

Primjena strojnog učenja za upravljanje raskrižjima u okruženju mješovitih prometnih tokova

Jakobović, Žana

Master's thesis / Diplomski rad

2021

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:119:997364>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-09-12**



Repository / Repozitorij:

[Faculty of Transport and Traffic Sciences -
Institutional Repository](#)



Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

**PRIMJENA STROJNOG UČENJA ZA UPRAVLJANJE RASKRIŽJIMA U OKRUŽENJU
MJEŠOVITIH PROMETNIH TOKOVA
APPLICATION OF MACHINE LEARNING FOR INTERSECTION CONTROL IN
MIXED FLOW ENVIRONMENT**

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

Studentica: Žana Jakobović

Komentor: predavač Dino Čakija, dipl.ing.

JMBAG: 0135243764

Zagreb, lipanj 2021.

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 30. lipnja 2021.

Zavod: Zavod za inteligentne transportne sustave

Predmet: Umjetna inteligencija

DIPLOMSKI ZADATAK br. 6407

Pristupnik: Žana Jakobović

Studij: Inteligentni transportni sustavi i logistika

Smjer: Inteligentni transportni sustavi

Zadatak: Primjena strojnog učenja za upravljanje raskrižjima u okruženju mješovitih prometnih tokova

Opis zadatka:

Povećanje prijevozne potražnje dovodi do svakodnevnih prometnih zagušenja, posebno u vršnim satima. U gradskoj sredini su zagušenja izražena oko semaforiziranih raskrižja. Kako bi se smanjilo vrijeme putovanja i duljine repa čekanja moguće je koristiti metode strojnog učenja za prilagodbu signalnih planova. Pri tome mješoviti prometni tokovi koji sadrže ljudski upravljana vozila i umrežena autonomna vozila predstavljaju novi nadolazeći upravljački problem. U radu je potrebno opisati značajke mješovitih prometnih tokova, upravljačke koncepte za slučaj semaforiziranih raskrižja i mješovitih tokova te analizirati mogućnosti primjene metoda strojnog učenja za upravljanje mješovitim prometnim tokovima.

Mentor:



izv. prof. dr. sc. Edouard Ivanjko

Predsjednik povjerenstva
za diplomski ispit:

Sadržaj

1. Uvod	1
2. Značajke mješovitih prometnih tokova	3
2.1. Autonomna vozila	3
2.2. Mješoviti prometni tokovi	5
3. Problem upravljanja semaforiziranim raskrižjima	11
3.1. Pristupi upravljanja semaforiziranim raskrižjima	12
3.2. Adaptivno upravljanje prometom	15
3.3. Mješoviti tokovi i semaforizirana raskrižja	18
4. Primjena umjetne inteligencije u upravljanju raskrižjima	20
4.1. Umjetna inteligencija i strojno učenje	20
4.2. Pristupi upravljanja semaforiziranim raskrižjima zasnovani na umjetnoj inteligenciji	21
4.3. Pristupi upravljanja semaforiziranim raskrižjima zasnovani na strojnom učenju	25
5. Strojno učenje u upravljanju mješovitim prometnim tokovima	27
5.1. Nadzirano učenje u upravljanju mješovitim prometnim tokovima	27
5.2. Nenadzirano učenje u upravljanju mješovitim prometnim tokovima	28
5.3. Ojačano učenje u upravljanju mješovitim prometnim tokovima	29
5.4. Utjecaj mješovitih prometnih tokova na upravljanje semaforiziranim raskrižjima	29
6. Analiza primjene strojnog učenja u upravljanju mješovitim prometnim tokovima	31
6.1. Simulacijsko okruženje SUMO-FLOW	31
6.2. Prikupljanje prometnih podataka u okolini mješovitih prometnih tokova	32
6.3. Genetski algoritam i upravljanje mješovitim prometnim tokovima	34
6.4. Ojačano učenje i upravljanje mješovitim prometnim tokovima	36
7. Zaključak	40
Literatura	41
Popis slika	44

Sažetak

Naslov: Primjena strojnog učenja za upravljanje raskrižjima u okruženju mješovitih prometnih tokova

Porast broja stanovništva uzrokovao je povećanje prijevozne potražnje što dovodi do svakodnevnih prometnih zagušenja, posebno u vršnim satima. Problem nastaje kada prijevozna potražnja postane veća od prijevozne ponude te prometnice nemaju dovoljan kapacitet za visoku razinu usluge. U gradskoj sredini zagušenja su izražena oko semaforiziranih raskrižja jer dolazi do preplitanja dvaju ili više prometnih tokova. Kako bi se smanjilo vrijeme putovanja i duljine repova čekanja moguće je koristiti metode strojnog učenja za prilagodbu signalnih planova. Pri tome mješoviti prometni tokovi koji sadrže ljudski upravljana vozila i umrežena autonomna vozila predstavljaju novi nadolazeći upravljački problem. Problemi nastaju zbog različitog percipiranja okoline i poštivanja pravila ponašanja kod vozača u ljudski upravljanim vozilima te autonomnim i umreženim autonomnim vozilima. U radu su opisane značajke mješovitih prometnih tokova, upravljački koncepti za slučaj semaforiziranih raskrižja i mješovitih tokova te analizirane mogućnosti primjene metoda strojnog učenja za upravljanje mješovitim prometnim tokovima.

Ključne riječi: mješoviti prometni tok; semaforizirana raskrižja; strojno učenje; umrežena autonomna vozila; autonomna vozila; umjetna inteligencija

Abstract

Title: Application of Machine Learning for Intersection Control in Mixed Flow Environment

The increase of the population caused the increase in transport demand which causes daily traffic congestions, especially during peak hours. The problem arises when traffic demand exceeds the traffic offer, and roads do not have enough capacity for a high level of service. In the urban environment, congestions are especially expressed around signalized intersections because two or more traffic flow intertwine. To decrease the travel time and waiting queue length, it is possible to implement machine learning methods to adapt intersection signal plans. Thereby, mixed traffic flows consisting of human-driven vehicles and connected autonomous vehicles represent an upcoming control issue. Problems arise due to different environment perceptions and respecting the rules with human-driven vehicles and autonomous and connected autonomous vehicles. In this thesis, mixed traffic flow features, traffic management concepts for signalized intersections, mixed traffic flows are described, and the possibilities of implementing machine learning methods for managing mixed traffic flows are analyzed.

Keywords: mixed traffic flow; signalized intersection; machine learning; connected autonomous vehicles; autonomous vehicles; artificial intelligence

1. Uvod

Razvitak tehnologije u današnje vrijeme igra veliku ulogu u napretku postojećeg prometnog sustava. S obzirom na ritam života današnjice sve više ljudi se oslanja na prijevoz „od vrata do vrata“ te očekuje visoku razinu usluge. To označava izravan prijevoz od točke A do točke B uz minimalne troškove poput minimalnog vremena putovanja, minimalnog čekanja te minimalne potrošnje goriva. Takvo ponašanje vozača uzrokuje velika prometna zagušenja zbog prevelikog broja vozila na prometnicama manjeg kapaciteta od traženog. Zbog nemogućnosti širenja postojećih prometnica na velikom broju lokacija, pristup poboljšanju prometne situacije sve se više oslanja na rješenja inteligentnih transportnih sustava (eng. Intelligent Transport Systems – ITS). ITS podrazumijeva nadgradnju postojećeg prometnog sustava korištenjem informacijsko-komunikacijskih tehnologija kojim se postižu poboljšanja performansi, učinkovitost transporta putnika i robe, povećanje sigurnosti u prometu te udobnost i zaštita putnika. ITS nudi rješenja poput adaptivnog upravljanja semaforiziranim raskrižjima, dijelovima dionica prometnica te privozima gradskim autocestama. U gradskom okruženju najveći problem predstavljaju raskrižja jer dolazi do ispreplitanja dvaju ili više prometnih tokova. Raskrižja s ustaljenim signalnim planovima više ne zadovoljavaju potrebe korisnika te se stoga nastoji adaptivno upravljati semaforiziranim raskrižjima. U tom slučaju umjetna inteligencija nudi rješenja primjenom osjetila i algoritama kako bi se znatno poboljšalo prometovanje kroz semaforizirana raskrižja.

Umjetna inteligencija i ITS jednu ključnu točku svog razvoja dosežu razvitkom potpuno autonomnih i umreženih autonomnih vozila. Njihova implementacija u prometni tok značila bi potencijalno još veća poboljšanja prometnih parametara poput brzine, protoka i gustoće. Za sada još nije moguća njihova implementacija i potpuna zamjena ljudski upravljanih vozila, ali se uvelike radi na istraživanju i simuliranju mješovitih tokova. Mješoviti prometni tok podrazumijeva takav prometni tok u kojem sudjeluju ljudski upravljana vozila i autonomna te umrežena autonomna vozila. Smatra se da će se povećanjem udjela umreženih autonomnih vozila i autonomnih vozila u prometni tok znatno poboljšati prometne performanse te smanjiti prometna zagušenja i vrijeme putovanja. Problem mješovitih prometnih tokova je u tome što ljudski upravljana vozila i autonomna vozila imaju različite principe ponašanja i percipiranja okoline. Iz tog razloga je potrebno precizno odrediti modele ponašanja kod jednih i kod drugih

kako bi se mogli pravilno simulirati scenariji implementacije te razviti algoritmi upravljanja prometnim tokom.

Ovaj rad sadrži sedam poglavlja kroz kojih će se opisati primjena strojnog učenja u upravljanju raskrižjima u okruženju mješovitih prometnih tokova. Prvo poglavlje daje uvod u temu te opisuje potrebu i važnosti umjetne inteligencije u razvoju tehnologije prometa. U drugom poglavlju opisane su značajke mješovitih prometnih tokova. Pojašnjen je pojam i opisane značajke autonomnih vozila, umreženih autonomnih vozila te umreženih vozila. Opisan je mješoviti prometni tok te utjecaj navedenih vrsta vozila na osnovni dijagram prometnog toka. Treće poglavlje uvodi u problematiku upravljanja semaforiziranim raskrižjima. U trećem poglavlju su obrađeni osnovni pojmovi prometnog inženjerstva, cestovne telematike i upravljanja semaforiziranim raskrižjima. Nadalje, objašnjeni su načini adaptivnog upravljanja prometnim tokovima te način funkcioniranja semaforiziranog raskrižja u uvjetima mješovitog prometnog toka. U četvrtom poglavlju opisana je umjetna inteligencija i područje strojnog učenja. Navedeni su i opisani pristupi upravljanja semaforiziranim raskrižjima zasnovani na umjetnoj inteligenciji te oni zasnovani na strojnom učenju. Peto poglavlje daje pregled metoda strojnog učenja u upravljanju mješovitim prometnim tokovima. Objašnjeni su algoritmi nadziranog, nenadziranog i ojačanog učenja i utjecaj korištenja istih u uvjetima mješovitog prometnog toka. U šestom poglavlju objašnjene su i navedene razlike između upravljanja mješovitim prometnim tokovima strojnim učenjem i genetskim algoritmom. Rad završava zaključkom i prijedlozima za nastavak istraživanja.

2. Značajke mješovitih prometnih tokova

Mješoviti prometni tokovi označavaju vrstu prometnih tokova u kojima sudjeluju vozila upravljana ljudima te autonomna vozila. U takvim prometnim tokovima pojavljuju se također pješaci i biciklisti koji uzrokuju dinamične promjene u prometnom sustavu. Jedan od vodećih problema je početak korištenja autonomnih vozila u sustavu s pretežno ljudski upravljanim vozilima jer autonomna vozila moraju biti sposobna upravljati i komunicirati s drugim vozilima, sudionicima u prometu te prometnom infrastrukturom [1].

Obzirom da s vremenom sve više raste broj vozila na prometnicama i stvaraju se sve veća prometna zagušenja naglasak je na važnosti i korisnosti primjene informacijsko-komunikacijskih tehnologija u upravljanju prometom. Inteligentni transportni sustavi primjenom informacijsko-komunikacijskih tehnologija nadograđuju postojeći prometni sustav pametnim načinom upravljanja prometom poput implementiranja algoritama za upravljanje prometom i automatizacije pojedinih dijelova prometne infrastrukture [2]. Uvođenjem pojma autonomnih vozila govori se o smanjenju prometnih zagušenja, optimiziranju prometnog toka te povećanju sigurnosti sudionika u prometu. Također dolazi se do pojma pametnog grada koji bi konceptu autonomnih vozila omogućio komunikaciju s infrastrukturom i okolinom te tako pridonio upravljanju, kooperaciji i regulaciji prometnog toka koji je sačinjen od autonomnih vozila. Pravi samovozeći automobil potpuno samostalno rješava sve probleme vožnje bez potrebe za ljudskom pomoći i oslanja se na prikupljene podatke pomoću svojih osjetila sustav upravljanja uz pripadne algoritme obrade mjernih podataka te upravljanja vožnjom koji su u njega ugrađeni. Takav sustav u automobilu je potpuno samostalan, ne oslanja se na druge sustave i njihove informacije te kao takav pruža efikasnost i sigurnost za korisnike i druge sudionike u prometu [3].

2.1. Autonomna vozila

Autonomna vozila predstavljaju koncept vozila kojima nije potreban ljudski vozač. Iako takva tehnologija nije još dosegla svoj vrhunac, za sada se koriste razna osjetila i algoritmi koji pomažu vozaču tijekom vožnje. Tehnologija koja se trenutno koristi u vozilima nepotpune autonomnosti su telematički sustavi koji kontroliraju rad motora i uređaja u vozilu te na taj način predstavljaju pomoć vozaču tijekom vožnje. Ciljevi telematike u vozilima su povećanje

sigurnosti u prometu, optimizacija prometnog toka te zaštita okoliša. Područja na kojim se primjenjuju su udobnost, sigurnost, produktivnost i pomoć u vožnji. Telematički sustavi dijele se u četiri osnovne skupine, a to su sustavi povećanja udobnosti (eng. Convenience systems), sustavi povećanja sigurnosti (eng. Safety systems), sustavi poboljšanja produktivnosti (eng. Productivity systems) te sustavi za pomoć u vožnji (eng. Traffic assist systems). Sustavi povećanja udobnosti pružaju pomoć prilikom parkiranja pomoću video kamera, parkirnih osjetila te pomoć pri bočnom parkiranju. Isto tako, sadrži sustav za prilagođavanje brzine vožnje (eng. Adaptive cruise control) i omogućuje prilagođavanje brzine vozila sporijem vozilu ispred sebe održavajući zadani razmak. Koristan je u vožnji u koloni ili kod zagušenog prometnog toka sa svrhom praćenja vozila ispred sebe. Također, sadrži sustav za pomoć vozaču u zadržavanju prometnog traka (eng. Lane keeping assistance) na način da se video kamerom prati bijela linija na prometnici te se upozorava vozača ako prijeđe na suprotni prometni trak. Sustavi povećanja sigurnosti obuhvaćaju sustave za bolju percepciju kao što su prilagodljiva svjetla koja optimiziraju vidljivost ispred i sa strane putanje vozila na temelju brzine vozila, noćna vidljivost odnosno infracrvena kamera, uređaji koji obavještavaju vozače svjetlećim znakovima uz cestu i preporuka održavanja razmaka odnosno intervala slijeđenja. Također sadrže uređaje za prevenciju prometnih nezgoda te uređaju za pomoć u vožnji u stvarnim uvjetima, uređaje za ublažavanje posljedica prometnih nezgoda i sustav određivanja brzine vozila u skladu sa zakonskim ograničenjima [4].

Prema Društvu automobilskih inženjera (eng. Society of automotive engineers - SAE) postoji 6 razina automatizacije vozila [5]:

- Razina 0 predstavlja vozila bez ikakve automatizacije, odnosno vozač sve procese obavlja sam;
- Razina 1 nudi pomoć vozaču u vožnji, ali vozač i dalje sve radi sam;
- Razina 2 predstavlja parcijalnu automatizaciju gdje napredni sustav pomoći vozaču (eng. Advanced Driver Assistant System - ADAS) može upravljati volanom (promjena smjera automobila) i ubrzanjem te kočenjem unutar nekih okolnosti iako vozač i dalje mora biti potpuno prisutan u upravljanju vozilom;
- Razina 3 – uvjetna automatizacija - sustav automatizirane vožnje (eng. Automated Driving System – ADS) može obaviti sve aspekte vožnje unutar

nekim okolnosti. U takvim situacijama ljudski vozač mora biti spreman preuzeti kontrolu nad vozilom u slučaju da ga ADS tako obavijesti;

- Razina 4, koja je obilježena kao visoka automatizacija, označava razinu gdje ADS može obaviti sve funkcije vožnje te pratiti okruženje vozila. U takvim okolnostima vozač ne mora brinuti o preuzimanju kontrole nad vozilom;
- Razina 5 predstavlja potpuno automatizirano odnosno autonomno vozilo pri čemu ADS upravlja vozilom od početne do završne lokacije bez ikakve intervencije putnika odnosno ljudskog vozača.

Autonomna vozila pružaju veću sigurnost od onih koja su ljudski upravljana upravo zbog činjenice da je 94% nesreća uzrokovano ljudskom pogreškom. Ono što je za kvalitetan prometni sustav bitno je da autonomna vozila mogu smanjiti prometna zagušenja i poboljšati prometni tok. Manje prometnih zagušenja znači i kraće vrijeme putovanja, smanjenu potrošnju goriva te smanjenu emisiju štetnih plinova. Također, mogu biti od velike pomoći osobama s invaliditetom osiguravajući im veću samostalnost i mobilnost [5].

2.2. Mješoviti prometni tokovi

Mješoviti prometni tokovi označavaju prometne tokove u kojima sudjeluju vozila upravljana ljudskim vozačima i autonomna vozila, odnosno vozila bez ljudskih vozača. U takvim situacijama dolazi do komunikacije između vozača i računala odnosno autonomnog vozila. Autonomna vozila koriste razna osjetila kako bi snimali svoju okolinu i odlučivali o svojim postupcima. Potrebna im je odgovarajuća infrastruktura s kojom mogu komunicirati kako bi mogli poštovati prometne znakove, prometnu signalizaciju i ostale sudionike. Obzirom da će u bliskoj budućnosti postojati velik broj takvih situacija potrebno je temeljito analizirati ponašanje vozača u automobilima kako bi se izradili modeli po kojima će autonomna vozila odlučivati u određenim trenucima. Kod vozača automobila postoji velik broj nasumično odrađenih poteza koji bi mogli uzrokovati zakašnjele reakcije autonomnih vozila te uzrokovati prometne nesreće. Miješanjem takvih vozila predstavlja vrlo složen problem u pogledu sigurnosti sudionika u prometu te je potrebno takvim prometnim tokom pažljivo upravljati [6].


Europski parlament [7] je jedna od institucija koja donosi odluke o implementaciji autonomnih vozila u postojeći prometni tok. Budući da je za implementaciju takvih vozila potrebna drugačija infrastruktura, nalaže se da bi se tehnički standardi za vozila i za

infrastrukturu trebali razvijati na međunarodnoj, europskoj i nacionalnoj razini. Na taj način bi se stvorila univerzalna prometna infrastruktura koja omogućuje povećanje cestovne sigurnosti te osigurava neometanu prekograničnu interoperabilnost. S obzirom da takva vozila prikupljaju i odašilju mnogobrojne podatke, stavlja se u pitanje privatnost i sigurnost korisnika. Stoga se naglašava da je apsolutni prioritet takve podatke posebno zaštititi, a one neosobne koristiti u svrhu daljnjeg razvitka za veću mobilnost. Također, povećanjem broja takvih vozila na prometnicama zahtijeva donošenje zakonske regulative kojima će se kontrolirati siguran rad i odlučivati o odgovornosti korisnika i vozila. Važno je razjasniti tko snosi odgovornost za štete u slučaju prometnih nezgoda koje prouzroče autonomna vozila te ispitati koliko je udio nesreća dosad bio pripisan tehničkim čimbenicima [7].

Za bolje razumijevanje teme u nastavku su objašnjeni pojmovi i razlike umreženih, autonomnih i umreženih autonomnih vozila. S obzirom da su autonomna vozila već objašnjena, u nastavku će se navesti i objasniti karakteristike samo umreženih i umreženih autonomnih vozila.

Umrežena vozila se smatraju vozilima koja sadrže tehnologije, aplikacije i usluge koje povezuju vozilo s njegovom okolinom. Sadržava različite komunikacijske uređaje, ugrađene ili prijenosne, koji omogućuju povezivanje uređaja u vozilu s uređajima, mrežama, aplikacijama i uslugama izvan vozila. Aplikacije uključuju sve sustave poput sustava za sigurnost i efikasnost u prometu, informiranje putnika, pomoć pri parkiranju, pomoć na cesti, navigacija, itd. Vozila koja sadržavaju ADAS, odnosno sustav pomoći vozaču, i kooperativne inteligentne transportne sustave mogu se nazivati umreženim vozilima. Aplikacije u umreženim vozilima su dizajnirane kako bi povećale sigurnost u prometu te ublažile incidente u prometu kroz komunikaciju vozilo-vozilo (eng. vehicle to vehicle – V2V) i vozilo-infrastruktura (eng. vehicle to infrastructure – V2I). ADAS tehnologija se zasniva na sustavima kamera, osjetila, podatkovne mreže vozila te V2V i V2I sustavima. Značajke mogu uključivati prilagodljivi tempomat, automatsko kočenje, GPS i prometna upozorenja, mogućnost spajanja s pametnim telefonom, upozoravanje vozača na opasnosti i obavještavati na prisustvo drugih vozila u mrtvom kutu. V2V komunikacija može smanjiti incidentne situacije u prometu i smanjiti prometna zagušenja razmjenjujući osnovne sigurnosne informacije poput položaja, brzine i smjera kretanja s vozilima u blizini. Na taj način se može zamijeniti sigurnosne značajke kao što su upozorenje na sudar i detekcija vozila u mrtvom kutu [8].

Umrežena autonomna vozila (eng. Connected Autonomous Vehicles – CAVs) su vozila koja imaju sposobnost dijeliti svoje informacije, poput položaja, brzine i ubrzanja s drugim autonomnim vozilima u određenoj udaljenosti preko komunikacije V2V ili V2I. Prometni tok koji se sastoji od vozila upravljanih čovjekom i autonomnih ili povezanih automobila naziva se mješoviti tok i prikazan je na slici 1. Zbog činjenice da autonomna vozila nisu razvijena do kraja te se ne mogu potpuno samostalno testirati u stvarnim uvjetima, mnogi istraživači su se fokusirali na upravljanje razmakom odnosno intervalom slijeđenja između vozila. U tu svrhu izrađeni su mnogi modeli praćenja automobila. Da bi se opisao prometni tok u kojem se, među vozilima upravljanim čovjekom, pojavljuju i autonomna vozila korišteni su modeli poput modela inteligentne vožnje (eng. Intelligent Driving Model, IDM), sustav za prilagođavanje brzine (eng. Adaptive Cruise Control, ACC) i modela kooperativnog upravljanja slijeđenja vozila (eng. Cooperative Adaptive Cruise Control, CACC). Također, provedene su studije utjecaja autonomnih vozila na postojeći prometni tok. Rezultati su pokazali povećanje propusnosti na autocestama, smanjeno ponašanje vozila što se tiče „stani-kreni“ vožnje te povećanje sigurnosti i energetske učinkovitosti. Neki istraživači smatraju da će implementacija autonomnih vozila u prometni tok umanjiti prometna zagušenja i vrijeme putovanja, dok drugi smatraju da će neautonomna vozila imati negativan učinak na mješoviti prometni tok i kapacitet prometnica. Tek kada broj autonomnih vozila u prometnom toku poraste, može se očekivati poboljšanje performansi prometnog toka [9].




Slika 1: Prikaz mješovitog toka na prometnici, [9]

Osnovni dijagram prometa prikazuje krivulju „tok-gustoća“. Tom krivuljom može se kontrolirati i upravljati prometom na cestama kao što je npr. mjerenje intervala praćenja. Osnovni uvjeti na kojima se zasniva osnovni dijagram prometa su [10]:

- Ako nema gustoće nema ni protoka. To znači da krivulja „tok-gustoća“ prolazi kroz koordinatni početak. Nagib s kojim krivulja napušta koordinatni početak predstavlja brzinu slobodnog toka što je ujedno i najveći nagib krivulje „tok-gustoća“.
- Ako je gustoća velika, a protoka nema (zbog zaustavljenih vozila na prometnici) onda se radi o točki maksimalne gustoće i protoku jednakom nuli.
- Između točaka ekstremnih gustoća ($g = 0$ i $g = g_{\max}$) mora postojati jedna ili više točaka maksimalnog protoka.
- Krivulja „tok-gustoća“ u stvarnim prometnim uvjetima ne mora biti kontinuirana u cijelom području između ekstremnih gustoća.

Na slici 2 je prikazan osnovni dijagram odnosa protoka i gustoće,



Slika 2: Fundamentalni dijagram protoka i gustoće, [10]

gdje je:

q – protok [voz/h],

ρ – gustoća [voz/km],

g_{zt} – gustoća zasićenog toka [voz/km],


V_s – brzina slobodnog toka [km/h],

V_w – brzina vala [km/h],

t_h – vremenski interval slijeđenja [s] [10].

Uvođenjem autonomnih vozila u postojeći prometni tok očekuje se da će se povećati kapacitet prometnica, smanjiti vrijeme putovanja te smanjiti potrošnja goriva i emisije štetnih plinova. Budući da će u početku postojati vrlo mali postotak autonomnih vozila u odnosu na ljudski upravljana vozila, potrebno je vidjeti kako će to utjecati na prometni tok. Provedena su mnoga istraživanja i simulacije koje su dovele do određenih zaključaka. Istraživanje [11] se provelo korištenjem modela staničnih automata (eng. Cellular Automata) kojim je moguće modelirati složenost i pojave u prometu te ih simulirati pomoću kratkih uvjeta i pravila. U [11] fokus je na promjeni prometnog traka jer se nepravilno mijenjanje prometnog traka smatra jednim od najvećih uzroka prometnog zagušenja i incidentnih situacija. Za model su određena dva pravila: normalno mijenjanje prometne trake i agresivno mijenjanje prometne trake.

Na slici 3 su prikazani utjecaji autonomnih vozila na osnovni dijagram prometnog toka. Isprekidanom linijom označeno je agresivno mijenjanje, punom linijom normalno mijenjanje prometne trake, a ispod slike 2 su označene količine autonomnih vozila u postocima u odnosu na ljudski upravljanim vozilima preko parametara brzine, gustoće i protoka. Na grafu 3(a) krivulja brzina-gustoća se pomiče u desno što znači da se, s povećanjem udjela autonomnih vozila u prometnom toku, povećava srednja brzina za istu gustoću. Na grafu 3(b) prikazana je krivulja protok-gustoća gdje se vidi da što je veći udio autonomnih vozila u prometnom toku, to je veći kapacitet i protok vozila [11].



Slika 3: Prikaz osnovnih dijagrama prometnog toka s različitim udjelima autonomnih vozila u prometnom toku, [11]

3. Problem upravljanja semaforiziranim raskrižjima

U određenoj zoni obuhvata često se nailazi na dva ili više prometna toka. Oni se razlikuju po smjeru kretanja, po intenzitetu, po sastavu i po vremenu u kojem se generiraju. Jedan od uzroka smanjene propusne moći su odnosi između prometnih tokova na raskrižjima. Kako bi se povećala propusna moć raskrižja potrebno je smanjiti i izbjegavati nepotrebno presijecanje i lomljenje prometnih tokova. Eliminacijom neautonomnih vozila iz prometnog toka mogla bi se potpuno ukloniti semaforizirana raskrižja jer samovozeća vozila imaju sposobnost komuniciranja s okolinom te s drugim vozilima oko sebe. Trenutno postoje promjenjivi prometni znakovi koji omogućavaju interakciju između korisnika prometnice te nadležnih centara za upravljanje cestovnom infrastrukturom. Promjenjivi prometni znakovi su povezani s uređajima za prikupljanje ulaznih podataka, kao što su podaci o gustoći prometa te meteorološki podaci, na temelju kojih se upravlja promjenjivim znakovima [10]. Na takav princip rade i autonomna vozila osim što interakciju s infrastrukturom ne odrađuje vozač već upravljačko računalo.

Osnovna zadaća prometnog inženjerstva je identificirati te analizirati prometni sustav te riješiti probleme na učinkovit, siguran, ekonomičan i udoban način kako bi se postigao prihvatljiv prijevoz ljudi, robe i informacija. Pri tome je potrebno koristiti odgovarajuća tehnička sredstva, prometnice i sustave upravljanja prometom. Prometni problemi rješavaju se na način da se precizno definira prometna potražnja, ulazni tokovi, određivanje kapaciteta, izbor odgovarajućeg moda prijevoza, vođenje kroz mrežu, itd. Temeljna povezanost prometa, transporta i sustava aktivnosti može se objasniti kroz interakciju mrežne infrastrukture, prometnih entiteta i transportnih entiteta [12]. Kako bi se objasnilo upravljanje semaforiziranim raskrižjima potrebno je detaljnije pojasniti pojmove navedene u nastavku.

Promet je sustav i proces koji za svrhu ima obavljanje prijevoza transportnih entiteta u odgovarajućim prometnim entitetima zauzimanja dijela kapaciteta prometne mreže prema pravilima i protokolima koji su unaprijed određeni [13].

Prometna infrastruktura obuhvaća sve prometne putove, čvorišta, objekte i opremu koja je učvršćena na određenom mjestu i služi za upravljanje prometa, odnosno pružanju prometne usluge [12].

Transportni entiteti podrazumijevaju ljude, robu i informacije, a prilagođavaju se prema određenom prometnom modu, prometnici i prometnom entitetu. Prometni entiteti obuhvaćaju sva vozila svih prometnih grana, poput osobnog automobila, zrakoplova, broda, vlaka, itd. Svaki prometni entitet koristi dio kapaciteta prometnice pripadnog moda transporta i tako stvara prometni tok [12].

Ono što predstavlja prekretnicu u upravljanju prometnim tokovima su inteligentni transportni sustavi. Inteligentni transportni sustavi su definirani kao holistička, upravljačka i kibernetička nadgradnja postojećeg prometnog sustava kojom se postiže znatno poboljšanje performansi, odvijanje prometa, učinkovitiji transport putnika i robe, povećanje sigurnosti u prometu, udobnost i zaštita putnika, manja onečišćenja okoliša, itd. Oni mijenjaju načine funkcioniranja i strukturiranja prometnog sustava. Takvi sustavi imaju sposobnost adaptivnog djelovanja u promjenjivim uvjetima i situacijama te mogu djelovati u stvarnom vremenu [2].


3.1. Pristupi upravljanja semaforiziranim raskrižjima

Za bolje razumijevanje teme ovog rada u nastavku će biti objašnjeni pojmovi vezani uz cestovnu telematiku koji se odnose na semaforizirana raskrižja poput signalnog ciklusa, signalne faze, signalnog pojma te signalnog plana. Također objasniti će se zaštitno međuvrijeme koje igra veliku ulogu u izbjegavanju konflikata u raskrižjima.

Semaforizirana raskrižja su križanja dva ili više prometnih tokova u istoj razini na kojima se prolaženje vozila upravlja vertikalnom svjetlosnom signalizacijom. Signalni ciklus predstavlja vremenski period potreban da se obave sve izmjene definiranih signalnih faza. Minimalna duljina ciklusa jednaka je zbroju zaštitnih vremena i minimalnih zelenih vremena. Maksimalna preporučena duljina ciklusa ne bi trebala biti veća od 120 [s], osim u slučajevima kada za to postoje posebni razlozi. Duljina ciklusa se određuje u ovisnosti o broju faza. Signalna faza je dio ciklusa u kojem pojedini prometni tokovi imaju istovremeno slobodan prolaz kroz raskrižje. Može biti sastavljena od jedne ili više signalnih grupa. Pravilnim definiranjem signalnih faza moguće je smanjiti konflikte između određenih prometnih tokova.


Signalni pojam obuhvaća sva stanja koja svjetlosni signalni uređaj može prikazati. Članak 59. Zakona o sigurnosti prometa na cestama [14] definira značenja prometnih svjetlosnih signala na slijedeći način: crveno svjetlo zabranjuje prolazak raskrižjem, zeleno svjetlo ga dopušta, dok samostalno upaljeno žuto svjetlo signalizira skorašnje uključivanje

crvenog svjetla, sugerirajući na smanjenje brzine i zaustavljanje vozila prije ulaska u raskrižje. Prolazak vozila je dopušten samo ako se vozilo ne može na siguran način zaustaviti. Žuto svjetlo uključeno zajedno sa crvenim svjetlom označava skoro pojavu zelenog svjetla te vozače priprema na uskoro pokretanje vozila. Žuto treptavo svjetlo obavještava sudionike u prometu da se kreću uz povećani oprez, a zeleno treptavo svjetlo služi za upozorenje sudionika u prometu na skori prestanak slobodnog prolaska i na pojavu žutog, odnosno crvenog svjetla [13]. Signalni plan je vizualni pregled trajanja svjetlosnih signalnih pojmova. Na slici 4 prikazan je primjer signalnog plana na kojem su prikazane duljine trajanja pojedinih faza za pojedine signalne grupe. Ukupno trajanje signalnog ciklusa je 60 [s], a definirane signalne grupe uključuju vozila i pješake.



Slika 4: Primjer signalnog plana, [13]

Zaštitno međuvrijeme predstavlja vrijeme između dvije konfliktne signalne grupe koje slijede uzastopno, smanjujući mogućnost za konfliktom. Ovisi o tri komponente, koje su prikazane na slici 5, a to su prozorno vrijeme (t_k), vrijeme pražnjenja (t_p) te vrijeme naleta (t_n). Prozorno vrijeme obuhvaća vrijeme od trenutka kraja zelenog svjetla do ulaska vozila u raskrižje za vrijeme trajanje žutog svjetla ili na početku crvenog svjetla. Vrijeme pražnjenja je vrijeme koje je potrebno da vozilo prođe točku kolizije brzinom pražnjenja (v_p). Vrijeme naleta je vrijeme koje je potrebno da vozilo kojem se upali zeleno svjetlo prođe put naleta (s_n), brzinom naleta (v_n) [13].



Slika 5: Komponente zaštitnog međuvremena, [13]

Zaštitno međuvrijeme računa se prema slijedećoj formuli [13]:

$$t_z = t_k + t_p - t_n = t_k + \frac{s_p + l_v}{v_p} - \frac{s_n}{v_n}, \quad (13)$$

gdje je:

t_z – zaštitno međuvrijeme [s],

t_k – provezno vrijeme [s],

t_p – vrijeme pražnjenja [s],

t_n – vrijeme naleta [s],

s_p – put pražnjenja [m],

l_v – duljina vozila [m],

v_p – brzina pražnjenja [m/s],


s_n – put naleta [m],

v_n – brzina naleta [m/s].

3.2. Adaptivno upravljanje prometom

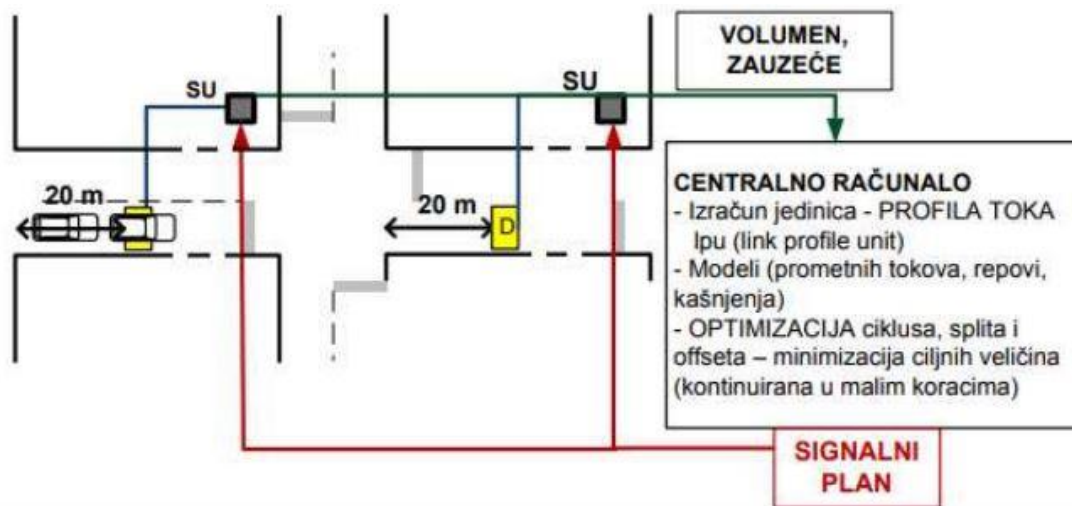
Neka od najučinkovitijih ITS rješenja poboljšanja kvalitete prometnog sustava koriste adaptivne sustave za upravljanje prometom (eng. ATCS – Adaptive Traffic Control Systems). Takvi sustavi namijenjeni su kako bi u stvarnom vremenu prilagođavali signalne planove na osnovu trenutne prometne potražnje. ATCS algoritmi većinom upravljaju trajanjem podjele (eng. split) faza, kasnijeg/ranijeg početka faze (eng. offset), redoslijeda faze i izmjene faza. Postoji nekoliko rješenja korištena u tu svrhu, a razlikuju se u vremenu odziva, algoritmima i detekciji [13].

Prvi takav sustav koji u stvarnom vremenu prilagođava signalne planove na osnovu prometne potražnje i kapaciteta prometnice je SCATS (eng. Sydney Coordinated Adaptive Traffic System), razvijen u Australiji početkom 1980-ih. Sustav je u mogućnosti upravljati grupom raskrižja (2-10 njih) te ih tretira kao podsustav s jednim glavnim raskrižjem. Upravlja raskrižjem na dvije razine, strateškoj i taktičkoj. Strateška razina odnosno viša razina na temelju prikupljenih podataka iz prometnog sustava računa optimalne parametre signalnog plana. Niža razina, tj. taktička razina omogućuje fino podešavanje parametara unutar granica koje su određene strateškom razinom. SCATS radi na način da se slijed faza određuje prema potražnji svakog privoza te ukoliko nema potražnje pojedine faze se mogu i preskočiti. Kasniji ili raniji početci faze se prethodno definiraju za svako raskrižje unutar upravljane grupe, a vrijednosti im se biraju prema trenutnim podacima s detektora u svrhu održavanja protoka grupe vozila određenim potezom. Također, izmjene trajanja ciklusa su do 21 [s] po ciklusu uz određivanje minimalnih i maksimalnih vrijednosti unutar grupe raskrižja. Sustav radi pomoću dvije vrste osjetila. Prva su taktička osjetila koji su smješteni na stop liniji radi određivanja smjera kretanja vozila, a drugi su strateški koji uočavaju rep čekanja i izračunavaju trajanje minimalnog zelenog svjetla. Na slici 6 je prikazana poopćena arhitektura SCATS sustava na kojoj se vide detekcijske zone za strategijsku i taktičku razinu te parametri koji se mjere pomoću pojedinih osjetila [13].



Slika 6: Prikaz poopćene arhitekture SCATS sustava, [13]

SCOOT (eng. Split Cycle Offset Optimization Technique) je sustav adaptivnog upravljanja raskrižjima, razvijen u Ujedinjenom Kraljevstvu početkom 1980-ih. Njime se optimizacija postiže malim i čestim izmjenama signalnih planova kako bi se izbjegli „šok“ valovi u prometnom toku. Bit ovog sustava je u tome da prilagodi signalni plan na način da svede smetnje u prometu na minimum. U svakoj sekundi detektori šalju podatke o zauzeću glavnom računalu koji nakon toga pomoću tri glavne optimizacijske procedure nastoji postići idealnu situaciju. U tri glavne optimizacijske procedure pripadaju optimizator podjele faza koji se uključuje prilikom svake izmjene faza te ispituje treba li trajanje faze povećati, smanjiti ili ostaviti onako kako je. Druga optimizacijska procedura je optimizator kasnijeg ili ranijeg početka faze koji se uključuje jednom u ciklusu za svako raskrižje te na temelju podataka sa detektora smanjuje ili povećava offset za 4 [s]. Treća procedura je optimizator trajanja ciklusa koji se uključuje jednom u 5 [min], određuje kritično raskrižje te prema njemu vrši prilagodbu trajanja ciklusa. Na slici 7 je prikazana poopćena arhitektura SCOOT sustava te se mogu vidjeti koji parametri se prikupljaju i šalju glavnom računalu na obradu [13].



Silka 7: Prikaz poopćene arhitekture SCOOT sustava, [13]

UTOPIA (eng. Urban Traffic Control System Architecture) je sustav stvarnovremenske optimizacije signalnih planova sa ciljem minimizacije svih sociološko-ekonomskih troškova prometnog sustava kao što su prometna zagušenja, emisije štetnih plinova, vremena putovanja, itd. Radi na principu mjerenja prometnih podataka na raskrižjima, prognoziranja prometne potražnje na mikro i makro razini te prognozi dolaska vozila javnog gradskog prijevoza. Implementiran je u nekim dijelovima Europe kao što su Švedska, Norveška, Danska, Nizozemska, Belgija, Poljska, itd. Glavna funkcija UTOPIA sustava je stvarnovremenski nadzor i upravljanje semaforiziranim raskrižjima u cilju poboljšanja kvalitete gradske prometne mreže. Neke od sekundarnih funkcija su nadzor i dijagnosticiranje kvara svih komponenata sustava poput induktivnih petlji i lokalnih semaforских uređaja te integracija s drugim ITS rješenjima poput dodjele prioriteta vozilima javnog gradskog prijevoza i prioritetni prolazak žurnih službi. Sustav UTOPIA ima značajke hijerarhijskog, adaptivnog, distribuiranog i otvorenog sustava. Kaže se da je hijerarhijski sustav jer središnji dio sustava koordinira rad druge razine sustava koja uključuje kontrolu u grupe semaforiziranih raskrižja. Pruža kriterije optimizacije za definiranu grupu raskrižja, svako pojedino raskrižje predstavlja treću razinu sustava, a optimizacija se provodi lokalno u skladu s najvišom, odnosno središnjom razinom. Nadalje, značajke adaptivnog sustava očituju se kroz kontrolne strategije koje se primjenjuju na mrežu i rezultat su optimizacijskih problema s ciljem minimiziranja ukupnog vremena putovanja kroz mrežu. Optimizacija se zasniva na kontinuiranom nadgledanju prometnog toka mreže koji se mjeri svake sekunde dok se status semaforiziranog raskrižja osvježava svake 3 sekunde. Za sustav UTOPIA smatra se da je distribuiran jer se optimizacija cijele prometne

mreže razlaže na koordinirane probleme svakog semaforiziranog raskrižja u međusobnoj suradnji. Otvorenost sustava daje mogućnost razmjene prometnih podataka s drugim sustavima s ciljem koordiniranog upravljanja prometnom mrežom. Također se može integrirati s drugim rješenjima poput informiranja putnika i vozača, automatskog lociranja vozila javnog gradskog prijevoza, itd. [13].

3.3. Mješoviti tokovi i semaforizirana raskrižja

Postojeći sustavi za upravljanje semaforiziranim raskrižjima koji su osmišljeni za upravljanje klasičnim vozilima ne daju dovoljno dobre rezultate kada se pojave mješoviti prometni tokovi. Razlog tomu je što autonomna vozila reagiraju na promjene u prometnom toku puno brže i točnije od vozila upravljanja ljudima. Promjene parametara prometnog toka su drugačije što rezultira potrebom za promjenom metoda korištenim pri planiranju signalnog ciklusa. Razvijen je protokol pod nazivom autonomno upravljanje raskrižjem (eng. Autonomous Intersection Management - AIM) kroz koji bi nadolazeća vozila unaprijed javila da stižu te bi im raskrižje omogućilo prolazak, ako je to u tom trenutku moguće [15]. AIM protokol trebao bi zadovoljiti sedam kriterija: potpuno distribuirana i autonomna kontrola od strane vozila, jednostavna komunikacija, jeftina osjetila u vozilima, standardizirani protokol komunikacije, raspoloživost, sigurnost i učinkovitost. Prilikom razvijanja AIM sustava potrebno je izbalansirati pet parova konfliktnih kriterija za evaluaciju. Prvi par takvih kriterija je robusnost i učinkovitost. Robusni AIM sustavi su dizajnirani sa sigurnosnim granicama koje osiguravaju da ne dođe do sudara između vozila u raskrižju. S druge strane, učinkovitost je bolja kada su sigurnosne granice niže, ali vozila ne reagiraju dovoljno dobro na nepredvidive situacije. Drugi par konfliktnih kriterija je savjetodavno i reaktivno planiranje. Kod planiranja trajektorija za pojedino vozilo neke strategije koriste buduća stanja sustava, a druga prošla i sadašnja stanja. Treći par je sastavljen od centraliziranog i distribuiranog AIM sustava. Centralizirani sustav navodi vozila kroz vožnju raskrižjem. To je učinkovit način informiranja, ali nije praktičan jer je proces donošenja odluka udaljen od vozila. U distribuiranom AIM sustavu komunikacija između sudionika i proces donošenja odluka se radi unutar vozila i mora biti vrlo pouzdana kako bi se osigurala konzistentna komunikacija. Četvrti par se uglavnom odnosi na višeagentne sustave u kojima vozila i upravitelj raskrižjem imaju različite ciljeve. Radi se od kooperativnom i egoističnom kriteriju. Dok upravitelj raskrižjem želi da vozila prođu najučinkovitije i najsigurnije kroz raskrižje, vozila žele proći što brže kako bi osigurali udobnost

i manju potrošnju goriva. Zadnji par kriterija odnosi se na homogena i heterogena vozila. U teoriji su sva vozila homogena i imaju ista svojstva dok su u stvarnosti većina vozila različita, razlikujući se po veličini, težini, razini prioriteta te je li vozilo upravljano čovjekom ili je autonomno što ih čini heterogenima.

Semaforizirana raskrižja su ograničenog kapaciteta zbog svjetlosnih signala te znakova obaveznog zaustavljanja. Radi toga su predložene i razvijene metode za učinkovitije upravljanje raskrižjima poput višeagentnog upravljanja raskrižjem (eng. Multi-agent intersection control), upravljanje zasnovano na skupinama slijeđenih vozila (eng. Platoon based control) i druge. One se zasnivaju na komunikaciji vozila s vozilima te vozila s infrastrukturom gdje se autonomna vozila trebaju najaviti za pravo sigurnog prolaska kroz raskrižje bez zaustavljanja [1].

4. Primjena umjetne inteligencije u upravljanju raskrižjima

U prometnom sustavu i pripadajućim prometnim problemima često nisu dostupne sve potrebne informacije za provođenje klasične optimizacije ili upravljanja. S obzirom na to, koriste se metode „mekog“ izračunavanja koje su pogodne za takve uvjete. Mogu se koristiti u uvjetima djelomičnih i nepotpunih informacija, nepreciznosti i nesigurnosti. Takvi koncepti su prilagodljivi i otklanjaju ograničenja predstavljena „tvrdim“ izračunavanjem. Takve metode i koncepti ubrajaju korištenje neizrazite logike, neuronskih mreža te genetskog algoritma. Prometni sustav je vrlo složen sustav koji se može objasniti jednostavnim veličinama i modelima, ali takvi modeli nisu dovoljni u incidentnim i nepredvidljivim situacijama [2]. Posebno u slučaju mreža međusobno povezanih semaforiziranih raskrižja.

4.1. Umjetna inteligencija i strojno učenje

Još od doba antike ljudi su nastojali izraditi strojeve koji bi obavljali poslove umjesto njih. Težilo se napraviti strojeve koji će poprimiti ljudske osobine univerzalnog rješavanja složenih problema. Riječ inteligencija dolazi od latinske riječi „intelligere“ što znači shvatiti, razumjeti. Tako se od inteligentne jedinke ili grupe jedinki očekuje da imaju svojstva intelektualnog ponašanja, da stječu nova znanja i samostalno zaključuju te da se prilagođavaju na nove nepoznate situacije. Također se zahtijeva da rješenja problema generiraju u stvarnom vremenu i rješavaju probleme pogrešaka, višeznačnosti i nejasnoća u komunikaciji. Umjetna inteligencija pripada području tehničkih znanosti i bavi se izgradnjom računalnih sustava čije se ponašanje može tumačiti kao inteligentno. Dan W. Patterson je 1990. godine definirao umjetnu inteligenciju kao granu računarske znanosti koja proučava i oblikuje računarske sustave koji pokazuju neki oblik inteligencije. Takvi sustavi mogu učiti, donositi zaključke o okolini, razumiju prirodni jezik te mogu spoznati i tumačiti složene vizualne scene te obavljati sve vještine za koje je potrebna ljudska inteligencija. Umjetna inteligencija povezana je s humanističkim, prirodnim i kognitivnim znanostima. Ona proučava govor, apstraktne probleme i svijest, modelira biološke stanice mozga i procesa zaključivanja te proučava um i inteligenciju [16].

Ethem Alpayadin je 2009. godine definirao strojno učenje kao programiranje računala na način da optimiziraju neki kriterij uspješnosti na osnovu podatkovnih primjera ili prethodnog


iskustva. Rezultat toga je model koji se uči izvođenjem algoritma koji optimizira parametre modela na osnovu prethodnih iskustava. Tom Mitchell kaže da je strojno učenje istraživanje računalnih algoritama koji se automatski poboljšavaju iskustvom. Kod strojnog učenja javljaju se pitanje kako programirati računala da rješavaju probleme te što se može naučiti iz podatkovnog skupa za učenje. Strojno učenje je izuzetno korisno u situacijama kada je problem presložen za rješavanje, kada ne postoji ideja za rješavanje problema te kada nije poznato kako bi čovjek riješio takav problem. Također je koristan u dinamičnim sustavima gdje je potrebna stalna prilagodba novim situacijama i problemima. Dakle, može se reći da se strojno učenje koristi u onim situacijama kada ljudi nisu pronašli odgovarajući matematički model za opis problema i izmjerene podatke. Strojno učenje dijeli se na nadzirano učenje, nenadzirano učenje i ojačano odnosno podržano učenje [16]. Strojno učenje temelj je primjene umjetne inteligencije na području poboljšanja adaptivnog upravljanja raskrižjima. Strojno učenje podrazumijeva optimizaciju performansi modela koristeći postojeće podatke i iskustva [17].

4.2. Pristupi upravljanja semaforiziranim raskrižjima zasnovani na umjetnoj inteligenciji

Osim korištenja ustaljenih signalnih planova i adaptivnih izmjena signalnih planova, za upravljanje semaforiziranim raskrižjima koriste se metode umjetne inteligencije. Neke od njih uključuju korištenje strojnog učenja, neizrazite logike, genetskog algoritma te neuronskih mreža. Posebno u slučaju adaptivnog upravljanja signalnim planovima.

Neizrazita logika je metoda umjetne inteligencije koja za razliku od klasične logike koristi neizrazite vrijednosti. Klasična ili Bool-ova logika ima dvije vrijednosti, a to su istina i neistina. Takvim vrijednostima možemo opisati samo elemente koji ili potpuno pripadaju ili ne pripadaju nekom skupu. Problem nastaje kod potrebe za stupnjevanom pripadnošću nekog elementa nekom skupu. Lotfi A. Zadeh 1965. godine predstavlja teoriju neizrazitih skupova na kojima se zasniva neizrazita logika. Neizrazita logika omogućuje bolju implementaciju ljudskog znanja o problemu regulacije procesa što ju čini korisnom za područje automatske regulacije, analize podataka te sustava za nadzor i dijagnostiku. Funkcionira na način da se semantički opišu ulazne i izlazne varijable poput „x je A“ gdje A označava jezičnu vrijednost zadanu s neizrazitim skupom nad domenom varijable X. Zatim neizrazita logika određuje stupanj pripadnosti varijable x neizrazitom skupu A. Pravila odlučivanja imaju opći oblik: AKO x je A I y

je B ONDA z je C, pri čemu je „x je A I y je B“ premisa ili uvjet, a „z je C“ zaključak pravila. Za dobro opisan sustav ili proces potrebno je izraditi što veći broj pravila, odnosno bazu neizrazitih pravila. Kao što je prethodno spomenuto, u neizrazitoj logici pripadnost elementa nekom skupu može biti djelomična s vrijednostima funkcije pripadnosti između 0 i 1. Radi lakše izrade složenijih sustava upravljanja neizrazita logika koristi i brojčane i jezične vrijednosti podataka. Za primjer je dan prikaz na slici 8 gdje se vidi razlika pripadnosti elemenata izrazitom i neizrazitom skupu. U izrazitom skupu element ili pripada ili ne pripada nekom skupu, a u neizrazitom skupu postoje vrijednosti pripadnosti elementa skupu između 0 i 1. Točnije, na slici vrijednosti između 25 i 35 stupnjeva Celzijevih pripadaju temperaturi vruće u određenom stupnju pripadnosti. Npr. Temperatura od 28 stupnjeva pripada skupu „vruće“ oko 0,3, 30 stupnjeva pripada 0,5, itd. [18].



Slika 8: Prikaz razlike pripadnosti elementa izrazitom i neizrazitom skupu, [18]

Neizrazita logika često se koristi u upravljanju semaforiziranim raskrižjima jer omogućava preciznije upravljanje prometnim tokom i točnije definiranje trenutnog stanja u odnosu na upravljanje klasičnom logikom. Sustavi koji koriste neizrazitu logiku za upravljanje prometnim tokom rade u stvarnom vremenu te mogu mijenjati signalni plan prema trenutnoj potrebi. Takav način upravljanja daje bolje rezultate u odnosu na upravljanje semaforiziranog raskrižja s ustaljenim signalnim planom [18]. Kod korištenja neizrazite logike na semaforiziranim raskrižjima, postavljaju se osjetilni uređaji za prepoznavanje duljine repa čekanja. Prema količini vozila određuju se jezične vrijednosti koje opisuju broj vozila na svakom privozu. Na primjer, 0-10 vozila pripada funkciji pripadnosti „malo“, 11-20 vozila funkciji pripadnosti „srednje“ i 21-više funkciji pripadnosti „puno“. Za svaki privoz se na taj način odrede funkcije pripadnosti te odgovarajuća pravila u neizrazitom regulatoru. Za svaku

kombinaciju ulaznih vrijednosti računa se izlazna vrijednost koja predstavlja trajanje zelenog ili crvenog signalnog svjetla, ovisno s čime se upravlja. U [19] simulacijski rezultati pokazuju smanjenje zaustavljanja vozila je 15% - 20% i smanjenje kašnjenja za 15% - 30% u rangu od 100 do 1500 voz/h.

Genetski algoritam se zasniva na konceptu evolucije. On slučajno pretražuje prostor rješenja po principu prirodnog izbora najsposobnijih kandidatnih rješenja. Oslanja se na načela živih organizama pa tako nastoji poboljšati sam sebe. Tijekom pretraživanja skup rješenja se mijenja i može se u svakoj iteraciji potpuno promijeniti ili zadržati najbolja rješenja. Na slici 9 je prikazan princip rada genetskog algoritma gdje se vidi kako svaka generacija rješenja prolazi evaluaciju te se po potrebi poboljšava selekcijom, križanjem i mutacijom do zadovoljenja uvjeta [16].




Slika 9: Prikaz rada genetskog algoritma, [16]

U procesu selekcije odabiru se rješenja radi očuvanja dobrih i odbacivanja loših rješenja. Također se radi očuvanje najboljeg rješenja. Postoji više vrsta selekcija, a one su jednostavna, stohastička, turnirska, linearno sortirajuća selekcija te selekcija najboljih. Za unos promjena u postojeći skup rješenja zaslužni su genetski operatori koji na osnovu postojećih rješenja, križanjem, mutacijom i inverzijom, kreiraju nova. Križanje imitira prirodnu reprodukciju i time se postiže brza konvergencija optimumu. Postoji nekoliko vrsta križanja, a to su uniformno, križanje s n točaka prekida, aritmetičko i heurističko križanje. Mutacija je trajna promjena genetskog materijala zbog vanjskog utjecaja, a unutar genetskog algoritma se radi ubacivanje novih nizova u pojedino postojeće rješenje. Razlikuju se jednostavna i miješajuća mutacija. Inverzija je premještanje dijela rješenja unutar niza, pri čemu se mjesto i duljina premještanja slučajno odabiru [16]. Genetski algoritam često se koristi u kombinaciji s neizravnom logikom

pri čemu se genetskim algoritmom unaprjeđuju pravila dana neizrazitom regulatoru. Na taj način dobivaju se točnija i pogodnija pravila neizrazitog regulatora za upravljanje prometnim tokom, odnosno upravljanje semaforiziranim raskrižjima. U [20] je provedeno takvo istraživanje, a rezultati simulacije pokazuju poboljšanje upravljanja raskrižjem za 30% kod inicijalne populacije u odnosu na ustaljeni signalni plan i 33,2% za unaprijeđenu populaciju genetskim algoritmom u odnosu na ustaljeni signalni plan kod protoka od 2340 vozila/h. U [21] cilj je bio maksimizirati prosječnu okupaciju raskrižja kako bi se povećala propusnost vozila. Za to je razvijen model staničnih automata koji će simulirati ponašanje vozila prilikom prolaska kroz raskrižje. Genetski algoritam korišten je za optimizaciju putanje vozila za vrijeme prolaska kroz raskrižje. Svaki individualni pristup je evaluiran zasebno prema fitnes funkciji i na taj način odabran je najbolji.

Umjetne neuronske mreže (eng. Artificial Neural Networks) kao i genetski algoritam oponašaju živa bića, točnije ljudski mozak. Ljudski mozak sačinjen je od 10^{11} neurona i oko $60 \cdot 10^{12}$ veza između neurona. Neuronima imaju mogućnost jednostavne i brze obrade ulaznog signala. Neuro-računarstvo (eng. Neurocomputing) je grana računarstva koja se bavi istraživanjem obrade podataka pomoću neurona. Ono je jedna od grana mekog računarstva i predstavlja konektivistički pristup izgradnji sustava umjetne inteligencije. To znači da se umjesto programiranja sustav samostalno uči na temelju iskustva pri čemu se omogućuje zaključivanje. U širem smislu umjetna neuronska mreža je replika ljudskog mozga s ciljem simuliranja postupka učenja i obrade podataka. U užem smislu predstavlja skup međusobno povezanih elemenata za obradu, tj. neurona koji oponašaju biološke neurone, koji služe za distribuiranu paralelnu obradu podataka. Umjetne neuronske mreže omogućavaju robusnu obradu složenih podataka, rješavanje problema klasifikacije i regresije podataka, sposobne su učiti iz danog podatkovnog skupa, omogućavaju generaliziranje naučenih podataka i imaju dobru toleranciju na pogreške u ulaznim podacima. Na slici 10 je prikazan model umjetnog neurona koji su predložili 1943. godine neuroznanstvenik Warren McCulloch i logičar Walter Pitts. Umjetni neuron oponaša ponašanje biološkog neurona pa tako x_i predstavlja signale na ulazu u neuron (dendriti), w_i su težine pojedinog ulaza (sinapse), w_0 je stalni odmak od nule, I je zbroj otežanih ulaza (jezgra), $\phi(I)$ je aktivacijska funkcija (jezgra), a y je izlaz neurona (akson) [16].



Slika 10: Model umjetnog neurona, [16]

Vrijednost izlaza pojedinog neurona određuje aktivacijska funkcija. Ona također određuje mogućnost učenja na skupu ulaznih podataka, pri čemu složeniji ulazni podaci zahtijevaju nelinearne aktivacijske funkcije, a za jednostavne linearne probleme koriste se linearne aktivacijske funkcije. Nadalje, aktivacijska funkcija neurona određuje granice izlaznog signala pojedinog neurona te ograničenje dinamičkog područja izlaznog signala neurona. Najčešće aktivacijske funkcije su skokomična, funkcija predznaka, funkcija identiteta, aktivacijska funkcija linearna po odsječcima, sigmoidalna funkcija, funkcija zglobnica te propusna zglobnica [16]. U [22] predstavljen je kontroler za upravljanje signalnim planovima naziva EOM-ANN kontroler (eng. Environment Observation Method based on Artificial Neural Networks Controller). Kontroler računa optimalne signalne planove za izolirana raskrižja. U svakom ciklusu računa minimalno trajanje zelenog svjetlosnog signala kako bi se izbjeglo prometno zagušenje. Simulacije su provedene u simulatoru SUMO, a rezultati pokazuju poboljšanja u upravljanju raskrižjem u odnosu na ustaljeni signalni plan.

4.3. Pristupi upravljanja semaforiziranim raskrižjima zasnovani na strojnom učenju

Primjena umjetne inteligencije je fokusirana na korištenje strojnog učenja kao alat za poboljšanje operacija adaptivnog upravljanja semaforiziranih raskrižja. Strojno učenje je način da se računalo programira tako da optimizira performanse modela po određenim kriterijima koristeći postojeće podatke ili iskustva. Kad se primjenjuju na sustave adaptivnog upravljanja semaforiziranih raskrižja, kriteriji su definirani s ukupnom propusnošću, kašnjenjem i repom čekanja, ali mogu biti definirani tako da daju prednost javnom gradskom prijevozu i vozilima hitne službe tzv. vozilima žurnih službi. Trenutna istraživanja strojnog učenja na adaptivno upravljanje semaforiziranim raskrižjima su većinom fokusirana na korištenje ojačanog i dubokog učenja kako bi se model direktno učio kroz interakciju s okolinom [17].

Ojačano (podržano) učenje (eng. reinforcement learning) je vrsta strojnog učenja pri kojoj se učenje optimalne strategije tijekom rada odvija pretraživanjem metodom pokušaja i pogrešaka. Ono omogućava učenje tijekom primjene modela, ali ne postoji poznata točna izlazna vrijednost već zakašnjela nagrada za odabranu izlaznu vrijednost ili niz izlaznih vrijednosti. Cilj ojačanog učenja je naučiti optimalni upravljački zakon ulaznog stanja u izlaznu akciju. Primjenjuje se kod upravljanja složenim tehničkim sustavima i kod učenja optimalnog slijeda akcija za postizanje željenog cilja [16]. Ojačano učenje je preferirana tehnika nenadziranog učenja u umjetnoj inteligenciji korištena za postizanje potpuno dinamičnog sustava za upravljanje semaforiziranim raskrižjima. Ima sposobnost da nauči veze između parova akcija i njihovih utjecaja na sustav upravljanja. Ojačano učenje može upravljati promjenom trajanja faze, pomicanjem početka faze za određeno vrijeme ili preskočiti pojedinu fazu u skladu sa stvarnim uvjetima na prometnici [23].

Za razliku od metoda nadziranog učenja koje nudi primjere dobrog i lošeg ponašanja, kod ojačanog učenja agent mora metodom pokušaja i pogrešaka saznati koje ponašanje mu donosi najveće nagrade. U tom zadatku, agent mora percipirati stanje okoline i na temelju te informacije treba poduzeti akciju koja rezultira novim stanjem. Kao rezultat te akcije agent dobiva nagradu i na taj način razvija buduće ponašanje. Praćenje rute ili slični jednostavniji upravljački zadaci ne zahtijevaju interakciju s agentima. Međutim, u složenijim situacijama kao što su prolasci kroz semaforizirana raskrižja, priključivanje u promet ili vožnja u prometnom toku, reakcije drugih sudionika snažno utječu na izbor i moguće ishode. Takvi procesi zahtijevaju sustave više agenata (eng. Multiagent Systems) [24].

5. Strojno učenje u upravljanju mješovitim prometnim tokovima

S obzirom da se sve više i brže razvijaju autonomna i umrežena autonomna vozila, očekuje se njihova implementacija u postojeći prometni tok. Time se otvaraju nove mogućnosti u ponašanju sustava za adaptivno upravljanje semaforiziranim raskrižjima. Što je veći udio autonomnih i umreženih autonomnih vozila u prometnom toku, to se bolje može upravljati prometnim tokom kroz semaforizirano raskrižje. Stopostotni udio umreženih autonomnih vozila značio bi mogućnost izbacivanja standardnih semaforiziranih raskrižja jer bi vozila mogla komunicirati s okolinom i izravno jedni s drugima. Takav način prolaska kroz raskrižje ipak zahtijeva određenu logiku prolaska kroz raskrižje kako bi se osigurala optimalna propusnost raskrižja. Pošto još dugo vremena prometni tok neće biti sastavljen od isključivo umreženih autonomnih vozila, razmatraju se opcije upravljanja mješovitim prometnim tokovima. Budući da su umrežena autonomna vozila opremljena raznim osjetilima može ih se koristiti kao uređaje za pomoć pri adaptivnom upravljanju semaforiziranih raskrižja, slanjem stvarnovremenih podataka uređaju za upravljanje. Primjena strojnog učenja na upravljanje semaforiziranim raskrižjima ima za cilj unaprijediti postojeće upravljačke sustave. Strojno učenje omogućava da računalo optimizira postojeće sustave na temelju dostupnih podataka ili iskustva. U ovom slučaju algoritam strojnog učenja nad podacima iz prometa rezultirat će matematičkim modelom s podešenim parametrima. Algoritmi strojnog učenja podijeljeni su na nadzirano učenje, nenadzirano učenje i ojačano učenje [17].

5.1. Nadzirano učenje u upravljanju mješovitim prometnim tokovima

Nadzirano učenje (eng. supervised learning) podrazumijeva grupu algoritama strojnog učenja u kojima se podaci nalaze u brojčanim ili nebrojčanim vrijednostima. Kada se radi o nebrojčanim vrijednostima algoritam koristi klasifikaciju nad podacima, a kod brojčanih vrijednosti regresiju. Klasifikacija ili razvrstavanje je pronalaženje modela za obilježje varijable vrste kao funkcije vrijednosti drugih obilježja. Skup podataka dijeli se na skup za treniranje i skup za testiranje algoritma. Algoritmi koji se najčešće koriste za klasifikaciju su algoritam stroja potpornih vektora (eng. Support Vector Machines) i algoritam najbližeg susjeda (eng. k-Nearest Neighbors – KNN). Regresija je predviđanje vrijednosti određene varijable na temelju

vrijednosti drugih varijabli pod pretpostavkom linearnog ili nelinearnog modela ovisnosti. Regresija traži kontinuirane trendove u skupu podataka i izrađuje matematički model ponašanja između ovisne i neovisne varijable. Najpoznatiji regresijski algoritam je linearna regresija koja pretpostavlja da postoji linearna veza između ovisne i neovisne varijable [17], [25].

Nadzirano učenje u upravljanju semaforiziranim raskrižjima je većinom korišten za predviđanje budućih stanja u prometnom toku. Istraživanje u kojem je korišten algoritam stroja potpornih vektora u kombinaciji s još nekim algoritmima uspjeli su predvidjeti volumen prometa koji se prikuplja pomoću osjetilnih petlji. Čak i pri ignoriranju vanjskih utjecaja, kao što su vremenski uvjeti, ova metoda je pokazala da je moguće koristiti algoritam stroja potpornih vektora za predviđanje prometnog protoka. Protok je uspješno predviđen sa srednjom apsolutnom postotnom pogreškom (eng. Mean Absolute Percentage Error, MAPE) manjom od 10%. Drugo istraživanje pokazalo je da se korištenjem k-NN algoritma također može predvidjeti prometni protok, isto tako sa srednjom apsolutnom postotnom pogreškom manjom od 10%. Iako nadzirano učenje može pomoći u predviđanju protoka koje se koristi za upravljanje semaforiziranim raskrižjem njegova glavna negativna strana je veliko oslanjanje na dostupnost povijesnih podataka. Nadalje, pristupi koji se oslanjaju samo na povijesne podatke su skloni greškama, ako se uvjeti u prometu mijenjaju zbog infrastrukturnih promjena ili incidenata [17].

5.2. Nenadzirano učenje u upravljanju mješovitim prometnim tokovima

Za razliku od nadziranog učenja, kod nenadziranog učenja nema definirane ciljane varijable u skupu podataka. Umjesto toga, algoritmi nenadziranog učenja uče identificirati rubne uzorke pronađene u setu podataka bez dodjeljivanja oznaka. Često se nazivaju i samoorganizirajućim jer sami procjenjuju na osnovu određenih kriterija. Cilj nenadziranog učenja je grupirati podatke, odnosno pronaći pravilnosti među podacima. Jedan od najkorištenijih algoritama nenadziranog učenja je k-means algoritam koji dijeli podatke na k broj klastera. Klasteri su grupe podataka sa sličnim obilježjima [17].

5.3. Ojačano učenje u upravljanju mješovitim prometnim tokovima

Najveći problem kod nadziranog i nenadziranog učenja je u tome što se previše oslanjaju na dostupne povijesne podatke. Zato je ojačano učenje pobudilo velik interes u korištenju strojnog učenja pri upravljanju semaforiziranim raskrižjima. Osnovni princip ojačanog učenja je da uči kroz komunikaciju s okolinom i u stvarnom vremenu daje bolje rezultate. Algoritmi ojačanog učenja su ojačano učenje zasnovano na vrijednosti, ojačano učenje zasnovano na strategijama i ojačano učenje zasnovano na arhitekturi glumac-kritičar.

Ojačano učenje zasnovano na vrijednosti radi na način da odabiru akciju nakon promatranja trenutnog stanja. Nakon svake akcije algoritam dobiva nagradu kao povratnu informaciju za odabranu akciju. Najpoznatiji algoritam je Q-učenje koji pretpostavlja da su akcije i stanja konačnih i diskretnih vrijednosti ili da je jedno od njih kontinuirana varijabla raspodijeljena u nekoliko diskretnih vrijednosti. Ojačano učenje zasnovano na strategijama upravljanja započinje s gotovom strategijom koja se postupno nadograđuje kako bi se dostigla optimalna kontrola raskrižja. Nagrada se ne dobiva odmah nakon poduzete akcije već na kraju epizode. Epizoda podrazumijeva jednu cijelu simulaciju prometa koja se sastoji od više akcija poduzetih za promjenu u signalnom programu. Nakon svake epizode trenutna strategija se nadograđuje. Prednost ovog algoritma je brza konvergencija prema optimalnoj strategiji zbog gradijenta kojim se naučena strategija popravljiva nakon svake epizode. Negativna strana je teško određivanje evaluacije strategije jer se nagrada daje nakon svake epizode umjesto nakon svake poduzete akcije. Ojačano učenje zasnovano na arhitekturi glumac-kritičar (eng. actor-critic) je kombinacija prethodna dva algoritma u kojem je komponenta glumac zasnovana na strategijama upravljanja, a komponenta kritičar zasnovana na vrijednosti. Glumac određuje koju akciju treba poduzeti u trenutnoj strategiji upravljanja, dok kritičar dobiva nagradu od okoline. Na taj način spajaju se prednosti prethodna dva algoritma, a pobijaju nedostaci [17].

5.4. Utjecaj mješovitih prometnih tokova na upravljanje semaforiziranim raskrižjima

Kako bi svi prethodno spomenuti algoritmi strojnog učenja mogli upravljati semaforiziranim raskrižjima potrebno je imati prikupljene ili stvarnovremene prometne podatke. S obzirom da se s postojećim osjetilima ne može dobiti detaljan uvid u stanje u prometu, umrežena autonomna vozila bi igrala veliku ulogu u davanju detaljnih informacija o trenutnom prometnom toku. Umrežena autonomna vozila mogu davati podatke poput lokacije, brzine, rute i

broja putnika, koje se može obraditi strojnim učenjem kako bi se optimalno upravljalo semaforiziranim raskrižjem. Uključivanjem umreženih autonomnih automobila u postojeći prometni tok bi rezultiralo poboljšanjem prometnih parametara na prometnicama u gradovima. Što veći broj umreženih autonomnih vozila bude prisutan u prometnom toku, to će više podataka biti prikupljano te se neće moći obraditi tradicionalnim tehnikama. Strojnim i ojačanim učenjem bi se moglo modelirati optimalno ponašanje semaforiziranih raskrižja kako bi se poboljšao prolazak konfliktnih prometnih tokova kroz semaforizirana raskrižja [17].

6. Analiza primjene strojnog učenja u upravljanju mješovitim prometnim tokovima

Zbog činjenice da se utjecaj autonomnih i umrežena autonomna vozila na postojeći prometni tok još uvijek istražuje potrebno je simulirati i istražiti njihov utjecaj na prometni tok, sigurnost u prometu, potrošnju goriva i emisije štetnih plinova. Uz to, potrebno je razviti algoritme upravljanja prometnim tokom prije nego ih se može implementirati u postojeći prometni tok [26].

6.1. Simulacijska okruženja

SUMO (eng. Simulation of Urban Mobility) je simulator prometnog toka na mikroskopskoj razini dizajniran za velike prometne mreže. Omogućava intermodalne simulacije uključujući i pješake te dolazi u paketu s velikim skupom alata za kreiranje scenarija. Simulator SUMO nudi značajke poput vremenski i prostorno kontinuiranih pokreta vozila, različite tipove vozila, prometnice s više prometnih traka, različita pravila prioriteta prolaska, svjetlosne signalne uređaje, itd. SUMO se koristi za evaluaciju svjetlosnih signalnih uređaja, odabir rute i rerutiranje, evaluaciju nadzora prometa, simulaciju komunikacije među vozilima i predviđanje prometa [27].

SUMO simulator definira svako vozilo s identifikacijskom oznakom ID, vremenom polaska i rutom vozila kroz prometnu mrežu, ali može se opisati i dodatnim detaljima. Polasci i dolasci, tip vozila i varijable kretanja se mogu modelirati. Za scenarije većih karakteristika definiraju se izvorišno-odredišne matrice (eng. origin-destination OD matrix) putovanja između zona u prometnoj mreži. SUMO sadrži naredbu „od2trips“ za pretvaranje OD matrice u putovanja pojedinačnih vozila s pozicijama polazišta i odredišta. Rute se računaju prema algoritmu najkraćeg puta s različitim troškovima. Simulator sadrži korisničko sučelje TraCI (eng. Traffic Control Interface), koje omogućava pregled statističkih podataka i izravan pristup svim elementima. Razvijen je i dodatak FLOW kao modularni okvir za strojno učenje koji olakšava konfiguraciju i sastav modula. Time je omogućeno učenje upravljačkih zakona za autonomna vozila u složenim prometnim mrežama [26].

FLOW je okruženje za simulaciju upravljanja željenih prometnih scenarija i integraciju dubokog ojačanog učenja. Prometni sustavi često mogu biti složeni i ne mogu biti objašnjena klasičnim sustavima te alatima za analizu. Duboko ojačano učenje omogućava proučavanje

složenijih problema upravljanja prometom, uključujući interakciju ljudi, automatiziranih vozila i osjetilne infrastrukture. Rezultirajući zakoni upravljanja i ponašanja vozila daju uvid i razumijevanje potencijalne automatizacije prometa kroz mješovite prometne tokove [28].

Još neki od simulatora koji se koriste za simulacije mješovitih prometnih tokova su PTV VISSIM i AIMSUN Next. VISSIM je simulacijski alat tvrtke PTV koji se koristi za simulaciju prometnog toka na izrađenom modelu prometnice. Koristi se za simulaciju prometa na razini pojedinih raskrižja ili dionica prometnice kojima se želi upravljati. Također je u mogućnosti simulirati ponašanje i međusobnu interakciju svih vrsta motornih vozila, vozila javnog prijevoza i pješaka te testiranje autonomnih vozila i njihovog ponašanja s obzirom na okolinu [18].

AIMSUN Next je simulator koji omogućava modeliranje malih i velikih transportnih mreža. Moguće je unositi i mijenjati parametre modela, ulazne i izlazne podatke, računati s podacima iz rezultata simulacije, itd. AIMSUN simulator sadrži dodatni softver za simulaciju komunikacije u mikroskopskoj simulaciji naziva V2X Software Development Kit. Sučelje naziva External Agent Interface je dizajnirano za simulaciju ljudski upravljanih vozila ili autonomnih vozila. AIMSUN Next simulacijsko okruženje posjeduje značajke za simulacije umreženih autonomnih vozila, uključujući praćenje vozila, promjenu prometnog traka, itd. [26].

6.2. Prikupljanje prometnih podataka u okolini mješovitih prometnih tokova

Kako bi semaforizirana raskrižja mogla učinkovitije upravljati prometnim tokom, potrebno im je osigurati ispravne prometne podatke. Iako je nekim algoritmima dovoljno upoznati se s povijesnim podacima kako bi optimizirali signalni plan, stvarnovremeni podatci bi značili još točnije i učinkovitije upravljanje prometnim tokom.

Cilj je da upravljački sustav radi na osnovu stvarnovremenih podataka kako bi se poboljšala propusnost raskrižja. Ono što autonomna i umrežena autonomna vozila mogu prikupljati su: brzina vozila, pozicija vozila, ubrzanje ili usporavanje vozila, itd. Na slici 11 je prikazana raspodjela najčešće prikupljenih podataka.




Slika 11: Raspodjela prikupljenih prometnih podataka, [29]

S velikom količinom prikupljenih podataka dolazi do pitanja kvalitete i komunikacije tijekom prijenosa podataka. Neki od problema mogu biti kašnjenje, neuspjeh prijenosa, sigurnost i duplikacija podataka, podatci loše kvalitete i efekt lošeg meteorološkog vremena na proces prikupljanja podataka. Komunikacijska mreža također može uzorkovati probleme zbog ograničenog doseg komunikacije. Rješavanje tih problema je kritično za sigurnost i učinkovitost upravljanja prometnim tokom. Bitan faktor u upravljanju su metode dijeljenja podataka. Kod prometnih tokova s autonomnim vozilima podatci se mogu dijeliti lokalno za donošenje odluka za jedno vozilo ili jedno raskrižje ili globalno odnosno između više raskrižja. Postoje različiti tipovi komunikacije između vozila i raskrižja. Prvi tip je V2I i podrazumijeva slanje podataka od vozila prema infrastrukturi odnosno raskrižju. Vozila su zadužena za prikupljanje podataka i slanje istih infrastrukturi. U I2V komunikaciji je infrastruktura zadužena za prikupljanje podataka i obradu istih kako bi se donijele odluke za upravljanje prometnim tokom. V2V komunikacija podrazumijeva da ne postoji središnji sustav upravljanja i da su

vozila zadužena za upravljanje prometnim tokom prikupljajući i obrađujući prometne podatke. V2V i V2I komunikacija mogu biti kontinuirane ili diskretne. Kod kontinuirane komunikacije slanje podataka se događa cijelo vrijeme, dok se u diskretnoj komunikaciji to događa u određenim vremenskim razmacima. Kako bi se povećala učinkovitost smanjenjem prijenosa podataka predlaže se slanje podataka samo ako se javljaju promjene u podacima. Na taj način bi razmjena podataka unaprijedila upravljanje semaforiziranim raskrižjem. U okruženju mješovitog prometnog toka predlaže se opremiti raskrižja i prometnice s raznim osjetilima, kao npr. sustav centara za umrežena vozila te druga osjetila zadužena za praćenje kretanja vozila [29]. Sensori ili mjerna osjetila služe za prikupljanje podataka odnosno detektiranje i mjerenje neke fizikalne veličine u prostoru. Kod osjetila se promjene pretvaraju u električni signal na temelju kojega se zaključuje da je vozilo prošlo. To mogu biti induktivne petlje, magnetski detektori, piezoelektrički detektori, infracrveni detektori, radarski detektori, zvučni i ultrazvučni detektori te videodetektori [30]. Međutim, opremanje svakog raskrižja takvim uređajima je vrlo skupo i neučinkovito u svim vremenskim uvjetima kao što je snijeg na cesti ili tama noću. Istraživanja su pokazala da je korištenje podataka od autonomnih vozila u uvjetima mješovitog prometnog toka učinkovito ako je udio umreženih autonomnih vozila manji od 10%. U suprotnom nastaje prevelik broj podataka i dolazi do problema brze obrade velike količine podataka [29].

6.3. Genetski algoritam i upravljanje mješovitim prometnim tokovima

U [31] istražena je primjena genetskog algoritma kod upravljanja raskrižjima s autonomnim vozilima. Istraživanje se provelo na raskrižju sa četiri privoza i punim skupom mogućih faza. Zbog toga što je skup rješenja za problem optimizacije proširen povećanim brojem mogućih kretanja vozila kroz raskrižje koristio se genetski algoritam za rješavanje problema prolaska vozila. Predloženi algoritam odlučuje redoslijed prolaska vozila raskrižjem zasnovano na redoslijedu zahtjeva. Iako je izračunata putanja za pojedinačno vozilo optimum sam po sebi, performanse raskrižja ne moraju nužno biti optimizirane korištenjem primijenjenog redoslijeda prolaska vozila. Na slici 12 je prikazano raskrižje sa četiri privoza na kojem postoji posebni trak za prolazak ravno, lijevo i desno skretanje.



Slika 12: Upravljanje raskrižje i komunikacijski doseg, [31]

Sustav upravljanja radi optimizacije raskrižja prikuplja informacije o vozilima, donosi odluke o redoslijedu prolaska vozila i računa optimalne putanje vozila. Omogućena je V2I komunikacija autonomnih vozila s okolinom kroz određeni komunikacijski doseg. Na početku optimizacije sustav upravljanja identificira vozila koja ulaze u komunikacijski doseg i prikuplja podatke potrebne za optimizaciju. Nakon toga, sustav upravljanja pokreće optimizacijski algoritam i rješava problem određivanja redoslijeda prolaska vozila poslužujući vozila koja nisu u konfliktu. U isto vrijeme, računaju se putanje vozila i šalju se vozilima kako bi prošla kroz raskrižje. Kada zadnje vozilo iz grupe prođe raskrižje završava prva faza optimizacije. Nakon toga počinje nova faza optimizacije gdje se proces optimizacije ponavlja za vozila koja uđu u komunikacijski doseg za vrijeme drugog vremenskog perioda. Taj proces se ponavlja dok god sva vozila ne uđu u komunikacijski doseg prođu raskrižje.

Upravljački algoritam je osmišljen za prometni tok koji se sastoji samo od autonomnih vozila koja ne trebaju signalizaciju za prolazak raskrižjem. Umjesto signalizacije dobivaju optimizirane putanje od sustava upravljanja raskrižjem kroz komunikacijski doseg. Time se postiže puno fleksibilniji prolazak kroz raskrižje sa ciljem smanjivanja kašnjenja. Genetski


algoritam se koristi za rješavanje problema optimizacije redoslijeda prolaska vozila kroz raskrižje. Algoritam optimizacije putanje ne može se izraziti jednostavnim numeričkim jednadžbama. Stoga je odabran dinamički algoritam koji se može koristiti za rješavanje problema određivanja redoslijeda prolaska vozila. Odluke se donose od početka svake faze kako bi se odredilo koje vozilo treba ući u raskrižje.

Na početku simulacije ulazni parametri su se učitali iz posebne tekstualne datoteke. Četiri su ulazne varijable za simulaciju: geometrijske informacije koje uključuju duljinu komunikacijskog dosega i dužinu raskrižja, parametri korišteni za generaciju vozila, parametri za optimizaciju i parametri pokreta vozila kao što su ubrzanje, interval slijeđenja, itd. Nakon učitavanja ulaznih parametara, sustav nasumično generira vremena i brzine dolaska svih vozila koja uđu u komunikacijski doseg. Tri su glavne izlazne vrijednosti algoritma: optimalni redoslijed prolaska vozila, optimizirana putanja vozila i prosječno vrijeme kašnjenja. Provedena je analiza osjetljivosti algoritma na ulazne vrijednosti. Testirani su: prometna potražnja, postotak skretanja i duljina komunikacijskog ranga. Za svaki faktor testirani su različiti scenariji korištenjem Java simulacije s optimizacijskim algoritmom. U prvom slučaju postotak skretanja bio je 15% za lijevo i desno skretanje, a komunikacijski doseg duljine 900 m od zaustavne trake. Nakon implementacije optimizacijskog algoritma kašnjenje na raskrižju se smanjilo za 16,3% do 79,3% ovisno o scenariju potražnje, a poboljšanje je bilo veće što je potražnja bila veća. U drugom slučaju potražnja je bila 4000 voz/h, ali različite potražnje su dodijeljene glavnim i sporednim prometnicama. Takve proporcije potražnje nisu imale velikog utjecaja na optimizacijski algoritam i nije bilo većih promjena u kašnjenju na raskrižju. Zadnji slučaj prikazuje kako postotak vozila koja skreću utječe na optimizacijski algoritam. Za svaki scenarij potražnja je iznosila 1000 voz/h, a postotak lijevih i desnih skretača je bio isti. U svim scenarijima performanse su se poboljšale za 15,6% do 67,9% nakon implementacije optimizacijskog algoritma. Također, rezultati pokazuju da se smanjenjem komunikacijskog ranga povećava kašnjenje na raskrižju jer je teže odrediti putanju vozila što je vozilo bliže raskrižju [31].

6.4. Ojačano učenje i upravljanje mješovitim prometnim tokovima

U [32] provedeno je istraživanje za primjenu ojačanog učenja pri upravljanju semaforiziranim raskrižjima u uvjetima umreženih autonomnih vozila i ljudski upravljanih vozila u svrhu povećanja učinkovitosti upravljanja prometnim tokom. Ojačano učenje

isprobava ogroman broj puta kombinacije akcija i mogućih putanja, puno više nego što to može čovjek. Uz to, primjenom ojačanog učenja, umjesto optimizacije putanja, rješava se problem računanja uzrokovan ponovnom optimizacijom kada dođe do promjena u prometnoj okolini. Tipično ojačano učenje sadrži agenta i okolinu gdje agent odrađuje akcije i dobiva povratnu informaciju od okoline. Agent pokušava naučiti funkciju upravljanja da zapamti zapažanja budućih nagrada. Cilj je naučiti strategiju koja maksimizira očekivani odgovor od trenutnog stanja. Kako bi se riješio problem konvergencije u ojačanom učenju uveden je algoritam Q-učenje (eng. Q-learning) koji je ograničen diskretnim izlaznim vrijednostima. Ne može upravljati akceleracijom ili skretanjem vozila jer nema mogućnost kontinuirane izlazne vrijednosti. Zato se uvodi gradijent strategije (eng. policy gradient) koji može dati kontinuiranu izlaznu vrijednost. Na osnovu koncepta algoritma gradijenta strategije predložen je algoritam glumac-kritičar koji spaja strategijsku i vrijednosnu funkciju u cilju povećanja stabilnosti ažuriranja. Korištenjem funkcije aproksimiranja kao što su neuronske mreže za parametriziranje glumac-kritičar algoritma značajno se poboljšava izvođenje algoritma u vidu bržeg procesa treniranja i povećane sposobnosti u nelinearnosti. Gradijent strategija može biti neučinkovit prilikom učenja stohastičke strategije kada treba naučiti koju determinističku akciju treba poduzeti u determinističkoj okolini. Stoga je uveden deterministički gradijent strategija (eng. deterministic policy gradient) koji vodi do poboljšanja učinkovitosti u treniranju. Ideja je ista kao i kod glumac-kritičar algoritma jer razdvaja treniranje na ažuriranje vrijednosne funkcije kako bi bolje evaluirao trenutnu situaciju i na ažuriranje strategijske funkcije izravno od kritičara kako bi zapamtio stanja akcija za dobivanje boljih vrijednosti. Problem konvergencije i stabiliziranje ažuriranja obično postoje kod ojačanog učenja, ali uspješno poboljšavaju učinkovitost učenja. Q-učenje uspješno rješava te probleme pa je kombinacijom nastao algoritam duboke determinističke gradijent strategije (eng. Deep Deterministic Policy Gradient - DDPG). U tom algoritmu glumac i kritičar nastavljaju evaluirati duboku neuronsku mrežu tijekom procesa treniranja. Rezultati pokazuju da DDPG postiže bolje upravljanje kada agent radi na prostoru kontinuirane akcije. Na slici 13 je prikazan dijagram treniranja umreženih autonomnih vozila. Umrežena autonomna vozila zasnovana na ojačanom učenju uče iz interakcije s okolinom. Svaki vozilo prikuplja zapažene podatke, pohranjuje ih u međuspremniku memorije gdje će se manji skup podataka koristiti za treniranje. DDPG model se primjenjuje nad skupom podataka za treniranje kako bi se ažurirali kritičar i glumac u svrhu postizanja veće akumulirane nagrade ili boljih performansi u okolini.



Slika 13: Dijagram učenja umreženog autonomnog vozila, [32]

Kako bi se validirala robusnost DDPG modela, određeno je 6 epizoda s različitim nagradama. Rezultati istraživanja su pokazali brzi rast kumulativne nagrade od početka treniranja. Osobito oko 80.000 koraka nagrada raste rapidno. Nakon 100.000 koraka model konvergira na vrijednost od 400. Nasumično je odabrana jedna epizoda te su provedeni različiti testovi.

Prvo su ispitane performanse modela pod različitim prometnim potražnjama. Simulirana su 3 slučaja s inicijalnim volumenom prometa od 600, 900 i 1.200 voz/h s ciklusom od 40 s za crveno i zeleno signalno svjetlo te 5 s za žuto signalno svjetlo. Rezultati simulacije su pokazali raspodjelu putanja umreženih autonomnih vozila kako bi se smanjio efekt zaustavljanja i oscilacije u prometnom toku. Vozila također uzimaju u obzir globalne promjene signalnog svjetla što znači da nekad unaprijed usporavaju za dobrobit budućeg stanja raskrižja. Protok u raskrižju se dvostruko povećao. Prosječna brzina umreženih autonomnih vozila prati uzorak gdje je najveća brzina postizana u sredinama trajanja crvenih i zelenih svjetlosnih signala što znači da su vozila u mogućnosti naučiti strategiju prolaska s povećanom učinkovitosti.

Nakon toga ispitan je slučaj performansi pod uvjetima različitih trajanja signalnog ciklusa, s obzirom da se trajanje ciklusa može mijenjati tijekom dana i u uvjetima različitih prometnih potražnji. Postavljen je fiksni prometni volumen od 900 voz/h s različitim trajanjima ciklusa. Ne postoji predodređeni plan po kojem se odvija promet, već DDPG prilagođava ponašanje vozila prema stvarnovremenim podacima kako bi se nosio s nesigurnošću u prometnoj okolini. S obzirom da su trajanja svjetlosnih signala kraća, učinkovitost raskrižja se

povećava. Kada su trajanja crvenog i zelenog svjetlosnog signala 25 s, prosječna brzina vozila je 84 km/h, a trajanjem fazi od 45 s smanjuje se prosječna brzina na 70 km/h.

Ljudski upravljana vozila su ograničena ljudskim pogreškama kao što su spore reakcije, ograničen kapacitet procesiranja informacija i nekooperativnost. Stoga su uspoređeni parametri potrošnje goriva, sigurnosti i učinkovitosti prolaska semaforiziranim raskrižjima između ljudski upravljanih i umreženih autonomnih vozila. Kod ljudski upravljanih vozila dolazi do većih oscilacija u putanjama vozila što je uzrokovano neefikasnim uzorkom vožnje. To prouzrokuje veću potrošnju goriva nego kod umreženih autonomnih vozila. Kod ljudski upravljanih vozila česta su zaustavljanja i kretanja što predstavlja veći rizik po pitanju sigurnosti u prometnom toku [32].

7. Zaključak

Zbog sve većih potreba današnjeg stanovništva i rasta istog stvaraju se velika prometna zagušenja u prometu, osobito u području raskrižja za vrijeme vršnih sati. Tu dolazi do znatnog smanjenja razine usluge i velikih kašnjenja u prometu što se odražava i na ekonomiju pojedine države. Današnje vrijeme predstavlja velike napretke u tehnologiji pa se tako uvelike razvijaju i autonomna te umrežena autonomna vozila. Takva vozila predstavljaju budućnost prometnog sustava gdje se eliminira ljudska pogreška i dolazi do boljih performansi u prometu i poboljšanja prometnih parametara. Njihov brzi razvitak znači potencijalnu skoriju implementaciju u postojeći prometni tok. Iako još takva vozila uvijek nisu razvijena i testirana do kraja, potrebno je prilagoditi infrastrukturu i postojeći prometni tok na dolazak novih vrsta vozila. S obzirom da se promet ne može odjednom prebaciti na potpuno autonomno upravljanje prometom, treba proći određen period vremena gdje će se miješati autonomna i umrežena autonomna vozila s ljudski upravljanim vozilima. Takav prometni tok naziva se mješoviti prometni tok i potrebno je pomno regulirati pravila prometovanja. Najveći problem izazivaju semaforizirana raskrižja čiju okolinu ljudski vozači i računala u umreženim autonomnim vozilima posve različito percipiraju. Ljudski upravljana vozila prate promjene faza na klasičan način, vizualno preko svjetlosnih signala, dok računala u umreženim autonomnim vozilima preko osjetila i središnjeg sustava upravljanja komuniciraju s okolinom te dobivaju informacije o pravodobnom prolasku kroz raskrižje. Potrebno je razviti algoritme upravljanja mješovitim prometnim tokovima kako bi se osiguralo učinkovito i sigurno prolaženje kroz semaforiziranih raskrižja. Najčešći algoritmi zasnovani na strojnom učenju korišteni za upravljanje semaforiziranih raskrižja koriste neizrastu logiku, genetski algoritam, ojačano učenje, itd. Iako su provedena mnoga istraživanja upravljanja semaforiziranim raskrižjima u uvjetima mješovitih tokova, potrebno je još puno toga istražiti i testirati kako bi se utvrdilo sigurno, učinkovito i poboljšano upravljanje prometom.

Literatura

- [1] Čakija D, Assirati L, Ivanjko E, Luiz Cunha A. Autonomous Intersection Management: A Short Review. Proceedings of 61st International Symposium ELMAR-2019, Special session Intelligent Transport Systems, Zadar, Croatia, 23.-25.09.2019., pp. 21-26., DOI: 10.1109/ELMAR.2019.8918864
- [2] Bošnjak I. Inteligentni transportni sustavi 1, Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2006.
- [3] McBride N. The Ethics of Driverless Cars. ACM SIGCAS Computers and Society. 2016;45(3):pp. 179-184, DOI:10.1145/2874239.2874265
- [4] Mandžuka S, Vujić M. Telematika u prijevoznim sredstvima. Autorizirana predavanja. Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2014.
- [5] National Highway Traffic Safety Administration. Preuzeto sa: <https://www.nhtsa.gov/technology-innovation/automated-vehicles-safety> (Pristupljeno: svibanj 2021.)
- [6] Yan W, Li C, Huang Y, Yang L. Smart Longitudinal Velocity Control of Autonomous Vehicles in Interactions With Distracted Human-Driven Vehicles. IEEE Access. 2019;PP(99):1-1, DOI: 10.1109/ACCESS.2019.2954863
- [7] IZVJEŠĆE o autonomnoj vožnji u europskom prometu (2018/2089(INI)). Preuzeto sa: https://www.europarl.europa.eu/doceo/document/A-8-2018-0425_HR.html (Pristupljeno: svibanj 2021.)
- [8] IEEE Connected & Autonomous Vehicles. Preuzeto sa: <https://site.ieee.org/connected-vehicles/ieee-connected-vehicles/connected-vehicles/> (Pristupljeno: lipanj 2021.)
- [9] Cao Z, Lu L, Chen C, Chen X. Modeling and Simulating Urban Traffic Flow Mixed With Regular and Connected Vehicles. IEEE Access. 2021;9:pp. 10392-10399. DOI: 10.1109/ACCESS.2021.3050199
- [10] Liu Y, Guo J, Taplin J, Wang Y. Characteristic Analysis of Mixed Traffic Flow of Regular and Autonomous Vehicles Using Cellular Automata. Journal of Advanced Transportation. 2017;(1705):pp. 1-10, DOI: 10.1155/2017/8142074

- [11] Bošnjak I, Badnjak D. Osnove prometnog inženjerstva. Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2005.
- [12] Vujić M. Cestovna telematika. Autorizirana predavanja. Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2014.
- [13] Zakon o sigurnosti prometa na cestama. Preuzeto sa: <https://www.zakon.hr/z/78/Zakon-o-sigurnosti-prometa-na-cestama> (Pristupljeno: svibanj 2021.)
- [14] Qi H, Dai R, Tang Q, Hu X. Coordinated Intersection Signal Design for Mixed Traffic Flow of Human-Driven and Connected and Autonomous Vehicles. IEEE Access. 2020;PP(99). DOI: 10.1109/ACCESS.2020.2970115
- [15] Ivanjko E. Umjetna inteligencija. Autorizirana predavanja. Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2020.
- [16] Miletić M. Application of Reinforcement Learning in Adaptive Traffic Signal Control: A Review. Report for Ph.D. qualifying exam, Fakultet prometnih znanosti; 2020.
- [17] Jakobović Ž. Okruženje za simulaciju upravljanja priljevnim tokovima gradskih autocesta zasnovanih na neizrastoj logici. Završni rad. Zagreb: Fakultet prometnih znanosti; 2019.
- [18] Wei W, Zhang Y, Zhang Z, Song J. Urban Intersection Traffic Signal Control Based on Fuzzy Logic. Tsinghua Science and Technology. 2002;7;pp. 502-507
- [19] Cheng X, Yang Z. Intelligent Traffic Signal Control Approach Based on Fuzzy-Genetic Algorithm. Fifth International Conference on Fuzzy Systems and Knowledge Discovery. 2018. DOI: 10.1109/FSKD.2008.389
- [20] Cruz-Piris L, Lopez-Carmona M A, Marsa-Maestre I. Automated Optimization of Intersections Using a Genetic Algorithm. IEEE Access. 2019;7;pp. 15452-15468. DOI: 10.1109/ACCESS.2019.2895370
- [21] De Oliviera M B W, de Almeida Neto A. Optimization of Traffic Lights Timing based on Artificial Neural Networks. 17th International IEEE Conference on Intelligent Transportation Systems (ITSC). 2014;pp. 1921-1922. DOI: 10.1109/ITSC.2014.6957986

- [22] Rasheed F, Yau KA, Noor RM, Wu C, Low Y. Deep Reinforcement Learning for Traffic Signal Control: A Review. IEEE Access. 2020;8;pp. 208016-208044. DOI: 10.1109/ACCESS-2020.3034141
- [23] Aradi S. Survey of Deep Reinforcement Learning for Motion Planning of Autonomous Vehicles. Budapest: University of Technology and Economics; 2020.
- [24] Gold H. Rudarenje podataka. Autorizirana predavanja. Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2019.
- [25] Vrbanić F, Čakija D, Kušić K, Ivanjko E. Traffic Flow Simulators with Connected and Autonomous Vehicles: A Short Review. Transformation of Transportation. 2021;pp. 15-30. DOI: 10.1007/978-3-030-66464-0_2
- [26] SUMO. Preuzeto sa: https://sumo.dlr.de/docs/SUMO_at_a_Glance.html (Pristupljeno: lipanj 2021.)
- [27] FLOW. Preuzeto sa: <https://flow-project.github.io/> (Pristupljeno: lipanj 2021.)
- [28] Namazi E, Li J, Lu C. Intelligent Intersection Management Systems Considering Autonomous Vehicles: A Systematic Literature Review. IEEE Access. 2019;7;pp. 91946-91965. DOI: 10.1109/ACCESS.2019.2927412
- [29] Jelušić N. Telematička sučelja. Autorizirana predavanja. Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2019.
- [30] Zhou M, Yang Y, Qu X. Development of and Efficient Driving Strategy for Connected and Automated Vehicles at Signalized Intersections: A Reinforcement Learning Approach. IEEE Access. 2020;21;pp. 433-443. DOI: 10.1109/TITS.2019.2942014
- [31] Li Z, Pourmehr M, Elefteriadou L, Ranka S. Intersection Control Optimization for Automated Vehicles Using Genetic Algorithm. Journal of Transportation Engineering Part A Systems. 2018;144;04018074. DOI: 10.1061/JTEPBS.0000197

Popis slika

1. Prikaz mješovitog toka na prometnici
2. Fundamentalni dijagram protoka i gustoće
3. Prikaz osnovnih dijagrama prometnog toka s različitim udjelima autonomnih vozila u prometnom toku
4. Primjer signalnog plana
5. Komponente zaštitnog međuvremena
6. Prikaz poopćene arhitekture SCATS sustava
7. Prikaz poopćene arhitekture SCOOT sustava
8. Prikaz razlike pripadnosti elementa izrazitom i neizrazitom skupu
9. Prikaz rada genetskog algoritma
10. Model umjetnog neurona
11. Raspodjela prikupljenih prometnih podataka
12. Upravljanje raskrižje i komunikacijski doseg
13. Dijagram učenja umreženog autonomnog vozila



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 **Primjena strojnog učenja za upravljanje raskrižjima u okruženju
mješovitih prometnih tokova**

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

U Zagrebu, _____ 30.6.2021 _____

Student/ica:

(potpis)