

Upravljanje promjenjivim ograničenjem brzine primjenom ojačanog učenja za prometne tokove s umreženim autonomnim vozilima

Strikinac, Filip

Master's thesis / Diplomski rad

2022

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:119:557628>

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

Download date / Datum preuzimanja: **2025-03-27**



Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Filip Strikinac

**UPRAVLJANJE PROMJENJIVIM OGRANIČENJEM
BRZINE PRIMJENOM OJAČANOG UČENJA ZA
PROMETNE TOKOVE S UMREŽENIM
AUTONOMNIM VOZILIMA**

DIPLOMSKI RAD

Zagreb, rujan 2022.

Zagreb, 4. svibnja 2022.

Zavod: Zavod za inteligentne transportne sustave
Predmet: Umjetna inteligencija

DIPLOMSKI ZADATAK br. 7005

Pristupnik: **Filip Strikinac (0135225671)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Inteligentni transportni sustavi

Zadatak: **Upravljanje promjenjivim ograničenjem brzine primjenom ojačanog učenja
za prometne tokove s umreženim autonomnim vozilima**

Opis zadatka:

U uvjetima povećane prometne potražnje i povećanja broja umreženih autonomnih vozila na gradskim autocestama javlja se potreba za upravljanje prometom s ciljem smanjenja posljedica nastajanja prometnih zagušenja. Jedno od rješenja iz područja inteligentnih transportnih sustava je sustav za upravljanje ograničenjem brzine na gradskim autocestama primjenom ojačanog učenja. U radu je potrebno opisati upravljanje prometom na gradskim autocestama zasnovano na upravljanju promjenjivim ograničenjem brzine primjenom ojačanog učenja za slučaj prometnog toka s umreženim autonomnim vozilima, te izraditi okruženje za simulaciju takvog upravljanja korištenjem mikroskopskog simulatora SUMO i programskog jezika Python.

Mentor:

Predsjednik povjerenstva za
diplomski ispit:



izv. prof. dr. sc. Edouard Ivanjko



Filip Vrbanić, mag. ing. traff. (komentor)

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

DIPLOMSKI RAD

**UPRAVLJANJE PROMJENJIVIM OGRANIČENJEM
BRZINE PRIMJENOM OJAČANOG UČENJA ZA
PROMETNE TOKOVE S UMREŽENIM
AUTONOMNIM VOZILIMA**

**REINFORCED LEARNING BASED VARIABLE SPEED
LIMIT CONTROL FOR TRAFFIC FLOWS WITH
CONNECTED AUTONOMOUS VEHICLES**

Mentor: izv. prof. dr. sc. Edouard Ivanjko
Komentor: Filip Vrbanić, mag. ing. traff.
Student: Filip Strikinac
JMBAG: 0135225671

Zagreb, rujan 2022.

Sažetak

Današnje autoceste dizajnirane su za pružanje većeg maksimalnog prometnog kapaciteta, ali se javlja sve veći problem premalog kapaciteta istih. Međutim, gradske autoceste se najčešće ne mogu širiti, stoga je potrebno tražiti druga rješenja kako bolje iskoristiti njihov raspoloživ kapacitet. Jedan od sustava iz domene inteligentnih transportnih sustava, koji se može iskoristiti u tu svrhu, je sustav za upravljanje promjenjivim ograničenjem brzine (*eng. Variable Speed Limit Control - VSLC*). Autonomna vozila (*eng. Autonomous vehicle - AV*) i umrežena autonomna vozila (*eng. Connected Autonomous Vehicles – CAV*) uvelike se testiraju i brzo razvijaju u posljednjih nekoliko godina. Da bi se ispitali potencijalni učinci mješoviti tokovi prometa moraju se simulirati u različitim prometnim scenarijima. U ovom diplomskom radu napravljen je QL-DVSL (*eng. Q-Learning – Dual Variable Speed Limit – QL-DVSL*) sustav koji postavlja ograničenja brzine na svaku prometnu traku zasebno u simulacijskom okruženju u cestovnom mikroskopskom simulacijskom programu SUMO (*eng. Simulation of Urban MObility*) i programskom okruženju Python. Dobiveni rezultati dokazuju da povećanje udjela autonomnih vozila u prometnom toku djeluje pozitivno, odnosno vožnja se odvija sinkroniziranije, promet se odvija jednolikom brzinom, vrijeme putovanja se smanjuje, postignuta je veća brzina u prometnom toku i smanjena je gustoća vozila čime se smanjuju repovi čekanja.

Ključne riječi: upravljanje promjenjivim ograničenjem brzine, ojačano učenje, autonomna vozila, povezana autonomna vozila, inteligentni transportni sustavi

Title: Reinforced Learning based Variable Speed Limit Control for Traffic Flows with Connected Autonomous Vehicles

Summary

Today's motorways are designed to provide a higher maximum traffic capacity, but the problem of insufficient capacity is increasing. However, urban motorways cannot be widened most of the time, thus, it is necessary to look for other solutions to make better use of the existing capacity of urban motorways. One of the systems from the domain of intelligent transportation systems, which can be used for this, is Variable Speed Limit Control (VSLC). Autonomous vehicles (AV) and connected autonomous vehicles (CAV) have been extensively tested and developed rapidly in the last few years. To examine the characteristics of mixed traffic flows, they must be simulated in different traffic scenarios. In this thesis, a QL-DVSL (Q-Learning – Dual Variable Speed Limit) system that sets separate speed limits on each lane in a simulation environment was created in the road microscopic simulation program SUMO (Simulation of Urban MObility) and the Python programming environment. The obtained results prove that the increase in the share of AV in the traffic flow has a positive effect, i.e., driving is more synchronized, traffic proceeds at a uniform speed, driving time is reduced, and a higher speed has been achieved in the traffic flow, the density of vehicles is reduced, which reduces waiting in queues.

Key words: reinforcement learning, variable speed limit control, autonomous vehicle, connected autonomous vehicles, intelligent transport systems

Sadržaj

1. Uvod.....	1
2. Značajke umreženih autonomnih vozila	3
2.1. Klasifikacija autonomnih vozila.....	5
2.2. Tehnologije u autonomnim vozilima	7
2.3. Umrežena autonomna vozila.....	9
3. Problem upravljanja promjenjivim ograničenjem brzine.....	11
4. Primjena ojačanog učenja u upravljanju promjenjivim ograničenjem brzine.....	16
4.1. Algoritam Q-učenja.....	17
4.2. Algoritam SARSA.....	19
4.3. Algoritam učenja zasnovan na principu duboke Q-mreže	20
4.4. Algoritam učenja zasnovan na principu dualne duboke Q-mreže.....	21
4.5. Primjena ojačanog učenja u upravljanju promjenjivim ograničenjem brzine u okruženju mješovitih tokova	22
5. Značajke simulacijskog okruženja	24
5.1. Povezivanje Python i SUMO	26
5.2. Simulacijski model.....	27
6. Simulacijski rezultati.....	30
6.1. TTS i MTT	30
6.2. Gustoća i brzina na prometnoj dionici	34
7. Zaključak.....	38
Popis kratica	39
Popis literature.....	41
Popis slika	44
Popis tablica	45
Popis grafikona.....	46

1. Uvod

U današnje vrijeme javlja se velika potreba za rješavanjem sve većih dnevnih migracija ljudi u gradovima. Uz povećanje osobnih vozila i rasta prometa u gradovima [1], jedno od rješenja su gradske autoceste koje se grade jer gradske prometnice stvaraju mrežu koja ne može postići zadovoljavajuću razinu usluga koja bi zadovoljila sve veću prijevoznu potražnju. Današnje autoceste dizajnirane su za pružanje većeg maksimalnog prometnog kapaciteta, odnosno prometnice imaju višu razinu uslužnosti (*engl. Level of Service – LoS*) u usporedbi s drugim cestama, te javlja se sve veći problem premalog kapaciteta istih.

Najveći manjak kapaciteta prometnica javlja se tijekom vršnih sati kada najčešće dolazi do preopterećenja, a najčešće se javljaju kod gradskih autocesta s velikim brojem bliskih ulaznih i izlaznih rampi. Ulazne i izlazne rampe povezane su s obližnjim gradskim područjem, te su time generatori velike prijevozne potražnje prema kapacitetu glavnog toka autoceste. Međutim, gradske autoceste se najčešće ne mogu širiti, stoga je potrebno tražiti druga rješenja kako bolje iskoristiti gradske autoceste. Zbog toga se koriste upravljački i nadzorni sustavi iz domene inteligentnih transportnih sustava (ITS) sa ciljem postizanja veće razine uslužnosti gradskih autocesta.


Jedan od servisa ITS-a je sustav za upravljanje promjenjivim ograničenjem brzine (*eng. Variable Speed Limit Control - VSLC*). Svrha VSLC-a je promjena ograničenja brzine na prometnom toku, odnosno gradskim autocestama kako bi se spriječila ili ublažila prometna zagušenja i smanjilo vrijeme putovanja određenom dionicom. Autonomna vozila (*eng. Autonomous vehicle - AV*) i umrežena autonomna vozila (*eng. Connected Autonomous Vehicles – CAV*) uvelike se testiraju i brzo razvijaju u posljednjih nekoliko godina. S razvojem i sve većim brojem AV i CAV nastaju mješoviti prometni tokovi koje je potrebno analizirati uključujući njihov utjecaj na sigurnost prometa, protok, brzinu, potrošnju goriva i emisije. Također, potrebno je razviti odgovarajuće algoritme za upravljanje prometom prije nego što se mogu u potpunosti implementirati i integrirati u prometno okruženje. Da bi se to postiglo, takvi mješoviti tokovi prometa moraju se simulirati u različitim prometnim scenarijima.

U ovom diplomskom radu napravljen je QL-DVSL (*eng. Q-Learning – Dual Variable Speed Limit – QL-DVSL*) sustav koji postavlja ograničenja brzine na svaku prometnu traku zasebno u cestovnom mikroskopskom simulacijskom programu SUMO (*eng. Simulation of Urban MObility*) i programskom okruženju Python. Svrha ovog diplomskog rada je pružiti uvid

u okruženje za simulaciju sustava VSLC-a, te se vrši provjera i testiranje upravljačkog algoritma zasnovanog na dubokom učenju. Rad je podijeljen u 7 poglavlja. Nakon uvodnog, u drugom poglavlju opisane su značajke AV-ova i CAV-ova. Treće poglavlje opisuje problematiku upravljanja promjenjivim ograničenjem brzine. U četvrtom poglavlju opisana je primjena ojačanog učenja u upravljanju promjenjivim ograničenjem brzine, te odabrani algoritmi ojačanog učenja. U petom poglavlju dane su značajke simulacijskog okruženja, odnosno značajke cestovnog mikroskopskog simulacijskog programa SUMO i programskog jezika Python s pripadnom razvojnom okolinom, te na koji način su povezani sa simulacijskim modelom. U šestom poglavlju dan je prikaz dobivenih rezultata tijekom izvršenih simulacija te njihova analiza. U sedmome poglavlje nalazi se zaključak u kojemu je iznesena dobivena spoznaja u izradi diplomskog rada.

2. Značajke umreženih autonomnih vozila

AV može vidjeti svoju okolinu, izmjeriti njeno stanje, te upravljati vozilom samostalno bez pomoći vozača. Tu mogućnost postiže koristeći razne tehnologije poput: RADAR-a (*eng. Radio Detecting and Ranging*), LIDAR-a (*eng. Light Detection and Ranging*), sonara, GPS-a (*eng. Global Positioning System*), računalnog vida itd. Pomoću prikupljenih podataka, a koristeći razne tehnologije, napredni upravljački sustavi u vozilima obrađuju prikupljene podatke i pomoću njih identificiraju okolinu, prepreke na koje nalaze, ostala vozila, prometne znakove i druge sudionike u prometu. AV-ovi u principu koriste umjetnu inteligenciju (*eng. Artificial Intelligence - AI*). Simboličan prikaz mogućnosti mjerenja vozila stanja u svojoj okolini prikazana je na slici 1.



Slika 1. CAV-ovi u prometnoj okolini


Izvor: [2]

Uvođenjem AV-a u prometne tokove u gradovima razvija se potreba za gradnjom mreže pametnih osjetila oko prometnica s kojima CAV mogu komunicirati. Na primjer, osjetila oko prometnice imaju mogućnosti registriranja oštećenja prometnice, zastoja, nepoznatih objekata na cesti, poledica na cesti i slično. Potpuno AV ima mogućnost prikupljanja takvih podataka i prema njima može nastaviti i planirati vožnju. Ovakvu komunikaciju, odnosno prikupljanje podataka moguće je usporediti s vožnjom čovjeka dok koristi navigaciju. Vozač upravlja vozilo i koristi navigaciju na nekom putovanju. Usred putovanja javlja se navigacija te obavještava vozača o nesreći na autocesti i da se događa zastoj. Navigacija pronalazi novu rutu kako bi se putovanje nastavilo i izbjeglo čekanje ispred mjesta nesreće. Međutim vozač je u ovome slučaju

taj koji odlučuje kojim putem će nastaviti svoje putovanje, dok kod AV-a takvu odluku donosi umjetna inteligencija [2].

Glavna karakteristika AV više nije kao kod običnih vozila na samome motoru, već na programskim sustavima te njihovoj razini mogućnosti. Tehnologije su primarne u AV, stoga i pokreću samo vozilo. Tehnologije su pogodne reprogramiranju i ažuriranju korištenjem ojačanog učenja i time se poboljšava vozno ponašanje samog vozila. Ranije je spomenuta komunikacija između AV i osjetila oko prometnice, međutim moguća je komunikacija između više AV koji se kreću u istome ili suprotnom smjeru. Izmjenom podataka razvija se veća razina sigurnosti, ugodnije putovanje i moguće je smanjenje putovanja [3].

Međutim nisu sva vozila potpuno autonomna. Njihova autonomnost ovisi o upravljačkim sposobnostima samog vozila, odnosno potrebom za čovjekom kao vozačem. Međunarodna udruga automobilskih inženjera (engl. *Society of Automotive Engineers International* - SAE) 2014. godine izdala je klasifikaciju AV u šest razina u rasponu od razine 0 (bez automatizacije vožnje) do razine 5 (potpuna automatizacija). Klasifikacija AV i uloga vozača u vožnji prikazana je na slici 2 [4].



Slika 2. Klasifikacija AV

Izvor: [4]

2.1. Klasifikacija autonomnih vozila

Već je spomenuto da se klasifikacija AV vrši u 6 kategorija (razina 0 – 5). U prve tri razine (razina 0-2) potrebna je uloga čovjeka kao vozača dok u druge tri (razina 3-5) nije potrebna uloga čovjeka kao vozača. Što je veća razina autonomnosti, to je uloga vozača manja, odnosno uloga upravljanja umjetne inteligencije AV postaje veća. Na slici 3. prikazano je uloga vozača i umjetne inteligencije vozila u svrhu uparivanja vozilom, te se nadalje objašnjava klasifikacija prema [5], [6], [7].

RAZINA AUTONOMIJE VOŽNJE

Što čovjek u vozačkom sjedalu mora raditi?

SAE RAZINA 0

SAE RAZINA 1

SAE RAZINA 2

SAE RAZINA 3

SAE RAZINA 4

SAE RAZINA 5

Upravljaate vozilom iako su uključene funkcije pomoći vozaču - čak i ako vaša stopala nisu na pedalama i ne držite volan

Morate stalno nadzirati ove funkcije pomoći; morate upravljati, kočiti ili ubrzavati prema potrebi kako biste održali sigurnost

Ne upravljate vozilom kada su uključene automatske funkcije pomoći vozaču - čak i ako sjedite u 'vozačkom sjedalu'

Kada funkcije zahtijevaju, morate voziti

Ove automatske funkcije ne zahtijevaju da preuzmete volan

OVE FUNKCIJE PODRŽAVA VOZAČ

OVO SU AUTOMATSKE FUNKCIJE

Što rade te funkcije

Ove funkcije su ograničene na pružanje upozorenja i trenutnu pomoć

Ove funkcije omogućuju upravljanje ILI pomažu vozaču da koči/ubrzava.

Ove funkcije omogućuju upravljanje I pružaju pomoć vozaču pri kočenju/ubrzavanju

Ove funkcije mogu upravljati vozilom u ograničenim uvjetima i neće raditi ako oni nisu zadovoljeni

Ova funkcija može upravljati vozilom u svim uvjetima

Primjer funkcija

• automatska kočnica u slučaju nužde

• upozorenje na mrtvi kut

• upozorenje na napuštanje vozne trake

• funkcija držanja vozne trake

ILI

• prilagodljivi tempomat

• funkcija držanja vozne trake

I

• prilagodljivi tempomat u isto vrijeme

• vozač u prometnim gužvama

• lokalni taxi bez vozača

• pedale/volan mogu ili ne moraju biti ugrađeni

• isto kao razina 4, ali funkcije mogu upravljati svugdje u svim uvjetima

Slika 3. Uloga vozača i umjetne inteligencije vozila u svrhu uparivanja vozilom

Izvor: [6]

Razina 0 je razina bez ikakve automatizacije vozila. Vozač posjeduje potpunu kontrolu nad vozilom, dok sustav ne sudjeluje u nikakvim radnjama koje utječu na vožnju. Sustavi razine 0 dostupni su gotovo u svim novim vozilima. Takvi upravljački sustavi su sustavi za: detektiranje vozila u mrtvom kutu, upozorenja o napuštanje prometne trake, detektiranje vozila ispred i dr. Takvi sustavi samo signaliziraju vozača te je na taj način dobivana veća razina sigurnosti vožnje, zbog čega se ovi sustavi nazivaju sustavi razine 0 jer ne upravljaju vozilom.

Razina 1 je razina pomoći vozača. Vozač i dalje samostalno upravlja vozilom, međutim sustav ima mogućnost mijenjanja brzine i smjer upravljanja vozila. Sustavi koji spadaju u razinu 1 su prilagodljivi tempomat (*eng. Adjustable Cruise Control - ACC*), elektronička kontrola stabilnosti (*eng. Electronic Stability Control - ESC*), pomoć pri kočenju u nuždi (*eng. Emergency Brake Assist - EBA*) ili pomoć pri održavanju trake (*eng. Lane Keep Assist - LKA*). Razina 1 podrazumijeva da ugrađeni sustavi mogu ponekad preuzeti dio kontrole nad upravljanjem vozila, te spadaju u najnižu razinu automatizacije. Vozač i dalje ima glavnu ulogu za upravljanjem vozila.

Razina 2 smatra se djelomičnom automatizacijom vožnje. Vozač više ne mora nužno upravljati vozilom jer upravljanje se odvija zajedničkim radom dva ili više autonomnih sustava. U ovu kategoriju može se svrstati korištenje dviju tehnologija poput vožnje unutar prometne trake i prilagodljiv tempomat. Na taj način vozilo je sposobno samostalno ubrzavati i usporavati, te kretati se unutar prometne trake. Međutim, vozač i dalje mora u svakome trenutku analizirati vožnju te sukladno time reagirati u vožnji.

Razina 3 smatra se uvjetovanom automatizacijom. Skok s razine 2 na razinu 3 je značajan iz tehnološke perspektive. Glavni razlog je taj što sustav ima potpunu kontrolu funkcija vozila kao što su brzina vozila, nadzor i upravljanje okoline u određenim uvjetima. Vozila razine 3 imaju mogućnost „otkrivanja stanja okoline“ i mogu sama donositi upravljačke odluke. Primjer takvog sustava je ubrzavanje pored vozila koji se sporo kreće, međutim sustav i dalje zahtjeva ljudsku intervenciju ukoliko je potrebno. Vozač mora ostati oprezan i spreman preuzeti kontrolu ako sustav samostalno ne može izvršiti zadatak. Razina 3 je prva razina u kojoj vozilo može samostalno upravljati samim sobom. Na današnjem tržištu moguće je pronaći vozila razine 3 koja se mogu sigurno koristiti na svim prometnicama.

Razina 4 je visoka automatizacija vožnje. Ključna razlika između vozila razine 3 i 4 je u tome što vozila razine 4 mogu intervenirati ukoliko dođe do kvara sustava ili određenih incidentnih situacija. U takvim slučajevima automobili razine 4 ne zahtijevaju ljudsku intervenciju, ali vozač i dalje ima mogućnost preuzimanja kontrole nad upravljanjem. Vozila mogu raditi samostalno ali dok se zakonodavstvo i infrastruktura ne razvije, njihovo korištenje moguće je samo na određenim geografskom području (*eng. geofencing*). Na primjer NAVYA je francuska kompanija koja već gradi vozila razine 4 u SAD-u koja se u potpunosti pogone na električnu energiju i mogu postići brzinu do 90 km/h [5].

Razina 5 smatra se najvećom automatizacijom vozila stoga se zove i potpuna automatizacija (autonomija). Takva vozila ne zahtijevaju ljudsku pozornost. Odnosno eliminira se dinamički zadatak vožnje. Vozilo razine 5 neće ni imati mogućnost upravljanje vozača jer vozilo neće imati upravljač niti papučice za ubrzavanje i usporavanje. Takva vozila bit će oslobođena upravljanja samo po određenom geografskom području te će imati sve sposobnosti koje je moću sa čovjekom kao vozačem. Danas se znatno razvijaju i testiranju vozila razine 5, ali takva vozila još nisu dostupna široj javnosti niti su u komercijalnoj upotrebi.

2.2. Tehnologije u autonomnim vozilima

Ranije je spomenuto korištenje raznih tehnologija u AV. Neke od tehnologije su: RADAR, LIDAR, sonar, GPS, računalni vid itd. Pomoću navedenih tehnologija, AV je svjesno svoje okoline te pomoću umjetne inteligencije sudjeluje u ili vrši upravljanje vozilom. Na taj način AV pridržavaju su prometnih pravila i mogu izbjeći opasne situacije u prometu. Arhitekturu upravljačkog sustava autonomnog moguće je podijeliti u četiri dijela koja čine: osjetilnih/mjernih sustava, akcijskih sustava, klijentskih sustava i korisničkih sustava [8].

Osjetilni/mjerni sustavi imaju ulogu prikupljanja podataka iz okoline vozila te se sastoje od više sustava koji rade zajedno. Prikupljeni podatci koriste se za: navigaciju, planiranje rute, percepciju, izračunavanje udaljenosti prepreka itd. Osjetila upravljačkog sustava AV je moguće podijeliti u dvije grupe. Prva grupa su osjetila kratkog dometa kao što su infracrvena osjetila, ultrazvučna osjetila. Druga grupa su osjetila dugog dometa poput kamera, LIDAR-a, RADAR-a i GPS-a.


Računalni vid je tehnologija koja služi za dobivanje informacije iz jedne ili više fotografija odnosno video zapisa. Kao osjetilo se koristi mono ili stereo kamera. Glavni cilj je detekcija objekata, praćenje objekata, prepoznavanje unaprijed zadanih događaja itd. AV koriste veći broj kamera čija je svrha prepoznavanje objekata, praćenje smjera vozila, očitavanje svjetlosnih signala. Međutim kamere za korištenje računalnog vida još uvijek ne mogu percipirati vizualne situacije kao ljudsko oko [9].

LIDAR (*eng. Light Detection and Ranging*) sustav određuje udaljenost pojedinih prepreka od vozila. Princip rada je emitiranje svjetlane zrake i izračunavanje vremena koje je potrebno da bi se vratila refleksija od pojedinog objekta. Prednost ovog sustava je preciznost rada i u otežanim vremenskim uvjetima što nije uvijek primjer kod računalnog vida. Prilikom detekcije pojedinog objekta stvara se detaljna trodimenzionalna mapa okoline pomoću koje AV raspozna je različite objekte i ostale sudionike u prometu. Međutim, nedostatak sustava je što nije uvijek pouzdan na većim udaljenostima [9].

RADAR (eng. *Radio Detecting and Ranging*) sustav koristi radiovalove. Sustav je odličan za detekciju metalnih objekata, ali nemetalne objekte je nemoguće registrirati. Sustav radi na principu slanja radiovalova i registriranja povratne reflektirajuće informacije radio iz okoline. Sustav je postavljen po cijelom vozilu, te zaprimanjem reflektirajućeg signala sustav dobiva informaciju o udaljenosti objekta ili prepreke. Također moguće je dobiti i informaciju kolikom brzine se objekt kreće i na taj način se prati brzina drugih vozila [9].

GPS (eng. *Global Positioning System - GPS*) je sustav za lokalizaciju, odnosno otkrivanje pozicije objekta u prostoru. GPS sustavi u vozilu primaju signale sa satelita koji se nalaze u Zemljinj orbiti. Koordinate GPS koje prima vozilo. Umrežene su sa cestovnim mapama i na taj način se vozilo lokalizirana na određenoj prometnici.

Ultrazvučna osjetila su osjetila koja pružaju precizne informacije iz okoline kratkoga dometa, dok su infracrvena osjetila pogodni za pružanje informacije po noći bez osvjetljenja prometnice. Na slici 4 prikaz je položaj nekih mjernih sustava na AV.



Slika 4. Položaj osjetila na AV


Izvor: [10]

Klijentski sustavi je sustav u AV koji obrađuje sve prikupljene podatke iz okoline, te odlučuje o daljnjim akcijama. Klijentski sustav je zapravo mozak AV. Informaciju o odlukama i daljnjim akcija šalju se prema izvršnim članovima. Oni izvode naredbe koje mu zadaje klijentski sustav, a čine ga mehanički dijelovi AV (pogonski i kočioni sustav, sustav upravljanja

itd.). Korisnički sustav služi kao komunikacija između korisnika i AV. AV komunicira s vozačem o prikupljenim podacima iz okoline i ukazuje mu na izvršavanje radnji, dok vozač također može zadati vozili radnju koju želi izvršiti [9].

2.3. Umrežena autonomna vozila

Postizanje punog potencijala autonomnih vozila ostvaruje se pomoću komunikacije. CAV je AV koje može komunicirati: međusobno (*eng. Vehicle to Vehicle – V2V*), s infrastrukturom (*eng. Vehicle to Infrastructure – V2I*), s internet mrežom (*eng. Vehicle to Network – V2N*), s električnom mrežom (*eng. Vehicle to Grid – V2G*), s mobilnim uređajem (*eng. Vehicle to Device – V2D*), s pješacima (*eng. Vehicle to Pedestrian – V2P*). Sve navedene komunikacije čine okolinu vozila sa kojom vozilo komunicira (*eng. Vehicle to Everything V2X*) što je prikazano na slici 5 [11].




Slika 5. Komunikacija vozila i okoline V2X

Izvor: [12]

V2I je neophodna za upravljanje prometom i koordinacijom CAV-ova. Nadzorni sustavi, koji su instalirani na prometnoj infrastrukturi, prikupljaju podatke o stanju prometa, uvjetima kolnika, prohodnosti prometa itd. Prikupljeni podatci analiziraju u stvarnom vremenu u centru za upravljanjem prometa, te se koriste u modelima protoka prometa i primjenjuju se za specifične radnje za određenu skupinu vozila. Takve informacije pružaju se vozilima putem semafora i promjenjivih znakovnih poruka pomoću kojih vozač može donositi odluke. Međutim

takve informacije moguće je prenositi izravno CAV-u, te vozilo može samo donositi odluku o određenim budućim akcijama u stvarnom vremenu. Na taj način moguća je optimizacija prometa poput optimizacija brzine, razmaka između vozila, izbjegavanja naglog kočenja i sl. [11].

V2V omogućava međusobnu komunikaciju vozila bez potreba za intervencijom centra za upravljanja prometom. CAV, koja su u neposrednoj blizini, razmjenjuju informacije i omogućuju koordinaciju procesa odlučivanja sa ciljem sigurnijeg odvijanja prometa. Na taj način sama vozila postaju i nadzorni elementi prometne infrastrukture. Time se upravljanje prometom oslanja na fuziju podataka iz međusobne komunikacije vozila s infrastrukturom i CAV međusobno kako je prikazano na primjeru na slici 6 [11].



Slika 6. Komunikacija između CAV (V2V)

Izvor: [13]


Komunikacija CAV i okoline (V2X) odnosi se na komunikaciju sa svim mogućim informacijama koje vozilo može primiti. Informacija se može primiti od: komunikacijske mreže, nadzornih elemenata, drugih CAV-ova, drugih sudionika prometa itd. [11].

3. Problem upravljanja promjenjivim ograničenjem brzine

Prometni sustavi svakoga dana postaju sve više opterećeniji, a pogotovo cestovne prometnice u samim gradovima. Gradovi postaju veći, njihova populacija raste, a time se povećava broj vozila. Taj podatak vidljiv je iz državnog zavoda za statistiku. Broj registriranih cestovnih vozila u Hrvatskoj u 2021. godini iznosio je 2.385.442, što je u odnosu na 2020. više za 3,2%, dok je broj registriranih osobnih vozila u Hrvatskoj u 2021. iznosio je 1.795.465, što je u odnosu na 2020. godinu više za 2,8% [1]. Rezultat toga je povećanje prometnih zagušenja zbog čega se vrijeme vožnje i vrijeme čekanja produljuje, te dolazi do smanjenja sigurnosti u prometu. Također povećava se potrošnja goriva i emisija štednih plinova što direktno utječe na zagađenje okoliša. Nažalost razvoj prometnica u gradovima je ograničen zbog urbanističkih planova gradova, stoga se grade gradske obilaznice, odnosno gradske autoceste oko većih gradova [14].

Gradske autoceste pružaju veći prometni kapacitet čime se znatno rasterećuje prometno zagušenje u gradovima. Najbolji primjer za gradsku obilaznicu je Zagrebačka obilaznica. Zagrebačka obilaznica ima veliki broj ulaznih i izlaznih rampi koje su dobro povezane sa gradskim četvrtima. Putovanje od istočnog do zapadnog dijela grada značajno je smanjeno, u odnosu na putovanje urbanim dijelom grada.


U vršnim satima prometna potražnja približava se maksimalnom kapacitetu prometnice, te se u takvim situacijama se razina uslužnosti (*eng. Level of Service - LoS*) smanjuje, a vrijeme putovanja prometnicom se povećava. Na slici 1. prikazano je kako na kvalitetu usluge utječe gustoća prometa (*eng. Traffic density*) i brzina kretanja vozila (*eng. Speed*). Postoji 6 LoS-a koja se označava slovima od A do F. Kvaliteta usluge A, B, C i D računaju se kao stabilnom uslugom te je protok vozila prometnicom prohodan. Kvaliteta usluge E je granica stabilnog protoka, a kada prometna potražnja postaje veća od maksimalnog kapaciteta prometnice, dolazimo do poremećaja u prometnim tokovima, odnosno dolazi do povremenih zagušenja a ponekad i do potpunog zastoja prometa što spada u kvalitetu usluge F [15].



Slika 7. 6 Utjecaj LoS-a

Izvor: [15]

Vrlo je teško uvidjeti kada će doći do zagušenja jer je promet stohastičke prirode zbog ovisnosti o ponašanju sudionika, ali je donekle moguće predvidjeti na kojim mjestima će doći do smanjenja propusnosti. Takve situacije najčešće se događaju na spajanju prometnog toka s ulazne rampe (ulazak na autocestu) i glavni prometni tok (autocesta) što još nazivamo usko grlo. Na slici 8 prikazana je pojava uskog grla u smjeru gibanja prometnog toka (*engl. Downstream Bottleneck*) u samoj blizini ulazne rampe, te se učinak preljeva prometa sa gradske ceste na autocestu. Na dionici autoceste gdje nastaje usko grlo u smjeru gibanja prometnog toka dolazi do stvaranja zagušenja što rezultira stvaranjem šok vala usmjeren suprotno smjeru gibanja prometnog toka, uzduž glavnog toka autoceste suprotnog smjera kretanja glavnog prometnog toka. Rezultat je smanjenje brzine te povećanje vremena putovanja na dionici autoceste čime se smanjuje sigurnost prometa [16].



Slika 8. Mjesto formiranja uskog grla i posljedice preljeva prometa

Izvor: [16]

Prilikom dimenzioniranja kapaciteta autocesta teško je precizno predvidjeti buduće promjene prijevozna potražnje na glavnom toku i pripadajućim priljevnim tokovima. Izgradnja takvih prometnica često privlači i stvaranje novih industrijskih zona i gospodarskih objekata poput tvornica, skladišta itd. Na taj način se smanjuje udio teretnih vozila u gradskoj sredini i stvara se bolja povezanost sa drugim industrijskim zonama, te se povećava prometna potražnja na gradskom autocestom. Izrazito je bitan porast prometne potražnje koja utječe na propusnost glavnog toka na lokaciji prometnice gdje se nalaze ulazne rampe, odnosno mjestu gdje se priljevni tokovi spajaju s glavnim tokom gradske autoceste. Prometna zagušenja najčešća su na mjestima gdje se na malim međusobnim udaljenostima nalazi veliki broj ulaznih i izlaznih rampi. Sami prometni zastoji na autocestama najizraženiji su u ranim jutarnjim i kasnim popodnevnim satima u blizini većih urbanih sredina. Porast problema raste zbog dnevnih migracija na relaciji privatnih i poslovnih obaveza. Tijekom navedenog perioda dolazi do značajnog narušavanja sigurnost prometnih sudionika te je znatno narušena propusnost gradske autoceste [17].

Upravljanje prometom na gradskim autocestama moguće je na osnovi nekoliko kriterija. Jedan od kriterija je sigurnost i upravljanje sigurnošću prometa na autocestama čija uloga počinje imati sve veću važnost. Sljedeći kriterij je upravljanje protočnošću prometa pomoću kojega se smanjuje zagušenje što je ujedno i glavni kriterij u ovome radu. Prilikom upravljanja protočnosti prometa postoje dva glavna problema koja uzrokuju zagušenje. Prvi problem su priljevni tokovi i nehomogene brzine kretanja vozila na glavnom prometnom toku. U slučaju veće potražnje za određenom rutom, u urbanoj sredini, dolazi do zagušenja na ulaznoj rampi te zagušenja na prometnom toku autoceste oko ulazne rampe. Posljedica je produljenje vremena putovanja svim vozilima na pripadnoj dionici autoceste. Prilikom dimenzioniranja kapaciteta autocesta teško je predvidjeti buduću prometnu potražnju na priljevnim tokovima, stoga je potrebno pronaći dodatna rješenja problem korištenjem upravljačkih problema iz domene ITS-a [17].

Pomoću naprednih sustava iz domene ITS-a omogućuje se poboljšanje kvalitete usluge upravljane prometnice. Jedan od sustava je dinamičko upravljanje prometom. Sustav radi na principu trenutne razmjene podataka prikupljenih od osjetila na prometnoj infrastrukturi. Da bi razmjena podataka bila uspješna, potrebna je odgovarajuća informacijsko-komunikacijska infrastruktura pomoću koje se podatci šalju, te se analiziraju i razmjenjuju između korisnika i pružatelja usluga unutar samog sustava. Dinamičko upravljanje prometom koristi dva pristupa

pomoću kojih je moguće upravljati prometom na gradskoj autocesti prilikom povećane prometne potražnje.

Prvi pristup dinamičkog upravljanja prometom jest upravljanje priljevnim tokovima (*eng. Ramp Metering - RM*) i zasnovano je na upravljanju količine vozila na ulaznim rampama koje se priključuju na glavni tok gradske autoceste. Na taj način reguliraju se broj vozila koja se uključuju na prometni tok gradske autoceste (npr. pomoću algoritma ALINEA [18]). Drugi pristup zasniva se na upravljanju promjenjivim ograničenjem brzine odnosno VSLC sustavu (*eng. variable speed limit control - VSLC*). VSLC sustav izmjenom ograničenja brzine na promjenjivim prometnim znakovima (*eng. variable message signs - VMS*) direktno regulira prometni tok vozila na gradskim autocestama. Ovisno o trenutnoj prometnoj situaciji, korištenjem odgovarajućeg prometnog algoritma, moguće je izmjenjivati vrijednosti ograničenja brzine. Zbog povećane prometne potražnje s pristupne rampe stvara se prometno zagušenje te se preopterećuje glavni prometni tok gradske autoceste. Time se stvaraju prometni čepovi gdje dolazi do velike smanjenje sigurnosti jer druga vozila dole većim brzinama do ruba repa čekanja. Nadolazeća vozila moraju naglo smanjivati brzinu kretanja što dovodi do povećanog rizika za prometnom nesrećom, povećanje stresa kod vozača, te se produljuje vrijeme putovanja.

VSLC sustavi se najčešće dijele u dvije grupe [17]: 1. VSLC sustav zasnovan na vremenskim uvjetima; i 2. VSLC sustav zasnovan na zagušenjima. Prvi sustav se koristi na prometnicama gdje se često javljaju nepovoljni vremenski uvjeti poput magle, snijega, leda ili drugih vremenskih uvjeta koji značajno utječu na sigurnost i prohodnost prometnice. Ukoliko se dogodi pogoršanje vremenskih uvjeta do predefiniране kritične točke, ograničenje brzine se smanjuje na prikladnu brzinu pri kojoj je moguće sigurno prometovanje bez incidentnih situacija. Druga vrsta sustava koristi se kada dolazi do povećanja prometnog volumena što bi moglo rezultirati pojavom zagušenja. Ukoliko dođe do povećanja volumena odnosno gustoće prometnog toga do predefiniране granice, aktivirat će se upravljačka strategija koja smanjuje ograničenje brzine. Smanje brzine je moguće na dva načina. Smanjenje algoritmom upravljanja koji je unaprijed definiran ili se smanjuje ručno preko centra za upravljanje autocestom. U ovome radu se analizira automatski pristup promjene ograničenja brzine na lijevoj i desnoj traci zasebno koji je zasnovan na upravljačkoj logici primjenom algoritma zasnovanog na ojačanom učenju.

Glavni operativni razlozi uvođenja VSLC sustava na autocesti su [19]: smjenjivanje vremena potrebnog za putovanje, pouzdanije vrijeme potrebno za putovanje, ujednačeniji vremenski interval slijednih vozila, povećanje iskorištenost prometnih traka, smanjivanje količine pada prosječne brzine glavnog toka, smanjivanje emisije ispušnih i štetnih plinova, smanjivanje broja incidentnih situacija.

4. Primjena ojačanog učenja u upravljanju promjenjivim ograničenjem brzine

Uz značajni napredak računalne tehnologije koja iz dana u dan i dalje napreduje, značajan broj istraživačkih radova vezanih za dinamičko upravljanje prometnim tokovima zasnivaju se na obradi velikih brojeva ulaznih podataka u realnom vremenu pomoću računalne tehnologije. Također računalno istodobno ima mogućnost prilagodbe i učenja prilikom raznih metoda primjene dinamičkog upravljanja. Jedan od glavnih razloga primjene računala kod rješavanja problematike zasnovano je na činjenici da se znanstvena zajednica i struka sve više pažnje pridodaje proučavaju „zadovoljavajuća“ rješenja koja su najčešće i približna točnim rješenjima. Razvijanje tehnologije razvijeno je i nekoliko metoda pomoću kojih računalo pronalazi rješenja. Jedna od metoda je metoda ojačanog učenja. Ojačano učenje može se definirati kao više algoritama koji izravno uče iz interakcije s okolinom. Okolina može biti razna poput računalne simulacije do stvarnog svijeta. Princip učenja agenta definira se kao kod čovjeka u stvarnom životu temeljem analiza posljedica svojih akcija a ne striktno unaprijed definiranim pravilima i formulama.

Postoji više metoda ojačanog učenja, a najznačajnije metode su:

- Q-učenje (*eng. Q-learning*),
- SARSA algoritam,
- Učenje duboke Q mreže (*eng. Deep Q-network - DQN*),
- Učenje dualne duboke Q-mreže (*eng. Dual Deep Q-network - DDQN*).

Ojačano učenje (*eng. Reinforcement Learning - RL*) je grana strojnog učenja gdje sustavi sam uči pomoću podataka prikupljenih iz okoline tijekom njegovog rada. Osnovna razlika klasičnog strojnog učenja i ojačanog učenja je u tome što je agent kod RL-a sposoban samostalno učiti za vrijeme svog rada dok se klasično strojno učenje zasniva na nadziranom učenju. Agent ojačanog učenja uči iz vlastitih iskustava pomoću metode pokušaj pogreška, odnosno temeljem dobivenih rezultata iz okoline. Glavni cilj učenja agenta je povećanje kumulativne nagrade tijekom njegovom učenja u određenom okruženju. Povratna informacija koju agent prima nakon izvršene akcije zapravo je nagrada [17].

Okolina odnosno model unutar kojega se nalazi agent opisna je, odnosno pretpostavlja se da ima svojstva Markovljevog procesa odlučivanja (*eng. Markov Decision Process - MDP*). Proces je definiran kao skup stanja i akcija koje se mogu izvršiti sa ciljem upravljanja okolinom. Praktični problemi poput hoda robota, balansiranja i upravljanja bespilotnih letjelica mogu se

definirati kao MDP. Učenje u kojemu je model okoline poznat naziva se učenje zasnovano na modelu (*eng. Model-Based Learning*) [20].

Postoje slučajevi kada okolina odnosno pripadni model nije poznat, te se takav način učenja naziva učenje bez modela (*eng. Model-Free Learning*). Takvi sustavi uče optimalni zakon upravljanja na osnovi iskustava na način da se nakon primjene akcije dobiva nagrada. Prethodno spomenuti praktični problemi ne mogu se uvijek opisati kao MDP zbog složenosti dinamike okoline. Umjesto toga opisani su prikupljanjem raznih uzoraka koji su stečeni iskustvom agenta iz neposredne okoline [20].

Neki od osnovnih elemenata koji opisuju proces ojačanog učenja, opis modela i nagrade u ojačanom učenju su:

- Model okoline koji reagira na poduzete akcije,
- Agent,
- Stanja koja opisuju agenta,
- Strategija odabira akcija ili politika,
- Akcije koje agent poduzima,
- Funkcija prijelaza,
- Funkcija vrijednosti ili za predviđanje budućih nagrada,
- Funkcija nagrade,

4.1. Algoritam Q-učenja

Algoritam Q-učenja predstavlja učenje bez korištenja modela (*engl. off-policy learning*). Q-učenje se zasniva na zapisivanju određenih vrijednosti u tablicu, te se na temelju zapisanih vrijednosti, agent bira sljedeće akcije koje će izvršiti. Ako agent obiđe svaki par akcija i stanja beskonačno puta, tada se prema [20] algoritam Q-učenja konvergira prema optimalnoj funkciji akcija i stanja (*eng. action-state*) (1):

$$Q(s,a) \rightarrow q^*(s,a), \quad (1)$$

gdje su:

- Q - takozvana Q-matrica,
- q - vrijednosti stanja i akcije,
- s - pojedino stanje,
- a - akcija.

Na slici 9 prikazan je princip Q-učenja te primjer Q-tablice gdje je vidljivo da su stanje (*eng. State*) i akcija (*eng. Action*) definirani kao ulazni parametri. Rezultat se zapisuje u Q tablici (*eng. Q Table*) te se dobiva Q vrijednost (*eng. Q-Value*).

Q(s,a)		Akcija (a)					
		0	1	2	3	4	...
Stanje (s)	0	0,2567	0,9865	0,4589	0,0035	0,0036	0,4502
	1	0,3679	0,4563	0,1687	0,2596	0,4921	0,4702
	2	0,1359	0,0305	0,0302	0,5746	0,4732	0,4732
	3	0,0356	0,0569	0,5698	0,9863	0,8961	0,4125
	4	0,4589	0,4896	0,1496	0,5463	0,7324	0,1234
	5	0,6002	0,2489	0,1483	0,2893	0,9675	0,3561
	...	0,0356	0,1459	0,0205	0,4963	0,4523	0,2486

Slika 9. Primjer Q-tablice

Model okoline kod ovoga algoritma nije potrebno poznavati, već informacije o okolini agent zaprima preko nagrada ili kazni u smislu povratne veze reakcija okoline na poduzetu akciju. Također, kod Q-učenja, agent može učini promatranjem drugih agenta prilikom izvođenja njihovih akcija. Agent ima mogućnost učenja i na temelju svog iskustva stečenih iz prijašnjih upravljačkih zakona u svrhu unaprijeđenja učenja. Algoritam Q-učenja posjeduje sposobnost istraživanja i istovremenog učenja optimalne politike. Proces ažuriranja Q-funkcije kod primjene Q-učenja dan je izrazom (2) [21]:

$$Q(s,a) \leftarrow Q(s,a) + \alpha (r + \gamma \max_{a'} Q(s',a') - Q(s,a)), \quad (2)$$


gdje su:

- Q - takozvana Q-matrica,
- α - koeficijent učenja,
- r - predstavlja trenutnu nagradu,
- $\gamma \max_{a'}$ - faktor najveće moguće nagrade,
- s' - je novo stanje,
- a' - predstavlja novu akciju iz stanja s' .

Algoritam Q-učenja nakon odabrane akcije a i preslikavanja na osnovi odabrane akcije u iduće novo stanje $s \rightarrow s'$, gleda još korak unaprijed sa svrhom odabira odgovarajuće akcije a' koja daje najveću nagradu za idući korak. Na osnovi prethodna dva koraka ažurira se vrijednost

Q funkcije za akciju a i stanje s . Međutim, algoritam nije nužan uvijek slijediti optimalni upravljački zakon iz stanja s' , već je bitno samo osvježavanje Q funkcije na poziciji $Q(s,a)$ s tim vrijednostima

Regulator koji služi za upravljanje ograničenja brzine poistovjećuje se sa agentom u ojačanom učenju. Prometni tok u kojoj agent vrši djelovanje predstavlja model okoline. Stanja su osnovne veličine pomoću kojih se opisuje prometni tok. Akcije su definirane kao izvršne brzine ograničenja kojima upravlja agent te ih šalje brzine na VMS-ove. Agent može odabrati pojedinu akciju iz skupa konačnih akcija za svako stanje okoline. Ovisno o odabranoj akciji okolina se mijenja te agent dolazi u novo stanje i time agent dobiva povratnu informaciju, ovisno o odabranoj akciji, u obliku nagrade čija visina ovisi o kvaliteti njegove poduzete akcije. Na slici 10. prikazan je proces.



Slika 10. Prikaz odnosa stanja okoline i povratne veze akcija

Izvor: [22]

4.2. Algoritam SARSA

SARSA algoritam predstavlja „on-policy“ algoritam učenja koji je zasnovan na Q funkciji. Idealna politika odgovara učenju Q funkcije, stoga odgovara učenju i njene vrijednosne funkcije korisnosti. Proces iterativnog učenja Q funkcije zasniva se samo o trenutnom stanju agenta i poduzetoj akciji. Dobivene vrijednosti bilježe se i osvježavaju u takozvanoj Q-matrici. Izrazom (3) prikazan je iterativni proces kod SARSA algoritma[21]:

$$Q(s,a) \leftarrow Q(s,a) + \alpha (r + \gamma Q(s',a') - Q(s,a)), \quad (3)$$

gdje su:


- Q - takozvana Q-matrica,
- r - predstavlja trenutnu nagradu,

- α - koeficijent učenja,
- γ - faktor odgode nagrade,
- s' - je novo stanje,
- a' - predstavlja novu akciju iz stanja s' .

Za razliku od algoritma Q-učenja, SARSA algoritam iz stanja s' odabire akciju a' te ažurira $Q(s,a)$. U novoj iteraciji slijedi tu istu akciju a' .

4.3. Algoritam učenja zasnovan na principu duboke Q-mreže

Algoritam učenja duboke Q-mreže (eng. *Deep Q-network - DQN*) koristi neuronske mreže (eng. *Convolutional Neural Network - CNN*) za aproksimaciju vrijednosti Q funkcije odnosno Q-tablice stanja i akcije. Neuronska mreža kod duboke Q-mreže ima ulogu naučenog preslikavanja akcije i stanja i time ima izravno djelovanje na okolinu. Promatranjem trenutnog stanja okoline i pomoću prikupljenih podataka donosi odluku koja akcija će biti poduzeta na osnovi trenutnog stanja iz dosadašnjih iskustava. Prema poduzetim akcijama, agent dobiva nagradu čija visina određuje kvalitetu poduzetih akcija s obzirom na rješavanje zadanog stanja. Glavni cilj agenta je učenje poduzimanja akcija u raznim okolnostima koje će maksimizirati akumuliranu nagradu tijekom vremena [23]. Stanje (eng. *State*) je dano kao ulaz, a vrijednost Q-funkcije (eng. *Q-Value Action*) generirana je kao izlaz što je prikazana na slici 11.



Slika 11. Prikaz funkcije dubokog Q-učenja

Izvor: [24]

Nagrada efektivno ocjenjuje kvalitetu djelovanja agenta. Upravljački zakon je taktika koju agent koristi za odabir iduće akcije na osnovi trenutnoga stanja. Time se preslikavaju stanja u akcije, odnosno radnje koje obećavaju najveću moguću nagradu kao cilj djelovanja. Matematički gledano, naučeni upravljački zakon odnosi se na distribuciju u svih radnji danih

pomoću upravljačkog zakona [25]. Pravilo koje određuje preslikavanje iz stanja s u akciju a koju agent mora poduzeti dano je izrazima:

$$a = \pi(s), \quad (4)$$


$$\pi(a|s) = \mathbb{P}[A_t=a|S_t=s], \quad (5)$$

gdje su:

- A – označava skup akcija,
- a – je pojedina akcija,
- s – je pojedino stanje,
- S – je skup svih stanja,
- π – je funkcija upravljačkog zakona.

4.4. Algoritam učenja zasnovan na principu dualne duboke Q-mreže

Algoritam učenja na principu dualne duboke Q-mreže je algoritam ojačanog učenja koji ima mogućnost učenja Q-vrijednosti iz dva procjenitelja funkcije. Jedan procjenitelj funkcije služi za procjenu funkcije prednosti, dok drugi procjenitelj služi za procjenu funkcije vrijednosti. Za izračunavanje vrijednosti određenog ulaza zadužena je funkcija vrijednosti, dok nagradu na osnovi izvršene akcije zadužena je je funkcija prednosti. Zajedno dvije funkcije pružaju značajnu uspješnost procjene sljedećeg ulaza s obzirom na sljedeći par stanja i akcije. Dodana prednost DDQN algoritma je učenje koji ulazi su vrijedni, za razliku od Q-mreže koja uči iz posljedica reakcije svakog ulaza. Ovaj način ima veliku prednost jer za puno ulaza postupci ne određuju ishod, te algoritam bolje razumije koji ulaz je bolji u stvarnom vremenu, a ne tek nakon više akcija. Time se dolazi do toga da dualna mreža pokazuje znatno bolje rezultate od pojedinačnih mrežnih struktura. Kao DQN. Razlog tome je taj što se svaki procjenjivač funkcije može usredotočiti na različiti dio slike koristeći drugačije strategije za kreiranje boljeg procjenitelja za Q funkciju [25]. Na slici 12 prikazana su dva procjenitelja funkcija, odnosno kako funkcija prednosti i funkcija vrijednosti imaju mogućnost zajedničkog učenja.



Slika 12. Prikaz funkcije dubokog Q-učenja

Izvor: [26]

Q-vrijednosti odgovaraju koliko je dobro biti u narednom stanju i poduzeti akciju u tom stanju $Q(s,a)$. Prema izrazu (6) $Q(s,a)$ može se rastaviti kao zbroj:

- $V(s)$ – procjena Q-vrijednosti u pripadnom stanju,
- $A(s,a)$ - nagrada za poduzimanje akcije u stanju (koliko je bolje poduzeti narednu akciju u odnosu na sve druge moguće akcije u stanju).

$$Q(s,a) = A(s,a) + V(s) \quad (6)$$

Pomoću DDQN-a dolazi do odvajanja neuronskih mreža koji procjenjuje dva elementa na dvije neuronske mreže. Jedna koja procjenjuje vrijednost stanja $V(s)$ i druga koja procjenjuje nagradu za svaku akciju $A(s,a)$. Zbog razdvajanja dobiva se mogućnost izračunavanja $V(s)$ što je korisno za sva stanja u kojima njihove akcije ne utječu na okolinu na odgovarajući način, zbog čega nije potrebno izračunavati vrijednost svake akcije.

4.5. Primjena ojačanog učenja u upravljanju promjenjivim ograničenjem brzine u okruženju mješovitih tokova

Dosadašnjim istraživanjima analizirano je kako utječe ojačano učenje s dvije različite funkcije nagrađivanja na makroskopske prometne parametre, ukupnu potrošnju energije i ispušne plinove emisije plinova za različite prometne scenarije stope penetracije CAV [27]. Glavni cilj bio je ukupno smanjenje potrošnje goriva i emisije ispušnih plinova. U tom smislu rezultati ovog istraživanja doprinosi razvoju metoda upravljanja koje poboljšavaju energetske


učinkovitost i mogu dovesti do korak bliže do održivog prometa za buduće mješovite prometne tokove.

Prema [28], implementacijom algoritma VSLC-a primijećeno je povećanje stupnja harmonizacije brzine kao i smanjenje zagušenja na kritičnim područjima gradske autoceste. Primjenom algoritma za VSL dobiva se značajno smanjenje gustoće prometnog toka vozila u području djelovanja. Povećanje srednje brzine kojom se vozila kreću od strane naučenog algoritma veća je za 16,22% u odnosu na stalno ograničenje brzine, a u odnosu na početno ispitivanje pojedinih akcija odnosno ograničenja brzina u sklopu VSLC-a za 16,13 %. Mjerenjem gustoće prometnog toka primijećeno je smanjivanje prosječne gustoće za 44,05% u slučaju primjene naučenog algoritma u odnosu na slučaj bez VSLC-a, a u odnosu na početno ispitivanje pojedinih akcija odnosno ograničenja brzina u sklopu VSLC-a za 48,12 %.

5. Značajke simulacijskog okruženja

AV i CAV uvelike se testiraju i brzo razvijaju u posljednjih nekoliko godina. S razvojem i sve većim brojem AV i CAV u mješovitom prometnom toku, potrebno je analizirati njihov utjecaj na sigurnost prometa, protok, brzinu, potrošnju goriva i emisije. Također, potrebno je razviti odgovarajuće algoritme za upravljanje prometa prije nego što se mogu u potpunosti implementirati i integrirati u prometno okruženje. Da bi se to postiglo, takvi mješoviti tokovi prometa moraju se simulirati u različitim prometnim scenarijima. Simulatori toka prometa upareni sa simulatorima komunikacijskih mreža obično se koriste za izvođenje višestrukih simulacija takvih tokova prometa prema [29].

U ovome radu simulacija prometa odvija se u cestovnom mikroskopskom simulacijskom programu SUMO. SUMO je razvijen od strane Njemačkog svemirskog centra (*eng. German Aerospace Center*). Podjela simulacija se dijeli na mikroskopske i makroskopske, ali postoji i hibridna kombinacije mikro i makro simulacije koja se zove mezoskopska simulacija. Kod mikroskopske simulacije svaki entitet, odnosno sudionik u prometu, gleda se zasebno unutar simulacije kao samostalna jedinka. Makroskopska simulacija se bavi kretanjem skupa vozila prometnim tokom kao da je fluid i ponaša se po pravilima mehanike fluida. SUMO omogućuje simulaciju tako da se određena prometna potražnja koja se sastoji od pojedinačnih vozila kreće kroz danu cestovnu mrežu. Također, SUMO je kompatibilan sa sistemskim jezicima C++, JAVA, Python. Simulacija omogućava rješavanje velikog skupa tema upravljanja prometom. Svako vozilo je eksplicitno modelirano i ima vlastitu rutu, te se pojedinačno kreće kroz mrežu. Simulacije su prema zadanim postavkama determinističke, ali postoje različite opcije za uvođenje slučajnosti. Sučelje simulacijskog alata SUMO je pristupačno i jednostavno za korištenje, te je prikazano na slici 13 [30].



Slika 13. Prikaz korisničkog sučelja SUMO


Python je objektu orijentiran programski jezik razvijen 1990. godine. Python je programski jezik koji ne nudi velike revolucionarne značajke u programiranju, već objedinjuje najbolje principe i načela rada raznih programskih jezika. Python programski jezik koji je moćan i jednostavan za korištenje. Python omogućuje programeru znatno više vremena i prostora za razmišljanje o problematici već o samoj sintaksi jezika. Python se može smatrati hibridom jer se nalazi između tradicionalnih skriptnih jezika i između sistemskih jezika. Time Python nudi jednostavno korištenje skriptnih jezika i samim time jednostavnost, uz brojne napredne programske alate koji se obično nalaze unutar sistemskih razvojnih jezika. Python je besplatan, s izuzetno kvalitetnom potporom, literaturom i dokumentacijom [31].

Jezične značajke Python-a su [31]:

1. Interpretacija međukôda,
2. Interaktivnost,
3. Jezik visoke razine,
4. Napredne značajke jezika,
5. Bogate knjižnice programa,
6. Potpora,
7. Čista sintaksa,.
8. Proširivost.


5.1. Povezivanje Python i SUMO

Model gradske autoceste napravljen je u svrhu testiranja upravljačkog algoritma unutar mikroskopskog simulatora SUMO. Upravljački algoritam implementiran je skriptom napisanom u Python programskom jeziku. Povezivanje simulatora SUMO i skripte s algoritmom učenja vrši se preko PyCharm-a koji je zapravo alat od strane Python-a, te se time omogućuje komunikacija i upravljanje. Povezivanje preko PyCharm-a omogućava upravljanje prometnom simulacijom pomoću programskog koda u Python-u. Python pomoću skripte kojom se simulacija u potpunosti upravlja. Prikaz korisničkog sučelja PyCharm-a prikazan je na slici 14.



Slika 14. Prikaz korisničkog sučelja PyCharm-a

Podaci prikupljeni o prometnom toku računaju se pomoću funkcija koji su izrađeni u programskoj skripti u Python-u. VMS-ovi u SUMO-u izravno zaprimaju odluke o ograničenju brzine koje dolaze od algoritma VSLC-a, te se donesene odluke primjenjuju od strane algoritma. Na slici 15 prikazana je Python - SUMO simulacijska shema zasnovana na Q-učenju.




Slika 15. Python - SUMO simulacijska shema

Simulacija započinje pokretanjem Python skripte, a zatim se vrši inicijalizacija SUMO simulacijskog modela. Sljedeći korak je definiranje ulaznih varijabli poput broj simulacija u simulacijskom okruženju, trajanja učenja mreže, trajanje opservacija, simulacijska ograničenja itd.

5.2. Simulacijski model

Simulacijski model segmenta autoceste ojačanog učenja i VSL (eng. *Variable Speed Limit*) u ovome radu prikazan je na slici 16. Konstruirani model sadrži dvije ulazne rampe ($r1$ i $r2$) i jednu izlaznu rampu ($s1$). Bitno je napomenuti da model na slici 16 nije u mjerilu sa stvarnim modelom autoceste. Mikroskopski prometni simulator simulacije urbane mobilnosti (SUMO) korišten je za izradu i izvođenje mikroskopskih simulacija prometa. PyCharm sučelje u SUMO-u korišteno je za povezivanje SUMO-a s Python skriptom koja je dopušta izravnu kontrolu simulacije uz istovremeno bilježenje simulacijskih rezultata. Simulacija se odvija na dva prometna traka gdje svaka prometna traka ima zasebnu brzinu ograničenja ($v1$ i $v2$) za vrijeme izvođenja simulacija [27].



Slika 16. Grafički prikaz modela gradske autoceste

Upravljačka logika VSLC-a zasniva se na učenju Q-mreže implementiranoj u skripti koja je kreirana u Python-u, dok je simulacijski model gradske autoceste sa dvije prometne trake napravljen u mikroskopskom simulatoru SUMO. U modelu je definirana dionica prometnog toka l . Prometna traka na kojoj koja služi za ubrzanje na ulaznoj rampi $r1$ i $r2$. *Ulazna rampa $r1$* započinje na 2.370 metru simulacijskog modela autoceste, dok ulazne rampe $r2$ započinje na 5.390 metru simulacijskog modela autoceste. Traka koja služi za silazak sa glavnog prometnog toka autoceste usporavanje na izlaznoj rampi $s1$ počinje na 3.380 metru simulacijskog modela autoceste. Maksimalna brzina na ulaznom rampama $r1$ i $r2$ i silaznim rampama $s1$ je 60 km/h (16,17 m/s), dok je maksimalna brzina na dionici za ubrzanje sa ulaznih rampi $r1$ i $r2$ i za usporavanje prema izlaznoj rampi $s1$ 130 km/h (36,11 m/s) čija duljina iznosi 254 i 257 metara. Na slikama 17, 18 i 19 prikazani su parametri rampi $r1$, $r2$ i $s1$ u mikroskopskom simulatoru SUMO.

lane:E8_0 Parameter				lane:E2_0 Parameter			
Name	Value	Dynamic		Name	Value	Dynamic	
maxspeed [m/s]	16.67	✗		maxspeed [m/s]	36.11	✗	
length [m]	204.54	✗		length [m]	254.04	✗	
width [m]	3.20	✗		width [m]	3.20	✗	
street name		✗		street name		✗	
stored traveltime [s]	-1.00			stored traveltime [s]	-1.00		
loaded weight	-1.00			loaded weight	-1.00		
routing speed [m/s]	16.67			routing speed [m/s]	36.11		
time penalty [s]	0.00			time penalty [s]	0.00		
brutto occupancy [%]	0.00			brutto occupancy [%]	0.00		
netto occupancy [%]	0.00			netto occupancy [%]	0.00		
pending insertions [#]	0.00			pending insertions [#]	0.00		
edge type		✗		edge type		✗	
type		✗		type		✗	
priority	-1	✗		priority	-1	✗	
distance [km]	0.00	✗		distance [km]	0.00	✗	
allowed vehicle class	all	✗		allowed vehicle class	all	✗	
disallowed vehicle class		✗		disallowed vehicle class		✗	
permission code	67108863	✗		permission code	67108863	✗	
color value	0.00			color value	0.00		

Slika 17. Prikaz parametara ulazne rampe $r1$

lane:E10_0 Parameter				lane:E6_0 Parameter				lane:E61_0 Parameter			
Name	Value	Dynamic		Name	Value	Dynamic		Name	Value	Dynamic	
maxspeed [m/s]	16.67	✗		maxspeed [m/s]	36.11	✗		maxspeed [m/s]	36.11	✗	
length [m]	204.52	✗		length [m]	121.56	✗		length [m]	123.50	✗	
width [m]	3.20	✗		width [m]	3.20	✗		width [m]	3.20	✗	
street name		✗		street name		✗		street name		✗	
stored traveltime [s]	-1.00	🖼		stored traveltime [s]	-1.00	🖼		stored traveltime [s]	-1.00	🖼	
loaded weight	-1.00	🖼		loaded weight	-1.00	🖼		loaded weight	-1.00	🖼	
routing speed [m/s]	16.67	🖼		routing speed [m/s]	36.11	🖼		routing speed [m/s]	36.11	🖼	
time penalty [s]	0.00	🖼		time penalty [s]	0.00	🖼		time penalty [s]	0.00	🖼	
brutto occupancy [%]	0.00	🖼		brutto occupancy [%]	0.00	🖼		brutto occupancy [%]	0.00	🖼	
netto occupancy [%]	0.00	🖼		netto occupancy [%]	0.00	🖼		netto occupancy [%]	0.00	🖼	
pending insertions [#]	0.00	🖼		pending insertions [#]	0.00	🖼		pending insertions [#]	0.00	🖼	
edge type		✗		edge type		✗		edge type		✗	
type		✗		type		✗		type		✗	
priority	-1	✗		priority	-1	✗		priority	-1	✗	
distance [km]	0.00	✗		distance [km]	0.00	✗		distance [km]	0.00	✗	
allowed vehicle class	all	✗		allowed vehicle class	all	✗		allowed vehicle class	all	✗	
disallowed vehicle class		✗		disallowed vehicle class		✗		disallowed vehicle class		✗	
permission code	67108863	✗		permission code	67108863	✗		permission code	67108863	✗	
color value	0.00	🖼		color value	0.00	🖼		color value	0.00	🖼	

Slika 18. Prikaz parametara ulazne rampe r2

lane:E4_0 Parameter				lane:E9_0 Parameter			
Name	Value	Dynamic		Name	Value	Dynamic	
maxspeed [m/s]	36.11	✗		maxspeed [m/s]	16.66	✗	
length [m]	257.38	✗		length [m]	247.41	✗	
width [m]	3.20	✗		width [m]	3.20	✗	
street name		✗		street name		✗	
stored traveltime [s]	-1.00	🖼		stored traveltime [s]	-1.00	🖼	
loaded weight	-1.00	🖼		loaded weight	-1.00	🖼	
routing speed [m/s]	36.11	🖼		routing speed [m/s]	16.66	🖼	
time penalty [s]	0.00	🖼		time penalty [s]	0.00	🖼	
brutto occupancy [%]	0.00	🖼		brutto occupancy [%]	0.00	🖼	
netto occupancy [%]	0.00	🖼		netto occupancy [%]	0.00	🖼	
pending insertions [#]	0.00	🖼		pending insertions [#]	0.00	🖼	
edge type		✗		edge type		✗	
type		✗		type		✗	
priority	-1	✗		priority	-1	✗	
distance [km]	0.00	✗		distance [km]	0.00	✗	
allowed vehicle class	all	✗		allowed vehicle class	all	✗	
disallowed vehicle class		✗		disallowed vehicle class		✗	
permission code	67108863	✗		permission code	67108863	✗	
color value	0.00	🖼		color value	0.00	🖼	

Slika 19. Prikaz parametara izlazne rampe s1

6. Simulacijski rezultati

U ovom poglavlju prikazani su rezultati prikupljenih tijekom izvršenih simulacija i analiza dobivenih rezultata. Kreirano je šest simulacijskih scenarija povećanjem stope udjela CAV od 10 do 100%, stvarajući različite mješovite prometne tokove. Svaki prometnih tok odvija se u dvije trake gdje se svaka traka kreće zasebnom brzinom. Unutar svakog simulacijskog scenarija odrađeno je 1.500 simulacija. U nastavku je tablica 1 u kojemu su vidljivi zbirni rezultati svih 6 simulacijskih scenarija, te uz ili bez VSLC-a koji postavlja ograničenja brzine na svaku prometnu traku zasebno.


Tablica 1. Rezultati simulacijskih scenarija

	VSLC	Udio CAV [%]					
		10	30	50	70	90	100
Brzina na cijeloj mreži [km/h]	NE	63,0	70,9	78,1	83,4	102,3	108,7
	DA	64,5	70,6	78,1	83,3	102,2	113,3
Brzina na kritičnom dijelu [km/h]	NE	62,7	75,1	87,8	95,8	112,9	114,0
	DA	64,4	74,6	88,1	95,7	113,0	118,9
Gustoća na cijeloj mreži [voz/km/traka]	NE	26,2	23,3	21,0	19,6	16,0	15,6
	DA	25,4	23,2	20,9	19,6	16,0	14,6
Gustoća na kritičnom dijelu [voz/km/traka]	NE	36,3	30,6	25,3	23,5	16,7	16,2
	DA	35,2	31,3	25,0	23,5	16,7	14,3
TTS [voz·h]	NE	838,3	743,6	670,4	634,0	509,5	450,2
	DA	811,1	741,8	669,8	625,3	511,7	450,4
Rep čekanja na rampi r2 [voz]	NE	41,3	47,3	48,5	48,9	50,6	49,4
	DA	45,7	46,3	49,7	49,2	49,0	48,8
MTT [s]	NE	365,8	327,3	298,3	280,0	229,0	205,8
	DA	357,4	329,2	299,1	277,1	229,9	205,8

6.1. TTS i MTT

Parametar ukupno potrošeno vrijeme (*eng. Total Time Spent - TTS*) je glavni parametar uspješnosti simulacije, a njegovo značenje je ukupno provedeno vrijeme svih vozila u prometnoj mreži. TTS predstavlja kvantitativnu mjeru koja dobro opisuje stanje prometnog toka. TTS će uvijek proporcionalno rasti s povećanjem gustoće prometnog toka ukoliko dođe do zagušenja unutar simulacijskog modela. TTS definiraj je mjernom jedinicom umnoška vozila i vremena provedenom u prometnoj mreži [voz·h]. Cilj simulacija je što kraće zadržavanje vozila na upravljanoj autocesti. Prema tome algoritam mora računati optimalne vrijednosti ograničenja brzine koja šalje na VMS-ove. Potrebno je napomenuti da je TTS

mjeren unutar svakog intervala uzorkovanja, te je izračunat je prosjek jednogminutnih uzoraka TTS-a za svaki upravljački interval. Na grafikonu 1 prikazani su sumarni rezultati odrađenih simulacija u 6 simulacijskih okolina, dok u tablici 2 su prikazane pripadne brojčane vrijednosti.




Grafikon 1. TTS

Na grafikonu 1 vidljivo je kako TTS odnosno ukupno provedeno vrijeme vozila u simulacijskoj okolini znatno se smanjuje s povećanjem udjela CAV u simulacijskog okolini. Međutim, prisustvo CAV vozila nije jedino što utječe na smanjenje TTS-a. Iz tablice 2 vidljivo je da TTS ima niže vrijednosti uz prisustvo VSLC-a kod udjela CAV do 70%, dok bez prisustva VSLC-a je niža kod 90 i 100% udjela CAV. Najveća stopa smanjenja promjene TTS-a izražena u postotcima [%] iznosi -3,2% je kod udjela CAV od 10%.

Tablica 2. TTS

		Udio CAV [%]					
VSLC		10	30	50	70	90	100
TTS [voz·h]	bez VSLC-a	838,3	743,6	670,4	634,0	509,5	450,2
	s VSLC-om	811,1	741,8	669,8	625,3	511,7	450,4
Promjena TTS-a [%]		-3,2%	-0,2%	-0,1%	-1,4%	0,4%	0,1%

Parametar srednje vrijeme putovanja (eng. *Mean Travel Time* - *MTT*) označava prosječno zadržavanje vozila u simulacijskoj okolini. Na grafikonu 2 vidljivo je znatno smanje MTT-a sa povećanjem udjela CAV u simulacijskog okolini. Međutim, prisustvo CAV vozila nije jedino što utječe na smanjenje MTT-a.




Grafikon 2. MTT

Iz tablice 3 vidljivo je da MTT ima niže vrijednosti uz prisustvo VSLC-a nego bez prisustva VSLC-a za simulacijska okruženja od 10, 70% udjela CAV, dok vrijednosti za 30, 50 i 90% udjela CAV imaju manje vrijednosti bez VSLC-a. Međutim, vrijednosti pri 100% udjela CAV su ista sa i bez prisustva VSLC-a. MTT smanjen je za 44% bez VSLC-a, odnosno 42% uz utjecaj VSLC.


Tablica 3. MTT

		Udio CAV [%]					
	VSLC	10	30	50	70	90	100
MTT [s]	bez VSLC-a	365,8	327,3	298,3	280,0	229,0	205,8
	s VSLC-om	357,4	329,2	299,1	277,1	229,9	205,8
Promjena MTT-a [%]		-2,3%	0,6%	0,2%	-1,1%	0,4%	0,0%

Uvidom u rezultate TTS-a i MTT-a može se zaključiti kako uvođenjem sve većeg broja CAV može pozitivno utjecati na vrijeme koje je potrebno za vozilu za prometovanje određenom dionicom. Na taj način dolazi se do sigurnijeg upravljanja prometom, ugodnijom i efikasnijom vožnjom. Na grafikonu 3 i 4 vidljiv je trend promjene prosječnog TTS-a i MTT-a za svaku iteraciju simulacije tijekom simulira. Za primjer je uzeto simulacijsko okruženje sa 10% udjela CAV. Povećanje broja simulacije, prosječni MTT i TTS opada. Tim je dokazano kako primijenjeni algoritam posjeduje sposobnost učenja, te djeluje sa ciljem smanjenja i u konačnici sprječavanja zagušenja.




Grafikon 3. Trend smanjenja prosječnog TTS-a tijekom provođenja simulacija



Grafikon 4. Trend smanjenja prosječnog MTT-a tijekom provođenja simulacija

6.2. Gustoća i brzina na prometnoj dionici

U ovome potpoglavlju prikazani su rezultati simulacija za prometne veličine gustoću i brzinu. Rezultati brzine su prosjek brzina u [km/h] prometnog toka za sve simulacije u svakome simulacijskom okruženju. Grafikon 5 prikazuje brzinu na cijeloj mreži i brzinu na kritičnom dijelu.




Grafikon 5. Brzine u simulacijskim rezultatima

Brzina na cijeloj mreži je prosječna brzina kojom se odvija vožnja na dionici 1 u simulacijskom modelu. Iz grafikona 5 i tablice 4 može se zaključiti da se sve tri brzine znatno povećavaju sa povećanjem udjela CAV u simulacijskom okruženju. Povećanje brzine na cijeloj mreži sa 10 na 100% udjela CAV povećala se sa 73% bez utjecaja VLSC-a, dok sa utjecajem VSLC-a povećanje iznosi 76%. Za istu simulacijsku usporedbu porast je vidljiv i kod brzine na kritičnom dijelu za 82% bez i 85% sa VLSC-om. U tablici 4 su jasnije prikazani rezultati simulacija.


Tablica 4. Brzine u simulacijskim rezultatima

	VSLC	Udio CAV [%]						Povećanje 10%→100%
		10	30	50	70	90	100	
Brzina na cijeloj mreži [km/h]	bez VSLC-a	63,0	70,9	78,1	83,4	102,3	108,7	73%
	s VSLC-om	64,5	70,6	78,1	83,3	102,2	113,3	76%
Brzina na kritičnom dijelu [km/h]	bez VSLC-a	62,7	75,1	87,8	95,8	112,9	114,0	82%
	s VSLC-om	64,4	74,6	88,1	95,7	113,0	118,9	85%

Razliku između brzina s i bez utjecaja VSLC-a najbolje je prikazati usporedbom jedne simulacijske akcije intervala 5 [min] i ukupnih rezultata za svih 1.500 simulacija. Na grafikonu 6 prikazana je brzina na cijeloj mreži za simulacijsko okruženje udjela 10% CAV, dok je na grafikonu 6 prikazana brzina na kritičnom dijelu.




Grafikon 6. Brzina na cijeloj mreži tijekom simulacije za 10% udjela CAV




Grafikon 7. Brzina na kritičnom dijelu tijekom simulacije za 10% udjela CAV

Na grafikonu 8 prikazani su rezultati postavljanja brzina na lijevoj i desnoj traci za 10% udjela CAV za 1472-u simulaciju. Iz grafikona vidljivo je kako algoritam prilikom izvođenja jedne simulacije čije vrijeme u jednoj simulaciji iznosi 120 [min], postavlja različita ograničenja brzine na lijevoj i na desnoj prometnoj traci. Krivulje ograničenja lijeve i desne trake za prvih 60 minuta su identične. Međutim, nakon 60 minuta izvođenja simulacije, pa sve do 95 minuta vidljivo je kako se ograničenja na lijevoj i desnoj traci imaju različite vrijednosti. Odnosno, ograničenje na lijevoj traci je veće od ograničenja na desnoj traci. Na taj način postignuto je uspješnije odvija prometa na prometnom tok u odnosu na konstantno ograničenje brzine u iznosu od 130 km/h. Time je vidljiv princip ojačanog učenja pomoću kojega se izvršava smirivanje prometnog toka i povećanje protoka pomoću postavljanja različitog ograničenja brzine na lijevoj i desnoj prometnoj traci.



Grafikon 8. Odnos brzina ograničenja na lijevoj i desnoj prometnoj traci za 10% udjela CAV

Gustoća prometnog toka je obrnuto proporcionalna brzini, odnosno povećanjem brzine smanjuje se gustoća prometnog toka. Gustoća je prikazana kao udio vozila po jednoj prometnoj traci. Grafikon 9 prikazuje gustoću na cijeloj mreži i na kritičnom dijelu sa i bez utjecaja VSLC-a.



Grafikon 9. Gustoće u simulacijskim rezultatima

Prema grafikonu 9 i tablici 5 vidljivo je kako se povećanjem udjela CAV gustoća vozila na cijeloj mreži smanjuje se za 41% bez, odnosno 43% sa utjecajem VSLC-a., dok se gustoća na kritičnom dijelu sa kritičnom dijelu smanjuje za 55% bez, odnosno 59% sa utjecajem VSLC-a. Iz dobivenih rezultata vidljivo je najveće osciliranje između prikazanih gustoća kod 10% udjela CAV, koje iznosi 0,8 voz/h/traci za gustoću na cijeloj mreži i 1,1 voz/h/traci za gustoću na kritičnom dijelu. Bitno je napomenuti kako je gustoća na kritičnom dijelu manja od gustoće na cijeloj mreži samo kod simulacije sa 100% CAV. Time se zaključuje da povećanjem udjela CAV vožnja se odvija sinkroniziranije, bez velikih oscilacija na prometnom toku.

Tablica 5. Gustoće u simulacijskim rezultatima

	VSLC	Udio CAV [%]						Smanjenje
		10	30	50	70	90	100	10%→100%
Gustoća na cijeloj mreži [voz/km/traka]	bez VSLC-a	26,2	23,3	21,0	19,6	16,0	15,6	-41%
	s VSLC-om	25,4	23,2	20,9	19,6	16,0	14,6	-43%
Gustoća na kritičnom dijelu [voz/km/traka]	bez VSLC-a	36,3	30,6	25,3	23,5	16,7	16,2	-55%
	s VSLC-om	35,2	31,3	25,0	23,5	16,7	14,3	-59%

7. Zaključak

Model gradske autoceste kreiran je unutar mikroskopskog simulatora SUMO sa svrhom testiranja upravljačkog algoritma u simulacijskom okruženju. Unutar skripte napisane u programskom jeziku Python implementiran je upravljački algoritam.. Povezivanje simulatora i skripte izvršeno je preko PyCharm-a koji je zapravo alat od strane Python-a, te se time omogućuje komunikacija i upravljanje. Povezivanje preko PyCharm-a dobiveno je upravljanje prometnom simulacijom pomoću programskog koda u Python-u pomoću skripte kojom se simulacija u potpunosti upravlja. Simulacija je upravljana u potpunosti pomoću skripte kreirane unutar Python-a, dok su podatci iz prometnog toka prikupljeni i izračunani pomoću funkcija izrađenih u Python-u pomoću kojih se pristupa prometnim podacima u SUMO-u.

Prikupljeni su podatci iz 6 različitih simulacijskih okruženja koja su se razlikovala po rastućem udjelu CAV od 10 do 100%, te je za svako simulacijsko okruženje odrađeno 1.500 simulacija (ukupno 9.000 simulacija). Model gradske autoceste u kojemu je simuliran rad sastoji se od glavnog toka autoceste sa dvije ulazne i jednom izlaznom rampom. Dobiveni rezultati ukazuju kako se smanjuje zagušenje i vrijeme putovanja svih vozila sa sve većim udjelom CAV u prometnom toku. Bez prisustva VSLC-a vrijednost TTS-a je manja za 19,2%, dok uz prisustvo VSLC-a vrijednost se smanjila za 18,2%, dok je MTT smanjen je za 44% bez, odnosno 42% uz utjecaj VSLC. Povećanje brzine na cijeloj mreži sa 10 na 100% udjela CAV povećala se sa 73% bez utjecaja VLSC-a, odnosno sa utjecajem VSLC-a povećanje iznosi 76%. Za istu simulacijsku usporedbu porast je vidljiv i kod brzine na kritičnom dijelu za 82% bez i 85% s VLSC-om. Vidljivo je najveće osciliranje između prikazanih gustoća kod 10% udjela CAV, dok kod udjela od 100% CAV oscilacije u gustoćama su minimalne. Gustoća na kritičnom dijelu manja od gustoće na cijeloj mreži samo kod simulacije sa 100% CAV.

Time se zaključuje da povećanje udjela CAV u prometnom toku djeluje pozitivno, odnosno vožnja se odvija sinkroniziranije, promet se odvija jednolikom brzinom, vrijeme vožnje se smanjuje, postignuta je veća brzina u prometnom toku, smanjena je gustoća vozila čime se smanjuju repovi čekanja. Nastavak istraživanja na ovoj temi bi mogao uključiti simulacijske scenarije s promjenjivim duljinama zona ograničenja brzine i zone ubrzavanja, dodavanje različitih stilova vožnje za CAV-ove i analiza prometnih parametara (npr. TTS, MTT) za pojedine vrste vozila u mješovitom prometnom toku.

Popis kratica

ACC	prilagodljivi tempomat (engl. Adjustable Cruise Control)
AI	umjetna inteligencija (engl. Artificial Intelligence)
API	aplikacijsko programsko sučelje (engl. Application Programming Interface)
AV	autonomna vozila (engl. Autonomous vehicle)
CAV	umrežena autonomna vozila (engl. Connected Autonomous Vehicles)
DDQN	dualna duboka Q-mreža (engl. Dueling Deep Q-Network)
DQN	duboka Q-mreža (engl. Deep Q-Network)
EBA	pomoć pri kočenju u nuždi (engl. Mergency Brake Assist)
ESC	elektronička kontrola stabilnosti (engl. Electronic Stability Control)
GPS	globalni sustav pozicioniranja (engl. Global Positioning System)
ITS	inteligentni transportni sustavi (engl. Intelligent Transport System)
LIDAR	detekcija svjetlosne zrake i mjerenje udaljenosti (engl. Light Detection and Ranging)
LKA	pomoć pri održavanju trake (engl. Lane Keep Assist)
LoS	razina uslужnosti (engl. Level of Service)
MDP	Markovljev proces odlučivanja (engl. Markov Decision Process)
MTT	prosječno vrijeme putovanja svih vozila u prometnoj mreži (engl. Mean Travel Time)
RADAR	detekcija radio valova i mjerenje udaljenosti (engl. Radio Detecting and Ranging)
RL	ojačano učenje (engl. Reinforcement Learning)
SAE	Međunarodna udruga automobilskih inženjera (engl. Society of Automotive Engineers International)
SUMO	cestovni mikroskopski simulacijski program (engl. Simulation of Urban MObility)
TTS	ukupno provedeno vrijeme svih vozila u prometnoj mreži (engl. Total Time Spent)
V2I	komunikacija vozila sa infrastrukturom (engl. Vehicle to Infrastructure)
V2V	komunikacija između vozila (engl. Vehicle to Vehicle)
V2X	komunikacija vozila sa okolinom (engl. Vehicle to Everything)
VMS	promjenjivi prometni znakovi (engl. Variable Message Signs)
VSL	promjenjivo ograničenje brzine (engl. Variable Speed Limit)

VSLC upravljanje promjenjivim ograničenjem brzine (engl. Variable Speed Limit Control)

Popis literature

- [1] Hrvatski zavod za statistiku, <https://podaci.dzs.hr/2022/hr/29136>, pristupljeno 25.08.2022.
- [2] Smart Cities World, <https://www.smartcitiesworld.net/opinions/opinions/driving-autonomous-vehicles-forward-with-intelligent-infrastructure>, pristupljeno 26.08.2022.
- [3] Mikulić D, Rauker J, Šaban A, B. Katana. Karakteristike automobila u budućnosti u kontekstu razvoja sigurnosti prometa. Veleučilište Velika Gorica
- [4] SAE mobilus, <https://www.sae.org/news/2019/01/sae-updates-j3016-automated-driving-graphic>, pristupljeno 26.08.2022.
- [5] Synopsys, <https://www.synopsys.com/automotive/autonomous-driving-levels.html>, pristupljeno 26.08.2022.
- [6] Tportal, <https://www.tportal.hr/autozona/clanak/trebaju-li-nam-uopce-vise-vozaci-autonomna-voznja-je-tema-koja-dobija-sve-vise-na-znacaju-vozacke-dozvole-nam-mozda-vise-nece-niti-trebati-foto-20190603>, pristupljeno 26.08.2022.
- [7] Yair Wiseman. Autonomous Vehicles, Bar-Ilan University, Israel, 2014.
- [8] Liu, S., Tang, J., Zhang, Z.: Computer architectures for autonomous driving, IEEE Comput. Archit. Lett., 2017.
- [9] Kočić J., Jovićić N., Drndarević V.: Sensors and Sensor Fusion in Autonomous Vehicles., Konferencija 2018 26th Telecommunications Forum (TELFOR), Belgrade, Serbia, 2018.
- [10] S. Mandžuka, A. Vučina, P. Škorput, Primjena autonomnih vozila u kriznim situacijama, XIII. Znanstveno-stručna konferencija Dani kriznog upravljanja, Velika Gorica, Hrvatska, 2020.
- [11] Rajasekhar MV, Kumar Jaswal A: Autonomous Vehicles: The Future Of Automobiles
- [12] Accesspartnership, <https://www.accesspartnership.com/how-vehicular-communications-will-revolutionise-mobility/>, pristupljeno 26.08.2022.
- [13] Cadillac, <https://media.cadillac.com/media/us/en/cadillac/news.detail.html/content/Pages/news/us/en/2017/mar/0309-v2v.html>, pristupljeno 26.08.2022.
- [14] Korent N., Kušić K., Analiza utjecaja promjenjivog ograničenja brzine na protočnosti prometa i zagađenje okoliša, Rektorova nagrada, Fakultet prometnih znanosti, Zagreb 2016.

- [15] The Geography of Transport Systems, <https://transportgeography.org/contents/methods/transport-technical-economic-performance-indicators/levels-of-service-road-transportation/>, pristupljeno 25.08.2022.
- [16] Galić I. Usporedba metoda za upravljanje priljevnim tokovima na primjeru zagrebačke obilaznice, Diplomski rad: Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2015.
- [17] Kušić K, Ivanjko E, Gregurić M. A Comparison of Different State Representations for Reinforcement Learning Based Variable Speed Limit Control, 6th Mediterranean Conference on Control and Automation (MED), Zadar, 2018.
- [18] Gregurić M, Ivanjko E, Korent N, Kušić K. Short Review of Approaches for Variable Speed Limit Control, ZIRP2016, Zagreb, Croatia, 12.04.2016. str. 41-52, 2016.
- [19] Kušić K. Okruženje za simulaciju sustava za upravljanje promjenjivim ograničenjem brzine na urbanim autocestama zasnovanih na učenju, Diplomski rad: Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2017.
- [20] Sutton RS, Barto AG. Reinforcement Learning: An Introduction, The MIT Press Cambridge, Massachusetts London, England, 2002.
- [21] Walraven E. Traffic Flow Optimization using Reinforcement Learning, Master's Thesis, Faculty EEMCS, Delft University of Technology, Delft, the Netherlands, 2014.
- [22] Teradata, <https://www.teradata.com/Blogs/Using-Data-to-Answer-the-Key-Challenge-to-Enterprise-Reinforcement-Learning>, pristupljeno 25.08.2022.
- [23] Oppermann A. Self Learning AI-Agents Part II: Deep (Double) Q-Learning, Towards Data Science, 2018.
- [24] Ankit Choudhary, A Hands-On Introduction to Deep Q-Learning using OpenAI Gym in Python, 2019.
- [25] Pathmind, A Beginner's Guide to Deep Reinforcement Learning, <https://wiki.pathmind.com/deep-reinforcement-learning>, pristupljeno 26.08.2022.
- [26] Mehdi Mohammadi, Semi-supervised Deep Reinforcement Learning in Support of IoT and Smart City Services, IEEE, Ala Al-Fuqaha, 2018.
- [27] Filip Vrbanić, Mladen Miletić, Leo Tišljarić, Edouard Ivanjko, Influence of Variable Speed Limit Control on Fuel and Electric Energy Consumption, and Exhaust Gas Emissions in Mixed Traffic Flows, Članak, Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2021.

- [28] Filip Vrbanić, Okruženje za simulacije sustava za upravljanje promjenjivih ograničenja brzine na gradskim autocestama zasnovano na dubokom učenju, Diplomski rad, Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2019.
- [29] Filip Vrbanić, Dino Čakija, Krešimir Kušić, Edouard Ivanjko, Traffic Flow Simulators with Connected and Autonomous Vehicles, Članak, Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2021.
- [30] SUMO, <https://sumo.dlr.de/docs/index.html>, pristupljeno 26.08.2022.
- [31] Essert M, Vazler I. Python – osnove, Odjel za matematiku Sveučilišta u Osijeku, Osijek, 2007.
- [32] Python <https://www.python.org/>, pristupljeno 25.08.2022.

Popis slika

Slika 1. Autonomno vozilo u okolini	3
Slika 2. Klasifikacija autonomnih vozila	4
Slika 3. Uloga vozača i umjetne inteligencije vozila u svrhu uparivanja vozilom	5
Slika 4. Položaj osjetila na AV.....	8
Slika 5. Komunikacija vozila i okoline	9
Slika 6. Komunikacija između autonomnih vozila (V2V).....	10
Slika 7. 6 razina kvalitete usluge.....	12
Slika 8. Mjesto nastanka uskog grla i posljedice preljeva promet	12
Slika 9. Primjer Q-tablice.....	18
Slika 10. Prikaz odnosa stanja okoline i povratne veze akcija.....	19
Slika 11. Prikaz funkcije dubokog Q-učenja.....	20
Slika 12. Prikaz funkcije dubokog Q-učenja.....	22
Slika 13. Prikaz korisničkog sučelja SUMO	25
Slika 14. Prikaz korisničkog sučelja PyCharm-a	26
Slika 15. Python -SUMO simulacijska shema	27
Slika 16. Grafički prikaz modela gradske autoceste	27
Slika 17. Prikaza ulazne rampe $r1$	28
Slika 18. Prikaza ulazne rampe $r2$	29
Slika 19. Prikaza silazne rampe $s1$	29

Popis tablica

Tablica 1. Rezultati simulacijskih scenarija	30
Tablica 2. TTS	31
Tablica 3. MTT	32
Tablica 4. Brzine u simulacijskim rezultatima	34
Tablica 5. Gustoće u simulacijskim rezultatima	37

Popis grafikona

Grafikon 1. TTS	31
Grafikon 2. MTT	32
Grafikon 3. Trend smanjenja prosječnog TTS-a tijekom provođenja simulacija	33
Grafikon 4. Trend smanjenja prosječnog MTT-a tijekom provođenja simulacija	33
Grafikon 5. Brzine u simulacijskim rezultatima	34
Grafikon 6. Brzina na cijeloj mreži tijekom simulacije za 10% udjela CAV	35
Grafikon 7. Brzina na kritičnom dijelu tijekom simulacije za 10% udjela CAV	35
Grafikon 8. Odnos postavljenih brzina na lijevoj traci za 10% udjela CAV	36
Grafikon 9. Gustoće u simulacijskim rezultatima	37

Sveučilište u Zagrebu
Fakultet prometnih znanosti
Vukelićeva 4, 10000 Zagreb

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOSTI

Izjavljujem i svojim potpisom potvrđujem da je _____ diplomski rad _____
(vrsta rada)

isključivo rezultat mogega vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju upotrijebljene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedopušten način, odnosno da je prepisan iz necitiranog rada te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu završnog/diplomskog rada pod naslovom **Upravljanje promjenjivim ograničenjem brzine primjenom ojačanog učenja za prometne tokove s umreženim autonomnim vozilima**, u Nacionalni repozitorij završnih i diplomskih radova ZIR.

Student/ica:

U Zagrebu, 09.09.2022



(ime i prezime, potpis)