Usporedba metode za upravljanje priljevnim tokovima na primjeru zagrebačke obilaznice

Galić, Ivana

Master's thesis / Diplomski rad

2015

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:119:539998

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Ivana Galić

USPOREDBA METODA ZA UPRAVLJANJE PRILJEVNIM TOKOVIMA NA PRIMJERU ZAGREBAČKE OBILAZNICE

DIPLOMSKI RAD

Zagreb, 2015.

Sveučilište u Zagrebu
FAKULTET PROMETNIH ZNANOSTI
Vukelićeva 4, 10000 Zagreb
DIPLOMSKI STUDIJ

Diplomski studij: Inteligentni transportni sustavi i logistika
Zavod: Zavod za inteligentne transportne sustave
Predmet: Umjetna inteligencija

ZADATAK DIPLOMSKOG RADA

Pristupnik: Ivana Galić
Matični broj: 0135218360
Smjer: Inteligentni transportni sustavi

ZADATAK:

Usporedba metoda za upravljanje priljevnim tokovima na primjeru zagrebačke obilaznice

ENGLESKI NAZIV ZADATKA:

Comparison of Methods for Ramp Metering on the Example of Zagreb Bypass

Opis zadatka:

Oko velikih gradova se grade zaobilaznice kako bi rasteretile urbanu cestovnu mrežu. Takve zaobilaznice se najčešće svode na urbane autoceste koje imaju veći broj prilaznih i odlaznih rampi. Mjesta spajanja glavnog toka urbane autoceste i priljevnog toka predstavljaju mjesta gdje se mogu pojaviti zastoji. Njihovo pojavljivanje se može smanjiti ili čak spriječiti prikladnim upravljanjem količinom vozila koja se priključuju u glavni tok urbane autoceste. U radu je potrebno napraviti pregled najčešće korištenih metoda upravljanja priljevnim tokovima, analizirati mogućnosti primjene metoda umjetne inteligencije za upravljanje priljevnim tokovima, izraditi model zaobilaznice grada Zagreba i iskoristiti postojeće prometne podatke za simulaciju navedene obilaznice uz korištenje makroskopskog simulatora CTMSIM.

Zadatak uručen pristupniku:
6. svibanj 2015.

Nadzorni nastavnik:

Predsjednik povjerenstva za diplomski ispit:

Djelovođa:

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

USPOREDBA METODA UPRAVLJANJA PRILJEVNIH TOKOVA NA PRIMJERU ZAGREBAČKE OBILAZNICE

COMPARISON OF METHODS FOR RAMP METERING ON THE EXAMPLE OF ZAGREB BYPASS

Mentor: doc. dr. sc. Edouard Ivanjko
Student: Ivana Galić, 0135218360

Zagreb, 2015.

Sažetak

U ovom radu opisane su temeljne pretpostavke uvođenja sustava upravljanja priljevnim tokovima urbanih autocesta uslijedzagušenja te je prikazan pregled najčešće korištenih metoda upravljanja priljevnim tokovima. Također, analizirane su mogućnosti primjene metoda umjetne inteligencije za upravljanje priljevnim tokovima. Na izrađenom modelu zaobilaznice grada Zagreba, uz korištenje postojećih prometnih podataka simulirana je navedena obilaznica uz pomoć simulatora CTMSIM.Analizom rezultata simulacije uspoređeni surezultati u slučaju kašnjenja, vremena putovanja i gustoće. Iz tih rezultata razvidno je manje zagušenje tijekom uporabe algoritama za upravljanje priljevnim tokovima.

Ključne riječi: Umjetna inteligencija; zagušenje; upravljanje priljevnim tokovima; model zaobilaznice; simulacija

Summary

This diploma thesis describesthe main reasons forthe introduction oframp metering due tocongestionand givesan overview ofthe most commonly usedmethods of managingthe mainstream flows. Possibilities of applyingartificial intelligence methodsfor ramp metering are analysed also. Using parameters of thebypass of the city of Zagreb a simulation model is createdand simulated usingof existing trafficdata. The macroscopicsimulatorCTMS is used for simulation. The analysis ofthe simulation resultsare compared according todelay, travel timeanddensity. From theseresultsare reflected inlesscongestionby usingalgorithmsto managethe inflowstreams.

Keywords: Artificial Intelligence; congestion;managethe inflowstreams; bypass model; simulation

Sadržaj

1. Uvod 1

2. Problem upravljanja priljevnim tokovima 3

2.1. Problemi zagušenja autocesta 5

2.2. Mjere razine usluge 9

2.3. Motivacija korištenja upravljanja priljevnim tokovima 10

3. Najčešće metode za upravljanje priljevnim tokovima 12

3.1. Strategija jedno vozilo po intervalu 14

3.2. Strategija više vozila po intervalu 14

3.3. Strategija dvotračnoga mjerenja 14

3.4. ALINEA algoritam 15

3.5. SWARM 17

4. Primjena metoda umjetne inteligencije u upravljanju priljevnim tokovima 19

4.1. Adaptivni *neuro-fuzzy* algoritam u upravljanju priljevnim tokovima 20

4.1.1. Metode prikupljanja podataka 22

4.2. Primjena Q-Learing algoritma 24

4.2.1. Q-Learning algoritam 26

5. Model zaobilaznice grada Zagreba 27

6. Simulacijski rezultati 34

6.1. CTMSIM simulator 34

6.2. Rezultati simulacije 36

7. Zaključak 42

Literatura 44

Popis kratica 46

Popis slika..... 47

Prilog 49

1. Uvod

Posljednjih godina s rastom stanovništva i gradova povećana je potreba i za prometnom infrastrukturom. Dosadašnje prometnice postaju pretijesne za sadašnji obim prometa koji se neprestano povećava. To je vidljivopogotovo u područjima velikih gradova. Primjer za to naveden u ovom radu odnosi se na grad Zagreb i uz njegove prometne potrebe vezane uz zagrebačku obilaznicu. Ova obilaznica, koja je čvorište svih prometnih putova preko Hrvatske, ujedno je i najveća gradska obilaznica Republike Hrvatske. Na postojećoj obilaznici svakodnevno dolazi do povećanja prosječnog godišnjeg dnevnog prometa (PGDP) zbog čega dolazi do značajnog pada razine uslužnosti. To za posljedicu ima česta i neugodna prometna zagušenja u pojedinim dijelovima dana. Izrazit problem predstavljaju i prometne nesreće te njihove posljedice koje dodatno utječu na zagušenje glavnih prometnih tokova. Sve navedeno značajno utječe na pad stupnja prometne uslužnosti (LOS – *Levelof Service*) za korisnike koji su u tranzitu. U ovom radu predlaže se mogućnost rješavanja navedenih prometnih problema uporabom informacijsko-komunikacijskih tehnologija i novousvojenih kompleksnih sustava i procesa o kojima će biti riječi u prvim poglavljima ovoga rada.

Za sve probleme vezane uzstupanj prometne uslužnosti autoceste, već se duže vrijeme u svijetu razmatraju metode upravljanjapriljevnim tokovima tzv.*rampmetering*. U hrvatskom jeziku nema izravnog prijevoda, već pojam možemo definirati kao skupinu prometnih signala koji upravljaju prometnim priljevnim tokovima na ulazima autoceste. To je jedan od najučinkovitijih sustava upravljanja koji je zasnovan na stvarnom vremenskom mjerenju prometnih parametara. Implementacija ovog sustava povezana je sa novim servisima upravljanja cestovnim prometom iz područja inteligentnog transportnog sustava (ITS).

U nastavku rada bit će opisani glavni razlozi uvođenja sustava upravljanja priljevnim tokovima uslijedzagušenje cestovnog prometa koje predstavlja stanje koje karakterizira smanjenje brzine protoka, povećanje vremena putovanja i povećanje kolone. Osnovne mjere za procjenu razine usluga na cestama na koje može utjecati upravljanje priljevnim tokovima su vrijeme putovanja, odgoda putovanja i gubitak produktivnosti. Tri temeljne strategije kod upravljanja priljevnim tokovima su strategija jedno vozilo po intervalu, više vozila po intervalu i strategija dvotračnog mjerenja.

U nastavku rada bit će prikazan pregled algoritama koji se koriste u upravljanju priljevnim tokovima urbanih autocesta. Algoritmi za upravljanje priljevnim tokovima razlikuju se od ostalih po tome jer im je temeljna svrha optimizirati parametre procesa priljeva priljevnih tokova u glavni tok autoceste kako bi se ostvarile što manje smetnje u protočnosti glavnog toka. Prikazani su najčešće korišteni algoritmi, među njima i ALINEA koja se ubraja u skupinu tzv. lokalnih algoritama.Princip funkcioniranja mu je dosta jednostavan, ali daje zadovoljavajuće rezultate s obzirom na implementaciju i jednostavnost njegove prirode. Predstavlja najkorišteniji algoritam na europskom sustavu za autoceste. Prikazan je i SWARM algoritam razvijen kao dio napredne tehnologije općenitog upravljanja priljevnim tokovima. On predstavlja kompetitivan i prometno ovisan algoritam upravljanja priljevnim tokovima. Osnovni mu je cilj zadržati gustoću glavnog toka ispod definirane razine u stvarnom vremenu.

U završnom dijelu rada prikazani su rezultati simulacijskog prikaza zagrebačke obilaznice. Za prikaz rezultata o prometnom modelu upravljanja priljevnim tokovima uporabljen je program CTMSIM izrađen u MATLAB-u. Za izračun simulacije uporabljeni su realni podaci iz Zagreba koje daju rezultate o priljevnom i ulaznom toku. Prikazani su rezultati uporabe ALINEA i SWARM algoritma te usporedba sa situacijama kada ih ne koristimo. Svi grafovi su prikazani kroz vremenski period od 24 sata. Na temelju dobivenih simulacijskih rezultata prikazani su rezultatepo njihovom potencijalu za daljini razvoj i primjenu na zagrebačkoj zaobilaznici.

2. Problem upravljanja priljevnim tokovima

U ovom radu bit će razrađen problem upravljanja prometom napriljevnim tokovima zagrebačke obilaznice. Grad Zagreb, kao najveće i najvažnije prometno križanje u kojemu se odvija ukupno 30% prometa Republike Hrvatske, ishodište je i cilj mnogih putovanja koja se ostvaruju preko šest pravaca različitih autocesta (A1, A2, A3, A4, A6 i buduća A11).Svi oni završavaju ili započinju na postojećoj zagrebačkoj obilaznici. Od europskih koridora tu se presijecaju koridori X, Xa i Vb.

Uz prometno opterećenje tranzitnim prometom, danas zagrebačka obilaznica preuzima i veliki dio lokalnog prometa grada Zagreba. Neki dijelovi obilaznice već danas su postali gradskom prometnicom na kojoj oko 70% prometa koji se njome odvija otpada na tzv. gradski promet (posebice dionica Jankomir – Lučko i čvor Lučko). S obzirom na ubrzan razvitak šireg područja Grada Zagreba i Zagrebačke županije, može se očekivati zadržavanje visoke stope rasta prometnog opterećenja što vodi k uvjetima odvijanja prometa neprimjerenim cestama visoke razine uslužnosti. Na postojećoj obilaznici neprestano dolazi do povećanja prosječnog godišnjeg dnevnog prometa (PGDP) zbog čega dolazi do značajnog pada razine uslužnosti. To za posljedicu ima značajna prometna zagušenja u pojedinim dijelovima dana. Izrazit problem predstavljaju i prometne nesreće te njihove posljedice koje dodatno utječu na zagušenje glavnih prometnih tokova. Sve navedeno značajno utječe na pad stupnja prometne uslužnosti (LOS – *Levelof Service*) za korisnike koji su u tranzitu[4].

Problem današnjice je konstantno povećanje urbanog prometa. To povećanje rezultira svakodnevnim zagušenjima što je vidljivo na primjeru situacije iz Slike 1**.** Urbane autoceste su dizajnirane na način da omogućuju vrlo brzo i sigurno odvijanja prometa. Najveći dio autocesta projektiran je tako da mogu podnositi velika prometna opterećenja, no pridimenzioniranju njihovoga kapaciteta teško se možepredvidjeti buduća promjena prometne potražnje na priljevnim tokovima koja će utjecati na propusnost glavnog toka. Urbane autoceste ključni su dio prometnih mreža svih velikih gradova jer rasterećuju gradske prometnice. Skoro svaki dan svjedoci smo većeg broja prometnih zastoja ili barem usporenja prometa. U prostornim i vremenskim dimenzijama prometni zastoji su uobičajeni na dijelovima autoceste u blizini velikih urbanih područja u ranim

jutarnjim ili kasnim poslijepodnevnim satima. Spomenute probleme zagušenja možemo pripisati dnevnim migracijama do i od mjesta zapošljavanja, obrazovanja, itd.[1].Upotrebe sustava upravljanje priljevnim vozilima predstavlja jedan od mogućih načina kakospriječiti navedeni problem.



Slika1. Stanja na zagrebačkoj obilaznici tijekom zagušenja

Za sve te probleme vezane uz autoceste u svijetu se već duže vrijeme razmatraju metode upravljanja priljevnim tokovima. Takav koncept je SAD imao već 60-tih godina prošloga stoljeća, dok je u Europu stigao tek 80-ih godina. U Europskoj Uniji je 2001. godine pokrenut projekt pod nazivom CENTRICO kako bi bili procijenjeni sustavi upravljanja priljevnim tokovima ubrzanih autocesta te kako bi na temelju njih bio napravljen standard na cijelom području. Takvi sustavi upravljanja priljevnim tokovima često se ujedinjuju pod engleskim nazivom – *rampmetering*[2].U hrvatskom jeziku nema izravnog prijevoda, već je pojam definiran kao skupinu prometnih signala koji upravljaju prometnim priljevnim tokovima na ulazima autoceste. To je jedan od najučinkovitijihsustava upravljanja koji je zasnovan na stvarnovremenskom mjerenju prometnih parametara s područja inteligentnog transportnog sustava (ITS).Predstavlja sustav koji prilikom prevelikog opterećenja na glavnom toku onemogućava priljevnim vozilima priključivanje na glavni tok. Priključivanje je onemogućeno sve dok se situacija ne raščisti ili ako vrijeme čekanja na priljevnoj rampi prelazi prihvatljive granice čekanja vozača ili pak ako red čekanja na priljevnoj rampi postane predug.

Glavni operativni razlozi uvođenja upravljanja priljevnim tokovima autocesta su:

- manja zagušenja i poboljšanje protočnosti glavnih prometnih tokova na autocesti;
- smanjenje vremena putovanja autocestom kao i povećanje pouzdanosti u planiranju potrebnog vremena za putovanje autocestom;
- smanjenje prometne potražnje za korištenje autocestom pri kratkim putovanjima;
- smanjenje rizika od nastajanja nesreća;
- unaprjeđenje okoliša nastalo kao rezultat smanjenja buke i potrošnje goriva.

Svrha uvođenja prvoga i drugogaoperativnog razloga je osiguranje stanja u kojem ukupni broj vozila koji ulazi na autocestu zajedno s vozilima u glavnom toku autoceste bude niži od kapaciteta koji upućuje na postojanje zagušenja na tom dijelu autoceste. Cilj trećega operativnoga razloga je stvaranje upravljivog zastoja na prilazima autoceste kako bi se spriječila kratka putovanja autocestom prilikom vršnih opterećenja. Četvrti operacijski razlog ima ulogu usklađivanja brzine i gustoćepriljevnoga toka s glavnim. Time se sugerira vozačima, koji se uključuju u glavni tok autoceste pravi trenutak u kojem se smiju uključiti u glavni tok, a da je pritom rizik od nesreće najmanji. Peti operacijski razlog rezultat je prvih triju operacijskih razloga[1].

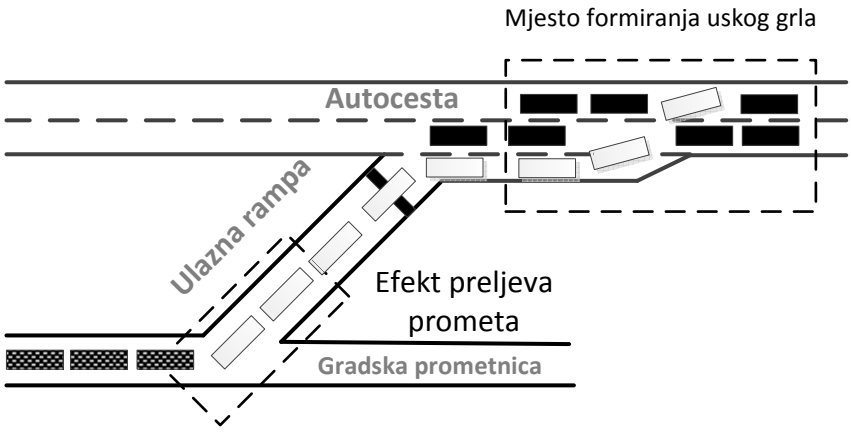
2.1. Problemi zagušenjaautocesta

Zagušenje cestovnog prometa je stanje karakterizirano smanjenjem brzine protoka, dužinom vremena putovanja i povećanjem kolone. Period ekstremnog zagušenja kolokvijalno nazivamo „prometni čep“(eng. *trafficjam*). Simulacija zagušenja ukazuje da u jakom i slobodnom protoku, „čep“ nastaje spontano, a može biti uzrokovan „manjim događajima“. Problem koji je već ranije spomenut najprimjetniji je u blizinivećih gradova. Posljedice zagušenja autocesta manifestiraju sepokazateljima koji se pretežito odnosena to da prometna potražnja premašuje kapacitet ceste, da se svakodnevno povećava broj nesreća i incidenata, da su česti radovi na prometnicama zbog kojih se promet prebacuju iz lokalnog prometa na autocestu te da se u „prometnim čepovima“stvara kolona vozila koja pokušavaju ući na autocestu. Gradovi diljem svijeta

našli su se na rubu masovne prometne eksplozije. Situacija se dodatno pogoršava zbog nekoliko razloga:

- **neplanirani gradovi** - prometnice su uske i loše izvedene,ne postoji odredba o skaliranju cestovne infrastrukture s porastom gradova;
- **rast stanovništva** – čini neuspješnom klasičnu strategije upravljanja prometom
- **slaba disciplina** – vozači se ne drže prometne discipline pogotovo na raskrižjima; topogoršava ionako pretrpanu prometnu situaciju,vozači nerijetko prolaze kroz crveno svjetlo što izaziva dodatne blokade i ove probleme čini jošsloženijima;
- **alternativna prometna sredstva** – zemlje s brzo rastućim gospodarstvom imaju sve više vozila na gradskim prometnicama, a zbograzrađenogsustave javnoga gradskoga prijevozaljudima često ne preostaje drugi izbor osim uporabe osobnoga vozila; dodatna složenost ovoga problema ogleda se u tome što ljudi doživljavaju posjedovanje osobnog automobila znakom blagostanja, dok javni prijevoz povezuju s nižim društvenim slojevima;
- **smanjeni proračuni** – značajan iznos sredstava potrebno je uložiti u upravljačku prometnu infrastrukturu koja se može nositi s rastućim prometom, a takva infrastruktura uključuje mjerenja i analize u stvarnom vremenu te podatke o prometu uz usredotočenost na otkrivanje zagušenja [1].

Uobičajen razlog zagušenja gradskih cesta je u gustoći prometnih tokova koji ulaze iz manje prometne u prometniju ulicu. Područje gdje ova dva toka prometa zapravo dolaze u dodir je poznato kao nizvodno usko grlo. Naslici 2. je prikazana lokacija nizvodnoga grla blizu ulaza na cestu učinak priljeva prometa na okolnu lokalnu cestovnu mrežu *(eng. Spilllback).*



Slika 2. Mjesto formiranja uskog grla i efekti preljeva prometa [2]

Posljedica zagušenja prometa su višeznačne i uzrokuju više problema:

- **zastoj** – gubitak vremena i vozača putnika; kako je za većinu vožnja predstavlja neproduktivnu aktivnost, zagušenje smanjuje regionalnu ekonomiju i produktivnost (prihod), odnosno generira dodatni trošak;
- **kašnjenje** – zagušenje može izazvat prekasni dolazak na posao, poslovni sastanak, školovanje ili bilo koji dogovor za koji je važan točan i pravovremeni dolazak;
- **gubitak goriva i povećano zagađenje okoliša** – u prometnom zagušenju prekomjerno se troši pogonsko gorivo i povećava onečišćenje okoliša zbog rada motora u mjestu, češćeg ubrzanja i kočenja;
- **efekt prelijevanja** – vozači nekontrolirano traže alternativne putove zagušenim glavnim arterijama, koristeći sekundarne ceste što uzrokuje povećanje prometa u inače mirnim naseljima;
- **stres** – povećanje stresa i frustracije vozača uzrokuje povećanu potencijalnu opasnost da dođe do nesreće;
- **otežane hitne intervencije** – blokiran promet može onemogućiti prolaz vozilima hitne pomoći da dođu pravovremeno do odredišta gdje su potrebni [3].

Prometno zagušenje je ozbiljan problem u mnogim gradovima u svijetu i dovodi do milijardi dolara gubitaka godišnje. Iako se ulaže mnogo napora da se smanje prometna

zagušenja, situacija postaje sve teža. Jedno istraživanje koje je Teksaški prometni zavod proveo u 75 velikih gradova diljem Sjedinjenih Država pokazalo je da je prosječan broj sati koje svaki stanovnik provede godišnje u prometnim gužvama porastao sa 16 sati u 1982. godini na 62 sata u 2000. godini. Razdoblje u kojem postoji veća vjerojatnost za stvaranje prometne gužve produljilo se s 4,5 sati na 7 sati dnevno. Azijske zemlje kao i Europa suočavaju se sa sličnim problemima [5]. Prisutne su velike nesuglasice u metodama izračuna troškova nastalih zbog zagušenja u prometu, no u svakom slučaju iznosi su ogromni. Procijenjeno je kako je u 2000. godini samo na području 75 najvećih metropola bilo 3,6 milijardi sati kašnjenja što je uzrokovalo dodatnu potrošnju od 21,6 milijardi litara goriva i 67,5 milijardi USD izgubljene produktivnosti, ili oko 0,7 % nacionalnog bruto domaćeg proizvoda (BDP-a). Također se procjenjuje da je godišnji trošak zbog zagušenja za svakog vozača u SAD-u bio oko 1.000 USD u velikim gradovima te oko 200 USD u manjim gradovima. U izvješću „Radovi na cestama i troškovi zagušenja prometa“ 2005. profesor PhilGoodwin, procjenjuje da su samo radovi na cestama u Engleskoj uzrokovali oko 5% ukupnog zagušenja prometa proizvodeći 4,2 milijarde funti troškova godišnje [6]. U nesrećama u RH godišnje u prosjeku pogine oko 600 osoba, što je po procijenjenoj vrijednosti EU od 1 – 1,2 milijuna eura po osobi što čini gubitak od 600 milijuna eura godišnje. Pribrojimo li tome troškove liječenja i rehabilitacije ozlijeđenih, prijevremene invalidske mirovine i slično dolazimo i do 15% BDP-a ukupnih eksternih troškova prometa koliko se procjenjuje u europskim tranzicijskim zemljama.

Realno gledano, zasad nije moguće potpuno riješiti problem prometnih gužvi. AnthonyDowns, autor knjige *StuckinTraffic - CopingWith Peak-HourTrafficCongestion*, zaključio je: “Unatoč svim strategijama koje se poduzimaju kako bi se u budućnosti smanjile prometne gužve, one će se u gotovo svim dijelovima svijeta vjerojatno još više povećati. Stoga vam ne preostaje ništa drugo nego da se naviknete na njih.”

Postoje dvije metode izračuna troškova zagušenja:

- **TOP DOWN metoda** - koristi se već oko 50 godina i njome se izračunavaju ukupni ekonomski troškovima u bazi podataka iz svih izvora, potom se izračunava proporcija zagušenja po uzorcima (%)koja se množi s ukupnim troškovima. Npr. procijenjeni ukupni troškovi zagušenja u Engleskoj su 20 milijardi funti godišnje pa 5% zagušenja zbog radova na cesti iznosi ukupno 1 milijardu funti godišnje.

- **BOTTOM UP metoda** - koristi se zadnjih 40 godina i izračunava trošak zagušenja po specifičnim radovima, utvrđuje koliko ukupno radova ima te se množi prosječni trošak s brojem ukupnih radova. Za isti primjer, uz ukupno 1,3 milijuna radova puta 5,3 dana (koliko prosječno traje pojedina intervencija na cesti) rezultira s 6,9 milijuna dana radova godišnje. Prosječni trošak zagušenja po danu je 633 funte (20 sekundi kašnjenja po vozilu)što rezultira s 4,3 milijarde funta godišnje [1].

Jedna od najučinkovitijih metodaupravljanja prometom na gradskim prometnicama pod domenom ITS-a je metodaupravljanja priljevnim tokovima *rampmetering*. Glavni cilj te metode je smanjiti i zadržati sposobnost protjecanja prometa na cesti reguliranjem pristupa ulaznim rampama matice prometa. Upravljanje priljevnim tokovima ograničava broj vozila koji se priključuju cijeloj prometnici koja ulazi na cestu te ih povremeno skladišti na ulaznu rampu.

2.2. Mjere razine usluge

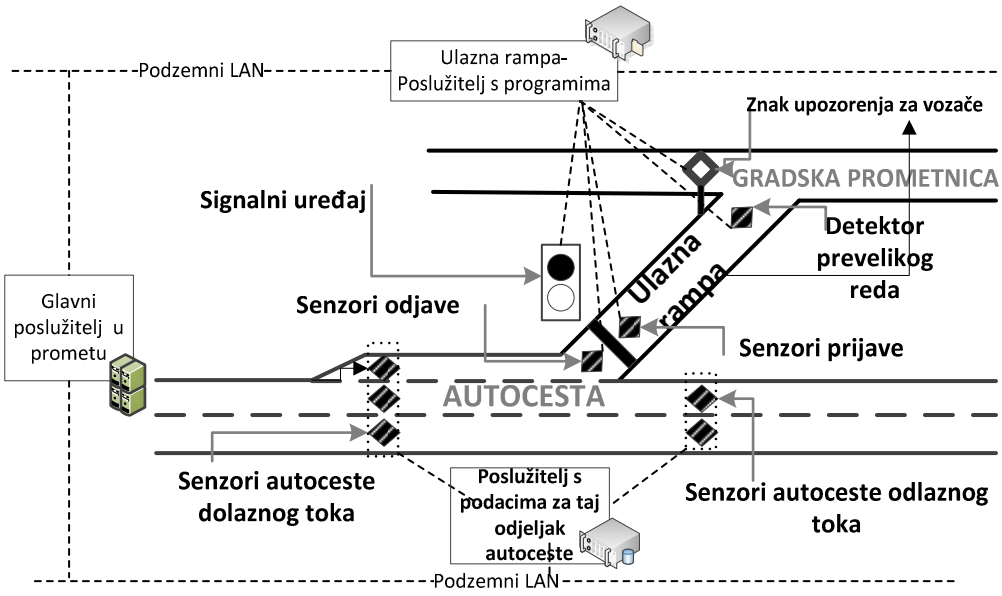
Generalno postoje tri osnovne mjere za procjenu razine usluge *(eng.LOS - Levelof Service*)cesta na koje može utjecati upravljanje priljevnim tokom, a to su vrijeme putovanja *(eng. TT-travel time*), odgoda putovanja i gubitak produktivnosti. Vrijeme putovanja je jednostavna mjera koja može pružiti odgovor na pitanje koje se odnosi na podatak koliko je vremena potrebno jednom vozilu da prijeđe promatrani dio ceste. Odgoda putovanja se može izračunati kao razlika između stvarnih VHT(*engl. vehiclehourstravelled*)vrijeme putovanja u satima i odnosnim VKT(*engl. vehiclekilometrestravelled*) kilometri koje je prošlo vozilokroz vrijednost dok ide brzinom slobodnog toka [sec/veh]. Gubitak produktivnosti je zapravo mjera propusnosti postrojenja. Definirana je kao broj izgubljenih traka-kilometara-sati na cesti zbog smanjenoga protoka prometa, dok se vozila u zagušenju prometa umjesto u uvjetima slobodnog toka [7].

Dodatno, definirana su dva nova kriterija: ukupno vrijemeputovanja svih vozila (*eng. total time spent*)TTS potrošeno u prometnoj mreži i ukupna udaljenost putovanja(*eng. total travel distance*)TTD. TTS vrijednost uključuje ukupno vrijeme čekanja(*eng. total waiting time*)TWT na ulaznoj rampi i ukupno vrijeme putovanja(*eng. total travel time)*TTT provedeno u prometnoj mreži: TTS = TTT + TWT. Minimalizacija TTS kriterija uključuje također minimalizaciju vremena čekanja ulazne rampe koja je dio

cilja optimizacije za razmatrani sustav kontrole prometa. TTD kriterij se često koristi u kombinaciji s TTS kriterijima za izračun brzine prometa (MS= TTD/TTS) [1].

2.3. Motivacija korištenja upravljanja priljevnim tokovima

Kao dio upravljačkog procesa, koriste se cestovni signali na ulaznoj rampi da upravljaju količinom ili veličinomskupine ulazećih vozila. Cijeli sustav se zasniva na stvarnim podacima prikupljenim preko cestovnih senzora. Takav sustav sadržava potrebne signalne uređaje i znakove kako bi se sudionike prometa na vrijeme upozorilo i obavijestilo o radu rampe.Radi pouzdanog rada sustav koristi priličan broj senzora. Senzori su uglavnom smješteni na ulaznoj rampi i na glavnoj cesti. Oni prate i mjere te vrše procjene toka prometa, brzinuvozila, brzinu ulazne rampe te detektore prevelike duljine reda čekanja na priljevnom toku. Osnovna instalacija toga sustava na dionici urbane autoceste je prikazana naSlici 3. Postavljena je samojedna lokalna ulazna rampa. Lokalni upravljački poslužiteljna ulaznoj rampi je povezan sa središnjim upravljačkim poslužiteljem. Podatci prikupljeni putem navedenih senzora skupljaju se u poslužitelje na ulaznoj rampi i autocesti. Informacije iz tih poslužitelja potom se distribuiraju do glavnog poslužitelja kojim potom prosljeđuje relevantne informacije višim razinama upravljanja kao što su lokalni odnosno regionalni prometni upravljački centri. Nakon razmjene informacija moguće je pouzdano i efikasno upravljati ulaznom rampom. Dodatno može postojati veza s ostalima prometnim upravljačkim sustavima kao što su varijabilno ograničenje brzine, informiranje vozača ili sprječavanje promjene prometne trake [1].



Slika 3. Osnovna upravljačka instalacija ulazne rampe na dijelu autoceste [1]

3. Najčešće metode za upravljanje priljevnim tokovima

Već dugi niz godina postoje metode za upravljanje priljevnim tokovima na autocestama.U samom početku, za upravljanje priljevnim tokovima korištene su izolirane ili lokane upravljačke metode (algoritmi) koje su upravljale priljevnim tokovima na pojedinom ulazu na autocestu. Kasnije su se počele primjenjivati koordinirane metode upravljanja koje prikupljaju i dijele informacije o zauzeću na svakoj ulaznoj rampi te ih međusobno razmjenjuju.Najveća moguća vrijednost propusnosti prilaza autocesti ovisi o tipu strategije koja se koristi kod upravljanja priljevnim tokovima. Tri su vrste strategija pri upravljanju pristupom glavnim priljevnim tokovima. Svaka se razlikuje prema vrsti i rasporedu prometne signalizacije, kao i dizajniranju mehanizma rada algoritma.

Algoritmi za upravljanje priljevnim tokovima razlikuju se od ostalih po tome jer im je temeljna svrha optimizirati parametre procesa priljeva priljevnih tokova u glavni tok autoceste kako bi bile ostvarene što manje smetnje u protočnosti glavnog toka. Algoritme kao takve možemo podijeliti u dvije skupine:

1. **Izolirane ili lokalne** – kod kojih je algoritam primijenjen na pojedinom prilazu autocesti neovisno o stanju prometa na drugim prilazima. Ovu skupinu čine dva tipa algoritma, upravljanje bez povratne veze i upravljanje s povratnom vezom. Algoritmi upravljani bespovratnom vezom uspoređuju trenutne podatke o zauzeću detektora sa povijesnim podacima o zauzeću za svaku detekcijsku lokaciju kako bi odabrao odgovarajući način upravljanja za slijedeći upravljački period ili imaju vremenski fiksno podešene načine upravljanja. Algoritmi upravljanja bezpovratne veze prilagođavaju način upravljanja kako bi smanjili izmjereno zauzeće na detektorima na željeno zauzeće koristeći usporedbu sa podešenim referentnim zauzećem glavnog toka.
2. **Koordinirane**–algoritam je primijenjen u međusobno ovisnom upravljanju priljevnim tokovima u određenoj skupini prilaza autocesti koji pokriva navedeni algoritam, to je skupina algoritama koja uzima u obzir prometno stanje cijelog prometnog sustava autoceste dok lokalna skupina algoritama donosi odluke o vrijednosti toka koji se propušta na prilazima neovisno o ukupnoj situaciji.
   Ovi algoritmi dodatno se dijele na:

A)Kooperativne – razlikuju se od klasičnih koordiniranih algoritama po tome što se nakon proračuna stupnja propuštanja toka na svakom prilazu dodatno proračunavaju promjene na tim vrijednostima. Promjene se proračunavaju prema informacijama o cijelom sustavu autocesta kako bi se izbjeglo zagušenje na uskim grlima ili propuštanje prevelike količine priljevnog prometnog toka s pojedinih prilaza. Najveća mana ovog algoritma je što je osjetljiv na iznenadne kritične situacije zagušenja poglavito iz razloga što se promjene proračunavaju po *ad hoc* prirodi. Danas ih gotovo nema u operacionalnoj upotrebi budući da predstavljaju novi pristup upravljanju. Najčešće se koristi ALINEJA ili neka njezina izvedenica.

B)Nadmetajuće – imaju pretežito dvije upravljačke logike po kojima proračunavaju stupanj propuštanja priljevnog prometnog toka s prilaza. Obično se radi o lokalnoj ili globalnoj upravljačkoj logici. Svaka vrsta upravljačke logike ponudi vlastitu vrijednost za stupanj propuštanja priljevnog toka pojedinog prilaza. Odabere se ona vrijednost koja je manja. Ovo je danas najraširenija podskupina algoritama za upravljanje priljevnim tokovima u operativnoj upotrebi.

C)Integrirane–od ove tri podskupine algoritama, ovi su najzanimljivija i najsofisticiranija podskupina; definira ih se kao upravljački sustav koji ima cilj optimizirati proces *upravljanja priljevnim tokovima* integracijom različitih tipova upravljačkih algoritama koji kao ulaz koriste širok spektar prometnih parametara. Oni mogu biti integrirani svi u jedinstven algoritam ili mogu djelovati jednostavno pomoću posebnih integracijskih modula. Također, često imaju precizan cilj u upravljanju koji može biti eksplicitno ili implicitno vezan za upravljačku akciju. Uglavnom ova skupina algoritama ima kompleksu logiku rada i zahtjevni proračun. Od iznimne im je važnosti kvaliteta ulaznih podataka. Danas je ova podskupina algoritama još u eksperimentalnoj fazi pa se stoga u praksi gotovo i ne koristi. Implementirani su u pilot projekte u sklopu njihove provjere na stvarnom prometnom sustavu.

3.1. Strategija jedno vozilo po intervalu

Ova strategiju omogućava jednom vozilu ulazak u glavni tok autoceste za vrijeme trajanja svakoga signalnoga ciklusa semafora. Klasični signalni ciklus semafora se sastoji od zelenoga, žutoga i crvenoga svjetlosnoga indikatora. U slučaju upravljanja priljevnim tokovima koristi se samo zeleni i crveni indikator semafora. Treptajuće žuto svjetlo u tom slučaju znači da je sustav isključen. Duljina zelenoga svjetlosnoga signala bi trebala biti postavljena na vrijednosti koje osiguravaju dovoljno vremena za prolazak jednoga automobila preko linije za zaustavljanje. Dok s druge strane, duljina crvenoga intervala trebala bi biti dovoljno dugačka za zaustavljanje vozila koje se nalazilo iza vozila koje se uključilo u glavni tok autoceste. Istraživanja su pokazala je minimalni ciklus u trajanju 4 sekunde premalen jer se njime ne postiže cilj da se svako vozilo zaustavi prije nego se priključi glavnom toku autoceste. Bilo koja dekoncentracija ili nepažnja vozača pri pokretanju vozila na zeleno svjetlo semafora uzrokuje nepotrebno trošenje vremena ciklusa zelenog svjetla. Zato je razumnije minimalno trajanje ciklusa od 4,5 sekunde strajanjem crvenoga svijetla od 2,5 sekunde [1].

3.2. Strategija više vozila po intervalu

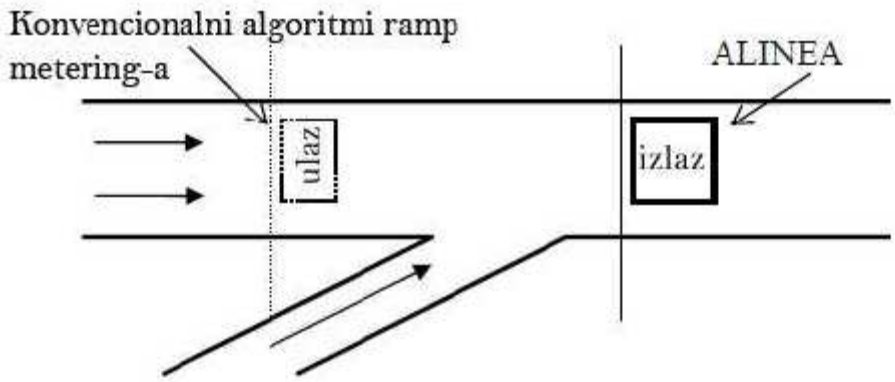
Ova strategija omogućava prolazak dvaju ili više vozila u glavni tok za vrijeme trajanja zelenog svjetla. Osnova ove strategije zasniva se napropuštanja dvaju automobila za vrijeme trajanja zelenog svijetla. Može se propuštati tri ili više vozila, ali time se povećava i mogućnost nesreća [1].

3.3. Strategija dvotračnoga mjerenja

Strategija je to koja zahtijeva dvije trake na prilazu autoceste. Temelji se na tome da se upravlja mijenjanjem trajanja ciklusa za svaku prometnu traku zasebno. Ciklusi koje upravljanje koristi mogu, ali ne moraju, biti sinkronizirani. U mnogim slučajevima sinkronizacija je napravljena na način da se nikada ne uključuje zeleno svijetlo za obje trake istovremeno. Intervali između dva zelena indikatora su sinkronizirani kako bi bio osiguran stalan razmak između dva vozila u različitim trakama [1].

3.4. ALINEA algoritam

Ubraja se u skupinu lokalnih algoritama. Princip funkcioniranja mu je dosta jednostavan, a daje zadovoljavajuće rezultate s obzirom na implementaciju i jednostavnostnjegove prirode. Njegova važnost se očituje pri bilo kojoj analizi i usporedbi algoritma za upravljanje priljevnim tokovima. Predstavlja najkorišteniji algoritam na europskom sustavu za autoceste. ALINEA je tip algoritma koji se temelji na logičkoj strukturi povratne veze od strane detektora glavnog toka autoceste. Cilj ovog algoritma je dinamički održati razinu zauzeća kapaciteta dijelova autoceste na koju se prelijeva sporedni tok ispod predefinirane granice zauzeća dotičnog toka [1].ALINEA algoritam radi na principu da je na svakoj traci autoceste samo jedan detektor. On se postavlja niže od prilaza autocesti na kojoj se nalazi ugrađeni algoritam [8].



Slika 4. Lokacija detektora algoritma ALINEJA u odnosu na klasični [1]

ALINEA algoritam je drukčiji od drugih algoritama za upravljanje priljevnim tokovima zbog toga što koristi sustav zatvorene petlje u upravljanju, dok ostali sustavi koriste otvorene petlje. ALINEA algoritam koristi jednadžbu pri određivanju stupnja propuštanja tokova koji se prilijevaju u glavni tok autoceste:

$$r(t) = r(t-1) + K_r\,[0\text{-}0_{izlaz}(t)], \qquad (1)$$

gdje je :

O - željeni prag zauzeća kapaciteta glavnog toka(%);

0_{izlaz} – izmjereno zauzeće u vremenskom periodu *t*(%);

r(t – 1) – dobiveni stupanj propuštanja u prethodnom vremenskom periodu;

Kr- regulatorni parametri; tvorci algoritma preporučuju postavljanje vrijednosti ovog parametra na 70 vph [9].

Jedan od nedostataka ovoga algoritma je pretpostavka kako vozilo prolazi udaljenost od zaustavne linije na prilazu od detektora do detektora, prethodno pretpostavljenim intervalom. Ako je detektor previše udaljen od prilaza autoceste ili je pretpostavljeni vremenski interval premalen, kako bi pretpostavka bila točna, koristit ćemo sljedeću jednadžbu :

$$r(t) = r(t\text{-}1) + K_r[O - O_{izlaz}(t)] + K_p[O\text{-}O_{izlaz}(t)] + \gamma[q_{ulaz}(t) - q_{ulaz}(t - 1)],$$

$$Kr$$

$$K_p = \delta/(T\alpha) \text{ - > } 0$$

$$\alpha = \frac{\mu}{100\lambda},$$

T – interval uzrokovanja (s)

μ – broj kolničkih traka

λ- daljina vozila (km)

q_{ulaz} – trenutačno zauzeće kapaciteta autocesta u vremenskom periodu *t(%)*

γ – koeficijent kalibracije ulaza.[21]

3.5. SWARM

Na samom početku SWARM (eng. *System-Wide AdaptiveRampMetering*) algoritam bio je razvijen kao dio napredne tehnologije općenitog upravljanja priljevnim tokovima pod nazivom ATMS (eng. *Advanced TransportationMenagment System*). Predstavlja kompetitivan i prometno ovisan algoritam upravljanja priljevnim tokovima. Osnovni mu je cilj zadržati gustoću glavnog toka ispod definirane razine u stvarnom vremenu.

Algoritam SWARM koristi dvije vrste upravljačke logike. S pravom ih zbog njihove kompleksnosti možemo nazvati i zasebnim algoritmom funkcionalno objedinjenim u jedan. Prva vrsta upravljačke logike obuhvaćena je SWARM 1 algoritmom te se obavlja na globalnoj razini. Djeluje na cijeli sustav korištenjem predviđene vrijednosti gustoće na lokacijama uskih grla za upravljanje. Pozitivna strana SWARM1 algoritma je mogućnost predviđanja lokacije uskoga grla na autocesti uz pomoć povijesnih podataka o parametrima glavnoga toka. Ukupni SWARM algoritam je više preventivan, a manje odzivan na već gotov slučaj zagušenja. Ukupna kvaliteta ovisi o stupnju predviđanja nastajanja uskih grla.

U algoritmu SWARM 1 gustoća na uskim grlima predviđa se upotrebom linearne regresije na podatke prikupljene u neposrednoj prošlosti te primjenom procesa Kalmanovog filtriranja. Parametar T_{crit} predstavlja vremenski raspon predviđanja koji najčešće iznosi nekoliko minuta. Parametar *Višak gustoće* predstavlja razliku između predviđene gustoće i unaprijed definirane granične gustoće koja predstavlja razinu zasićenja na uskom grlu. Višak gustoće je zamijenjen s (trenutnim) parametrom potrebne gustoće kako bi se izbjegla gustoća u $T_{crit.}$[10].

Potrebna gustoća = Trenutna gustoća – (Višak gustoće/ T_{crit})

Odgovarajuće smanjenje prometnog volumena na pojedinom detektoru računa se:

Smanjenje prometnog volumena = (Lokalna gustoća – potrebna gustoća)*(Broj traka)*(Udaljenost do slijedećeg sektora)

Smanjenje prometnog volumena (ili višak ako je lokalna gustoća manja od potrebne gustoće) distribuira se prema drugim ulaznim rampama u sektoru u skladu s unaprijed definiranim distribucijskim faktorima baziranim na potražnji, duljini reda čekanja i dr.

Na lokalnoj razini funkcionira SWARM2B algoritam. Koristi stvarno vremenske podatke o lokalnim prometnim uvjetima prikupljenim senzorom postavljenim na početku svake ulazne rampe. Predstavlja tradicionalni lokalni sustav za upravljanje ulaznim rampama. Može se mijenjati ovisno o lokaciji i situaciji te može biti bilo koji od postojećih lokalnih upravljačkih sustava. Koristi tradicionalne empiričke metodologije za lokalno upravljanje priljevnim tokovima na prilazima autoceste. Koeficijent mjerenja u ovom algoritmu prilagođen je na način prema kojemu se gustoća prometnog toka zadržava ispod kritične.

Napomenuti algoritmi se paralelno odvijaju te daju različite vrijednosti pri čemu nadređeno SWARM upravljanje odabire minimalnu vrijednost kao konačnu. Danas je SWARM algoritam jedan od najboljih algoritama u upravljanju priljevnim tokovima koji se primjenjuje u praksi.

4. Primjena metoda umjetne inteligencije u upravljanju priljevnim tokovima

Danas su moderne autoceste pod utjecajem pojačane prometne potražnje i sve teže mogu ispuniti traženu razinu usluge. U većini slučajeva nema ni prostora za gradnju dodatne infrastrukture. Kako bismo se nosili s velikim svakodnevnim promjenama u prometnoj potražnji, za upravljanje priljevnim tokovima primjenjuju se razni pristupi s autonomnim svojstvima kao što je automatsko ispravljanje (samoučenje, eng. *self-learning*). Trend pojačane prometne potražnje je posebno aktivan u gusto naseljenim područjima gdje se dnevna prometna zagušenje događaju redovno tijekom špice. Zagušenje je važan problem u cestovnom prometu jer može značajno smanjiti razinu uslužnosti (LOS – *Levelof Service*) korisnicima prometa. Prometno zagušenje izaziva kašnjenje koje uzrokuje gubitak vremena vozačima i putnicima kao i pojačanu potrošnju goriva.

Uzimajući u obzir gore navedene činjenice, jasno je kako je važno razviti učinkovite metode upravljanje prometom autoceste kako bi se ublažilo zagušenje i osigurao inicijalno planiran LOS. Takve metode kontrole prometa su u djelokrugu Inteligentnog transportnog procesa s korištenjem informacijsko-komunikacijske infrastrukture i uređaja, a danas su tome dodana i autonomna svojstva kao što su samoučenje, samoprilagodba, samokonfiguracija, i druga.

U prethodnom poglavlju opisan je rad najraširenijih algoritama za upravljanje priljevnim tokovima u operativnoj primjeni. Cilj ovoga rada je i pokušaj stvaranja novog kontrolora koji će biti baziran na neuronskim mrežama i neizrazitoj logici. U umjetnoj inteligenciji ovi sustavi se nazivaju hibridnim. Izabrana je ova metoda poglavito iz razloga što se danas rijetko koriste metaheurističke metodologije u rješavanju razmatranog problema.

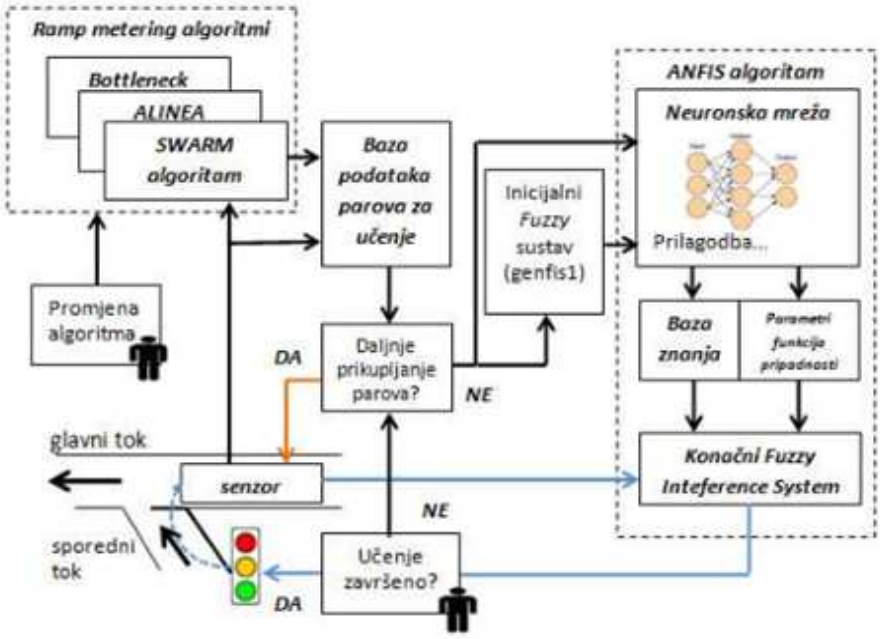
4.1. Adaptivni *neuro-fuzzy* algoritam u upravljanju priljevnim tokovima

Sinteza neizrazite logike i neuronskih mreža označava se u MATLAB okruženju akronimom ANFIS. Akronim označava *adaptiveneuro-fuzzyinference system*, tj. algoritam koji na principu umjetnih neuronskih mreža modelira parametre sustava neizrazitih pravila odnosno FIS-a (eng. *Fuzzyinteference system*). Parametri su u obliku AKO-ONDA pravila, značajke funkcija pripadnosti, broj ulaza, i slično. Sve ga to čini svojevrsnom bliskom kopijom ljudskog rasuđivanja o upravljanju prometnim tokovima na autocesti kao što je već ranije opisano. Motiv zbog kojeg rabimo ovaj algoritam je nemogućnost određivanja preciznih granica funkcije pripadnosti pri pojedinim ulazima FIS-a. Osnovna i temeljna ideja ANFIS algoritma je da se na temelju poznatih ulazno/izlaznih skupina podataka konstruira FIS pri kojemu se funkcije pripadnosti prilagođavaju samostalnim korištenjima algoritama povratnog rasprostiranja pogreške ili kombinacije s metodom najmanjih kvadrata – hibridni algoritam učenja. Prilagodbe omogućuju neizrazitom sustavu da uči na temelju ulazno/ izlaznih skupina podataka.

Rad ANFIS algoritma za isključivo upravljanje priljevnim tokovima je prikazan na Slici 5.Sustav upravljanja ANFIS za upravljanje priljevnim tokovima koristi jedan od već postojećih algoritama na segmentu autoceste nad kojim se primjenjuje sustav upravljanjapriljevnim tokovima.U našem slučaju uporabljen je SWARM algoritam. SWARM algoritam ili bilo koji dugi algoritam, funkcionira normalno, ali se ulazni i izlazni podatci procesuirani od strane algoritma bilježe u posebnu bazu podataka po principu jedan par (ulaz-izlaz) - jedan element u tablici. Zatim se na temelju tih podataka inicijalizira početni neizraziti sustav MATLAB naredbom *genfis*[2].

Adaptivna neuronska mreža prilagođava parametre funkcije pripadnosti neizraziti sustava i gradi bazu znanja na temelju baze podataka parova za učenje. Neuronska mreža stvara novi neizraziti sustav koji je prilagođen potrebnom načinu reagiranja na specifične i nespecifične situacije u prometnom sustavu autoceste. Općim „znanjem“ o upravljanju algoritam bi u teoriji trebao prepoznati situacije koje su slične situacijama kojima je prilagođen te na njih odgovarati u skladu s tim naučenim općim „znanjem“. Cilj je odrediti jesu li njegovi odgovori zaista bolji od SWARM algoritma i kako utječu na parametre prometnog sustava autoceste. Neizrazita logika bi cijelom sustavu trebala dati dodatni stupanj kvalitete u odlučivanju. Trenutak kad je „učenje“

završeno kao i pitanje odabira algoritma, odabire operater. Odabir ovisi o željenoj kakvoći djelovanja cijelog sustava te o odluci želi li se algoritam postaviti u funkciju lokalno ili globalno.



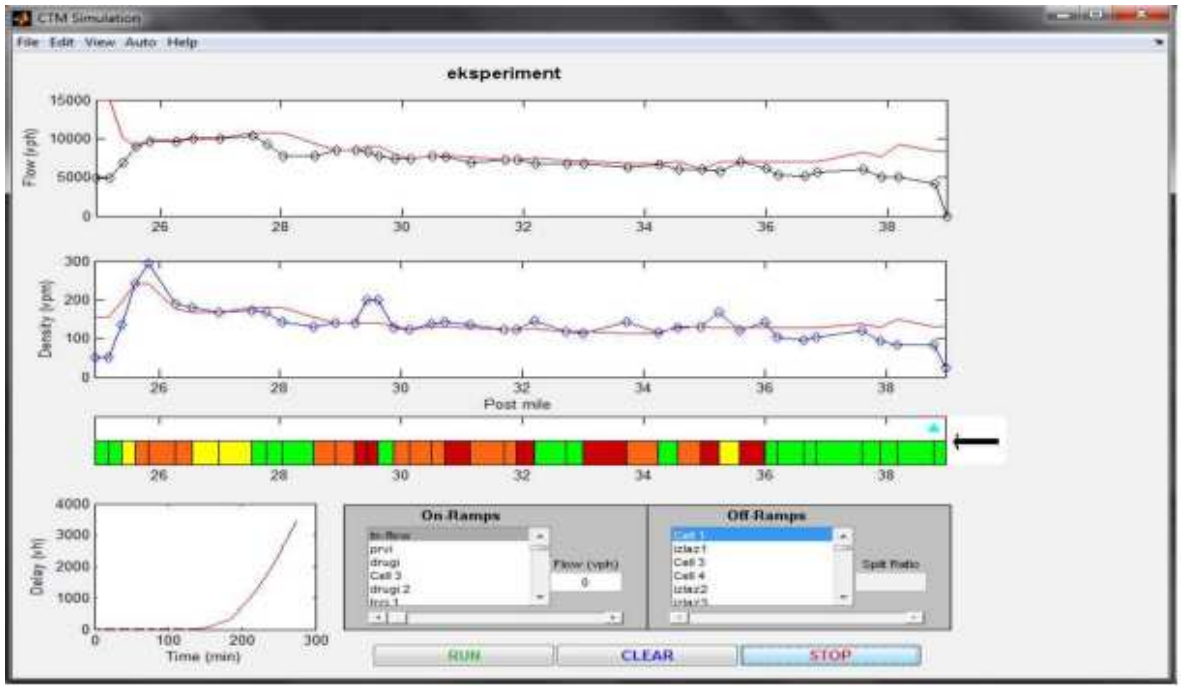
Slika 5. Koncept rada ANFIS algoritma za isključivanje upravljanja priljevnim tokovima [2]

Struktura ANFIS algoritma sastoji se od procesa izgradnje adaptivne mreže koja je u stvari velika skupina različitih unaprijednih neuronskih mreža s mogućnošću nadzornog učenja. Adaptivna mreža je mrežna struktura koja se sastoji do čvorova i usmjerenih veze putem kojih su čvorovi povezani. Čvorovi su organizirani u mrežu unutar koje su neki (ili čak svi) čvorovi prilagodljivi što znači da njihovi izlazi ovise o parametrima koji se mijenjaju kroz mrežu prolazeći kroz razne veze i čvorove koji dovode parametre do promatranog čvora. Sukladno spomenutom, primjenu vrijednosti parametara provode adaptivni i neadaptivni čvorovi mreže, ali u sprezi s pravilima učenja koji specificiraju na koji će se način ti parametri mijenjati kako bi se minimalizirala popisana mjera pogreške.

4.1.1. Metode prikupljanja podataka

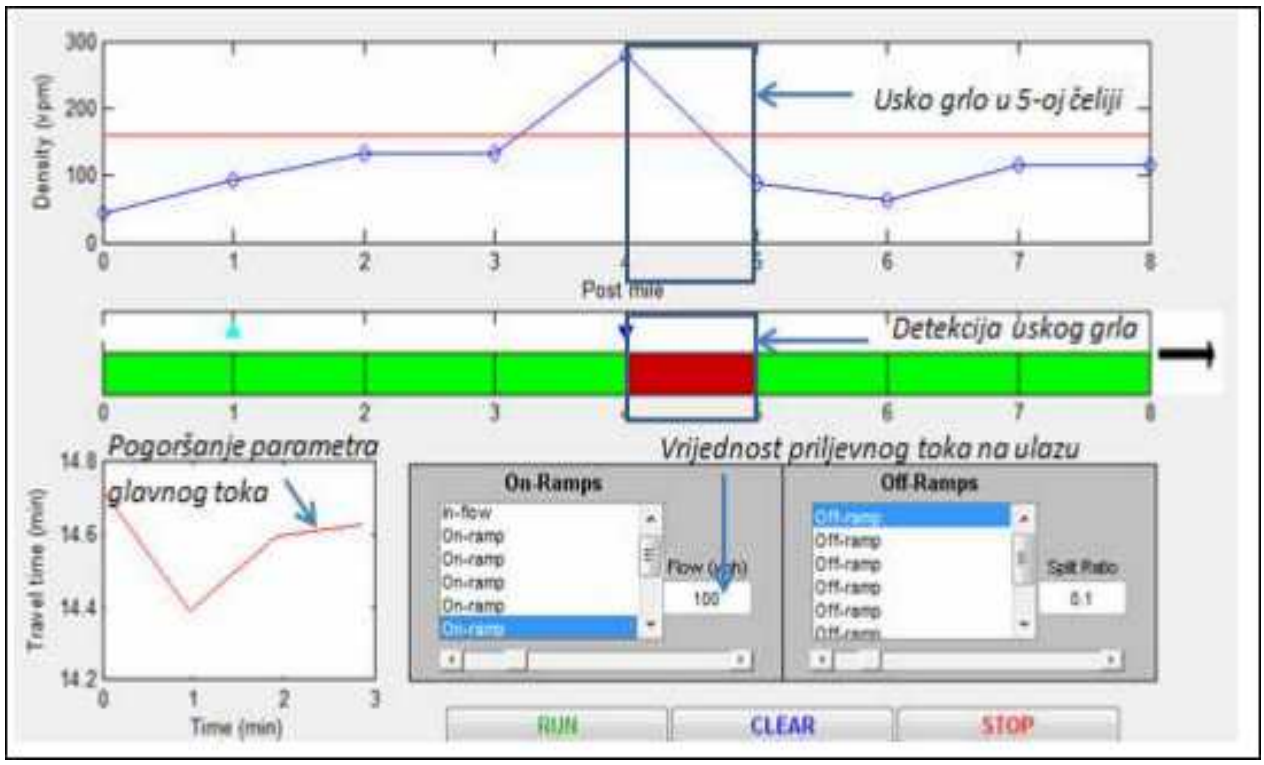
Za prikupljanje skupa podataka za učenje u prometnom modelu upravljanja priljevnim tokovima na zagrebačkoj obilaznici korišten je simulacijski program CTMSIM izrađen u MATLAB okruženju. Prije samog procesa prikupljanja podataka postavljen je hipotetski model buduće ANFIS strukture, odnosno konačno dobivenog neizrazitog sustava. Donijeli smo odluku što će biti izlaz FIS-a koji će generirati ANFIS algoritam i koji će to ulaz biti u smislu najboljeg opisivanja sustava i produkcije najmanje pogreške prilikom učenja. Izlaz ćemo definirati kao veličinu toka koju može propustiti algoritam na prilazima autoceste. Izlaze i potencijalne ulaze generirat ćemo uz pomoć CTMSIM simulacijskog alata kojega ćemo u idućem poglavlju detaljnije obraditi.

Bilo je potrebno izgraditi odgovarajući model autoceste u odgovarajućem mikrosimulacijskom alatu kako bi mogao biti dizajniran prikladni algoritam za upravljanje priljevnim tokovima na promatranoj obilaznici. CTMSIM je odgovarajući mikrosimulacijski alat između glavnih i priljevnih tokova na autocesti. Uz umjeravanje parametara navedenih prometnih tokova nudi se i mogućnost komparacije, dizajna i ugradnje različitih algoritama stupnja propuštanja priljevnih tokova. To ga čini izuzetno pogodnim za implementaciju i testiranje ANFIS algoritma, ali i drugih algoritama. Grafičko sučelje CTMSIM alata vidljivo je na Slici 6.



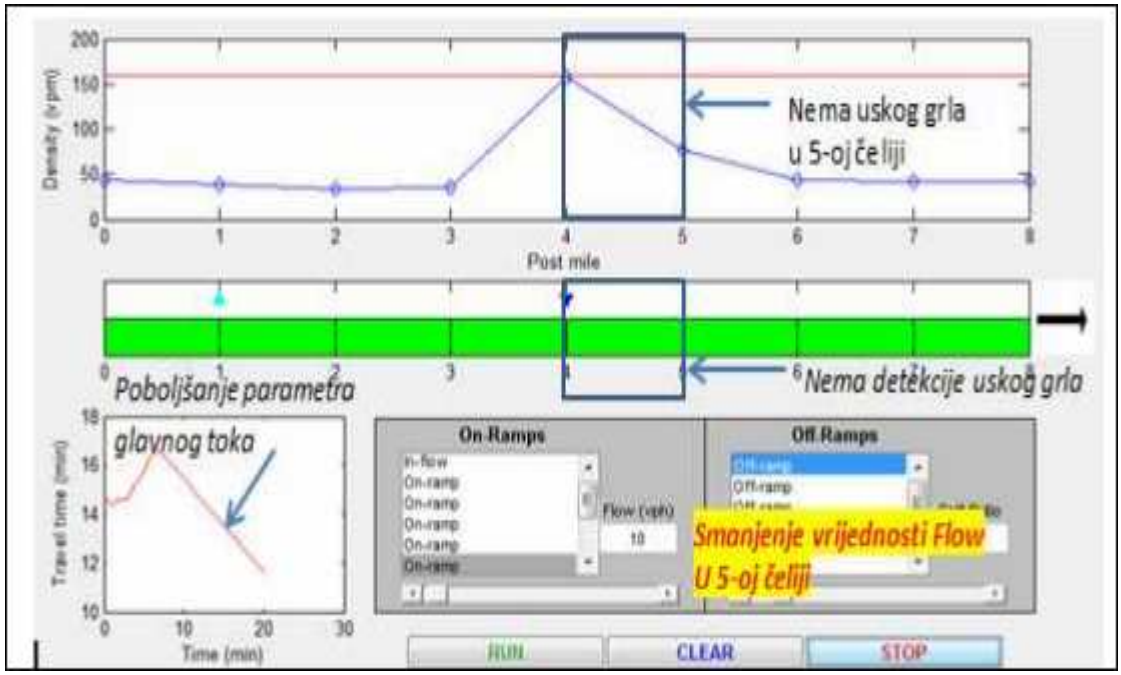
Slika 6. Sučelje CTMSIM makrosimulacijskog alata [2]

Osnovni princip rada programa očituje se kroz provođenje sljedećeg eksperimenta s jednostavnim modelom autoceste. Uzimamo 8 segmenata/ćelija pri čemu je svaki segment duljine 1 milje. Na prilazu u petom segmentu prouzrokovano je usko grlo jer smo vrijednosti priljevnog toka u tom segmentu povećali za 100 vph što je, logično, dovelo do pogoršanja parametara prometnog toka. U ovom slučaju prosječno vrijeme putovanja autocestom prikazano je na Slici 7.



Slika 7. CTMSIM prikaz detekcije uskog grla [2]

Nakon ručne korekcije priljevnog toka sa 100 vph na 10 vph, situacija je nakon 17 minuta tijekom simulacije bila kako je prikazano na Slici 8.



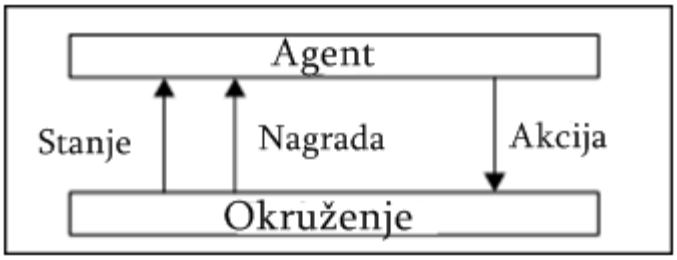
Slika 8. CTMSIM prikaz rješenja uskog grla [2]

Ovim je primjerom prikazana važnost utjecaja regulacije priljevnih tokova na parametre glavnog toka. U ovom slučaju promatralo se prosječno trajanje putovanja cijelom autocestom (eng. *Travel Time*) u minutama. Zbog ograničenja priljevnog toka u segmentu 5 sa 100 vph na 10 vph, prosječno trajanje putovanja autoceste se skratilo na 4 minute. Taj rezultat upućuje na potrebu razmatranja mogućnosti automatske regulacije priljevnih tokova pogotovo iz razloga što u našem slučaju primijenjen jednostavan model autoceste, dok su u stvarnosti sustavi autoceste znatno kompleksniji i dinamičniji. Stoga je teško s njima ručno upravljati [2].

4.2. Primjena Q-Learing algoritma

Standardni *rampmetering* algoritmi, kakva je ALINEA, ne mogu se nositi sa širokim opsegom primjene u prometnoj potražnji. Istraživači su zato počeli razvijati i primjenjivati razne pristupe inteligentne kontrole utemeljene na učenju. Naučiti reagirati na način koji se nagrađuje, znak je inteligencije. Ojačano učenje (eng. *ReinforcementLearning, RL*) je jedna od osnovnih tehnika tehnologije inteligentnih agenata (IA). Učenik ili kreator odluka je potaknut izvršiteljem i onim s čime dođe u kontakt iz okoline. Izvršitelj ima niz senzora za promatranje stanja okoline i za izvođenje potrebnih akcija kako bi primijenio stanje okoline. Najvažnije karakteristike izvršitelja su

proba i traženje pogreške te nagrada. Učenik ili autonomni izvršitelj koji osjeća svoju okolinu ili djeluje u njoj, može kroz probe odabrati optimalnu akciju ili akcije koje vode većoj nagradi. Veća nagrada ujedno znači i veću uslužnost upravljanje dionice urbane autoceste.



Slika 9. Interakcija agent-okruženje [14]

Za točnu prezentaciju interakcije, pretpostavit ćemo da izvršitelj i okolina komuniciraj u nizovima diskretnih vremenskih koraka: t=0, 1, 2, … za svaki korak *t*izvršitelj dobije određenu sliku okoline $st \in S$, gdje je S niz mogućih stanja. Sukladno tome, akcija $atA(st)$ je odobrena, gdje je $A(st)$ niz akcija koje su dostupne u stanju *st*. Korak poslije, kao posljedica njegovih akcija, izvršitelj dobije numeričku nagradu, $rt+1 \in R$ i nađe se u tom novom stanju $st+1$. Izvršitelj dobiva nagradu ili kaznu kako bi bio potaknut da se usmjeri ka finalnom stanju. Slika 9. prikazuje interakciju izvršitelj - okolina. Promjena iz jednog stanja u drugo prikazana je kao

$$S_0 \frac{a_0}{r_0} \to S_1 \frac{a_1}{r_1} \to S_2 \frac{a_2}{r_2} \to \cdots S_i \frac{a_i}{r_i} \to \cdots, \qquad (1)$$

gdje je S_i stanje u koraku i,a_i je moguća akcija dostupna u svakom stanju za vrijeme koraka i,$r_i$je nagrada koju izvršitelj dobije za vrijeme koraka i za korištenje akcije a_i. Jedno od najvećih postignuća u RL je bio razvoj TemporalDifferences Off-PolicyAlgorithm poznatog kao Q-Learning. Upravljanje priljevnim tokovima za kontrolu strategije razvijenu u ovom istraživanju izvodi izvršitelj, agent.

4.2.1. Q-Learning algoritam

Q-Learning pruža izvršitelju priliku da nauči politiku kontroliranja. Za nedeterminističke okoline *Q*- funkcija je redefinirana kao očekivana vrijednost $Q_n(s, a)$ iz prethodno definirane vrijednosti za deterministički slučaj.Primjenjujući pravilo učenja:

$$\hat{Q}_n(s,a) \longleftarrow (1-\alpha_n)\hat{Q}_{n-1}(s,a) + \alpha_n[r + \gamma \max \hat{Q}_{n-1}(s',a')], \quad (2)$$

gdje je razina učenja:

$$\alpha_n = \frac{1}{1+\text{visits}_n(s,a)}, \quad (3)$$

Q ipak konvergira*Q**,gdje je*Q** optimalna akcija za vrijednost funkcije,*Qn*(*s*, *a*) je očekivana vrijednost prethodno definirane vrijednosti za slučaj determinističke funkcije za akciju *a* i stanje *s* i $Q_{n-1}(s', a')$ je očekivana vrijednost prethodno definirane vrijednosti za novu akciju *a′* na sljedećem stanju *s′*. Parametar γ je diskontna stopa u intervalu $0 \leq \gamma \leq 1$, αn je stopa učenja, (*s*, *a*) je ažurirano stanje i akcija tijekom *n* ponavljanja, *n* (*s*, *a*) je ukupan broj posjeta za ovaj par stanje-akcija do *n* -tog ponavljanja [14].

5. Model zaobilaznice grada Zagreba

U ovom radu bit će prikazan model zaobilaznice grada Zagreba na potezu Zaprešić – Ivanja Reka. Zagreb je najvažnije i najveće prometno križanje u kojem se odvija 3'% ukupnog prometa Republike Hrvatske, ishodište je i cilj mnogih putovanja koji se danas ostvaruju preko šest pravaca autoceste(A1, A2, A3, A4, A6 i buduća A11). Njihov početak ili kraj je na obodnoj južnoj prometnici zagrebačke obilaznice. Autocesta A1, najdulja autocesta, preko čvorišta Lučko povezuju Zagreb s Karlovcem, Gospićem, Zadrom, Šibenikom, Splitom i Pločama, dok A6 preko čvora Lučko povezuje Zagreb s Rijekom najvećim lučkim središtem Republike Hrvatske. Autocesta A3 je druga autocesta po dužini u Republici Hrvatskoj. Vodi od Bregane preko Zagreba i Slavonskog Broda na granicu sa Srbijom. Autocesta A4 ide od Goričana na mađarskoj granici prema Zagrebu i povezuje Zagreb s Varaždinom i Čakovcem. Autocesta A2 proteže se od Macelja na hrvatsko-slovenskoj granici preko Krapine do čvora Jankomir. Ove autoceste su već izgrađene i nalaze se u sustavu prometne mreže šireg područja grada Zagreba. Autocesta A11 buduća je autocesta koja će kada bude dovršena povezivati gradove Sisak i Veliku Goricu sa Zagrebom i Zagrebačkom zračnom lukom. Njezina međunarodna oznaka, koja apostrofira njezinu važnost, je E70 (europska autocesta 70).

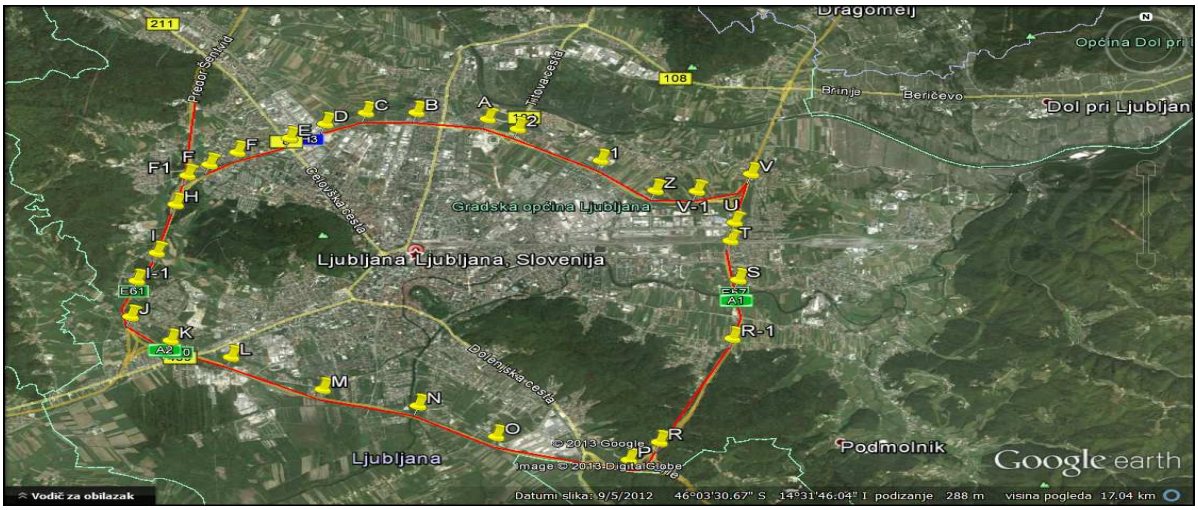


Slika 10. Prikaz spoja autocesta oko grada Zagreba [11]

Zbog svog karaktera zagrebačka obilaznica u značajnoj mjeri služi i kao dio mreže gradskog prometa, a neki dijelovi obilaznice već danas su postali gradskom prometnicom tako da oko 70% prometa koji se po njoj odvija otpada na tzv. gradski promet (posebice dionica Jankomir – Lučko i čvor Lučko). S obzirom da smo svjedoci ubrzanog razvitka šireg područja Grada Zagreba i Zagrebačke županije, može se očekivati zadržavanje visoke stope rasta prometnog opterećenja na svim spomenutim dionicama. Dakle, nije nimalo neočekivano što se u pojedinim dijelovima dana tamo skoro svakodnevno javljaju značajna prometna zagušenja. Ona su naročito izražena tijekom ljetne turističke sezone te u razdoblju blagdana sa produženim vikendima. Izrazit problem za zagušenje glavnih prometnih tokova predstavljaju prometne nesreće i njihove posljedice. Sve navedeno utječe na značajan pad stupnja prometne uslužnosti za korisnike autoceste koji su u tranzitu. Na Slici 11. prikazana je obilaznica grada Zagreba koja je u središtu teme ovoga rada. Sastoji se od 32 čvora, a proteže se od Zaprešića do Ivanja Reke u dužini od oko 44 km.



Slika 11. Zagrebačka obilaznica



Slika 12. Obilaznica Ljubljana

I u nekim europskim gradovima postoje slični problemi kakve imamo na zagrebačkoj obilaznici. Za potrebe ove analize uzeli smo primjer Ljubljane. Na Slikama 11. i 12. vidimo usporedbu dvaju gradova (gornja se odnosi na Zagreb, a donja na Ljubljanu). Na prvi pogled zapažamo da oba ova grada imaju dosta prometnih čvorova na svojim obilaznicama. Prosječna duljina jednog čvora u Ljubljani se odnosi na 1,13 km dok u Zagrebu iznosi 1,37 km. Vidljivo je da u Zagreb ima složenije čvorove od Ljubljane jer postoji više ulaza i izlaza što dodatno zagušuje prometnu mrežu. Međutim, značajna razlika je u tome što se ljubljanska obilaznica sastoji od niza autocesta i brzih cesta koji čine prsten oko Ljubljane, dok zagrebačka obilaznica nije u potpunosti zaokružena oko grada. Zaobilaznice za Ljubljanu i za Zagreb imaju veliku važnost jer ih neposredno povezuje s nekoliko susjednih zemalja. Još je jedan faktor zajednički objema zaobilaznicama: slove kao prometno najubojitije autoceste u Europi. Ljubljana naime jest *najubojitija* prijestolnica u Europi, dok autoceste u Hrvatskoj imaju najveći stupanj smrtnosti. Ako uzmemo u obzir da hrvatske autoceste imaju gotovo tri puta manje prometa nego susjedne Italija i Austrija, PGDP (prosječni godišnji dnevni promet) državnih cesta i autocesta u 2013.godini iznosio je samo 6,643 vozilašto je daleko ispod europskih vrijednosti.

S obzirom da Hrvatske autoceste imaju jako nisku prosječnu prometnu gustoću, ali visok stupanj smrtnosti, ugradnja sustava za upravljanje priljevnim tokovima u početku bi imala pretežito sigurnosnu zadaću. Na temelju navedenih svjetskih iskustava to se i predlaže. U slučaju zagrebačke obilaznice treba promatrati sustav sa stvarno-vremenskim podatcima koji su karakterizirani značajnim prometnim opterećenjima u pojedinim dobima dana na pojedinim čvorištima. Svoju punu ulogu ovaj sustav mogao bi

ostvariti pri naglim porastima prometne gustoće u špici turističke sezone. Sustav bi također uspješno mogao biti ugrađen i na prilazima brzih gradskih cesta. Na hrvatskim autocestama predlaže se primjena lokalnih algoritama za upravljanje priljevnim tokovima zbog veće udaljenosti između čvorova i relativno male gustoće prometa.

Uslijed povećanje gustoće prometa na zagrebačkoj obilaznici, trebalo bi provesti testiranje s algoritmima koji u svojoj logici rada imaju mogućnost predviđanja nastajanja uskih grla. Algoritmi s takvim mogućnostima su SWARM ili čak ANFIS uz odgovarajuću nadogradnju. To su algoritmi koji bi, teorijski gledano, mogli ostvariti dobre rezultate u upravljanju priljevnim tokovima na prilazima autoceste u glavni tok poglavito iz razloga što svoj rad temelje na prepoznavanju uzroka nastajanja uskih grla koja se periodično pojavljuju na ovoj obilaznici.

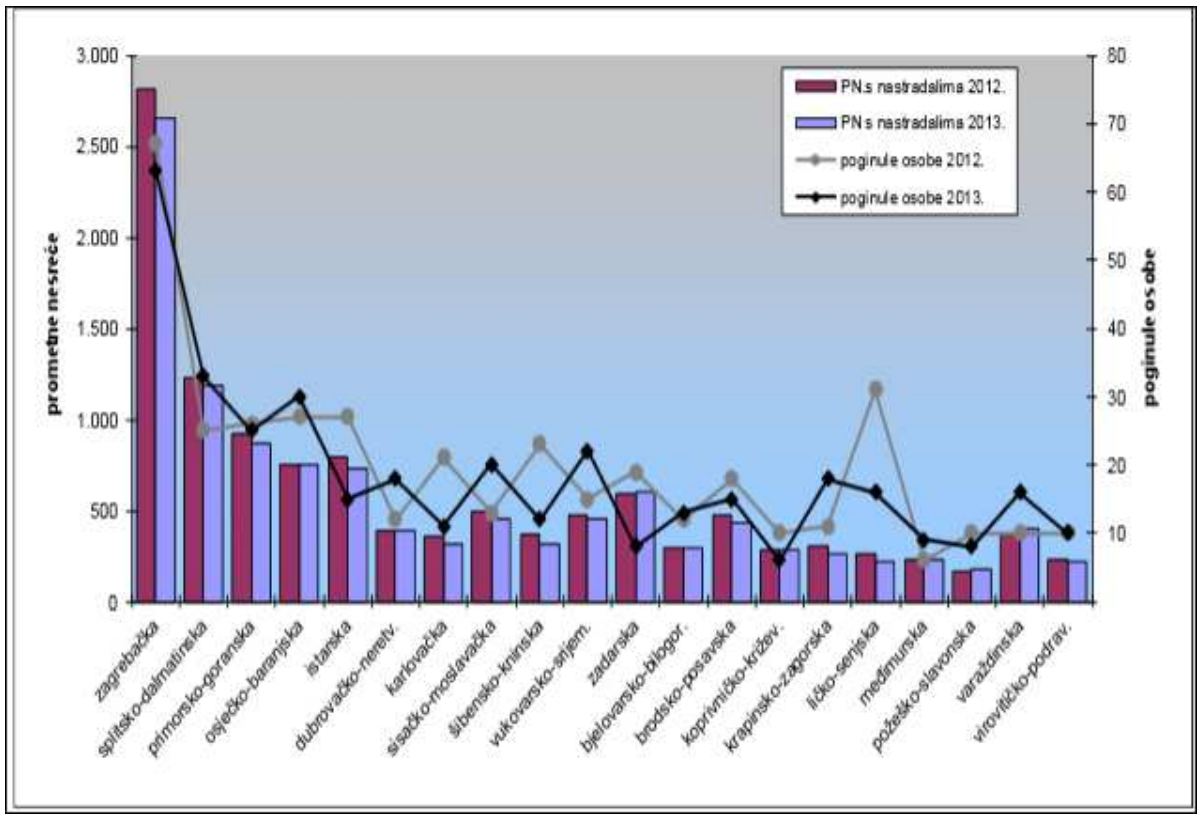
U nastavku rada izvršit će se raščlamba sustava upravljanja priljevnim tokovima na zagrebačkoj obilaznici iz razloga postojanja dnevnih vršnih opterećenja zbog ustaljenih dnevnih migracija stanovništva (migracijama do i od mjesta zapošljavanja, obrazovanja, i sl.), a što je vidljivo na Slici 13.



Slika 13. Prikaz PGDP-a u 2015. godini na hrvatskim autocestama [12]

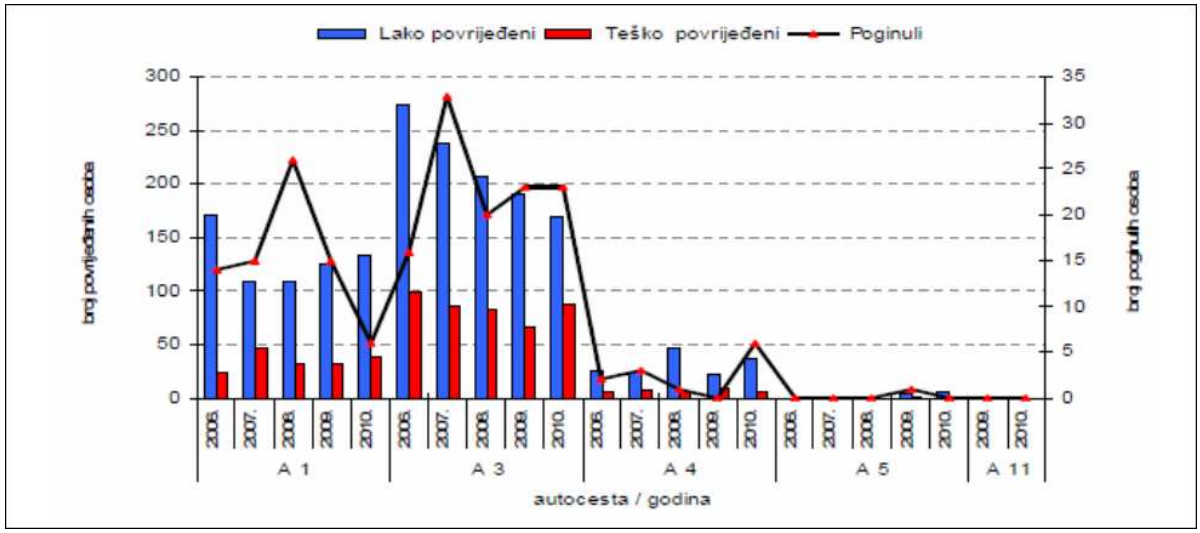
Sustav za upravljanje priljevnim tokovima imao bi značajnu ulogu u poboljšanju prometne sigurnosti na ovim osjetljivim dijelovima prometnice. Poznato je da stanje sigurnosti cestovnog prometa ovisi o gustoći prometa i značajkama prometnih smjerova. Temeljem sustava praćenja stanja sigurnosti i prikupljenih podataka uočava se pravilnost da na području s porastom gustoće prometa raste i broj prometnih nesreća, ali su najteže posljedice (poginuli i teško ozlijeđeni) razmjerno blaže nego u područjima rjeđe naseljenosti i slabije gustoće prometa. Na Slici 14. vidimo da se na područjima Zagrebačke, Splitsko-dalmatinske, Osječko-baranjske i Istarske županije događa 59% od ukupnog broja prometnih nesreća na hrvatskim cestama. U 2013. godini zabilježen je manji broj prometnih nesreća u odnosu na 2012.godinu, kao i manji broj poginulih osoba u tim nesrećama. Međutim, vidljivo je također da je broj poginulih u Zagrebačkoj

županiji znatno iznad broja poginulih po ostalim županijama. U Zagrebačkoj županiji u 2013. godini dogodilo se više od 2.500 nesreća s više od 70 poginulih osoba.



Slika 14. Prometne nesreće s nastradalim osobama i poginule osobe po policijskim upravama 2012/2013 [13].

Danas stopa na sto tisuća poginulih stanovnika iznosi 8,6. Prisjetimo se da je najdramatičnije bilo 1979. godine kada je bilo 1.605 poginulih osoba. To je bila stopa od 34 poginula na sto tisuća stanovnika. Samo u najrazvijenijim europskim zemljama koje najviše ulažu u sigurnost cestovnog prometa danas se ta stopa kreće oko četvero poginulih. Kada će sigurnost prometa na hrvatskim cestama, pa i na zagrebačkoj zaobilaznici, dosegnuti tu razinu, ovisi o naporu cjelokupnog društva, ulaganjima u povećanje sigurnosti cestovnog prometa te osobito o razvitku prometne infrastrukture svih sudionika u prometu.



Slika 15. Prikaz broja stradalih sudionika u nesrećama po autocestama u razdoblju 2006. – 2010 [7]

Budući da je u ovom radu težište na zagrebačkoj obilaznici koja je segment autocesta A3, A1, A4 i A11 iz navedenog grafa sa Slike 15.možemo uočiti podatke za cjelovitu autocestu A3. Iz tih podataka moguće jeuočiti kako je ona među najnesigurnijim autocestama u Republici Hrvatskoj. Uočavamo smanjenje broja smrtno stradalih za 10,3% dok se broj teže povrijeđenih osoba povećao za 21,1%, a lakše povrijeđenih za 0,6% u odnosu na 2009. godinu. Ti podatci sugeriraju da su potrebna daljnja ulaganja u podizanje stupnja sigurnosti na toj autocesti, a jedna od mogućih mjera je svakako i sustav upravljanja priljevnim tokovima prometa.

6. Simulacijski rezultati

U ovom poglavlju bit će prikazani i analizirani rezultati simulacije zagrebačke obilaznice. Za prikaz rezultata o prometnom modelu upravljanja priljevnim tokovima uporabljen je program CTMSIM izrađen u MATLAB-u. Za izračun simulacije uporabljeni su realni podaci iz Zagreba koje daju rezultate o priljevnom i ulaznom toku. Prikazani su rezultati uporabe ALINEA i SWARM algoritma te usporedba kada ih ne koristimo. Svi grafovi su prikazani kroz vremenski period od 24 sata. Očekivani rezultati su poboljšanje protočnosti vozila na glavnom toku te smanjenje vremena.

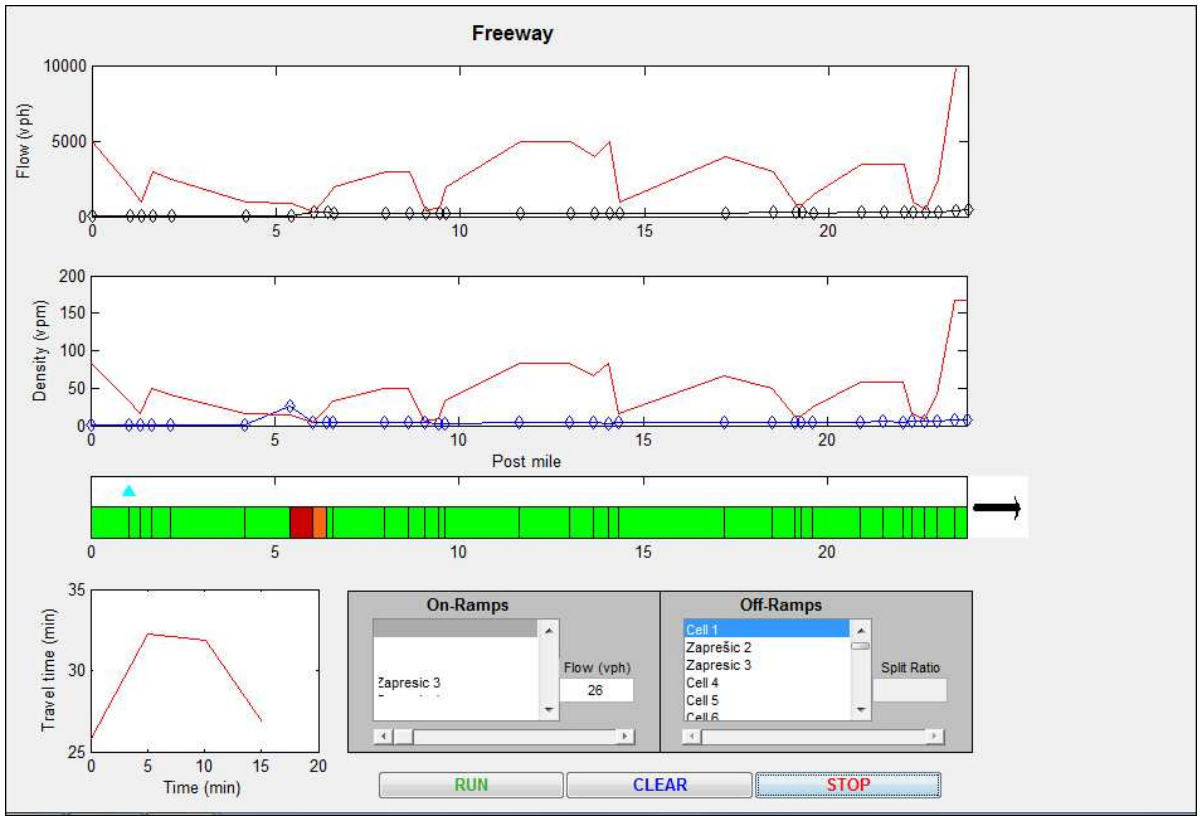


Slika 16. Zagrebačka obilaznica

6.1. CTMSIM simulator

Za prikupljanje podataka u prometnom modelu upravljanja priljevnim tokovima na zagrebačkoj obilaznici korišten je program CMTSIM izrađen u MATLAB okruženju.

Kako bismo mogli dizajnirati odgovarajući algoritam za upravljanje priljevnim tokovima na toj obilaznici, potrebno je izraditi odgovarajući model autoceste u odgovarajućem makrosimulacijskom alatu. CTMSIM je makrosimulacijski alat interakcije glavnih i priljevnih tokova na autocesti. Mikrosimulacijski alat CTMSIM služi za provedbu makrosimulacije prometnih tokova na autocesti s naglaskom na upravljanje ulaznim i izlaznim tokovima u svrhu poboljšanja parametara glavnog toka. Okruženje CTMSIM alata vidimo na Slici 17.



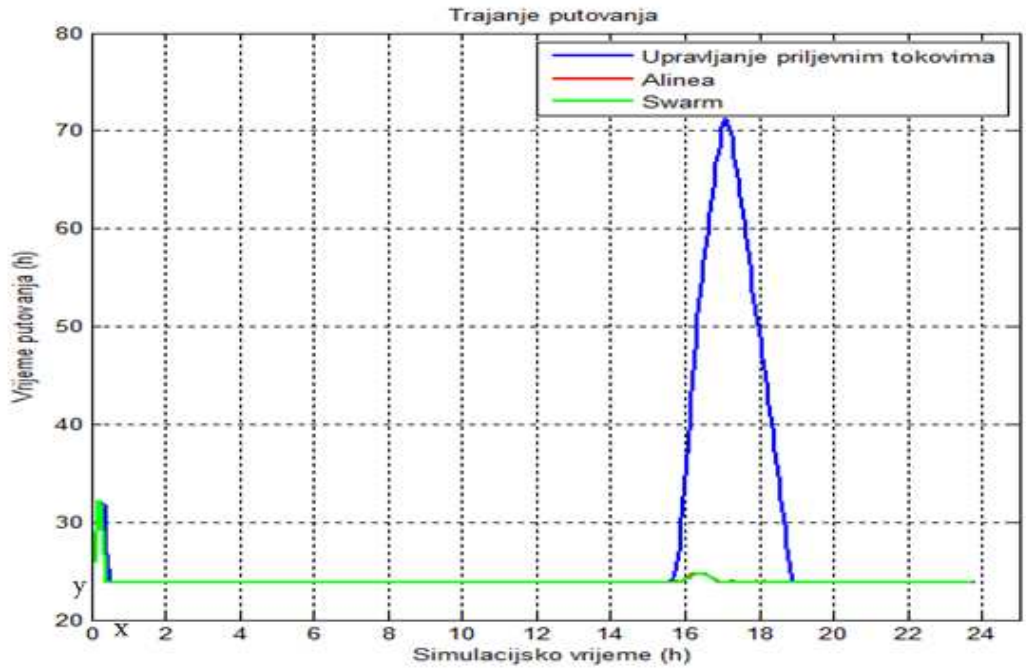
Slika 17. Sučelje CTMSIM makrosimulacijskog alata

Na Slici 17.vidimo dio početnog prozora CTMSIM simulatora u tijeku simulacije. Gornji dijagram je dijagram prometnog toka u odnosu na milje/segmenti autoceste. Također na njemu imamo dvije linije: crvenu i crnu. Crvena linija odnosi se na maksimalni protok za koji je projektirana autocesta, dok je crna linija dinamička linija koja pokazuje simulirani tijek toka u pojedinačnim segmentima koji ne može biti viši od crvene linije. Na slici je prikazan i donji dijagram koji ukazuje na prometnu gustoću po pojedinim segmentima. Crvenom linijom je označena vrijednost slobodnog toka, koja je fiksna, dok crna linija označava ponašanje prometne gustoće po pojedinim segmentima pa je dinamičke prirode. Na donjem dijelu (oznaka *density mile*) vidljivo je kako je plava dinamička linija na

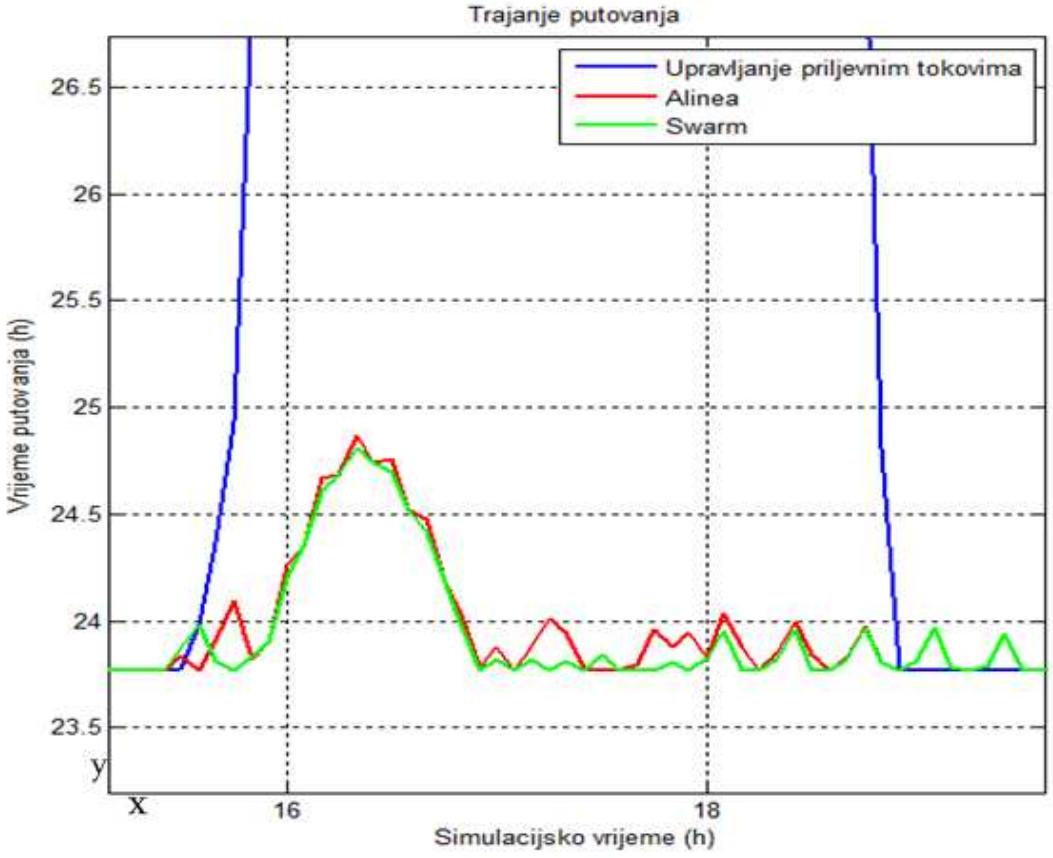
jednom dijelu povišena iznad crne linije slobodnog toka. Na tom dijelu se prikazuje početak stvaranja zagušenja tj. povećanje stvaranja prometne gustoće u tom segmentu. Taj događaj indicira donji dijagram koji segmente u kojima su vrijednosti gustoće manje od vrijednosti slobodnog toka prikazuje u obliku zelenih, narančastih, crvenih i žutih pravokutnika. Iznad vrijednosti slobodnog toka koriste se crveni pravokutnici kao indikatori nastajanja uskih grla dok narančasti pravokutnici sugeriraju pojačano pražnjenje stvorenog zagušenja. Mjesta gdje je simulacija stabilizirana na vrijednost ispod gustoće slobodnog toka prikazuju zeleni pravokutnici što ujedno znači potpuno smanjenje gustoće koje uzrokuje povećanje maksimalne propusnosti.

6.2. Rezultati simulacije

Za rezultate simulacije uspoređeni su rezultati vremena putovanja i kašnjenja koji se odnose na zagrebačku obilaznicu. Gotovi rezultati su uporabljeni u lokalnom algoritmu ALINEA (označena crvenom bojom), SWARM algoritmu (označen zelenom) i upravljanju priljevnim tokovima (označeno plavom). *Travel Time* – prosječno je vrijeme putovanja svih vozila koja žele koristiti kapacitet autoceste u odnosu prema trajanju simulacije u minutama. Vremenski period u kojem smo promatrali je 24 sata. U početku vidimo da je vrijeme putovanja u porastu, ali stagnira do prometnog zagušenja koje se događa oko 16:00 sati i traje približno 2 sata. Nakon 16:00 sati događaju se velike promjene. Algoritam bez upravljanja proljevnim tokovima počinje gotovo konstantno rasti tj. vozilo počinje provoditi duže vremena na autocesti čime se ono pokazalo kao najlošije rješenje u ovom segmentu analize. Također uporabom algoritama ALINEA I SWARM uviđamo istovjetne rezultate, a ti su se rezultati pokazali kao najkvalitetniji. Na Slici 19.prikazan je uvećani graf stanja prometa od 16:00 do 18:00 sati na kojemu je vidljiva mala razlika između ALINEA I SWARM algoritma.

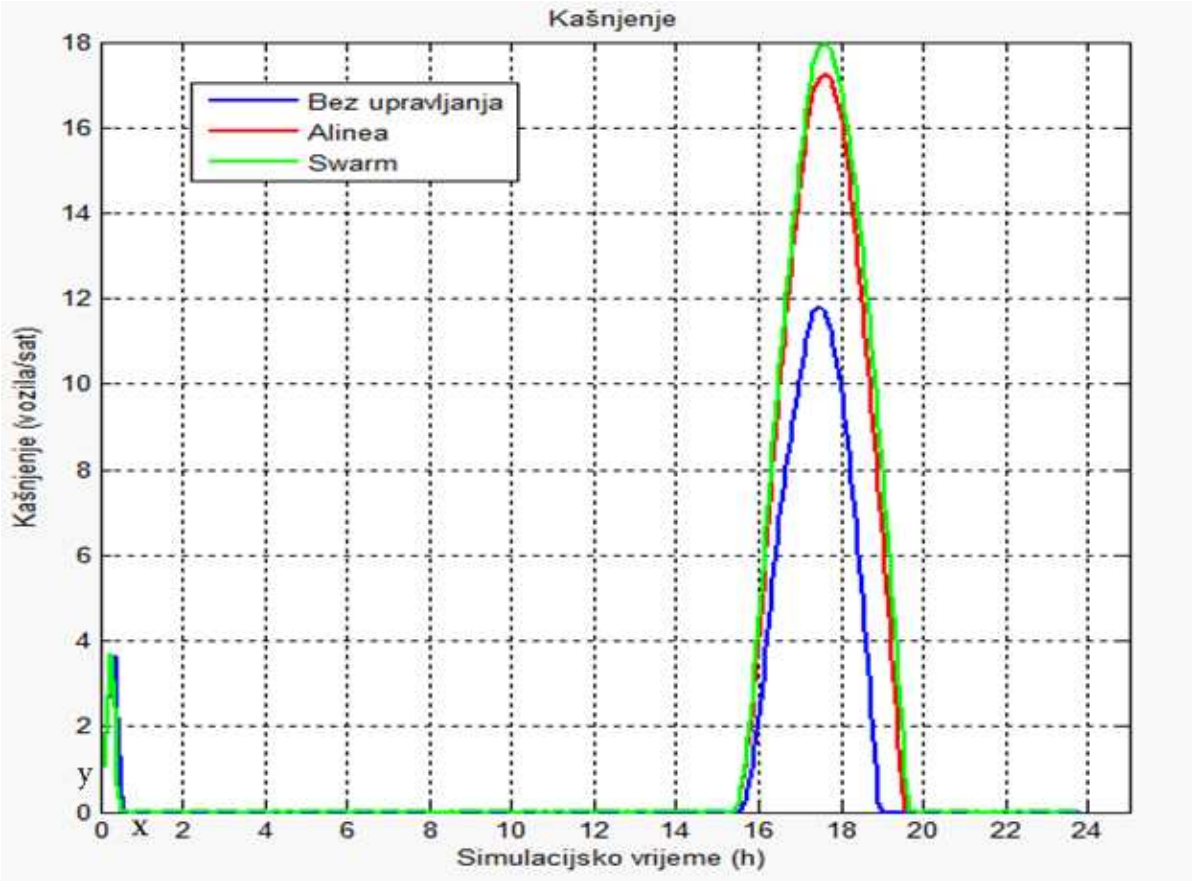


Slika 18. Odnos vremena putovanja, u odnosu prema trajanju simulacije po pojedinim algoritmima



Slika 19. Odnos vremena putovanja, u odnosu na simulacijsko vrijeme – dio od 16 do 18 sati gdje dolazi do promjene

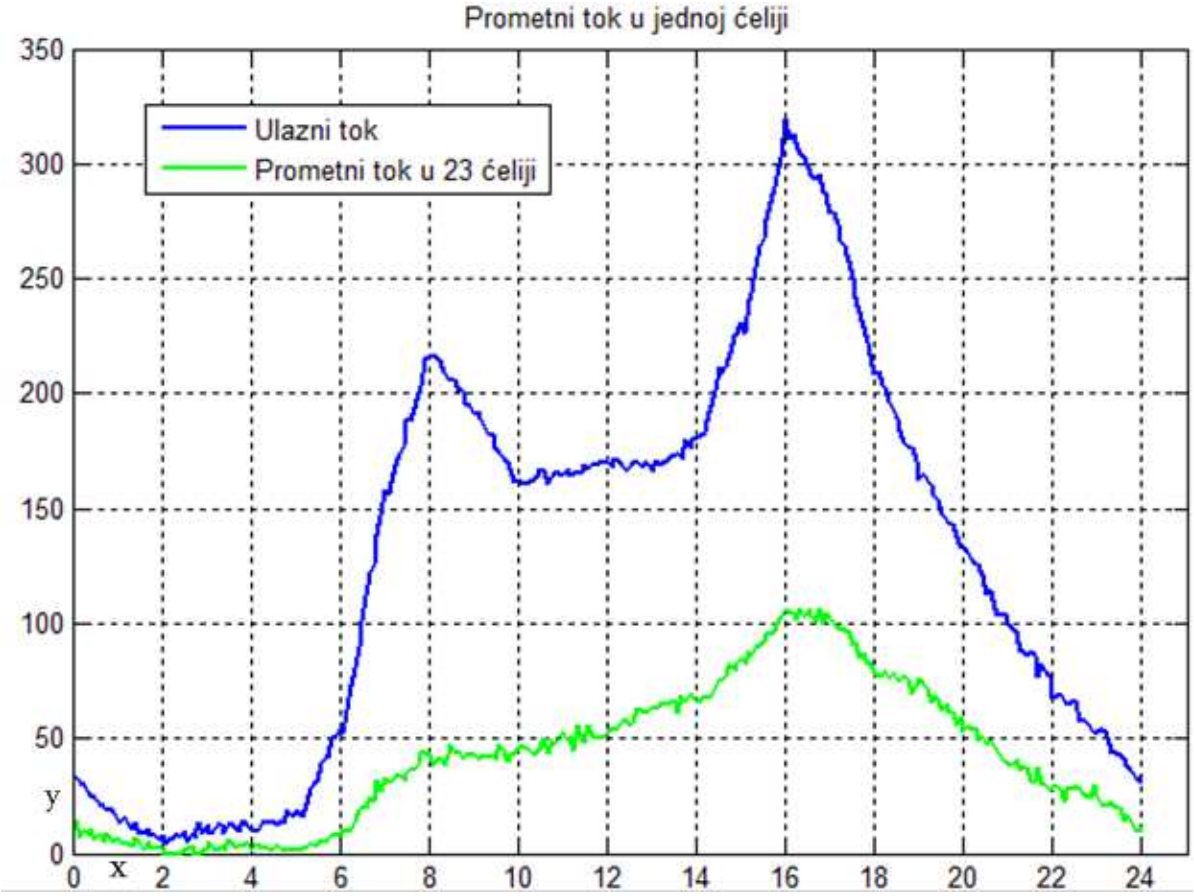
Slika 20. prikazuje odnos stvaranja kašnjenja pojedinih algoritama prema vremenu trajanja simulacije. Interval mjerenja je 24 sata. Kašnjenje definiramo kao razliku između stvarnog VHT-a (VehicleHoursTraveled) i VHT-a kojeg bi vozila ostvarila u slučaju potpuno neometanog glavnog toka pri maksimalnoj dozvoljenoj brzini. Jedinica mjerenja je vozilo po satu.



Slika 20. Graf odnosa kašnjenja i trajanja simulacije po pojedinom algoritmu

Parametri kašnjenja nam daju drukčije tumačenje kvalitete reakcije algoritma s obzirom na parametar VHT. Kašnjenje je puno opsežniji parametar od VHT parametra. VHT prati skup vozila glavnog i priljevnog toka na početku i na kraju promatranog segmenta autoceste. Broj vozila na ulazu i izlazu promatranog segmenta autoceste biti će različit zbog priljeva vozila sa sporednih prilaza. Za parametre VHT je bolje što je veća i duža propusnost priljevnih tokova, jer će na kraju simulacije više vozila proći promatrani segment autoceste te će biti kraće provedeno vrijeme vozila na autocesti i prilazima. Kod parametara kašnjenja veća propusnost daje nepovoljniji rezultat jer što više automobila imamo u glavnom toku, to će dovesti do pada vrijednosti brzine glavnog toka i uzrokovati kašnjenje. Vidimo da situacija bez upravljanja ima mali stupanj propusnosti. Razlog tome je što vozači, za razliku od situacije u gradskoj mreži gdje su brzine manje, čekaju veće

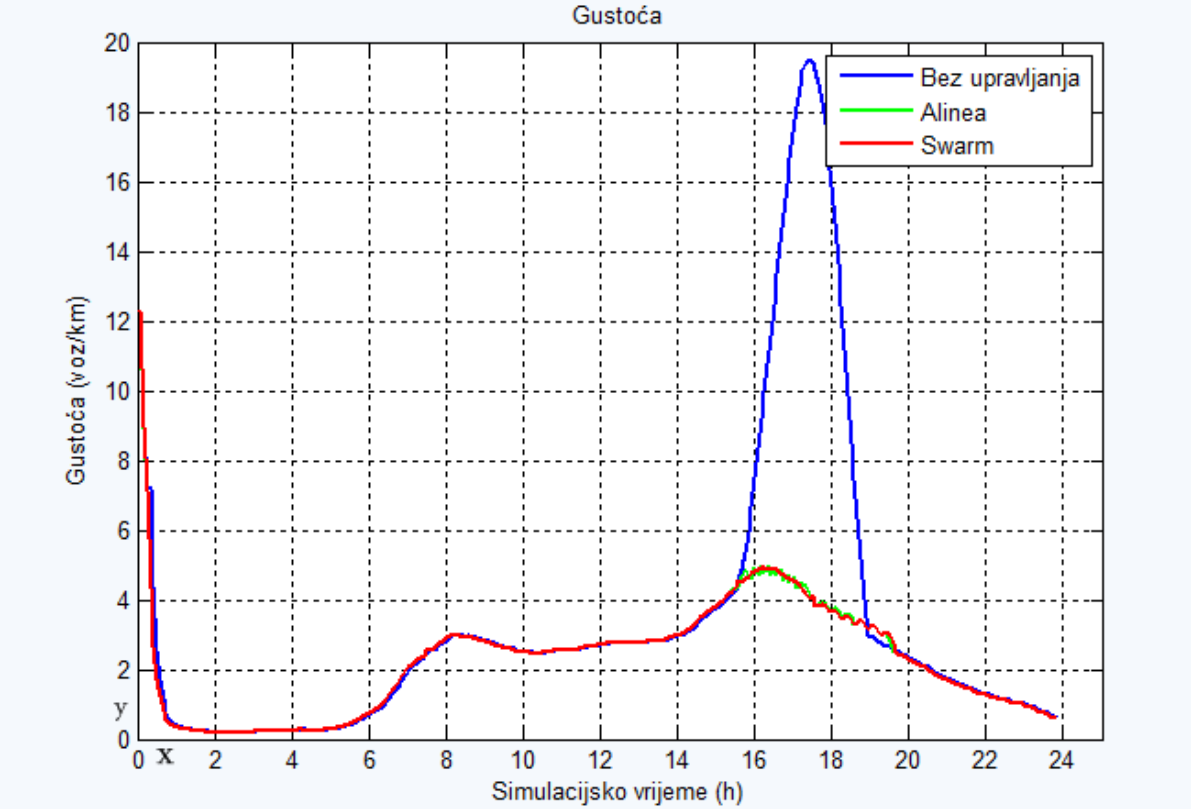
razmake između dvaju vozila koja se na autocesti brže kreću. Primjećujemo kako i ALINEA i SWARM algoritmi bilježe povećano kašnjenje zbog pojačanog propuštanja priljevnih tokova.



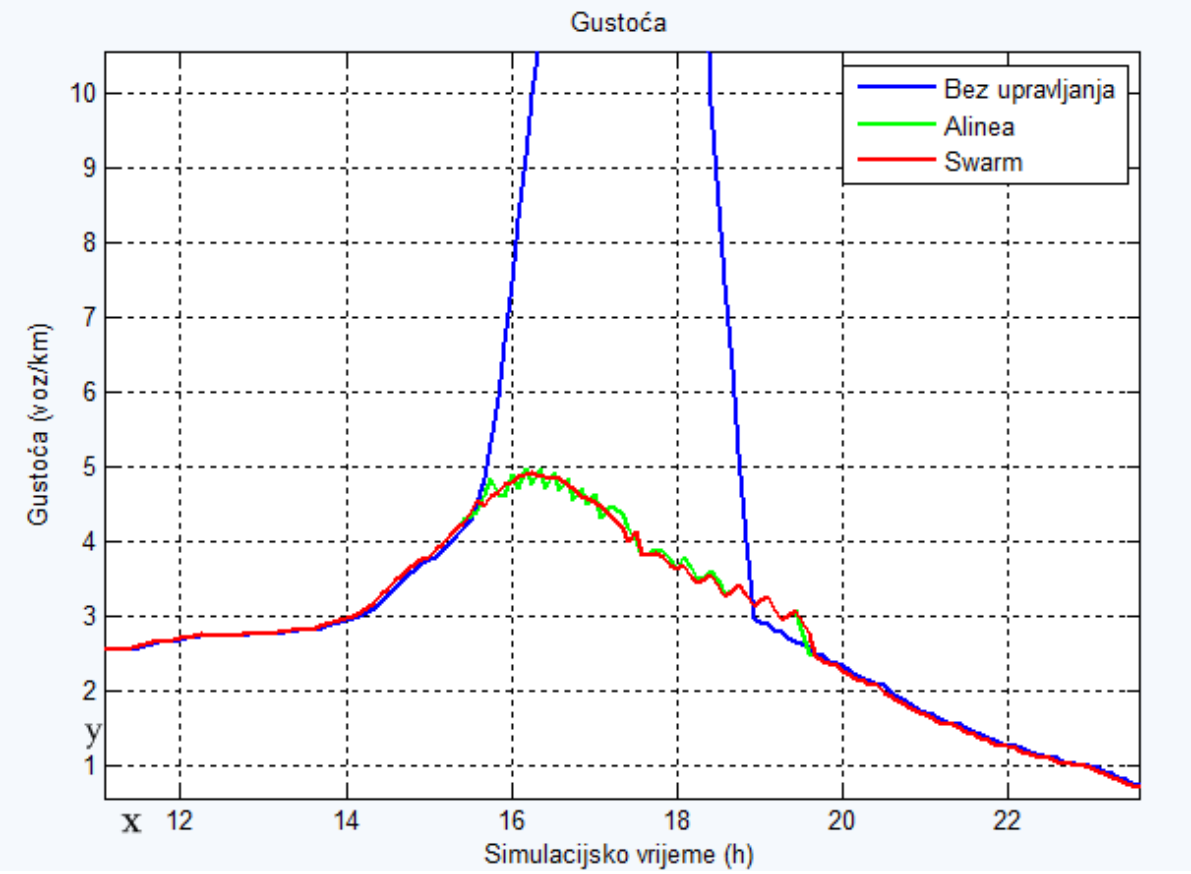
Slika 21. Prikaz glavnog toka u usporedbi d prometnim tokom jedne ćelije

Na Slici 21. prikazan je prometni tok u jednom segmentu, u ovom slučaju uzet je smo segment 23 čvora Velika Kosnica gdje se događaju najveće zagušenje u popodnevnim satima. Iz grafa na Slici 21.možemo vidjeti da je prometni tok u 23. segmentu znatno manji od ulaznog toka. Rezultat toga je zagušenje i kašnjenje jer sam segment ne može primiti toliki broj vozila u određenom vremenskom intervalu.

Sljedeći dijagram nam pokazuje gustoću prometnog toka (Slika 22.). Gustoća prometnog toka predstavlja broj vozila na jedinici duljine prometnice, po prometnoj traci, po smjerovima za jednosmjerne prometnice, odnosno u oba smjera za dvosmjerne. Pojam gustoće vezan je prostorno za odsjek ili prometnu dionicu, a vremenski za trenutno stanje. Vidljivo je da je gustoća konstantna tijekom cijeloga dana. Međutim, u vremenu od 16:00 do 18:00 sati vidljivo je povećanje na strani bez algoritma dok su se ALINEA I SWARM i u ovom slučaju pokazali kao idealno rješenje kod ovog problema.



Slika 22. Graf odnosa gustoće i trajanja simulacije po pojedinim algoritmima



Slika 23. Odnos gustoće, u odnosu na simulacijsko vrijeme – dio od 16:00 do 18:00 sati gdje dolazi do promjene

Analizom rezultata simulacije zagrebačke obilaznice dobili smo rezultate u slučaju kašnjenja, vremena putovanja i gustoće. U navedenim slučajevima vidimo da korištenje algoritama za upravljanje ima bolje rezultate za razliku od onih bez upravljanja. Jedino se očituje kod parametara kašnjenja da je veća propusnost u konačnici, nepovoljnija jer što više automobila imamo u glavnom toku to će dovesti do pada vrijednosti brzine glavnog toka i uzrokovati kašnjenje. Prikazana je situacija gdje bez upravljanja imamo mali stupanj propusnosti te kako ALINEA i SWARM algoritmi bilježe povećano kašnjenje zbog pojačanog propuštanja priljevnih tokova. Prikazani rezultati pokazuju da je uporabom algoritama upravljanja priljevnim tokovima urbanih autocesta moguće dobiti bolje rezultate uslužnosti prometa na simuliranom modelu zagrebačke obilaznice te da oni lakše rješavaju očekivane prometne probleme.

7. Zaključak

Kao što tema (naslov) ovoga rada govori, odnosno kako je u uvodu najavljeno, u ovome raduprikazana je, a zatim i napravljena usporedba metoda upravljanjapriljevnih tokova na primjeru zagrebačke obilaznice. Cilj rada je izvršiti raščlambu sustava upravljanja priljevnim tokovima na zagrebačkoj obilaznici zbog postojanja dnevnih vršnih opterećenja koja se pojavljuju kao rezultat ustaljenih dnevnih migracija Zagrepčana do i od mjesta zapošljavanja ili obrazovanja. Podatci o smrtnosti u prometu u Zagrebačkoj županiji sugeriraju da su potrebna nova i veća ulaganja u podizanje stupnja sigurnosti na toj autocesti, a jedna od mogućih mjera za ostvarenje toga cilja je svakako i sustav upravljanja priljevnim tokovima prometa. Predložene mogućnost rješavanja navedenih prometnih problema vezane su za uporabu informacijsko-komunikacijskih tehnologija i novousvojenih kompleksnih sustava i procesa.

U slučaju zagrebačke obilaznice potrebno je u prvom redu promatrati sustav sa stvarno-vremenskim podatcima koji su karakterizirani značajnim prometnim opterećenjima u pojedinim dobima dana na pojedinim čvorištima, a punu bi ulogu sustav mogao ostvariti pri naglim porastima promete gustoće u jeku turističke sezone. Općenito na hrvatskim autocestama struka predlaže primjenu lokalnih algoritama za upravljanje priljevnim tokovima zbog veće udaljenosti između čvorova i relativno male gustoće prometa.

Za prikaz rezultata o prometnom modelu upravljanja priljevnim tokovima uporabljen je program CTMSIM izrađen u MATLAB-u. Za izračun simulacije uporabljeni su realni podatci iz Zagreba koji daju rezultate priljevnom i ulaznom toku. Kako bismo mogli dizajnirati odgovarajući algoritam za upravljanje priljevnim tokovima na toj obilaznici, izradili smo odgovarajući model autoceste u CTMSIM makrosimulacijskom alatu u interakciji glavnih i priljevnih tokova na autocesti. Taj mikrosimulacijski alat poslužio je za provedbu makrosimulacije prometnih tokova na autocesti s naglaskom na upravljanje ulaznim i izlaznim tokovima u svrhu poboljšanja parametara glavnog toka. Prikazani surezultatiuporabe ALINEA i SWARM algoritama te usporedba kada ih ne koristimo. Svi rezultati su prikazani kroz vremenski period od 24

sata, a očekivali smo poboljšanje protočnosti vozila (prometa) na glavnom toku te smanjenje vremena putovanja.

Za rezultate simulacije uspoređeni su rezultati vremena putovanja i kašnjenja na zagrebačkoj obilaznici. Rezultati u lokalnom algoritmu ALINEA,SWARM te upravljanju priljevnim tokovima pokazuju u početnim periodima kako je vrijeme putovanja u porastu, ali stagnira do prometnog zagušenja 16:00 – 18:00 sati. Nakon 16:00 sati događaju se, naime, promjene. Algoritam bez upravljanja proljevnim tokovima počinje značajno rasti zbog čega pojedino vozilo počinje provoditi duže vremena na autocesti. Time se, naravno, to pokazalo kao najlošije rješenje u ovom segmentu analize. Nadalje, uporabom algoritama ALINEA i SWARM uviđamo istovjetne rezultate, a ti su se rezultati pokazali kao najkvalitetniji. Analize su također pokazale da je ostvarena mala razlika između ALINEA I SWARM algoritma.

Analizom rezultata simulacije usporedili smo rezultate u slučaju kašnjenja, vremena putovanja i gustoće. Iz tih rezultata jasno se vidi da uporaba algoritama za upravljanje priljevnim tokovima daje uočljivo bolje rezultate od onih bez upravljanja. Kod parametara kašnjenja veća je propusnost zapravo nepovoljnija jer što je veći broj automobila u glavnom toku, to će se odraziti na pad brzine glavnog toka i onda time uzrokovati kašnjenje. Prikazana je situacija bez upravljanja koja rezultira niskim stupnjem propusnosti, a zatim situacija kako ALINEA i SWARM algoritmi bilježe povećano kašnjenje zbog pojačanog propuštanja priljevnih tokova. Prikazani rezultati kroz simulacije upućuju da korištenje algoritama ipak daje bolje rezultate na način da lakše rješavaju prometne probleme.

Literatura

1. Galić, I.: Analiza metoda upravljanja priljevnim tokovima urbanih autocesta, završni rad, Fakultet prometnih znanosti, Zagreb 2013.

2.Gregurić, M.:Upravljanje priljevnim tokovima na zagrebačkoj obilaznici, diplomski rad Fakultet prometnih znanosti, Zagreb 2011.

3.Galović, B., Marušić Ž., Gurić J.: Rukovođenje kriznim situacijama kod prometnih zagušenja, Hrvatska akademija znanosti i umjetnosti Zagreb 2007.

4. http://hac.hr/odnosi-s-javnoscu/informacije-i-obavijesti/nova-obilaznica-grada-zagreba (lipanj, 2015)

5. http://wol.jw.org/hr/wol/d/r19/lp-c/102005848#h=17 (lipanj 2015.)

6. Goodwin, P.:Utilities' streetworksandthecostoftrafficcongestion, University oft he West ofEngland, Bristol,2005.

7.Gregurić, M., Buntić, M., Škorput, P., Ivanjko E., Mandžuka S.: CooperativeRampMeteringin urban areas, InteligenttransportationsystemsdepartmentFacultyof transport andtrafficsciences, University of Zagreb, 2013.

8. LianyuChu, XuYang, Optimizationofthe ALINEA Ramp-meteringControlUsingGeneticAlgorithmwith Micro-simulation, Transport Research bord, AnnualMeeting, 2003

9.http://www.ltrc.lsu.edu/TRB_82/TRB2003-002400.pdf (lipanj 2015.)

10. Pandža H.: Kooperativno upravljanje priljevnim tokovima zagrebačke obilaznice, diplomski rad, Fakultet prometnih znanosti, Zagreb, 2014.

11.http://hac.hr/ (srpanj 2015,)

12. http://hac.hr/sites/hac.hr/files/cr-collections/1/pgdp_2014.pdf

13. Bilten o sigurnosti cestovnog prometa, Ministarstvo unutarnjih poslova, Zagreb 2014.

14. Ivanjko E., KoltovskaNečoska D., Gregurić M., Vujić M., Jurković G., Mandžuka S.: RampMeteringControlBased on the Q-LearningAlgorithm, CyberneticsandInformation

Technologies, SpecialIssue on ControlingTransportation Systems, Vol. 15 (2015), No. 5; pp. 88-97, DOI: 10.1515/cait-2015-0019, 2015.

Popis kratica

ITS	*Asynchronous Transfer Mode*	Inteligentni transportni sustavi
TT	*Travel time*	Vrijeme putovanja
VHT	*Vehiclehoursetravelled*	Vrijeme putovanja u satima
VKT	*Vehiclekilometerstravelled*	Kilometri koje je prešlo vozilo
LOS	*Levelofservice*	Razina usluge
TTS	*Time to spent*	Ukupno vrijeme putovanja svih vozila
TTD	*Total travel distance*	Ukupna udaljenost putovanja
TTT	*Total travel time*	Ukupno vrijeme putovanja
RS	*Road side*	Strana cestovne prometnice
TWT	*Total waiting time*	Ukupno vrijeme čekanja
PGDP		Prosječni godišnji dnevni promet
FIS	*Fuzzyinteference system*	
RL	*ReinforcementLearning*	Ojačano učenje
IA	*Intelligent agent*	Inteligentni agent

Popis slika

Slika 1. Stanja na zagrebačkoj obilaznici tijekom zagušenja.....4

Slika 2. Mjesto formiranja uskog grla i efekti preljeva prometa [2].....7

Slika 3. Osnovna upravljačka instalacija ulazne rampe na dijelu autoceste [1].....11

Slika 4. Lokacija detektora algoritma ALINEJA u odnosu na klasični [1] 15

Slika 5. Koncept rada ANFIS algoritma za isključivanje upravljanja priljevnim tokovima [2] 21

Slika 6. Sučelje CTMSIM makrosimulacijskog alata [2] 22

Slika 7. CTMSIM prikaz detekcije uskog grla [2].....23

Slika 8. CTMSIM prikaz rješenja uskog grla [2].....24

Slika 9. Interakcija agent-okruženje [14].....25

Slika 10. Prikaz spoja autocesta oko grada Zagreba [11] 27

Slika 11. Zagrebačka obilaznica 28

Slika 12. Obilaznica Ljubljana.....29

Slika 13. Prikaz PGDP-a u 2015. godini na hrvatskim autocestama [12].....31

Slika 14. Prometne nesreće s nastradalim osobama i poginule osobe po policijskim upravama 2012/2013 [13].....32

Slika 15. Prikaz broja stradalih sudionika u nesrećama po autocestama u razdoblju 2006. – 2010 [7] 33

Slika 16. Zagrebačka obilaznica 34

Slika 17. Sučelje CTMSIM makrosimulacijskog alata.....35

Slika 18. Odnos vremena putovanja, u odnosu prema trajanju simulacije po pojedinim algoritmima.....37

Slika 19. Odnos vremena putovanja, u odnosu na simulacijsko vrijeme – dio od 16 do 18 sati gdje dolazi do promjene.....37

Slika 20. Graf odnosa kašnjenja i trajanja simulacije po pojedinom algoritmu.....38

Slika 21. Prikaz glavnog toka u usporedbi d prometnim tokom jedne ćelije.....39

Slika 22. Graf odnosa gustoće i trajanja simulacije po pojedinim algoritmima 40

Slika 23. Odnos gustoće, u odnosu na simulacijsko vrijeme – dio od 16:00 do 18:00 sati gdje dolazi do promjene 41

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000
Zagreb
Vukelićeva
4

METAPODACI

Naslov rada: Usporedba metoda upravljanja priljevnim tokovima na primjeru zagrebačke obilaznice

Autor: Ivana Galić

Mentor: doc. dr. sc. Edouard Ivanjko

Naslov na drugom jeziku (engleski):

Comparison of methods for ramp metering on the example of Zagreb bypass

Povjerenstvo za obranu:

- prof.dr.sc. Sadko Mandžuka , predsjednik
- doc.dr.sc. Edouard Ivanjko , mentor
- dr.sc. Miroslav Vujić , član
- pof.dr.sc. Hrvoje Gold , zamjena

Ustanova koja je dodjelila akademski stupanj: Fakultet prometnih znanosti Sveučilišta u Zagrebu

Zavod: Zavod za inteligentne transportne sustave

Vrsta studija: sveučilišni

Naziv studijskog programa: Inteligentni transportni sustavi i logistika

Stupanj: diplomski

Akademski naziv: mag. ing. traff.

Datum obrane diplomskog rada: **25.09.2015.**

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 **Usporedba metoda upravljanja priljevnim tokovima na primjeru zagrebačke obilaznice**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 15.9.2015

(potpis)