Upravljanje prioritetom prolaska vozila žurnih službi kroz izolirano semaforizirano raskrižje primjenom neizrazite logike

Kapusta, Borna

Master's thesis / Diplomski rad

2019

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:789877

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Borna Kapusta

UPRAVLJANJE PRIORITETIMA PROLASKA VOZILA ŽURNIH SLUŽBI KROZ IZOLIRANO SEMAFORIZIRANO RASKRIŽJE PRIMJENOM NEIZRAZITE LOGIKE

DIPLOMSKI RAD

Zagreb, 2019.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 4. travnja 2019.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Umjetna inteligencija**

DIPLOMSKI ZADATAK br. 5289

Pristupnik: **Borna Kapusta (0135233675)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Inteligentni transportni sustavi

Zadatak: **Upravljanje prioritetom prolaska vozila žurnih službi kroz izolirano semaforizirano raskrižje primjenom neizrazite logike**

Opis zadatka:

Radi smanjenja vremena putovanja vozila žurnih službi koristi se upravljanje prioritetom njihovog prolaska kroz semaforizirano raskrižje. Jedna od mogućnosti je i primjena neizrazite logike. U radu je potrebno opisati problem upravljanja prioritetom prolaska žurnih službi te implementirati algoritam promjene signalnog plana primjenom neizrazite logike koji upravlja izoliranim semaforiziranim raskrižjem ovisno o prometnoj potražnji. Također ispitati mogućnosti optimizacije pravila sustava neizrazitog zaključivanja.

Mentor:

izv. prof. dr. sc. Edouard Ivanjko

Predsjednik povjerenstva za diplomski ispit:

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

UPRAVLJANJE PRIORITETIMA PROLASKA VOZILA ŽURNIH SLUŽBI KROZ IZOLIRANO SEMAFORIZIRANO RASKRIŽJE PRIMJENOM NEIZRAZITE LOGIKE

PREEMPTIVE TRAFFIC LIGHT CONTROL FOR EMERGENCY VEHICLES ON ISOLATED INTERSECTIONS USING FUZZY LOGIC

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

Student: Borna Kapusta
JMBAG: 0135233675

Zagreb, rujan 2019.

Zahvale

Zahvaljujem se svojem mentoru izv. prof. dr. sc. Edouardu Ivanjku na brojnim savjetima, smjernicama i riječima podrške prilikom pisanja ovog rada. Zahvaljujem se kolegi Mladenu Miletiću mag. ing. traff. na dosadašnjoj suradnji na radovima koji su bila podloga za ovaj rad. Zahvaljujem se tvrtci PTV na ustupljenom simulacijskom alatu za modeliranje prometne mreže i prometnih entiteta PTV VISSIM. Također, zahvaljujem se svojoj obitelji i prijateljima na potpori te strpljenju tijekom mojeg studiranja.

Sažetak

Naslov: Upravljanje prioritetima prolaska vozila žurnih službi kroz izolirano semaforizirano raskrižje primjenom neizrazite logike

Zbog sve veće prometne potražnje i razvoja društva, u gradskim sredinama dolazi do sve više prometnih zagušenja i nesreća. Nemogućnost širenja prometne infrastrukture u gradskim sredinama stvara potrebu za uvođenjem pametnijih rješenja upravljanja već postojećom prometnom infrastrukturom. Takvi sustavi i pristupi upravljanja koji nam donose bolje iskorištavanje postojeće infrastrukture zovu se inteligentni transportni sustavi (ITS). Implementacijom servisa ITS-a za upravljanje semaforiziranim raskrižjem korisnicima može pružati rasterećenje prometa i informiranje putnika te dodatne mogućnosti poput dodjele prioriteta vozilima žurnih službi. Uvođenjem upravljanja prioritetima semaforiziranim raskrižjima moguće je smanjiti vrijeme putovanja određenim skupinama vozila kao što su vozila žurnih službi. U radu je opisano i analizirano upravljanje prioritetima prolaska vozila žurnih službi kroz semaforizirano raskrižje primjenom neizrazite logike s naglaskom na optimizaciju pomoću genetskog algoritma. Za implementiranje i analiziranje algoritma, izrađeno je okruženje za simulaciju takvog upravljanja korištenjem mikroskopskog simulatora VISSIM i programskog paketa MATLAB.

Ključne riječi: Inteligentni transportni sustavi, upravljanje prioritetima za vozila žurne službe, neizrazito upravljanje, genetski algoritam (GA), adaptivno upravljanje

Abstract

Title: Preemptive Traffic Light Control for Emergency Vehicles on Isolated Intersections Using Fuzzy Logic

Due to increasing traffic demand and development of society in urban areas, the number of traffic congestions and accidents is on the rise. The inability to expand transportation infrastructure in urban areas is creating the need to introduce smarter management solutions for the existing transportation infrastructure. The systems and management approaches which better utilize existing infrastructure are called Intelligent Transport Systems (ITS). The implementation of ITS services in traffic light control can provide users with the added convenience of delivering better traffic demand and information to passengers as well as priority assignment to emergency services vehicles. By implementing preemptive traffic light control systems in urban areas it is possible to reduce the travel time of specific groups of vehicles such as emergency vehicles. This paper describes and analyses the preemptive traffic light control for emergency vehicles on isolated intersections using fuzzy logic with an emphasis on genetic algorithm optimization. To implement and analyze the algorithm, an environment for simulating such a system is developed using the microscopic simulator VISSIM and the MATLAB software package.

Keywords: Intelligent transport systems, priority control of emergency vehicles, fuzzy control, genetic algorithm (GA), adaptive control

Sadržaj

1. Uvod **1**

2. Upravljanje prioritetom prolaska vozila žurnih službi **3**

2.1. Strategije dodjeljivanja prioriteta na semaforiziranim raskrižjima 4

2.1.1. Pasivne strategije dodjele prioriteta 5

2.1.2. Aktivne strategije dodjele prioriteta 7

2.1.3. Prometno adaptivne strategije dodjele prioriteta 9

2.2. Algoritam za dodjelu prioriteta zasnovan na duljini repa čekanja i praćenju vozila 10

2.2.1. Algoritam za dodjelu prioriteta 11

2.2.2. Algoritam vraćanja oduzetog vremena 13

3. Primjena neizrazite logike za upravljanje signalnim planom semaforiziranog raskrižja **15**

4. Implementacija neizrazitog upravljanja prioritetima vozila žurnih službi **20**

5. Optimizacija pravila sustava neizrazitog zaključivanja **23**

5.1. Strategija optimizacije 23

5.2. Prirodni evolucijski procesi 24

5.3. Uvod u genetske algoritme 25

5.4. Kôdiranje 27

5.5. Funkcija dobrote 28

5.6. Selekcija 29

5.6.1. Jednostavna selekcija 30

5.6.2. Turnirska selekcija 31

5.6.3. Eliminacijska selekcija 31

5.7. Elitizam 32

5.8. Genetski operatori 33

5.8.1. Križanje . . . 33
5.8.2. Mutacija . . . 35
5.9. Implementacija genetskog algoritma . . . 35
5.9.1. Kôdiranje neizrazitih pravila . . . 36
5.9.2. Kôdiranje funkcija pripadnosti . . . 36
5.9.3. Križanje i mutacija . . . 37
5.9.4. Agregacija i optimizacija više scenarija . . . 38

6. Simulacijski rezultati **40**
6.1. Simulacijsko okruženje . . . 40
6.2. Prometni model i podaci . . . 41
6.3. Analiza dobivenih rezultata . . . 44
6.3.1. Analiza rezultata za scenarije 1 i 2 . . . 45
6.3.2. Analiza rezultata za scenarij 3 i 4 . . . 46
6.3.3. Analiza rezultata za scenarij 5 i 6 . . . 48
6.3.4. Sažetak analize rezultata . . . 50

7. Zaključak **54**

Popis literature **56**

Popis ilustracija **59**

Popis tablica **60**

Popis grafikona **61**

1. Uvod

Razvoj motoriziranog prometa te gradskih sredina doveo je do eksponencijalno rastućeg broja prometnih entiteta na prometnicama. Sve veća prometna potražnja uzrokovala je negativne posljedice kao što su zagušenje prometa i smanjenje sigurnosti u prometu. Samim time sve više se pažnje pridodavalo pravilima i propisima za ponašanje sudionika u prometu pa tako i potrebi za uvođenjem uređaja za regulaciju prometa kao što su to npr. semafori. Sve većom potrebom za prijevoz prometnih entiteta uzrokovalo je brzo razvijanje prometne infrastrukture i povećanjem broja vozila u gradskim sredinama.

Svojim djelovanjem na ekonomiju, gospodarstvo, zdravstvo i sve ostale bitne čimbenike razvoja i funkcionalnosti društva, promet je postao složen i vrlo bitan. Ne može se gledati na njega kao sustav kojim se može jednostavno upravljati već je izrazito složen sa stanovišta tehničkih, tehnoloških, organizacijskih i društvenih čimbenika. Zbog sve veće prometne potražnje i ograničenjima infrastrukture u gradskim sredinama, nastaje potreba za implementiranjem pametnijih sustava upravljanja. Takva upravljanja, koja ujedno omogućuju informacijsku transparentnost, upravljivost i poboljšan odziv prometnog sustava donose danas inteligentni transportni sustavi (ITS). U [1] se može naći sljedeća definicija ITS-a: ”ITS se definira kao holistička, upravljačka i informacijsko- komunikacijska (kibernetska) nadogradnja klasičnog sustava prometa i transporta kojim se postiže znatno poboljšanje performansi, odvijanje prometa, učinkovitiji transport putnika i roba, poboljšanje sigurnosti u prometu, udobnost i zaštita putnika, manja onečišćenja okoliša, itd.” [1, 2].

Jedna od najčešće primjenjivanih metoda upravljanja prometom u današnjim gradskim područjima su sustavi upravljanja semaforima s jednim ili više unaprijed određenih signalnih planova. Primjenom adaptivnih sustava upravljanja semaforima moguće je izmijeniti postojeće signalne planove promjenom redoslijeda faza ili izravno utječući na određeno trajanje pojedine faze. U gusto naseljenim gradskim područjima, prometna zagušenja mogu uzrokovati značajna kašnjenja koja su dodatno povećana ustaljenim signalnim planovima koji se nisu u stanju nositi sa stohastičkom prirodom prometnih tokova. Za povećanje protoka raskrižja i smanjenje kašnjenja, mogu se primijeniti adaptivni upravljački sustavi. Osim toga, adaptivni sustavi se mogu koristiti i za prioritetno dodjeljivanje prava prolaska vozilima javnog prijevoza i vozilima žurnih službi [3].

Budući da tradicionalni matematički modeli upravljanja, odnosno na njima zasnovani sustavi upravljanja, nisu uvijek zadovoljavajućih performansi zbog velike složenosti prometnih tokova, implementacija neizrazitog upravljanja je uvelike pomogla pri poboljšanju rasterećenja prometne potražnje. Neizrazita logika nalikuje ljudskoj metodologiji odlučivanja te se bavi nejasnim i nepreciznim informacijama. Glavna značajka neizrazite logike je sposobnost prevođenja ljudskog oblika zaključivanja i upravljanja u formalni matematički opis i računalni program.

Međutim o izboru pravila odlučivanja i funkcija pripadnosti na kojima se zasniva neizrazita logika, odlučuje stručnjak. Budući da čovjek odlučuje o dizajnu modela upravljanja, uvijek ima prostora za pogreške i optimizaciju. Proces odabira ispravnih pravila i funkcija pripadnosti se zasniva na mišljenju stručnjaka te isprobavanju i ispravljanju pogrešaka. U tom procesu može pomoći genetski algoritam (GA). On je pretraživačkog tipa, odnosno optimizacijski algoritam osnovan na biološkim procesima selekcije i genetike.

Cilj ovog rada je predstaviti problematiku dodjele prioriteta prolaska vozilima žurnih službi primjenom adaptivnog upravljanja na semaforiziranim raskrižjima pomoću neizrazite logike. Kroz rad će se opisati implementacija algoritma, optimizacija neizrazitih pravila pomoću GA te evaluacija algoritma dodjele prioriteta vozilima žurnih službi. Algoritam je zasnovan na praćenju lokacije vozila i duljine repa čekanja te je implementiran za slučaj izoliranog semaforiziranog raskrižja korištenjem simulacijskog alata PTV VISSIM i programskog paketa MATLAB.

Ovaj rad je sastavljen od sedam poglavlja. U uvodnom poglavlju iznesena je motivacija, cilj i osnovna struktura rada. U drugom poglavlju su opisane tehnike dodjele prioriteta vozilima žurnih službi te je prikazan i opisan predloženi algoritam za dodjelu prioriteta zasnovan na duljini repa čekanja i praćenja vozila žurnih službi. U trećem poglavlju opisana je primjena neizrazite logike za upravljanje signalnim planom semaforiziranog raskrižja. U četvrtom poglavlju opisana je implementacija neizrazite logike u algoritmu za upravljanje signalnim planom semaforiziranog raskrižja. Peto poglavlje opisuje i daje pregled GA te objašnjava njegovu primjenu za optimizaciju pravila i pripadnih funkcija neizrazitog upravljača. U šestom poglavlju su opisani prometni scenariji korišteni u simulacijama te je dan prikaz i analiza rezultata. U zadnjem poglavlju dan je zaključak prema prethodnim poglavljima s prijedlozima za nastavak rada na ovoj temi.

2. Upravljanje prioritetom prolaska vozila žurnih službi

Semaforizirana raskrižja igraju glavnu ulogu u sigurnosti i efikasnosti kretanja svih prometnih entiteta u gradskom prometu. Glavni cilj semaforiziranog raskrižja, odnosno signalnog plana je koordinacija prometnih entiteta bilo koje skupine na način da se kreću što efikasnije i sigurnije. Takvim tehnikama i strategijama postiže se minimalno vrijeme putovanja i vrijeme čekanja, te se smanjuje mogućnosti stvaranja konflikata, odnosno prometnih nesreća. Signalni planovi su izrađeni i implementirani samo za individualno raskrižje koje je uzeto u obzir bez mogućnosti za široku primjenu na drugim raskrižjima. Svako raskrižje je problematika za sebe. Također, upravljanje prometom treba biti planirano i implementirano na razini cijelog sustava [3, 4].

Zbog sve veće zagušenosti prometa u gradskim sredinama, problem dodjele prioriteta na semaforiziranim raskrižjima postaje aktivna tema istraživanja. Dodjela prioriteta se prvenstveno razvija zbog potrebe optimizacije prometa javnog gradskog prijevoza (JGP), ali se zbog analogije pristupa može primjeniti i na vozila žurnih službi. Iznenadni dolazak žurnih službi na raskrižje na putu do hitnog slučaja može biti jako stresno i dezorijentirajuće za ostale sudionike u prometu kako bi se na vrijeme i sigurno maknuli s puta vozila žurne službe. Takvi scenariji često rezultiraju konfliktima vozila žurnih službi s drugim sudionicima u prometu, blokiranjem vozila i zagušenjem prometnih tokova [5].

Prema detaljnoj i opsežnoj analizi Ureda za promet države Oregon, SAD (engl. State of Oregon, Office of Transportation) ustanovilo se da 31% do 39% ukupnog putovanja vozila JGP-a otpada na samu vožnju, dok se ostatak vremena potroši na čekanje na stajalištima, raskrižjima te zastojima u prometu. Prema toj analizi 27% ukupnog vremena putovanja uključuje čekanje na semaforiziranim raskrižjima [6]. Taj je postotak moguće smanjiti odgovarajućim adaptivnim upravljanjem semaforiziranim raskrižjem.

2.1. Strategije dodjeljivanja prioriteta na semaforiziranim raskrižjima

Dodjeljivanje prioriteta je upravljačka metoda koja omogućava brže kretanje vozila poput žurnih službi i JGP-a prilagođavanjem signalnih planova. Dodjeljivanje prioriteta na semaforiziranim raskrižjima je mjera ITS-a koja modificira ustaljeni proces prometne signalizacije radi boljeg odvijanja prometa za ciljanu skupinu prometnih entiteta. Cilj je smanjiti vrijeme čekanja i vrijeme putovanja, te povećati kvalitetu usluge s minimalnim utjecajem na ostali promet. Adaptivno upravljanje prometom je testirano i implementirano diljem svijeta, posebice u Europi i Sjedinjenim Američkim Državama. Mnoga istraživanja kao što navodi [7], pokazala su da utjecaji i efektivnost strategija upravljanja dodjeljivanjem prioriteta dosta ovisi o prometu u okolici. Stoga, kako bi se odabrala idealna strategija potrebno je analizirati kako određena strategija utječe na određenu prometnu okolinu [4, 7].

Strategije dodjeljivanja prioriteta su implementirane i testirane na prometnoj infrastrukturi ili u računalnoj simulaciji u posljednjih 20 ili 30 godina. Zahvaljujući tim istraživanjima i testiranjima postoje mnogobrojne recenzije i evaluacije strategija u različitim promjenama uvjeta u prometnoj mreži. Strategije dodjeljivanja prioriteta na semaforiziranim raskrižjima mogu se podijeliti na tri osnovna pristupa [6, 8]:

- **Aktivni i pasivni prioriteti** - aktivni prioriteti se odnose na detekciju pristupa vozila žurne službe u stvarnom vremenu; dok se pasivni prioriteti odnose na prethodno izmjerenim prometnim veličinama i uključuju predefiniranu koordinaciju signalnog plana;
- **Potpuni, djelomični i relativni prioriteti** - prema [8], strategije dodjeljivanja apsolutnog, djelomičnog i relativnog prioriteta mogu se opisati:
  - **Apsolutni prioritet** - strategija koja daje potpuni prioritet i zelenu fazu bez čekanja. Nastoji vozilu žurne službe dati pravo prolaska raskrižju bez odgode;
  - **Djelomični prioritet** - djelomično davanje prioriteta dopušta strategiju s najmanje utjecaja na ostali promet, poput produživanje zelene faze i skraćivanje faze crvenog svijetla s ciljem ranijeg početka faze zelenog svijetla;
  - **Relativni prioritet** - pod relativnim prioritetom vozilo kojem je potrebna dodjela

prioriteta, uspoređuje se s ostalim prometom za dodjelu prioriteta i faze zelenog svijetla. Jedan od značajki odnosno bitnosti zahtjeva je broj putnika, ali zahtjev može biti odbijen zbog prometnog volumena i veće duljine repa čekanja na ostalim prilazima.

- **Uvjetni i bezuvjetni prioriteti** - pristup koji se uglavnom odnosi na vozila JGP-a. Bezuvjetni prioritet je ako se vozilu JGP-a dodjeli prioritet, bez obzira na uvjete u kojima se nalazi, poput popunjenosti vozila, kašnjenja za voznim redom i slično. Tehnike uvjetnog prioriteta koriste uključivanje dodjelu prioriteta samo ako vozilo ispunjava definirane uvjete poput kašnjenja za voznim redom, promjena linije itd.

2.1.1. Pasivne strategije dodjele prioriteta

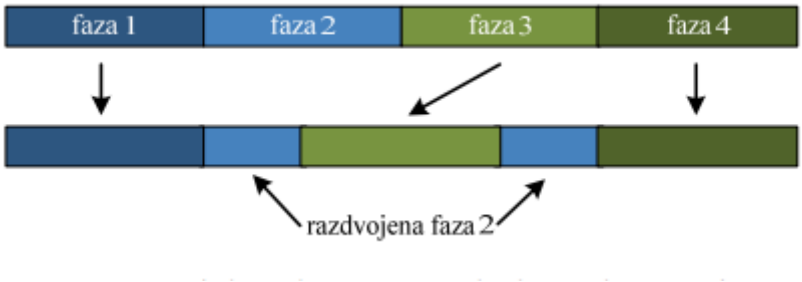
Pasivne strategije koriste prethodno obavljene analize i mjerenja relevantnih prometnih veličina prometnog toka, te zahtjeva sustav vozila koji traži dodjeljivanje prioriteta kao ulazne parametre za izmjenu signalnog plana. Strategija pasivne dodjele prioriteta ne zahtjeva sustav nadgledanja, kao ni sustav detekcije i praćenja vozila. Ne obrađuje i ne koristi trenutne mjerne podatke s prometnice, odnosno promjene prometnog toka. Cilj pasivne strategije je smanjiti vrijeme čekanja vozila na semaforiziranom raskrižju smanjenjem trajanja ciklusa ili izmjenom redoslijeda pojedinih faza da bi se omogućilo što veća učestalost zelenog svjetla [6].

Podešavanje vremena trajanja ciklusa signalnog plana

Tehnika produljenja faze zelenog svijetla uključuje detekciju odabranog vozila, dodjelu prioriteta te produljenje faze zelenog svijetla dok vozilo žurne službe ne prođe. Produljenje faze zelenog svijetla može se svrstati u dvije vrste: produljenje zelenog svjetla, te skraćivanje trajanja crvenog svjetla. Na osnovu predviđenog dolaska vozila na raskrižje, faze se modificiraju tako da se dodjeli zeleno svjetlo odabranom vozilu [6].

Razdvajanje faza

Tehnika razdvajanje faza dijeli trenutnu signalnu fazu na privozu vozila kojem je potrebna dodjela prioriteta u više faza s duljinom jednakom originalnom trajanju. Tehnika razdvajanja faza se koristi kod raskrižja kod kojih je striktno napravljen signalni plan i ne smije se mijenjati trajanje pojedinih faza kako se ne bi utjecalo na protok ostalog prometa [6].



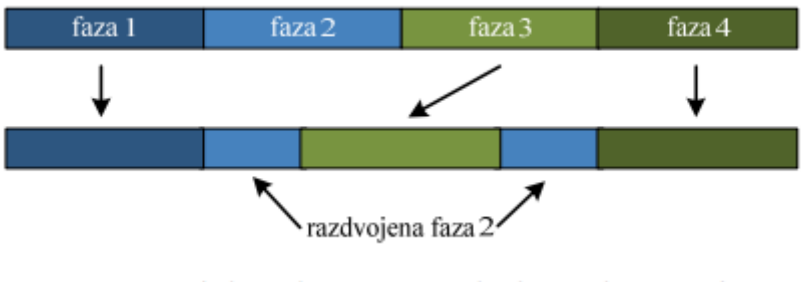
Slika 1: Grafički prikaz pasivne tehnike razdvajanja faze [6]

Koordinacija voznog reda

Tehnika dodjele prioriteta pomoću koordinacije, uglavnom se odnosi na vozila JGP-a. Ova tehnika je osnovana na rasporedu dolaska JGP-a. Signalni plan se koordinira po voznom redu JGP-a, poput zelenog vala. Ne mora se odnositi samo na jednu prometnicu, ali se ne koristi zbog velikih odstupanja posluživanja, odnosno vremena potrebnog da se putnici iskrcaju i ukrcaju u vozilo JGP-a na stajalištima [6].

Smanjenje vremena trajanja ciklusa

U tehnici smanjenja trajanja ciklusa cilj je povećanje frekvencije uključivanja zelenog svjetla pomoću smanjenja trajanja svih faza u signalnom planu. Većom frekvencijom uključivanja zelenog svjetla vozilima kojima je potreban prolaz kroz raskrižje omogućavamo brži prolaz kroz raskrižje, ali ako nema odabranih vozila nema ni negativnih efekta. Vrijeme trajanja faza se ravnomjerno smanjuje u ciklusu relativnom udjelu pojedine faze [6].

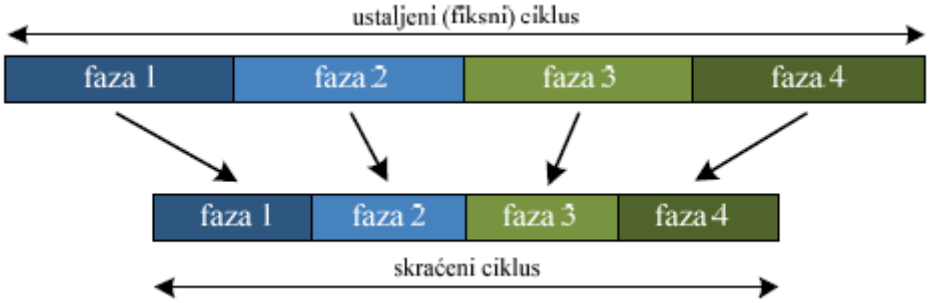


Slika 2: Grafički prikaz pasivne tehnike razdvajanja faze [6]

”Preskakanje” repa čekanja

Tehnika preskakivanja repa čekanja može se koristiti i idealna je za raskrižja s infrastrukturom koja omogućava vozilima JGP-a i vozilima žurnih službi poseban trak za brži prolaz kroz raskrižje. Ova tehnika omogućava dodatnoj prometnoj traci dodatno zeleno svjetlo (ranije zeleno

svjetlo) da bi odabrana vozila brže prošla kroz raskrižje [6].



Slika 3: Grafički prikaz pasivne tehnike smanjenja trajanja ciklusa [6]

2.1.2. Aktivne strategije dodjele prioriteta

Strategija aktivne dodjele prioriteta zahtjeva mogućnost obrade mjernih podataka s osjetila na prometnicama, odnosno raskrižjima u stvarnom vremenu. Kako bi se takva strategija implementirala potrebni su mjerni podaci u stvarnom vremenu za sustav detekcije i identifikacije ciljane skupine vozila kojima je potrebna dodjela prioriteta. Takvim sustavima omogućena je izmjena signalnog plana u svrhu što manjeg čekanja ciljane skupine vozila na prolazak raskrižjem. Kao takve, ove strategije su zbog preciznosti i učinkovitosti trenutno najčešće korištene strategije upravljanja semaforiziranim raskrižjima. Prema [6] četiri skupine aktivnih tehnika mogu se dijeliti na [4]:

1. Produljenje trajanja zelenog svjetla;
2. Skraćivanje crvenog svjetla, odnosno raniji početak zelenog svjetla:
3. Dodatna faza za ciljanu skupinu vozila;
4. Selektivne strategije.

Produljenje trajanja zelenog svjetla

Kako bi se smanjilo čekanje određene skupine vozila na semaforiziranom raskrižju, ili ga u potpunosti maknulo, koristi se tehnika produljenja trajanja zelenog svjetla. Tehnika produljenja trajanja zelenog svjetla na dolazak odabrane skupine vozila produljuje fazu zelenog svjetla sve dok vozilo ne prođe raskrižje ili ne istekne najduže vrijeme produljenja faze. Ako se ne radi o žurnim službama, maksimalna vrijednost trajanja zelenog svjetla mora se definirati zbog

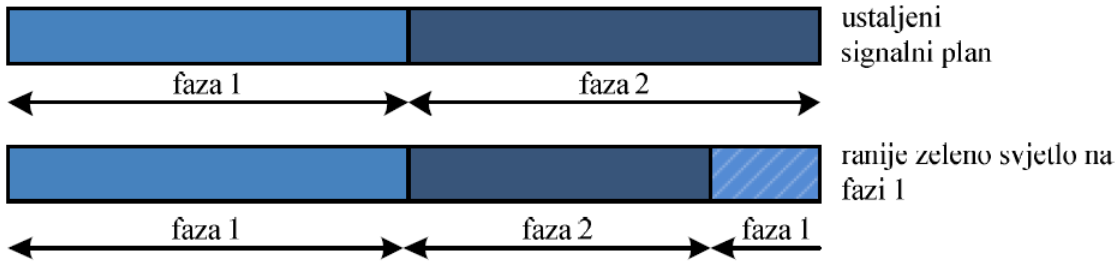
utjecaja na protok vozila na ostalim privozima raskrižja i mogućnosti višestrukih zahtjeva za prioritetom [6].

Tehnika produljenja trajanja zelenog svjetla uglavnom se koristi na raskrižjima sa samo dvije faze. Također maksimalno produljenje zelenog svijetla ima ograničenja zbog utjecaja na ostatak prometa. Najduže vrijeme produljenja vremena faze zelenog svjetla se mijenja ovisno o prometnom opterećenju, broju vozila kojima je potrebno adaptivno upravljanje itd. U većini slučajeva koriste se granice u vremenskom okviru od 10 do 20 sekundi ili relativno produljenje trajanja faze do 20 % [7]. Relativno produljenje trajanje faze je korišteno u ovom radu s najvećim dopuštenim iznosom od 20%. Kada je riječ o vozilima žurne službe i opasnosti po život, faza zelenog svjetla se produljuje sve dok vozilo ne prođe upravljano raskrižje [4].

Kako bi se detektirao dolazak i prolazak odabranog vozila kroz raskrižje, potrebna su dva detektora. Jedan prije raskrižja kako bi sustav znao da vozilo dolazi i traži prioritet, te jedan nakon raskrižja kako bi sustav znao da je vozilo prošlo kroz raskrižje. U novije vrijeme koriste se tehnologije poput GPS-a, kod kojeg nisu potrebni detektori na infrastrukturi, već samo uređaj u vozilu koji koordinate vozila na prometnici javlja upravljačkom sustavu raskrižja [6].

Skraćivanje vremena trajanja crvenog svjetla, odnosno raniji početak zelenog svjetla

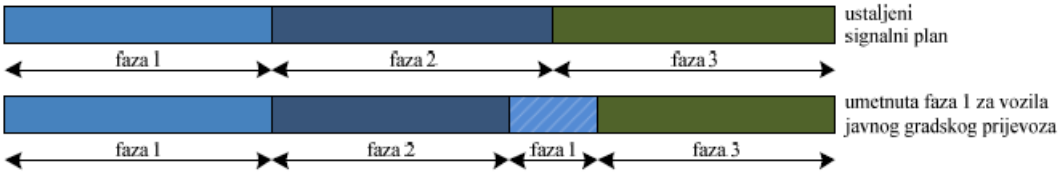
Ovom tehnikom se skraćuje trajanje faze crvenog svjetla ukoliko odabrana skupina vozila prilazi raskrižju, a predviđen je dolazak za vrijeme trajanja crvenog svjetla. Ova tehnika se koristi kako bi se skratilo vrijeme čekanja odabrane skupine vozila, te ranije uključilo zeleno svjetlo na tom privozu. Ukoliko je po signalnom programu definirano više faza na raskrižju, moguće je skratiti sve ili samo neke faze. Isto kao i kod tehnike produljenja trajanja zelenog svjetla, tehnika skraćivanja trajanja crvenog svjetla ima minimalno trajanje faze. Maksimalna vrijednost skraćenja trajanja crvenog svjetla se također mijenja i ovisi o specifičnostima pojedinih raskrižja, te o matrici zaštitnih međuvremena, odnosno najkraćem vremenu potrebnom da pješaci prijeđu cestovnu prometnicu. Ova strategija je kao i tehnika produljenja trajanja zelenog svjetla, najčešća na raskrižjima sa dvije signalne grupe [4, 6].



Slika 4: Grafički prikaz tehnike ranijeg početka zelenog svjetla [6]

Dodatna faza za ciljanu skupinu vozila

U ovoj tehnici, nova faza dodana je u ciklus kako bi dala prioritet vozilu kojem je potreban prioritet. Tehnika dodavanja faze u ciklusu je isključivo primjenjiva na raskrižjima sa dvije ili više faza. Dobar primjer je dodavanje faze kada vozilo treba skrenuti lijevo na raskrižju s dvije faze. Na slici 5 grafički je prikazana tehnika dodavanja faze između postojeće faze 2 i faze 3 [6].



Slika 5: Grafički prikaz tehnike umetanja faze za ciljanu skupinu vozila [6]

Selektivne strategije

Selektivna strategija dodjele prioriteta uključuje odabir najpogodnije tehnike aktivne dodjele prioriteta s obzirom na predviđeno vrijeme dolaska vozila JGP-a na semaforizirano raskrižje. Odnosno ovisi o predviđenom vremenu dolaska odabranog vozila na semaforizirano raskrižje i o trenutnoj aktivnoj fazi u trenutku dolaska vozila na raskrižje [6].

2.1.3. Prometno adaptivne strategije dodjele prioriteta

Na prometnoj mreži gdje se promet regulira neadaptivnim i nekoordiniranim signalnim planovima dolazi do nepotrebnog zaustavljanja i prekidanja prometnih tokova. ITS rješenja adaptivnog vođenja prometnog toka rješavaju takve probleme te nastoje održati ukupnu razinu uslužnosti pojedinog raskrižja. U odnosu na koordinirani ustaljeni režim rada semafora, adaptivni je složeniji, ali i učinkovitiji. Adaptivne strategije nazivamo i stvarnovremenskim strategijama

iz razloga što se odluka o promjeni signalnog plana osniva na stvarnovremenskim prometnim podacima. Kao takve, odluke o izmjenama signalnog plana zasnivaju se na težinskim faktorima ili na prethodno definiranim korisničkim algoritmima za donošenje odluka, a ne na predefiniranim strategijama dodjele prioriteta [1, 4].

Adaptivno upravljanje signalnim planovima je bitna komponenta u ITS-u. ITS rješenje adaptivnog upravljanja prometnim tokom povećava propusnost tako da se redoslijed faza i trajanja ciklusa stalno prilagođavaju promjenjivim potrebama prometnog toka i uvjetima okruženja. Prema [6, 9] tri su osnovna pristupa optimizacije rada prometno adaptivnih dodjela prioriteta koje se najčešće koriste:

- Klasični optimizacijski model;
- Modeli zasnovani na GA i neuronskim mrežama;
- Algoritmi zasnovani na neizrazitoj logici.

2.2. Algoritam za dodjelu prioriteta zasnovan na duljini repa čekanja i praćenju vozila

Nesreće i medicinski hitni slučajevi kao što su požar, prometne nesreće, srčani udari itd. javljaju se svakodnevno. Važno je da žurne službe dođu do mjesta nesreće u što kraćem roku kako bi spasili ljudske živote. Tako se bolnice i vatrogasne stanice ravnomjerno postavljaju po gradu (gradskim sredinama) kako bi se smanjilo vrijeme odaziva. Međutim, brz rast populacije u gradovima rezultirao je velikim gustoćama prometa na gradskim prometnicama. Prilikom putovanja po potrebnoj ruti, vozila žurnih službi najviše gube vremena na semaforiziranim raskrižjima. Razlog tome su osobni automobili u redu čekanja pred raskrižjem iako vozači ipak nastoje propustiti vozila žurnih službi i osloboditi im prostor za prolazak. Takav proces raščišćavanja je spor i nepouzdan, a uz to je i značajno narušena sigurnost svih sudionika u prometu [4].

Cilj algoritma za dodjelu prioriteta je smanjiti izgubljeno vrijeme vozila žurnih službi i povećati sigurnost svih sudionika u prometu utjecanjem na signalni plan raskrižja. Ulazni podaci na kojima je zasnovan algoritam su lokacija i brzina vozila žurne službe te broj vozila u redu čekanja na svim privozima raskrižju. U stvarnom sustavu lokaciju i brzinu vozila moguće je

odrediti korištenjem GPS prijemnika dok se za određivanje broja vozila u redu čekanja mogu koristiti razni detektori, video prepoznavanje itd. [3].

Algoritam za dodjelu prioriteta zasnovan na duljini repa čekanja i praćenju vozila se dijeli na dva dijela. Prvi dio algoritma omogućava raščišćavanje privoza te što nesmetaniji prolaz žurne službe kroz raskrižje. Nakon što žurna služba prođe kroz raskrižje, pokreće se drugi dio algoritma u svrhu vraćanja prometa u "normalu". Odnosno smanjenje negativnih učinaka uzrokovanih korištenjem algoritma za dodjelu prioriteta, te vraća promet u prvobitno stanje [3].

2.2.1. Algoritam za dodjelu prioriteta

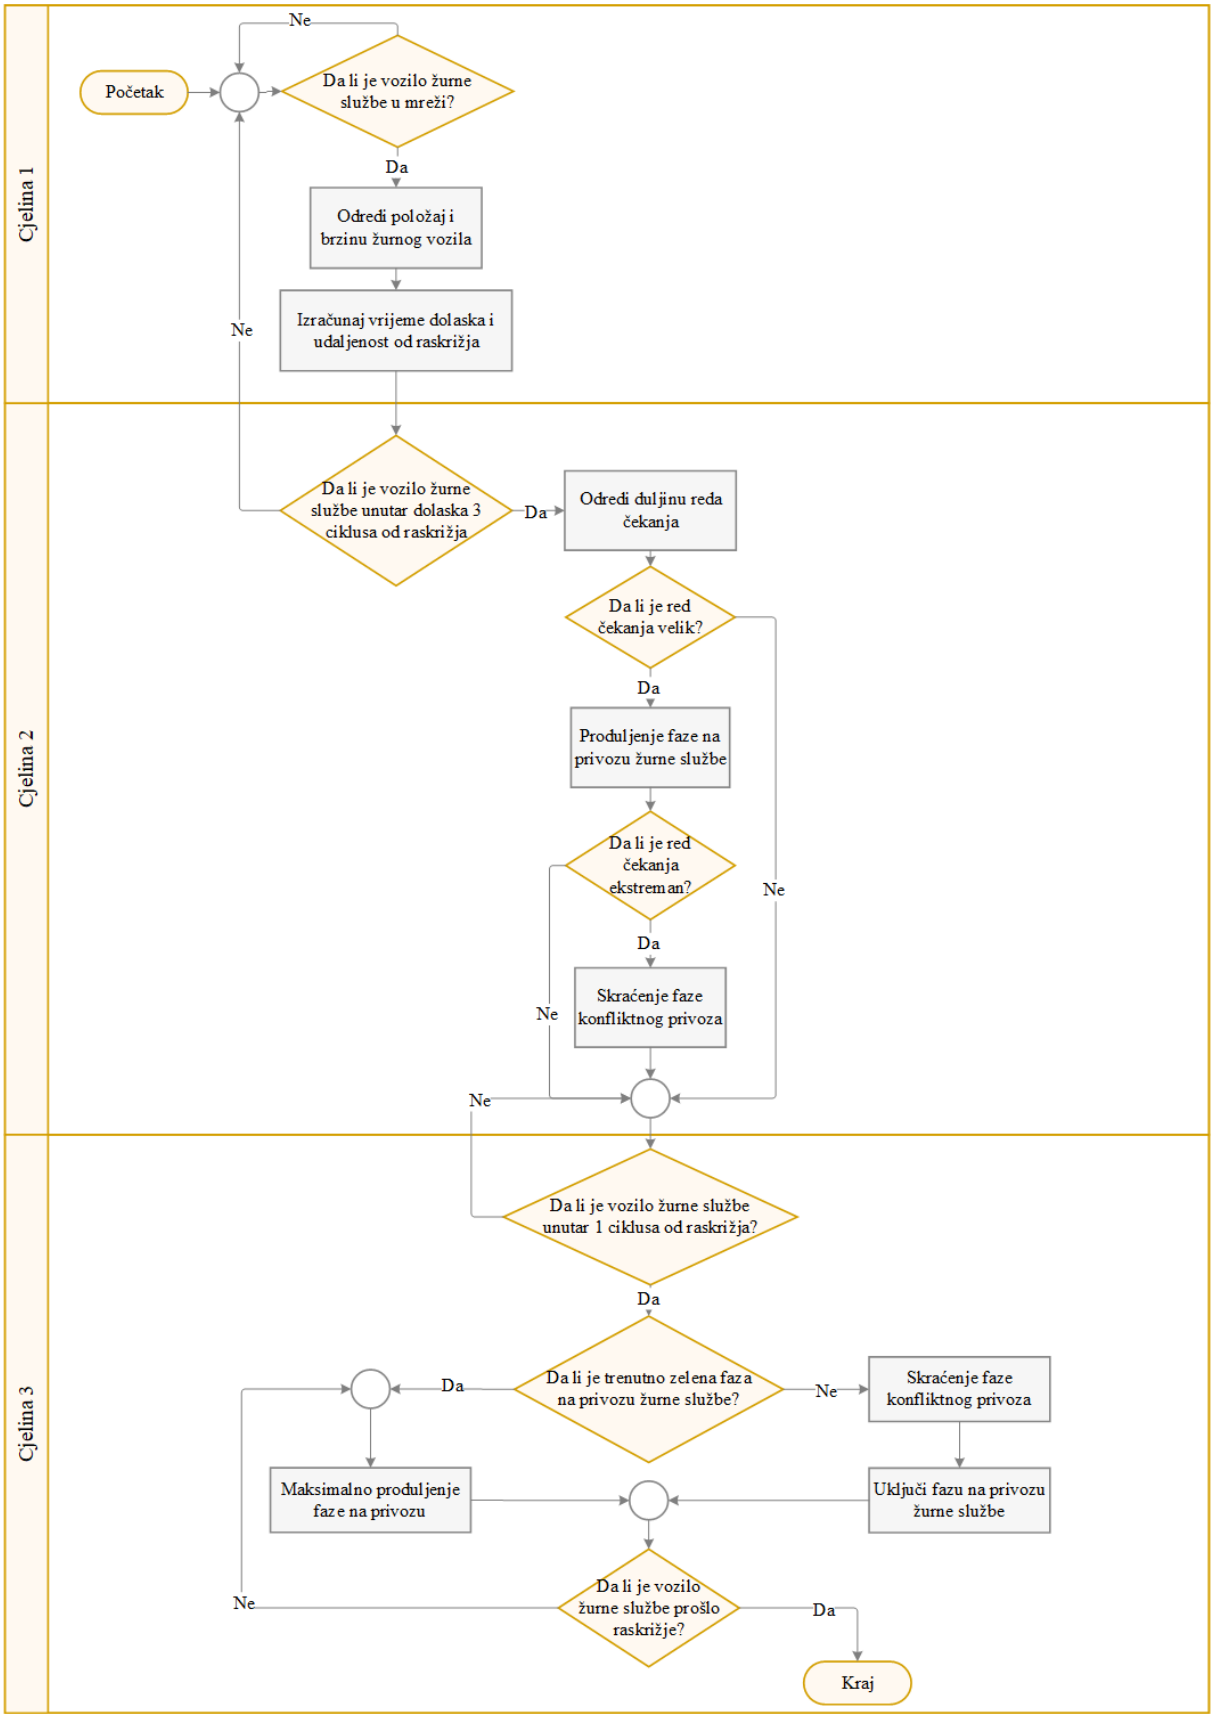
Zbog jednostavnosti i boljeg objašnjenja, algoritam je podijeljen u tri cjeline djelovanja [3, 4, 10]:

- **Cjelina 1** - praćenje vozila žurne službe;
- **Cjelina 2** - dodjela prioriteta zasnovana na duljini repa čekanja;
- **Cjelina 3** - dodjela apsolutnog prioriteta.

U prvoj cjelini algoritma se detektira pojava vozila žurne službe na prometnoj mreži te se određuje kojom rutom prolazi i kojoj signalnoj grupi vozilo žurne službe pripada. Na osnovi lokacije i brzine vozila žurne službe izračunava se procjena vremena njegovog dolaska do semaforiziranog raskrižja. Nakon što je određena procjena dolaska vozila žurne službe unutar granica određenih vremenskih parametara započinje druga cjelina [3].

U drugoj cjelini algoritma se broje vozila u redu čekanja na privozu iz smjera dolaska žurnog vozila te se u slučaju zagušenosti, odnosno postojanja repa čekanja produžuje faza zelenog svjetla kako bi se dobilo više vremena za raščišćavanje vozila u pripadnom privozu. Iznimno se u slučaju jače zagušenosti skraćuje faza konfliktnih privoza. Procjena vremena dolaska vozila žurne službe na raskrižje se i dalje računa te ukoliko je procijenjen dolazak unutar trajanja jednog ciklusa signalnog plana započinje treća cjelina algoritma [3].

Treća cjelina algoritma dodjeljuje apsolutni prioritet nadolazećem vozilu žurne službe, odnosno u najbržem mogućem roku poštujući sigurnosne zahtjeve dodjeljuje zeleno svijetlo te ga drži sve do prolaska vozila žurne službe kroz raskrižje. Kada je dobiven signal potvrde prolaska vozila žurne službe kroz raskrižje algoritam završava [3].



Slika 6: Prikaz dijagrama toka algoritma za dodjelu prioriteta prema cjelinama [3]

2.2.2. Algoritam vraćanja oduzetog vremena

Primjenom algoritma za dodjelu prioriteta stvara se neizbježan negativan utjecaj na ostatak prometa, odnosno na konfliktne privoze. Kako bi se smanjio negativan utjecaj korišten je algoritam povratka oduzetog vremena. Predloženi algoritam povratka oduzetog vremena iz [11] daje ravnomjerni povrat (engl. round robin) gdje je svakoj zakinutoj fazi vraćeno vrijeme jednako oduzetom vremenu. U ovom radu korištena je nadogradnja algoritma iz [11]. Umjesto ravnomjernog povrata oduzetog vremena uzet je u obzir odnos trajanja pojedinih faza ustaljenog signalnog plana. Nakon što završi algoritam dodjele prioriteta izračunava se ukupno skraćeno vrijeme prema izrazu 1.

Nakon algoritma dodjele prioriteta i izračuna ukupnog skraćenog vremena vrši se povrat oduzetog vremena raspodijeljen periodično unutar nekoliko ciklusa signalnog plana [3]. Iznos vremena povrata se određuje prema sljedećem izrazu:

$$T_{povratak} = T_{oduzeto} \cdot \frac{t_1}{t_2}, \tag{1}$$

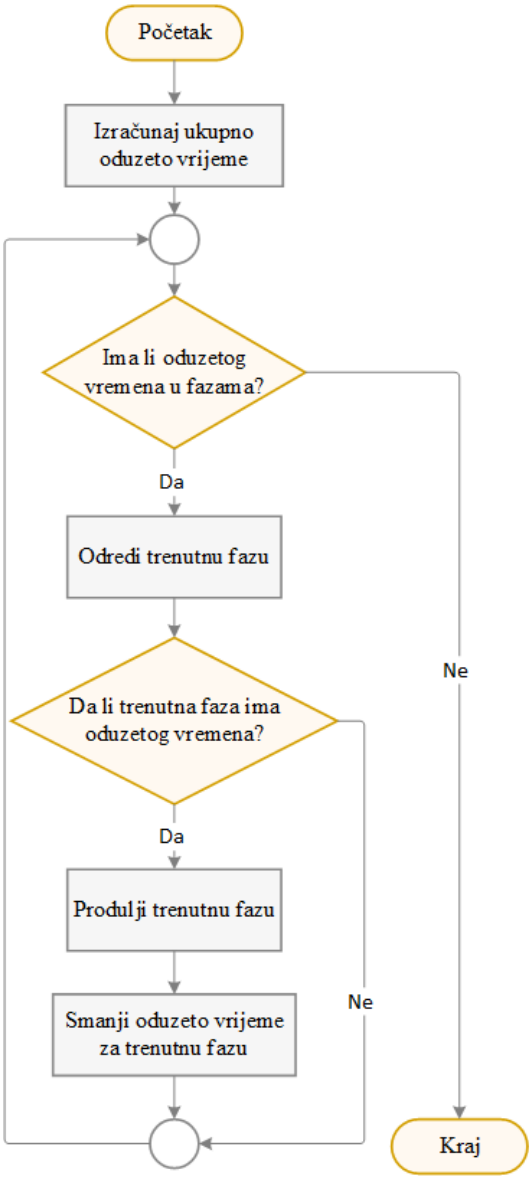
gdje je:

$T_{povratak}$ - ukupno vrijeme vraćeno zakinutoj fazi [s];

$T_{oduzeto}$ - ukupno vrijeme oduzeto zakinutoj fazi [s];

t_1 - trajanje zakinute faze [s];

t_2 - trajanje konfliktne faze [s].



Slika 7: Prikaz dijagrama toka algoritma povratka oduzetog vremena [3]

3. Primjena neizrazite logike za upravljanje signalnim planom semaforiziranog raskrižja

Neizrazitu logiku prvi puta predložio je Lotfi A. Miris s Kalifornijskog sveučilišta u Berkeleyu u časopisu iz 1965. godine. Svoje ideje razradio je u radu iz 1973. godine koji je uveo koncept neizrazitih skupova [12, 13]. Prvo ispitivanje neizrazitog upravljanja proveo je Mamdani na laboratorijskom parnom stroju 1974. godine. U sedamdesetim godinama je to motiviralo istraživače da razviju niz primjena neizrazitog upravljanja [14, 15].

Potencijal neizrazite logike prepoznat je i u dizajniranju sustava upravljanja kočenja vlakova za japanski željeznički sustav u Sendaiu 1985. godine. Takav uspjeh modernizacije prometne infrastrukture dao je podlogu za daljnje istraživanje mogućih načina uporabe neizrazitih sustava, kako unutar prometne struke, tako i primjenom u sustavima korištenih na dnevnoj razini. Primjer široke primjene neizrazite logike može se naći u raznim istraživačkim područjima od svemirskog zrakoplovstva do područja psihologije. Od sredine osamdesetih istraživanja su usmjerena prema primjeni neizrazite logike i na sklopovskoj razini. Rad na neizrazitom čipu koji je Togai Watanabe 1985. godine te time izveo važan korak u tom smjeru [14, 15].

U sklopu ovog diplomskog rada korišten je sustav neizrazite logike kako bi se adaptivno mijenjalo vrijeme produljenja faze na privozu žurne službe prema potrebi. Odabir neizrazite logike u svrhu adaptivnog upravljanja nastao je zbog mogućnosti korištenja trenutnih prometnih podataka za vrijeme simulacije te upravljanje signalnim planom ovisno o trenutnom stanju u prometnoj mreži. Prema tome, produljenje faze na privozu žurne službe više ne mora biti fiksno, već se mijenja ovisno o redovima čekanja na privozima semaforiziranog raskrižja te udaljenosti žurne službe od raskrižja.

Osnove neizrazite logike

Eksponencijalnim razvojem računala, kao i proučavanjem umjetne inteligencije, počelo se postavljati pitanje prevođenja ljudskog oblika zaključivanja i upravljanja u formalni matematički opis i računalni program [16]. Neizrazita logika je tu vrlo bitna. Ona nalikuje ljudskoj metodologiji odlučivanja te se bavi nejasnim i nepreciznim informacijama. Može se promatrati

kao proširenje Boolove logike, koja od ulaznih podataka može imati vrijednosti 0 i 1 ili *istina* i *laž*. Izrazitom teorijom skupova jednoznačno je definirana pripadnost nekog elementa skupu. Odnosno, ulazna vrijednost pripada skupu A ili ne pripada skupu A, što znači da postoje samo dva međusobno isključena rješenja. Kod izrazitih skupova pripadnosti nekog elementa, tj. ulazne vrijednosti x skupu A moguće je zapisati kao [17]:

$$\mu_A(x) = \begin{cases} 1 & \rightarrow \quad \text{x} \in \text{A} \\ 0 & \rightarrow \quad \text{x} \notin \text{A}, \end{cases} \tag{2}$$

gdje je:

$\mu_A(x)$ - pripadnost elementa x skupu A;

x - element skupa;

A - izraziti skup.

Različito od izrazitih skupova, kod neizrazitih skupova pripadnosti elementa x skupu F nije apsolutna vrijednost, već je opisana funkcijom pripadnosti $\mu_F(x)$ koja može poprimiti bilo koju vrijednost između 0 i 1. Neizraziti skup F definiran je skupom uređenih parova elementa x osnovnog izrazitog skupa X i stupnja pripadnosti $\mu_F(x)$ te se matematički zapisuje prema [17]:

$$F = \{X, \mu_F(x)\}, \quad x \in X. \tag{3}$$

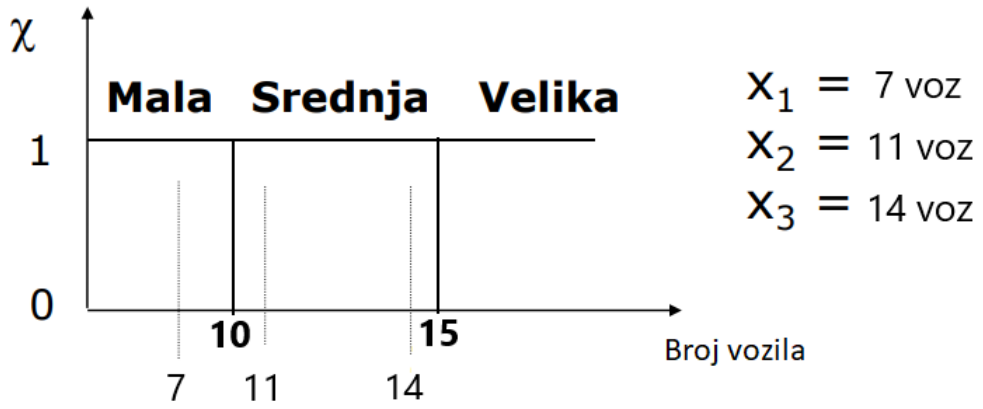
gdje je:

F - neizraziti skup;

X - izraziti skup;

$\mu_F(x)$ - funkcija pripadnosti.

Na slici 8 prikazan je grafikon na kojem su kao primjer dane funkcije pripadnosti izrazitog skupa koji opisuje pripadnosti ulaznih vrijednosti udaljenosti vozila žurne službe od semaforiziranog raskrižja. Dok se u tablici 1 može vidjeti tablični prikaz vrijednosti funkcija pripadnosti izrazitih skupova [17].



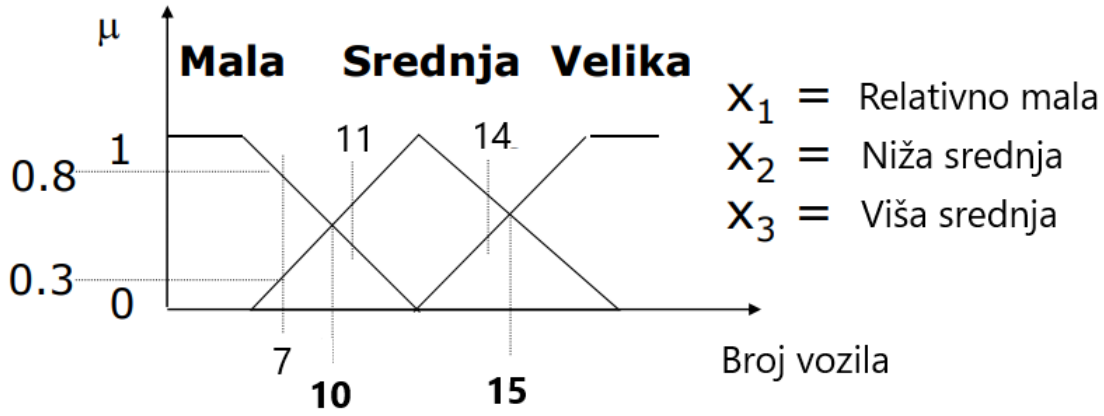
Slika 8: Funkcija pripadnosti za izraziti skup

Tablica 1: PRIMJER STANJA BINARNE LOGIKE

	Malo	Srednje	Veliko
7 vozila	1	0	0
11 vozila	0	1	0
14 vozila	0	0	1

Sustav neizrazitog zaključivanja ima dvije vrsti varijabli: ulazne i izlazne. Na osnovi dostupnih podataka, odabiru se ulazne i izlazne varijable gdje ulazne varijable predstavljaju varijable o kojima izlaz ovisi kako će se ponašati.

Funkcije pripadnosti (engl. Membership functions) neizrazitog skupa je kontinuirana i određuje stupanj pripadnosti nekog elementa, odnosno ulazne vrijednosti neizrazitom skupu. Na slici 9 prikazan je graf koji prikazuje na osi apscise funkcije pripadnosti $\mu(x)$, koja za različite vrijednosti pokazuje stupanj pripadnosti svakom skupu, prikazano u tablici 2.



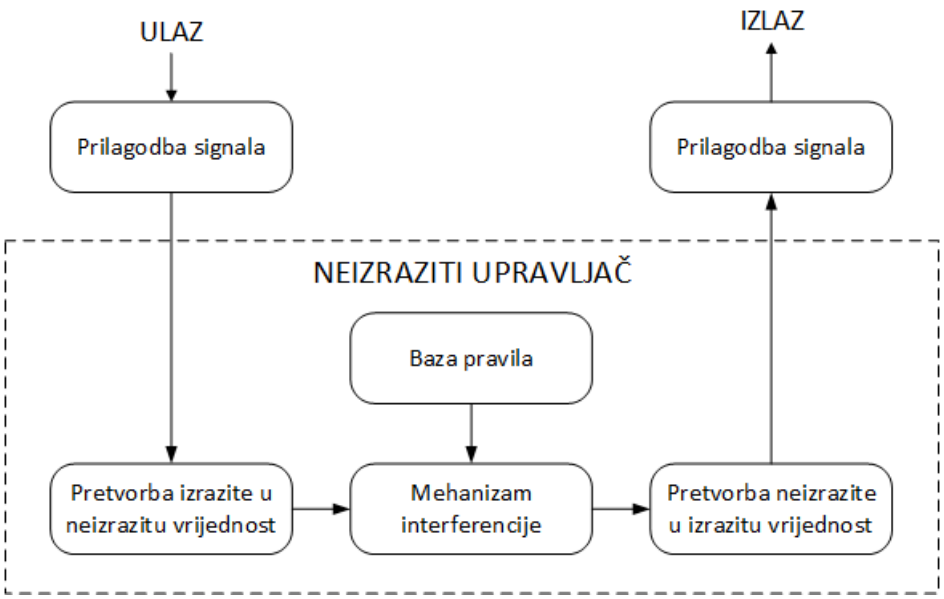
Slika 9: Funkcija pripadnosti za neizraziti skup

Tablica 2: PRIMJER STANJA NEIZRAZITE LOGIKE

	Malo	Srednje	Veliko
7 vozila	0,8	0,7	0
11 vozila	0,4	0,7	0
14 vozila	0	0,7	0,4

Struktura i način rada neizrazitog upravljača

Sama struktura neizrazitog upravljača ovisi o procesu kojim se upravlja i o zahtjevima za kvalitetu upravljanja. Primjene neizrazite logike je vrlo široka pa isto tako ima i velik broj različitih razvijenih struktura neizrazitog upravljača. Generalna struktura koja se može vidjeti na slici 10, sastavljena je od glavnog bloka i prilagodbi signala ulaznih i izlaznih podataka [18].



Slika 10: Struktura neizrazitog upravljača

Prilagodba podataka

Ulazni podaci su često izravni podaci mjerenja te kao takvi nisu najrelevantniji uzorci podataka kao ulaz za neizrazitu logiku. Prilagodba ili predprocesiranje podataka služi za normalizaciju fizikalne vrijednosti signala iz procesa prema fizikalnoj domeni funkcija pripadnosti. Procesi prilagodbi signala mogu biti poput: odstranjivanje šumova, zaokruživanje brojeva, agregiranja i slično. Prilagodba signala izlaznih podataka služi za dobivanje pogodnog signala za upravljačku komponentu.

Pretvorba izrazite u neizrazitu vrijednost

Prvi blok unutar strukture neizrazitog upravljača je pretvorba izrazite u neizrazitu vrijednost. Predstavlja postupak preslikavanja ulaznih podataka kojim se numeričke vrijednosti pretvaraju u lingvističke varijable, odnosno neizrazite skupove. Blok pretvorbe izrazite u neizrazitu vrijednost na taj način spaja ulazne podatke s uvjetima pravila koji određuju o kakvom se ulazu radi. Na primjer, ako je broj vozila na privozu velik, zaključuje da se radi o velikoj prometnoj potražnji.

Baza pravila

U mehanizmu upravljanja neizraziti skupovi se koriste za matematički opis procesa unutar baze pravila. Pravila mogu koristiti više ulaznih varijabli u uvjetima za zaključivanje pravila. Upravljaču se samim time može pridodati više ulaza i više izlaza, ali i može imati jedan ulaz, jedan izlaz. Baza pravila sastoji se od lingvističkog oblika:

$$AKO(IF) < uvjet >, ONDA(THEN) < posljedica > . \tag{4}$$

Neke od operacija nad izrazitim skupovima:

- Unija $\rightarrow$ ILI (or);
- Presjek $\rightarrow$ I (and);
- Komplement $\rightarrow$ NE (not).

Interferencija

Interferencija ili proces odlučivanja pomoću baze pravila određuje promjene vrijednosti izlaza upravljača, definiranim lingvističkim pravilima kojima se okida neka od akcija koju stručnjak postavi.

Pretvorba neizrazite u izrazitu vrijednost

Pretvorba neizrazite u izrazitu vrijednost pretvara dobivenu vrijednost iz mehanizma interferencije opet u izlazni kontrolni signal. Radi obrnuto od bloka za pretvorbu izrazite u neizrazitu vrijednost.

4. Implementacija neizrazitog upravljanja prioritetima vozila žurnih službi

Jedna od najčešće primjenjivanih metoda upravljanja prometnom mrežom u današnjim gradskim područjima su sustavi za upravljanje semaforima s jednim ili više unaprijed određenih ustaljenih signalnih planova. Primjenom adaptivnih sustava za upravljanje semaforiziranim raskrižjima moguće je modificirati postojeće signalne planove promjenom redoslijeda faza ili izravno utječući na određeno trajanje faze. U visoko naseljenim gradskim područjima, prometni zastoji mogu uzrokovati značajne zastoje koji se dodatno povećavaju ustaljenim signalnim planovima koji se nisu u stanju nositi sa stohastičkom prirodom prometnih tokova [19].

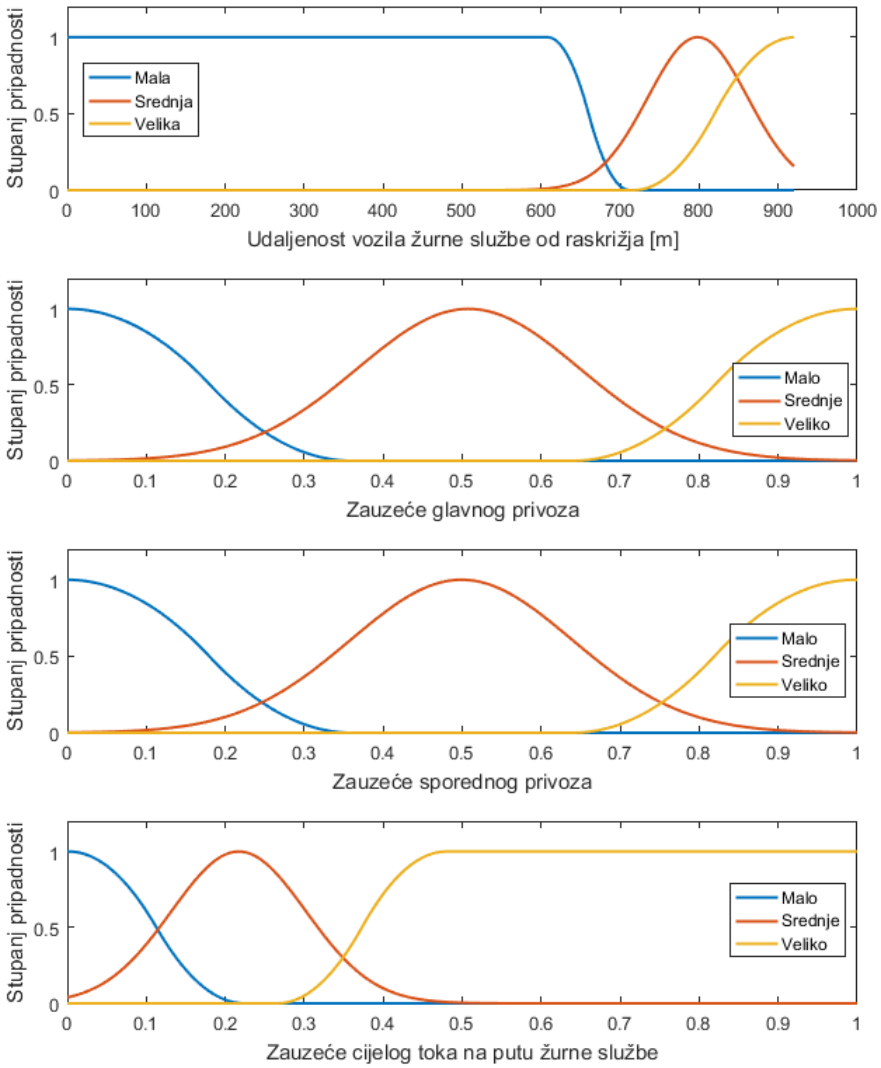
Mogu se implementirati prilagodljivi sustavi kontrole kako bi se smanjilo kašnjenje i povećao operativni kapacitet raskrižja. Osim toga, prilagodljivo upravljanje može se koristiti i za prioritetno dodjeljivanje vozilima JGP-a te vozilima žurnih službi. Takav se pristup upravljanja naziva adaptivnim upravljanjem semaforiziranim raskrižjima [3, 4, 10].

Osnovna ideja upravljanja neizrazitom logikom je modeliranje zakona o upravljanju na temelju ljudske ekspertize i znanja, a ne na temelju preciznog modeliranja samog procesa. Neizraziti upravljač prati trenutno stanje prometa i mijenja trajanje faze na temelju stvarnih trenutnih uvjeta na svim privozima [10].

Glavna razlika u odnosu na upravljanje bez neizrazitog upravljača je da se problem upravljanja signalnim planom rješava pomoću pravila odlučivanja zasnovanih na neizrazitoj logici. U ovom upravljačkom pristupu nema fiksnih parametara za produljenje zelene faze na putu vozila žurne službe. Pristup neizrazite logike daje prilagođeniji signalni plan ovisno o prometnoj situaciji. Odlučivanje u ovom neizrazitom upravljaču zasniva se na višestrukoj ulaznoj teoriji pojedinačnog izlaza. U razvijenom neizrazitom regulatoru postoji skup od 81 pravila implementiranih u sustavu neizrazitog zaključivanja [10].

Spomenuta pravila o neizrazitoj odluci uzimaju vrijednost udaljenosti vozila žurne službe od upravljanog raskrižja, zauzeće cijelog toka na putu žurne službe prije raskrižja te duljine repa čekanja na pristupima raskrižja koji se prikazuju kao zauzetost vozila u segmentu prometnice na putu vozila žurne službe prema raskrižju. Svaki od ova četiri ulaza predstavljena su s tri

Gaussove funkcije pripadnosti koje odgovaraju ljudskim perceptivnim lingvističkim pojmovima. Za udaljenost žurne službe, termini su *bliski*, *srednji* i *daleko*. Za ostala tri ulazna podatka na temelju zauzetosti, pojmovi su *niski*, *srednji* i *visoki*, kao što je prikazano na slici 11. Rezultat ovog neizrazitog sustava je postotak produženja zelene ne-konfliktne faze u rasponu od nula do dvadeset posto. Kada je vozilo žurne službe vrlo blizu raskrižja, biti će dodijeljeni apsolutni prioritet, dok vozilo ne izađe iz raskrižja nakon čega slijedi trenutna aktivacija algoritma za vraćanje *oduzetog* vremena isto kao u pristupu opisanim u [10].



Slika 11: Definirane funkcije pripadnosti neizrazite logike za ulaze u neizraziti upravljač

Upravljač neizrazite logike dizajniran je s osnovom pravila pomoću *AKO – I – ONDA* uvjeta. Neka od pravila prikazana su u tablici 3, dok ostatak slijedi sličan pristup.

Tablica 3: ODABRANA PRAVILA NEIZRAZITE LOGIKE ADAPTIVNOG UPRAVLJANJA

	Udaljenost žurne službe		**Zauzeće glavnog privoza**		**Zauzeće sporednog privoza**		**Zauzeće cijelog toka na putu žurne službe**		**Produljenje faze**
AKO	Blizu	I	Velik	I	Srednje	I	Velik	ONDA	Veliko
AKO	Srednje	I	Srednji	I	Mali	I	Velik	ONDA	Srednje
AKO	Srednje	I	Srednji	I	Velik	I	Mali	ONDA	Malo
AKO	Daleko	I	Mali	I	Srednji	I	Srednji	ONDA	Malo
AKO	Daleko	I	Velik	I	Mali	I	Srednji	ONDA	Srednje

5. Optimizacija pravila sustava neizrazitog zaključivanja

Kako je prethodno opisano u 4. poglavlju, neizrazita logika, uvedena zahvaljujući Zadehovim radovima sredinom 1960-ih godina ispostavila se kao pogodno rješenje za niz zahtjevnih industrijskih problema. Neizrazita logika je matematička podloga koja omogućava modeliranje procesa u čovjeku jasnom jezičnom obliku. Prikladno je za definiranje odnosa ulaza sustava i željenog izlaza sustava. Jedna je od vrlo uspješnih tehnologija današnjice zaslužnom za razvijene sofisticirane upravljačke sustave. Neizrazito zaključivanje je pronašlo veliku primjenu u složenijim industrijskim sustavima koji su vrlo složeni i ne mogu se modelirati precizno ni pod raznim pretpostavkama i aproksimacijama. Upravljanje takvim složenim sustavima od strane ljudskih stručnjaka je rezultiralo puno boljim rezultatima nego klasična automatizacija sustava. Ljudska ekspertiza i znanje o upravljanju moguće je prenijeti u neizrazitu logiku. Takvo zapažanje je nadahnulo mnoge istražitelje i stručnjake da razvijaju i istražuju tehnologiju u skladu s neizrazitom logikom [20]. Glavni nedostatak ovog pristupa su subjektivnost i ovisnost o znanju stručnjaka, koje možda i nije najbolje u nekim slučajevima.

Kako bi se smanjilo oslanjanje na znanje stručnjaka te olakšao proces ”pokušaja” pronalaska ispravnih parametara, kao što su npr. funkcije pripadnosti ulaza i izlaza te pravila odlučivanja, uvodi se GA. Radi se o alatu zasnovanom na mehanici prirodne selekcije i prirodne genetike s ciljem pretraživanja globalnog optimuma, odnosno optimizacije parametara. Korišten je za učinkovito pronalaženje optimalnih rješenja za razne probleme (npr. operacijska istraživanja, hibridne tehnike, obrada slike, itd.). U ovom poglavlju opisana je struktura genetskog algoritma, funkcionalnost i primjena u problematici adaptivnog upravljanja semaforiziranim raskrižjem pomoću neizrazite logike s više scenarija.

5.1. Strategija optimizacije

U ovom radu korištena su dva pristupa korištenja genetskog algoritma koji su neovisni jedan o drugome. Neizrazita pravila i funkcije pripadnosti optimizirani su asinkrono i iterativno.

Ponajprije se optimiziraju neizrazita pravila odnosno njihovi izlazi, a potom i funkcije pripadnosti na temelju optimiziranih neizrazitih pravila. Sustav radi na način da se prvo preuzmu već postojeća pravila i funkcije pripadnosti te reprezentiraju kao inicijalni kromosomi. Da bi mogli usporediti učinkovitost svakog od algoritama, postupak je sljedeći:

1. Kôdiranje već postojećih neizrazitih pravila i funkcija pripadnosti u inicijalne kromosome;
2. Izvršavanje optimizacije neizrazitih pravila pomoću genetskog algoritma i simulacija u VISSIM-u;
3. Spremanje rezultata te novo postavljanje varijabli s rezultatima prijašnje optimizacije pravila;
4. Izvršavanje optimizacije funkcija pripadnosti pomoću GA i simulacija u VISSIM-u;
5. Evaluacija rezultata.

5.2. Prirodni evolucijski procesi

Evolucija je neprekidan proces u kojemu se jedinke prilagođavaju promjenjivim uvjetima okoliša. Svaka se jedinka može opisati nekim svojim svojstvom, a ono određuje koliko će ta jedinka biti uspješna u borbi za preživljavanje u trenutnim uvjetima. Prema tome, evolucija je promjena nasljednih karakteristika biološke populacije tijekom više ili manjih uspješnih generacija [21].

Jedinka koja se najuspješnije prilagodila svojoj okolini s najboljim svojstvima, ima najveću šansu za preživljavanje i razmnožavanje. Pri tome slabije jedinke neće preživjeti ili će imati jako male šanse za razmnožavanjem. Svaka se jedinka može okarakterizirati nizom svojstva, kao što su: sposobnost učenja, boja očiju, oštrina vida, broj zubi itd. Takva svojstva su zapisana u kromosome. Kromosomi su lančane tvorevine koje se nalaze u jezgri svake stanice. Skup informacija koje karakteriziraju jedno od svojstva zapisano je u djelić kromosoma koji se naziva gen [21].

U biološkom svijetu molekula deoksiribonukleinske kiseline (DNK) je u obliku spirale građene od fosforne kiseline i šećera, a mostovi između spiralnih niti građeni su od dušičnih baza. Te dušične baze su jedinice informacija, slično kao i kod računala što su informacije u obliku bitova 0 i 1, tako je u prirodi najmanja informacija jedna dušična baza (A, G, C ili T) [21].

5.3. Uvod u genetske algoritme

Razvoj računalstva i povećanje procesne moći računala u posljednjih dvadeset godina potaknulo je značajno razvoj evolucijskih algoritama. Evolucijski sustavi u svrhu optimizacije simuliraju evoluciju pomoću računala, s ciljem imitiranja generacijske evolucije pomoću algoritma koji će ponuditi najbolje rješenje u što kraćem roku. Na sličan način, postupak se može primjeniti i u problematici optimizacije, gdje optimalno rješenje računalo traži kroz niz iteracija. GA se primjenjuje i daje dobre rezultate u područjima učenja neuronskih mreža, pri traženju najkraćeg puta, problemu trgovačkog putnika, strategiji igara, problemima sličnim transportnom problemu, problemu raspoređivanja procesa, problemu određivanja parametara sustava, optimiranju upita nad bazom i slično [21, 22].

GA je heuristička metoda optimiranja koja imitira prirodni evolucijski proces. Evolucija je robustan proces pretraživanja prostora rješenja. Živa bića se tijekom evolucije prilagođavaju uvjetima u prirodi, tj. životnoj okolini. Analogija evolucije kao prirodnog procesa i GA kao metode optimiranja, očituje se u procesu selekcije i genetskim operatorima. Mehanizam odabira nad nekom vrstom živih bića u evolucijskom procesu čine okolina i uvjeti u prirodi. U GA ključ selekcije je funkcija cilja, koja na odgovarajući način predstavlja problem koji se rješava. Slično kao što su okolina i uvjeti u prirodi, ključ selekcije nad nekom vrstom živih bića, tako je i funkcija cilja ključ selekcije nad populacijom rješenja u GA-u. Naime, u prirodi jedinka koja je najbolje prilagođena uvjetima i okolini u kojoj živi ima najveću vjerojatnost preživljavanja i parenja, a time i prenošenja svojeg genetskog materijala na svoje potomke. Za GA jedno rješenje je jedna jedinka. Selekcijom se odabiru dobre jedinke koje se prenose u sljedeću populaciju, a manipulacijom genetskog materijala stvaraju se nove jedinke. Takav ciklus selekcije, reprodukcije i manipulacije genetskim materijalom jedinki ponavlja se sve dok nije zadovoljen uvjet zaustavljanja evolucijskog procesa, što je najčešće unaprijed određeni broj iteracija [21].

GA je predloženi od strane Johna H. Hollanda još u ranim sedamdesetima prošlog stoljeća. Tijekom nešto više od dva desetljeća, a posebno u posljednjih nekoliko godina, pokazali su se vrlo moćnim i u isto vrijeme općenitim alatom za rješavanje čitavog niza problema iz inženjerske prakse. To se može objasniti njihovom jednostavnošću; kako same ideje na kojoj su osnovani, tako i njihove primjene te doprinosu niza znanstvenika i inženjera na njihovom prilagođavanju velikom broju problema i povećanju efikasnosti. Paralelno s povećanjem primjene povećava se i

opseg istraživanja rada i svojstva GA te se pokušavaju njihovi elementi svesti na neke teorijske osnove. Nažalost, rezultati postignuti na teorijskom području su dvojbeni, a genetski algoritmi ostaju i do danas u osnovi heurističke metode [21, 23].

Po načinu djelovanja ubrajaju se u metode usmjerenog slučajnog pretraživanja prostora rješenja u potrazi za globalnim optimumom. U istu grupu možemo ubrojiti još neke metode koje se zasnivaju na sličnim principima, a to su: evolucijske strategije, simulirano kaljenje i genetsko programiranje [21].



Slika 12: Dijagram toka postupka genetskog algoritma

5.4. Kôdiranje

Kako bi se GA primijenio na određeni problem, potrebno je prije svega donijeti odluku o koju vrstu genotipa koristiti. Odabir genotipa znači kako će se parametri problema prenijeti u konačni niz simbola, poznati kao geni. Problematika odabira odgovarajućeg reprezentativnog načina kôdiranja problema je krucijalna za istraživanje i dobar rezultat. Pronalazak odgovarajućeg prikaza problematične domene za kromosom važan je za razmatranje, jer će dobar prikaz rješenja olakšati pretraživanje ograničavanjem prostora za pretraživanje. Isto tako lošiji prikaz rješenja uzrokovati će veći prostor za pretraživanje. Kôdiranje uvelike ovisi o samom problemu koji je potrebno riješiti odnosno optimizirati, pa tako postoje sljedeće vrste kôdiranja [24]:

- **Binarno kôdiranje -** najčešće korišteni oblik kôdiranja. Svaki kromosom je predstavljen korištenjem binarnog niza, odnosno niza 0 ili 1 prikazano u tablici 4;

Tablica 4: BINARNO KÔDIRANJE

Kromosom1	110101110010
Kromosom2	011010011101

- **Permutacijsko kôdiranje-** je korišteno za problematiku redoslijeda. Svaki kromosom predstavlja položaj u slijedu kao što je prikazano u tablici 5. Npr. niz cijelih brojeva predstavlja slijed gradova koje posjećuje prodavač;

Tablica 5: PERMUTACIJSKO KÔDIRANJE

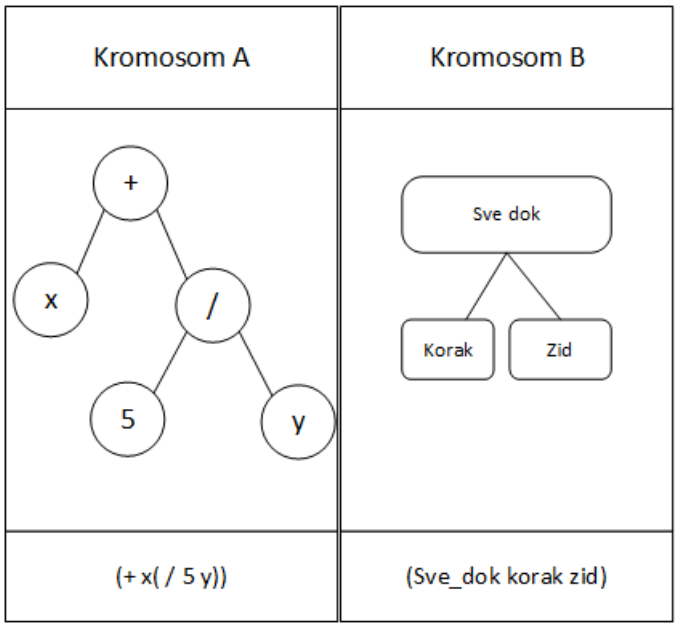
Kromosom1	1 5 2 3 5 2 6 4 6 9 8
Kromosom2	8 6 3 6 3 9 6 3 1 5 8

- **Vrijednosno kôdiranje -** kod nekih problema gdje se koriste složenije vrijednosti, poput realnih brojeva, korištenje binarne vrijednosti je teško. Ovakvim pristupom kôdiranja moguće je kôdiranje izravno postavljene vrijednosti. Svaki kromosom je predstavljen kao niz određenih vrijednosti, koje mogu biti cijeli broj, realni broj, znak ili objekt, prikazano u tablici 6;

Tablica 6: VRIJEDNOSNO KÔDIRANJE

Kromosom1	1,23 2,12 3,14 0,34 4,62
Kromosom2	ABDJEIFJDHDDLDFLFEGT

- **Kôdiranje stabla -** najčešće se koristi za evoluirajuće programe ili izraze za genetičko programiranje. U kôdiranju stabla svaki kromosom je stablo nekih objekata, kao što su funkcije ili naredbe u programskom jeziku. Za razliku od ostalih kôdiranja koje su jednodimenzionalna, kôdiranje stalba je dvodimenzionalno, a prikazano je na slici 13.



Slika 13: Kôdiranje stabla

5.5. Funkcija dobrote

Funkcija dobrote ili funkcija cilja ili funkcija ocjene kvalitete jedinke (engl. fitness function, evaluation function, criteria function) procjenjuje koliko je dano rješenje dobro odnosno optimalno rješenje željenog problema uz dani kriterij optimiziranja. Utvrđuje koliko je rješenje pogodno te i u najjednostavnijoj interpretaciji ekvivalent je funkciji f koju treba optimizirati [21, 25]:

$$dobrota(v) = f(x), \tag{5}$$

gdje je:

$dobrota(v)$ - dobrota cijele jedinke;

$f(x)$ - funkcija koju treba optimizirati.

Binarni vektor v predstavlja realan broj unutar zadanih granica promjene svakog gena te što je dobrota jedinke veća, ima veću vjerojatnost preživljavanja i križanja. Izračunavanje vrijednosti

funkcije dobrote je ključ za proces selekcije, izračunava se iterativno te u zadanim ograničenjima nad $f(x)$. Tijekom procesa evolucije ispravan GA generira iz generacije u generaciju populacije čija je ukupna i prosječna dobrota sve bolja i bolja. Izračunavanje ukupne dobrote populacije d i prosječne dobrote populacije $\overline{D}$ se radi pomoću izraza:

$$D = \sum_{i=1}^{VEL_POP} dobrota(v), \tag{6}$$

$$\overline{D} = \frac{D}{VEL_POP}, \tag{7}$$

gdje je:

D - ukupna dobrota populacije;

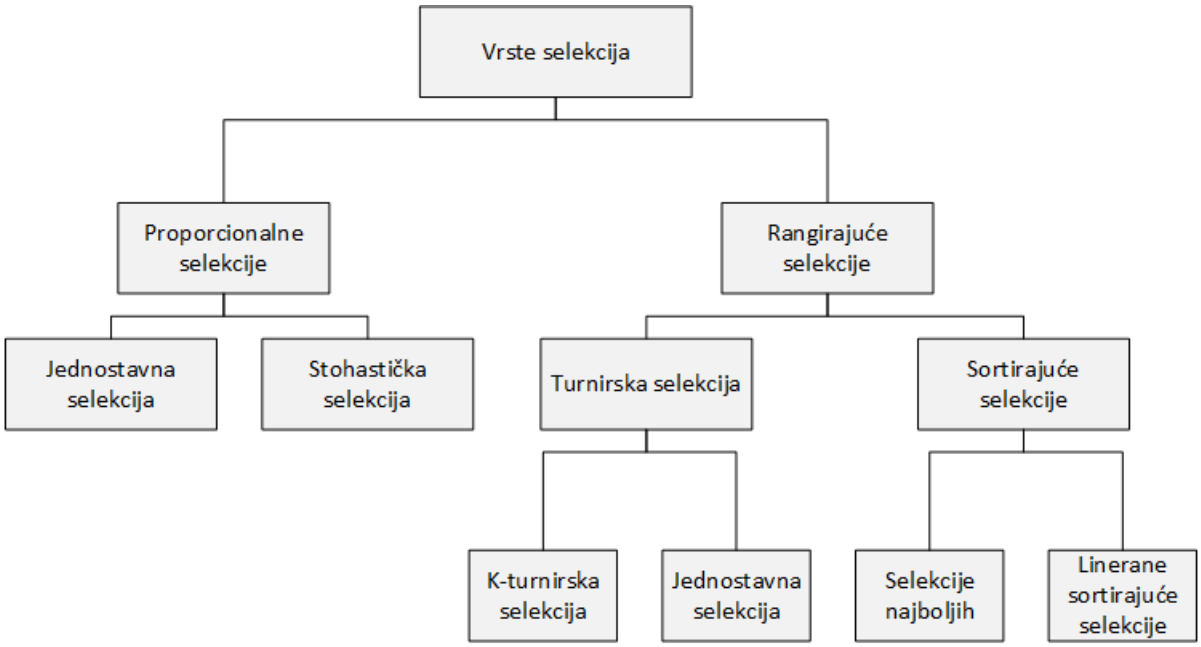
$\overline{D}$ - prosječna dobrota populacije,

$dobrota(v)$ - dobrota cijele jedinke;

VEL_PO - veličina populacije.

5.6. Selekcija

Selekcija je proces odabira dva roditelja za križanje iz dane populacije. Svrha odabira je čuvanje i prenošenje dobrih svojstva na slijedeću generaciju jedinki, odnosno populaciju. Izračunom dobrote jedinki, odabiru se dobri geni koji će sudjelovati u sljedećem koraku reprodukcije [21]. Karakteristične vrste selekcija koje koristi GA su: jednostavna i turnirska selekcija. S obzirom na vrstu selekcije, dijelimo ih na proporcionalne (generacijske) i rangirajuće (eliminacijske) selekcije, a detaljniji prikaz moguće je vidjeti na slici 14 prema [25].



Slika 14: Drvo grananja vrsti selekcija

5.6.1. Jednostavna selekcija

Jednostavna selekcija ili rulet selekcija (engl. Roulette selection) je operator selekcije u kojemu je mogućnost da određeni kromosom iz populacije bude odabran, proporcionalna njegovoj dobroti. GA koji koristi jednostavnu selekciju naziva se generacijskim genetskim algoritmom. Time, bolje jedinke imaju veću vjerojatnost da budu odabrane [21]. Opći postupak procesa jednostavne selekcije može se provesti na sljedeći način:

1. Funkcija dobrote se izračunava za svaki kromosom;
2. Računa se kumulativna vrijednost dobrote svakog kromosoma;
3. Računa se odnos dobrote jedinke i dobrote cijele populacije, što čini vjerojatnost odabira;
4. Populacija se sortira prema vjerojatnosti odabira, od najveće prema najmanjoj;
5. Jedinke s vrlo velikom dobrotom prejako utječu na cijelu populaciju. Zato se generira nasumični broj R iz područja vrijednosti $[0,1]$, kako bi se dobio efekt nasumičnosti te se odabire jedinka čija je normalizirana vrijednost dobrote veća ili jednaka broju R.

Tablica 7: VJEROJATNOST ODABIRA POJEDINE JEDINKE

Jedinka	1	2	3	4	5	6	7	8
Dobrota jedinke	6	4	3,6	0,4	0,8	1,2	2,4	1,6
Vjerojatnost odabira	0,3	0,2	0,18	0,02	0,04	0,06	0,12	0,08

Ako s $dobrota(i)$ označavamo dobrotu *i*-te jedinke, a s $dul\,jina(i)$ označavamo duljinu segmenta koji pripada toj jedinki prema [26] vrijedi:

$$dul\,jina(i) = \frac{dobrota(v)}{\sum_{j=1}^{n} dobrota(i)}, \tag{8}$$

gdje je:

$dul\,jina(i)$ - duljina segmenta koji pripada toj jedinki;

$dobrota(v)$ - dobrota cijele jedinke;

$dobrota(i)$ - dobrota *i*-te jedinke.

5.6.2. Turnirska selekcija

Turnirskom selekcijom izvodi se turnir između nekoliko slučajno odabranih jedinki iz populacije. Jedinka s najvećom dobrotom je pobjednik turnira. GA u svakom koraku generira novu populaciju iz stare, tako da VEL_POP puta odabire s jednakom vrijednošću k jedinki iz stare populacije. Odabrane jedinke uzima u obzir za slijedeći korak na kojem će djelovati genetski operatori. Eliminacijska turnirska selekcija odabire k jedinki, ali eliminira najlošiju i nadomješta je s djetetom dviju preživjelih jedinki [21, 26].

Turnirska selekcija je vrlo pogodna kada su populacije vrlo velike te informacije o cijeloj populaciji može biti vrlo zahtjevno za obraditi. Ne zahtjeva znanje o cijeloj populaciji, već je dovoljno imati relaciju koja može usporediti bilo koje dvije jedinke [21, 26].

5.6.3. Eliminacijska selekcija

U jednom koraku generacijski GA raspolaže sa dvije populacije jedinki: jednu populaciju dobiva iz prethodnog koraka, a drugu generira jednostavna selekcija. Jednostavna i turnirska selekcija biraju dobre kromosome u populaciji, dok eliminacijska selekcija odabire loše kromosome koje treba eliminirati i reprodukcijom ih zamijeniti novima. Loše kromosome nadomještaju djeca

nastala reprodukcijom roditelja, odnosno preživjelih kromosoma [21]. Algoritam eliminacijske selekcije se sastoji od sljedećih procesa:

- Selektiraj n loših kromosoma;
- Genetskim operatorima generiraj nove kromosome;
- Izbriši selektirane kromosome;
- Dodaj nove kromosome.

Algoritam eliminacije je vrlo sličan jednostavnoj selekciji. Što je dobrota manja veća je vjerojatnost za odabir, dok je kod jednostavne selekcije obrnuto, što je veća dobrota, veća je vjerojatnost za odabir. Umjesto funkcije dobrote definira funkciju penala ili kazne [21]:

$$p_k \simeq penal(v_k), k = 1,2...VEL_POP, \tag{9}$$

$$penal(v_k) = max(dobrota(v_i)) - dobrota(v_k), \tag{10}$$

gdje je:

p_k - vjerojatnost selekcijei;

$penal(v_k)$ - iznos penala za svaki kromosom.

Samim time, riješen je problem očuvanja najbolje jedinke s najvećom dobrotom jer je njegova kazna jednaka nuli. Takvim računanjem nije potreban onda mehanizam elitizma za očuvanje najbolje jedinke, više o tome u sljedećem poglavlju 5.7..

5.7. Elitizam

Zbog mogućnosti gubljenja dobrog rješenja nakon puno iteracija algoritma, uvodi se mehanizam elitizma. Služi kao zaštita od gubljenja dobrog rješenja koja se izmjene kroz genetske operatora mutacije ili selekcije. Pomoću takvog mehanizma zaštite dobrih jedinki, algoritam iz generacije u generaciju teži ka globalnom optimumu, odnosno najboljem rješenju problema. Mehanizam elitizma se izvršava u svakoj iteraciji te iznova traži najbolju jedinku koju treba zaštiti [21].

5.8. Genetski operatori

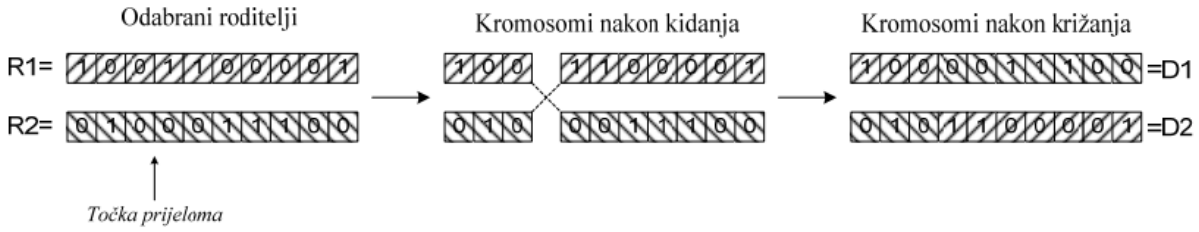
Nakon selekcije, slijedi druga važna karakteristika genetskog algoritma, reprodukcija. U procesu reprodukcije sudjeluju prethodno odabrane dobre jedinke iz procesa selekcije. Reprodukcija je razmnožavanje s pomoću genetskog operatora križanja. Kao i u biološkom svijetu, tijekom procesa reprodukcije moguće je da dolazi i do slučajnih promjena u kromosomu nastalom od roditelja nakon samog križanja kromosoma. Taj proces promjena nekih gena naziva se mutacija [27].

5.8.1. Križanje

Nakon što su odabrane dvije jedinke (roditelja) u procesu selekcije, križanjem nastaje jedna ili dvije nove jedinke (djeca). Budući da u križanju sudjeluju dvije jedinke, radi se o binarnom operatoru. To je jedan od načina stohastičkog generiranja novih rješenja iz postojeće populacije, analogno križanju koje se događa tijekom spolne reprodukcije u biologiji [21, 26]. Ako su roditelji dobra rješenja, tada će najvjerojatnije i dijete biti dobro rješenje, ako ne i bolje od svojih roditelja.

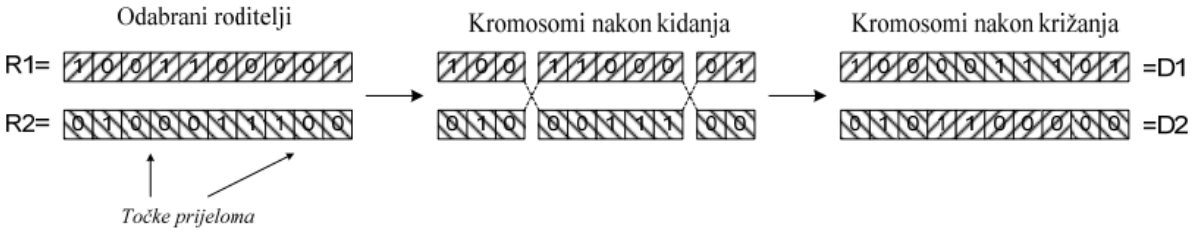
Primjeri križanja [26]:

- Križanje s *n* točaka prekida - nasumično odabire jednu ili više mjesto križanja kromosoma. Primjer sa jednom i dvije točke križanja, kao najčešći oblici:
  - ”Jedna točka” (engl. One point) - nasumično odabire točku križanja u kromosomu. Od te točke križanja kopiraju se geni prvog roditelja, a nakon točke križanja kopiraju se geni drugog roditelja kako bi stvorili dijete. Primjer se može vidjeti na slici 15:



Slika 15: Križanje sa jednom točkom prekida [26]

  - ”Dvije točke” (engl. Two point) - nasumično odabire dvije toke unutar kromosoma te potom između točaka izmiješa gene jednog i drugog roditelja. Primjer se može vidjeti na slici 16:



Slika 16: Križanje sa dvije točke prekida [26]

- Uniformni - kod oba roditelja svaki gen se zasebno razmatra te nasumično bira od kojeg roditelja će se naslijediti. Vjerojatnost koja određuje kako će dijete imati raspodijeljene gene zove se razmjer miješanja (engl. mixing ratio). Ako je razmjer miješanja 0.5, znači da će dijete naslijediti 50% gena od jednog roditelja i 50% gena od drugog roditelja;

- Aritmetičko - koristi se kod prikaza rješenja u obliku realnih brojeva. Linearno kombinira dva roditelja kromosoma prema izrazu:

$$\begin{aligned} Dijete1 &= \alpha * roditelj1 + (1-\alpha) * roditelj2, \\ Dijete2 &= (1-\alpha) * roditelj1 + \alpha * roditelj2. \end{aligned} \tag{11}$$

  gdje je:

  $roditelj1$ - prva odabrana jedinka iz populacije;

  $roditelj2$ - druga odabrana jedinka iz populacije;

  $Dijete1$ - novonastala jedinka od roditelja iz procesa križanja;

  $Dijete2$ - novonastala jedinka od roditelja iz procesa križanja,

  α - slučajni težinski koeficijent između 0 i 1 križanja.

- Heuristički - koristi se kod prikaza rješenja u obliku realnih brojeva. Za razliku od aritmetičkog, koristi i koeficijent dobrote, odnosno razlikuje dobre roditelje od lošijih. Križanje se obavlja prema izrazu:

$$\begin{aligned} Dijete1 &= boljiroditelj + r * (boljiroditelj - lošijiroditelj), \\ Dijete2 &= boljiroditelj, \end{aligned} \tag{12}$$

  gdje je:

  $boljiroditelj$ - odabrana jedinka s boljom dobrotom;

loši jiroditelj - odbarana jedinka s lošijom dobrotom;

r - slučajni težinski koeficijent između 0 i 1.

5.8.2. Mutacija

Mutacija je genetski operator koji se brine za održavanje genetske raznolikosti od jedne generacije kromosoma genetskog algoritma do druge. Mijenja vrijednosti jednog ili više gena u kromosomu, što može rezultirati dodavanjem potpuno novih vrijednosti gena. Mutacija je važan korak genetskog algoritma jer sprječava preranu stagnaciju evolucije, odnosno prerano konvergenciju. Operator se najčešće opisuje vjerojatnošću promjene bita koja uobičajeno iznosi između 1% i 5%, a određuje ju korisnik. Što je veća vjerojatnost promjene, veća je nasumičnost samog algoritma tijekom izvršavanja. Jednostavna mutacija svaki bit kromosoma mijenja s jednakom vrijednošću p_m koji označava vjerojatnost promjene bita. Potpuna mutacija nasumičnim odabirom odabire cijeli kromosom a ne gen, te mutira, odnosno ispremiješa sve bitove u kromosomu. Miješajuća mutacija također slučajno odabire kromosom za mutaciju te prvu i drugu granicu i tada ili izmiješa gene ili ih slučajno generira ili ih invertira [21].
Primjer jednostavne mutacije:

Tablica 8: PRIMJER MUTACIJE GENA U KROMOSOMU

Kromosom prije mutacije	1 0 1 1 0 1 0 1 1 1 0 1 1 1 0
Kromosom nakon mutacije	0 0 1 1 0 1 0 1 1 1 0 1 1 1 0

5.9. Implementacija genetskog algoritma

GA, kao što je već opisano u prijašnjim poglavljima, osigurava robusnu pretragu u složenim višedimenzionalnim prostorima mogućih rješenja. Obično se koristi za generiranje visokokvalitetnih rješenja za optimizaciju i probleme pretraživanja oslanjajući se na bio-nadahnute operatore poput mutacije, križanja i selekcije. U ovom radu je GA korišten za optimizaciju izlaza pravila i pripadnih funkcija pripadnosti neizrazitog upravljača s ciljem minimiziranja vremena putovanja žurne službe.

5.9.1. Kôdiranje neizrazitih pravila

Kako bi se pravila neizrazitog upravljača optimizirala, ponajprije ih je potrebno ispravno reprezentirati, odnosno kôdirati. Za predstavljanje neizrazitih pravila primjenjuje se kôdiranje cijelih brojeva. Skup jezične vrijednosti svake neizrazite varijable mapiran je u skup prirodnih brojeva. Na primjer, *Malo*, *Srednje*, *Veliko* je mapirano u skup prirodnih brojeva $\{1, 2, 3\}$. Neka je x izlaz produljenja vremena faze na putu vozila žurne službe [20]:

$$x = \in \{i | i = 1, 2, 3, ..., l\} \ , \tag{13}$$

gdje je:

l - broj gena u kromosomu koji reprezentira pravila;

x - izlaz produljenja vremena faze na putu vozila žurne službe.

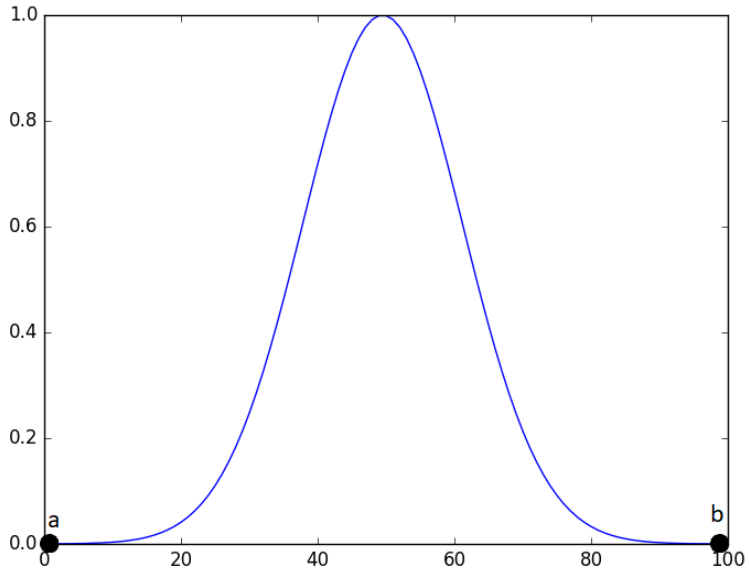
Primjer mapiranih pravila u kromosome moguće je vidjeti u slijedećoj tablici 9:

Tablica 9: PRIMJER PRAVILA MAPIRANIH U KROMOSOM

Kromosom	1 3 3 1 2 3 1 2 3 1 1 2 1 1 2 1 2 ... l

5.9.2. Kôdiranje funkcija pripadnosti

Gaussov oblik funckije primijenjen je na svim funkcijama pripadnosti neizrazitog upravljača. Gaussova funkcija se može definirati s dvije točke, početak i kraj, a označene su s a i b, kao što je prikazano na slici fig:gauss. Neka a i b označavaju prvu početnu funkciju članstva, koja se daje na temelju inženjerskog iskustva. Budući da GA nasumičnim kreiranjem ili promjenom kromosoma može generirati krivo zadane funkcije pripadnosti, uvodi se niz granica u kojima svaki od gena ima interval s donjom i gornjom granicom kretanja po osi. Granični intervali su zadani na način da svaka od obje granice ne smije biti izvan intervala ulaza/izlaza, da gornja točka b nije manja od točke a, te da je točka a veća od a_0 prijašnje funkcije pripadnosti i b manji od sljedeće b_1 funkcije pripadnosti [20].



Slika 17: Primjer Gaussove funkcije

5.9.3. Križanje i mutacija

Kôdiranje neizrazitih pravila opisano je u prijašnjim poglavljima kao kôdiranje cijelih brojeva. Implementacija genetskog algoritma kod problema cijelih brojeva ne koristi klasične genetske operatore i funkciju dobrote kao što je do sada opisano. Kod problema cijelih brojeva koristi se programiranje cijelih brojeva koje uključuje nekoliko modifikacija u osnovnom genetskom algoritmu. Prema [28] koristi se:

- Posebna funkcija stvaranja novih kromosoma, križanja i mutacije koje forsiraju da varijable budu cjelobrojne;
- GA pokušava smanjiti funkciju penala, a ne funkciju dobrote. Funkcija penala ili kazne, kombinirana je binarnim turnirom selekcije jedinki za sljedeće generacije. Vrijednost funkcije penala svake jedinke populacije je: Ako je jedinka zadovoljava, funkcija penala je funkcija dobrote. Ako je jedinka ne zadovoljava, funkcija penala je maksimum funkcije dobrote među svim jedinkama populacije, plus zbroj prekršaja ograničenja neizvedive točke;
- GA ne nameće linearna ograničenja ako postoje cjelobrojna ograničenja. Umjesto toga, uvodi funkciju penala linearnog ograničenja.

Umjesto kumulativne dobrote računa se kumulativna kazna, a jedinka se ne kopira u novu populaciju, već se briše iz trenutne.

Drugačije od kôdiranja neizrazitih pravila, kôdiranje funkcije pripadnosti nije ograničeno na cijele brojeve već na bilo koji decimalni broj unutar zadanih intervala i granica. GA pri optimizaciji funkcija pripadnosti koristi standardne funkcije i operatore GA funkcije iz MATLAB paketa.

5.9.4. Agregacija i optimizacija više scenarija

Zbog učinka, rješenja za većinu praktičnih optimizacija problema moraju se ispitati na određeni broj različitih uvjeta rada, u ovom radu opisanih kao različite prometne scenarije. Scenariji u ovom radu predstavljaju različite rute vozila žurne službe isto kao i različita opterećenja prometne mreže. Stoga, optimalno i razumno rješenje treba biti izvedivo u svim zadanim realnim scenarijima rada. Međutim, optimalno rješenje dobiveno iz najgoreg pojedinačnog scenarija može biti precjenjivanje u odnosu na druge scenarije. Na taj način mogu se izvoditi sasvim drugačije u odnosu na njihova pojedinačna optimalna rješenja [29, 30].

Više kriterijska optimizacija problema se sastoji od problema s optimizacijom M-ciljeva s K različitih scenarija. U prisutnosti više scenarija $(S_k, k = 1,2...,K)$, prvo se treba izračunati funkcija cilja za svaki scenarij, izračunavajući na taj način $f(k,x)$ za svaki k [29, 30].

Postoji nekoliko metoda agregiranja rezultata koje se obično provode u praksi, ovisno o kakvom se problemu radi. U ovom radu uzeta je metoda agregiranja prosjeka svih scenarija za zadanu funkciju cilja, prema strukturi prikazanoj na slici 18. Metoda agregiranja prosječnog rezultata za optimizaciju se koristi kada ne postoji velika razlika u učinkovitosti između svih K scenarija. Ako je razlika između scenarija velika, agregiranje prema medijanu bi bio bolji izbor. Prosječna vrijednost svih K scenarija može se opisati [29, 30]:

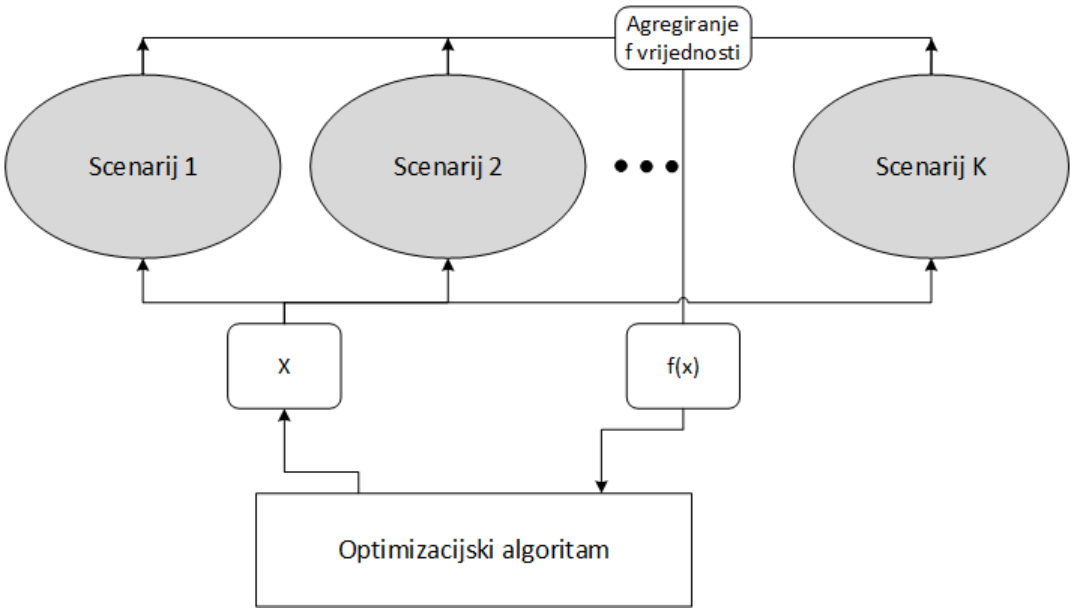
$$\sqcup_{k=1}^{k} f(k,x) = \frac{1}{K} \sum_{k=1}^{K} f(k,x), \tag{14}$$

gdje je:

K - broj scenarija;

$\sqcup_{k=1}^{k} f(k,x)$ - agregirana vrijednost funkcije dobrote za svaki svenarij;

$f(k,x)$ - funkcija dobrote za određeni scenarij.



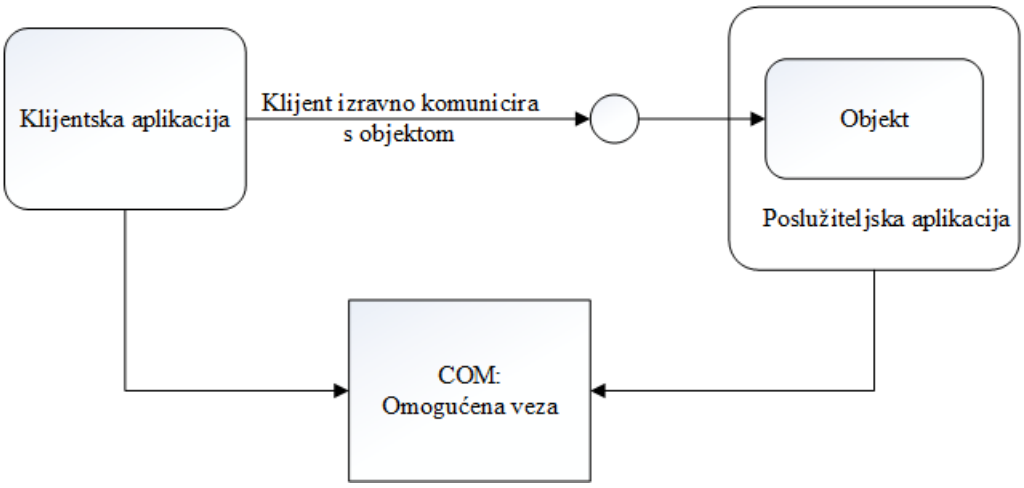
Slika 18: Struktura agregiranja rezultata u skladu s optimizacijskim algoritmom

6. Simulacijski rezultati

6.1. Simulacijsko okruženje

Za simuliranje prometa korišten je mikroskopski simulacijski alat za modeliranje gradske mreže i prometnih entiteta PTV VISSIM. To je programski paket koji služi za analizu i upravljanje prometnim tokovima u svrhu analize i optimizacije različitih prometnih rješenja. Trenutno jedan od najmoćnijih dostupnih alata za simuliranje višemodalnih mreža prometa i prometnih entiteta. Mikroskopskim simulacijama moguće je simuliranje pojedinog prometnog entiteta, poput automobila, tramvaja, biciklista, pješaka i slično. Takve simulacije služe za analizu prometnih mreža od reda veličine jednog pojedinačnog raskrižja pa sve do veličine mreže cijelog grada. Predstavlja promet u puno više detalja nego makroskopska ili mezoskopska vrsta simulacije. Točnost i vjerodostojnost evaluacije podataka simulacijskog modela najviše ovisi o samoj kvaliteti izrade modela ponašanja prometnih entiteta u simuliranoj mreži [4].

U ovom radu algoritam adaptivnog upravljanja semaforiziranim raskrižjem, napravljen je u programskom paketu MATLAB, a simulacijski dio u aplikaciji VISSIM. Pomoću COM (engl. Component Object Model, COM) sučelja povezana su oba alata (prikazano na slici 19), čime je omogućena komunikacija. Komponentni objektni model (COM) je model arhitekture koja omogućuje povezivanje i interakciju između VISSIM simulacije i drugog programskog paketa različitog proizvođača. VISSIM simulacija sadrži simulacijske parametre i podatke dobivene mjerenjem ponašanja simulacije. Korištenjem COM sučelja moguće je pristupiti tim podacima te upravljati različitim objektima i pravilima ponašanja entiteta i prometne infrastrukture [3, 31].

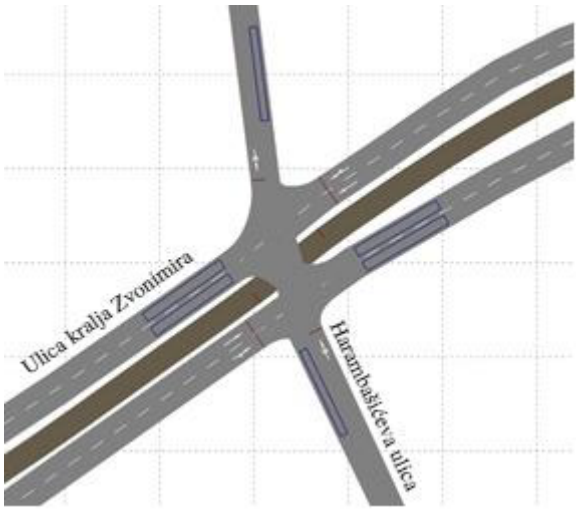


Slika 19: Struktura COM sučelja [3]

6.2. Prometni model i podaci

Kako bi se testirali implementirani algoritmi adaptivnog upravljanja, kreiran je model raskrižja ”Ulica kralja Zvonimira - Harambašićeva ulica” kao što je prikazano na slici 20. Samo raskrižje nalazi se na jednom od glavnih pravaca koji povezuju grad Zagreb s istoka na zapad i obrnuto. Osim toga, drugi razlozi za odabir ovog raskrižja su: velika razlika u prometnoj potražnji sporednog i glavnog toka, postojanje JGP-a u vidu tri tramvajske linije te ustaljeni signalni plan koji je izveden u dvije faze [3, 4].

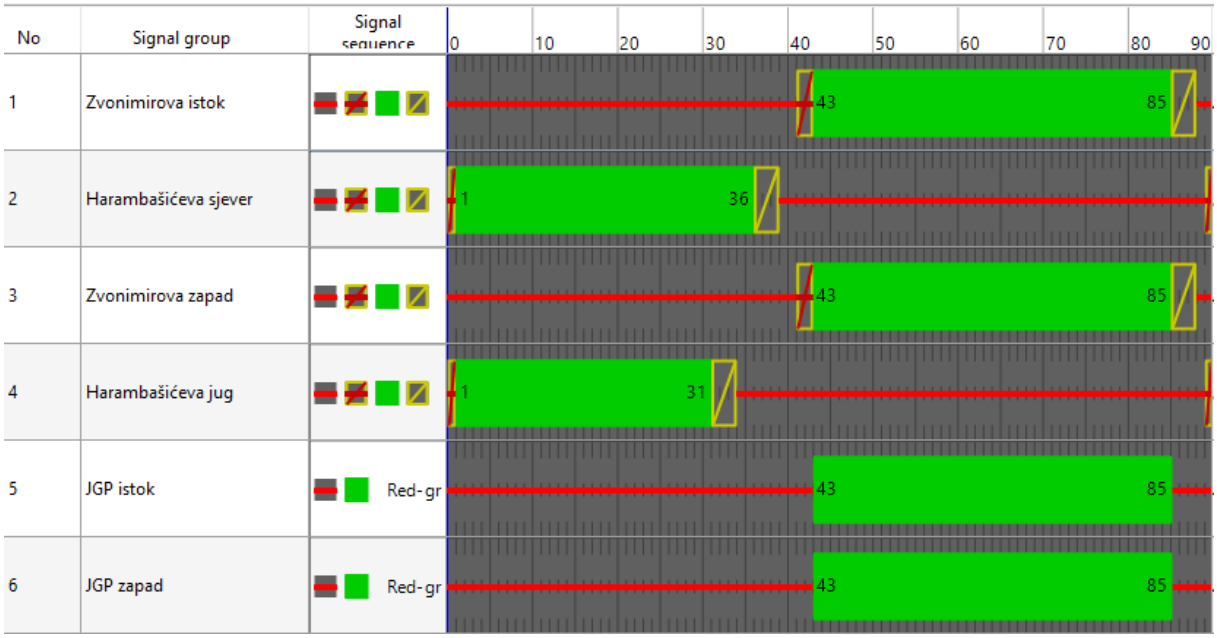
Glavni privoz od Zvonimirove ulice sastoji se od dvije prometne trake u oba smjera, dok oba privoza Harambašićeve ulice imaju po jedan prometni trak u oba smjera. Također, na Zvonimirovoj ulici nalazi se tramvajska pruga kojom prolaze tri tramvajske linije. Na slici 20 sivo su označene prikazane cestovne površine, smeđe su prikazane tramvajske tračnice te plavim pravokutnicima su označeni detektori korišteni za registraciju prolaska vozila žurne službe kroz raskrižje [3, 4].



Slika 20: Model raskrižja ”Ulica kralja Zvonimira - Harambašićeva ulica” [3]

Signalni plan

Ustaljeni signalni plan je izveden u dvije slijedne faze te prikazan na slici 21. Prva faza se izvodi na glavnom prometnom toku Ulice kralja Zvonimira sa zelenim svjetlom u trajanju od 42 sekunde, dok se druga faza izvodi na sporednom toku Harambašićeve ulice sa zelenim svjetlom u trajanju od 35 sekundi [3, 4].



Slika 21: Prikaz signalnog plana raskrižja ”Ulica kralja Zvonimira - Harambašićeva ulica” u VISSIM-u [3]

Postavke simulacije

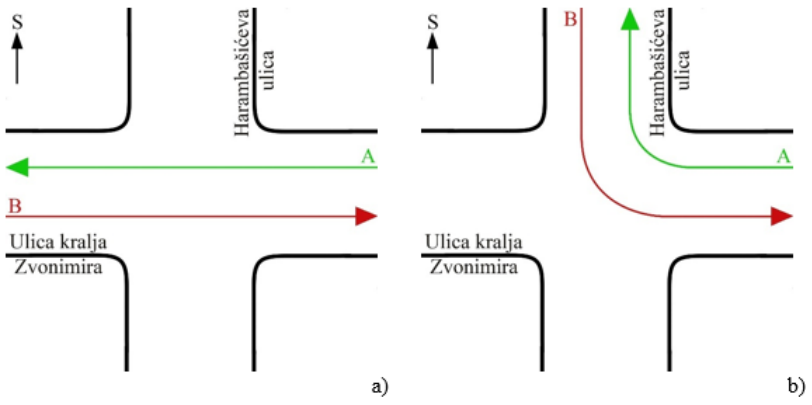
Za analizu rezultata korištenja kreiranog algoritma adaptivnog upravljanja korišteni su prometni scenariji koji definiraju različite rute putovanja žurne službe i potražnje prometnih tokova.

Zbog stohastičke prirode prometnog sustava i njenih entiteta za svaki scenarij je simulirano tri različitih simulacija koje su simulirane s različitim sjemenom generatora slučajnih vrijednosti varijabli. Takvim pristupom se utječe na vremensku raspodjelu generiranja prometne potražnje i na dolazak žurnog vozila u prometnu mrežu, ali ne i na broj vozila koje ulaze u prometnu mrežu već samo na vremensku raspodjelu ulaska pojedinog vozila.

Svaka od simulacija, simulirana je u trajanju od 60 simulacijskih minuta, od toga je 15 $[min]$ period *zagrijavanja* koji se ne uzima u obzir pri evaluaciji podataka. VISSIM simulacija počinje bez vozila, stoga *zagrijavanje* se koristi za punjenje mreže vozilima i stvaranja realistične situacije u prometu.

Scenariji simulacije

Analiza predloženog algoritma adaptivnog upravljanja provedena je korištenjem šest različitih scenarija prometa. U prvom i drugom scenariju simulirani su normalni prometni uvjeti s podacima dobivenih iz tablice 10. Treći i četvrti scenarij imaju povećanu potražnju (za 40%) kako bi bilo simulirano zagušenje prometne mreže. U petom i šestom scenariju, potražnja se dodatno povećava za 60% u odnosu na prva dva scenarija za simuliranje velikih prometnih potražnji. Stoga, postoje dvije različite rute 22 i tri različite prometne potražnje.



Slika 22: Prikaz smjera dolaska (zeleno) i povratka (crveno) vozila žurne službe a) Scenarij 1, 3 i 5; b) Scenarij 2, 4 i 6 [4]

Tablica 10: PROMETNA POTRAŽNJA ZA SVAKI SCENARIJ

Scenarijo	Prometna potražnja [veh/h]			
	Harambašićeva ulica		Ulica Kralja Zvonimira	
	Sjever	Jug	Istok	Zapad
1	220	150	1.100	720
2	220	150	1.100	720
3	308	210	1.540	1.008
4	308	210	1.540	1.008
5	352	240	1.760	1.152
6	352	240	1.760	1.152

6.3. Analiza dobivenih rezultata

U svrhu evaluacije podataka predloženih algoritama i njihovih optimizacija, svaki od prethodno opisanih scenarija simuliran je po 5 puta u 6 različitih konfiguracija. Simulirano je po 3 puta za svaki scenarij bez algoritma, uz ustaljeni algoritam dodjele prioriteta, uz neizraziti algoritam dodjele prioriteta, te uz neizraziti algoritam dodjele prioriteta s optimizacijom pomoću genetskog algoritma. Oba genetska algoritma su bila podešena na 10 generacija te 10 jedinki u populaciji. Za usporednu analizu uzeti su slijedeći parametri [3]:

1. **Vrijeme putovanja vozila žurne službe** - vrijeme mjereno od trenutka pojave vozila žurne službe u simulacijskoj mreži do izlaska iz mreže ($VP_{\check{Z}S}$);

2. **Izgubljeno vrijeme vozila žurne službe** - vrijeme koje vozilo žurne službe provede s brzinom jednakom nuli ($IV_{\check{Z}S}$);

3. **Broj zaustavljanja vozila žurne službe** - zaustavljanje je definirano kao svaki trenutak u kojem je brzina vozila žurne službe jednaka nuli, dok je u prethodnom vremenskom koraku simulacije bila veće od nule ($BZ_{\check{Z}S}$);

4. **Ukupno vrijeme putovanja svih vozila** - zbroj vremena putovanja za svako vozilo u mreži ($VPSV$).

Izgubljeno vrijeme vozila žurne službe definirano je prema izrazu:

$$t_{izgubljeno} = \sum_{i=1}^{N} \left(\frac{S_i}{V_i} - \frac{S_i}{V_d} \right) \ , \tag{15}$$

gdje je:

$t_{izgubljeno}$ - ukupno izgubljeno vrijeme vozila žurne službe [s];

i - broj trenutnog vremenskog koraka;

S_i - udaljenost pređena u vremenskom koraku i [m];

V_i - brzina vozila žurne službe u vremenskom koraku i [m/s];

V_d - željena brzina vozila žurne službe u vremenskom koraku i [m/s].

6.3.1. Analiza rezultata za scenarije 1 i 2

Rezultati dobiveni za prva dva scenarija s malom prometnom potražnjom prikazani su u tablicama 11 i 12.U prvom scenariju vidljivo je da promjena srednjeg vremena putovanja vozila žurne službe mala između pristupa bez algoritma te svih predloženih algoritma upravljanja. Vrijeme putovanja vozila žurne službe bez pristupa upravljanja prioritetom prolaska iznosi 179 $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je putovalo 175 $[s]$ (promjena $-1,7\%$). Primjenom neizrazitog upravljanja vozilo žurne službe je putovalo 179 $[s]$ (promjena 0%). Korekciju nešto lošijih rezultata neizrazitog algoritma poboljšava pristup s optimizacijom genetskog algoritma. Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe u prosjeku je putovalo 176 $[s]$ (promjena $-1,68\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe u prosjeku je također putovalo 176 $[s]$ (promjena $-1,68\%$). Bolji rezultati nakon GA optimizacije neizrazitih pravila govore da pravila koja je stručnjak namjestio nisu bila idealna za model u kojemu se nalazi, dok nepromijenjeni rezultati nakon GA optimizacije funkcija pripadnosti znače da su već postavljene funkcije pripadnosti zadovoljavale uvjete u kojima se nalaze.

Prema parametrima drugog scenarija prosječno vrijeme putovanja vozila žurne službe vidljivo je smanjenje kroz sve pristupe algoritma upravljanja, a ponajviše s neizrazitim algoritmom i GA optimizacijom. Bez algoritma vozilo žurne službe je prosječno putovalo $222,6$ $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je putovalo $188,1$ $[s]$ (promjena -15%). Primjenom neizrazitog upravljanja vozilo žurne službe je putovalo $183,3$ s (promjena $-17,67\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe u prosjeku je putovalo 183 $[s]$ (promjena $-17,81\%$). Primjenom neizrazitog

algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe u prosjeku je putovalo $173,6[s]$ (promjena $-22,01\%$). Također, proporcionalno vremenu putovanja vozila žurne službe, prosječno izgubljeno vrijeme vozila žurne službe je smanjeno i do 75% uz primjenu neizrazitog algoritma s GA optimizacijom.

Prosječno izgubljeno vrijeme putovanja vozila žurne službe iznosi $63,33\ [s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je izgubilo $30,53\ [s]$ putovanja (promjena $-51,84\%$). Primjenom neizrazitog upravljanja vozilo žurne službe prosječno je izgubilo $25,33\ [s]$ putovanja (promjena -60%). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe prosječno je izgubilo $23,66\ [s]$ putovanja (promjena $-62,64\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe prosječno je izgubilo $13,66\ [s]$ putovanja (promjena $-78,53\%$).

Poboljšanjem vremena putovanja vozila žurne službe neznatno utječe na prosječno vrijeme putovanja svih vozila u mreži, zahvaljujući algoritmu vraćanja oduzetog vremena koji smanjuje taj negativni utjecaj na konfikltne privoze. Prosječno vrijeme putovanja svih vozila u mreži iznosi u promjenama od $-0,24\%$ do $0,45\%$ što je zanemarivo.

Tablica 11: DOBIVENE SREDNJE VRIJEDNOSTI ZA SCENARIJ 1

Parametri	**Scenarij 1**								
	Bez algoritma	**Ustaljeni algoritam**		**Neizraziti algoritam**		**GA optimizacija neizrazitih pravila**		**GA optimizacija funkcija pripadnosti**	
		Vrijednost	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**
$VP_{\check{Z}S}$ [s]	179	175	-1,7	179	0	176	-1,68	176	-1,68
$BZ_{\check{Z}S}$	1	0,33	-67	0,66	-34	0,67	-33	0,67	-33
$IV_{\check{Z}S}$ [s]	25	21,33	-14,68	26	4	21,6	-13,6	21,4	-14,4
$VPSV$ [h]	57,91	57,99	0,14	57,98	0,12	58,11	0,35	58,06	0,26

Tablica 12: DOBIVENE SREDNJE VRIJEDNOSTI ZA SCENARIJ 2

Parametri	**Scenarij 2**								
	Bez algoritma	**Ustaljeni algoritam**		**Neizraziti algoritam**		**GA optimizacija neizrazitih pravila**		**GA optimizacija funkcija pripadnosti**	
		Vrijednost	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**
$VP_{\check{Z}S}$ [s]	222,66	188,1	-15,52	183,33	-17,68	183	-17,81	173,66	-22,01
$BZ_{\check{Z}S}$	2,67	1	-62,55	1	-62,5	0,66	-75,28	0,66	-75,28
$IV_{\check{Z}S}$ [s]	63,33	30,53	-51,84	25,33	-60	23,66	-62,64	13,66	-78,53
$VPSV$ [h]	57,93	57,76	-0,24	58,01	0,19	58,11	0,36	58,16	0,45

6.3.2. Analiza rezultata za scenarij 3 i 4

Rezultati dobiveni za treći i četvrti scenarij s umjerenom prometnom potražnjom, prikazani su u tablicama 13 i 14. Slično kao i kod prvog i drugog scenarija u trećem scenariju algoritam

neizrazite logike nije utjecao s poboljšanjem u odnosu na pristup bez algoritma, ali je optimizacija pomoću genetskog algoritma popravila rezultate.

Kod scenarija 3, vrijeme putovanja vozila žurne službe bez pristupa upravljanja prioritetom prolaska iznosi $201,33$ $[s]$ s. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je putovalo 190 $[s]$ (promjena $-14,29\%$). Primjenom neizrazitog upravljanja vozilo žurne službe je putovalo 202 $[s]$ (promjena $0,5\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe u prosjeku je putovalo $186,67$ $[s]$ (promjena $-15,79\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe u prosjeku je također putovalo 185 $[s]$ (promjena $-16,54\%$).

Prosječno izgubljeno vrijeme putovanja vozila žurne službe iznosi 48 $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je izgubilo 37 $[s]$ putovanja (promjena $-22,92\%$). Primjenom neizrazitog upravljanja vozilo žurne službe prosječno je izgubilo $48,6$ $[s]$ putovanja (promjena $1,25\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe prosječno je izgubilo $33,33$ $[s]$ putovanja (promjena $-30,56\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe prosječno je izgubilo $31,33$ $[s]$ putovanja (promjena $-34,73\%$).

Poboljšanjem vremena putovanja vozila žurne službe nije uveliko utjecalo na prosječno vrijeme putovanja svih vozila u mreži. Prosječno vrijeme putovanja svih vozila u mreži iznosi u promjenama od $0,26\%$ do $0,52\%$ što je zanemarivo.

Kod scenarija 4, vrijeme putovanja vozila žurne službe bez pristupa upravljanja prioritetom prolaska iznosi 224 $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je putovalo $196,3$ $[s]$ (promjena $-12,35\%$). Primjenom neizrazitog upravljanja vozilo žurne službe je putovalo $181,66$ $[s]$ (promjena $-18,9\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe u prosjeku je putovalo 186 $[s]$ (promjena $-19,2\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe u prosjeku je također putovalo 186 $[s]$ (promjena $-19,2\%$).

Prosječno izgubljeno vrijeme putovanja vozila žurne službe iznosi $66,66$ $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je izgubilo 37 $[s]$ putovanja (promjena $-44,49\%$). Primjenom neizrazitog upravljanja vozilo žurne službe prosječno je izgubilo 24 $[s]$ putovanja (promjena -64%). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe prosječno je izgubilo $21,33$ $[s]$ putovanja (promjena -60%). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo

žurne službe prosječno je izgubilo 21,33 $[s]$ putovanja (promjena -68%).

Poboljšanjem vremena putovanja vozila žurne službe neznatno utječe na prosječno vrijeme putovanja svih vozila u mreži, zahvaljujući algoritmu vraćanja oduzetog vremena koji smanjuje taj negativni utjecaj na konfikltne privoze. Prosječno vrijeme putovanja svih vozila u mreži iznosi u promjenama od $-1,17\%$ do $0,8\%$ što je zanemarivo.

Tablica 13: DOBIVENE SREDNJE VRIJEDNOSTI ZA SCENARIJ 3

Parametri	**Scenarij 3**								
	Bez algoritma	**Ustaljeni algoritam**		**Neizraziti algoritam**		**GA optimizacija neizrazitih pravila**		**GA optimizacija funkcija pripadnosti**	
		Vrijednost	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**
$VP_{\check{Z}S}$ [s]	201,33	190	-14,29	202	0,5	186,67	-15,79	185	-16,54
$BZ_{\check{Z}S}$	1	1	0	1.5	50	0,66	-34	0,66	-34
$IV_{\check{Z}S}$ [s]	48	37	-22,92	48,6	1,25	33,33	-30,56	31,33	-34,73
$VPSV$ [h]	89,64	89,87	0,26	90,33	0,77	89,16	0,54	89,17	0,52

Tablica 14: DOBIVENE SREDNJE VRIJEDNOSTI ZA SCENARIJ 4

Parametri	**Scenarij 4**								
	Bez algoritma	**Ustaljeni algoritam**		**Neizraziti algoritam**		**GA optimizacija neizrazitih pravila**		**GA optimizacija funkcija pripadnosti**	
		Vrijednost	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**
$VP_{\check{Z}S}$ [s]	224	196,33	-12,35	181,66	-18,9	181	-19,2	181	-19,2
$BZ_{\check{Z}S}$	2,66	1,33	-50	0,66	-75,19	1	-62,41	1	-62,41
$IV_{\check{Z}S}$ [s]	66,66	37	-44,49	24	-64	21,33	-68	21,33	-68
$VPSV$ [h]	90,08	90,1	0,08	90,12	0,04	89,03	-1,17	89,03	-1,17

6.3.3. Analiza rezultata za scenarij 5 i 6

Rezultati dobiveni za peti i šesti scenarij s velikom prometnom potražnjom, prikazani su u tablicama 15 i 16. Kod oba scenarija vidljivo je poboljšanje kod svih predloženih algoritama upravljanja.

Kod scenarija 5, vrijeme putovanja vozila žurne službe bez pristupa upravljanja prioritetom prolaska iznosi 280,33 $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je putovalo 232,66 $[s]$ (promjena -17%). Primjenom neizrazitog upravljanja vozilo žurne službe je putovalo 232 $[s]$ (promjena $-17,24\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe u prosjeku je putovalo 228,33 $[s]$ (promjena $-18,55\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe u prosjeku je također putovalo 228,33 $[s]$ (promjena $-18,55\%$).

Prosječno izgubljeno vrijeme putovanja vozila žurne službe iznosi 128 $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je izgubilo 79,33 $[s]$ putovanja

(promjena $-38,02\%$). Primjenom neizrazitog upravljanja vozilo žurne službe prosječno je izgubilo $78,66$ $[s]$ putovanja (promjena $-38,55\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe prosječno je izgubilo 75 $[s]$ putovanja (promjena $-41,41\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe prosječno je izgubilo 75 $[s]$ putovanja (promjena $-41,41\%$).

Poboljšanjem vremena putovanja vozila žurne službe nije uveliko utjecalo na prosječno vrijeme putovanja svih vozila u mreži. Prosječno vrijeme putovanja svih vozila u mreži iznosi u promjenama od $-0,58\%$ do $2,69\%$ što je zanemarivo.

Kod scenarija 6, vrijeme putovanja vozila žurne službe bez pristupa upravljanja prioritetom prolaska iznosi $223,3$ $[s]$. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je putovalo 195 $[s]$ (promjena $-12,69\%$). Primjenom neizrazitog upravljanja vozilo žurne službe je putovalo $185,33$ $[s]$ s (promjena $-17,02\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe u prosjeku je putovalo $172,66$ $[s]$ (promjena $-22,69\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe u prosjeku je također putovalo $172,66$ $[s]$ (promjena $-22,69\%$).

Prosječno izgubljeno vrijeme putovanja vozila žurne službe iznosi 65 s. Primjenom ustaljenog algoritma upravljanja vozilo žurne službe prosječno je izgubilo $36,33$ $[s]$ putovanja (promjena $-44,11\%$). Primjenom neizrazitog upravljanja vozilo žurne službe prosječno je izgubilo $27,33$ $[s]$ putovanja (promjena $-57,95\%$). Primjenom neizrazitog algoritma s GA optimizacijom neizrazitih pravila vozilo žurne službe prosječno je izgubilo $14,33$ $[s]$ putovanja (promjena $-77,95\%$). Primjenom neizrazitog algoritma s GA optimizacijom funkcijama pripadnosti vozilo žurne službe prosječno je izgubilo $14,33$ $[s]$ putovanja (promjena $-77,95\%$).

Poboljšanjem vremena putovanja vozila žurne službe neznatno utječe na prosječno vrijeme putovanja svih vozila u mreži, zahvaljujući algoritmu vraćanja oduzetog vremena koji smanjuje taj negativni utjecaj na konfikltne privoze. Prosječno vrijeme putovanja svih vozila u mreži iznosi u promjenama od $-0,56\%$ do $0,58\%$ što je zanemarivo.

Tablica 15: DOBIVENE SREDNJE VRIJEDNOSTI ZA SCENARIJ 5

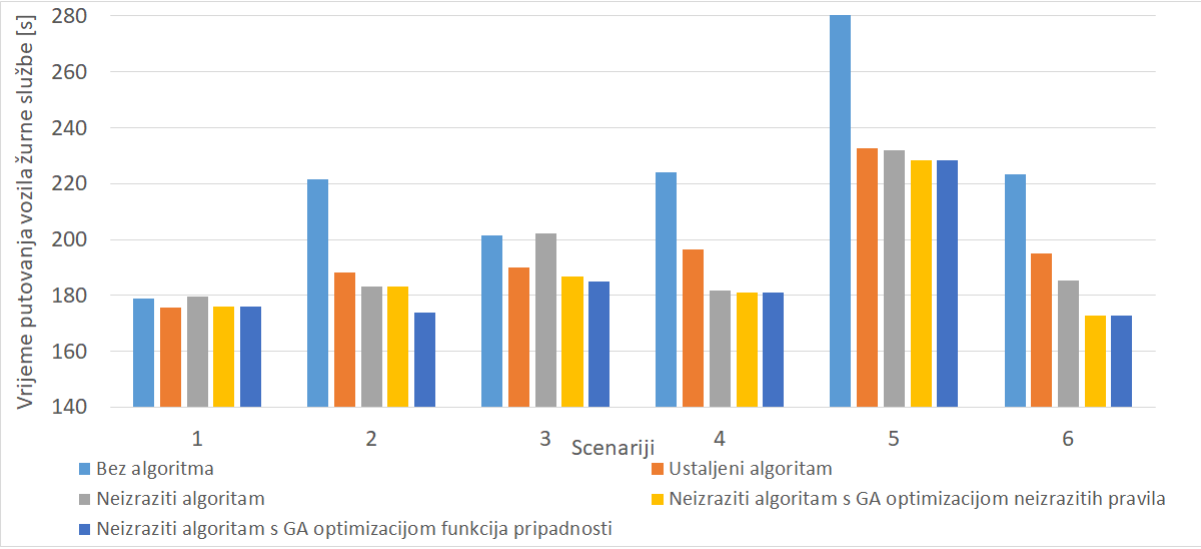
Parametri	**Scenarij 5**								
	Bez algoritma	**Ustaljeni algoritam**		**Neizraziti algoritam**		**GA optimizacija neizrazitih pravila**		**GA optimizacija funkcija pripadnosti**	
		Vrijednost	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**	**Vrijednost**	**Promjena [%]**
$VP_{\check{Z}S}$ [s]	280,33	232,66	-17	232	-17,24	228,33	-18.55	228,33	-18,55
$BZ_{\check{Z}S}$	3,33	3,33	0	2,33	-30,03	2,66	-20,12	2,66	-20,12
$IV_{\check{Z}S}$ [s]	128	79,33	-38,02	78,66	-38,55	75	-41,41	75	-41,41
$VPSV$ [h]	122,55	121,84	-0.58	121,99	-0,46	125,85	2,69	125,85	2,69

Tablica 16: DOBIVENE SREDNJE VRIJEDNOSTI ZA SCENARIJ 6

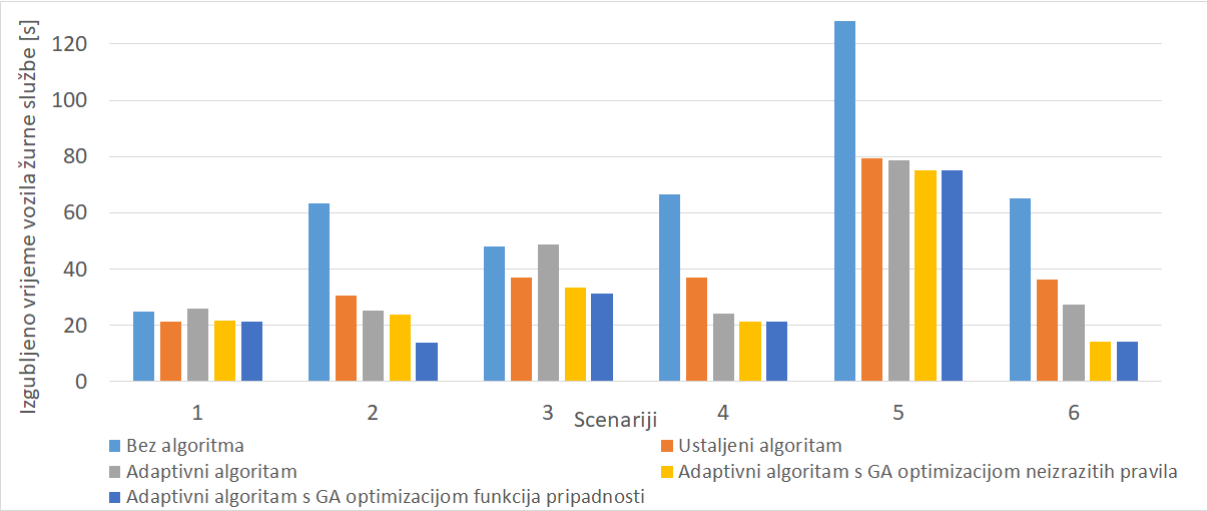
Parametri	Scenarij 6								
	Bez algoritma	Ustaljeni algoritam		Neizraziti algoritam		GA optimizacija neizrazitih pravila		GA optimizacija funkcija pripadnosti	
		Vrijednost	Promjena [%]	Vrijednost	Promjena [%]	Vrijednost	Promjena [%]	Vrijednost	Promjena [%]
$VP_{\check{Z}S}$ [s]	223,33	195	-12,69	185,33	-17,02	172,66	-22,69	172,66	-22,69
$BZ_{\check{Z}S}$	1,66	1	-39,76	1	-39,76	0,33	-80,12	0,33	-80,12
$IV_{\check{Z}S}$ [s]	65	36,33	-44,11	27,33	-57,95	14,33	-77,95	14,33	-77,95
$VPSV$ [h]	125,13	124,43	-0,56	125,06	-0,06	125,85	0,58	125,85	0,58

6.3.4. Sažetak analize rezultata

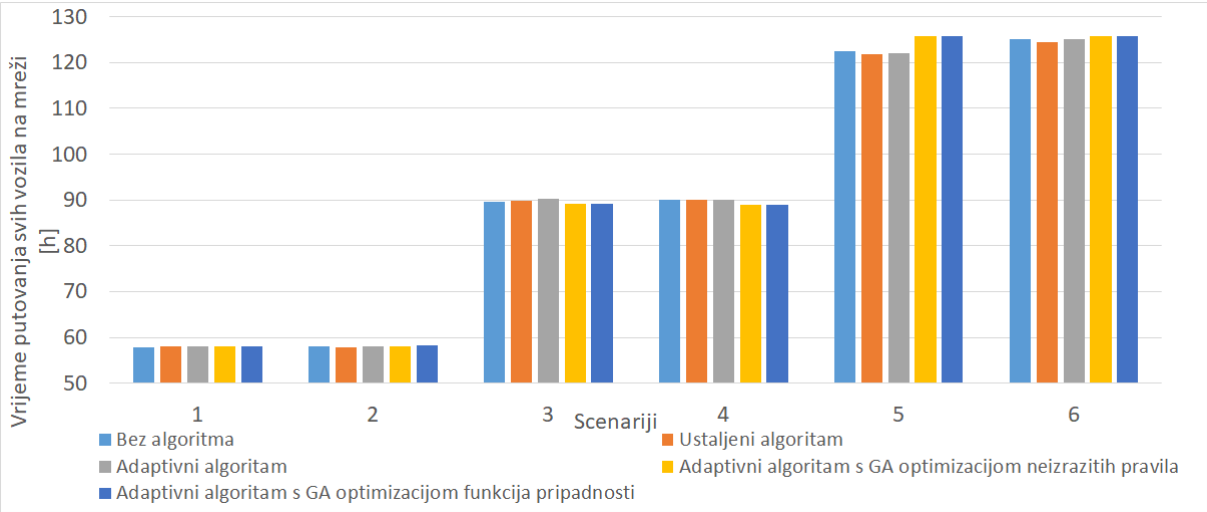
Prema grafikonu 1 vidljivo je stepenasto poboljšanje u četiri od šest scenarija za svaki algoritam upravljanja. Odnosno, u dva scenarija algoritam neizrazite logike pokazao se nešto lošijim od ustaljenog algoritma upravljanja. Nešto lošije rezultate kod primjene neizrazitog upravljanja u svakom slučaju poboljšavaju GA optimizacije neizrazitih pravila i funkcija pripadnosti. Kroz ostale scenarije vidljivo je značajno poboljšanje pristupa neizrazitog upravljanje te dodatno uvođenjem GA optimizacije. Prosječno vrijeme putovanja vozila žurne službe smanjeno je i do $22,69\%$ u iznosu od 51 $[s]$ kod scenarija s velikim prometnim potražnjama u odnosu na pristup bez algoritma. Također, izgubljeno vrijeme putovanja vozila žurne službe smanjeno je i do 77% u iznosu od $50,67$ $[s]$, vidljivo na grafikonu 2. Broj stajanja vozila žurnih službi je u svim pristupima algoritma upravljanja smanjeno u odnosu na pristup bez algoritma, prikazano na grafikonu 4. Upravljanje predloženim algoritmima nije uveliko utjecalo na ostatak prometa, što se može vidjeti na grafikonu 3 koji prikazuje vrijeme putovanja svih vozila u mreži.



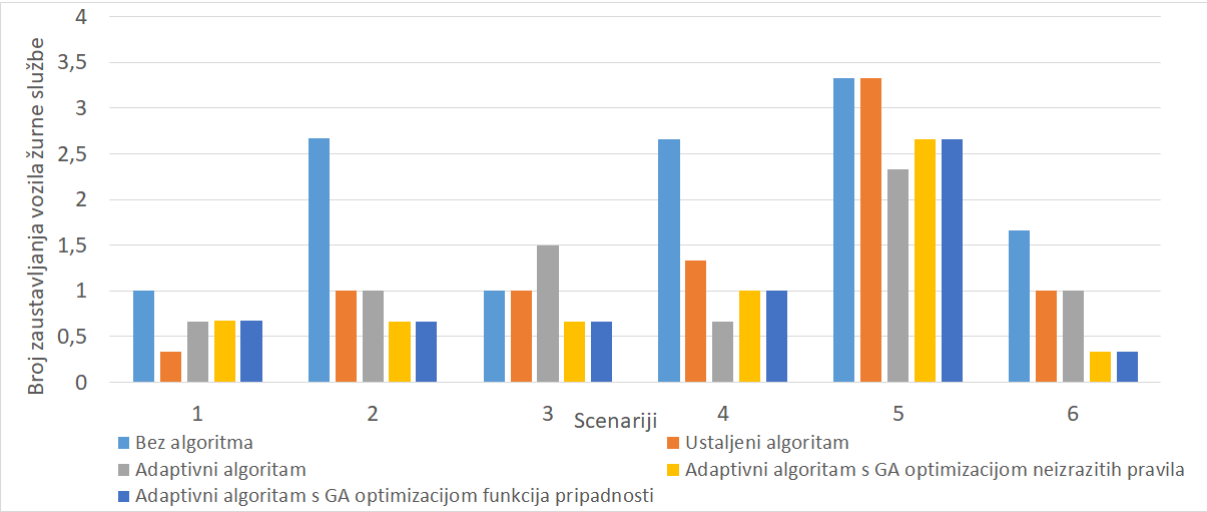
Grafikon 1: Srednje vrijednosti izgubljenog vremena vozila žurne službe za sve scenarije



Grafikon 2: Srednje vrijednosti vremena putovanja svih vozila na mreži za sve scenarije

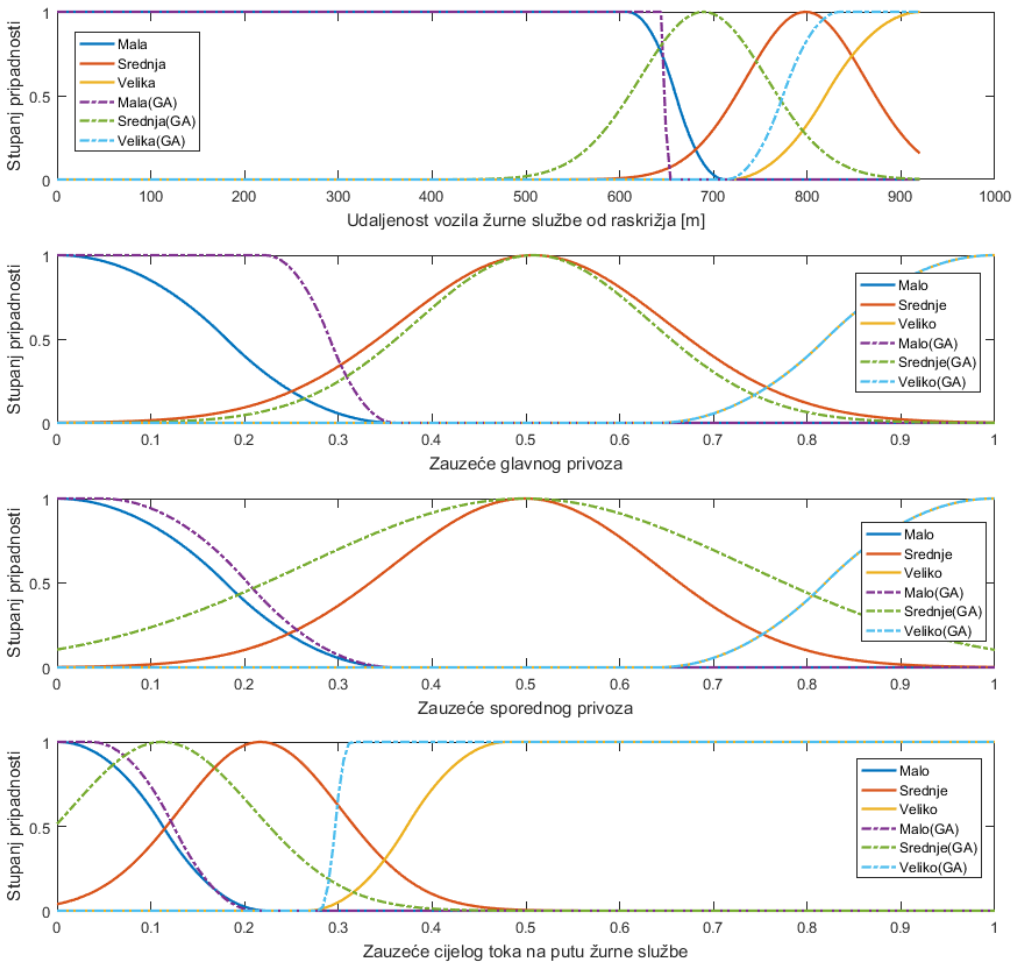


Grafikon 3: Srednje vrijednosti vremena putovanja vozila žurne službe za sve scenarije

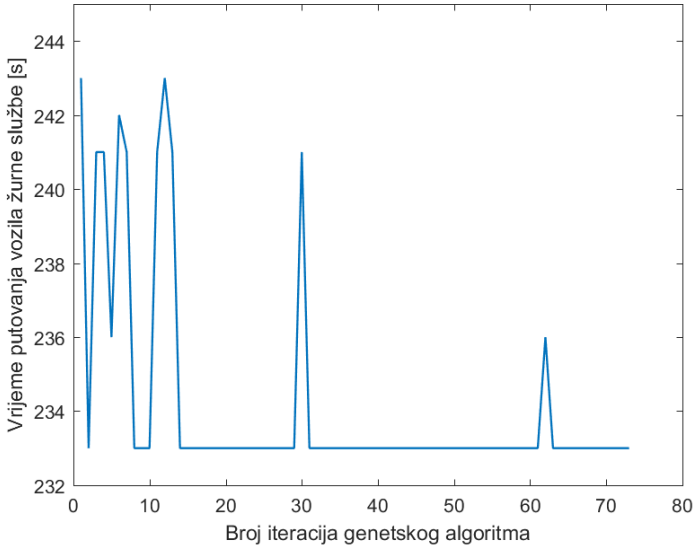


Grafikon 4: Srednje vrijednosti broja zaustavljanja vozila žurne službe

Grafikoni na slici 23 prikazuju ulaze u neizraziti upravljač. Na svakom od ulaza punim linijama prikazane su funkcije koje su postavljene prije optimizacije genetskog algoritma. Iscrtanim linijama moguće je vidjeti funkcije koje je korigirao GA za dobivanje nabjboljih rezultata vremena putovanja vozila žurne službe. Na slici 24 vidljivo je vrijeme putovanja vozila žurne službe kroz iteracije genetskog algoritma kako se korigira iz iteracije u iteraciju sve dok ne postigne minimalnu vrijednost koju može postići s postavljenim opcijama i zadanim granicama.



Slika 23: Prikaz GA optimiziranih funkcija pripadnosti



Slika 24: Vrijeme putovanja vozila žurne službe kroz iteracije genetskog algoritma

7. Zaključak

Povećanje broja vozila u gradskim sredinama izravno utječe na kvalitetu i sigurnost gradskog prometnog sustava. Zbog nemogućnosti fizičkog širenja prometne infrastrukture dolazi do potrebe pametnog upravljanja postojećom prometnom mrežom. Takve mogućnosti pametnog upravljanja moguće je primjenom ITS-a. Primjenom ITS rješenja u području upravljanja semaforiziranim raskrižjem u gradskim sredinama pruža mogućnosti poput dodjele prioriteta vozilima žurnih službi. U radu su implementirani i testirani algoritmi ustaljenog signalnog plana, dodjele prioriteta na osnovi duljine repa čekanja, neizrazitog upravljanja, te neizrazitog upravljanja s optimizacijom primjenom genetskog algoritma za neizrazita pravila i funkcija pripadnosti. Navedeni algoritmi rade na osnovu procjene vremena dolaska žurnog vozila te mijenjanja trajanja faza signalnog plana s ciljem omogućavanja brzog i sigurnog prolaska vozila žurne službe kroz raskrižje.

Zbog dodjele bezuvjetnog prioriteta vozilu žurne službe dolazi do negativnih utjecaja na ostatak prometne mreže. Kako bi se smanjio taj negativan učinak dodatno je predložen i implementiran algoritam za povratak oduzetog vremena. Navedeni algoritam ima ustaljeni pristup, a kako bi se algoritam učinio adaptivnim za bolji rad u različitim uvjetima, uvodi se upravljanje pomoću neizrazite logike. Upravljač neizrazite logike podešava prometni stručnjak te samim time se stvara mjesto za ljudsku pogrešku ili krivu procjenu. Kako bi se greška smanjila ili uklonila uvodi se GA optimizacija neizrazitih pravila i funkcija pripadnosti. Algoritmi su implementirani u programskom paketu MATLAB povezan COM sučeljem s mikroskopskim prometnim simulatorom PTV VISSIM radi njihove simulacijske provjere.

Analiza rada implementiranih algoritama nad izrađenom prometnom mrežom pokazuje poboljšanja za neizrazito upravljanje u četiri od šest scenarija, dok s optimizacijom pomoću genetskog algoritma pokazuje poboljšanje u svim scenarijima. Najbolje prosječno poboljšanje se očituje u scenariju šest s generiranom velikom prometnom potražnjom gdje je postignuto smanjenje trajanja putovanja vozila žurne službe za $50,67\ [s]$, odnosno 77%. Ovakvo poboljšanje pridonosi većoj sigurnosti sudionika u prometu, smanjenju troškova poreznih obveznika i vlasti, te omogućuje brz odziv žurnih službi što doprinosi većoj javnoj sigurnosti i spašava živote.

Nastavak istraživanja vidi se u većem broju iteracija genetskog algoritma, većem broja simu-

lacija različitih prometnih scenarija, te proširenje prometne mreže za optimizaciju postavljenih parametara dodjele prioriteta na više bliskih raskrižja na ruti vozila žurne službe.

Popis literature

[1] Bošnjak, I. *Inteligentni transportni sustavi 1*. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2006.

[2] Skočibušić B M. *Ekonomika prometa*. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2011.

[3] Kapusta, B, Miletić, M. Analiza utjecaja adaptivnog upravljanja signalnim planovima semaforiziranog raskrižja na vrijeme putovanja vozila žurnih službi. Rektorova nagrada, Sveučilište u Zagrebu, Zagreb, 2017.

[4] Borna Kapusta. Simulacija prioriteta prolaska vozila žurne službe kroz semaforizirano raskrižje. Završni rad, Sveučilište u Zagrebu, 2017.

[5] Marilena Amoni Jeffrey, F Paniati. Traffic signal preemption for emergency vehicles. Report FHWA-JPO-05-010, Federal Highway Administration and National Federal Highway Administration, 2006.

[6] Vujić, M. *Sustav dinamičkih prioriteta za vozila javnog gradskog prijevoza u automatskom upravljanju prometom*. Zagreb. Doktorska disertacija, Fakultet Prometnih Znanosti, Sveučilište u Zagrebu, 2013.

[7] VWK Ngan. A comprehensive strategy for transit signal priority. Master's thesis, University of British Columbia, Vancouver, Canada, 2002.

[8] Furth P G, Muller T H J. Conditional bus priority at signalized intersections: Better service quality with less traffic disruption, 2000.

[9] W Ekeila, T Sayed, and M El Esawey. Development of dynamic transit signal priority strategy, transportation. *Transportation Research Record: Journal of the Transportation Research Board*, 2111:1–9, 2009.

[10] Miletić, M, Kapusta, B, Ivanjko, E. Comparison of Two Approaches for Preemptive Traffic Light Control. Proceedings of 60th International Symposium ELMAR-2018, September, 2018.

[11] D Roegel. Simple algorithms for preemptive traffic control, and an appraisal of their quality. Research Report inria-00000658, INRIA; French Institute for Research in Computer Science and Automation, France, 2005.

[12] Lotfi Aliasker Zadeh. Fuzzy sets. Information and Control, 1965.

[13] Lotfi Aliasker Zadeh. Outline of a new approach to the analysis of complex systems and decision processes. IEEE Trans. Systems, Man and Cybernetics, 1973.

[14] Neizrazita logika. Preuzeto sa: `https://en.wikipedia.org/wiki/Fuzzy_logic` [Pristupljeno: kolovoz 2019.].

[15] Franck Dernoncourt. Introduction to fuzzy logic. Massachusetts Institute of Technology, 2013.

[16] H Haramina. Predavanja iz kolegija Inteligentni transportni sustavi u željezničkom prometu, Fakultet prometnih znanosti, Zagreb, 2017.

[17] E Ivanjko. Umjetna inteligencija, Neizrazita logika, Skupovi. predavanja, Fakultet Prometnih Znanosti, Sveučilište u Zagrebu, 2011.

[18] Petar Cuglin. Regulacija hidrauličkih sustava primjenom neizrazitog regulatora. Fakultet strojarstva i brodogradnje, Zagreb, 2009.

[19] Seyed Ali Mohamad Dehghan Hamed Homaei, S. R. Hejazi. A new traffic light controller using fuzzy logic for a full single junction involving emergency vehicle preemption. *Journal of Uncertain Systems*, 9:49–61, 2015.

[20] J Qiao, N Yang, and J Gao. Two-stage fuzzy logic controller for signalized intersection. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 41(1):178–184, Jan 2011.

[21] Marin Golub. Genetski algoritmi, skripta prvi dio. Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu, 2004.

[22] Genetski algoritmi. Preuzeto sa: `https://en.wikipedia.org/wiki/Genetic_algorithm` [Pristupljeno: srpanj 2017.].

[23] Nedeljko Perić Ivan Petrović, Mato Baotić. Inteligentni sustavi upravljanja: Neuronske mreže, evolucijski i genetički algoritmi, Udžbenik iz kolegija Inteligentni sustavi upravljanja, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu, 2015.

[24] Anit Kumar. Encoding schemes in genetic algorithm. International Journal of Advanced Research in IT and Engineering, 2013.

[25] Ivanjko E. Genetski algoritam. predavanja, Fakultet Prometnih Znanosti, Sveučilište u Zagrebu, 2018.

[26] Čupić, M. Prirodom inspirirani optimizacijski algoritmi. Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu, 2010.

[27] How the genetic algorithm works. Preuzeto sa: `https://www.mathworks.com/help/gads/how-the-genetic-algorithm-works.html` [Pristupljeno: kolovoz 2019.].

[28] Mixed integer optimization. Preuzeto sa: `https://www.mathworks.com/help/gads/mixed-integer-optimization.html#bs1cihn` [Pristupljeno: kolovoz 2019.].

[29] K Deb, L Zhu, and S Kulkarni. Handling multiple scenarios in evolutionary multiobjective numerical optimization. *IEEE Transactions on Evolutionary Computation*, 22(6):920–933, Dec 2018.

[30] L Zhu, K Deb, and S Kulkarni. Multi-scenario optimization using multi-criterion methods: A case study on byzantine agreement problem. In *2014 IEEE Congress on Evolutionary Computation (CEC)*, pages 2601–2608, July 2014.

[31] Stefan Wedin. Microsoft's Component Object Model (COM). Department of Computer Engineering, Malardalens Hogskola, 2000.

Popis ilustracija

1 Grafički prikaz pasivne tehnike razdvajanja faze [6] 6
2 Grafički prikaz pasivne tehnike razdvajanja faze [6] 6
3 Grafički prikaz pasivne tehnike smanjenja trajanja ciklusa [6] 7
4 Grafički prikaz tehnike ranijeg početka zelenog svjetla [6] 9
5 Grafički prikaz tehnike umetanja faze za ciljanu skupinu vozila [6] 9
6 Prikaz dijagrama toka algoritma za dodjelu prioriteta prema cjelinama [3] . . . 12
7 Prikaz dijagrama toka algoritma povratka oduzetog vremena [3] 14
8 Funkcija pripadnosti za izraziti skup 17
9 Funkcija pripadnosti za neizraziti skup 17
10 Struktura neizrazitog upravljača 18
11 Definirane funkcije pripadnosti neizrazite logike za ulaze u neizraziti upravljač 21
12 Dijagram toka postupka genetskog algoritma 26
13 Kôdiranje stabla 28
14 Drvo grananja vrsti selekcija 30
15 Križanje sa jednom točkom prekida [26] 33
16 Križanje sa dvije točke prekida [26] 34
17 Primjer Gaussove funkcije 37
18 Struktura agregiranja rezultata u skladu s optimizacijskim algoritmom 39
19 Struktura COM sučelja [3] 41
20 Model raskrižja ”Ulica kralja Zvonimira - Harambašićeva ulica” [3] 42
21 Prikaz signalnog plana raskrižja ”Ulica kralja Zvonimira - Harambašićeva ulica” u VISSIM-u [3] 42
22 Prikaz smjera dolaska (zeleno) i povratka (crveno) vozila žurne službe a) Scenarij 1, 3 i 5; b) Scenarij 2, 4 i 6 [4] 43
23 Prikaz GA optimiziranih funkcija pripadnosti 52
24 Vrijeme putovanja vozila žurne službe kroz iteracije genetskog algoritma . . . 53

Popis tablica

1 Primjer stanja binarne logike 17
2 Primjer stanja neizrazite logike 18
3 Odabrana pravila neizrazite logike adaptivnog upravljanja . . 22
4 Binarno kôdiranje 27
5 Permutacijsko kôdiranje 27
6 Vrijednosno kôdiranje 27
7 Vjerojatnost odabira pojedine jedinke 31
8 Primjer mutacije gena u kromosomu 35
9 Primjer pravila mapiranih u kromosom 36
10 Prometna potražnja za svaki scenarij 44
11 Dobivene srednje vrijednosti za scenarij 1 46
12 Dobivene srednje vrijednosti za scenarij 2 46
13 Dobivene srednje vrijednosti za scenarij 3 48
14 Dobivene srednje vrijednosti za scenarij 4 48
15 Dobivene srednje vrijednosti za scenarij 5 49
16 Dobivene srednje vrijednosti za scenarij 6 50

Popis grafikona

1 Srednje vrijednosti izgubljenog vremena vozila žurne službe za sve scenarije . 50
2 Srednje vrijednosti vremena putovanja svih vozila na mreži za sve scenarije . . 51
3 Srednje vrijednosti vremena putovanja vozila žurne službe za sve scenarije . . . 51
4 Srednje vrijednosti broja zaustavljanja vozila žurne službe 51

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.

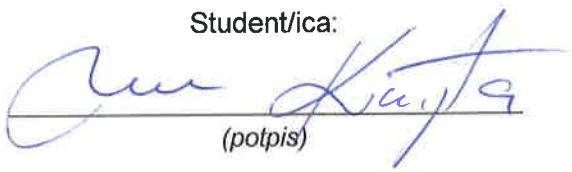
Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

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 **UPRAVLJANJE PRIORITETIMA PROLASKA VOZILA ŽURNIH SLUŽBI KROZ IZOLIRANO SEMAFORIZIRANO RASKRIŽJE PRIMJENOM NEIZRAZITE LOGIKE** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 9/11/2019

Student/ica:



(potpis)