

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Sanja Palajsa

**UPRAVLJANJE PROMJENJIVIM OGRANIČENJEM
BRZINE NA URBANIM AUTOCESTAMA ZASNOVANO
NA LOGIČKOM STABLU ODLUČIVANJA**

DIPLOMSKI RAD

Zagreb, 2017.

Zagreb, 24. travnja 2017.

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

DIPLOMSKI ZADATAK br. 4220

Pristupnik: **Sanja Palajsa (0135225970)**
Studij: **Inteligentni transportni sustavi i logistika**
Smjer: **Inteligentni transportni sustavi**


Zadatak: **Upravljanje promjenjivim ograničenjem brzine na urbanim autocestama zasnovano na logičkom stablu odlučivanja**

Opis zadatka:

Oko velikih gradova se grade obilaznice kako bi rasteretile urbanu cestovnu mrežu. Takve obilaznice se najčešće svode na urbane autoceste s većim brojem prilaznih i odlaznih rampi. Područja gdje se nalaze prilazne i odlazne rampe predstavljaju mjesta gdje se mogu pojaviti zastoji. Njihovo pojavljivanje se može smanjiti ili čak spriječiti prikladnim upravljanjem promjenjivim ograničenjem brzine vozila glavnog toka urbane autoceste. U radu je potrebno opisati probleme upravljanja prometom na urbanim autocestama, dati pregled pristupa za upravljanje ograničenjem brzine, analizirati mogućnosti primjene logičkog stabla odlučivanja za upravljanje promjenjivim ograničenjem brzine, izraditi model dionice urbane autoceste i iskoristiti postojeće prometne podatke za simulaciju modelirane dionice autoceste uz korištenje simulatora VISSIM.


Zadatak uručen pristupniku: 28. travnja 2017.

Mentor:



doc. dr. sc. Edouard Ivanjko

Predsjednik povjerenstva za
diplomski ispit:



Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

**UPRAVLJANJE PROMJENJIVIM OGRANIČENJEM
BRZINE NA URBANIM AUTOCESTAMA ZASNOVANO
NA LOGIČKOM STABLU ODLUČIVANJA**

**VARIABLE SPEED LIMIT CONTROL ON URBAN
MOTORWAYS BASED ON DECISION LOGIC TREE**

Mentor:
doc. dr. sc. Edouard Ivanjko

Studentica:
Sanja Palajsa, univ. bacc. ing. traff.
JMBAG: 0135225970

Zagreb, rujan 2017.

Zahvala

Zahvaljujem se svome mentoru, docentu Edouardu Ivanjku na pruženoj prilici te na vođenju tijekom izrade ovog rada, kao i na suradnji i angažmanu tijekom njegovog mentorstva.

Hvala mojim roditeljima i sestri na bezuvjetnoj podršci i strpljenju tijekom mog školovanja. Dijelili smo radost za svaki položen ispit i pružali ste mi ohrabrenje u svim trenucima nesigurnosti.

Također, hvala i mojim prijateljima koji su mi bili potpora u studiranju.

Na kraju, hvala mome dečku Viktoru za potporu i razumijevanje u vrijeme studiranja i tijekom pisanja ovog rada, kao i za svu podršku i ljubav koju mi svakodnevno pruža.

UPRAVLJANJE PROMJENJIVIM OGRANIČENJEM BRZINE NA URBANIM AUTOCESTAMA ZASNOVANO NA LOGIČKOM STABLU ODLUČIVANJA

Sažetak

Oko velikih gradova grade se obilaznice čija je namjena rasteretiti urbanu cestovnu mrežu unutar grada. Takve obilaznice se najčešće svode na urbane autoceste s većim brojem ulaznih i izlaznih rampi. Mjesta gdje se nalaze ulazne i izlazne rampe sklona su pojavljivanju prometnih zastoja. Njihovo pojavljivanje se može smanjiti ili u potpunosti spriječiti prikladnim upravljanjem ograničenjem brzine vozila glavnog toka urbane autoceste. U radu su opisani problemi upravljanja prometom na urbanim autocestama, objašnjeni su pristupi za upravljanje ograničenjem brzine, analizirane su mogućnosti primjene logičkog stabla odlučivanja za upravljanje promjenjivim ograničenjem brzine, izrađen je model dionice urbane autoceste i iskorišteni su postojeći prometni podaci za simulaciju modelirane dionice autoceste uz korištenje simulatora VISSIM.

KLJUČNE RIJEČI: urbane autoceste, ulazne i izlazne rampe, prometno zagušenje, upravljanje promjenjivim ograničenjem brzine, logičko stablo odlučivanja

VARIABLE SPEED LIMIT CONTROL ON URBAN MOTORWAYS BASED ON DECISION LOGIC TREES

Summary

Bypasses are being built around big cities to disburden the urban road network within the city. Such bypasses are usually confined as urban motorways with a large number of entry and exit ramps. Traffic jams are prone to occur in places where the entry and exit ramps are. Occurrence of traffic jams can be reduced or completely prevented by the appropriate use of vehicle speed limit control on the main road of the urban motorway. In this thesis, problems of traffic management on urban motorways are discussed, approaches for speed limit control are explained, the possibilities of applying the decision logic tree for variable speed limit control are analyzed, a model of an urban motorway stretch was made and the existing traffic data were used for simulation of the modeled motorway section using the VISSIM simulator.

KEYWORDS: urban motorways, entry and exit ramps, traffic congestion, variable speed limit control, logic decision trees

Sadržaj

1. Uvod.....	1
2. Problemi upravljanja prometom na urbanim autocestama	3
3. Najčešće metode upravljanja ograničenjem brzine.....	9
4. Primjena logičkog stabla odlučivanja u upravljanju ograničenja brzine	15
4.1. Analiza stabla odlučivanja	17
4.2. Upravljanje promjenjivim ograničenjem brzine zasnovano na logičkom stablu odlučivanja uključujući protok, gustoću i srednju brzinu	18
5. Model urbane autoceste	20
5.1. Parametri modela autoceste.....	20
5.2. Simulator prometa VISSIM	22
5.3. Simulator emisije štetnih plinova	23
6. Simulacijski rezultati	25
6.1. Protok, gustoća i srednja brzina po ćelijama.....	25
6.2. Ograničenje brzine	28
6.3. Ukupno utrošeno vrijeme i vrijeme putovanja	29
6.4. Duljina reda čekanja na ulaznim rampama r_1 i r_2	32
6.5. Emisija štetnih ispušnih plinova	33
7. Zaključak.....	35
Literatura	37
Popis kratica.....	40
Popis slika	41
Popis tablica	42
Popis grafikona.....	43

1. Uvod

Kako bi se riješili problemi cestovnog prometa, sve se više teži optimalnom iskorištenju postojeće cestovne infrastrukture, a ne samo izgradnji novih prometnih kapaciteta. U tu svrhu se koriste metode upravljanja cestovnim prometom iz domene inteligentnih transportnih sustava (ITS). Kako bi se one mogle koristiti potrebno je upravljačkom sustavu dati pristup stvarnovremenskim prometnim parametrima koji se prikupljaju korištenjem različitih senzora i detektora.

Iako je na autocestama predviđen veći prometni kapacitet, zbog povećanja prometne potražnje na urbanoj prometnoj mreži, na urbanim autocestama dolazi do zagušenja. Urbane autoceste služe i kao obilaznice oko velikih gradova na kojima se odvija tranzitni promet, a ujedno povezuju velike gradove sa susjednim većim mjestima. Do povećane prometne potražnje, koja uzrokuje zagušenja, najčešće dolazi zbog svakodnevnih migracija ljudi zbog posla ili škole te kada se dogodi incidentna situacija ili kada nastupe loši vremenski uvjeti.

Jedna od mjera za poboljšanje razine uslužnosti urbane autoceste jest i primjena naprednih metoda upravljanja iz područja inteligentnih transportnih sustava, odnosno upravljanje promjenjivim ograničenjem brzine u cilju harmonizacije prometnog toka, povećanja sigurnosti te uštede vremena i goriva. Korištenje ove metode regulacije prometa rezultira boljim protokom vozila i moguće je spriječiti nastajanje zagušenja na kritičnim dijelovima urbane autoceste koji bi se dalje širili prometnim tokom urbane autoceste. Ukoliko se dogodi takav slučaj, zagušenje se ubrzano širi i na lokalnu urbanu cestovnu mrežu povezanu s urbanom autocestom.

Svrha ovog diplomskog rada je prikazati poboljšanja u odvijanju prometnog toka na dionicama urbanih autocesta primjenom sustava za promjenjivo ograničenje brzine koji je zasnovan na logičkom stablu odlučivanja, predstaviti važnost te prednosti uporabe takvog algoritma u svrhu harmonizacije prometnog toka na već postojećoj mreži urbanih autocesta.

Cilj istraživanja je približavanje načina rada logičkog stabla odlučivanja i njegove primjene u upravljanju ograničenjem brzine kao alternativa postojećim pristupima za upravljanje promjenjivim ograničenjem brzine te uputiti na potencijalnu mogućnost primjene takvog sustava u Republici Hrvatskoj.

U dosadašnjim istraživanjima algoritama za promjenjivo ograničenje brzine zasnovanih na pravilima ustanovljeno je da takve predodređene odluke donose poteškoće u donošenju pravovremenih odluka zbog nelinearnog i složenog ponašanja prometnog sustava. Kako bi se optimizirao prometni proces na urbanim autocestama potrebno je da procjena i djelovanje ograničenja brzine bude u skladu sa stvarnovremenskim te stvarno-prometnim uvjetima. S obzirom da primjena umjetne inteligencije može uzeti u obzir neodređenosti i netočnosti vezane za prometne procese, njena primjena je danas važan segment razvoja u ITS-u. Nastavno tome, kao

jedna od mogućnosti ističe se logičko stablo odlučivanja koje u sklopu donošenja odluke za iznos ograničenja brzine može u obzir uzeti više prometnih parametara, kao što su na primjer protok, gustoća i srednja brzina kretanja vozila. Osnovni rezultat ovog istraživanja je prikaz rada sustava upravljanja promjenjivim ograničenjem brzine koji je zasnovan na logičkom stablu odlučivanja.

U drugom poglavlju nakon uvoda opisani su problemi upravljanja prometom na urbanim autocestama. U trećem poglavlju opisane su najčešće metode upravljanja promjenjivim ograničenjem brzine (eng. Variable Speed Limit Control - VSLC), nabrojane su vrste promjenjivih prometnih znakova, objašnjene su komponente VSLC sustava te je opisan utjecaj VSLC-a na prometne tokove urbanih autocesta. U četvrtom poglavlju objašnjena je primjena logičkog stabla odlučivanja u upravljanju ograničenja brzine, nabrojane su prednosti i nedostaci takve primjene te objašnjen algoritam koji se zasniva na logičkom stablu odlučivanju uključujući protok, gustoću i srednju brzinu kretanja vozila. U svrhu ovog rada izrađen je model urbane autoceste u mikroskopskom prometnom simulatoru PTV VISSIM koji je objašnjen u petom poglavlju. U simulatoru PTV VISSIM napravljena je simulacija s generiranim prometnim podacima koji opisuju vršni sat u tipičnom radnom danu jedne dionice urbane autoceste. U šestom poglavlju dani su rezultati simulacije te su uspoređeni rezultati između prometnih situacija kada djeluje regulator ograničenja brzine zasnovan na logičkom stablu odlučivanja s fiksno podešenim vrijednostima ograničenjima brzine i za slučaj bez primjene promjenjivog ograničenja brzine. Dobiveni rezultati VISSIM simulacije proslijeđeni su simulatoru EnViVer koji je na osnovu njih izračunao emisiju štetnih ispušnih plinova podataka radi analize utjecaja upravljanja ograničenjem brzine na okoliš. Zaključak sadrži osvrt na dobivene rezultate simulacije i na moguća buduća istraživanja.

2. Problemi upravljanja prometom na urbanim autocestama

Do problema upravljanja prometom na urbanim autocestama dolazi kada urbana autocesta ne ispunjava svoju primarnu funkciju, a to je brz i siguran protok prometa. S ciljem rasterećivanja prometne mreže unutar grada, a uvažavajući konstantno povećanje urbanog prometa, grade se urbane autoceste, odnosno obilaznice koje u današnje vrijeme predstavljaju ključan dio prometne mreže većih gradova. Urbane autoceste mogu povezivati centar grada s predgrađem ili se, u vidu obilaznice, grade oko centra grada. Sav tranzitni promet koji se odvija u prometnoj mreži u gradu prebacuje se na obilaznicu.


Svakim danom sve je više vozila na cestama što uzrokuje duže vrijeme putovanja od polazišta do odredišta i zagušenja koja smanjuju sigurnost na autocesti. Ukupno kašnjenje se računa kao zbroj vozila koji se nalaze u glavnom toku i vozila na prilazu u ćeliji dotičnog prilaznog toka. Rezultat se oduzme od broja vozila u glavnom toku koja se kreću pri brzini slobodnog toka. Duže vrijeme putovanja i zagušenje, također utječu na povećanu potrošnju goriva te povećanu emisiju štetnih plinova. Zagušenja nastaju tijekom vršnih sati, odnosno onda kada je prekoračen kapacitet autoceste i smanjena je propusnost. Smanjena propusnost autoceste dovodi i do većeg broja nesreća te incidenata koji dodatno usporavaju odvijanje prometa odnosno znatno povećavaju vrijeme putovanja. Još jedan od problema koji nastaju na urbanim autocestama su velike duljine repova čekanja na ulaznim i izlaznim rampama.

Urbane autoceste su građene tako da mogu primiti veliki kapacitet vozila što sukladno tome povećava i razinu uslužnosti autoceste (eng. Level of Service - LoS). Razina uslužnosti autoceste je kvalitativna mjera koja se koristi za analizu autoceste na način da se kategorizira promet i dodjeljuje se razina kvalitete na temelju mjera izvedbe kao što su brzina, gustoća i tako dalje. Definirano je šest razina usluga označene simbolima od A do F, gdje je razina usluge A najbolja (slobodni tok), a F najlošija (zagušenje). Za prometnice koje imaju više traka razina usluge je određena gustoćom, a neizravno je opisana i prosječnom brzinom te vremenom putovanja. Prema HCM [1] razini usluga, definirana je prema kriterijima danim u tablici 1.

Tablica 1. Razine uslužnosti

Razina uslužnosti	Maksimalna gustoća (vozilo/kilometru)
A	$\leq 6,0$
B	$> 6,0 - 12,0$
C	$> 12,0 - 17,0$
D	$> 17,0 - 22,0$
E	$> 22,0 - 27,0$
F	$> 27,0$

Iako urbane autoceste mogu podnijeti znatno veći kapacitet vozila nego druge prometnice, može doći to prekoračenja tog kapaciteta i nastaju zagušenja te povećani repovi čekanja na ulaznim i izlaznim rampama. Povećanje broja ulaznih i izlaznih rampi na autocesti proporcionalno povećava vjerojatnost da će doći do zagušenja. Pogotovo na mjestima gdje se nalaze rampe. Termin zagušenje označuje pojavu do koje dolazi kada je potražnja prometa veća od maksimalnog kapaciteta prometnice, čime se povećava vrijeme čekanja, povećava broj incidentnih situacija, povećava se vrijeme putovanja, povećava se potrošnja goriva i emisija štetnih plinova, a smanjuje se razina uslužnosti. Ako zagušenje traje neki duži period vremena onda se ta pojava naziva „prometni čep“. Prometni čep može nastati sasvim spontano, ali i kao posljedica nekih manjih događanja jer promet je stohastičke prirode pa je vrlo teško predvidjeti kada će točno doći do zagušenja. Prometni zastoji najčešće nastaju tijekom jutarnjih i kasnih poslijepodnevni sati, odnosno u vremenu odlaska na posao ili u školu i dolaska kući. Zagušenja na gradskim cestama najčešće nastaju na ulazima iz manje prometne ulice u prometniju ulicu. To mjesto spajanja dva takva prometna toka naziva se nizvodno usko grlo (eng. downstream bottleneck). Na slici 1. prikazana je situacija nizvodnog uskog grla blizu ulaza na urbanu autocestu i učinak preljeva prometa na lokalnu gradsku cestu.



Slika 1. Ilustracija situacije nizvodnog uskog grla blizu ulaza na urbanu autocestu [2]

Zbog povećanog zauzeća urbane autoceste dolazi do smanjenja propusnosti što produžuje vrijeme putovanja i smanjuje sigurnost. Sigurnost cestovnog prometa definira se kao skup mjera i načina pomoću kojih se štite svi sudionici u prometu od mogućih stradavanja. Kod narušene sigurnosti cestovnog prometa dolazi do prometnih nesreća i nezgoda što negativno utječe na cijelo društvo u cjelini. Incidentne situacije u kojima je osoba izgubila život direktno utječu na gospodarstvo države jer preminula osoba više nije u mogućnosti doprinosti gospodarstvu države čiji je državljanin. Prometne nesreće mogu nastati ljudskom greškom, neodgovarajućim vozilom (vozilo nije tehnički ispravno) ili lošom kvalitetom infrastrukture (kao na primjer smanjena preglednost na autocesti, oštećenja kolnika i slično). Ipak najčešći uzrok prometnih

nesreća je ljudska greška jer ljudi voze svoja vozila na temelju svojih osjećaja, znanja i do sad prikupljenog iskustva, odnosno oni su donositelji odluka u prometnom sustavu. Mnoge države prepoznale su sigurnost cestovnog prometa kao najbitniji problem u prometu zbog velikih nedostataka koje smanjena sigurnost donosi.

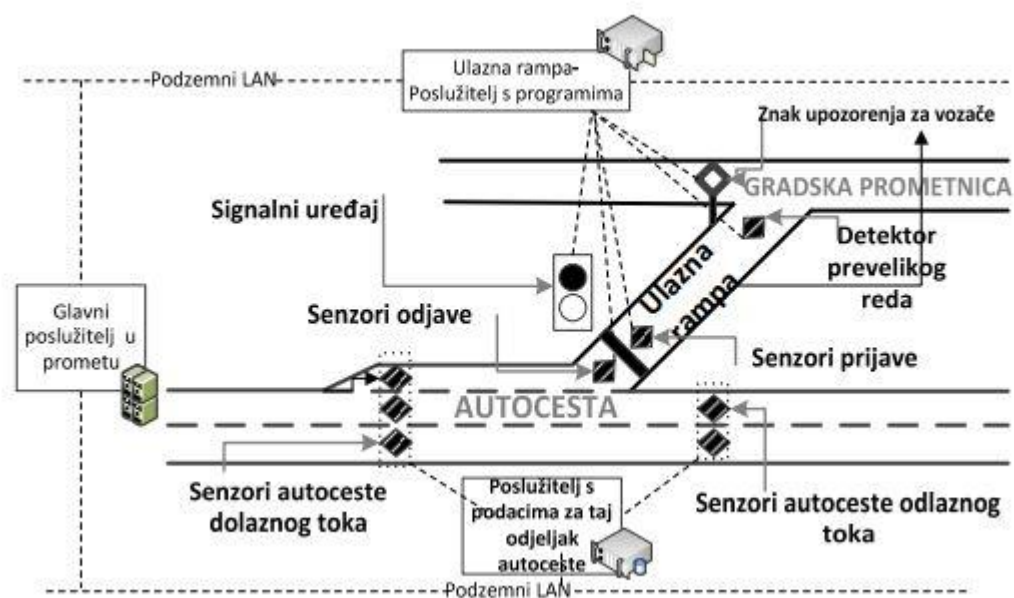
Za gore nabrojane probleme upravljanja prometom na urbanim autocestama kao jedno od rješenje se razmatra upravljanje priljevnim tokovima. Cilj upravljanja priljevnim tokovima je povećati sigurnost u prometu, a to se postiže smanjenjem vremena kašnjenja i održavanjem protoka vozila na prometnicama reguliranjem pristupa ulaznoj rampi. Prednosti upravljanja priljevnim tokovima na autocestama su:

- Veća propusnost glavnog prometnog toka autoceste i manja zagušenja;
- Smanjenje vremena putovanja autocestom;
- Smanjenje vremena čekanja na priljevnim tokovima;
- Smanjenje rizika od nastajanja prometnih nesreća;
- Smanjenje emisije štetnih plinova i buke.

Smanjenje emisije štetnih plinova je bitna stavka s obzirom da ispušni plinovi ugrožavaju ljudsko zdravlje. Emisije štetnih plinova zagađuju zrak čime se stvaraju eksterni troškovi u prometu. Pod eksterne troškove uzrokovane zagađenjem zraka spadaju utjecaj na ljudsko zdravlje, utjecaj na materijale i građevine, gubitak usjeva i oštećenje šuma. Od navedenih utjecaja, najveći postotak odnosi se na troškove povezane s ljudskim zdravljem, o čemu postoji najviše studija, dok o utjecaju na materijale i građevine gotovo da i ne postoje studije. Kao važni ulazni podaci za ovu skupinu troškova uzimaju se emisija NO_x koji uzrokuje pojavu kiselih kiša te količina PM_{10} čestica. PM_{10} čestice su fine, sitne čestice, dovoljno male da mogu biti udahnute u pluća, a koje su u promjeru manje od $10\mu\text{m}$. Te čestice mogu uzrokovati kronične probleme respiratornog sustava i prijevremenu smrt. PM_{10} čestice su samo manjim dijelom proizvedene ispuhom, dok je većina PM_{10} čestica vezana uz trošenje ceste, kvačila i guma, slijedom čega, prema statistikama, samo oko 20 posto PM_{10} čestica u cestovnom prometu dolazi od ispušnih plinova.

Buka se javlja kao veliki problem u prometnom sektoru, a kao posljedice buke mogu se navesti ne samo uznemiravanje stanovništva, nego i druge fizičke i psihičke posljedice. Tako npr. buka od 85 dB može ostaviti posljedice na sluh dok manja razina buke, buka preko 60 dB, može proizvesti stres i nervozu, promjenu pulsa, povećanje krvnog tlaka te hormonalne poremećaje. Izlaganje pretjeranoj buci također povećava rizik od kardio–vaskularnih smetnji. Osim kardio–vaskularnih smetnji, buci izloženi ljudi, posebno noću, imaju povećani rizik od želučano–crijevnih tegoba. Da bi se ljudi zaštitili od loših utjecaja buke implementiraju se bukobrani uz prometnice. Sad u svijetu postoje bukobrani koji su napravljeni od bala sijena, a sadržaj sijena je takav da na sebe prima čestice monoksida i na taj način se te štetne čestice ne ispuštaju u naseljena mjesta.

Upravljanje priljevnim tokovima (eng. ramp metering), također smanjuje turbulencije u zoni spajanja ulazne rampe na glavni tok te na taj način povećava sigurnost u prometu (smanjuje bočne sudare i sudare u stražnji dio vozila). Upravljanje priljevnim tokovima se sastoji od prometnih signala koji su postavljeni na rampama koje kontroliraju kada i koliko vozila smije ući na glavni tok ovisno o situaciji na njoj. Vozilima neće biti dopušten ulazak na glavni tok ako vrijeme čekanja na priljevnoj rampi prelazi prihvatljive granice čekanja vozača ili ako red čekanja na ulaznoj rampi postane predug. Upravljanje priljevnim tokovima je postao dobro poznat način kako smanjiti zagušenja na autocestama. Prometni signali u upravljanju priljevnim tokovima su unaprijed određeni i to tako da se zeleno svjetlo koje znači slobodan ulazak na prometnicu s ulazne rampe pali nakon određenih vremenskih intervala. Trajanje tog zelenog svjetla je, također unaprijed definirano. Sada ti prometni signali rade na principu da prvo u obzir uzmu trenutno stanje prometa i putem tih podataka mijenja se frekvencija pojave zelenog svjetla. Na slici 2 prikazana je infrastruktura upravljanja priljevnim tokovima.



Slika 2. Infrastruktura upravljanja priljevnim tokovima [2]

Istraživanja su pokazala da su sigurnosne prednosti upravljanja priljevnim tokovima ograničene na dionice autoceste koje su se nalazile u blizini rampe. Prednosti su ovisne i o postojećim prometnim uvjetima, kao i o prostornom opsegu nad kojim je provedena evaluacija. Upravljanje priljevnim tokovima jedna je od najučinkovitijih metoda upravljanja prometom na urbanim autocestama s područja ITS-a.

Sustavi upravljanja prometom na autocestama koriste razne tehnologije kao što su na primjer primjena detektora i video kamera, promjenjivi prometni znakovi i ostali

sustavi informiranja sudionika u prometu. Sustavi upravljanja prometom na autocestama uključuju sljedeće [3]:

- Nadzor prometa korištenjem detektora i video-opreme;
- Mjere upravljanja prometom na ulaznim rampama korištenjem senzora i podataka za optimizaciju brzine putovanja na autocesti i vremena čekanja na rampama;
- Upravljanje prometnim trakovima za optimizaciju efektivnog kapaciteta autocesta i promoviranje korištenja visokih zauzeća vozila;
- Sustave upravljanja posebnim događajima za kontrolu utjecaja zagušenja na sportskim igralištima ili kongresnim centrima;
- Upravljanje dinamičkim znakovima s porukama vozačima (promjenjivi prometni znakovi).

Kod zagušenja na autocestama veliki problem predstavlja i neujednačena brzina kretanja vozila, stoga se, uz upravljanje priljevnim tokovima, razmatra i upravljanje promjenjivim ograničenjem brzine (eng. variable speed limit control – VSLC). Ako dođe do preopterećenja neke dionice urbane autoceste, na mjestu gdje se nalazi ulazna rampa, može doći do prometnog čepa. Prometni zastoj bi se širio prema natrag po cijeloj duljini prometnog toka u obliku šok valova, a razina sigurnosti na autocesti bi se značajno smanjila i postojala bi velika mogućnost incidentne situacije, odnosno sudara. Fenomen šok-vala nastaje pri skokovitim promjenama osnovnih parametara prometnog toka. Uglavnom se kreće duž prometnice u smjeru suprotnom od smjera prometnog toka. Do lančanih sudara dolazi zbog nagle razlike u brzinama između segmenata autoceste gdje se ne nalaze zagušenja (brzina slobodnog toka) i gdje se nalaze zagušenja (jako mala brzina kretanja). VSLC sustav ima zadaću homogenizirati brzine vozila na autocesti. Vrijednost VSLC sustava se može mijenjati kroz vrijeme, na primjer postepeno povećavati ili smanjivati. U slučajevima smanjene vidljivosti, skliskih kolnika, prometne nesreće ili prilikom zatvaranja traka prometnice VSLC sustav se koristi za smanjenje brzine vozila do mjesta gdje nastaje usko grlo ili zagušenje. VSLC sustav sprečava dotok novih vozila u glavni tok niže od mjesta zagušenja kako bi lakše i učinkovitije vršio homogenizaciju sa manjim brojem vozila. Glavni cilj VSLC sustava je omogućavanje sigurnog i brzog putovanja sudionicima prometa.

Neprikladna brzina kretanja vozila je jedan od najčešćih uzročnika prometnih nesreća. Ako vozač nije dovoljno rano upozoren da se da se u nastavku prometnice odvijaju radovi, da je sklizak kolnik ili se nalazi zagušenje, on ne može pravovremeno početi uspraviti svoje vozilo, a upravo to je zadaća VSLC sustava.


Uz promjenjive prometne znakove postoji promjenjiva prometna signalizacija koja za zadaću ima obavijestiti sudionike u prometu o pridržavanju propisa u prometu koji su nastali nekom atipičnom situacijom. Pod promjenjivom prometnom signalizacijom i obavijestima podrazumijevaju se [4]:

- Upravljanje svjetlosnom signalizacijom promjenjive obavijesti;
- Upravljanje promjenjivim pisanim porukama na displeju;
- Naredbe i obavještanje preko internog razglasnog sustava;
- Obavijesti preko radiodifuzije.

Uz promjenjivu prometnu signalizaciju postoji i stalna svjetlosna signalizacija koja podrazumijeva stalno svjetleće prometne znakove i LED delineatore. Na obilaznicama su najčešći upravo takvi, rijetko promjenjivi, znakovi. Stalnom i promjenjivom prometnom signalizacijom, u slučaju zagušenja ili incidenta, vozače se upozorava pravovremeno na nastalu situaciju te oni mogu postepeno usporavati čime se smanjuje rizik od nove prometne nezgode ili nesreće. Ako urbana autocesta prolazi kroz tunel, problem nastaje u slučaju ako s jedne tunelske cijevi pada kiša, a s druge ne, a prometna signalizacija nije prilagođena za vozače koji iz povoljnijih vremenskih uvjeta ulaze u zonu gdje je poledica, mokri i skliski kolnik. Naravno, to nije jedina atipična situacija koja se može dogoditi u tunelu. Može doći do tehničkog kvara vozila, požara u vozilu, prometne nezgode ili nesreće ili bilo kakvih drugih nepredvidljivih zastoja prometa u tunelu. Zbog svih navedenih razloga može se zaključiti da je promet potrebno nadzirati, voditi i upravljati.

3. Najčešće metode upravljanja ograničenjem brzine

Jedan od često zastupljenih oblika upravljanja prometom na urbanim autocestama u današnje vrijeme je VSLC. U slučajevima smanjene propusnosti autoceste ili potpunog prometnog zastoja, sudara ili lošeg vremena (kao na primjer kiša, snijeg, snažni vjetar i slično) mijenja se dopuštena brzina kretanja pomoću promjenjivih prometnih znakova (eng. Variable Message Signs - VMS). Promjenjivi prometni znakovi upozoravaju i informiraju vozače o novonastaloj promijeni ograničenja brzine. VMS znakovi koji sadrže ograničenja brzine se najčešće postavljaju iznad prometnih trakova radi bolje uočljivosti u odnosu na statične prometne znakove koji se nalaze uz rub kolnika, kao što je prikazano na slici 3. U slučaju da ne postoji promjenjivo ograničenje brzine, VMS znakovi prikazuju već određeno ograničenje brzine za tu dionicu autoceste ili preporučenu brzinu, a kako bi podsjetili vozače na održavanje sigurne udaljenosti od vozila ispred [5].



Slika 3. Ilustracija sigurne udaljenosti od vozila ispred [6]

Istraživanja u [7] pokazuju da se većina prometnih nesreća na autocestama događaju iz razloga što su između pojedinih vozila velike razlike u brzini, kao što su i

velike razlike u brzini u pojedinim prometnim trakama. Upravo ta nejednolikost u brzini kretanja između vozila i prometnih traka uvelike povećava rizik od nastanka prometnih nesreća na autocestama. Stoga su danas među najznačajnijim istraživanjima ona na području kooperativnog upravljanja vozila i njegovog okruženja gdje se analizira komunikacija između vozila, infrastrukture i vozača (V2V – vozilo s vozilom, V2I – vozilo s infrastrukturom i V2U – vozilo s ostalim korisnicima u prometu) s ciljem smanjivanja prometnih nesreća. Također, postoje istraživanja [8] koja pokazuju da je moguće ograničiti priljev prometnog zastoja dinamičkim ograničenjima brzine uz održavanje stabilnog tijeka prometa. Uz povećavanje sigurnosti u prometu, VSLC sustav smanjuje vrijeme putovanja [9], a pozitivno utječe i na smanjivanje nastajanja prometnih zastoja odnosno zagušenja. Postoje tri vrste prometnih zastoja, a to su [10]:

- Zagušeni tok karakteriziran jakom interakcijom između vozila-vozača i nelinearnih dinamičkih pojava kao što je prometni zastoj ili šok val;
- Klasični zastoj u prometu gdje se brzina približava nuli i gustoća se povećava do maksimalne, ako ne i iznad maksimalne vrijednosti;
- Zagušenje nastalo stacionarnim valovima u kojima je protok na dionici autoceste konstantan, ali se brzina i gustoća znatno mijenjaju.

Trenutno se koristi nekoliko pristupa u primjeni VSLC-a, ovisno o tome kako se želi utjecati na prometni tok. Ti pristupi [11] se mogu podijeliti u sljedeće grupe:

- Pristupi usmjereni na učinke harmonizacije primjenom VSLC-a (homogenizacija znači stvaranje ravnomyernosti brzina i prometnog toka unutar prometnih trakova i između njih, te prema tome znači i smanjenje rizika od nastanka šok-valova, sudara i prometnog zagušenja);
- Pristupi usmjereni na sprječavanje prometnih slomova (eng. *traffic breakdowns*) smanjenjem prekomjernog prometnog toka primjenom ograničenja brzine;
- Pristupi usmjereni na stabilizaciju prometnog toka u slučaju loših vremenskih uvjeta.

Prvom pristupu odnosno homogenizacijskom pristupu namjera je smanjiti razliku u brzini između vozila u prometnom toku, čime se postiže sigurniji i stabilniji protok. Ovaj pristup koristi ograničenja brzine koja su iznad kritične brzine (kritična brzina je brzina koja odgovara maksimalnom protoku ili kapacitetu) tako da se ne ograničava protok. Učinci homogenizacijskog pristupa su [3]:

- Blago smanjenje prosječne brzine i blagi porast gustoće;
- Sigurniji i stabilniji prometni tok;
- Ne dolazi do znatnijeg povećanja prometnog toka;
- U teoriji, može odgoditi nastanak zagušenja, ali ne može suzbiti nastanak šok-valova.

Drugi pristup odnosno pristup sprječavanja nastanka zasićenja prometnih tokova orijentira se na sprječavanje nestabilnih uvjeta prometa što se može postići postavljanjem ograničenja brzine koja su niža od kritične brzine, sa svrhom ograničavanja dotjecanja vozila u područja uskih grla. Sprječavajući nestabilne prometne uvjete može se postići veća propusna moć u odnosu na homogenizacijski pristup [11].

Treći pristup VSLC sustava koji je zasnovan na vremenskim uvjetima koristi se na urbanim autocestama u slučaju pojave magle, kiše, leda, snijega ili drugih vremenskih nepovoljnih uvjeta koji značajno utječu na sigurnost autoceste. Takav VSLC sustav radi tako da se u slučaju pogoršanja vremenskih uvjeta smanjuje ograničenje brzine na prikladnu brzinu kako bi se smanjile mogućnosti nastanka incidentnih situacija.

Uz ova dva pristupa koja se koriste kod primjene VSLC sustava, postoje i tri metode koje se mogu svrstati u sljedeće kategorije [11]:

1. Teorijske metode zasnovane na naprednim upravljačkim metodologijama;
2. Praktične metode zasnovane na jednostavnoj, na pravilima zasnovanoj heuristici;
3. Znanstveno utemeljene metode zasnovane na tehnikama umjetne inteligencije poput neizrazite logike i ekspertnih sustava.

Teorijske metode se zasnivaju na makroskopskim modelima prometnog toka na dionici autoceste. Na određenim mjestima na autocesti nalaze se detektori koji prikupljaju podatke o brzini i propusnoj moći pomoću kojih se procjenjuje stanje prometa. Nakon što se procjeni stanje prometa, i uz pomoć modela prometnog toka, moguće je dizajnirati optimalnu strategiju za optimalno postavljanje signala. Praktične metode se zasnivaju na upravljačkoj logici gdje se promjena ograničenja brzine zasniva na prometnom toku, brzini ili gustoći. Pri odabiru promjene ograničenja brzine veliku važnost imaju posebne okolnosti koje se mogu događati na odabranoj dionici autoceste, kao što su na primjer klimatski uvjeti, doba dana ili promjenjivost brzina. Znanstveno utemeljene metode generiraju rješenje za trenutnu situaciju u prometu koristeći mehanizme rasuđivanja. Danas se znanstveno utemeljene metode najčešće koriste u drugim područjima upravljanja prometom (kao na primjer upravljanja priljevnim tokovima na autocestama), ali se također počinje razmatrati njihova primjena u VSLC sustavima [3]. U svijetu se trenutno primjenjuju uglavnom metode za upravljanje VSLC-om temeljene na praktičnim metodama. Međutim, svaka od navedenih metoda dizajnirana je za postizanje određenih ciljeva i u tu svrhu se koriste.

Primarni ciljevi primjene VSLC-a na autocestama [12, 13]:

- Harmoniziran prometni tok;
- Smanjenje vremena putovanja;
- Povećanje pouzdanosti vremena putovanja;
- Veća iskorištenost prometnih traka;

- Smanjenje učestalosti stani-kreni vožnje;
- Povećanje sigurnost odnosno smanjenje broja incidentnih situacija;
- Smanjenje emisije ispušnih plinova;
- Smanjenje stresa u vožnji.

Dakle, glavne prednosti primjene VSLC sustava su smanjenje razlike brzina između vozila u različitim trakama (primjena na autocestama pri većem prometnom opterećenju) te omogućavanje ujednačenog i stabilnog prometnog toka u svim prometnim trakovima, zbog čega se stvara uniforman i prihvatljiv interval slijeđenja vozila [14].

Na slici 4. je prikazan primjer rada VSLC sustava [15]. Komponente VSLC sustava su:

- Promjenjivi prometni znakovi za prikazivanje ograničenja brzina (VMS);
- Detektori koji prate zauzeće na glavnom toku;
- Upravljačko računalo koje donosi odluku o ograničenju brzine;
- Sensori za otkrivanje kiše, vjetra, temperature i magle (meteorološko upravljani VSLC).



Slika 4. Primjer rada VSLC sustava [15]


Postoje određeni zahtjevi za vizualnim performansama odnosno zahtjevi kako bi izgled znaka koji služi za regulaciju prometa putem VSL sustava trebao izgledati. Primjer je vidljiv na slici 5. Obavezni VSL-ovi trebali bi zadovoljavati jedan od sljedećih opisa izgleda znaka [16]:

- Promjenjivi znakovi su označeni bijelom, bijelom isprekidanom ili žutom linijom na crnoj podlozi okruženi sa crvenom kružnicom;
- Promjenjivi znakovi mogu biti izvedeni bez kontrasta boja ako nacionalni zakoni to dozvoljavaju;
- Nepromjenjivi znakovi trebaju biti izvedeni tako da budu slični stalnim ograničenjima brzine kako je propisano nacionalnim zakonima.




Slika 5. Izgled VSL znaka [16]

Najčešća metoda za prikupljanje stvarnovremenskih podataka poput protoka, gustoće i brzine vozila je uporaba detektora induktivne petlje koji su smješteni uz sam kolnik. Druge metode obuhvaćaju korištenje radara i video nadzora (eng. Closed Circuit Television - CCTV). Da bi se unaprijedila točnost procjene prometnih podataka, često se kombiniraju ove tri metode. Najtočnije podatke daje video nadzor, a korištenje istog u svrhu senzora u prometnoj mreži ima puno prednosti, kao što su npr. istovremeno mjerenje više prometnih parametara poput prometnog protoka, ishodišno-odredišne (OD) matrice, udaljenosti između vozila, brzine kretanja vozila, klasifikacije tipa vozila (motocikl, osobno/teretno vozilo, autobus i dr.), estimacija distribucije zemlje porijekla vozača. Ujedno, video kamere je jednostavno implementirati u postojeću prometnu infrastrukturu i mali su troškovi u usporedbi sa drugim sensorima. Međutim, postoje i neki nedostaci kao što je veliki udio grešaka u izmjerenim prometnim parametrima zbog utjecaja loših vanjskih uvjeta okoline (kiša, magla, vibracija, nagla promjena osvjjetljenja i dr.) i potrebno je održavanje (čišćenje stakla objektiva kamere) [17]. Na slici 6. prikazano je prikupljanje podataka o učestalosti pretjecanja video nadzorom.



Slika 6. Prikaz prikupljanja podataka o učestalosti pretjecanja video kamerom [18]

Također, postoje dva algoritma na kojima se zasniva rad VSLC regulatora, a to su: regulator virtualnog upravljanje priljeva glavnog toka (eng. Mainline Virtual Metering - MVM) i jednostavni proporcionalni regulator ograničenja brzine (eng. Simple Proportional Speed Limit Controller - SPSC) [4]. MVM regulator zasniva se na konceptu upravljanja priljevnim tokovima, dok je SPSC pojednostavljeni MVM regulator. Oba mogu djelovati samo u uskom području primjene prometne potražnje, što je ujedno i njihov nedostatak te su zasnovani na osnovnoj zavisnosti toka-gustoće preslikanoj u iznos brzine kao što je prikazano na slici 7.



Slika 7. Osnovna zavisnosti toka-gustoće preslikana u iznos brzine [4]

U idućem poglavlju analizirana je primjena logičkog stabla odlučivanja u upravljanju ograničenjem brzine.

4. Primjena logičkog stabla odlučivanja u upravljanju ograničenja brzine

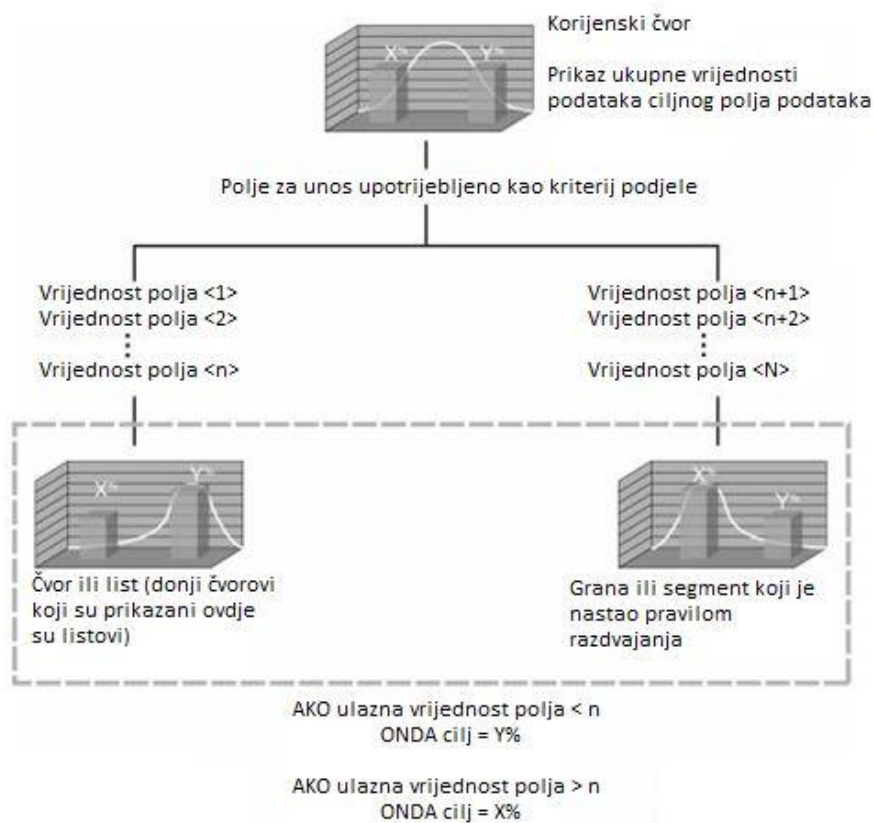
Logička stabla odlučivanja su jednostavna, ali moćna forma višestruke analize varijable. Pružaju jedinstvene mogućnosti dopune, nadopune i zamjene za [19]:

- Tradicionalni statistički oblik analize (poput višestruke linearne regresije);
- Niz alata i tehnika rudarenja podataka (poput neuronskih mreža);
- Nedavno razvijene višedimenzionalne oblike izvješćivanja i analize u području poslovne inteligencije.

Stablo odlučivanja je alternativni način prikazivanja i analize situacije odlučivanja. Sve situacije koje možemo prikazati na tablici odlučivanja mogu se također prikazati i na stablu odlučivanja. Stablo odlučivanja je slikovit model koji reprezentira čitavu strukturu odlučivanja. Pretpostavke uporabe stabla odlučivanja su [20]:

- Donositelj odluke ima na raspolaganju većinu relevantnih inačica odluke;
- Moguće posljedice (ishodi) inačica odluke mogu se na neki način kvantificirati;
- Pri izboru se razmatraju samo ona obilježja inačica odluka koja se mogu kvantificirati;
- Stablo odlučivanja može se analizirati ako postoje subjektivne vjerojatnosti nastupanja nesigurnih događaja.

Logička stabla odlučivanja izrađuju se pomoću algoritama koji identificiraju različite načine raspodjele skupova podataka u segmente sličnih grana. Ti segmenti čine obrnuto stablo odluke koje potječe od korijenskog čvora na vrhu stabla. Cilj analize odražava se u tom korijenskom čvoru kao jednostavan, jednodimenzionalni prikaz u sučelju stabla odlučivanja. Obično se prikazuje naziv polja podataka koji je predmet analize, zajedno sa širenjem ili distribucijom vrijednosti koje se nalaze u tom polju. Stablo odlučivanja prikazano je na slici 8.

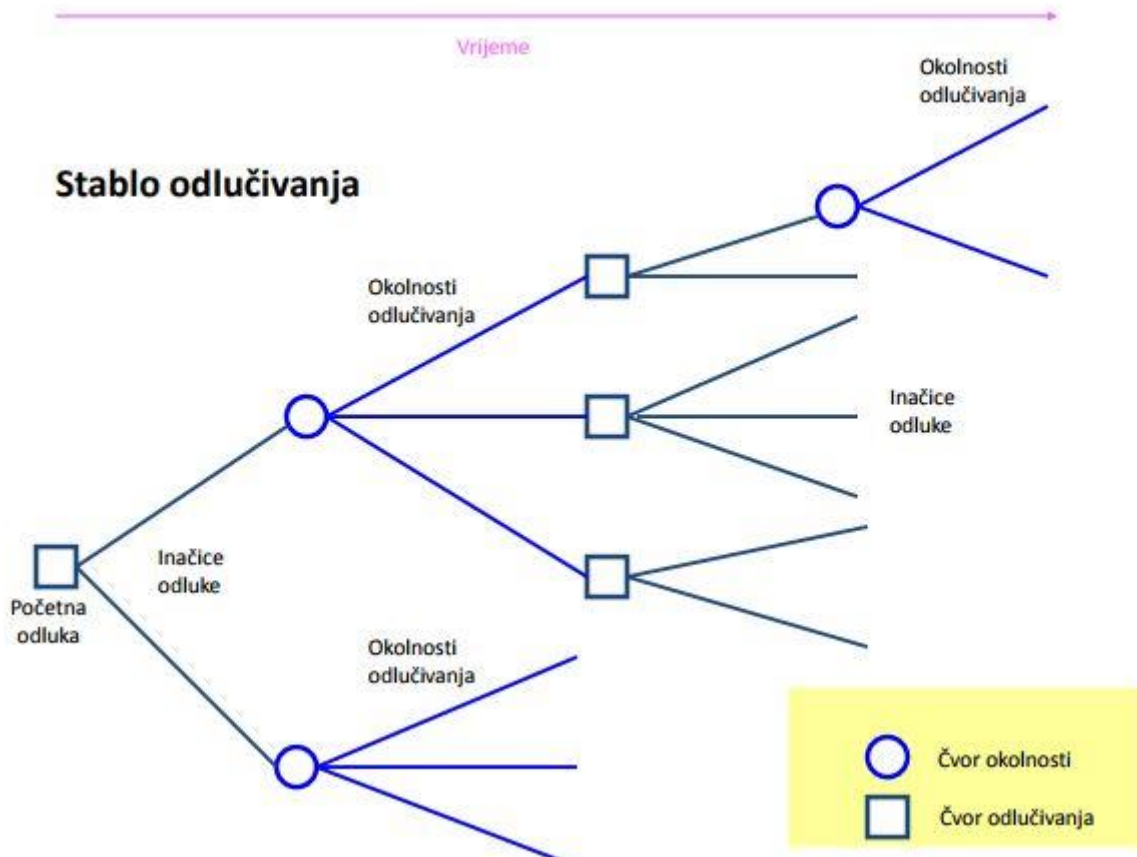


Slika 8. Ilustracija stabla odlučivanja [19]

Na slici 8. vidljivo je kako stablo odlučivanja može odražavati kontinuirani i kategorijski objekt analize. Ovakav čvor sadrži sve zapise podataka, polja i vrijednosti polja koji se nalaze u objektu analize. Pravila razdvajanja, pomoću kojih se odlučuje oblikovanje grana ili segmenata ispod korijenskog čvora, se zasnivaju na metodi koja ekstrahira odnos između objekta analize (koji predstavlja ciljano polje u podacima) i jedno ili više polja koja služe kao ulazna polja za stvaranje grana ili segmenata. Vrijednosti u ulaznom polju se koriste za procjenu vjerojatne vrijednosti ciljnog polja. Ciljno polje se također naziva ishodom, odgovorom, ovisnim poljem ili varijablom. Kada se odnos ekstrahira, tada se može izvesti jedno ili više pravila odlučivanja koja opisuju odnose između ulaza i ciljeva. Pravila se mogu odabrati i koristiti za prikaz logičkog stabla odlučivanja što omogućuje vizualni pregled svih ulaznih i ciljnih vrijednosti. Pravila odlučivanja mogu predvidjeti vrijednosti novih ili neviđenih opažanja koja sadrže vrijednosti ulaza, ali možda ne sadržavaju vrijednosti ciljeva.

4.1. Analiza stabla odlučivanja

Kao što je prethodno spomenuto, analiza stabla odlučivanja zasniva se na metodi povratne indukcije, koja je prikazana na slici 9. Analiza počinje na krajnjim granama i nastavlja se u pravcu početnog čvora odlučivanja. Na svakom čvoru okolnosti izračunava se očekivana korisnost (novčana vrijednost u slučaju ovog primjera). Na svakom čvoru odlučivanja bira se inačica koja maksimizira očekivanu korisnost (novčanu vrijednost u slučaju ovog primjera).




Slika 9. Prikaz metode povratne indukcije na primjeru stabla odlučivanja [20]

Tehnika logičkog stabla odlučivanja pogodna je za analizu složenijih i dinamičnijih situacija odlučivanja. Osobito je korisna kada postoji mogućnost da se odlučivanje podijeli u niz manjih situacija izbora, koje se u vremenskom slijedu naslanjaju jedna na druge. Postoje i neke poteškoće u primjeni stabla odlučivanja, a to su [20]:

- Dobro stablo odlučivanja ne može „podnijeti“ preveliki broj inačica, niti preveliki broj nesigurnih događaja;
- Što je vremensko obzorje udaljenije, analiza je teža;
- Potrebna je konzistencija u dodjeljivanju subjektivnih vjerojatnosti nesigurnim događajima.

4.2. Upravljanje promjenjivim ograničenjem brzine zasnovano na logičkom stablu odlučivanja uključujući protok, gustoću i srednju brzinu

U algoritmu koji je korišten u ovom radu ograničenja brzina određuju se na temelju logičkog stabla odlučivanja koji sadrži protok, gustoću i srednju brzinu kretanja vozila. Logika donošenja odluka primijenjena u ovom radu prikazana je na grafikonu 1.



Grafikon 1. Logika donošenja odluka [21]

Algoritam prvo uzima u obzir podatke o protoku iz detektora koji se nalaze na autocesti. Ako je protok manji ili jednak 2.000 vozila po satu po traci, u sljedećem koraku se promatra gustoća. Ako je gustoća manja ili jednaka 15 [voz/km/trak], postavlja se maksimalna dopuštena brzina od 130 kilometara po satu. Ako je gustoća veća od 15 [voz/km/trak], srednja brzina određuje brzinu koja se prikazuje na VMS-u. Vraćajući se na prvi korak, ako je protok veći od 2.000 vozila po satu po traci, logika prelazi ravno do srednje brzine koja određuje ograničenje. Brzina koja se prikazuje se zatim šalje na odgovarajući VSL znak. Pragovi koji u prikazani na slici su fiksni. Prosječna brzina kretanja vozila odnosno ograničenja brzine koja se prikazuju na VSL znakovima su između 130 i 80 kilometara na sat.


U idućim poglavljima objašnjen je model urbane autoceste na kojem se odvija simulacija, kao i rezultati iste te usporedba algoritama bez VSLC i s VSLC-om.

5. Model urbane autoceste

U svrhu ovog rada izrađen je model urbane autoceste u mikroskopskom prometnom simulatoru PTV VISSIM. Model autoceste sadrži dva priljevna toka i jedan odljevni tok na glavnom toku s tri trake. Uz dodatak VISSIM API omogućena je komunikacija između programskih paketa MATLAB i VISSIM. Pomoću programskog kôda napisanog u MATLAB programskom paketu može se upravljati prometnom simulacijom u PTV VISSIM-u. Dobiveni rezultati VISSIM simulacije proslijeđeni su simulatoru EnViVer koji je dobiven kao dodatak programskom paketu VISSIM. Programski alat EnViVer koristi se za izračun emisija štetnih ispušnih plinova. U slijedećim podpoglavljima dodatno su opisani parametri modela autoceste koji su korišteni u svrhu ovog istraživanja (konfiguracija i prometni podaci), simulator prometa VISSIM te simulator zagađenja EnViVer.

5.1. Parametri modela autoceste

S ciljem dobivanja relevantnih rezultata, odnosno rezultati koji se mogu uzeti u obzir, veoma je bitno dobro podesiti parametre na modelu kako bi se što više približili stvarnom ponašanju vozila na autocesti. Praćenje vozila podešeno je na model Wiedemann 99. Neki od parametara Wiedemann 99 modela su udaljenost između vozila tijekom zastoja u iznosu od 1,5 [m], vremenski interval slijeđenja koji iznosi 0,9 [s], varijacije slijeđenja koje mogu biti do 4 metra, oscilacije akceleracije do 0,25 [m/s²], akceleracija s mjesta do 2,5 [m/s²], a akceleracija pri brzini od 80 [km/h] iznosi 1,5 [m/s²]. Sve vrijednosti parametara Wiedemann 99 modela prikazani su na slici 10.



Car following model


Wiedemann 99

Model parameters

CC0 (Standstill Distance):	1.50	m
CC1 (Headway Time):	0.90	s
CC2 ('Following' Variation):	4.00	m
CC3 (Threshold for Entering 'Following'):	-8.00	
CC4 (Negative 'Following' Threshold):	-0.35	
CC5 (Positive 'Following' Threshold):	0.35	
CC6 (Speed dependency of Oscillation):	11.44	
CC7 (Oscillation Acceleration):	0.25	m/s ²
CC8 (Standstill Acceleration):	2.50	m/s ²
CC9 (Acceleration with 80 km/h):	1.50	m/s ²


Slika 10. Parametri Wiedemann 99 modela [22]

Model urbane autoceste je podijeljen na četiri ćelije, a od kojih se u prve tri vrše promjene ograničenja brzine s obzirom na ćeliju ispred (gledajući s lijeva na desno). Pošto ćelija četiri nema simuliranu ćeliju ispred sebe, ne postoje podaci u stvarnom vremenu o prometnoj situaciji te zato nije moguće izvršiti promjene ograničenja brzine unutar iste. Prva ćelija je dugačka 1 [km], druga ćelija je dugačka 700 [m] i ima priljevni tok r_1 . Treća ćelija dugačka je 800 [m] i u njoj se odvija odljev dijela prometnog toka s_1 . Četvrta ćelija dugačka je 2 [km] i na njoj se nalazi priljevni tok r_2 . Tijekom simulacije na glavnom prometnom toku (Q) generira se konstantan tok od 4.200 [voz/h]. Raspored ćelija označen je na slici 12 gdje je prikazana skica modela urbane autoceste korištenog u simulaciji. Priljevni tok r_1 ima također konstantan tok od 1.250 [voz/h], dok priljevni tok r_2 ima promjenjiv iznos prometnog generiranog toka. Priljevni tokovi prikazani su na slici 11. Minimalni iznos prometnog toka r_2 iznosi 300 [voz/h], a maksimalni iznos je 1.250 [voz/h]. Ukupno trajanje simulacije je dva sata.



Slika 11. Raspored ćelija [22]

Izlazna mjerenja simulacije programskog paketa VISSIM šalju se kao ulazni podaci MATLAB programskom jeziku u kojem je napravljen algoritam upravljanja promjenjivim ograničenjem brzine koji kao izlaz daje ograničenje brzine na VSL znaku. Nakon što se simulacija izvrši, na osnovi dobivenih podataka, pokrene se analiza emisije štetnih plinova u programskom alatu EnViVer. Blokovska shema funkcioniranja prikazana je na grafikonu 2.



Grafikon 2. Blokovska shema funkcioniranja svih korištenih programa [22]

5.2. Simulator prometa PTV VISSIM

VISSIM je cestovni simulacijski program tvrtke PTV koji se zasniva na mikroskopskoj simulaciji što znači da se svaki entitet (automobil, kamion, vlak, osoba i drugo) simulira na individualnoj razini. Ovi modeli se temelje na opisivanju razmaka uzastopnih vozila u koloni pomoću brzine, ubrzanja, puta kočenja i dr. Opisivanje prometnog toka, koje se zasniva na promatranju kretanja njegovih elemenata (pojedinih vozila), naziva se u teoriji prometnog toka mikroskopsko promatranje, a matematički modeli zasnovani na takvim promatranjima nazivaju se mikroskopski modeli [23]. Uz mikroskopsku simulaciju postoji i makroskopska simulacija. Ukoliko se prometni tok promatra kao kontinuirani proces protjecanja vozila u jednom smjeru prometnice uz činjenicu da je svako vozilo individualno kontrolirano od strane vozača, odnosno poštujući stav da se svako pojedinačno vozilo u promatranom prometnom toku kreće isključivo po zakonitostima ukupnog toka, takvo promatranje se naziva makroskopsko promatranje. Obzirom na određenu sličnost između protjecanja fluida i prometnih tokova i obzirom na činjenicu da je hidrodinamika starija znanstvena disciplina od teorije prometnog toka, polazna je ideja da se, uz određena ograničenja, poznate zakonitosti kojima se opisuje kretanje fluida iskoriste u opisivanju zakonitosti protjecanja prometnim tokovima [23].

Dakle, mikroskopski modeli opisuju ponašanje između dva vozila u toku, uz pretpostavku da se takvo ponašanje može primijeniti na sva ostala vozila. Zbog toga se koriste parametri koji opisuju kretanje na razini svakog tipa vozila, a neki od njih su brzina, interval slijeđenja i razmak vozila [24].

5.3. Simulator emisije štetnih plinova

Promet velikim dijelom utječe na okoliš na način da ga zagađuje ispušnim plinovima. Danas je emisija štetnih plinova jedna od najbitnijih stavki u prometnim studijama. U ovom radu korišten je programski dodatak EnViVer, koji je zasnovan na VERSIT+ modelu emisije štetnih plinova, pomoću kojeg je moguće proučavati emisiju zagađenja. EnViVer je u mogućnosti izračunati emisije CO₂, NO_x i PM₁₀ štetnih ispušnih plinova na temelju podataka dobivenih iz simulacije prometa. Pomoću podataka o brzini, akceleraciji, tipova vozila i količini prometnog toka iz rezultata prometne simulacije programski dodatak EnViVer može odrediti emisiju štetnih plinova. U ovom diplomskom radu odabrane su postavke za sastav vozila (raspodjela po starosti i vrsti pogona) temeljene na realnim podacima za Republiku Hrvatsku za 2016. godinu. Odabrani parametri su:

- Vrsta prometnice na kojoj se odvija simulacija (autocesta ili urbano područje);
- Tip vozila (teški, srednji ili laki tip vozila, odnosno kamioni, autobusi ili osobni automobili);
- Statistička raspodjela zastupljenosti goriva (benzin, dizel, ukapljeni naftni plin, hibridi i električna vozila) [25, 26];
- Distribucija starosti vozila [27];
- Raspodjela o legislaciji emisija;
- Podaci o prosječnoj emisiji CO₂.

Vrijednosti navedenih parametara korištenih u ovom radu prikazani su na slici 12.

Vehicle parc

Road type:
 Urban Highway

Vehicle type:
 Light-duty Bus Heavy-duty

Name: Custom_light_RH
Era: 2016
Reset to road & vehicle type defaults

Fuel type

Fuel type	Percentage	Lock
Petrol:	56.8 %	<input type="checkbox"/>
Diesel:	39.4 %	<input type="checkbox"/>
LPG:	3.5 %	<input type="checkbox"/>
CNG:	0.1 %	<input type="checkbox"/>
Electric:	0.1 %	<input type="checkbox"/>

Vehicle age distribution

Newer than 1 year: 5.3 %
Average vehicle age: 13.8 year
Average exit age: 20.0 year
Maximum age: 50 year

Emission legislation

Euro nom	Regular date	Introduction date
Euro 1:	1.7.1992.	1992 Year
Euro 2:	1.10.1995.	1993 Year
Euro 3:	1.10.2000.	2000 Year
Euro 4:	1.10.2005.	2005 Year
Euro 5:	1.10.2008.	2009 Year
Euro 6:	1.1.2013.	2014 Year

Average regional CO2 emission

Petrol: 166 g/km
Diesel: 158 g/km

Slika 12. Odabrane postavke u EnViVer programskom paketu


6. Simulacijski rezultati

U ovom poglavlju uspoređeni su dobiveni podaci simulacije prometnog modela urbane autoceste s primjenom promjenjivog ograničenja brzine zasnovanog na logičkom stablu odlučivanja i bez primjene promjenjivog ograničenja brzine. Prometni model koji je korišten objašnjen je u prethodnom poglavlju. Rezultati simulacija sadrže karakteristične parametre prometnog toka na temelju kojih su uspoređeni odabrani algoritam promjenjivog ograničenja brzine sa slučajem u kojem nije korišten niti jedan algoritam. Algoritam skuplja mjerenja sa senzora, izračunava prometne parametre i kao izlaznu vrijednost vraća ograničenje brzine koje djeluje na prometni tok i nastalu prometnu situaciju u simulaciji. Rezultati simulacije ovise o nasumično generiranom sjemenu, što znači da ovisi o reakciji algoritma na nastale prometne situacije i njegovu sposobnost da utječe na prometni tok pomoću prikupljenih mjerenja i prometnih parametara.

Drugi dio dobivenih rezultata opisuju ekološki utjecaj prometnog toka vozila na okolinu za slučaj s upravljanjem ograničenjem brzine. Glavni pokazatelj ekološkog utjecaja na prometni tok je zagađenje koje nastaje kao posljedica ispušnih plinova vozila. Za izračun emisije ispušnih plinova korišten je programski alat EnViVer koji se koristi u kombinaciji s programskim paket VISSIM.

6.1. Protok, gustoća i srednja brzina po ćelijama


U ovom podpoglavlju prikazani su rezultati izmjerenog protoka, gustoće i srednje brzine po ćelijama za slučaj s upravljanjem ograničenjem brzine i za slučaj bez upravljanja. Podjela rezultata je napravljena na principu vremenskog intervala osvježavanja vrijednosti ograničenja brzine. Algoritam za svaki taj interval mijenja ograničenje brzine, odnosno ulazi u provjeru da li se iznos ograničenja brzine treba promijeniti. U slijedećim grafikonima zelenom bojom označena je krivulja koja opisuje prometni tok za slučaj bez VSLC-a, tj. ograničenje brzine se ne mijenja i iznosi konstantnih 130 [km/h]. Crvenom bojom označena je krivulja koja opisuje prometni tok sa VSLC koji je aktivan svakih 5 [min]. Apscise na grafovima predstavljaju vremenski tijek simulacije izražen u satima [h], dok ordinate prikazuju protok toka, gustoću te srednju brzinu vozila. Kako je autocesta definirana s tri prometna traka, dobivene vrijednosti protoka toka izražene su kao ukupan protok kroz promatrani presjek triju traka, dok je gustoća toka definirana kao mjerna jedinica po prometnom traku. Protok se izračunava za svaku ćeliju posebno i to pomoću detektora koji se nalaze na izlazu iz ćelije (eng. *downstream flow*).



Grafikon 3. Protok, gustoća i srednja brzina prometnog toka za prvu i drugu ćeliju

U prvoj skupini grafova (Grafikon 3) uspoređeni su podaci za prvu i drugu ćeliju bez VSLC-a i s VSLC-om. Oznaka grafova u desnom gornjem kutu (C_1 i C_2) označavaju redni broj ćelije. Duljina prve ćelije iznosi 1 [km] i kritična druga rampa, koja je udaljena 1,5 [km] od prve ćelije, nema značajan utjecaj na prometni tok unutar spomenute ćelije. Duljina druge ćelije iznosi 0,7 [km], te se na njenom početku nalazi ulazna rampa r_1 čiji tok iznosi 1.250 [voz/h] i konstantan je tokom cijele simulacije.

Iz gornjih grafova vidljivo je kako su protok, gustoća i srednja brzina u prvoj i drugoj ćeliji približno ista i nema većih odstupanja koje narušavaju protočnost prometnog toka, iako postoji manji pad sva tri parametra za slučaj s VSLC-om. Razlog tome je što VSLC smanjuje ograničenje brzine u drugoj ćeliji što proporcionalno smanjuje i brzinu prometnog toka s ciljem da se smanji brzina propagacije šok vala koji nastaje zbog poremećaja prometnog toka u području oko rampe r_2 koji se širi unatrag niz glavni tok (karakteristika šok vala) prelijevajući se iz ćelije u ćeliju. VSLC algoritam detektira taj poremećaj (povećanje gustoće prometnog toka u ćeliji ispred odnosno u trećoj ćeliji) i smanjuje ograničenje brzine u drugoj ćeliji što dovodi do malog pada protoka, gustoće i srednje brzine za slučaj s VSLC-om.



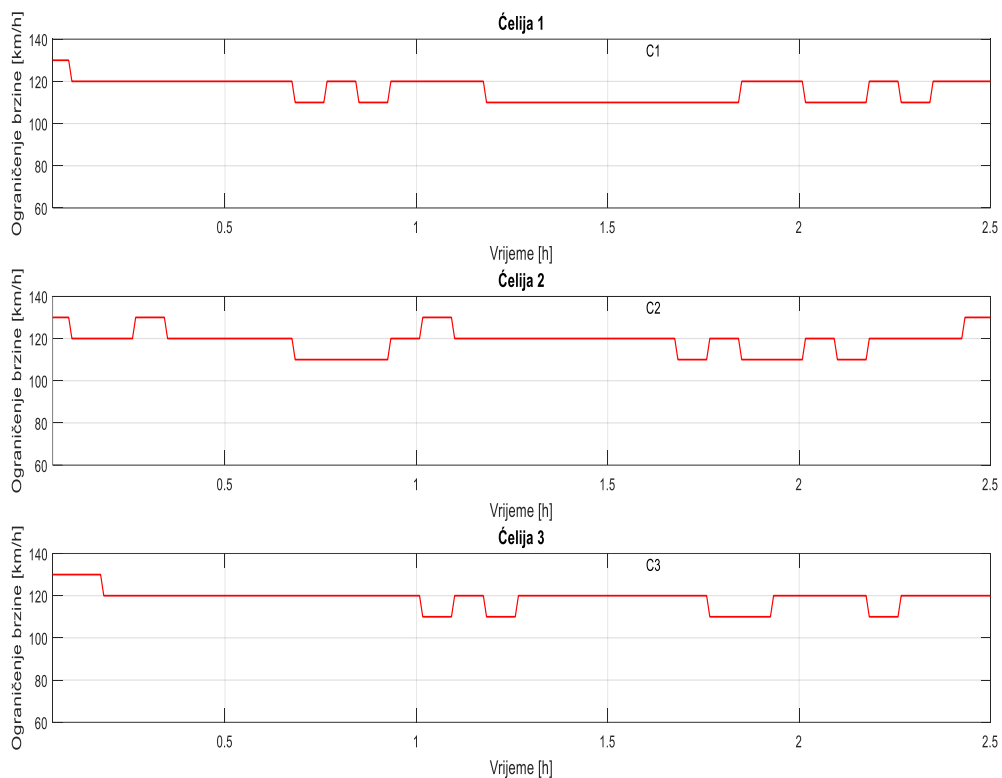
Grafikon 4. Protok, gustoća i srednja brzina prometnog toka za treću i četvrtu ćeliju

U drugoj skupini grafova (Grafikon 4) uspoređeni su podaci za treću i četvrtu ćeliju bez VSLC-a i s VSLC-om. Oznaka grafova u gornjem desnom kutu (C_3 i C_4) označavaju redni broj ćelije. Duljina treće ćelije iznosi $0,8 [km]$ i ona je najbliža drugoj ulaznoj rampi r_2 zbog čega je najizloženija nepovoljnim uvjetima koje stvara, a na njezinom početku nalazi se prva izlazna rampa s_1 .

Iz gornjih grafova vidljivo je da je protok u trećoj i četvrtoj ćeliji približno isti, te nema nekih većih odstupanja za slučaj s VSLC-om i bez VSLC-a. Veće odstupanje vidljivo je kod gustoće i srednje brzine u intervalu od 1 do 2 [h] zbog ulazne rampe r_2 na kojoj nakon 40-tak minuta povećava prometna potražnja na $1.250 [voz/h]$. Povećanjem prometne potražnje na drugoj rampi dehomogenizirao se prometni tok i došlo je do značajnih odstupanja kod gustoće i srednje brzine. Gustoća se naglo povećava, dok brzina pada. Da bi se brzina opet digla na normalne vrijednosti, što je zapravo cilj VSLC sustava, potrebno je da prođe određeno vrijeme da bi se homogenizirao prometni tok. Za slučaj bez VSLC-a, povećanjem prometne potražnje srednja brzina vozila u prometnom toku više pada nego u slučaju s upravljanjem ograničenjem brzine, što se vidi u četvrtoj ćeliji. Usporedno s time, kod slučaja bez upravljanja vidljivo je kako gustoća ostaje duže povišena nego kod slučaja s upravljanjem. Zbog VSLC sustava dolazi do bržeg homogeniziranja prometnog toka.

6.2. Ograničenje brzine

U ovom podpoglavlju prikazani su i analizirani rezultati generiranja promjenjivog ograničenja brzine dobiveni simulacijom. VSLC sustav radi na principu detekcije zagušenja, odnosno smanjenja propusnosti prometnice te sukladno time se odabire novo ograničenje brzine. Da bi protočnost prometnice bila zadovoljavajuća, ali i svi ostali prometni parametri, potrebno je pravovremeno detektirati poremećaje u prometnom toku. Na ovom modelu urbane autoceste nalaze se tri upravljačka algoritma VSLC sustava koja su bazirana na logičkom stablu odlučivanja. Čelije na kojim djeluju su C_1 , C_2 i C_3 . Vrijednosti koje daje VSLC algoritam su cjelobrojne, stoga je krivulja stepenastog oblika u grafu. Raspon brzina koje generira VSLC algoritam kreće se od minimalnih 60 [km/h] do maksimalnih 130 [km/h].



Grafikon 5. Rezultati promjenjivog ograničenja brzine

Na grafikonu 5 prikazani su rezultati ograničenja brzine. Graf s oznakom C_1 prikazuje ograničenje brzine u prvoj ćeliji, graf s oznakom C_2 prikazuje ograničenje brzine u drugoj ćeliji, a graf s oznakom C_3 prikazuje ograničenje brzine u trećoj ćeliji. VSLC algoritam mijenja brzine ovisno o vrijednosti protoka i gustoće koju je izmjerio. Najniža vrijednost brzine koju je izgenerirao VSLC regulator je 110 [km/h], a najviša 130 [km/h]. U slučaju simulacije bez VSLC algoritma vrijednost ograničenja brzine je konstantna i iznosi 130 [km/h]. Kada VSLC senzori koji mjere prometne parametre

detektiraju povećanje protoka ili gustoće, VSLC sustav smanjuje brzinu toka. Primjer je vidljiv u trećoj ćeliji oko 1 [h] od trajanja simulacije kada dolazi do povećanja prometne potražnje zbog druge ulazne rampe. Sustav detektira to povećanje i smanjuje prikazanu brzinu na VSLC znaku.

6.3. Ukupno utrošeno vrijeme i vrijeme putovanja


U ovom podpoglavlju analizirane su dobivene vrijednosti ukupnog utrošenog vremena svih vozila u mreži tijekom simulacije i vrijednost vremena putovanja pojedinog vozila da prođe od početka do kraja modela autoceste po glavnom prometnom toku. Vrijednost ukupnog utrošenog vremena (eng. *Total Time Spent* - TTS) označava ukupno vrijeme koje su vozila provela unutar prometne mreže. Ako je vrijeme kraće, znači da su vozila manje vremena provela unutar mreže, odnosno da se prometni tok brže odvijao i suprotno. Kada dođe do zagušenja, brzina vozila se smanjuje i TTS se počne povećavati, odnosno povećanjem intenziteta zagušenja proporcionalno se povećava TTS. TTS se računa prema slijedećoj formuli:

$$TTS = T \sum_{k=1}^k \sum_{i=1}^N Li \cdot \rho_i(k), \quad (1)$$

gdje su:

- $\rho_i(k)$ – gustoća u segmentu i ;
- Li – duljina segmenta i ;
- N – ukupan broj segmenata;
- k – vrijeme trajanja simulacije;
- T – korak simulacije.

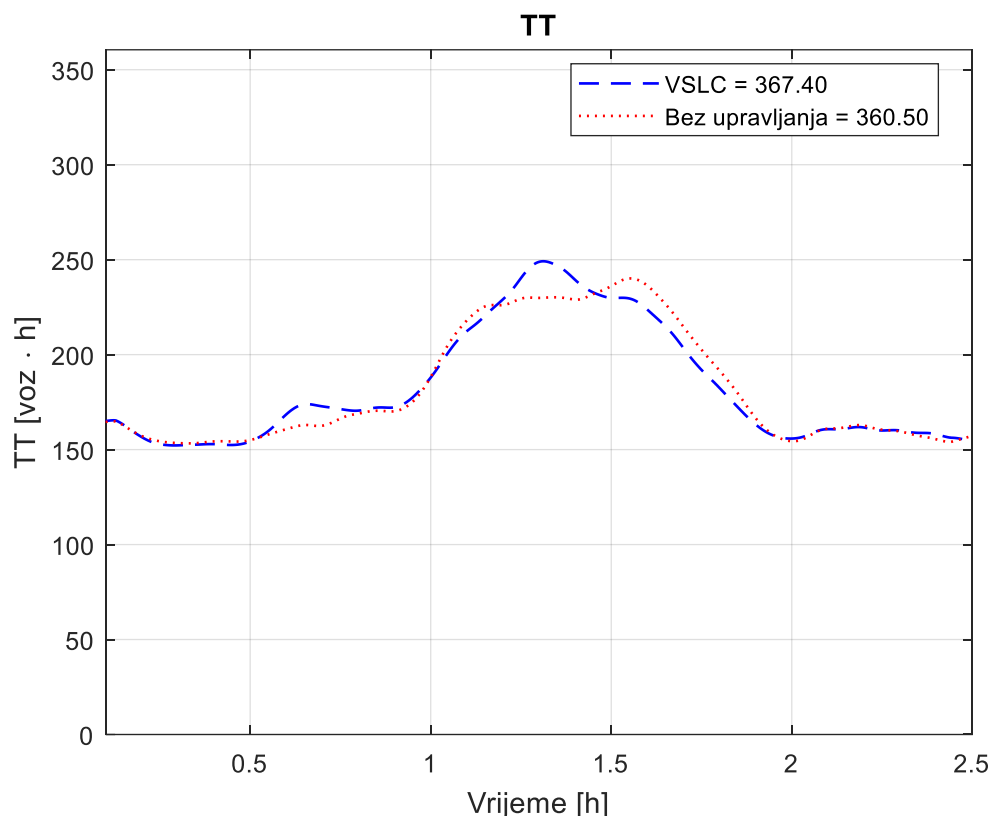
TTS se opisuje mjernom jedinicom umnoška vozila i vremena provedenog u prometnoj mreži [voz·h].



Grafikon 6. Ukupno utrošeno vrijeme putovanja za cijelo trajanje simulacije

Na grafikonu 6. vidljivo je ukupno utrošeno vrijeme putovanja s primjenom VSLC-a i bez primjene VSLC-a za cijelo trajanje simulacije. Primjenom VSLC sustava, koji također smanjuje brzinu ograničenja u slučaju zagušenja, dobije se kraće vrijeme putovanja nego bez VSLC sustava iz razloga što se primjenom VSLC sustav u kraćem vremenu digne brzina vozila u prometnom toku. TTS u slučaju upravljanja iznosi 702,62 [voz h], dok bez upravljanja iznosi 709,58 [voz h]. Primjenom VSLC regulatora TTS je smanjen za otprilike 1%.

Na grafikonu 7 prikazane su prosječne vrijednosti vremena putovanja. Vrijeme putovanja (eng. *Travel Time* - TT) označava vrijeme koje je potrebno jednom vozilu da prođe kroz glavni tok. Kao i za ukupno utrošeno vrijeme, ako dođe do zagušenja u prometnom toku vrijeme putovanja pojedinog vozila se povećava, odnosno intenzitet zagušenja je proporcionalan s vremenom putovanja vozila kroz mrežu. Ukoliko je vrijeme putovanja vozila kraće, znači da se prometni tok brže odvijao i intenzitet zagušenja je bio manji.



Grafikon 7. Prosječne vrijednosti vremena putovanja

Krivulje u grafikonu 7 označavaju prosječne vrijednosti TT, dok se u legendi nalaze maksimalne vrijednosti TT za slučaj bez upravljanja i s upravljanjem. Maksimalna vrijednost TT za slučaj korištenja VSLC regulatora iznosi 367,40 [s] i označena je krivuljom plave boje, dok je maksimalna vrijednost TT za slučaj bez korištenja VSLC regulatora 360,50 [s]. Iz grafa je vidljivo kako su prosječne vrijednosti TT veće naspram prosječnih vrijednosti za slučaj bez regulatora VSLC. U tablici 2 prikazani su rezultati maksimalnog TT, prosječnog TT i TTS za oba slučaja, te njihovo poboljšanje. Vidljivo je da je vrijeme putovanja pojedinog vozila u slučaju bez VSLC regulatora kraće nego u slučaju s VSLC regulatorom, ali je ukupno utrošeno vrijeme svih vozila da prođu od početka do kraja modela kraće nego u slučaju bez upravljanja.


Tablica 2. Rezultati maksimalnog i prosječnog TT i TTS

	Bez VSLC	VSLC	Poboljšanje [%]
Maksimalni TT [s]	360,50	367,40	-1,89
Prosječni TT [s]	180,95	181,01	-0,03
TTS [voz·h]	709,58	702,62	0,98

6.4. Duljina reda čekanja na ulaznim rampama r_1 i r_2

U ovom podpoglavlju analizirana je duljina reda čekanja vozila na ulaznim rampama r_1 i r_2 . Duljina reda čekanja vozila na ulaznim rampama izražena je u broju vozila koja čekaju uključeno na glavni tok. Red čekanja na ulaznim rampama ovisi o prometnoj situaciji na glavnom toku. Ukoliko dođe do zagušenja red na ulaznim rampama se povećava. Primjenom VSLC regulatora red čekanja bi trebao biti manji nego u slučaju bez VSLC regulatora jer se prometni tok brže harmonizira što se najbolje vidi na drugoj ulaznoj rampi r_2 na kojoj povećava prometna potražnja nakon 40-tak minuta povećava za 1.250 [voz/h].

Na grafikonu 8 prikazane su krivulje reda čekanja na rampama r_1 i r_2 . Crvenom bojom označena je krivulja koja prikazuje red čekanja s primjenom regulatora VSLC, dok je zelenom bojom označen red čekanja bez upravljanja.



Grafikon 8. Duljina reda čekanja vozila na ulaznim rampama r_1 i r_2

Iz grafa je vidljivo kako je red čekanja na rampi r_1 skoro isti u oba dva slučaja, dok na rampi r_2 u jednom trenutku dolazi do velikog skoka krivulje u intervalu od 1 [h] do 1,5 [h] u slučaju bez upravljanja, što je razumljivo s obzirom da se nakon 40-tak minuta

povećava prometna potražnja na toj rampi. U slučaju s primjenom VSLC regulatora povećanje prometne potražnje je također vidljivo, ali ne u tolikoj mjeri koliko bez upravljanja. U tablici su prikazane prosječni i maksimalni red čekanja na drugoj rampi u oba slučaja te njihovo poboljšanje. Iz tablice 3. se može zaključiti da se primjenom VSLC regulatora prosječni red čekanja smanjio na drugoj rampi za 13,83% u odnosu bez primjene VSLC regulatora, te maksimalni red čekanja za 47,11%.

Tablica 3. Maksimalne i prosječne vrijednosti reda čekanja

Red čekanja	Bez VSLC [voz]	VSLC [voz]	Poboljšanje [%]
Maksimalni	21,46	11,35	47,11
Prosječni	4,05	3,49	13,83

6.5. Emisija štetnih ispušnih plinova

U ovom podpoglavlju prikazani su rezultati analize emisije štetnih ispušnih plinova te ekološki utjecaj prometa na okoliš. Za procjenu emisije štetnih ispušnih plinova korišten je programski alat EnViVer koji rezultate prikazuje numerički i grafički. Model urbane autoceste je ostao isti i korištene su tri kategorije vozila: teška, srednja i mala vozila.


Od ispušnih plinova mjereni su ugljični dioksid CO₂, dušikov oksid NO_x i štetne čestice PM₁₀ (lebdeće čestice koje su manje od 10 μm). U tablici 4 prikazani su rezultati emisije za slučaj bez upravljanja i s upravljanjem te njihovo poboljšanje.

Tablica 4. Prikaz emisije štetnih ispušnih plinova i čestica

	Bez VSLC	VSLC	Poboljšanje [%]
CO₂	52,29·10 ⁶ g	50,51·10 ⁶ g	3,38
	20,92·10 ⁶ g/h	20,21·10 ⁶ g/h	
	758,1 g/km	732,5 g/km	
NO_x	386,0·10 ³ g	373,8·10 ³ g	3,16
	154,4·10 ³ g/h	149,5·10 ³ g/h	
	5,597 g/km	5,42 g/km	
PM₁₀	9312 g	9158 g	1,63
	3725 g/h	3664 g/h	
	0,135 g/km	0,1328 g/km	

Iz tablice je vidljivo da kod korištenja VSLC sustava dolazi kod smanjenja emisije štetnih ispušnih plinova i čestica od 1% pa do skoro 4%. Tako mali postotak smanjenja emisije nije značajan, ali valja uzeti u obzir da je trajanje simulacije samo 2,5 [h] te nije moguće u njoj prikazati sve prometne situacije koje se događaju tijekom dana (vršni sat), vikendom ili ljeti, odnosno onda kada se prometna potražnja poveća. Kada bi to bilo moguće, smanjenje ispušnih plinova bilo bi puno značajnije. Kod emisije CO₂ dolazi do poboljšanja od 3,38%, kod emisije NO_x 3,16%, a kod čestica PM₁₀ 1,63%. Primjenom VSLC sustava dolazi do smanjenja emisije štetnih plinova i čestica.

U nastavku su prikazani grafički rezultati emisije štetnih ispušnih plinova. Grafički prikaz uključuje oblik korištenog modela urbane autoceste koji je ispunjen nijansama crvene i plave boje. Intenzitet boje se mijenja ovisno o količini koncentracije koja se nalazi na promatranom dijelu autoceste. Područja povećane koncentracije ispušnih plinova su oko prve i druge ulazne rampe gdje je i najveća gustoća prometa. Područje oko druge ulazne rampe je ujedno i područje najveće koncentracije CO₂, NO_x i čestica PM₁₀. Na slici 13 prikazana je koncentracija CO₂, na slici 14 prikazana je koncentracija NO_x, a na slici 15 prikazana je koncentracija ispušnih čestica PM₁₀. Na slikama je vidljivo da se područja najvećih emisija štetnih plinova i čestica nalaze kod obje ulazne rampe zbog ubrzavanja vozila koja se priključuju na glavni tok. Nadalje, najmanja emisija štetnih plinova vidljiva je u trećoj prometnoj traci, odnosno prvoj s lijeva, dok je najveća emisija u središnjoj prometnoj traci.



Slika 13. Koncentracija CO₂



Slika 14. Koncentracija NO_x



Slika 15. Koncentracija PM₁₀

7. Zaključak

Cestovni promet je područje prometa koje zahtjeva konstantna poboljšanja u vidu povećavanja sigurnosti, smanjenja zagušenja i smanjenja emisije štetnih ispušnih plinova s ciljem zaštite svih sudionika u prometu. Jedan od načina poboljšavanja razine uslužnosti urbanih autocesta je primjena naprednih upravljačkih rješenja iz područja ITS-a. Ista napredna upravljačka rješenja se mogu iskoristiti i u povećanju sigurnosti te zaštite okoliša (smanjenje emisije ispušnih plinova cestovnih vozila). Emisija štetnih plinova predstavlja bitan problem koji se pokušava riješiti raznim zabrana (na primjer zabrana prometa za sva motorna vozila u centru grada), ali i tehnološkim inovacijama (na primjer hibridnim ili električnim vozilima) koje su sve zastupljenije u svijetu.

U ovom radu implementiran je i testiran jednostavan algoritam za upravljanje promjenjivim ograničenjem brzine čiji rad se zasniva na principu logičkog stabla odlučivanja. VSLC sustav mijenja ograničenje brzine na osnovu izmjerenih stvarnovremenskih prometnih parametara kao što su protok, gustoća i brzina. Te prometne parametre mjere senzori u svrhu upravljanja prometnim tokom.

Algoritam korišten u ovom radu implementiran je u programski alat MATLAB, a simulacija se odvijala na mikroskopskom prometnom modelu u programskom paketu VISSIM. Korišteni model urbane autoceste na kojem se odvijala simulacija predstavlja dionicu autoceste s tri prometne trake, dvije ulazne i jednom izlaznom rampom. Model je prilagođen da omogućuje analizu utjecaja promjenjivog ograničenja brzine, a sama simulacija traje 2,5 sata. Analizirani su rezultati simulacija s primjenom i bez primjene VSLC sustava. Primjenom ovog algoritma postignuta je veća homogenizacija prometnog toka, veće srednje brzine vozila, te kraće ukupno utrošeno vrijeme svih vozila u mreži u odnosu na stanje bez primjene VSLC algoritma. Također, postignuta su i poboljšanja pri smanjenju emisije štetnih ispušnih plinova te čestica.

Kritična područja na urbanim autocestama su oko ulaznih rampi jer oko njih dolazi do interakcije između priljevnog i glavnog prometnog toka. Zbog te interakcije nastaju zagušenja pa su te lokacije mjesta nastajanja najvećih prometnih problema. Povećanjem stupnja harmonizacije brzina pojava zagušenja na autocestama se smanjuje. Tijekom simulacija s primjenom i bez primjene VSLC sustava, na drugoj ulaznoj rampi dolazi do povećanja prometne potražnje koja se manifestirala nastajanjem zagušenja, ali u slučaju s primjenom VSLC sustava brže se smanjuje intenzitet zagušenja te gustoća što za posljedicu ima smanjenje emisije ispušnih plinova i kraće ukupno utrošeno vrijeme.

Među većim problemima koji se ističu kod korištenja sustava upravljanja promjenjivim ograničenjem brzine je nizak stupanj poštivanja prikazanog ograničenja brzine od strane sudionika prometa odnosno vozača. Dio vozača voze brzinom blizu brzine ograničene zakonom ili onom brzinom koju oni smatraju prigodnom i sigurnom pa ako bi ograničenje brzine određeno putem VSLC-a znatno odstupalo od brzine koju bi oni odabrali, velika je vjerojatnost da ta brzina neće biti ispoštivana već ignorirana. Međutim, postoji drugi dio vozača koji poštuje ograničenje brzine pa VSLC sustav ima potencijal za smanjenje brzine vozača u svrhu povećanja protočnosti prometnog toka. Nepoštivanje zadanog ograničenja brzine samo je jedan od razloga nastajanja

incidentnih situacija i zagušenja. S obzirom da se pokazalo simulacijama da se primjenom promjenjivog ograničenja brzine korištenjem promjenjivih prometnih znakova može djelovati na prometni tok, VSLC ima dobar potencijal u smanjenju prometnih nesreća i prekoračenja kapaciteta urbanih autocesta. Za dobivanje točnih rezultata ipak je potrebno provesti temeljita ispitivanja uz korištenje stvarnih prometnih podataka te uključiti nepoštivanje ograničenje brzine.

Iz navedenih rezultata simulacije daje se zaključiti da pravovremena preventivna djelovanja VSLC sustava imaju pozitivna poboljšanja u odnosu na sustav bez upravljanja. Iako su poboljšanja dobivena s upravljanjem ograničenjem brzina minimalna, na godišnjoj razini ona bi bila veća. To predstavlja izazov i motivaciju za daljnji rad na ovom sustavu s ciljem postizanja još boljih rezultata.

Literatura

- [1] Highway capacity manual, Transportation Research Board, National Research Council, Washington, 2000.
- [2] Galić, I.: Usporedba metoda upravljanja priljevnih tokova na primjeru zagrebačke obilaznica, diplomski rad, Fakultet prometnih znanosti, Zagreb, 2015.
- [3] Katava, D.: Upravljanje sigurnošću prometa na autocestama promjenjivim ograničenjem brzine, diplomski rad, Fakultet prometnih znanosti, Zagreb, 2015.
- [4] Predavanja ITS2, Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2015.
- [5] Sisiopiku, V. P.: Variable Speed Control: Technologies and Practice, Proceedings of the 11th Annual Meeting of ITS America, Michigan, 2001.
- [6] Traffic Management Services - Variable speed limits deployment guideline tms-DG02 /version 02-00-00/ December, 2012.
- [7] Lee, C., Hellinga, B., Saccomanno, F.: Assessing Safety Benefits of Variable Speed Limits, Transportation Research Record, Waterloo, Canada, 2004.
- [8] Hegyi, A., Hoogendorn, S.P.: Dynamic speed limit control to resolve shock waves on freeways – Field test results of the SPECIALIST algorithm, 13th International IEEE, Annual Conference on Intelligent Transportation Systems, Madeira Island, Portugal, 2010.
- [9] Allaby, P., Hellinga, B., Bullock, M.: Variable Speed Limits: Safety and Operational Impacts of a Candidate Control Strategy for Freeway Applications, IEEE Transactions on ITS, vol. 8, No. 4, 2007
- [10] Lenz, H., Sollacher, R., Lang, M., Standing waves and the influence of speed limits, 2001 European Control Conference (ECC), 4-7 Sep. 2001. pp. 1228-1232
- [11] Tafti, M. F.: An Investigation on the Approaches and Methods used for Variable Speed Limit Control, 8th Transportation and Traffic Engineering Conference of Iran, Teheran, 2009.
- [12] Talebpour, A., Mahmassani, H. S., Hamdar, S. H.: Speed Harmonization: Effectiveness Evaluation under Congested Conditions, Evanston, UK, Northwestern University, 2012.
- [13] Grumert, E.: Cooperative Variable Speed Limit Systems, Norrköping, Linköping University Institute of Technology, 2014.

- [14] Vujić, M.: Inteligentno upravljanje prometnih tokova regulacijom ograničenja brzine; sažeci s predavanja, Zagreb, 2014.
- [15] Lee, B., Chung, E. Managed motorways project, Literature Review Report Brisbane: Smart Transport Research Centre, 2011.
- [16] Dedić, L., Inteligentno upravljanje prometnim tokovima uporabom koncepta ograničenja brzine, završni rad, Fakultet prometnih znanosti, Zagreb, 2015.
- [17] Palajsa, S., Analiza distribucije vozila prema zemlji porijekla na zagrebačkoj obilaznici primjenom metoda video detekcije, Fakultet prometnih znanosti, Zagreb, 2015.
- [18] Katava, D., Ćosić, M.: Modeliranje utjecaja pretjecanja vozila u sustavu upravljanja sigurnošću prometa na dionici autoceste primjenom funkcije sudarnog potencijala, Fakultet prometnih znanosti Sveučilišta u Zagrebu, rad predan na Natječaj za Rektorovu nagradu, Zagreb, 2015.
- [19] URL: <http://support.sas.com/publishing/pubcat/chaps/57587.pdf>, pristupljeno: srpanj 2017.
- [20] Predavanja iz Poslovnog odlučivanja, Ekonomski fakultet, Zagreb, 2011.
- [21] Letter, C.: A Framework for Simulating Variable Speed Limit Algorithms in CORSIM, University of Florida, 2011.
- [22] Korent, N., Kušić, K., Analiza utjecaja promjenjivog ograničenja brzine na protočnost prometa i zagađenje okoliša, Rad za rektorovu nagradu, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2016.
- [23] I. Dadić, G. Kos, M. Ševrović: Teorija prometnog toka, Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2014.
- [24] Korent N., Mogućnosti primjene MATsim simulatora cestovnih prometnih mreža, završni rad, Fakultet prometnih znanosti, 2015
- [25] URL: <http://www.eihp.hr/wp-content/uploads/2015/03/Energija2013.pdf>, pristupljeno: svibanj 2017.
- [26] URL: https://www.cvh.hr/media/2406/s12_broj_vozila_s_elektricnim_i_hibridnim_pogonom_2007do2016.pdf, pristupljeno: svibanj 2017.

[27] URL:
https://www.cvh.hr/media/2404/s11_prosjecna_starost_po_vrstivozila_2007do_2016.pdf, pristupljeno: svibanj 2017.

Popis kratica

CCTV	-	<i>Closed Circuit Television</i>
HCM	-	<i>Highway Capacity Manual</i>
ITS	-	Inteligentni transportni sustavi
LOS	-	<i>Level of Service</i>
MVM	-	<i>Mainline Virtual Metering</i>
OD	-	<i>Origin-Destination</i>
SPSC	-	<i>Simple Proportional Speed Limit Controller</i>
V2I	-	<i>Vehicle-to-infrastructure</i>
V2U	-	<i>Vehicle-to-other users</i>
V2V	-	<i>Vehicle-to-vehicle</i>
VMS	-	<i>Variable Message Signs</i>
VSLC	-	<i>Variable Speed Limit Control</i>
TTS	-	<i>Total Time Spent</i>
TT	-	<i>Travel Time</i>

Popis slika

Slika 1. Ilustracija situacije nizvodnog uskog grla blizu ulaza na urbanu autocestu [2]	4
Slika 2. Infrastruktura upravljanja priljevnim tokovima [2]	6
Slika 3. Ilustracija sigurne udaljenosti od vozila ispred [6]	9
Slika 4. Primjer rada VSLC sustava [15]	12
Slika 5. Izgled VSL znaka [16]	13
Slika 6. Prikaz prikupljanja podataka o učestalosti pretjecanja video kamerom [18].....	13
Slika 7. Osnovna zavisnosti toka-gustoće preslikana u iznos brzine [4]	14
Slika 8. Ilustracija stabla odlučivanja [19].....	16
Slika 9. Prikaz metode povratne indukcije na primjeru stabla odlučivanja [20]	17
Slika 10. Parametri Wiedemann 99 modela [22]	20
Slika 11. Raspored ćelija [22].....	21
Slika 12. Odabrane postavke u EnViVer programskom paketu	24
Slika 13. Koncentracija CO ₂	34
Slika 14. Koncentracija NO _x	34
Slika 15. Koncentracija PM ₁₀	34

Popis tablica

Tablica 1. Razine uslužnosti	3
Tablica 2. Rezultati maksimalnog i prosječnog TT i TTS.....	31
Tablica 3. Maksimalne i prosječne vrijednosti reda čekanja	33
Tablica 4. Prikaz emisije štetnih ispušnih plinova i čestica.....	33

Popis grafikona

Grafikon 1. Logika donošenja odluka [21].....	18
Grafikon 2. Blokovska shema funkcioniranja svih korištenih programa [22].....	22
Grafikon 3. Protok, gustoća i srednja brzina prometnog toka za prvu i drugu ćeliju	26
Grafikon 4. Protok, gustoća i srednja brzina prometnog toka za treću i četvrtu ćeliju.....	27
Grafikon 5. Rezultati promjenjivog ograničenja brzine	28
Grafikon 6. Ukupno utrošeno vrijeme putovanja za cijelo trajanje simulacije	30
Grafikon 7. Prosječne vrijednosti vremena putovanja	31
Grafikon 8. Duljina reda čekanja vozila na ulaznim rampama r_1 i r_2	32



Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj _____ diplomski rad

isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

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

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu _____ diplomskog rada

pod naslovom **Upravljanje promjenjivim ograničenjem brzine na urbanim
autocestama zasnovano na logičkom stablu odlučivanja**

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

U Zagrebu, 9/12/2017

Student/ica:

Saya Palgisa
(potpis)