zbog već navedenih razloga u uvodu, sva oprema na raskrižjima mora biti nadograđena i jednostavna za postavljanje. Raskrižja u ovom sustavu moraju biti opremljena mnoštvom tehnologije. Počevši od samih kamera koje služe kao oči sustava. Kamere su uređaji koji bilježe i prenose sliku iz stvarnog svijeta. WEB kamere prenose sliku u stvarnom vremenu te bi kamere na raskrižjima trebale biti web kamere. Trebale bi to biti kamere visoke rezolucije za što bolje raspoznavanje koje koristi računalni vid i zbog mogućnosti noćnog snimanja. Svako raskrižje treba biti opremljeno s nekoliko web kamera koje su usmjerene u nekoliko pravaca. Osim kamera moraju postojati i senzori pokreta te brojači prometnih vozila radi mjerenja efikasnosti rada sustava. Raskrižja moraju biti opremljena zaslonima na kojima bi se svim vozačima davale upute i obavijesti, pa bi po jedan zaslon morao biti usmjeren na sve dijelove. Zaslon kao dio signalizacije mora pratiti sve uvjete dosadašnje prakse u prometu, mora biti vidljiv i osvijetljen te davati točne i jasne upute. Glavna svrha ovakvog zaslona bilo bi preusmjeravanje prometa na druge rute koje vode na isto mjesto.

3.4 Senzorno upravljačke jedinice

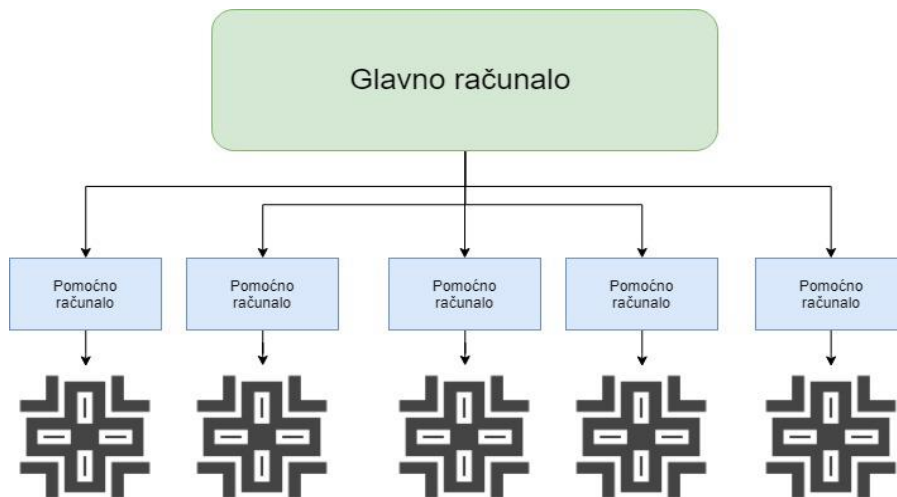
Zadnja stavka na raskrižju bila bi senzorno upravljačka jedinica koja bi služila kao pomoćno računalo. Zadaća takve jedinice je da bude računalo pridruženo raskrižju. Pomoćno računalo je računalo koje preuzima informacije sa svih navedenih uređaja na raskrižju. Kamera šalje videosliku prema pomoćnom računalu, a potom i prema glavnom računalu. Senzori pokreta šalju informacije pomoćnom računalu o postojanju pješaka na pješačkim prijelazima, a brojači prometa pokazuju pomoćnom računalu koliko je vozila prošlo kroz raskrižje. Senzorno upravljačka jedinica također upravlja svim ekranima na raskrižju i preusmjerava promet. Pomoćno računalo je u ovakvom sustavu poveznica svakog pojedinačnog raskrižja sa centralnim računalom. SUJ isto tako mora biti opremljen 5G antenom i odašiljačem da bi mogao nesmetano komunicirati s glavnim računalom, ali također može poslužiti i kao odašiljač 5G signala za komercijalnu upotrebu stanovništvu.

Osim komunikacijskog i upravljačkog centra za raskrižja, pomoćno računalo ima još jednu iznimno važnu ulogu kod ovakvog sustava. Mora biti pričuvni sustav u slučaju kvara glavnog računala. Taj sustav bi funkcionirao prema FLUX sustavu iz Darmstadta. Svako zasebno raskrižje bilo bi kontrolirano videonadzorom. Dosad su raskrižja u Splitu bila kontrolirana sensorima i

indukcijskim pločama koje bi očitale prisutnost automobila na raskrižju. Takvi sustavi ne pružaju puno informacija, a zahtijevaju mnogo održavanja. Uz navedeno, nemaju nikakvu podršku za očitavanje pješaka, osim ako pješak sam ne odluči pritisnuti tipku za prijelaz preko pješačkog prijelaza. Drugi problem kod ovakvih sustava je taj što su potrebni radovi da bi se takve sustave uopće implementiralo. Sustav koji se razvija bio bi jednostavan, automatiziran i lak za ugradnju na već postojeća raskrižja. Kao što je opisano, raskrižje bi se kontroliralo korištenjem kamera i senzora za pješake što se može lako ugraditi na već postojeću infrastrukturu bez ikakvih posebnih radova. Kod pričuvnog sustava koriste se iste te kamere i senzori postavljeni za cijeli sustav, na razini jednog raskrižja kojeg kontrolira pomoćno računalo. Očitavanje pješaka i vozila je neometano, a trajanje zelenih i crvenih svjetala prilagođava se da bi smanjilo gužvu i omogućilo siguran i slobodan promet na raskrižju. Pomoćno računalo optimizirat će vrijeme čekanja svih mogućih strana raskrižja te osigurati neometan prolazak koliko god bude moguće. Većina sporednih raskrižja u Splitu mogla bi funkcionirati samo uz pomoć ovakve optimizacije raskrižja. Nažalost, kontroliranje raskrižja na ovaj način ne omogućava sinkronizaciju s ostalim raskrižjima. Takva sinkronizacija je ključna za ovakav sustav te je u punom sustavu obavlja glavno računalo. Pomoćni sustav bi zbog toga mogao privremeno kontrolirati gužve, no dugoročno glavno bi računalo igralo najveću ulogu u rješavanju gužvi. Pomoćni sustav radi na razini jednog raskrižja, cijeli sustav optimizira promet na razini kompletnog grada.

3.5 Funkcioniranje sustava

Sustav se oslanja na sinkroniziranje i kontroliranje semafora radi smanjenja gužvi, kao i preusmjerenje prometa na manje zakrčene prometnice. Cijeli sustav je hijerarhijski raspoređen, a na samom vrhu sustava jest glavno računalo koje kontrolira pomoćna računala (*Slika 8*). Pomoćna računala potom kontroliraju same semafore i šalju feedback glavnom računalu.

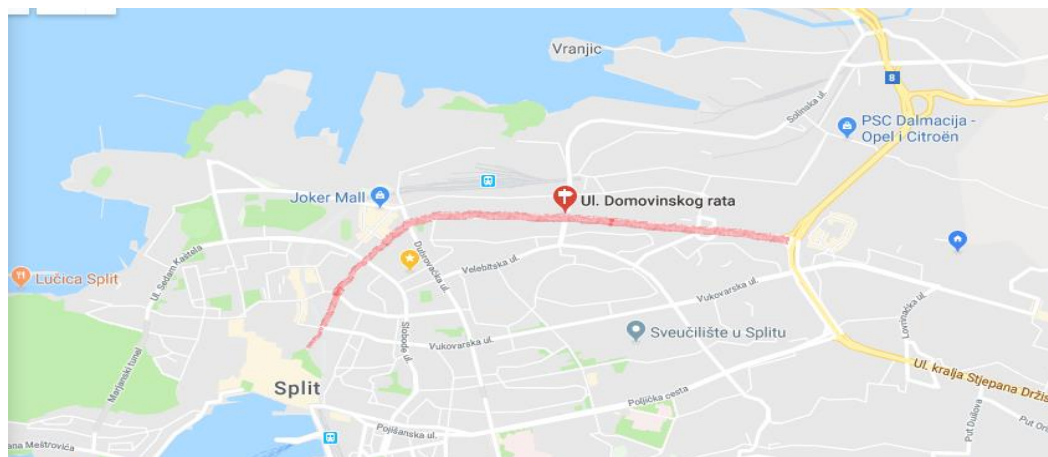


Slika8. Hijerarhija upravljanja

Izvor: Prikaz autora

Svrha primjera funkcioniranja sustava jest opisati kako bi funkcionirao sustav na jednoj od najvećih i najprometnijih prometnica u gradu Splitu, Ulici Domovinskog rata (Slika9).

Ulica Domovinskog rata je, uz Poljičku ulicu i Vukovarsku ulicu, jedna od tri žile kućavice cestovnog prometa u Splitu. Ta je ulica također prvi ulaz u Split iz smjera Solina te se na toj ulici uvijek javljaju najveće prometne gužve. Osim toga, isprepletana je s iznimno mnogo raskrižja kojima se mogu napraviti veliki napreci u smislu smanjenja gužvi.



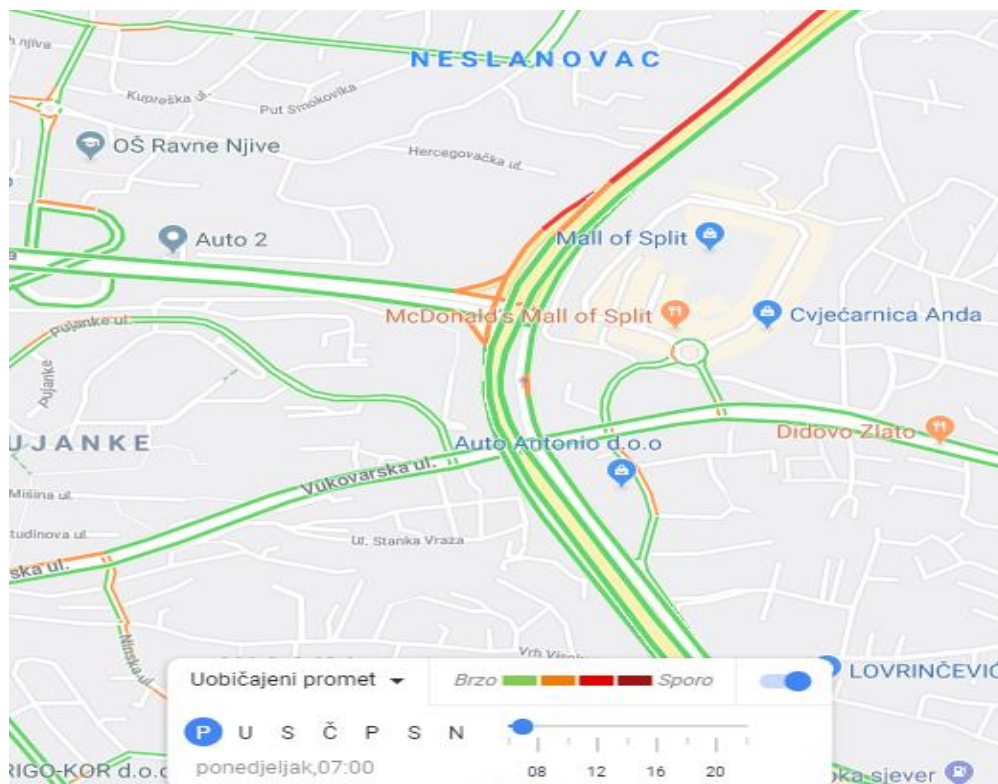
Slika9. Prikaz Ulice Domovinskog rata

Izvor: Google Maps

Najveća raskrižja na toj ulici nalaze se na križanjima sa ulicama ;Ul. Zbora narodne garde, Solinska ul., Dubrovačka ul. ,Ul. Stinice, Ul. Hrvatske mornarice, Ul. Slobode. Mažuranićevo šetalište, Ul. Ivana Gundulića, Vukovarska ul. Bihaćka ul.

Na tim raskrižjima bili bi postavljeni opisani dijelovi sustava. Web video kamere visoke rezolucije, senzori za pješake, obavijesni displeji i pomoćna računala opremljena 5G odašiljačem i antenom za komunikaciju sa glavnim računalom. Glavno računalo, koje je mozak cijelog sustava, trebalo bi biti smješteno na sredini samog sustava. Jedna od mogućih lokacija jest Sveučilišni kampus zbog geografske lokacije i lake pristupačnosti. Sam sveučilišni kampus je svojevrstan geografski centar grada. Takva lokacija definitivno pogoduje sustavu zbog korištenja 5G mreže koja je osjetljiva na fizičke prepreke i nema velik domet signala.

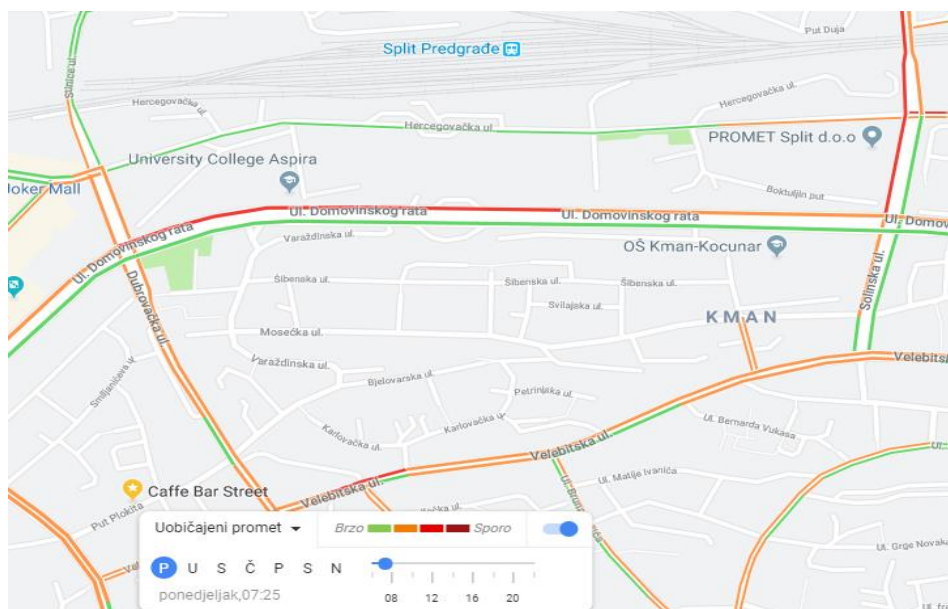
Sustav je vremenski svjestan te u rano jutro sustav pretpostavlja veliki priljev vozila u smjeru centra grada i općenito prema gradu Splitu. Zbog toga sustav pokušava otvoriti ulaz u grad (Slika10), križanje s Ulicom Zbora narodne garde što je duže moguće.



Slika10. Prikaz gustoće prometa na ulazu u Split

Izvor: Google Maps/traffic

Na taj način smanjuje gužvu na toj ulici pod cijenu većeg čekanja na izlazak iz Splita. Svi umreženi korisnici sustava koji su sustavu prenijeli informaciju o svojoj ciljanoj destinaciji, ukoliko je to moguće, na križanju će biti preusmjereni na druge prometnice na kojima je gužva manja. Promet bi trebao teći neometano sve do križanja sa Solinskom ulicom gdje se redovito ponovno javljaju kraći prometni čepovi i gužve. Sustav na ovom raskrižju preusmjerava sve koji mogu biti preusmjereni te pomoću kamera očitava broj automobila na Solinskoj ulici kao i na Ulici Domovinskog rata. Dodatno, računalo zna koliko automobila dolazi s drugih raskrižja na Domovinskoj ulici te sukladno tomu priprema raskrižje za prolazak (Slika11).



Slika11. Prikaz gustoće prometa

Izvor: Google Maps/traffic

Ukoliko se veliki broj automobila nalazi na Ulici Domovinskog rata, a mali broj automobila na Solinskoj ulici, te nema pješaka koji žele prijeći Ulicu Domovinskog rata, računalo ostavlja zeleno svjetlo na Ulici Domovinskog rata znatno duže nego što bi to bilo uobičajeno.

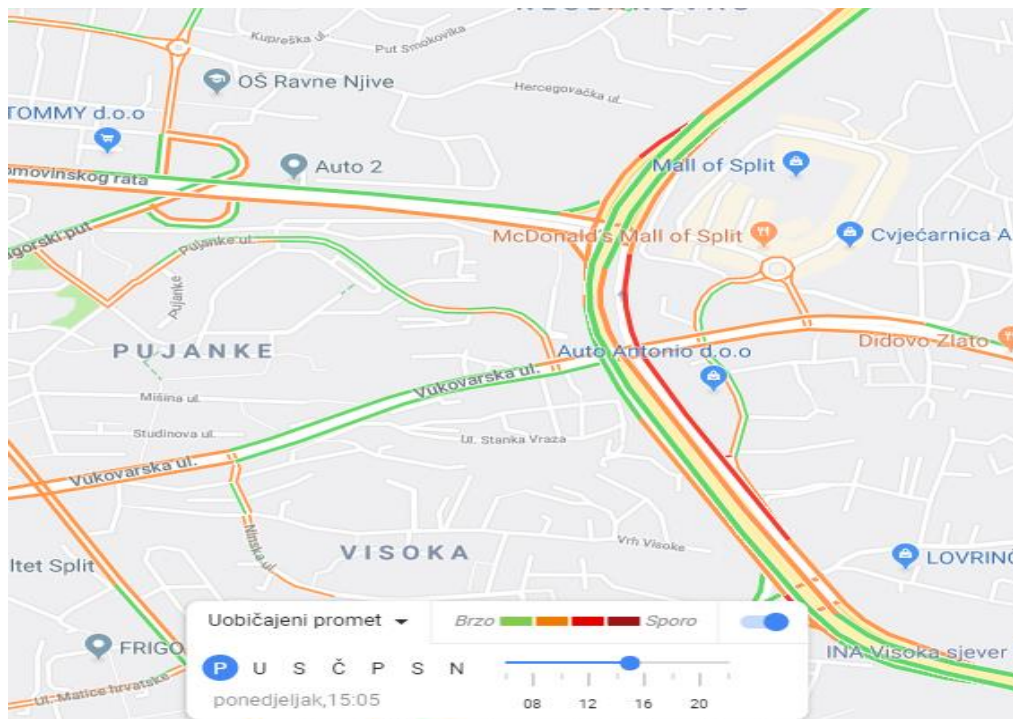
Razlika ovog sustava od ostalih je ta što se uzimaju obzir i raskrižja prije i raskrižja iza, kao i radovi na cesti, prometne nesreće itd.

Sustav neće ostaviti zeleno svjetlo upaljeno previše vremena ukoliko zna da je na sljedećem raskrižju sa ulicom Stinice i Dubrovačkom ulicom već nastala gužva. Naprotiv, prilagodit će vrijeme čekanja na raskrižju prije, i pod cijenu stvaranja manje gužve da bi riješio gužvu na idućem

raskrižju. Na taj način optimizira vrijeme čekanja svih sudionika u prometu. Iako ne rješava apsolutno sve moguće zastoje, smanjuje njihov intenzitet i onemogućuje nepomično čekanje u prometu duže od par minuta.

Ponovna gužva se javlja u razdoblju od 2 sata poslijepodne do 5 sati poslijepodne na Ulici Domovinskog rata, kao i na križanju te ulice sa Ulicom Zbora narodne garde. Takva gužva javlja se u vrijeme kada obično završavaju poslovi te se radnici vraćaju svojim domovima van Splita.

Kod takvih gužvi bitno je kontrolirati izlaze i optimizirati vrijeme čekanja. Sustav otvara izlaze iz Splita što je duže moguće te omogućava brži protok prometa van grada pod cijenu smanjenog protoka prema gradu (*Slika12*).



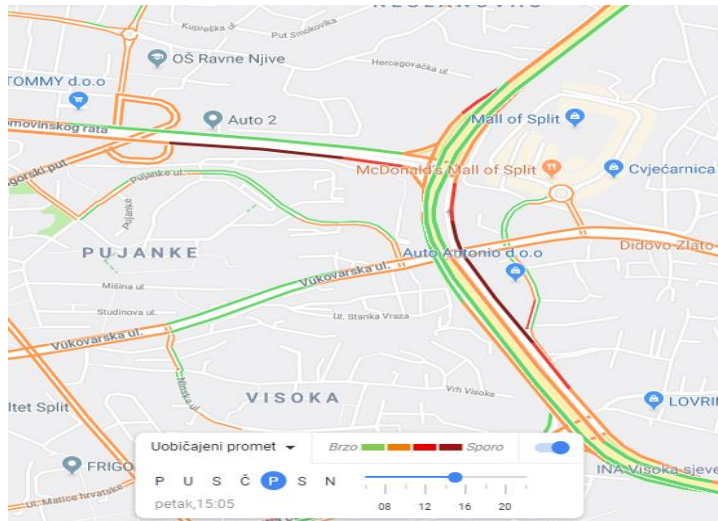
Slika12. Prikaz gustoće prometa na izlazu iz Splita

Izvor: Google Maps/traffic

Intenzitet gužvi se mijenja u odnosu na dane u tjednu. Veće gužve na ulazu u grad možemo vidjeti ponedjeljkom u ranim jutarnjim satima nego petkom u istim satima. Također, izlaz iz grada petkom popodne pati od većih gužvi nego ponedjeljkom popodne. To dokazuje da osim dnevnih oscilacija postoje i tjedne oscilacije. Takav uzorak se poklapa sa provedenim anketama koje pokazuju da stanovništvo tjedno migrira prema Splitu i van Splita. Ponajviše migriraju studenti i učenici, a

potom i radnici. Sustav također mora prepoznati takvu sezonalnost kao i turističku sezonalnost, te sukladno tome pripremiti prometnice za nadolazeće događaje.

Pod pripremom se podrazumijeva preusmjeravanje prometa, bilježenje bilo kakvih radova koji bi mogli dodatno usporiti promet i otvaranje prometnica sukladno naučenom ponašanju prometa u tim danima.



Slika13. Prikaz gustoće prometa na izlazu iz Splita petkom

Izvor: Google Maps/traffic

Petkom se iznimne gužve događaju na izlazima iz grada, naročito na Ulici Domovinskog rata te Ulici zbornarstva (Slika13). Nije ih moguće jednostavno riješiti samo kontroliranjem semafora, ali je moguće preusmjeravanje na manje zagušene ceste kojima promet teče neometano te na taj način smanjivati zastoje na već ustaljenim rutama.

Ovakav sustav gleda na cijeli grad. Glavno računalo je središte cijeloga sustava te koordinira, sinkronizira i upravlja kompletnim prometom na svim ulicama. Zahvaljujući umjetnoj inteligenciji ovaj sustav uči, raspoznaje i prilagođava se svim zadanim parametrima koji su konstantno promjenjivi. Takvo učenje ne bi bilo moguće od strane ljudi jer je previše kompleksno. Stoga deep learning tehnologija, koja može uočiti uzorke čak i kada se čini da ne postoje, trebala bi činiti glavnu razliku u koordinaciji ovakvog prometnog sustava. Deep learning tehnologija bila bi beskorisna ukoliko je ne bi hranili podacima. Upravo zato postoji mnoštvo kamera u ovom sustavu, koje uz pomoć tehnologije računalnog vida, hrane glavno računalo i umjetnu inteligenciju

iznimnom količinom informacija. Na taj način osiguravaju brz i sinkroniziran promet dužinom cijelog grada.


3.6 Rezultati istraživanja

Provedena je anketa čiji su detalji navedeni u prvom dijelu rada. Drugi dio te ankete odnosio se na spoznaju upoznatosti ljudi sa tehnologijom i mogućnosti prihvaćanja modernih tehnologija, kao i korištenje istih.

Nažalost, rezultati ankete nisu pokazali očekivana predviđanja, s tehnologijom “Internet of Things” upoznato je tek nešto manje od polovice ispitanika (*Slika14*).

Jeste li upoznati s "Internet of Things" tehnologijom?

102 responses



Slika14. Upoznatost ispitanika s tehnologijom “Internet of Things”

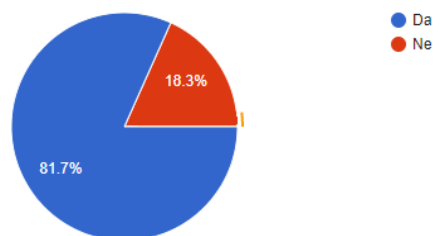
Izvor: Izračun autora

To nam pokazuje da bi uvođenje ovakvog sustava moglo biti kontroverzno, a prihvaćanje te tehnologije u svakodnevnom životu problematično. U prilog ne ide činjenica da takvu tehnologiju aktivno koristi tek nešto manje od 38% ispitanika.

Pojam “Umjetna inteligencija” je na ovim područjima poprilično poznat te je sa njime upoznato više od 80% ispitanika (*Slika15*). Stupanj znanja o samom konceptu nije ispitan, ali dobar odaziv na samo pitanje o tome da li bi ljudi prihvatili umjetnu inteligenciju kao kontrolora prometa nam govori da bi ovaj sustav mogao zaživjeti bez previše problema.

Jeste li upoznati s pojmom "Umjetna inteligencija"?

104 responses



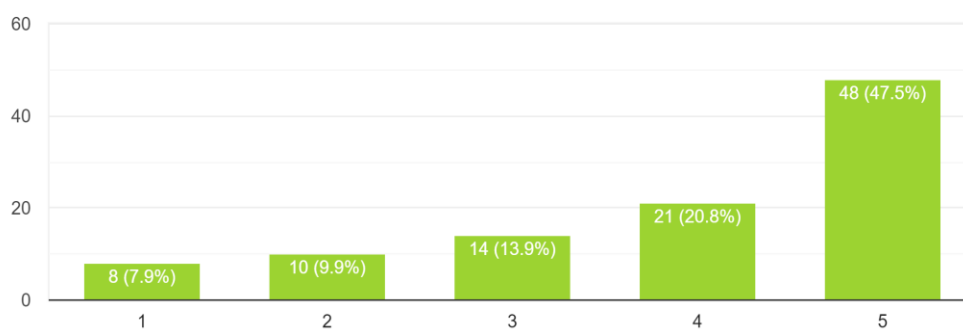
Slika15. Upoznatost ispitanika s pojmom "Umjetna inteligencija"

Izvor: Izračun autora

Ovom se anketom ispitalo koliko se ljudi, koji se kreću tim područjem, koriste tehnologijom kao pomagačem u svome kretanju i snalaženju. Većina ispitanika ove ankete bili su sa područja Splita i okolice, tek 17,3% ispitanika ne živi u blizini Splita. Sukladno tome su se i kretali odgovori na pitanja o poznavanju prometnica i korištenju GPS-a za snalaženje u kretanju gradom.

Koliko dobro poznajete ceste u Splitu?

101 responses




Slika16. Poznavanje cesta među ispitanicima

Izvor: Izračun autora

Koristite li GPS za snalaženje po gradu?

100 responses



Slika17. Korištenje GPS-a

Izvor: Izračun autora

Na pitanje “Koliko dobro poznajete ceste u Splitu” (*Slika16*) na skali od 1 do 5, gdje 1 znači ne poznajem ceste u Splitu, a 5 iznimno dobro poznajem ceste u Splitu više od 67% ispitanika dobro ili iznimno dobro poznaje ceste u Splitu. Drugačija je situacija u korištenju GPS-a, gdje 55% ljudi slabo ili uopće ne koristi GPS u kretanju gradom (*Slika17*). Rezultati nisu recipročni, prema tome, čak i ljudi koji dobro poznaju ceste, ponekad koriste GPS uređaje za snalaženje pri kretanju, a čak je 63,7% ispitanika spremno i iznimno spremno dijeliti svoju GPS lokaciju za pomoć radu samom sustavu, te 82% ispitanika želi koristiti aplikaciju koja će im pomoći u izbjegavanju gužvi. Ti rezultati se slažu u potpunosti sa rezultatima na posljednje pitanje, Jeste li spremni prihvatiti nove tehnologije u prometu?, gdje se također 82% ljudi izjasnilo kao spremno, dok je 16% ispitanika bilo nesigurno. Samo 2 od ukupno 104 ispitanika se izjasnilo kao nesporno prihvatiti nove tehnologije.

Rezultati ove ankete pokazali su da se društvo mijenja. Trenutačno stanje u prometu je postalo iznimno neugodno za vozače koji se svakodnevno kreću tim prometnicama. Zbog toga bi se s lakoćom mogla uvesti tehnologija koja će svima pomoći da ne čekaju u prometnim gužvama dugo vremena, čak i pod cijenu mogućeg narušavanja privatnosti za vrijeme trajanja same vožnje.

4 ZAKLJUČAK

Kroz proteklo stoljeće tehnologija je preobrazila svijet kakav je postojao. Izum mikroprocesora omogućio je razvoj računala, a time i svijeta oko nas. Kroz godine razvijanja ljudi su nastojali pronaći lakši i jednostavniji način obavljanja svakodnevnih zadaća, uz što manje troškove i što veću sigurnost. Sve se digitaliziralo i preobrazilo te ljudi gotovo ništa više ne rade bez nekog oblika tehnologije da im pomaže. Razvoj je omogućio lagodan život i veliki napredak u civilizaciji, te sve veći broj ljudi na zemlji koristi modernim tehnologijama. Razvoj čovječanstva u novom dobu sa sobom dovodi nove izazove i prijetnje koje se rješavaju novim naprednim tehnologijama.

Gradovi su vremenom postali mjesta iznimno guste naseljenosti. Koncentracija ljudi izaziva nove prilike za rad i život te je sve veći problem centraliziranje u velikim mjestima i napuštanje manjih mjesta. Hrvatska država nikako nije iznimka pa se zbog toga bilježi ogroman rast i razvoj gradova kao što su Zagreb i Split, a sve manje ljudi danas živi na selima i u manjim gradovima. Ukoliko se na takvu situaciju poveže i postojanje turizma u velikim gradovima te veliki priljev ljudi u određenim mjesecima, evidentno je da će se javiti svojstveni problemi.

Ovaj rad ponudio je rješenje sve većih nesnosnih prometnih gužvi u gradu Splitu na vrlo specifičan i ekonomičan način, korištenjem moderne tehnologije.

Prometne gužve u Splitu stvaraju velike probleme svim sudionicima u prometu. Provedena anketa pokazala je da je većina ljudi koja boravi u Splitu nezadovoljna prevelikim prometnim gužvama, naročito u ljetnim mjesecima. Veliko nezadovoljstvo također stvaraju prometni čepovi u određenim vremenskim intervalima, uzrokovani velikim migracijama ljudi iz okolice Splita, najčešće radnika i učenika.

Jasno je da je Split kao grad postao prenapučen, te da se prometnice i infrastruktura ne mogu graditi brzinom kojom se sam grad razvija.

Upravo iz tih razloga traži se rješenje koje ne zahtjeva dugotrajne i skupe radove na prometnicama te ne izaziva dodatne naknadne gužve koje su uobičajena pojava kod izgradnje bilo kakve infrastrukture. Osmišljeni sustav koristi isključivo modernu tehnologiju da bi smanjio i optimizirao prometne gužve, a sama ugradnja sustava je neinvazivna i zahtjeva minimalne napore. Opisani sustav umjetnom inteligencijom vlada svim prometnicama u gradu, uči na primjerima iz prošlosti i pronalazi rješenja za budućnost, sve uz pomoć tehnike dubokog učenja. Takva tehnika bazira se na korištenju algoritama i obrađivanja velikog broja informacija te bi bila u mogućnosti optimizirati

vrijeme trajanja signalizacije na semaforima i na taj način smanjiti prometne čepove na minimum, smanjiti prometne gužve na svim prometnicama, omogućiti nesmetano putovanje i sigurnost apsolutno svih sudionika u prometu.

Učenje na ogromnom broju informacija je nemoguće ukoliko se samome mozgu računala ne dostavi ogroman broj informacija. Za glavni izvor informacija koriste video kamere uparene sa tehnologijom računalnog vida. Na taj se način samom sustavu omogućila potpuna autonomija u djelovanju. Kompletan sustav organiziran je kao Internet of Things sustav u kojem su svi dijelovi sustava povezani konstantnom internetskom vezom putem 5G mreža. Takve mreže odlikuju se iznimnom brzinom kao i mogućnošću spajanja ogromnog broja uređaja. Njihove odlike daleko nadmašuju njihovu manu malog dometa, naročito kad se radi o Internet of Things sustavu sa velikim brojem komponenata u neposrednoj blizini.

Cjelokupan sustav je baziran na najmodernijoj tehnologiji i dovodi mogućnost skore zastarjelosti gotovo na nulu. Godine razvijanja i samostalnog učenja činile bi ovaj sustav sve boljim.

Sama prihvaćenost sustava od strane finalnih korisnika bi barem po anketama bila više nego zadovoljavajuća. Većina ispitanika se složila da se stvari moraju mijenjati te su spremni koristiti pomoć umjetne inteligencije, kao i odreći se dijela svoje privatnosti u zamjenu za manje frustracija s prometnim gužvama. Slične tehnologije već postoje u svijetu i pokazale su odlične rezultate u borbi protiv prometnih gužvi, bez negativnih posljedica. To sve ukazuje da bi ovakav sustav u Split donio ogromne promjene i poboljšanja. Čak i kada ne bi uspio u potpunosti eliminirati sve prometne gužve i prometne čepove, ovakav sustav bi uvelike pridonio njihovom smanjenju i puno bržem razrješavanju. Njegova ugradnja bila na korist apsolutno svih ljudi koji se kreću tim područjem, te bi pozitivno utjecala na ekonomsku situaciju i općenito zadovoljstvo.

Zahvaljujući tehnologiji ljudi mogu mijenjati svijet, tehnologija je ekstenzija ljudskog tijela, a bilo koja dovoljno napredna tehnologija je nalik magiji.

LITERATURA

1. Ashton, K. (2015): How to Fly a Horse
2. Sinković, J. (2015): Vodič za razumijevanje Interneta stvari, [Internet], raspoloživo na: <https://www.racunalo.com/vodic-za-razumijevanje-internet-stvari-internet-of-things-iot/>
3. Nepoznati autor (2017): Smart traffic management in the city of Darmstadt, [Internet], raspoloživo na: <https://www.flir.com/discover/traffic/roads-tunnels/smart-traffic-management-in-the-city-of-darmstadt/>
4. Nepoznati autor (nepoznata godina): Reference radova tvrtke Peek, [Internet], raspoloživo na: <https://peek.hr/reference/>
5. Toh M., Erasmus L. (2019): Alibaba's 'City Brain' is slashing congestion in its hometown, [Internet], raspoloživo na: <https://edition.cnn.com/2019/01/15/tech/alibaba-city-brain-hangzhou/index.html>
6. Kordić Z. (2009): E-prijava – brže i jednostavnije, [Internet], raspoloživo na: <http://www.infotrend.hr/razgovori/e-prijava---brze-i-jednostavnije.613.html>
7. Copeland J. (2014): Artificial Intelligence: A Philosophical Introduction
8. Goodfellow I., Bengio Y., Courville A. (2016): Deep Learning, [Internet], raspoloživo na: <http://www.deeplearningbook.org/>
9. Jejdling F. (2019): Ericsson Mobility Report, [Internet], raspoloživo na: <https://www.ericsson.com/49d1d9/assets/local/mobility-report/documents/2019/ericsson-mobility-report-june-2019.pdf>
10. Blažev K. (2019): Što je 5G mreža i nosi li sa sobom rizike po zdravlje čovjeka?, [Internet], raspoloživo na: <https://mob.hr/sto-je-5g-mreza-i-nosi-li-sa-sobom-rizike-po-zdravlje-covjeka/>
11. Legac, I. (2008): Raskrižja javnih cesta: cestovne prometnice II, Zagreb
12. Slike preuzete s internet aplikacije Google Maps

SAŽETAK

Moderno društvo se razvija i raste, te ima tendenciju centraliziranja u većim središtima. Ona s vremenom postaju prenapučena i javljaju se problemi od kojih je jedan gužva u prometu na cestama. Jedno takvo središte je i grad Split, koji osim fenomena centralizacije ima i ogromnu turističku ponudu. Priljev turističke populacije stvara dodatne gužve na prometnicama te otežava svakodnevni život svih ljudi koji se kreću tim područjem.

Ovaj rad će se pobliže pozabaviti rješavanjem problema prometnih gužvi na moderan način; koristeći moderne tehnologije. Osmišljen je sustav koji funkcionira kao Internet stvari. Sustav koristi umjetnu inteligenciju za upravljanje prometom, video kamere i tehnologiju računalnog vida za nadgledanje prometnica i 5G mreže kao komunikacijske kanale unutar sustava. Tendencija samostalnog održavanja i dubokog učenja na prijašnjim situacijama čini ovaj sustav otpornim na protok vremena. Slični sustavi već postoje u svijetu, te se u osmišljavanju ovog sustava koristilo više nepovezanih sustava od kojih su se preuzele najbolje karakteristike, da bi se eliminirale negativne karakteristike istih. Provedene ankete pokazuju veliku prihvaćenost modernih tehnologija među društvom, a rezultati sličnih sustava pokazuju ogromne uspjehe u smanjivanju i eliminiranju prometnih gužvi na područjima na kojima su ugrađene, te bi ovaj sustav bio od iznimne koristi za sve sudionike u prometu na tom području.

SUMMARY

Modern society is developing and growing, with tendencies of centralisation in bigger cities. That kind of centers become overcrowded over time and start having a lot of problems, one of which is traffic jams. Town of Split in Croatia is a population center as well as a tourist center and that means this kind of problems are regular in a place like that. To resolve traffic jams, the system is invented. That system functions as Internet of things and uses artificial intelligence to direct and control traffic. System uses video cameras and computer vision to see the roads as well as 5G networks to communicate and function. Tendency of self caring and deep learning on past situations makes this system timeless. Similar systems already exist around the world, and some of the ideas are used to make this system better. Best characteristics of their systems are used a combined to eliminate bad characteristics of those systems. According to surveys made, this system would be greatly accepted among the citizens and visitors of Split.

Other systems that are already in function have shown great success in reducing and eliminating traffic jams, so it is to expect for this system to show the same, or even better results in this area.