Okruženje za simulaciju upravljanja priljevnim tokovima gradskih autocesta zasnovanih na neizrazitoj logici

Jakobović, Žana

Undergraduate thesis / Završni rad

2019

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:088490

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

Žana Jakobović

OKRUŽENJE ZA SIMULACIJU UPRAVLJANJA PRILJEVNIM TOKOVIMA NA GRADSKIM AUTOCESTAMA ZASNOVANO NA NEIZRAZITOJ LOGICI

ZAVRŠNI RAD

Zagreb, 2019.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
ODBOR ZA ZAVRŠNI RAD

Zagreb, 25. ožujka 2019.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Automatsko upravljanje u prometu i transportu**

ZAVRŠNI ZADATAK br. 5052

Pristupnik: **Žana Jakobović (0135243764)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Inteligentni transportni sustavi

Zadatak: **Okruženje za simulaciju upravljanja priljevnim tokovima gradskih autocesta zasnovanih na neizrazitoj logici**

Opis zadatka:

S obzirom na povećanje broja vozila na cestama u gradu, sve češće se koriste zaobilaznice ili gradske autoceste kako bi se izbjegle gužve i smanjilo vrijeme putovanja. Razvoj inteligentnih transportnih sustava omogućuje bolje upravljanje prometom u gradskim sredinama. Korištenjem neizrazite logike te raznih algoritama se postiže bolja razine uslužnosti gradskih autocesta. U završnom radu potrebno je opisati problem upravljanja priljevnim tokovima gradskih autocesta, analizirati moguća rješenja zasnovana na neizrazitoj logici te na postojećem modelu gradske autoceste izrađenim u programskim paketima VISSIM/Matlab ispitati jednostavan sustav upravljanja priljevnim tokovima zasnovan na neizrazitoj logici.

Mentor:

izv. prof. dr. sc. Edouard Ivanjko

Predsjednik povjerenstva za završni ispit:

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

ZAVRŠNI RAD

OKRUŽENJE ZA SIMULACIJU UPRAVLJANJA PRILJEVNIM TOKOVIMA NA GRADSKIM AUTOCESTAMA ZASNOVANO NA NEIZRAZITOJ LOGICI

SIMULATION ENVRIONMENT FOR FUZZY LOGIC BASED RAMP METERING

Mentor: izv. prof. dr. sc. Edouard Ivanjko

Studentica: Žana Jakobović 0135243764

Zagreb, rujan 2019.

SAŽETAK

Naslov: Okruženje za simulaciju upravljanja priljevnim tokovima na gradskim autocestama zasnovano na neizrazitoj logici

Povećanje broja vozila na cestovnim prometnicama u gradovima je uzrokovalo sve češće korištenje zaobilaznice ili gradske autoceste kako bi se izbjeglo zagušenje u određenim dijelovima grada i smanjilo vrijeme putovanja. U ovom završnom radu objasniti će se uloga upravljanja priljevnim tokovima na gradskim autocestama i postojeći problemi koji utječu na potrebu upravljanja priljevnim tokovima. Nadalje, objasnit će se osnove neizrazite logike i njena primjena u upravljanju prometom te priljevnim tokovima. Korištenjem MATLAB i VISSIM programskih alata izraditi će se okruženje za simulaciju upravljanja priljevnih tokova zasnovana na neizrazitoj logici. Pri tome je neizraziti regulator, koji će upravljati priljevnim tokom gradske autoceste u cilju smanjenja prometnih zagušenja na glavnom toku gradske autoceste, implementiran programskom alatu MATLAB. Na postojećem modelu gradske autoceste u VISSIM-u simulirat će se prometni tok u 3 slučaja: bez upravljanja, upravljanje ustaljenim signalnim planom te upravljanje neizrazitim regulatorom. Na kraju će se analizirati svaki slučaj pojedinačno te će se usporediti rezultati sve tri simulacije.

Ključne riječi: upravljanje priljevnim tokovima; neizrazita logika; gradska autocesta; prometni tok; VISSIM; MATLAB

SUMMARY

Title: Simulation Environment for Fuzzy Logic Based Ramp Metering

With the increase in the number of vehicles on the city roads, people tend to more and more use detour roads or urban motorways to avoid congestions and decrease traveling time. In this thesis, the function of ramp metering on urban motorways and existing problems which affect management of inflow ramps on urban motorways will be explained. Furthermore, the basics of fuzzy logic and its application in traffic management and management of inflow ramps will be explained. Using MATLAB and VISSIM programming tools a simulation environment for fuzzy logic based ramp metering will be made. Thereby, a fuzzy regulator, which will manage traffic on the inflow ramp in order to reduce congestions on the mainstream flow, will be designed and implemented in MATLAB. On an existing model of urban motorway in VISSIM 3 different simulations will be run: without traffic control, control with a predefined signal plan and using the fuzzy regulator. In the end each case will be analyzed and compared to others.

Key words: ramp metering; fuzzy logic; urban motorway; traffic flow; VISSIM; MATLAB

Zahvala

Zahvaljujem tvrtki PTV na dodijeljenoj licenci za izradu ovog završnog rada u programskom alatu PTV VISSIM. Također zahvaljujem svom mentoru, izvanrednom profesoru Edouardu Ivanjku na potpori, motivaciji i pomoći tijekom izrade ovog završnog rada. Zahvaljujem se asistentu Krešimiru Kušiću na pomoći s radom u MATLAB-u i VISSIM-u. Zahvaljujem kolegi Filipu Antoniu Pavliniću na suradnji tijekom izrade završnog rada te svima koji su na bilo koji način pomogli u izradi završnog rada. Također zahvaljujem svojim roditeljima na podršci i motivaciji tijekom cijelog studiranja.

Sadržaj

1. Uvod 1
2. Problemi u prometu na gradskim autocestama 3
2.1. Karakteristike autoceste 4
2.2. Neharmonizirani prometni tok 6
2.3. Upravljanje priljevnim tokovima 7
3. Primjena neizrazite logike u upravljanju prometom 10
3.1. Neizrazita logika 10
3.2. Neizrazita logika u upravljanju prometom 12
4. Upravljanje priljevnim tokovima zasnovano na neizrazitoj logici 14
4.1. Funkcije pripadnosti 15
4.2. Pravila u neizrazitom regulatoru 17
5. Simulacijsko okruženje VISSIM/MATLAB 19
5.1. Simulacijski alat PTV VISSIM 19
5.2. Programski alat MATLAB 20
5.3. Povezivanje MATLAB-a i VISSIM-a pomoću COM sučelja 21
6. Rezultati simulacije 24
6.1. Simulacija prometnog toka bez upravljanja 24
6.2. Simulacija prometnog toka s upravljanjem ustaljenim signalnim planom 26
6.3. Simulacija prometnog toka s upravljanjem neizrazitim regulatorom 28
6.4. Usporedba rezultata svih simulacija 30
7. Zaključak 33
Literatura 34
Popis slika 36
Popis tablica 37

1. Uvod

Zadnjih nekoliko godina značajno raste broj stanovnika u gradovima te se stvaraju sve veća zagušenja na cestama. Cestovni promet je i dalje najpopularniji oblik prijevoza, a pogotovo u slučajevima osobnih vozila gdje se putnika prevozi od ''vrata do vrata''. Upravo zbog takvih potreba korisnika nužno je optimizirati i poboljšati učinkovitost postojećih prometnica jer u većini slučajeva nema mjesta za fizičku nadogradnju ili proširenje prometnica u gradskim sredinama. Kako se sve više prometnih zagušenja događa u centru grada, tako sve više korisnika odabire putovanje zaobilaznicom ili gradskom autocestom kako bi smanjili vrijeme putovanja, vrijeme čekanja itd. Iako putovanje takvom prometnicom većeg kapaciteta može biti puno jednostavnije i brže, postoje situacije gdje dolazi do zagušenja te zastoja i na takvim prometnicama. Naime, zaobilaznice ili gradske autoceste su ceste kojima se vozi i do dvostruko većom brzinom nego na gradskim prometnicama kako imaju više prometnih traka bez raskrižja. To stvara dinamičan i promjenjiv prometni tok te se povećava vjerojatnost za pojavom prometne nezgode i zastoja s povećanjem gustoće prometnog toka. Također kod takvih prometnih tokova dolazi i do šok valova, pojave koja je uzrokovana kočenjem prvog automobila, a koja se prenose na svako vozilo iza prvog.

Razvojem inteligentnih transportnih sustava pojavljuje se sve više pametnih rješenja za upravljanje prometom, kako u centru grada, tako i izvan njega. Specifično za autoceste ili brze ceste je da vozači ne poštuju sva pravila, poput ograničenja brzine, već voze brzinom za koju su ''sposobni''. Tako dolazi do stvaranja neharmoniziranog prometnog toka jer dio vozača vozi prebrzo, drugi dio presporo, a ostatak vozača prati ograničenje brzine. To stvara problem vozačima koji ulaze na autoceste s ulaznih rampi jer ne mogu procijeniti brzinu nadolazećih vozila s glavnog toka pa dolazi do usporavanja na samom ulazu te nastaju čepovi i zagušenja. Korištenjem pametnog upravljanja priljevnim tokovima (engl. *ramp metering*), odnosno prometne signalizacije koja vozilima na priljevnom toku govori kada da se priključe na glavni tok povećava razinu usluge na glavnom toku gradske autoceste.

Rad je podijeljen u sedam cjelina:

1. Uvod,
2. Problemi upravljanja prometom na autocestama,
3. Primjena neizrazite logike u upravljanju prometom,
4. Upravljanje priljevnim tokovima zasnovano na neizrazitoj logici,
5. Simulacijsko okruženje VISSIM/MATLAB,
6. Rezultati simulacije i
7. Zaključak.

U drugom poglavlju bit će opisan proces upravljanja priljevnim tokovima, zašto i kako se koristi, te kakvi su ishodi njegove primjene. Bit će navedene karakteristike autoceste i prometnog toka te opisan uzrok i posljedice neharmoniziranog prometnog toka.

U trećem poglavlju bit će objašnjene osnove neizrazite logike, usporedba neizrazite logike u odnosu na klasičnu logiku, te primjena neizrazite logike u prometu.

U četvrtom poglavlju bit će opisano okruženje za upravljanje priljevnim tokovima zasnovano na neizrazitoj logici te kako je podešen neizraziti regulator u programskom alatu MATLAB.

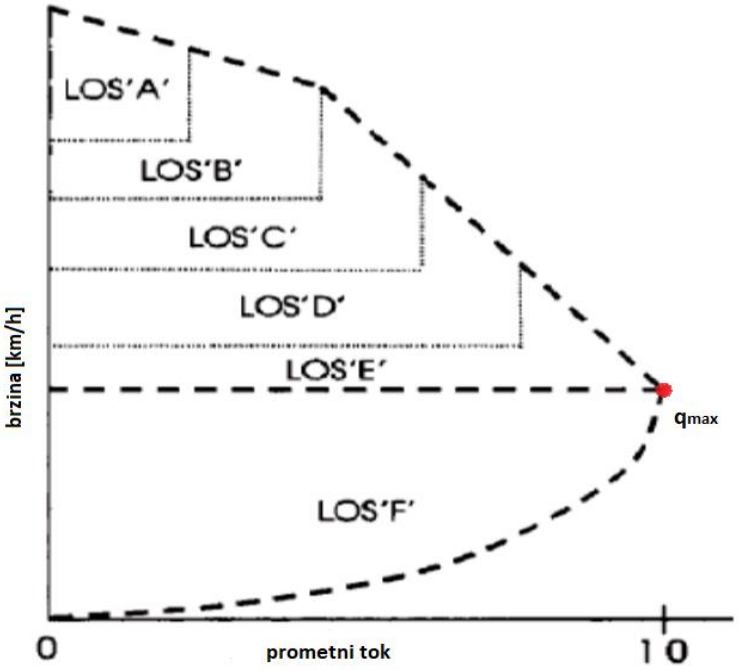
U petom poglavlju bit će navedeni i opisani simulacijski alat PTV VISSIM i programski alat MATLAB te povezivanje ta dva alata pomoću COM sučelja.

U šestom poglavlju bit će prikazani rezultati simulacije bez upravljanja priljevnim tokom, upravljanje priljevnim tokom s ustaljenim signalnim planom te upravljanje priljevnim tokom zasnovano na neizrazitoj logici.

U sedmom poglavlju dat će se zaključak te prijedlozi za nastavak rada i poboljšanje na ovoj temi.

2. Problemi u prometu na gradskim autocestama

Sve više raste broj vozila na cestama pa zbog velike prometne potražnje dolazi do čestih prometnih zagušenja, a time i smanjenja razine usluge (engl. *Level of Service*) prometnice. Na slici 1. prikazan je odnos mijenjanja razine usluge na autocesti u odnosu na brzinu prometnog toka te količinu prometnog toka. Što je veća količina prometnog toka, smanjuje se brzina vožnje te se smanjuje razina usluge, gdje razina A predstavlja najbolji slučaj, a razina F najlošiji. Problemi nastaju kada vozači ne poštuju prometna pravila odnosno voze većom ili manjom brzinom nego dopuštenom, odnosno preporučenom, te se stvara neharmonizirani prometni tok. U takvim uvjetima dolazi do prometnih zagušenja i zastoja, produljenja vremena putovanja, neučinkovitog prijevoza te ekoloških onečišćenja. Zbog nemogućnosti nadogradnje i proširenja infrastrukture koriste se različiti načini upravljanja prometom. Inteligentni transportni sustavi se javljaju krajem 20. stoljeća i nude tzv. pametna rješenja za upravljanje prometom. Inteligentni transportni sustavi su holistička, upravljačka i informacijsko-komunikacijska nadgradnja klasičnog sustava prometa i transporta kojim se postiže znatno poboljšanje performansi, odvijanja prometa, učinkovitiji transport putnika i roba, poboljšanje sigurnosti u prometu, udobnost i zaštita putnika, manja onečišćenja okoliša, itd. ITS usluga kao što je upravljanje prometnog toka (engl. *Traffic Control*) odnosi se na upravljanje prometnog toka u mreži gradskih prometnica, ali i izvan gradova i sastoji se od slijedećih usluga: adaptivno upravljanje prometnim svjetlima odnosno semaforima, promjenjive prometne poruke, kontrola pristupa na autocestu, kontrola brzine, upravljanje parkiranjem, itd. [1].



Slika 1. Prikaz razina usluge na autocesti, [2]

2.1. Karakteristike autoceste

Autoceste su javne ceste s najvišom razinom usluge koje se sastoje od dvije razdvojene kolničke trake i namijenjene su samo za promet motornih vozila. Od običnih prometnica razlikuju se po tome što nemaju raskrižja u istoj razini i dozvoljene brzine su puno veće nego na gradskim prometnicama. Navedeno zahtijeva veću širinu prometne trake te dodatnu traku za zaustavljanje u nuždi. Kako je na autocestama ograničenje brzine 130 [km/h] prometna traka široka je do 3,5 [m] što omogućava vozačima bolje zadržavanje vozila unutar vozne trake pri velikim brzinama. Također sadrži zaustavni trak te posebno uređene priključke za uvoženje i izvoženje, odnosno priljevne i odljevne tokove.

Prometni tok je definiran kao istodobno kretanje više prometnih entiteta na prometnoj infrastrukturi prema određenim zakonitostima, a čine ga entiteti koji su u međusobnoj interakciji, interakciji s infrastrukturom i okolinom. Prometni tok može bit opisan na mikroskopskoj razini gdje se svako vozilo promatra odvojeno i izučavaju se interakcijski procesi između vozila na individualnoj razini te na makroskopskoj gdje se prometni tok proučava na razini cijelog toka. Vrste prometnih tokova se dijele prema kontinuitetu, prema sastavu i prema stanju toka tijekom vremena pa tako postoje:

•prema kontinuitetu:

• neprekinuti prometni tok – nema elemenata izvana koji bi prouzročili prekid toka,

• prekinuti prometni tok – prekid prouzročen izvana kao što je semafor, stop znak itd.,

• prema sastavu:

• homogeni – vozila istog tipa i veličine,

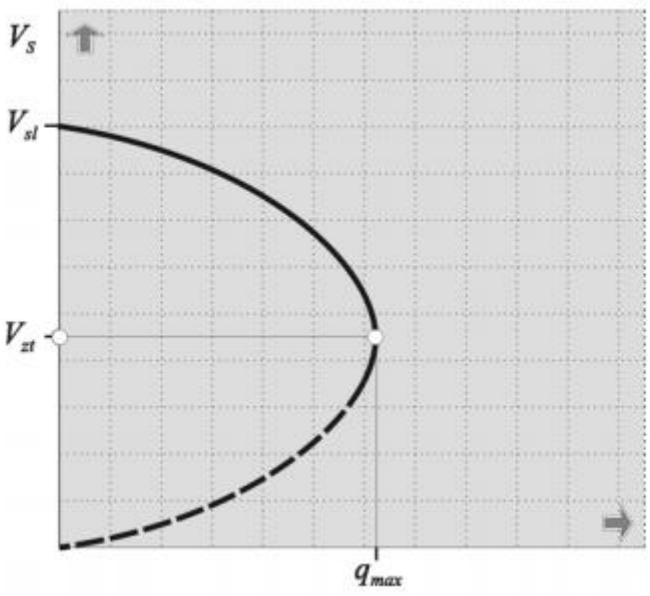
•nehomogeni – sastavljen od različitih entiteta,

•prema stanju toka tijekom vremena:

• stacionarni – brzina, putanje i protoci se ne mijenjaju u vremenu,

• nestacionarni – stvarni tok, akceleracija, deceleracija.

Osnovni parametri prometnog toka se dijele na makroskopske i mikroskopske. Makroskopski parametri su volumen prometnog toka, gustoća prometnog toka, brzina prometnog toka te vrijeme putovanja vozila u toku. Mikroskopski parametri su vremenski i prostorni interval slijeđenja vozila u toku te prostorne i vremenski razmaci između vozila.



Slika 2. Prikaz paraboličnog modela ''brzina-tok'', [3]

Na slici 2. je prikazana krivulja ''brzina-tok'' koja ima tri poznate točke: jedna u ishodištu koordinatnog sustava, jedna na ordinati koja odgovara maksimalnoj vrijednosti brzine vozila odnosno brzine slobodnog toka te jednu točku u koordinatama qzt = max q i Vzt. Dakle protok prometnog toka dosiže svoj maksimum kada je brzina prometnog toka jednaka srednjoj prostornoj brzini prometnog toka, tzv. kritična brzina. Površina grafa iznad kritične brzine Vzt smatra se stabilnim tokom, a površina ispod kritične brzine je nestabilan tok [3].

2.2. Neharmonizirani prometni tok

Glavni problem nastaje kad prometna potražnja postane prevelika za ponuđeni kapacitet prometnice. Pojave koje mogu uzrokovati zagušenja u prometu na gradskim autocestama su u najvećoj mjeri pojava uskih grla (lokaliziranog poremećaja odvijanja prometa uzrokovano radovima na cesti ili loše signaliziranim i dizajniranim raskrižjima), prometne nezgode, loši vremenski uvjeti i slično. Fenomen koji u uvjetima veće gustoće prometnog toka nastaje zbog kočenja jednog vozila, a prenosi se na svako vozilo iza toga, zovemo šok valom. Sva vozila koja nailaze iza prvog vozila koje je zakočilo primorana su također smanjiti brzinu čime dolazi do efekta šok vala i obično traje dugo dok se ne izregulira prometni tok i vrati u harmonizirani način prometnog toka. Kako bi se takva pojava izbjegla potrebno je pratiti preporučene brzine na prometnicama i što je rjeđe moguće naglo kočiti.

2.3. Upravljanje priljevnim tokovima

Upravljanje priljevnim tokovima je reguliranje prometa koji se priključuje s prilaznog toka na glavni tok gradske autoceste. Upravljanje priljevnim tokovima se dijeli u tri kategorije: upravljanje s operatorom, ustaljeno signalno upravljanje te upravljanje na temelju trenutne prometne potražnje [4]. To je vrlo koristan način upravljanja prometom jer se s lakoćom može implementirati na postojeću infrastrukturu prometnica ili prilikom gradnje dodati u novu infrastrukturu. Također je moguće dodijeliti prioritet vozilima javnog gradskog prijevoza ili vozilima hitne službe u cilju poboljšanja kvalitete gradskog prometnog sustava. Sustav za upravljanje priljevnim tokovima upravlja frekvencijom ulaska vozila koji ulaze na autocestu. Takvim načinom upravljanja povećava se iskorištenje odnosno kapacitet autoceste te prometni tok postaje ujednačen.

Pozitivne značajke primjene upravljanja priljevnim tokovima su:

- povećana sigurnost,
- povećana propusnost prometnog toka,
- smanjenje zagušenja prometa,
- skraćeno ukupno vrijeme putovanja,
- manje emisija štetnih plinova,
- smanjenje potrošnje goriva,
- manje sekundarnih incidenata [5].

Koristi se kako bi se na glavnom toku autoceste ili brze ceste održao harmonizirani prometni tok, ostvario puni potencijal prometnice, te kako bi se vozila s priljevnog toka neometano mogla priključiti na glavni tok. Signalni uređaj postavlja se na priljevnom toku koji propušta jedno do dva vozila po zelenom svjetlu na glavni tok kako se ne bi stvarala zagušenja i zastoji na glavnom toku zbog previše priključenih vozila što je prikazano na slici 3. Sustav upravljanja priljevnim tokovima, kao što je prikazano na slici 4., sastoji se od nekoliko detektora koji broje vozila te računaju gustoću prometa i broj vozila koji čekaju na ulaznom toku, zaustavne linije te od signalnog uređaja prije samog ulaza na glavni tok [5]. Postoji više različitih algoritama namijenjenih za upravljanje priljevnim tokovima, od kojih su najpoznatiji:

• lokalni algoritam ALINEA,

• centralizirani algoritam BOTTLENECK,

• algoritam ZONE,

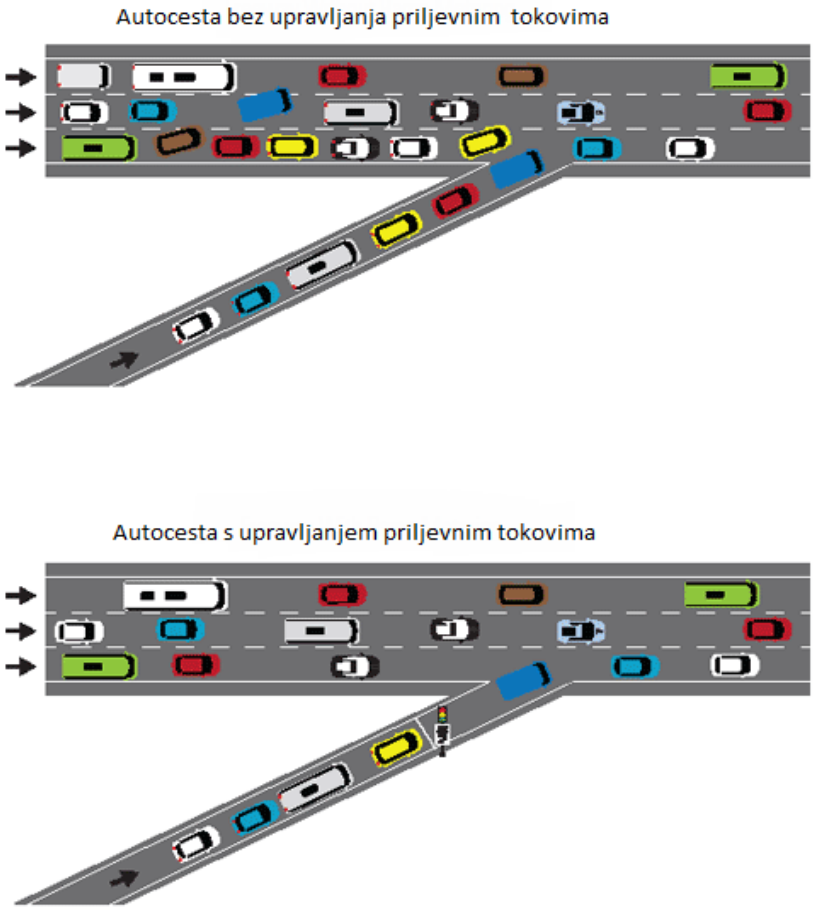
• algoritam RAMBO ,

• algoritam MILOS,

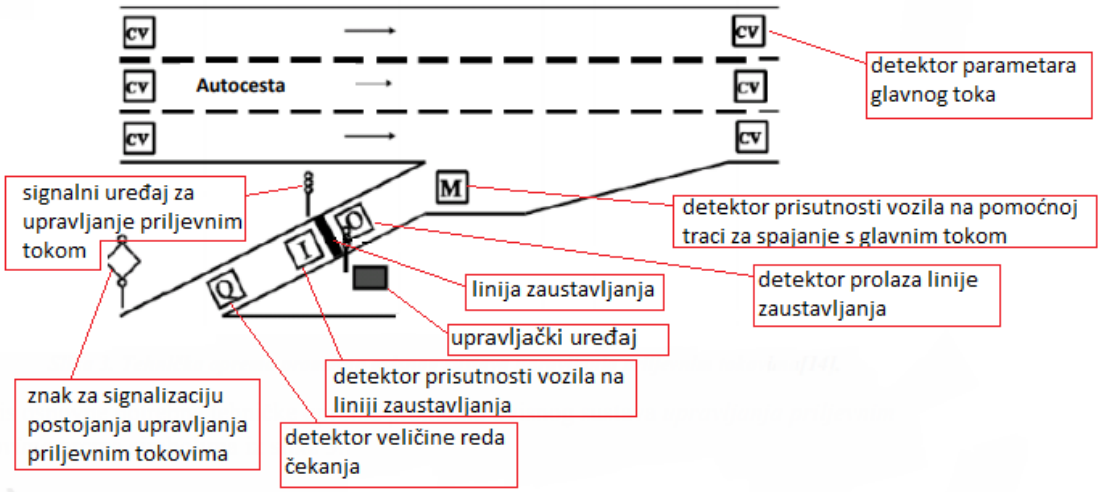
• algoritam SWARM,

• algoritam METLINE i

• algoritmi bazirani na umjetnim neuronskim mrežama i neizrazitim skupovima [6].



Slika 3. Prikaz izgleda prometnog toka s i bez upravljanja priljevnim tokom, [7]



Slika 4. Prikaz uređaja korištenih za upravljanje priljevnim tokovima, [8]

3. Primjena neizrazite logike u upravljanju prometom

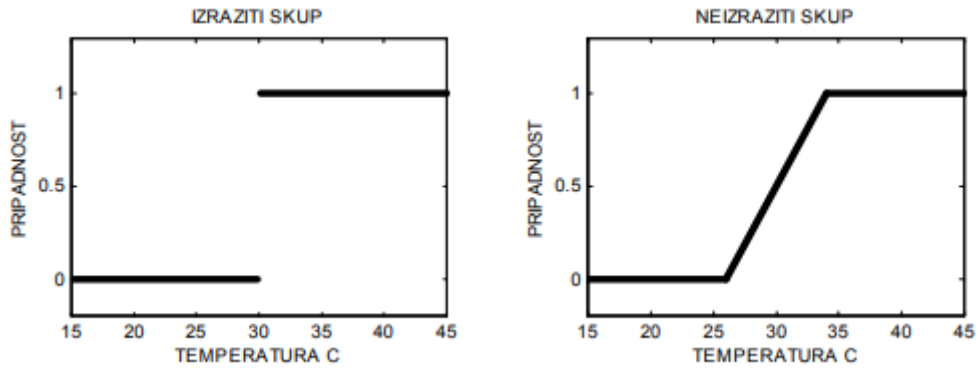
Zbog svojih svojstava obrade neodređenih vrijednosti neizrazita logika se primjenjuje u raznim sustavima upravljanja prometom, ali i u drugim procesima u znanstveno-tehničkom pogledu, osobito u automatizaciji i umjetnoj inteligenciji.

3.1. Neizrazita logika

Poljski filozof Jan Lukasiewicz je bio prvi koji je predložio zamjenu za klasičnu logiku dodavši moguće (engl. *Possible*) vrijednosti između pripadnosti elementa skupu istina (engl. *True*) i neistina (engl. *False*). Pojam neizrazita logika dolazi iz 1965. godine kada je Lotfi A. Zadeh predstavio svoju teoriju neizrazitih skupova. Neizrazita logika se zasniva na matematičkoj interpretaciji ljudskog znanja i prikupljenih iskustava [9]. Neizrazita logika omogućava formalnu metodologiju za prikazivanje, manipulaciju i implementaciju ljudskog znanja o problemu regulacije procesa. Iz tog razloga je primjena neizrazite logike povezana s područjem automatske regulacije, analize podataka te sustava za nadzor i dijagnostiku. U regulaciji procesa koji se temelje na kompleksnim matematičkim modelima neizrazita logika je dobra zamjena za iskusnog operatera. Glavni razlozi za primjenu neizrazite logike su veća robusnost i lakša sinteza regulatora. Neizrazita logika funkcionira na način da se semantički opišu ulazne i izlazne varijable odnosno neizrazite propozicije. Općeniti oblik neizrazite propozicije glasi "x je A", gdje A označava jezičnu vrijednost zadanu s neizrazitim skupom nad domenom varijable x. Neizrazita propozicija uspoređuje odnosno određuje stupanj pripadnosti varijable x neizrazitom skupu A. Za povezivanje propozicija koriste se veznici I, ILI te AKO-ONDA. Kombiniranjem propozicija i veznika nastaje neizrazito pravilo koje u općem slučaju ima oblik: AKO x je A I y je B ONDA z je C. "x je A I y je B" je premisa ili uvjet, a "z je C" predstavlja zaključak ili posljedicu pravila. Kako bi se opisao odabrani sustav ili proces potrebno je izraditi veći broj pravila pa se često govori o skupu ili bazi neizrazitih pravila. Neizrazite relacije definiraju kvantitativnu vezu između varijabli premise i varijabli zaključka, a koriste se za matematičku interpretaciju neizrazitih pravila. Također je potrebno odrediti način na koji se određuju zaključci na temelju poznatih činjenica i zadanih neizrazitih relacija. Takav proces zove se neizrazito zaključivanje s kojim je moguće kvantificirati ideju približnog rasuđivanja što je glavna značajka procesa ljudskog razmišljanja. Modeli koji se koriste za kvantificiranje postupka neizrazitog zaključivanja zovu se neizraziti sustavi. To su statički ili

dinamički sustavi koji koriste neizrazitu logiku, teoriju neizrazitih skupova, neizrazita pravila i neizrazito zaključivanje. Neizraziti sustavi sadrže tri osnovne komponente: bazu pravila, bazu podataka o funkcijama pripadnosti koje su zadane nad domenama ulaznih i izlaznih varijabli te mehanizam zaključivanja [10].

U klasičnoj logici pripadnost nekog elementa nekom skupu može biti 0 ili 1, odnosno element je unutar ili izvan skupa. Kod neizrazite logike pripadnost elementa nekom skupu može biti djelomična, a vrijednost funkcije pripadnosti su između 0 i 1. Vrijednost 0 označava da element ne pripada skupu, a 1 da potpuno pripada skupu. Neizraziti skup je određen funkcijom pripadnosti kojom se može bolje opisati pripadnost elementa nekom skupu, npr. više pripada skupu A nego skupu B. Karakteristika neizrazite logike je da u isto vrijeme koristi brojčane i jezične prikaze podataka što olakšava izradu složenijih sustava upravljanja [11]. Na slici 5. je prikazana razlika između izrazitog i neizrazitog skupa te prikaz funkcije pripadnosti ''vruće''. Kako je već rečeno, kod izrazitog skupa pripadnost može biti samo 0 ili 1, a kod neizrazitog imamo sve vrijednosti između 0 i 1, uključujući i njih. Konkretno, vrijednosti između 25 i 35 stupnjeva Celzijevih pripadaju temperaturi vruće u određenom stupnju pripadnosti te možemo odrediti koliko određeni element pripada skupu ''vruće''. Npr., temperatura od 27 stupnjeva pripada skupu ''vruće'' oko 30%, temperatura od 32 stupnja pripada oko 70%, dok temperatura od 30 stupnjeva pripada 50% skupu ''vruće'' [10].



Slika 5. Prikaz razlike između izrazitog i neizrazitog skupa, [10]

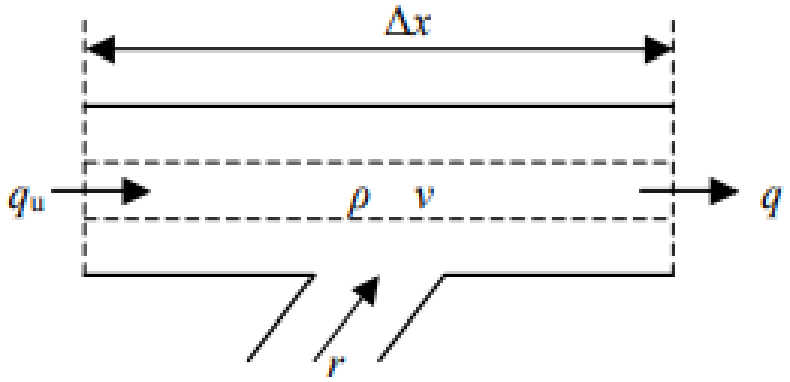
Mamdani neizrazito zaključivanje je tip zaključivanja koji se najčešće koristi u neizrazitom reguliranju. Izradio ga je Ebrahim Mamdani 1975. godine kao pokušaj za upravljanje parnim strojem. Neizraziti regulator radi na principu AKO-ONDA pravila. Npr. AKO

je protok prije priljevnog toka srednji, gustoća nakon priljevnog toka velika i duljina reda čekanja srednja ONDA trajanje crvenog svjetla je srednje [12].

3.2. Neizrazita logika u upravljanju prometom

Kod neizrazitih skupova prijelazi između karakterističnih ponašanja nisu izraziti s točno određenom granicom nego s postupnom degradacijom pripadnosti pojedinom skupu. To omogućava preciznije upravljanje prometnim tokom i bolje definiranje trenutnog stanja u odnosu na upravljanje s izrazitim skupovima. Iz tog razloga neizrazita logika često se primjenjuje u upravljanju semaforiziranih raskrižja. Velika većina semaforiziranih raskrižja temelji se na ustaljenom signalnom planu koji se mogu opisati pomoću izrazitih skupova. Za izradu takvih signalnih planova prethodno se odrađuju mjerenja prometnih parametara, kao što su broj vozila, gustoća prometnog toka, brzina prometnog toka te protok prometnog toka, u različitom dobu dana, tjedna, mjeseca i godine. Na taj način utvrđuju se vršni sati te pojačana prometna potražnja. Prema tome se matematički računaju signalni planovi koji upravljaju prolaskom vozila kroz raskrižje. Negativna posljedica takvih raskrižja je što ne postoje detektori koji prate prometnu potražnju u stvarnom vremenu te može dovesti do prometnih zagušenja i poremetiti veći dio prometne mreže. Iz tog razloga počela se koristiti neizrazita logika u upravljanju semaforiziranih raskrižja. Sustavi koji koriste neizrazitu logiku za upravljanje prometom rade u stvarnom vremenu te mogu mijenjati signalni plan prema potrebi. Takav način upravljanja daje bolje rezultate u odnosu na upravljanje semaforiziranog raskrižja s ustaljenim signalnim planom [1]. Također, iz istih razloga se počela koristiti neizrazita logika za upravljanje priljevnim tokovima na gradskim autocestama.

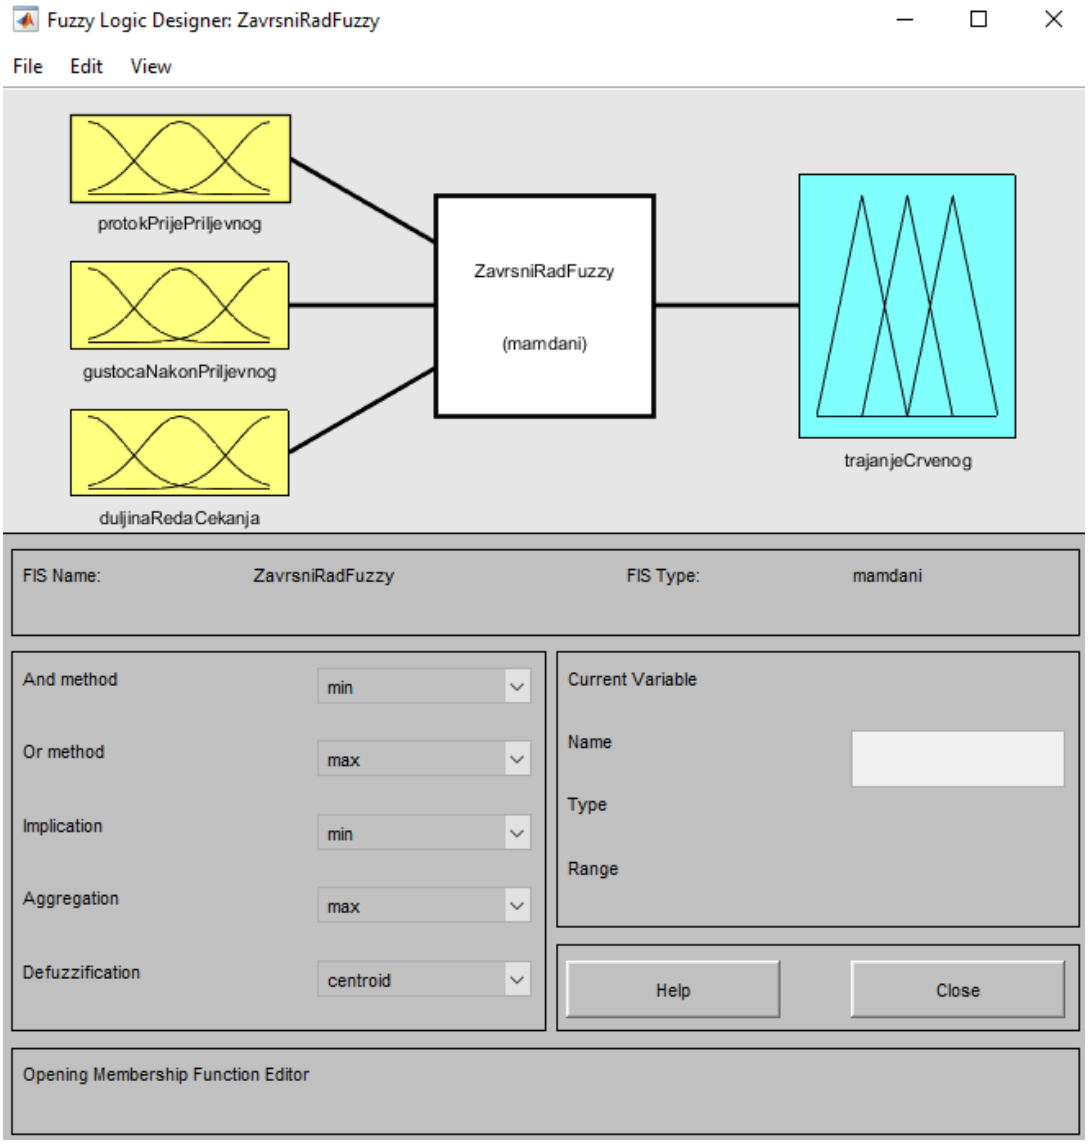
Poznati Lighthill-Whitham-Richards model (skraćeno LWR model) pruža jednostavan oblik opisivanja prometnog toka za simulacije i analize prometnog toka. Koristi se zbog kvalitetnih rezultata opisivanja pojava kao što su šok valovi, zagušenja te zastoji. Na slici 6. vide se parametri koji se mjere za upravljanje priljevnim tokom na autocesti [13].



Slika 6. Prikaz Lighthill-Whitham-Richards modela za upravljanje priljevnim tokom autoceste, [13]

4. Upravljanje priljevnim tokovima zasnovano na neizrazitoj logici

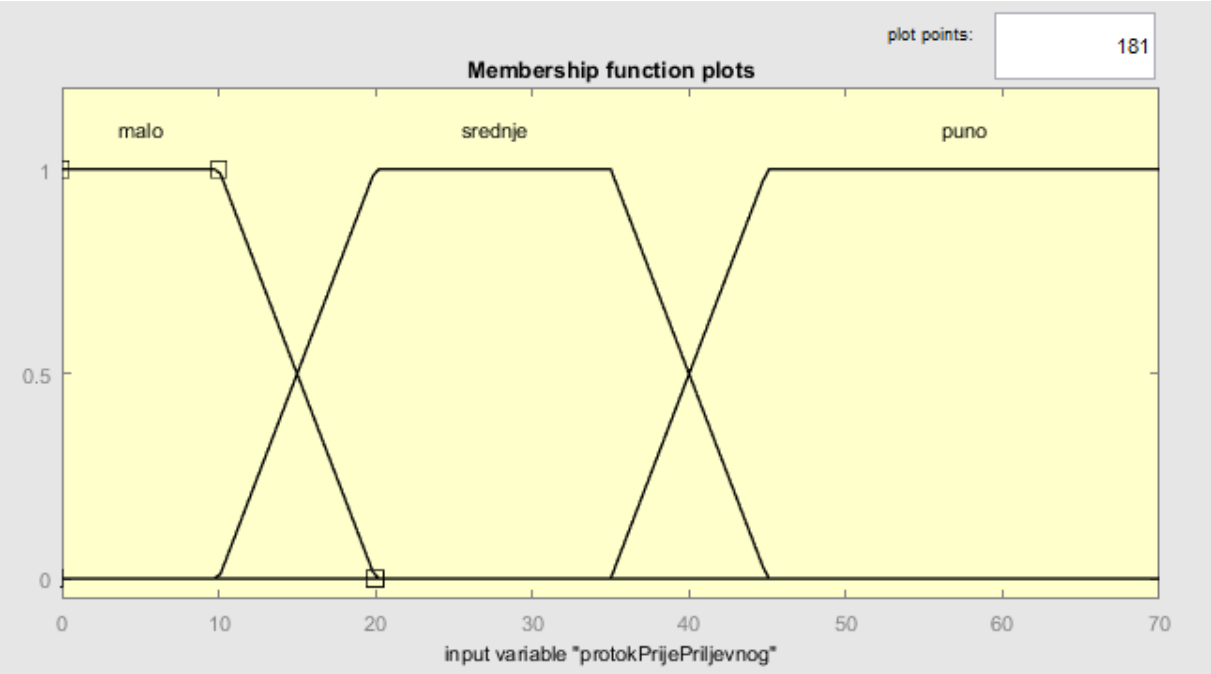
Za izradu ovog završnog rada koriste se mikroskopski simulator prometa VISSIM te programski alat MATLAB. U VISSIM-u je izrađen model autoceste s dva priljevna toka te jednim odljevnim. Zadatak je upravljati drugim ulaznim tokom neizrazitim regulatorom izrađenim u MATLAB-u kao što je prikazano na slici 7. Činjenica da neizraziti regulator radi na jezičnim pravilima olakšava izradu složenog sustava kojim se želi upravljati. Što sustav ima više zadanih pravila, odnosno više opisanih situacija, to će bolje funkcionirati.



Slika 7. Prikaz sučelja za izradu neizrazitog regulatora u MATLAB-u

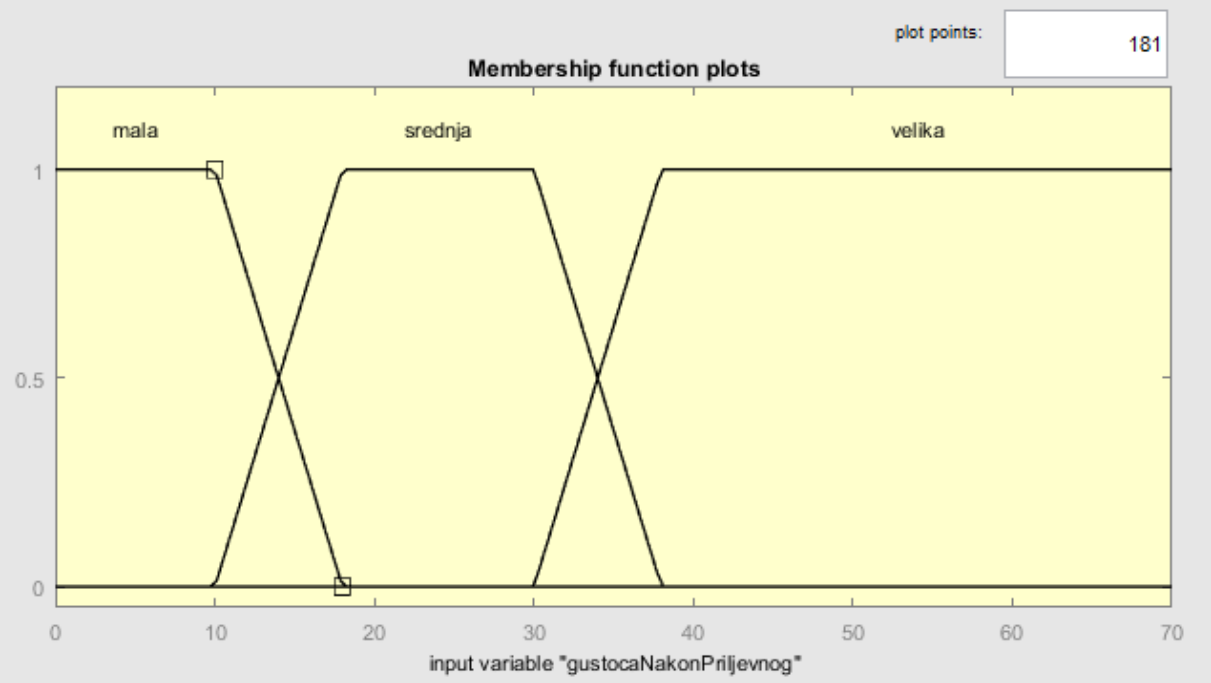
4.1. Funkcije pripadnosti

Funkcije pripadnosti su funkcije kojima se određuje pripadnost pojedinog elementa nekom skupu. Za sve ulazne parametre koriste se trapezoidne funkcije pripadnosti. Ulazne veličine u neizraziti regulator su protok prije priljevnog toka, gustoća nakon priljevnog toka i duljina reda čekanja na priljevnom toku, a izlazna veličina je trajanje crvenog svjetla na signalnom uređaju na priljevnom toku. Za svaku ulaznu veličinu dodijeljene su funkcije pripadnosti malo, srednje i veliko (puno). Na slici 8. je prikazan raspored funkcija pripadnosti za ulaznu varijablu ''protok prije priljevnog toka''. Ako je protok do 10 [voz/h] pripada malom protoku, ako je protok između 20 i 35 [voz/h] onda pripada srednjem protoku, a ako je veći od 45 [voz/h] pripada skupu puno. Sve vrijednosti između navedenih se očitavaju na grafu da bi se utvrdio postotak pripadnosti pojedinom skupu.



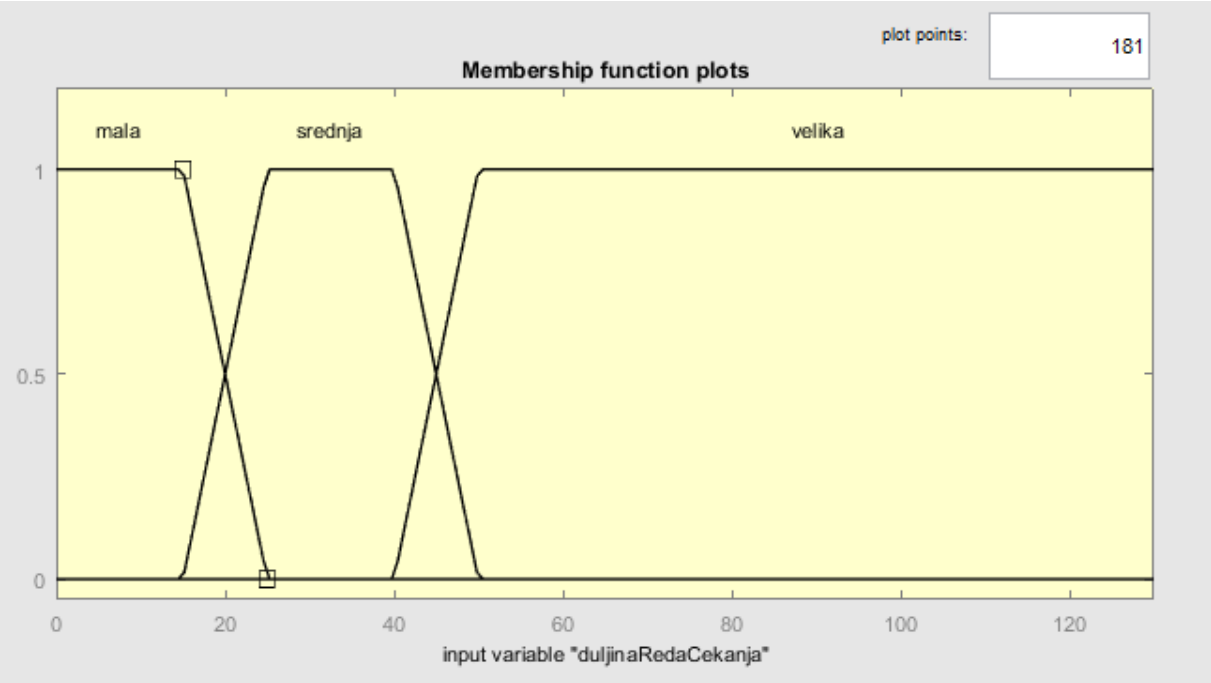
Slika 8. Prikaz funkcija pripadnosti ulazne varijable ''protok prije priljevnog toka''

Na slici 9. prikazane su funkcije pripadnosti ulazne varijable ''gustoća nakon priljevnog toka''. Vrijednosti su raspoređene u tri skupa – mala, srednja i velika, gdje skupu mala pripadaju vrijednosti do 10[voz/km], skupu srednja vrijednosti od 18 do 30 [voz/km], a skupu velika vrijednosti preko 38 [voz/km].



Slika 9. Prikaz funkcija pripadnosti ulazne varijable ''gustoća nakon priljevnog toka''

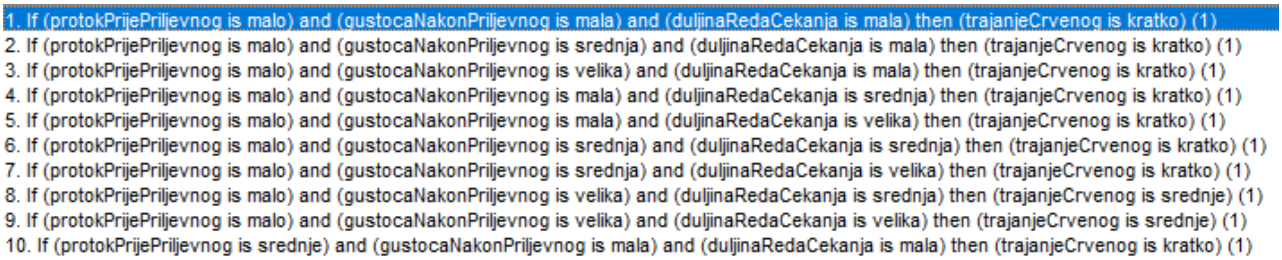
Funkcije pripadnosti ulazne varijable ''duljina reda čekanja'' prikazane su na slici 10. Funkcije pripadnosti su određene skupovima mala, srednja i velika. Skupu mala pripadaju vrijednosti do 15 [voz], skupu srednja pripadaju od 25 do 40 [voz], a skup velika sadrži vrijednosti iznad 50 [voz].



Slika 10. Prikaz funkcija pripadnosti ulazne varijable ''duljina reda čekanja''

4.2. Pravila u neizrazitom regulatoru

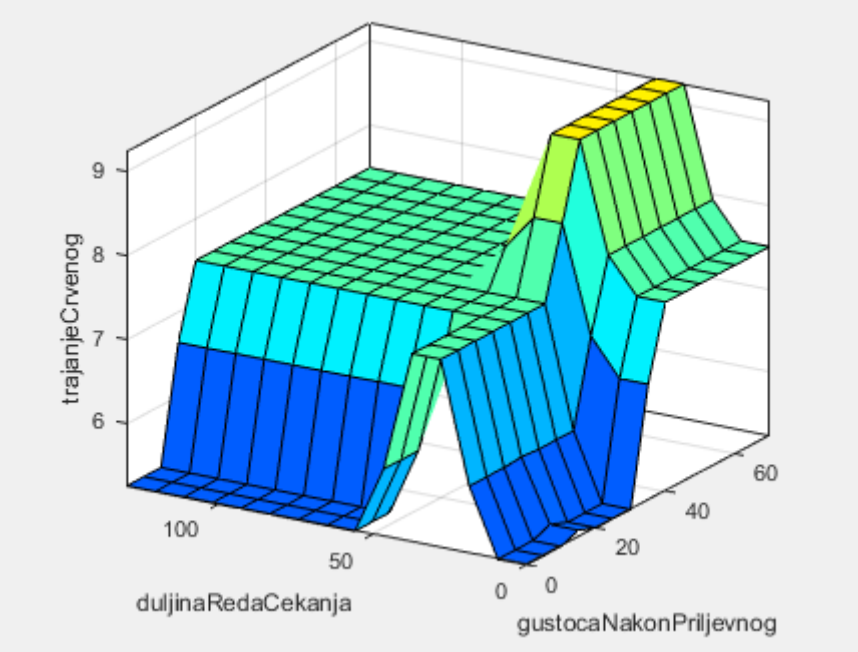
Za ovaj završni rad mjerene su određene veličine tokom simuliranja prometnog toka. Parametri koji su mjereni za vrijeme simulacije su protok prometnog toka prije ulazne rampe, gustoća nakon ulazne rampe te duljina reda čekanja su također i ulazne veličine odnosno inputi u regulator. Izlazna veličina koju je potrebno regulirati je duljina trajanja crvenog svjetla na signalnom uređaju na priljevnom toku. Zadano je da trajanje zelenog svjetla na signalnom uređaju traje 4 [s] što je dovoljno za prolazak jednog do dva vozila te da se duljina crvenog svjetla izmjenjuje ovisno o prometnoj potražnji. Izrađeno je 27 pravila za potrebe upravljanja priljevnim tokom u ovom slučaju kao što je prikazano na slici 11.



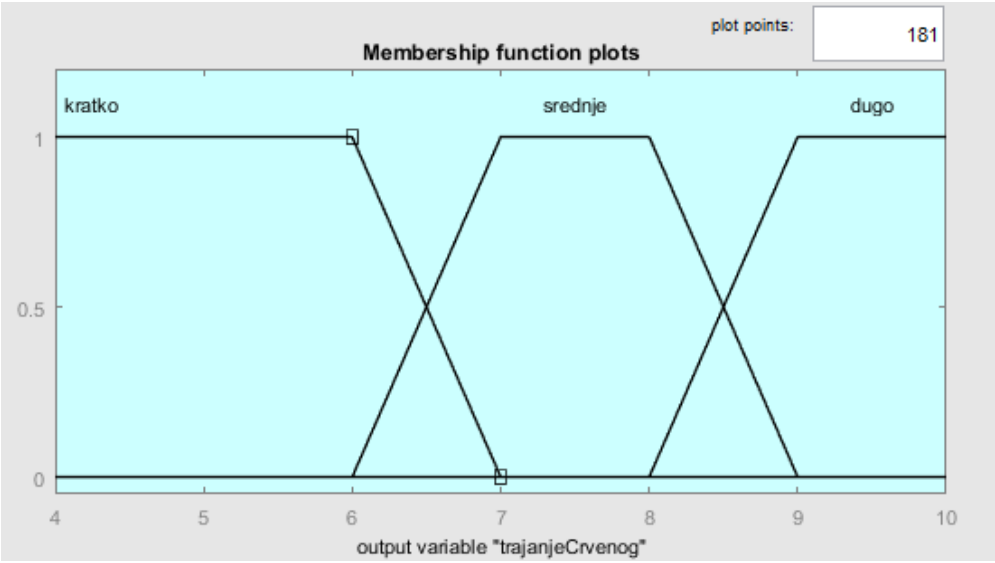
Slika 11. Prikaz pravila za upravljanje neizrazitim regulatorom

Nakon određivanja pravila i pregleda površine odlučivanja prikazane na slici 12. simulacija se provodi te se na temelju tri navedene ulazne veličine upravlja izlaznom veličinom, odnosno trajanjem crvenog svjetla na signalnom uređaju. Na 3D grafu vidi se ravni dio površine gustoće nakon priljevnog toka, bez obzira na povećanje duljine reda čekanja na priljevnom toku. Razlog tomu je nedostatak neizrazitih pravila za odlučivanje, ali isto tako i nemogućnost zaustavljanja vozila s priljevnog toka. Iako su duljina reda čekanja na priljevnom toku i gustoća nakon priljevnog toka veliki, ne smije se uskratiti ulazak vozila s priljevnog toka pa se trajanje crvenog svjetla zadržava na vrijednosti od 7-8 s što pripada funkciji pripadnosti - srednje. Trajanje crvenog svjetla se sastoji od također tri trapezoidne funkcije pripadnosti – kratko, srednje i dugo. Izražava se u sekundama i zaduženo je za upravljanjem crvenim svjetlosnim signalom. Nakon prolaska kroz sva pravila, u ovisnosti o iznosima ulaznih veličina,

dolazi se do potrebnog trajanja crvenog svjetla na signalnom uređaju kao što je prikazano na slici 13.



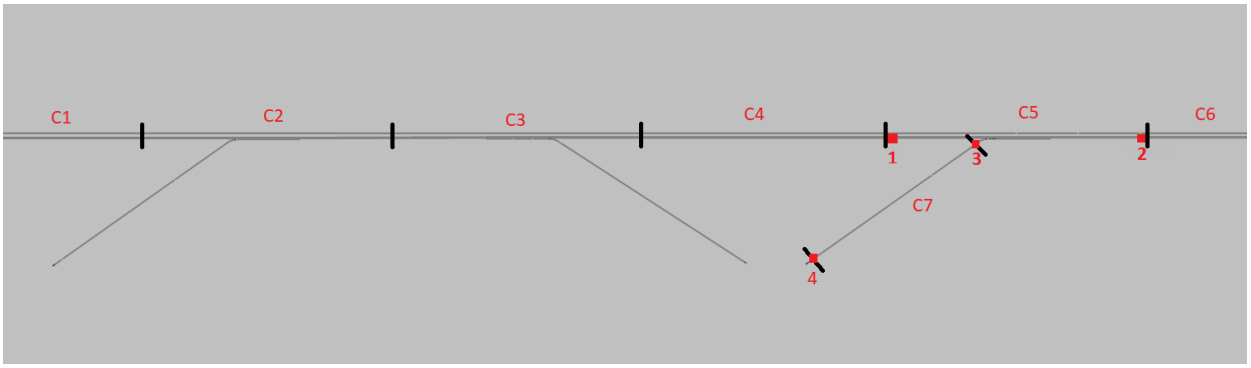
Slika 12. Prikaz površine odlučivanja koju čine napisana pravila u neizrazitom regulatoru



Slika 13. Prikaz funkcija pripadnosti izlazne varijable ''trajanje crvenog''

5. Simulacijsko okruženje VISSIM/MATLAB

Za izradu ovog završnog rada koriste se mikroskopski simulator prometa VISSIM te programskog alata MATLAB. U VISSIM-u je izrađen model autoceste s dva priljevna toka te jednim odljevnim kao što je prikazano na slici 14. Zadatak je upravljati drugim ulaznim tokom neizrazitim regulatorom izrađenim u MATLAB-u. Model autoceste podijeljen je na sedam ćelija, a područje upravljanja je u ćeliji oznake C5.



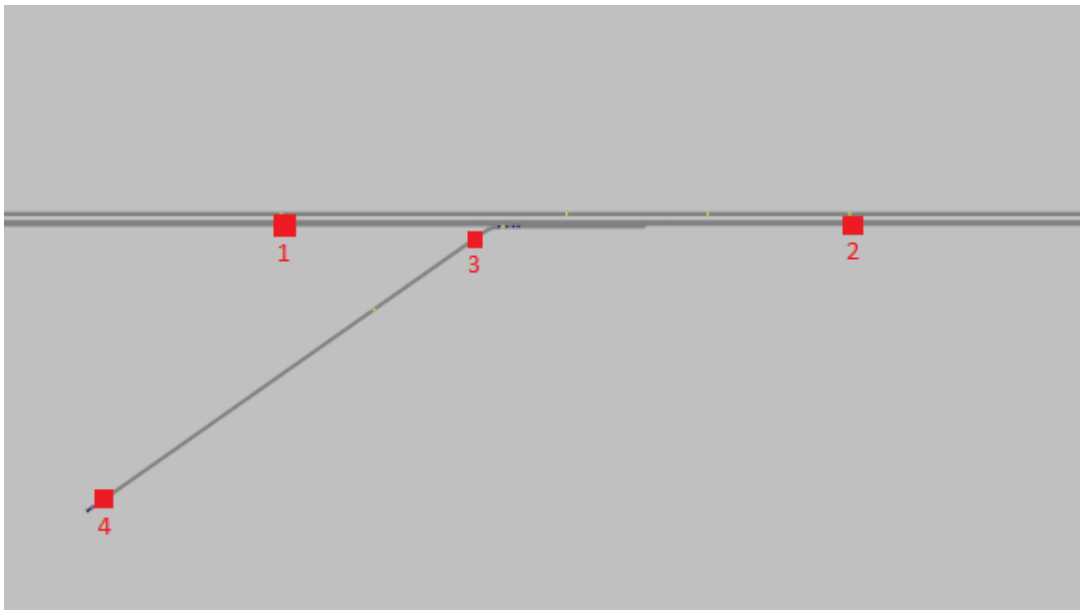
Slika 14. Prikaz modela autoceste u VISSIM-u

5.1. Simulacijski alat PTV VISSIM

VISSIM je alat tvrtke PTV za mikroskopsku simulaciju prometnog toka na izrađenom modelu prometnice. Koristi se za izradu i simulaciju prometa za pojedina križanja ili dionice kojom se želi upravljati. VISSIM prikazuje i simulira ponašanje i interakcije svih vrsta motornih vozila, transporta dobara, vozila javnog prijevoza te pješaka. Također se može koristiti za testiranje autonomnih vozila i njihovog ponašanja s obzirom na okolinu, što je puno učinkovitije, jeftinije i sigurnije od puštanja takvih vozila u stvarni promet [14]. VISSIM ima dodatak EnViVer s kojim je moguće odrediti i grafički prikazati količine emitiranja ugljikovog dioksida $C0_2$, dušičnog oksida NOx te PM10 čestica [15].

Model autoceste na kojem su rađene simulacije podijeljen je u ćelije. Promatrana ćelija s priljevnim tokom sastoji se od detektora prije ulazne rampe, dva detektora na samoj rampi – jedan koji detektira prisutnost vozila iza linije zaustavljanja, a drugi na početku ulazne rampe koji broji duljinu reda čekanja odnosno broj vozila koji čekaju ulaženje na glavni tok autoceste;

te detektora nakon spajanja prometa s glavnog toka i priljevnog toka. Na slici 15. vide se lokacije na kojima su postavljeni detektori za brojanje ulaznih parametara. Broj 1 označava mjesto na kojem se nalazi detektor pomoću kojeg se broji protok prometnog toka. Na broju 2 je detektor koji računa gustoću prometnog toka po kilometru. Brojevi 3 i 4 označavaju detektore na prilaznoj rampi pomoću kojih se određuje duljina reda čekanja.



Slika 15. Prikaz razmještaja mjernih mjesta na modelu autoceste u VISSIM-u

5.2. Programski alat MATLAB

MATLAB skraćenica dolazi od imena Matrix Laboratory. To je programski sustav koji se definira kao okružje s programskim jezikom namijenjeno tehničkim izračunima. Osnovna svojstva MATLAB-a su matrični kalkulator interpreterskog tipa, grupiranje naredbi u skripte i funkcije, razvoj skupova alata za rješavanje specifičnog tipa problema i testiranje algoritma u stvarnom vremenu.

Fuzzy Logic Designer je alat unutar MATLAB-a koji se koriti za izradu neizrazitog regulatora kojim se kasnije može upravljati odabranim tehničkim procesom. Za svaki drugi proces potrebno je podesiti ulazne i izlazne varijable te odrediti pravila. Pokreće se tako da se u command window unutar MATLAB-a upiše naredba *FuzzyLogicDesigner* te se otvara zaseban

prozor. Nakon toga potrebno je odučiti se koji tip pravila će biti korišten – Mamdani ili Sugeno [16].

5.3. Povezivanje MATLAB-a i VISSIM-a pomoću COM sučelja

Programski paket MATLAB i simulacijski alat VISSIM povezani su preko COM (engl. *Component Object Model*) sučelja čime se omogućava međusobna komunikacija. To je osnovni model arhitekture zbog kojeg je omogućeno povezivanje i interakcija između različitih vrsta programskih alata proizvedenih od različitih proizvođača. *Component Object Model* klijentima omogućuje komunikaciju, potražnju i spajanje na potrebnu uslugu. Jednom kad se uspostavi veza, COM se otpušta te sva daljnja komunikacija između poslužitelja i klijenta postaje izravna. U ovom slučaju COM sučeljem su povezani programi MATLAB i VISSIM, gdje je MATLAB klijentska, a VISSIM poslužiteljska aplikacija. Na slici 16. prikazan je proces izvršavanja simulacije. Na dijagramu se vidi da proces započinje pokretanjem MATLAB skripte, koja dalje pokreće VISSIM COM poslužitelj te VISSIM aplikaciju. Nakon toga učitavaju se VISSIM model i simulacija, prometna mreža i njeni objekti: signalni upravljači, poveznice, osjetila na prometnicama, entiteti u mreži itd. Nakon što MATLAB skripta postavi potrebne postavke kao što su period trajanja simulacije, rezolucija simulacije i količina vozila na prometnicama, pokreće se VISSIM simulacija. Nakon izvršenih simulacija u VISSIM-u, prikupljaju se rezultati i analiziraju. Kroz cijelo vrijeme simulacije prikupljaju se podaci te se pohranjuju u matricu rezultata 'mat_Rezultat' kako bi se kasnije mogli analizirati.

Naredbe pomoću kojih se povezuju MATLAB i VISSIM su sljedeće:

vis = actxserver('Vissim.Vissim'); - pristupanje VISSIM objektu

vis.LoadNet('C:\Desktop\model_za_fuzzy\model_mreza.inpx'); - učitavanje mreže

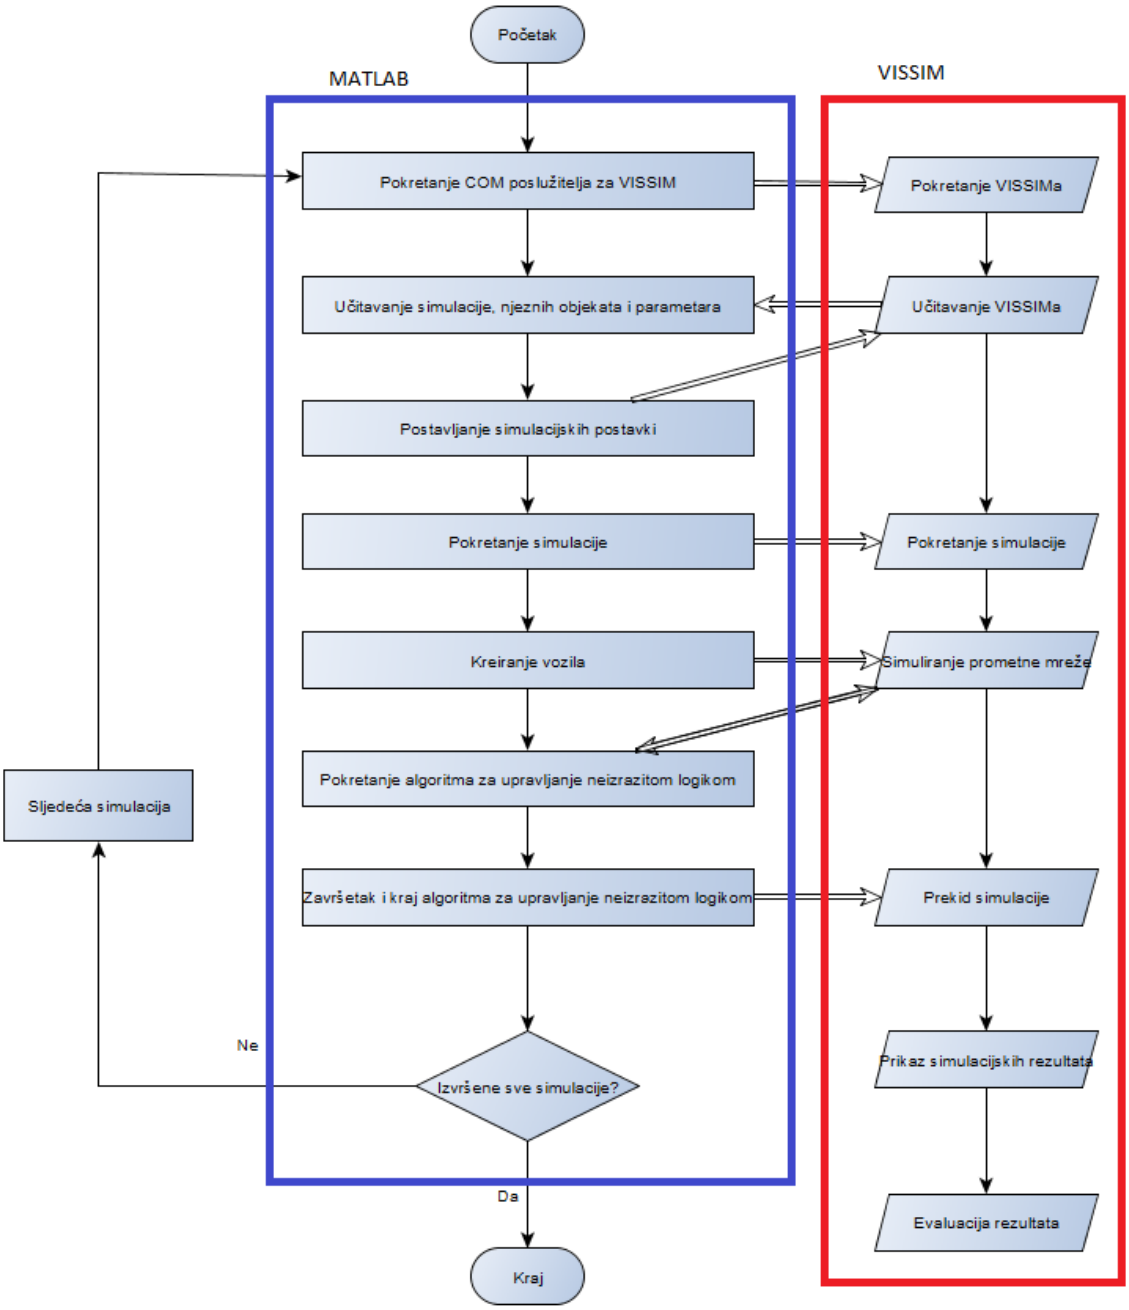
vis.LoadLayout('C:\Desktop\model_za_fuzzy\model_mreza.layx'); - učitavanje okoline

vnet = vis.Net; - pristupanje objektu mreže

scs = vnet.SignalControllers; - pristupanje listi signalnih kontrolera

sc_1 = scs.ItemByKey(1); - pristupanje prvom signalnom kontroleru

dets = sc_1.Detectors; - pristupanje listi detektora



Slika 16. Prikaz dijagrama toka spajanja programskog paketa MATLAB i simulacijske aplikacije VISSIM, [17]

Kako bi se koristio prethodno izrađen neizraziti regulator, potrebno je nakon pristupanja svim potrebnim objektima učitati datoteku s nastavkom ''.fis''.

fis = readfis('ZavrsniRadFuzzy');

Nadalje, u petlji koja pokreće simulaciju potrebno je inicijalizirati ulazne varijable i dodijeliti im vrijednosti. Vrijednosti se računaju i evaluiraju tokom cijele simulacije pa tako dobivamo rezultate u stvarnom vremenu [18].

```
for i = 0 : (period*step_time)
   sim.RunSingleStep;
trajanjeCrvenog= evalfis([protokPrijePriljevnog gustocaNakonPriljevnog duljinaRedaCekanja], fis);
```

6. Rezultati simulacije

U ovom poglavlju bit će opisane, analizirane i uspoređene simulacije prometnog toka na gradskoj autocesti bez upravljanja, s upravljanjem fiksnim signalnim planom i s upravljanjem neizrazitom logikom u trajanju od 2,5 [h]. Parametri koji se mjere tijekom simulacije u petoj ćeliji su volumen ili protok prometnog toka mjeren na detektorima prije priljevnog toka, gustoća prometnog toka unutar promatrane ćelije nakon stapanja priljevnog toka s glavnim te duljina reda čekanja na ulaznoj rampi.

Protok prometnog toka odnosno protok vozila je broj vozila koji prođu kroz promatrani presjek prometnice u jedinici vremena. S obzirom na način promatranja u odnosu na prostor razlikuju se protok vozila na presjeku ceste i protok vozila na dionici ceste. Protok vozila na presjeku ceste ''q'' izražava se u vozilima po satu [voz/h].

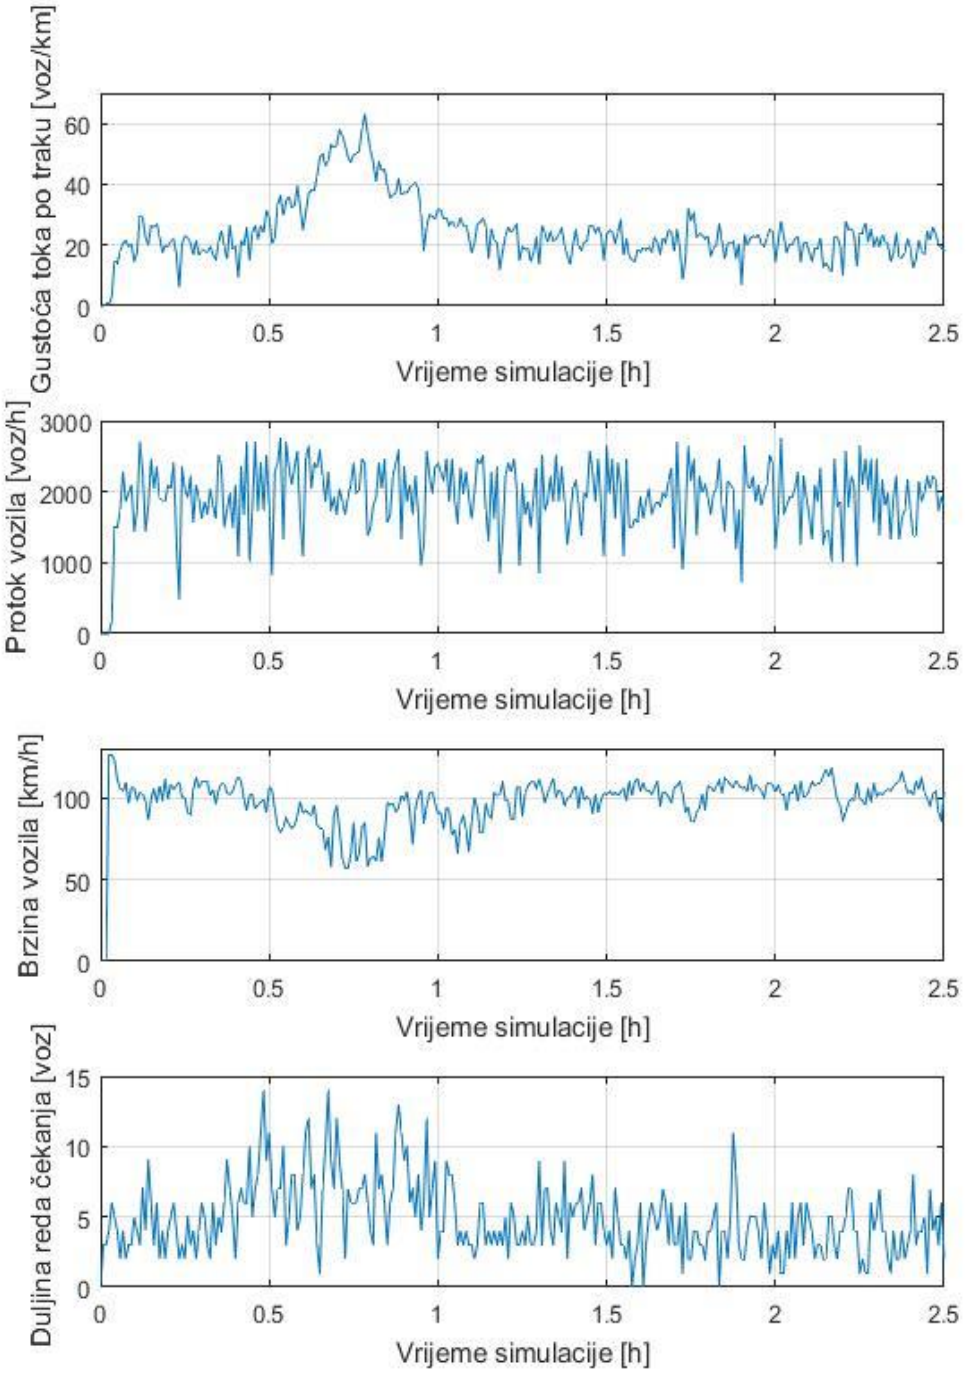
Gustoća prometnog toka podrazumijeva broj vozila na jedinici duljine prometnice, po prometnoj traci, po smjerovima za jednosmjerne prometnice, odnosno u oba smjera za dvosmjerne prometnice. Gustoća prometnog toka ''g'' izražava se u količini vozila po kilometru [voz/km].

Brzina prometnog toka ''v'' se odnosi na prosječnu brzinu svih vozila koja sudjeluju u promatranom prometnom toku, a izražava se u kilometrima na sat [km/h] [3].

6.1. Simulacija prometnog toka bez upravljanja

U prvom slučaju ispitan je sustav odvijanja prometnog toka bez upravljanja priljevnim tokom. Kako se na autocestama prometni tok pojačava i smanjuje u valovima na grafu gustoće vide se skokovi odnosno padovi količine vozila po kilometru. Kao što je prikazano na slici 17. nakon 0,5 [h] simulacije gustoća prometnog toka počinje znatno rasti što uzrokuje smanjenje prosječne brzine prometnog toka. Oko 40. minute simulacije gustoća prometnog toka doseže svoj maksimum u iznosu od oko 60 [voz/km/trak]. U tom trenutku prosječna brzina vozila je bila oko 60 [km/h] što znači da je došlo do zagušenja i produljuje se vrijeme putovanja. Za razinu usluge A uzima se da je gustoća prometnog toka oko 10 [voz/km/trak], a sve preko toga

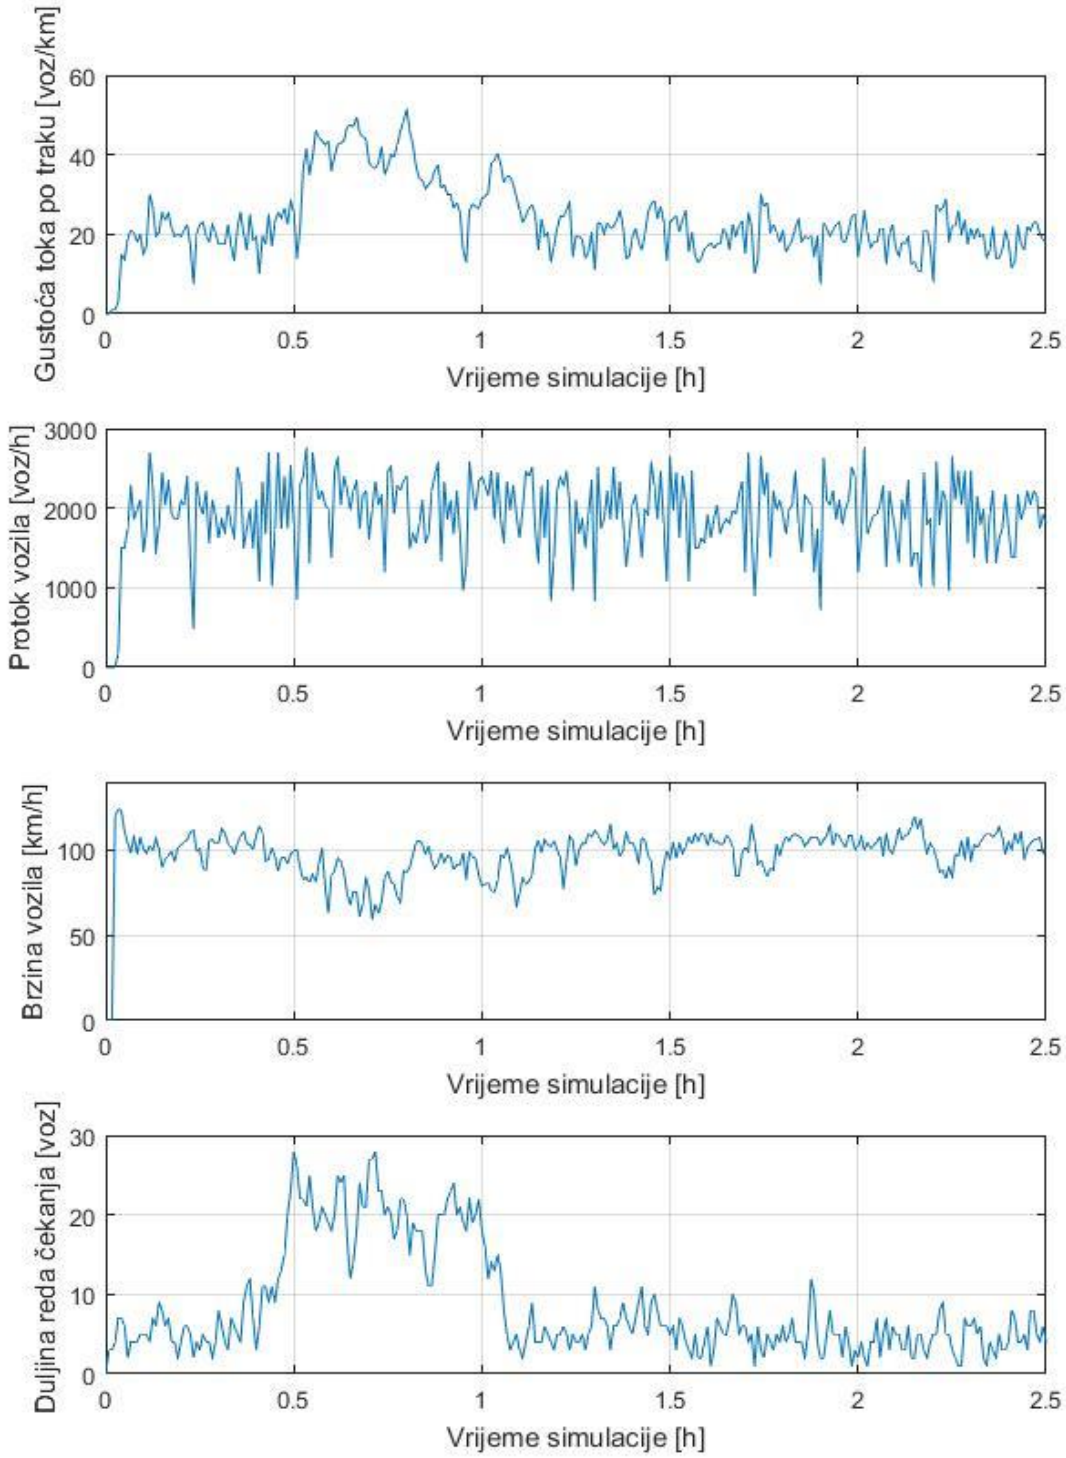
počinje smanjivati razinu usluge. U ovom slučaju razina usluge je F što podrazumijeva više od 45 [voz/km/trak] što znači velika zagušenja i smanjenje sigurnosti. Na priljevnom toku maksimalno je bilo 15 [voz] i nema dugih čekanja na prilaznoj rampi. Prosječna gustoća prometnog toka iznosi 24,57 [voz/km/trak], srednja brzina je 97,11 [km/h], a prosječna duljina čekanja je 5 [voz].



Slika 17. Prikaz rezultata simulacije bez upravljanja

6.2. Simulacija prometnog toka s upravljanjem ustaljenim signalnim planom

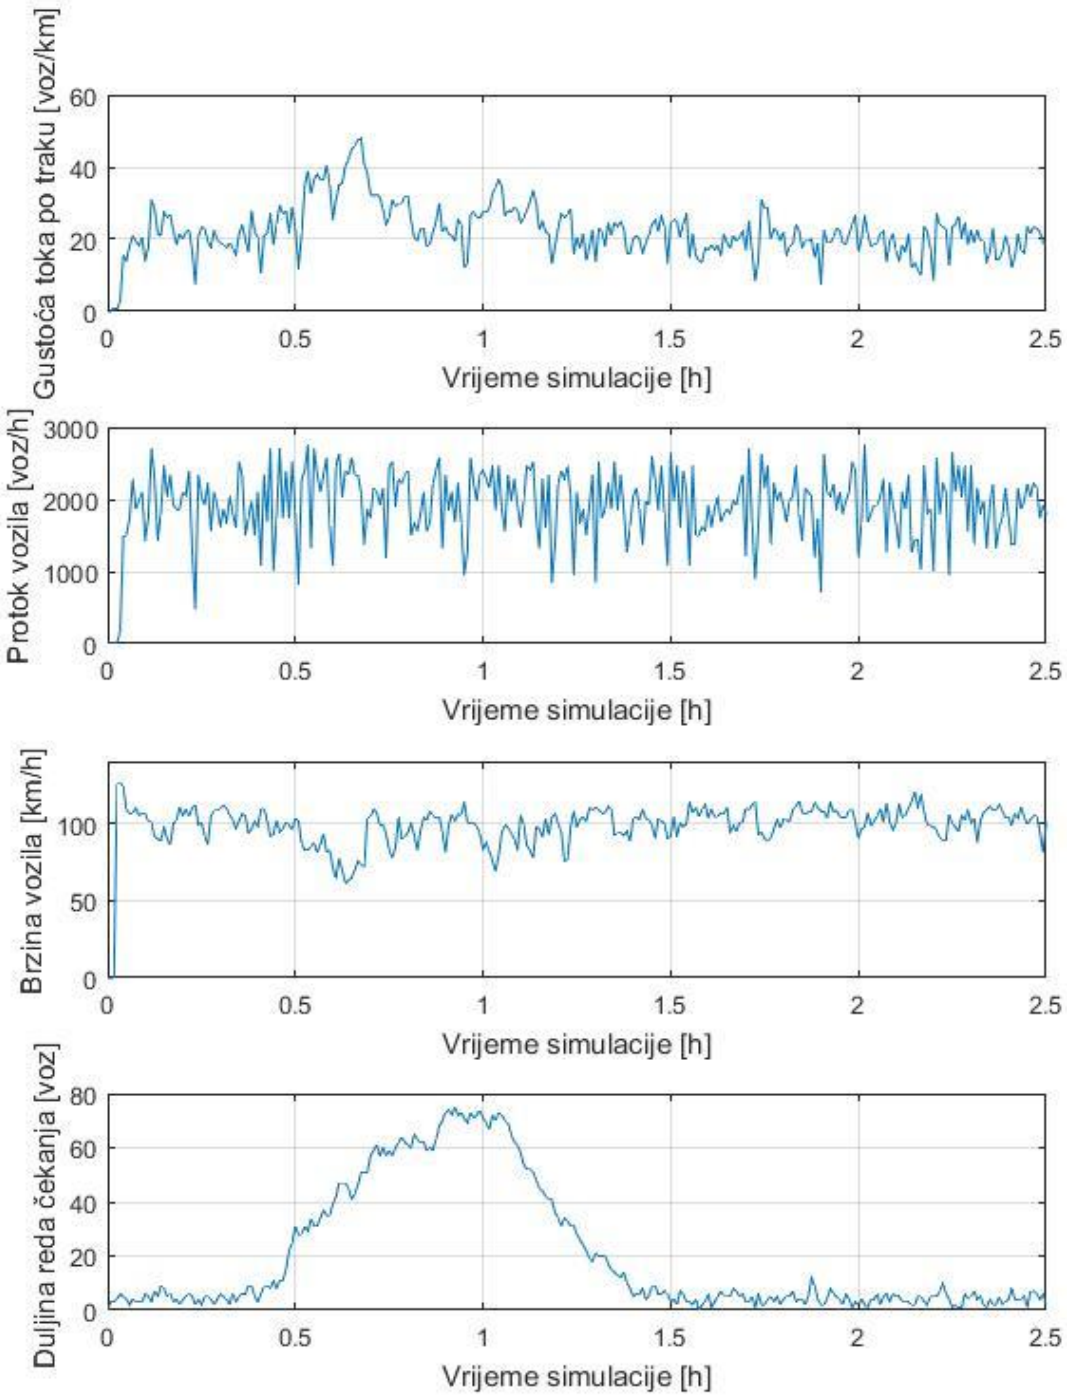
Drugi slučaj ispitivanja prometnog toka bio je s upravljanjem ustaljenim signalnim planom u kojem signalni ciklus traje 25 [s] od kojih je trajanje crvenog svjetla 15 [s], a zelenog 10 [s]. Na grafu gustoće prometnog toka po traku po kilometru se vidi smanjenje maksimalnog iznosa gustoće nego na prošlom primjeru. Maksimalna vrijednost gustoće u ovom slučaju doseže oko 50 [voz/km/trak], a prosječna brzina također pada na 60 [km/h] što se vidi na slici 18. Znatne promjene uočavaju se u grafu duljine reda čekanja gdje se lako vidi promjena u odnosu na prethodni slučaj. Broj vozila koji čekaju na priljevnoj rampi se dvostruko povećao, ali nije došlo do prelijevanja reda čekanja na sporednu prometnicu što je iznimno bitno za funkcioniranje cjelokupnog gradskog prometnog sustava. Samim time što je više vozila čekalo na priljevnom toku, znači da je protok na glavnom toku autoceste bio nesmetan i odvijao se u normalnim uvjetima rada. U upravljanju ustaljenim signalnim planom prosječna gustoća prometnog toka je bila 23,53 [voz/km/trak], srednja brzina je 97,02 [km/h], a prosječan broj vozila koji čekaju na rampi je 8,5 [voz].



Slika 18. Prikaz rezultata simulacije s upravljanjem ustaljenim signalnim planom

6.3. Simulacija prometnog toka s upravljanjem neizrazitim regulatorom

U slučaju upravljanja prometnim tokom s neizrazitim regulatorom upravljalo se na način da je zeleno signalno svjetlo podešeno na 4 [s], a neizraziti regulator mijenja trajanje crvenog svjetla po unešenim pravilima za neizrazito odlučivanje. Postavljeno je sedam signalnih programa koji se na osnovu izlazne varijable iz regulatora mijenjaju u stvarnom vremenu. Tako je gustoća prometnog toka nešto manja od prethodnog slučaja, a prosječna brzina vozila malo veća kao što je prikazano na slici 19. Najveća razlika je u tome što je znatno povećana duljina reda čekanja u periodu od 0,5h do 1,5 h. Razlog tomu je što je neizraziti regulator sastavljen od pravila koja kažu da je prioritet održati glavni tok gradske autoceste sa što boljim rezultatima čak i ako to znači dulje čekanje na prilaznom toku. U ovom slučaju prosječna gustoća prometnog toka je bila 22,29 [voz/km/trak], srednja brzina je 98,16 [km/h], a broj vozila koji čekaju na priljevnom toku 20,27 [voz].



Slika 19. Prikaz rezultata simulacije s upravljanjem neizrazitim regulatorom

6.4. Usporedba rezultata svih simulacija

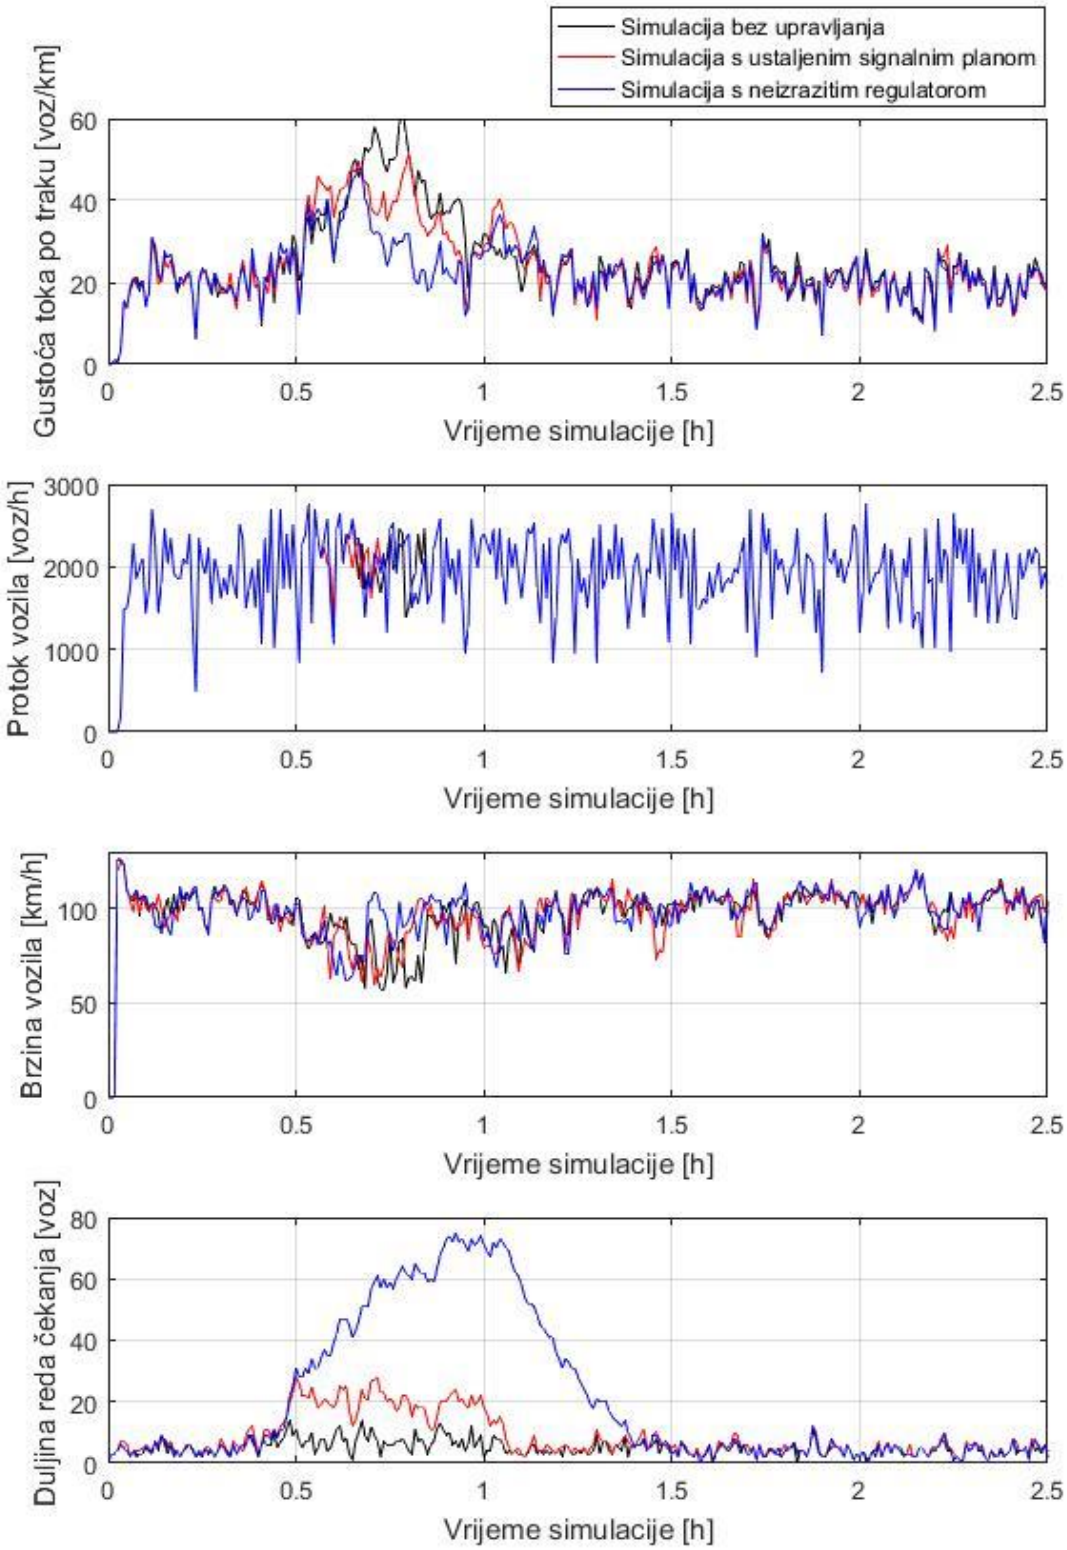
Tablica 1. Prikaz rezultata usporedbe simulacija upravljanja priljevnim tokom

	Simulacija bez upravljanja	**Simulacija s upravljanjem - ustaljeni signalni plan**	**Simulacija s upravljanjem -neizraziti regulator**
Prosječna gustoća prometnog toka [voz/km/trak]	24,57	23,53	22,29
Prosječna brzina prometnog toka [km/h]	97,11	97,02	98,16
Prosječna duljina repa čekanja [voz]	5	8,5	20,27
MAX gustoća [voz/km/h]	63	51,5	48
MIN gustoća [voz/km/h]	6	7,5	7,5
MAX brzina [km/h]	126,21	124,36	125,91
MIN brzina [km/h]	56,69	59,29	61,17
MAX protok [voz]	126	103	96
MIN protok [voz]	12	15	15

Tablica 2. Prikaz poboljšanja u odnosu na slučaj bez upravljanja

	Simulacija s upravljanjem - ustaljeni signalni plan	**Simulacija s upravljanjem - neizraziti regulator**
Prosječna gustoća prometnog toka	5,3%	6,8%
Prosječna brzina prometnog toka	-0,1%	1,1%
Prosječna duljina reda čekanja	-41,2%	-75,3%

Na slici 20. se vidi usporedba rezultata sve tri simulacije. Iako je broj vozila na priljevnom toku, odnosno duljina reda čekanja, vrlo velika u slučaju upravljanja neizrazitim regulatorom, gustoća prometnog toka na glavnom toku ima poboljšanje od 6,8% u odnosu na simulaciju bez upravljanja te 5,3% u odnosu na upravljanje ustaljenim signalnim planom. U tablici 1. prikazane su prosječne vrijednosti gustoće prometnog toka, brzine prometnog toka te duljine reda čekanja na priljevnom toku, u tablici 2. postotak poboljšanja sustava, a u tablici 3. minimalne i maksimalne vrijednosti pojedine simulacije. Za računanje poboljšanja uzeti su rezultati koji ne uključuju prvih 5 [min] simulacije jer je tada sustav još u procesu punjenja odnosno dolaska do stvarnog stanja.



Slika 20. Prikaz usporedbe rezultata simulacije bez upravljanja, s upravljanjem ustaljenim signalnim planom i upravljanjem neizrazitim regulatorom

7. Zaključak

Upravljanje priljevnim tokovima gradskih autocesta vrlo je bitan proces u upravljanju prometnim tokovima. Na taj način se održava optimalni prometni tok na glavnom toku gradske autoceste te na sporednoj prometnici koja povezuje gradske prometnice s gradskom autocestom. Poželjno je upravljati prometnim tokom na način da ne dolazi do prelijevanja repa čekanja vozila na prilaznoj rampi, u isto vrijeme propustiti dovoljno, ali ne i previše, vozila na glavni tok gradske autoceste kako ne bi dolazilo do zagušenja na glavnom toku. Nakon kreiranja okruženja za simulaciju upravljanja priljevnim tokovima gradskih autocesta simulirana su tri slučaja upravljanja priljevnim tokovima. Prvi slučaj je sustav bez upravljanja priljevnim tokom gradske autoceste. Drugi slučaj simulacije je bilo upravljanje priljevnim tokom gradske autoceste s ustaljenim signalnim planom gdje je signalni plan bio podešen na 10 [s] zelenog i 15 [s] crvenog svjetla. Zadnji slučaj simulacije bilo je upravljanje priljevnim tokom gradske autoceste pomoću neizrazitog regulatora kojem su dane ulazne varijable protok prije priljevnog toka, gustoća nakon priljevnog toka i duljina reda čekanja. izlazna varijabla iz regulatora je trajanje crvenog svjetla na signalnom uređaju. Pri izradi neizrazitog regulatora u programskom alatu MATLAB prvotno su podešene funkcije pripadnosti po mišljenju prometnog stručnjaka. Nakon simuliranja s takvim postavkama vidi se da sustav ima mane te se dodatno dorađuje. Naknadnim podešavanjem pravila u regulatoru dolazi se do poboljšanja rezultata simulacije. Grafički se prikazuju rezultati simulacije s upravljanjem neizrazitog regulatora i računaju prosječne vrijednosti prometnog toka te postotak poboljšanja u odnosu na slučaj bez upravljanja i slučaj upravljanja s ustaljenim signalnim planom.

S obzirom da neizraziti regulator radi na temelju dodijeljenih pravila potrebno je izraditi dovoljno dobar skup pravila kako bi prometni sustav ispravno radio. U ovom radu bilo je potrebno kreirati minimalno 27 pravila. Moguće je pravilima postaviti i stupanj težine (u ovom slučaju svugdje je težina 1). Također, bitno je točno odrediti funkcije pripadnosti i njihove vrijednosti. Nadalje, za dobro podešavanje pravila i funkcija pripadnosti potrebno je pomno odabrati napredne optimizacijske metode (npr. genetski algoritam) za unaprjeđenje trenutnog stanja sustava te za poboljšanje rezultata s upravljanjem neizrazitim regulatorom. To predstavlja prostor za nastavak rada na ovoj temi.

Literatura

[1] Bošnjak I.: Inteligentni transportni sustavi, Fakultet prometnih znanosti, Zagreb 2005.

[2] Šimunović, Lj.: Osnove prometnog inženjerstva, Fakultet prometnih znanosti, predavanja, Zagreb, 2015.

[3] Dadić I., Kos G., Ševrović M.: Teorija prometnih toka, Fakultet prometnih znanosti, Zagreb 2014.

[4] CHI Rong-hu, LI Jian-ying, LIU Xiang-peng: A New PI Controller for Freeway Ramp Metering Based on Fuzzy Logic, 25th Chinese Control and Decision Conference (CCDC), Guiyang, China, 2013.

[5] Šehagić D.: Sustav upravljanja priljevnim tokovima na urbanim autocestama, završni rad, Fakultet prometnih znanosti, Zagreb, 2017.

[6] Galić, I.: Usporedba metoda upravljanja priljevnih tokova na primjeru zagrebačke obilaznice, diplomski rad, Fakultet prometnih znanosti, Zagreb 2015.

[7] Federal Highway Administration. Preuzeto s: https://ops.fhwa.dot.gov/publications/fhwahop14020/sec1.htm [Pristupljeno: srpanj 2019.]

[8] Gregurić, M.: Inteligentno upravljanje priljevnim tokovima autoceste s osvrtom na mogućnost primjene na zagrebačkoj obilaznici, diplomski rad, Fakultet prometnih znanosti, Zagreb, 2011.

[9] Voskoglou, M.: Fuzzy Logic: History, Methodology and Applications to Education, Sumerianz Journal of Education, Linguistics and Literature, 2018, Vol. 1, No. 1, pp. 10-18

[10] Lončar, D.: Primjena neizrazite logike u regulacijskom sustavu termoenergetskog bloka, Fakultet strojarstva i brodogradnje, Zagreb, 2001.

[11] Ivanjko, E.: Automatsko upravljanje prometom i transportom, Fakultet prometnih znanosti, predavanja, Zagreb, 2018.

[12] MATLAB. Preuzeto s: https://www.mathworks.com/help/fuzzy/what-is-mamdani-type-fuzzy-inference.html [Pristupljeno: kolovoz 2019.]

[13] Xinrong Liang, Zheng Li: Freeway Ramp Control Based on Genetic PI and Fuzzy Logic, 2008 IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application, Wuhan, China, 2008.

[14] Ge, Y.: A Two-Stage Fuzzy Logic Control Method of Traffic Signal Based on Traffic Urgency Degree, Modelling and Simulation in Engineering, Volume 2014, Article ID 694185, 6 pages, 2014. Preuzeto s: https://www.hindawi.com/journals/mse/2014/694185/ [Pristupljeno: kolovoz 2019.]

[15] VISSIM. Preuzeto s: http://vision-traffic.ptvgroup.com/en-us/products/ptv-vissim/ [Pristupljeno: kolovoz 2019.]

[16] VISSIM. Preuzeto s: http://vision-traffic.ptvgroup.com/en-us/products/ptv-vissim/use-cases/emissions-modelling/ [Pristupljeno: kolovoz 2019.]

[17] Kapusta B.: Simulacija prioriteta prolaska vozila žurne službe kroz semaforizirano raskrižje, završni rad, Fakultet prometnih znanosti, Zagreb, 2017.

[18] Tettamanti, T.: A practical manual for Vissim COM programming in Matlab – 1st edition for Vissim 5.40, 2015.

Popis slika

1. Prikaz razina usluge na autocesti, [2]
2. Prikaz paraboličnog modela ''brzina-tok'', [3]
3. Prikaz izgleda prometnog toka s i bez upravljanja priljevnim tokom, [6]
4. Prikaz uređaja korištenih za upravljanje priljevnim tokovima, [7]
5. Prikaz razlike između izrazitog i neizrazitog skupa, [9]
6. Prikaz Lighthill-Whitham-Richards modela za upravljanje priljevnim tokom autoceste, [13]
7. Prikaz sučelja za izradu neizrazitog regulatora u MATLAB-u
8. Prikaz funkcija pripadnosti ulazne varijable ''protok prije priljevnog toka''
9. Prikaz funkcija pripadnosti ulazne varijable ''gustoća nakon priljevnog toka''
10. Prikaz funkcija pripadnosti ulazne varijable ''duljina reda čekanja''
11. Prikaz pravila za upravljanje neizrazitim regulatorom
12. Prikaz površine koju čine napisana pravila u neizrazitom regulatoru
13. Prikaz funkcija pripadnosti izlazne varijable ''trajanje crvenog''
14. Prikaz modela autoceste u VISSIM-u
15. Prikaz razmještaja mjernih mjesta na modelu autoceste u VISSIM-u
16. Prikaz dijagrama toka spajanja programskog paketa MATLAB i simulacijske aplikacije VISSIM, [15]
17. Prikaz rezultata simulacije bez upravljanja
18. Prikaz rezultata simulacije s upravljanjem ustaljenim signalnim planom
19. Prikaz rezultata simulacije s upravljanjem neizrazitim regulatorom
20. Prikaz usporedbe rezultata simulacije bez upravljanja, s upravljanjem ustaljenim signalnim planom i upravljanjem neizrazitim regulatorom

Popis tablica

1. Prikaz rezultata usporedbe simulacija upravljanja priljevnim tokom
2. Prikaz poboljšanja u odnosu na sustav bez upravljanja

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj završni 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 završnog rada pod naslovom **Okruženje za simulaciju upravljanja priljevnim tokovima na gradskim autocestama zasnovano na neizrazitoj logici** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 5.9.2019

Student/ica:

(potpis)