



CESTE[®]
2026

50. INTERNATIONAL ROAD CONFERENCE & EXPO

CROATIA | ROVINJ | HOTEL LONE 17. - 20.03.2026.

ZBORNİK RADOVA
BOOK OF PROCEEDINGS

GlasGrid® Rapid


SUPERIORAN SUSTAV ZA OJAČANJE
KOLNIČKIH KONSTRUKCIJA



BEZ KORIŠTENJA EMULZIJE – BRZA I LAKA
UGRADNJA ZAHVALJUJUĆI SAMOLJEPLJIVOM
BITUMENSKOM SLOJU

**50. MEĐUNARODNA KONFERENCIJA
O CESTOVNOJ INFRASTRUKTURI I
SIGURNOSTI U PROMETU**

**50TH INTERNATIONAL CONFERENCE
ON ROAD INFRASTRUCTURE
AND TRAFFIC SAFETY**



CESTE 2026

ROVINJ, CROATIA, 17.-20.03.2026.

Organized by

Andreja Feistritzer

for

PLENORIA

www.plenoria.hr

**ZBORNİK RADOVA
BOOK OF PROCEEDINGS**

**ORGANIZACIJSKI ODBOR
ORGANIZING COMMITTEE**

Predsjednica / President:
Andreja Feistritzer dipl.oec

Članovi / Members: doc.dr.sc. Marko Ševrović,
John Leko dipl.ing., Saša Tomašić dipl.ing., Slaviša
Babić dipl.ing., Slavko Inić dipl.ing., prof. dr. Tomaž
Tollazzi, Veronika Feistritzer oec.

**ZNANSTVENO PROGRAMSKI ODBOR
SCIENTIFIC PROGRAM COMMITTEE**

Predsjednik / President:
prof.dr.sc. Hrvoje Baričević

Članovi / Members: doc.dr.sc. Marko Ševrović, Željko Remenar dipl.ing., doc.dr.sc. Marko Šošćarić,
Slaviša Babić dipl.ing., Jozo Šitum dipl.ing., mr.sc. Miron Huljak, Ivan Laco dipl.ing., Ivan Molnar
dipl.ing., Slavko Inić dipl.ing., prof.dr Goran Mijoski, Silvijo Čamber dipl.ing., Mladen Hranilović
dipl.ing., John Leko dipl.ing., doc.dr.sc. Robert Maršanić

SADRŽAJ CONTENT

- 06 REKLAMNI DIO
ADVERTISING PART**
- 11 EVALUACIJA NACIONALNOG PLANA SIGURNOSTI CESTOVNOG PROMETA RH-KLJUČNI
POKAZATELJI USPJEŠNOSTI
EVALUATION OF THE NATIONAL ROAD SAFETY PLAN OF CROATIA – KEY PERFORMANCE INDICATORS**
- 38 INTEGRIRANJE NAČELA LJUDSKOG FAKTORA U MODERNI PROCES PROJEKTIRANJA CESTA
INTEGRATING HUMAN FACTORS PRINCIPLES INTO THE MODERN ROAD DESIGN PROCESS**
- 43 VISION ZERO U KONTEKSTU STAJALIŠTA EUROPSKOG SUDA ZA LJUDSKA PRAVA O
ODGOVORNOSTI DRŽAVE ZA SIGURNOST PROMETA NA CESTAMA
VISION ZERO IN THE CONTEXT OF THE EUROPEAN COURT OF HUMAN RIGHTS COURT PRACTICE ON
STATE LIABILITY FOR ROAD TRAFFIC SAFETY**
- 54 ORGANIZACIJA INTEGRIRANOG PRIJEVOZA PUTNIKA
ORGANISATION OF INTEGRATED PASSENGER TRANSPORT**
- 62 SMANJENJE OGRANIČENJA BRZINE: ISKUSTVA IZ NIZOZEMSKJE
SPEED LIMIT REDUCTION: EXPERIENCES FROM THE NETHERLANDS**
- 74 EVALUACIJA PROMETNOG RJEŠENJA
EVALUATION OF A TRAFFIC ENGINEERING SOLUTION**
- 86 PROCESNO OSIGURAVANJE SIGURNOSTI CESTOVNOG PROMETA U VELIKIM INFRASTRUKTURNIM
PROJEKTIMA PODJELA ZADATAKA I ODGOVORNOSTI IZMEĐU PROJEKTOG TIMA I UPRAVLJAČA CESTA
PROCESS-BASED ASSURANCE OF ROAD SAFETY IN LARGER ROAD PROJECTS TASK AND
RESPONSIBILITY ALLOCATION BETWEEN THE PROJECT TEAM AND THE ROAD AUTHORITY**
- 91 RELEVANTNE KARAKTERISTIKE TERMOSTABILNE MREŽE ZA ARMIRANJE ASFALTA
RELEVANT CHARACTERISTICS OF THERMOSTABLE ASPHALT REINFORCEMENT GRIDS**
- 101 PRIMJENA UMJETNE INTELIGENCIJE U DETEKCIJI I KVANTIFIKACIJI OŠTEĆENJA KOLNIKA NA
CESTAMA NIŽEG RANGA - PREGLED LITERATURE I PRIJEDLOZI ZA DALJNJA ISTRAŽIVANJA
APPLICATION OF ARTIFICIAL INTELLIGENCE IN DETECTING AND QUANTIFYING PAVEMENT DISTRESS
ON LOWER-RANKING ROADS: A LITERATURE REVIEW AND FUTURE RESEARCH DIRECTIONS**
- 108 UTJECAJ MATERIJALA IZRADE STUPOVA UZ CESTE NA SIGURNOST U PROMETU
IMPACT OF ROADSIDE POLE MATERIALS ON TRAFFIC SAFETY**
- 119 UTJECAJ PROJEKTNIH PARAMETARA CESTA I PROMETNOG OPTEREĆENJA NA TROŠKOVE
KORISNIKA
IMPACT OF ROAD DESIGN PARAMETERS AND TRAFFIC LOADS ON USER COSTS**
- 128 PAMETNO UPRAVLJANJE PROMETOM ZA ODRŽIVE GRADOVE
SMART TRAFFIC MANAGEMENT FOR SUSTAINABLE CITIES**
- 135 UPRAVLJANJE S PROMETOM NA VPADNICAH LJUBLJANE – SPEED MANAGEMENT
TRAFFIC MANAGEMENT ON THE MAIN ROADS INTO LJUBLJANA – SPEED MANAGEMENT**
- 150 PREVENTIVNE AKTIVNOSTI SAVJETA ZA SIGURNOST PROMETA PGŽ ZA ZAŠTITU DJECE U PROMETU
PREVENTIVE ACTIVITIES OF THE TRAFFIC SAFETY COUNCIL OF PG COUNTY FOR CHILD ROAD SAFETY**
- 159 PROCJENA SIGURNOSTI CESTOVNE MREŽE REPUBLIKE HRVATSKE PRIMJENOM NWRSA
METODOLOGIJE
ROAD NETWORK SAFETY ASSESSMENT IN THE REPUBLIC OF CROATIA USING THE NWRSA
METHODOLOGY**

SADRŽAJ

CONTENT

- 173** **SIGURNOSNI RIZICI ZBOG NEPOŠTIVANJA TEHNIČKIH STANDARDA PRI POSTAVLJANJU ZAŠTITNIH ODBOJNIKA**
SAFETY RISKS DUE TO NON-COMPLIANCE WITH TECHNICAL STANDARDS WHEN INSTALLING PROTECTIVE GUARDRAIL
- 179** **BRZINA KAO KLJUČNI POKAZATELJ USPJEŠNOSTI SIGURNOSTI CESTOVNOG PROMETA U REPUBLICI HRVATSKOJ**
SPEED AS A KEY PERFORMANCE INDICATOR OF ROAD TRAFFIC SAFETY IN THE REPUBLIC OF CROATIA
- 191** **PRIMJENA BESPILOTNIH LETJELICA U KALIBRACIJI MIKROSIMULACIJSKIH MODELA KOD PROMETNE ANALIZE VARIJANTNIH RJEŠENJA RASKRIŽJA**
APPLICATION OF UNMANNED AERIAL VEHICLES IN CALIBRATING MICROSIMULATION MODELS FOR TRAFFIC ANALYSIS OF INTERSECTION DESIGN ALTERNATIVES
- 203** **DEA UČINKOVITOST DVIJU ALTERNATIVNIH TUNELSKIH TRASA KORISTEĆI OKOLIŠNE I SIGURNOSNO RELEVANTNE POKAZATELJE**
DEA EFFICIENCY OF TWO TUNNEL CORRIDOR ALTERNATIVES USING ENVIRONMENTAL AND SAFETY-RELEVANT PROXIES
- 213** **ISTRAŽIVANJE I EVALUACIJA UČINKOVITOSTI USPORNICA PROMETA U GRADU ZAGREBU**
RESEARCH AND EVALUATION OF THE EFFICIENCY OF TRAFFIC SPEEDERS IN THE CITY OF ZAGREB
- 224** **REKLAMNI DIO**
ADVERTISING PART

VAŠA CESTA

U DOBRIM RUKAMA

- › Površinska obrada
- › Konzervacija asfalta
- › Povezivanje slojeva
- › Sanacija:
 - udarnih rupa
 - pukotina
 - spojeva



TSD

Optimum road maintenance with the
Traffic Speed Deflectometer

Visit our
booth at
CESTE



WHY MEASURE WITH A TSD?

- ✓ **Network and Project** assessment of structural and functional conditions **in one go**
- ✓ **Measurements at 80 km/h**. No traffic interruptions, **increased safety**
- ✓ **500 km+** continuous bearing capacity measurements **per day**
- ✓ **Fast network overview** with strain index, such as **SCI_{TSD}**
- ✓ **Full Visco-Elastic back calculation** available, **E-Moduli**, **Strain** (hor.+ver.), temp. correction etc.
- ✓ Export data **down to 5 cm intervals** to assess features like concrete slab joints and cracks



GREENWOOD ENGINEERING

www.greenwood.dk



SAOBRAĆAJ ▽ GRAĐEVINA ▽ GRAFIKA TRAFFIC ▽ CONSTRUCTION ▽ GRAPHICS

Za više informacija o nama posetite naše strane na društvenim mrežama:




model5doo



model-5-d-o-o



model5doo



+381 11 2851-572

www.model5.rs

office@model5.rs





**KVALITETA
I POUZDANOST.**



SINCE 1954

Livar d.d. | Ljubljanska cesta 43 | 1295 Ivančna Gorica | Slovenija
info@livar.si | www.livar.si | +386 (0)1 786 99 60



OTKRIJTE SVIJET UPRAVLJANJA OBORINSKIM VODAMA



Upravljanje oborinskim vodama nije tema budućnosti.
Ono se mora planirati već danas.
HAURATON Vam nudi prava rješenja.

www.hauraton.hr

mr.sc. Miron Huljak, dipl. ing.,
Ministarstvo unutarnjih poslova
10000 Zagreb
Ilica 335
mhuljak@mup.hr

Josip Mataija, dipl. ing.,
Ministarstvo unutarnjih poslova
10000 Zagreb
Ilica 335
[jmatija@mup.hr](mailto:jmataija@mup.hr)

EVALUACIJA NACIONALNOG PLANA SIGURNOSTI CESTOVNOG PROMETA RH -KLJUČNI POKAZATELJI USPJEŠNOSTI-

Sažetak:

Republika Hrvatska se s ciljem uspostave pouzdane i vjerodostojne baze podataka o ponašanju sudionika u prometu, putem Ministarstva unutarnjih poslova, priključila projektu Europske unije, Trendline. Fakultet prometnih znanosti u Zagrebu, kao stručni partner, terenski je prikupio i analizirao podatke vezane za sigurnost cestovnog prometa. Ovaj rad prikazuje sažetu verziju prikupljenih ključnih pokazatelja sigurnosti.

Ključne riječi: Sigurnost cestovnog prometa, baza podataka, Trendline, Nacionalni plan sigurnosti cestovnog prometa

The Republic of Croatia, through the Ministry of the Interior, has joined the European Union project, Trendline, with the aim of establishing a reliable and credible database on the behavior of road users. The Faculty of Transport Sciences in Zagreb, as an expert partner, has collected and analyzed data related to road safety in the field. This paper presents a summary version of the collected key safety indicators.

Keywords: Road safety, database, Trendline, National Road Safety Plan

1. Uvod

Aktualnim Nacionalnim planom sigurnosti cestovnog prometa Republike Hrvatske za razdoblje od 2021. do 2030., zadan je cilj smanjenja smrtnog stradavanja u cestovnom prometu za 50% u odnosu na referentnu, 2019. godinu.

Jedno od bitnih postupanja koje prethodne poduzimanju adekvatnih aktivnosti je prikupljanje relevantnih podataka. Osim redovitih podataka o nesrećama i broju teško stradalih, države članice Europske unije počele su koristiti standardizirane ključne

pokazatelje uspješnosti (KPI)¹ s ciljem boljeg razumijevanja čimbenika rizika i svrhovitije evaluacije nacionalnih sigurnosnih politika.

Projekt Baseline bio je prvi zajednički europski okvir za prikupljanje i prezentaciju KPI pokazatelja, kojim su definirani metodološki standardi i minimalni zahtjevi koje države EU trebaju zadovoljiti radi osiguravanja usporedivosti rezultata. Budući da Republika Hrvatska u Baseline projektu nije sudjelovala, prije početka Trendline projekta nije se raspolagalo početnim referentnim vrijednostima KPI pokazatelja.

Projekt Trendline osmišljen je kao nastavak Baseline projekta s proširenim brojem država sudionica, unaprjeđenom metodologijom te uključivanjem dodatnih eksperimentalnih pokazatelja. Republika Hrvatska se u navedeni projekt priključila kroz Ministarstvo unutarnjih poslova koje je vodilo projekt na nacionalnoj razini, dok je Fakultet prometnih znanosti bio stručni partner zadužen za terensko prikupljanje i analizu podataka.

Cilj hrvatskog sudjelovanja u projektu bila je uspostava pouzdane i reprezentativne baze podataka o ponašanju sudionika u prometu za potrebe realne procjene učinkovitosti Nacionalnog plana sigurnosti cestovnog prometa. Prikupljeni podaci predstavljaju nacionalnu referentnu vrijednost KPI pokazatelja i temelj su za buduća mjerenja, praćenje trendova i planiranje mjera.

Ovim dokumentom objedinjeni su metodološki okviri, rezultati i prilozi za sve osnovne i eksperimentalne KPI pokazatelje prikupljene tijekom provođenja projekta. Dokument pruža cjelovit stručni pregled provedenih aktivnosti i predstavlja temelj za nastavak razvoja nacionalnog sustava praćenja pokazatelja sigurnosti cestovnog prometa, uključujući buduće cikluse evaluacije i novi programski okvir koji Europska unija planira kroz predstojeće pozive CEF² programa.

2. Ključni pokazatelji uspješnosti

Ključni pokazatelji uspješnosti (KPI) dio su zajedničkog europskog okvira za praćenje čimbenika koji neposredno utječu na sigurnost cestovnog prometa. Usmjereni su na ponašanje sudionika u prometu, prometnu infrastrukturu i sigurnosne karakteristike vozila. Uvođenjem harmoniziranih metodologija svakoj državi članici omogućeno je praćenja trendova, usporedbe s drugim zemljama te planiranja mjera temeljenih na pouzdanim i reprezentativnim podacima.

U okviru projekta Trendline, u Republici Hrvatskoj provedena su mjerenja za četiri osnovna KPI pokazatelja definirana europskim okvirom. Dodatno su uključena i tri eksperimentalna pokazatelja s ciljem boljeg razumijevanja ponašanja ranjivih sudionika u prometu i učinkovitosti prometnih pravila u urbanim okruženjima. Odlučeno je provesti prikupljanje podataka za sljedeće pokazatelje:

2.1 Osnovni ključni pokazatelji uspješnosti:

1. KPI Brzina (eng. KPI Speed)

¹ Engl, Key Performance Indicators

² CEF je financijski instrument osnovan za dodatna ulaganja u izgradnju nove te unaprjeđenje postojeće prometne, energetske i telekomunikacijske strukture iz kojeg države članice, osim postojećih Strukturnih i Kohezijskog fonda, mogu financirati projekte.

2. KPI Distrakcija (eng. KPI Distraction)
3. KPI Sigurnosni pojasevi i sigurnosni sustavi za djecu (eng. KPI safety belts and child restraint systems (CRS))
4. KPI Korištenje kaciga među biciklistima i vozačima dvokotača na motorni pogon (eng. KPI Helmet use among Cyclists and Powered two-wheelers (PTWs))

Provedenim mjerenjima u okviru projekta Trendline uspostavljena je prva nacionalno utemeljena referentna vrijednost ključnih pokazatelja uspješnosti u Republici Hrvatskoj. Time je stvoren nužan temelj za praćenje budućih promjena u ponašanju sudionika u prometu i učinkovitosti provedenih mjera. Dobiveni rezultati omogućuju kvalitetnije planiranje i usmjeravanje aktivnosti s ciljem smanjenja broja ozlijeđenih i poginulih osoba u prometu te doprinose ostvarivanju strateških ciljeva Nacionalnog plana sigurnosti cestovnog prometa.

2.1.1 KPI Brzina

Prema metodološkim smjernicama učinkovitost za brzinu definirana je kao udio vozila koja poštuju zakonski propisano ograničenje brzine. Ovaj pokazatelj jedan je od temeljnih indikatora sigurnosti cestovnog prometa s obzirom da brzina iznad ograničenja, odnosno neprilagođena brzina značajno povećava vjerojatnost nastanka prometnih nesreća i težinu posljedica.

Navedeni ključni pokazatelj uspješnosti bio je podijeljen u tri podskupa s obzirom na različite prometne karakteristike, odnosno različita ograničenja brzine:

-  Udio vozila koja poštuju zakonski propisano ograničenje brzine na autocestama
-  Udio vozila koja poštuju zakonski propisano ograničenje brzine na cestama izvan naseljenog područja
-  Udio vozila koja poštuju zakonski propisano ograničenje brzine na cestama unutar naseljenog područja

U okviru projekta Trendline, Republika Hrvatska odabrala je provođenje aktivnosti na autocestama i cestama izvan naseljenog područja, dok ceste unutar naseljenog područja nisu bile obuhvaćene. Kako bi rezultati bili usporedivi između svih država sudionika, u metodološkim smjernicama definirani su minimalni zahtjevi koje je potrebno ispuniti pri odabiru lokacija, načinu prikupljanja podataka i strukturi uzorka.

Lokacije za mjerenje bilo je potrebno nasumično odabrati te prostorno rasporediti tako da predstavljaju nacionalnu cestovnu mrežu i obuhvate različite geografske dijelove države. Mjerenja se nisu smjela provoditi u neposrednoj blizini fiksnih ili mobilnih sustava za nadzor brzine kako bi se izbjegao utjecaj njihov utjecaj na ponašanje vozača. Na svakoj lokaciji bilo je nužno osigurati minimalan prometni tok od najmanje deset vozila na sat.

Mjerenja je bilo potrebno provoditi na ravnim dionicama cesta, u uvjetima slobodnog toka prometa, odnosno u situacijama u kojima vozači brzinu biraju samostalno bez utjecaja zagušenja, radova na cesti, blizine raskrižja ili drugih

elemenata koji ograničavaju kretanje vozila. U analizu su uključena samo vozila s dovoljnom vremenskom udaljenošću od vozila (5 sekundi razmaka) ispred kako bi izmjerene brzine doista odražavale individualno ponašanje vozača, a ne trenutnu prometnu situaciju.

Nadalje, minimalni zahtjevi odnosili su se prvenstveno na osobna vozila kao dominantnu kategoriju u prometu, dok je uključivanje ostalih vrsta vozila bilo opcionalno. Za svaku odabranu kategoriju vozila moralo se prikupiti najmanje 500 opažanja, a ukupan broj opažanja u državi morao je iznositi najmanje 2.000. Što se tiče minimalnog broja lokacija, bilo je potrebno provesti mjerenja na najmanje deset lokacija po kategoriji ceste te osigurati da udio opažanja svakog podskupa iznosi najmanje 20 posto ukupnog uzorka, a sve s ciljem osiguravanja reprezentativnosti podataka i sprječava dominacije pojedinog podskupa u ukupnim rezultatima.

2.1.2 KPI Distrakcija

Na temelju metodoloških smjernica učinkovitost za distrakciju definirana je kao udio vozača koji tijekom vožnje ne koriste mobilni uređaj. Korištenje mobilnih uređaja za vrijeme upravljanja vozilom smanjuje razinu pažnje vozača te produljuje vrijeme reakcije čime se posljedično povećava vjerojatnost nastanka prometne nesreće.

Kako bi se osigurala usporedivost rezultata između država, bilo je potrebno ispuniti jasno definirane minimalne zahtjeve vezane uz odabir lokacija, obuhvat prometnica, način prikupljanja podataka te veličinu uzorka. Promatranja su provedena na presjeku prometnica u uvjetima slobodnog prometnog toka, dok podatci za vozila koja su bila zaustavljena (primjerice ispred semafora) nisu uključena u analizu. Tijekom svakog prikupljanja podataka bilo je potrebno istovremeno provoditi i brojanje prometa kako bi se omogućilo pravilno ponderiranje rezultata i procjena pouzdanosti.

Za potrebe postizanja reprezentativnosti na nacionalnoj razini, obvezno je bilo obuhvatiti sve definirane vrste prometnica, odnosno autoceste, ceste izvan naseljenog područja i ceste unutar naseljenog područja. Za svaku kategoriju ceste minimalni uzorak iznosio je najmanje 500 opažanja te je bilo potrebno provođenje mjerenja na najmanje deset različitih lokacija po vrsti ceste, odnosno najmanje 2.000 opažanja te 30 lokacija na nacionalnoj razini. Lokacije su morale biti slučajno odabrane i prostorno raspoređene kako bi pokrivale različite dijelove cestovne mreže.

2.1.3 KPI Sigurnosni pojasevi i sigurnosni sustavi za djecu

Prema metodološkim smjernicama, učinkovitost ovog pokazatelja definirana je kao udio putnika u vozilima koji pravilno koriste sigurnosni pojas ili sigurnosni sustav za dijete (CRS). Sigurnosni pojas osnovni je element zaštite putnika u vozilu te dokazano smanjuje posljedice prometnih nesreća stoga sustavno praćenje ovog pokazatelja predstavlja jedan od ključnih alata u evaluaciji sigurnosnog ponašanja sudionika u cestovnom prometu.

Kako bi rezultati bili usporedivi između svih država koje su sudjelovale, u metodološkim smjernicama definirani su minimalni zahtjevi koje je bilo potrebno ispuniti pri odabiru lokacija, strukturi uzorka i načinu prikupljanja podataka.

Promatranja su se provodila metodom izravnog opažanja na lokacijama koje su prostorno raspoređene tako da predstavljaju nacionalnu cestovnu mrežu. U okviru obveznog obuhvata bile su uključene autoceste, ceste izvan naselja i ceste u naselju. Podatke je bilo potrebno prikupljati tijekom dnevnih sati uz zasebno evidentiranje radnih dana i vikenda kako bi se umanjio utjecaj sezonalnosti i specifičnih prometnih opterećenja na rezultate.

Minimalni zahtjevi odnosili su se prvenstveno na osobna vozila kao najzastupljeniju kategoriju u prometu, dok je uključivanje ostalih kategorija vozila bilo opcionalno uz odvojeno izvješćavanje. Uz osnovni podatak o korištenju sigurnosnog pojasa na prednjim i stražnjim sjedalima, prema smjernicama predviđena su i dodatna opažanja o sigurnosnom sustavu za dijete u vozilima u kojima se prevoze djeca. Ukupan broj opažanja morao je iznositi najmanje 2.000, uz najmanje 500 opažanja po tipu ceste i po dijelu tjedna (radni dan / vikend) kako bi se osigurala reprezentativnost podataka i mogućnost pouzdane procjene ciljnih skupina. Također, tijekom prikupljanja podatak bilo je potrebno brojanje prometa kako bi se omogućilo pravilno ponderiranje rezultata i procjena pouzdanosti.

2.1.4 KPI Korištenje kaciga kod biciklista i vozača dvokotača na motorni pogon

Na temelju metodoloških smjernica, učinkovitost ovog pokazatelja definirana je kao udio korisnika mopeda, motocikala i bicikala koji tijekom vožnje koriste propisanu zaštitnu kacigu. Kaciga je osnovni element zaštite navedenih sudionika u prometu jer značajno smanjuje rizik od teških ozljeda glave u slučaju prometne nesreće. Sustavno praćenje ovog pokazatelja stoga predstavlja važan alat u procjeni sigurnosnog ponašanja korisnika mopeda, motocikala i bicikala u cestovnom prometu. Nadalje, navedeni pokazatelj bio je podijeljen u dva podskupa s obzirom na vrstu vozila:

- uporaba kacige na motociklima i mopedima
- uporaba kacige na biciklima

U okviru projekta Trendline, Hrvatska je odabrala provođenje mjerenja za oba navedena podskupa čime je osigurana cjelovitija procjena razine korištenja zaštitne opreme među svim relevantnim skupinama korisnika.

Kako bi rezultati bili usporedivi između svih država, u metodološkim smjernicama definirani su minimalni zahtjevi koje je bilo potrebno ispuniti pri odabiru lokacija, strukturi uzorka i načinu prikupljanja podataka. Promatranja su se provodila metodom izravnog opažanja na lokacijama koje su prostorno raspoređene tako da predstavljaju nacionalnu cestovnu mrežu. U okviru obveznog obuhvata predviđeno je bilo prikupljanje podataka na cestama izvan naselja i cestama u naselju, dok se autoceste uključuju isključivo u slučaju promatranja mopeda i motocikala. Bilo je predviđeno prikupljanje podataka tijekom dnevnih sati, uz zasebno evidentiranje radnih dana i vikenda kako bi se umanjio utjecaj sezonalnosti i specifičnih prometnih opterećenja na rezultate.

Što se tiče minimalnog uzorka, bilo je potrebno najmanje 2.000 opažanja za kacige s većim udjelom uzorka za mopede i motocikliste u odnosu na potreban minimalan uzorak za bicikliste.

2.2 Eksperimentalni ključni pokazatelji uspješnosti:

1. KPI Korištenje svjetla kod biciklista u uvjetima smanjene vidljivosti (eng. KPI Light use by cyclists in the dark)
2. KPI Poštivanje prometnih propisa na semaforiziranim pješačkim prijelazima i raskrižjima (eng. KPI Compliance with traffic rules on signalized pedestrian crossings and intersections)
3. KPI Poštivanje prometnih propisa na nesemaforiziranim pješačkim prijelazima i raskrižjima (eng. KPI Compliance with traffic rules on unsignalized pedestrian crossings and intersections)

2.2.1 KPI Korištenje svjetla kod biciklista u uvjetima smanjene vidljivosti

Korištenje svjetala na biciklu u uvjetima smanjene vidljivosti ključan je čimbenik vidljivosti i sigurnosti biciklista u prometu, budući da izravno utječe na mogućnost pravovremenog uočavanja biciklista od strane drugih sudionika u prometu. U okviru projekta Trendline, ovaj pokazatelj uveden je kao eksperimentalni KPI koji je za cilj imao uspostaviti početnu referentnu vrijednost za procjenu ponašanja biciklista u noćnim uvjetima prema jedinstvenoj europskoj metodologiji. U trenutku provedbe projekta postupci prikupljanja podataka i pripadajuće metodološke smjernice još su bile u razvoju zbog čega nisu bili detaljno i jednoznačno definirani u usporedbi sa standardnim ključnim pokazateljima.

Pokazatelj se temeljio na izravnom opažanju i definiran je kao udio biciklista koji tijekom vožnje u mraku koriste barem jedno svjetlo na biciklu. Prema smjernicama, moguće je bilo zasebno prikazati korištenje prednjeg svjetla, stražnjeg svjetla ili kombinacije oba svijetla čime je omogućena dodatna analitička vrijednost pokazatelja.

Opažanja su se provodila isključivo u uvjetima smanjene razine prirodnog osvjetljenja radnim danima i tijekom vikenda pri čemu su se promatrala samo svjetla koja sama emitiraju svjetlost. Na svakoj mjernoj lokaciji opažanja su se provodila u trajanju od najmanje 30 minuta, uz obveznu evidenciju prometnog toka biciklista. U skladu s razvojnim karakterom ovog KPI-ja, prikupljanje dodatnih informacija kao što su tip bicikla ili procjena starosne skupine biciklista bilo je moguće u nacionalnim okvirima ali nije bilo obvezno.

Nadalje, s obzirom na eksperimentalni tip pokazatelja, baziralo se samo na urbanom području s obzirom na veći očekivani broj biciklista u odnosu na područja izvan naselja. U trenutku provođenja navedenog pokazatelja, bio je definiran značajno manji minimalni broj lokacija i uzorka koji je iznosio minimalno 5 lokacija te minimalno 200 opažanja.

2.2.2 KPI Poštivanje prometnih propisa na semaforiziranim pješačkim prijelazima i raskrižjima

Poštivanje prometnih propisa na signaliziranim pješačkim prijelazima i raskrižjima ključan je čimbenik sigurnosti pješaka i drugih sudionika u prometu. Nepoštivanje svjetlosne signalizacije, osobito prolazak kroz crveno svjetlo, povećava rizik nastanka prometnih nesreća s teškim posljedicama te ugrožava najranjivije sudionike u prometu. U okviru projekta Trendline, ovaj pokazatelj uveden je kao eksperimentalni KPI s ciljem uspostave početne referentne vrijednosti o razini poštivanja signalizacije u urbanim uvjetima prema jedinstvenoj europskoj metodologiji. Budući da se metodologija za ovaj pokazatelj u trenutku provedbe još razvijala, pojedini elementi nisu bili detaljno propisani niti ujednačeni među državama sudionicama.

Pokazatelj je temeljen na izravnom opažanju i definiran je kao udio pješaka i vozača motornih vozila koja poštuju svjetlosnu signalizaciju pri prolasku kroz signalizirani pješački prijelaz ili raskrižje. U praksi se bilježilo samo nepoštivanje signalizacije, dok se uz to evidentirao i ukupni broj prolazaka kako bi se mogla izračunati konačna razina usklađenosti. Promatranje pješaka i vozača provodilo se neovisno, pri čemu su se opažale različite prometne situacije na mjestu signaliziranog prijelaza ili raskrižja.

Kako bi se osigurala usporedivost rezultata između država sudionika, u metodološkim smjernicama definirani su osnovni zahtjevi vezani uz izbor lokacija, strukturu uzorka i način provođenja opažanja. Također, navedeno je da se mjerenja provode u urbanim područjima gdje je rizik interakcije između vozila i pješaka najizraženiji. Lokacije su trebaju biti odabrane tako da predstavljaju tipične prometne situacije s različitim prometnim opterećenjima i ograničenjima brzine, a opažanja je bilo potrebno provoditi u razdobljima bez zagušenja kako bi se izbjegao utjecaj grupnog kretanja i smanjena prepoznatljivost pojedinačnih ponašanja. U trenutku provedbe projekta bila je propisana minimalna provedba mjerenja na najmanje pet lokacija, dok ukupan minimalni broj opažanja nije bio definiran.

Metodologijom se predviđela mogućnost prikupljanja dodatnih informacija o karakteristikama promatranih sudionika, poput spola, starosne skupine i korištenja mobilnih uređaja u trenutku prelaska, kao i obilježja prometnice i signalizacijskog sustava. Prikupljanjem navedenih podataka otvorena je mogućnost provedbe dublje analize čimbenika koji mogu imati utjecaj na nepoštivanje prometnih pravila ali u eksperimentalnoj fazi njihovo prikupljanje nije bilo obvezno.

2.2.3 KPI Poštivanje prometnih propisa na nesemaforiziranim pješačkim prijelazima i raskrižjima

Poštivanje prometnih propisa na nesemaforiziranim pješačkim prijelazima i raskrižjima jedan je od temeljnih čimbenika zaštite najranjivijih sudionika u urbanom prometnom sustavu. Nepravilno kretanje pješaka ili nepropuštanje pješaka od strane vozača povećava rizik konflikata i nastanka prometnih nesreća sa smrtnim ili teškim posljedicama. U okviru projekta Trendline, ovaj pokazatelj uveden je kao eksperimentalni KPI s ciljem uspostave početne nacionalne referentne vrijednosti za procjenu poštivanja pravila o prednosti prolaska u tipičnim urbanim okruženjima. Pokazatelj je bio zamišljen kao dvije zasebne kategorije, odnosno prometne situacije

koje predstavljaju najčešće izvore konflikata u prometu bez svjetlosne signalizacije:

- interakcije pješaka i vozila na nesemaforiziranim pješačkim prijelazima
- poštivanje prednosti prolaska između vozača na nesemaforiziranim raskrižjima

S obzirom na eksperimentalni karakter pokazatelja, metodološke smjernice u trenutku provedbe projekta još su bile u razvoju stoga su zahtjevi za izbor lokacija i strukturu uzorka bili znatno fleksibilniji u odnosu na standardne ključne pokazatelje. Promatranja je bilo potrebno provoditi u urbanim područjima gdje je dinamika prometnih interakcija između pješaka i vozila najizraženija. Lokacije su trebale odražavati tipične prometne situacije uz obilježenu regulaciju prednosti (horizontalna signalizacija te prometni znakovi) i dovoljno dobre uvjete vidljivosti za pouzdano opažanje ponašanja sudionika.

Za razliku od standardnih pokazatelja u kojima je minimalni broj opažanja bio unaprijed definiran, za navedeni pokazatelj je u eksperimentalnoj fazi bio propisan samo minimalni broj lokacija u iznosu od 5 po kategoriji (ukupno 10 lokacija), dok minimalan broj opažanja nije bio određen. Uz osnovna opažanja bilo je moguće, ali ne i obvezno, evidentirati dodatne karakteristike sudionika (spol, dob, korištenje mobilnog uređaja) s ciljem dubljeg razumijevanja čimbenika koji mogu utjecati na nepoštivanje pravila.


3. Rezultati

Kako je već navedeno, provedbom aktivnosti u okviru projekta Trendline prikupljeni su prvi nacionalni podaci o ključnim pokazateljima uspješnosti sigurnosti cestovnog prometa u Republici Hrvatskoj prema jedinstvenoj europskoj metodologiji. Rezultati prikazani u nastavku predstavljaju početnu referentnu vrijednost za praćenje trendova u ponašanju sudionika u prometu i učinkovitosti sigurnosnih mjera te su ujedno omogućili buduću usporedbu Republike Hrvatske s ostalim državama članicama Europske unije.

U nastavku će za svaki ključni pokazatelj uspješnosti biti navedena detaljna metodologija prikupljanja podataka, ukupan broj lokacija te ukupna veličina uzorka, kao i dobiveni rezultati. Također, prilogima od 8 do 17 prikazana su sva konačna izvješća rezultata za sve promatrane ključne pokazatelje uspješnosti (KPI) koja su proizašla u sklopu Trendline projekta.

3.1 KPI Brzina

Prikupljanje podataka za potrebe utvrđivanja udjela vozila koja poštuju zakonski propisano ograničenje brzine provedeno je na ukupno 25 lokacija na autocestama i cestama izvan naselja. Od ukupnog broja lokacija, 12 terenskih istraživanja provedeno je na autocestama, dok je 13 izvršeno na cestama izvan naselja. Za ovaj pokazatelj prikupljanje podataka provedeno je tijekom tjedna te tijekom vikenda na većini spomenutih lokacija što je u konačnici rezultiralo sa ukupno 55 provedenih terenskih istraživanja. Grafički prikaz lokacija prikupljanja podataka vidljiv je na slici 1.



Slika 1. Lokacije prikupljanja podataka - KPI Brzina


Što se tiče uzorka, ukupno su prikupljeni podatci za 29.063 vozila, od čega je 8.835 vozila zabilježeno na autocestama, a 20.228 vozila na cestama izvan naselja. Uzorkom su se obuhvatile sve najzastupljenije kategorije vozila u prometu:

- 24.220 osobnih vozila
- 2.944 teških teretnih vozila
- 1.681 lakih teretnih vozila
- 218 motocikala

Na temelju prikupljenih podataka provedena je analiza kojom su dobiveni rezultati za promatrani pokazatelj. Prema minimalnim zahtjevima, za izračun primarnog pokazatelja učinkovitosti bilo je potrebno uzeti u obzir samo skup podataka koja uključuju osobna vozila koja su prometovala tijekom radnog tjedna za vrijeme dana.

Temeljem navedenog ključni pokazatelji uspješnosti izračunati su posebno za svaku kategorije cesta te je dobiven postotak od 45% vozila koja poštuju zakonski propisano ograničenje brzine na autocestama te 65% posto na cestama izvan naselja. Za autoceste utvrđen je 85. percentil brzine (V85) u iznosu od oko 152 km/h, dok je za ceste izvan naselja iznosio oko 100 km/h. Također, izračunate su i prosječne brzine za navedene kategorije te je za autoceste dobivena prosječna brzina od oko 133 km/h te oko 82 Km/h za ceste izvan naselja.


Nadalje, rezultati po kategorijama vozila pokazali su varijacije ovisno o kategoriji. Među rezultatima istaknula su se laka teretna vozila koja su zabilježila značajno veće poštivanje ograničenja na autocestama u odnosu na prethodno prikazane rezultate sa iznosom od oko 71%. Grafički prikaz pokazatelja po kategorijama vozila ovisno o kategoriji ceste prikazani su na grafikonu 1, dok su svi rezultati koji su izračunati u sklopu ovog pokazatelja dati su u tablicama 8, 9 i 10.



Grafikon 1. Udio poštivanja ograničenja brzine po kategorijama vozila ovisno o kategoriji ceste

3.2 KPI Distrakcija

Prikupljanje podataka za potrebe procjene udjela vozača koji tijekom vožnje ne koriste mobilni uređaj provedeno je na ukupno 41 lokaciji u urbanim područjima, na cestama izvan naselja te na autocestama. Od ukupnog broja lokacija, 18 terenskih istraživanja provedeno je na cestama unutar naselja, 13 na cestama izvan naselja, dok se 10 lokacija nalazilo na autocestama. Na većini lokacija prikupljanje podataka provedeno je i tijekom radnog dana i tijekom vikenda čime je ukupno realizirano 61 terensko istraživanje. Grafički prikaz lokacija prikupljanja podataka vidljiv je na slici 2.



Slika 2. Lokacije prikupljanja podataka - KPI Distrakcija


Na svim lokacijama ukupno je prikupljen uzorak od 22.675 opažanja vozača. Od navedenog broja, 10.780 opažanja zabilježeno je na cestama unutar naselja, 7.018 na cestama izvan naselja te 4.877 na autocestama. U uzorak su bile uključene sve najzastupljenije kategorije vozila u cestovnom prometu:

- 19.869 osobnih vozila
- 1.197 lakih teretnih vozila
- 1.228 teških teretnih vozila
- 381 autobusa

Na temelju prikupljenih podataka provedena je analiza kojom su dobivene vrijednosti pokazatelja uspješnosti za promatrani indikator. U skladu s minimalnim metodološkim zahtjevima, u izračun primarnog pokazatelja uzeta su opažanja prikupljena tijekom radnih dana za vrijeme dnevnih uvjeta, a u obzir su uključeni svi promatrani tipovi cesta. Na autocestama je zabilježena razina usklađenosti s pokazateljem od oko 94%, na cestama izvan naselja utvrđena je razina usklađenosti od oko 96%, dok je na cestama unutar naselja udio vozača koji tijekom vožnje ne koriste mobilni uređaj iznosio je oko 94%.

3.3 KPI Sigurnosni pojasevi i sigurnosni sustavi za djecu

Prikupljanje podataka za potrebe procjene udjela putnika u vozilima koji pravilno koriste sigurnosni pojas ili sigurnosni sustav za dijete (CRS) ukupno je provedeno na 42 odabrane lokacije koje obuhvaćaju urbana područja, cestovne pravce izvan naselja te autoceste. U urbanim sredinama provedeno je 19 terenskih opažanja, na cestama izvan naselja obavljeno je 13 opažanja, dok je 10 lokacija obuhvatilo autoceste. Na većini lokacija terenska istraživanja provedena su u dva vremenska perioda, odnosno ukupno 62 terenska istraživanja koja su obuhvatila radne dane i vikend. Prostorni raspored svih lokacija prikazan je na slici 3.




Slika 3. Lokacije prikupljanja podataka - KPI Sigurnosni pojasevi i sigurnosni sustavi za djecu

Na svim lokacijama ukupno je prikupljen uzorak od 31.551 opažanja putnika u vozilima. Od navedenog, 15.193 opažanja zabilježeno je na cestama unutar naselja,

9.279 na cestama izvan naselja te 7.079 na autocestama. U uzorak su bila uključena sva najzastupljenija vozila u cestovnom prometu:

- 28.098 osobnih vozila
- 1.756 lakih teretnih vozila
- 1.339 teških teretnih vozila
- 358 autobusa


Sukladno minimalnim metodološkim zahtjevima, za izračun primarnog pokazatelja uključena su samo opažanja iz osobnih vozila prikupljena tijekom cijelog tjedna (radni dani i vikend) na svim tipovima prometnica. Na autocestama je zabilježena razina korištenja sigurnosnog pojasa od oko 97%. Na cestama izvan naselja udio korištenja pojasa iznosio je oko 91%, dok je na cestama unutar naselja udio korištenja pojasa iznosio je oko 88%. Opisani rezultati grafički su prikazani na grafikonu 3, dok su svi izračunati rezultati za promatrani pokazatelj vidljivi u tablicama 15 i 16.



Grafikon 3. Udio osoba koji pravilno koriste sigurnosni pojas u osobnim vozilima ovisno o kategoriji ceste


3.4 KPI Korištenje kaciga među biciklistima i vozačima dvokotača na motorni pogon

Prikupljanje podataka za potrebe procjene udjela biciklista koji koriste zaštitnu kacigu provedeno je u urbanim područjima te na cestama izvan naselja na ukupno 32 lokacije. Od toga je 19 lokacija obuhvatilo ceste unutar naselja, dok je 13 lokacija obuhvatilo ceste izvan naselja. S obzirom na zakonska ograničenja, biciklistički promet nije prisutan na autocestama pa opažanja nisu provedena na toj vrsti cesta. Na većini lokacija prikupljanje podataka provedeno je i radnim danom i vikendom što je rezultiralo sa ukupno realiziranih 46 terenskih istraživanja. Grafički prikaz lokacija prikupljanja podataka prikazan je na slici 4.



Slika 4. Lokacije prikupljanja podataka - KPI Korištenje kaciga među biciklistima i vozačima dvokotača na motorni pogon (bicikli)

S druge strane, prikupljanje podataka za potrebe procjene udjela vozača dvokotača na motorni pogon koji koriste zaštitnu kacigu provedeno je na ukupno 42 lokacije u urbanim područjima, na cestama izvan naselja te na autocestama. Od navedenog, 19 lokacija obuhvatilo je ceste unutar naselja, 13 lokacija ceste izvan naselja, dok je 10 lokacija obuhvatilo autoceste. Na većini lokacija opažanje je provedeno i tijekom radnog dana i tijekom vikenda, odnosno ukupno su provedena 62 terenska istraživanja. Grafički prikaz lokacija prikupljanja podataka prikazan je na slici 5.




Slika 5. Lokacije prikupljanja podataka - KPI Korištenje kaciga među biciklistima i vozačima dvokotača na motorni pogon (mopedi/motocikli)

Na svim lokacijama prikupljen je uzorak od 853 biciklista i njihovih putnika, od čega je 796 opažanja zabilježeno na cestama unutar naselja, a 57 na cestama izvan naselja. Terenska istraživanja provedena su tijekom cijelog tjedna radi ispunjenja minimalnih zahtjeva. Što se tiče dvokotača na motorni pogon, ukupno je prikupljeno

730 opažanja radnim danom i vikendom na svim tipovima prometnica (359 mopeda i 371 motocikla), pri čemu je 597 opažanja zabilježeno na cestama unutar naselja, 124 na izvangradskim cestama te 9 na autocestama.

Rezultati su pokazali da je na svim promatranim lokacijama i u svim razdobljima opažanja ukupni udio korištenja kacige na biciklima iznosio oko 12%. Nadalje, na cestama izvan naselja udio korištenja kacige na biciklima iznosio oko 49%, dok je na cestama unutar naselja udio korištenja kacige iznosio oko 11%. Što se tiče dvokotača na motorni pogon, rezultati su pokazali da je na svim promatranim cestama i u svim razdobljima opažanja ukupni udio korištenja zaštitne kacige iznosio oko 99%. Na cestama izvan naselja utvrđeno je nošenje zaštitne kacige od 100%, dok je udio nošenja zaštitne kacige na cestama unutar naselja zabilježen sa iznosom od oko 99%. Grafički prikaz opisanih rezultata dat je na grafikonu 4, dok je detaljan prikaz rezultata za promatrani pokazatelj prikazan je u tablicama 17, 18, 19, 20, 21 i 22.



Grafikon 4. Udio osoba koji koriste sigurnosnu kacigu ovisno o kategoriji ceste


3.5 KPI Korištenje svjetla od strane biciklista u uvjetima smanjene vidljivosti

Istraživanje je provedeno s ciljem utvrđivanja učestalosti korištenja svjetala na biciklima u noćnim uvjetima u urbanom okruženju. Promatrani su ključni pokazatelji uspješnosti (KPI):

- udio biciklista koji koriste prednje svjetlo
- stražnje svjetlo
- te oba svjetla u mraku.


Mjerenje je provedeno noću, u razdoblju kada je razina prirodne osvjetljenosti ispod 26 luxa, a uvjeti o početnom i završnom osvjetljenju, temperaturi i vremenskim uvjetima zabilježeni su na svakoj lokaciji. Obavezno je bilo prikupljanje podataka o korištenju i poziciji svjetala, dok su dodatno prikupljeni podaci o obilježjima biciklista i bicikala (spol, dob, profesionalni status, kategorija bicikla, električni pogon i dr.).

Broj lokacija odabran je prema smjernicama kako bi se osigurao reprezentativan uzorak što je rezultiralo prikupljanjem podataka na pet urbanih lokacija u Zagrebu sa postojećom biciklističkom i pješačkom infrastrukturom pri čemu je ukupno prikupljen uzorak u iznosu od 417 opažanja. Sva mjerenja odvijala su se radnim danom, izvan vršnih opterećenja i u trajanju od jednog sata. Grafički prikaz lokacija prikupljanja podataka dat je na slici 6.



Slika 6. Lokacije prikupljanja podataka - KPI Korištenje svjetla od strane biciklista u mraku

Analizom prikupljenih podataka dobiveni su rezultati koji su pokazali da od ukupno 417 zabilježenih bicikala, 252 biciklista (60,5%) nisu imala istovremeno prednje i stražnje svjetlo, odnosno da im je nedostajalo jedno ili oba svjetla. Samoprednje svjetlo imalo je 227 bicikala (54,4%), dok je samo stražnje svjetlo zabilježeno na 175 bicikala (42%). Ukupno su zabilježena 3 zaklonjena prednja svjetla (0,7%) i 9 zaklonjenih stražnjih svjetala (2,1%). Oba svjetla koristilo je 156 bicikala (37,4%), dok je broj bicikala sa zaklonjenim i prednjim i stražnjim svjetlom bio 9 (2,1%). Sva evidentirana prednja svjetla bila su bijele boje, a stražnja crvene. Opisani rezultati, kao i rezultati analize za svaku lokaciju vidljivi su na slici 7.




Slika 7. Rezultati KPI Korištenje svjetla od strane biciklista u mraku po lokacijama

3.6 KPI Poštivanje prometnih propisa na semaforiziranim pješačkim prijelazima i raskrižjima

Za potrebe utvrđivanja udjela pješaka i vozača koji poštuju svjetlosnu signalizaciju prilikom prolaska kroz signalizirani prijelaz, odnosno raskrižje provedeno je prikupljanje podataka na 7 lokacija (slika 8) u gradu Zagrebu tijekom radnih dana i u dnevnim uvjetima. Lokacije su bile smještene u urbanom području u skladu s propisanim smjernicama te su odabrane prema nekoliko kriterija. Prednost je dana mjestima s protočnim prometom, dobrim uvjetima vidljivosti i uredno održanom horizontalnom signalizacijom. Također se nastojalo obuhvatiti lokacije s različitim ograničenjima brzine i različitim prometnim opterećenjima.

Svako opažanje trajalo je jedan sat, tijekom kojeg se bilježilo ponašanje pojedinačnih sudionika u prometu, koristeći unaprijed pripremljene obrasce koji omogućuju sustavno prikupljanje, obradu i analizu podataka. U okviru ovog pokazatelja prikupljani su podaci za pješake i za vozače motornih vozila, pri čemu su bilježeni slučajevi poštivanja i nepoštivanja svjetlosne signalizacije:


- prikupljani podaci za pješake
 - o spol (muškarac, žena, skupina od dvije ili više osoba)
 - o dobna skupina (mlađi od 14 godina, od 15 do 60 godina, stariji od 60 godina)
 - o distrakcija (slušalice, tipkanje, razgovor)
 - o ponašanje u odnosu na signalizaciju (nije se zaustavio na crveno svjetlo, zaustavio se na crveno svjetlo)
- prikupljani podaci za vozače
 - o spol (muškarac, žena)
 - o vrsta vozila (osobno vozilo, lako teretno vozilo, teško teretno vozilo, autobus, moped/motocikl, bicikl)
 - o ponašanje u odnosu na signalizaciju (nije se zaustavio na crveno ili žuto svjetlo, zaustavio se na crveno ili žuto svjetlo)




*Slika 8. Lokacije prikupljanja podataka na semaforiziranim raskrižjima - KPI
Poštivanje prometnih propisa na semaforiziranim pješačkim prijelazima i raskrižjima*

Na svim lokacijama prikupljanja podataka ukupno je prikupljeno 1.130 opažanja za pješake od čega je 1.113 pješaka (oko 85%) poštivalo propise, dok je za 197 pješaka (oko 15%) evidentiran prelazak na crveno svjetlo. Što se tiče uzorka za vozače, u sklopu terenskih istraživanja prikupljeno je 1.242 opažanja od čega je 868 (oko 70%) vozača poštovalo propisana pravila, 293 (oko 24%) vozača prošlo je semaforiziranim raskrižjem tijekom žutog svjetla, dok je 81 (oko 6%) vozač prošao kada se već upalilo crveno svjetlo. Grafički prikaz svih rezultata poštivanja

prometnih propisa na semaforiziranim pješačkim prijelazima i raskrižjima vidljivi su na grafikonima 5 i 6.



Grafikon 5. KPI Poštivanje prometnih propisa na semaforiziranim pješačkim prijelazima i raskrižjima po lokacijama (pješači)




Grafikon 6. KPI Poštivanje prometnih propisa na semaforiziranim pješačkim prijelazima i raskrižjima po lokacijama (vozači)


3.7 KPI Poštivanje prometnih propisa na nesemaforiziranim pješačkim prijelazima i raskrižjima

Za potrebe utvrđivanja udjela pješaka i vozača koji poštuju prometna pravila na nesemaforiziranim pješačkim prijelazima i raskrižjima, prikupljanje podataka provedeno je na ukupno 10 lokacija u gradu Zagrebu tijekom radnih dana i u dnevnim uvjetima. Sve lokacije odabrane su u skladu s metodološkim smjernicama, pritom vodeći računa o protočnosti prometa, dobroj vidljivosti te uredno održanoj i jasno uočljivoj horizontalnoj signalizaciji. Također se nastojalo obuhvatiti prijelaze u različitim prometnim uvjetima (ograničenja brzine od 30 do 60 km/h) na ulicama različitog funkcionalnog značaja.

Na slici 9 prikazano je 5 lokacija na kojima su provedena terenska istraživanja za potrebe određivanja pokazatelja na nesemaforiziranim pješačkim prijelazima, a na slici 10 dat prikaz 5 lokacija na kojima su prikupljeni podatci za potrebe izračuna pokazatelja za poštivanje prometnih propisa na nesemaforiziranim raskrižjima. Potrebno je napomenuti da je na tri nesemaforizirana raskrižja regulacija prometa bila definirana preko prometnog znaka B02, dok je na dva raskrižja regulacija prednosti prolaska bila regulirana preko prometnog znaka B01.



Slika 9. Lokacije prikupljanja podataka na nesemaforiziranim pješačkim prijelazima - KPI Poštivanje prometnih propisa na nesemaforiziranim pješačkim prijelazima i raskrižjima



*Slika 10. Lokacije prikupljanja podataka na nesemaforiziranim raskrižjima - KPI
Poštivanje prometnih propisa na nesemaforiziranim pješačkim prijelazima i
raskrižjima*

Svako opažanje trajalo je jedan sat, a ponašanje svakog sudionika u prometu bilježeno je u unaprijed pripremljene obrasce koji omogućuju sustavno prikupljanje i naknadnu analizu podataka. U okviru ovog pokazatelja prikupljani su podatci o pješacima i vozačima motornih vozila, pri čemu su kategorizirana pravilna i nepravilna ponašanja u kritičnim trenucima interakcije na prijelazu. Za potrebe izračuna dijela pokazatelja vezanog za poštivanje prometnih propisa na nesemaforiziranim pješačkim prijelazima prikupljani su podatci o:

- pješacima


- o spol (muško, žensko)
- o dob (mlađi od 14, od 15 do 60 godina, stariji od 60 godina)
- o distrakcija (slušalice, tipkanje, razgovor)
- o ponašanje u odnosu na vozilo (započeo prelazak; zaustavio se i čekao; čekao unatoč tome što ga je vozilo propuštalo)
- vozačima
 - o vrsta vozila (osobno vozilo, lako teretno vozilo, teško teretno vozilo, autobus, moped/motocikl, bicikl)
 - o spol (muško, žensko)
 - o ponašanje u odnosu na pješaka (stao, zakočio, nije stao)

Za potrebe izračuna dijela pokazatelja vezanog za poštivanje prometnih propisa na nesemaforiziranim raskrižjima prikupljeni su podatci o:

- spolu vozača (muško, žensko)
- vrsti vozila (osobno vozilo, lako teretno vozilo, teško teretno vozilo, autobus, moped/motocikl, bicikl)
- prisutnosti vozila na glavnom pravcu prilikom nailaska
- ponašanje vozača (stao, usporio, nije stao)

Na svim lokacijama prikupljanja podataka ukupno je prikupljeno 156 opažanja u kojima su istovremeno bilježene reakcije pješaka i vozača na nesemaforiziranim pješačkim prijelazima. U većini opažanja, njih 113 (oko 72%), i pješak i vozač postupili su u skladu s propisanim pravilima, dok je u preostalih 43 (oko 28%) opažanja zabilježeno nepropisno ponašanje barem jedne od uključenih strana. Detaljni prikaz pravilnog i nepravilnog postupanja pješaka i vozača u interakciji vidljiv je u tablici 23.

Nadalje, u sklopu istog pokazatelja provedeno je zasebno prikupljanje podataka na nesemaforiziranim raskrižjima na koja je prednost prolaska regulirana znakovima. Ukupno je evidentirano 564 opažanja vozača, od čega je 257 vozača (oko 46%) u potpunosti poštivalo propisana pravila, dok je 307 vozača (oko 54%) zabilježeno u prekršaju. Analiza po lokacijama ukazuje na značajne razlike u razini usklađenosti ovisno o vrsti prometnog znaka. Na lokacijama sa znakom B02 (lokacije 1., 2. i 3.) zabilježene su niske razine poštivanja u rasponu između 25% i 35% što upućuje na to da se većina vozača ne zaustavlja u potpunosti nego samo usporava prolazak kroz raskrižje. Nasuprot tome, na lokacijama s prometnim znakom B01 (lokacije 4. i 5.) razina poštivanja propisa bila je znatno viša te je iznosila 96 odnosno 91%. Opisani rezultati po lokacijama prikazani su na grafikonu 7.



Grafikon 7. KPI Poštivanje prometnih propisa na nesemaforiziranim raskrižjima po lokacijama

4. Zaključak

Provedbom projekta Trendline u Republici Hrvatskoj se po prvi put uspostavila nacionalno utemeljena referentna vrijednost svih odabranih ključnih pokazatelja uspješnosti sigurnosti cestovnog prometa prema zajedničkim europskim smjernicama. Time je ostvaren važan iskorak u razumijevanju stvarnog ponašanja sudionika u prometu izvan konteksta prometnih nesreća, te je stvoren temelj za mjerenje napretka strateških ciljeva Nacionalnog plana sigurnosti cestovnog prometa.

Rezultati ukazuju na područja u kojima je razina sigurnosti na zadovoljavajućoj razini (primjerice korištenje sigurnosnog pojasa na autocestama ili razina distrakcije među vozačima na cestama izvan naselja), ali i na izazove koji zahtijevaju ciljano djelovanje (prekoračenja brzine na autocestama, poštivanje prednosti na nesemaforiziranim raskrižjima, vidljivost biciklista u noćnim uvjetima). Posebnu važnost pritom imaju pokazatelji koji obuhvaćaju ranjive skupine sudionika u prometu te pokazatelji koji imaju direktan utjecaj na nastanak prometne nesreće i težinu posljedica.

Dobivenim rezultatima uspostavljen je polazišni podatkovni skup koji će omogućiti dugoročnu evaluaciju učinaka prometno-sigurnosnih mjera, donošenje ciljanih intervencija utemeljenih na stvarnom ponašanju sudionika te usporedivost Republike Hrvatske s drugim državama članicama Europske unije. Kontinuirano praćenje KPI pokazatelja omogućuje pravovremenu identifikaciju trendova i odstupanja te vrednovanje učinkovitosti postojećih mjera u kontekstu ostvarenja ciljeva do 2030. godine.

S obzirom na uspješno proveden Trendline projekt te pozitivne prakse koja je iz njega proizašla, Republika Hrvatska, odnosno Ministarstvo unutarnjih poslova iskazalo je interes za nastavak praćenja ključnih pokazatelja uspješnosti kroz nadolazeći otvoreni poziv Europske komisije *CEF-T-2025-TAGENE-IBA - Technical Assistance to Member State in Road Safety u okviru programa Connecting Europe Facility (CEF) - Transport*.

Literatura:

[1] Evaluacija Nacionalnog plana sigurnosti cestovnog prometa Republike Hrvatske tijekom 2022.-2024. godine – prikupljanje podataka o ključnim pokazateljima uspješnosti u sklopu projekta TRENDLINE – Objedinjeno izvješće - Fakultet prometnih znanosti Sveučilišta u Zagrebu

INTEGRIRANJE NAČELA LJUDSKOG FAKTORA U MODERNI PROCES PROJEKTIRANJA CESTA

Integrating Human Factors Principles into the Modern Road Design Process

Zoran Kenjić, mag.ing.gr.

Ministarstvo za infrastrukturu i vode Kraljevine Nizozemske
e-mail: zoran.kenjic@gmail.com

Sažetak: Ljudska greška učestvuje u više od 90% prometnih nesreća, što jasno ukazuje da sigurnost prometa ne zavisi isključivo od tehničkih i geometrijskih rješenja, već i od toga koliko je infrastruktura usklađena sa sposobnostima, ograničenjima i očekivanjima vozača. U radu se analiziraju načela prometne sigurnosti zasnovani na ljudskim faktorima, s posebnim fokusom na odnos između ceste i vozača. Predstavljeno je pet ključnih načela: očekivana situacija, opažanje, razumijevanje, moći (radno opterećenje) i željeti (motivacija). Rad ukazuje na značaj sustavne integracije ovih načela u proces projektiranja cesta kao osnovu za stvaranje predvidljivog, intuitivnog i sigurnog prometnog sustava.

Ključne riječi: human factors, projektiranja cesta, prometna sigurnost, Safe System, očekivana situacija


Abstract: Human error is involved in more than 90% of traffic accidents, which clearly indicates that traffic safety does not depend solely on technical and geometric solutions, but also on how well the infrastructure is aligned with the abilities, limitations and expectations of drivers. The paper analyzes the principles of traffic safety based on human factors, with a special focus on the relationship between the road and the driver. Five key principles are presented: expected situation, perception, understanding, ability (workload) and desire (motivation). The paper points to the importance of systematically integrating these principles into the road design process as a basis for creating a predictable, intuitive and safe traffic system.

Keywords: human factors, road design, traffic safety, Safe System, expected situation

1. UVOD

Savremeni pristup sigurnosti prometa polazi od pretpostavke da su ljudske greške neizbježne, ali da njihove posljedice mogu biti značajno ublažene pravilnim projektiranjem prometne infrastrukture. Tradicionalni pristupi projektiranju cesta fokusirani su na tehničke parametre kao što su radijusi krivina, preglednost i širine kolnika. Međutim, brojna istraživanja pokazuju da tehnička ispravnost sama po sebi nije dovoljna da jamči sigurnost ukoliko projektirana rješenja nisu usklađena sa načinom na koji vozači opažaju, obrađuju informacije i donose odluke.

U tom kontekstu, koncept ljudskih faktora predstavlja teorijski i praktični okvir za razumijevanje ponašanja vozača u realnim prometnim uvjetima. Projektovanje ceste mora uzeti u obzir kognitivna ograničenja, percepcijske sposobnosti, mentalno opterećenje i motivaciju sudionika u prometu. Istraživanja ukazuju da ljudska greška učestvuje u više od **90% prometnih nesreća**, što zahtijeva usklađivanje infrastrukture sa očekivanjima vozača. (1, 2)




Slika 1. Uticaji na nastanak prometnih nesreća [1]

Cilj ovog rada je da prikaže i objasni načela prometne sigurnosti zasnovane na ljudskim faktorima, te da ukaže na njihov značaj u procesu savremenog projektiranja cesta.

2. NAČELA PROMETNE SIGURNOSTI ZASNOVANI NA LJUDSKIM FAKTORIMA

U prometnom sustavu postoje tri međusobno povezane komponente koje zajednički definišu razinu sigurnosti prometa: vozač, vozilo i cesta. Sigurnost se ne može promatrati kao rezultat djelovanja samo jedne od ovih komponenti, već kao posljedica njihove stalne međusobne interakcije. Dok tehničke značajke vozila i geometrijska rješenja ceste imaju značajnu ulogu, ponašanje vozača i način na koji on opaža i obrađuje informacije presudni su za konačni ishod prometne situacije.

Savremena načela prometne sigurnosti u velikoj mjeri proizlaze iz teorija ljudskih faktora. Ove teorije zasnovane su na saznanjima iz psihologije i ergonomije, posebno u oblastima kognitivnih sposobnosti, percepcije, mentalnog opterećenja i motivacije. Njihova primjena u projektiranju cesta proizlazi iz osnovnog pitanja: koje značajke vozača treba uzeti u obzir kako bi se omogućilo sigurno i udobno korištenje prometne infrastrukture? Drugim riječima, projektiranje ceste mora biti usklađeno sa realnim sposobnostima, ograničenjima i očekivanjima sudionika u prometu.



Slika 2. Načela prometne sigurnosti zasnovani na ljudskim faktorima [6]

U okviru odnosa između ceste i vozača mogu se definisati pet osnovnih načela prometne sigurnosti zasnovanih na ljudskim faktorima: načelo očekivane situacije, načelo opažanja, načelo razumijevanja, načelo moći (radnog opterećenja) i načelo željeti (motivacije). Ova grupa načela direktno se odnosi na kognitivne procese vozača. Pored njih, postoje i načela opraštanja greške i fizičkih faktora, koji su također važni za sigurnost, ali se primarno odnose na tolerantnost sustava i tehničke značajke infrastrukture, a ne direktno na psihološke procese.

Sistematska integracija pet ključnih načela, **očekivana situacija, opažanje, razumijevanje, moći (radno opterećenje) i željeti (motivacija)**, predstavlja osnovu za stvaranje predvidljivog sustava. Ovi načela direktno se odnose na kognitivne procese vozača i njihovu interakciju sa cestom. Projektovanje koje se oslanja na ove faktore omogućava prelazak na infrastrukturu "po mjeri čovjeka".

2.1. Načelo očekivane situacije

Očekivanja sudionika u prometu formiraju se na osnovu njihovog prethodnog iskustva i dugotrajnog učenja kroz vožnju. Vozač tokom godina razvija mentalne obrasce ili „modele“ tipičnih prometnih situacija. Kada prepozna određeni tip ceste, on nesvjesno aktivira očekivanja o njegovim značajkama, dozvoljenoj brzini, mogućim konfliktima i ponašanju drugih sudionika.

Očekivanja se mogu podijeliti na dugoročna, koja su rezultat ukupnog vozačkog iskustva stečenog tokom života, i kratkoročna, koja nastaju tokom vožnje određenom dionicom ili rutom. Kratkoročna očekivanja oblikuju se na osnovu neposredno doživljenih situacija, dok dugoročna iskustva, naročito ona snažna i emocionalno obojena, pocesta prometnih nezgoda, mogu trajno utjecati na ponašanje vozača.

Odnos između vozača i ceste zasniva se upravo na tim očekivanjima. Ona utječu na to koje informacije vozač uopće primjećuje, kako ih tumači, koje radnje planira poduzeti i koliko je spreman da se pridržava pravila. Ukoliko je projektno rješenje ceste dosljedno i jasno prepoznatljivo, vozač će lakše predvidjeti situaciju i reagovati pravovremeno. Predvidljivost se postiže uniformnošću projektiranih rješenja i jasnom kategorizacijom cestovne mreže, pri čemu svaki tip ceste mora imati prepoznatljiv vizuelni identitet. Time se smanjuje mogućnost pogrešnih procjena i naglih, nepredvidivih manevara.

2.2. Načelo opažanja

Tijekom vožnje najveći dio informacija vozač prima putem vizuelnog sustava, pri čemu se procjenjuje da oko 85% relevantnih informacija dolazi upravo putem vida. Zbog toga je način na koji je cesta vizuelno oblikovan od presudnog značaja za sigurnost.

Ipak, u vidnom polju vozača ne nalaze se samo informacije relevantne za vožnju. Okolina može sadržavati brojne elemente koji odvlače pažnju, pocesta reklama, pejzažnih detalja ili unutrašnjih distrakcija u vozilu. Zadatak projektanta jeste da osigura da ključne informacije – horizontalna signalizacija, vertikalni znakovi, promjene u geometriji ceste – budu jasno uočljive i smještene u centralnom vidnom polju vozača.

Vidljivost informacija zavisi od njihove udaljenosti, kontrasta u odnosu na okolinu i usklađenosti sa očekivanjima vozača. Ukoliko su informacije postavljene prekasno ili na neobičajenom mjestu, vozač ih može previdjeti ili ih uočiti tek u trenutku kada više nema dovoljno vremena za sigurnu reakciju. Stoga projektiranje mora osigurati adekvatnu preglednost, pravovremeno postavljanje oznaka i jasno razlikovanje bitnih od nebitnih vizuelnih elemenata.

2.3. Načelo razumijevanja

Sam čin opažanja informacije ne jamči sigurnost. Vozač mora biti sposoban razumjeti značenje uočene informacije i procijeniti njene posljedice. Razumljivost prometne situacije podrazumijeva da su informacije jasno strukturirane, logično povezane i usklađene s kontekstom ceste.

To znači da simboli, znakovi i oznake moraju biti univerzalno razumljivi i dosljedno primjenjivani. Kada su projektna rješenja standardizovana – na primjer, kada su uključenja i isključenja sa autoceste oblikovana na isti način na svim lokacijama – vozač može brže protumačiti situaciju jer je već ranije susreo sličan raspored elemenata. Time se smanjuje potreba za dodatnom mentalnom obradom informacija i skraćuje vrijeme donošenja odluke.

Razumljivost je, dakle, rezultat kombinacije jasnih vizuelnih poruka i logične organizacije prostora ceste.

2.4. Načelo moći (radno opterećenje)

Vozač raspolaže ograničenim kognitivnim kapacitetom i ne može istovremeno obrađivati neograničen broj informacija. Tokom vožnje mora upravljati vozilom, pratiti kretanje drugih vozila, procjenjivati udaljenosti, koristiti retrovizore i donositi odluke o promjeni trake ili napuštanju ceste. Svaki od ovih zadataka zahtijeva određeno vrijeme i pažnju.

Kada se više složenih zadataka pojavi istovremeno, dolazi do povećanja radnog opterećenja. Ukoliko projektirana situacija ne ostavlja dovoljno vremena i prostora za izvršenje manevara, rizik od greške se značajno povećava. Zbog toga je u projektiranju neophodno osigurati dovoljan razmak između tačaka odlučivanja, razdvajanja i spajanja, kako bi vozač imao dovoljno vremena da percipira situaciju, donese odluku i sigurno izvrši manevar.

Ovaj načelo jasno pokazuje da sigurnost ne zavisi samo od tehničke ispravnosti rješenja, već i od vremensko-prostorne organizacije prometnih zadataka.

2.5. Načelo željeti (motivacija)

Sigurnost prometa zavisi i od spremnosti vozača da poštuju pravila i ograničenja. Motivacija je povezana s percepcijom rizika, ličnim stavovima i procjenom vjerodostojnosti okruženja.

Ukoliko izgled ceste sugerise visoku dozvoljenu brzinu, vozači će biti manje skloni poštovanju nižeg ograničenja, čak i ako je ono formalno propisano. Stoga projektiranje mora osigurati usklađenost između projektirane brzine, vizuelnog identiteta ceste i postavljenih ograničenja.

Vjerodostojnost infrastrukture znači da cesta svojim izgledom i okruženjem intuitivno usmjerava vozača ka željenom ponašanju. Kada su pravila logična i podržana fizičkim značajkama ceste, većina vozača će ih spontano poštovati. Na taj način infrastruktura postaje sredstvo preventivnog djelovanja, a ne samo prostor u kojem se pravila primjenjuju.

3. DISKUSIJA

Integracija ljudskih faktora u projektiranje cesta omogućava prelazak sa tehnički ispravnog, ali često neintuitivnog projektiranja, na projektiranje prometne infrastrukture koja je usklađena sa načinom na koji ljudi opažaju, obrađuju informacije i donose odluke. Ovakav pristup potvrđuje da sigurnost cesta nije isključivo rezultat geometrijskih parametara, već sinergije između infrastrukture, čovjeka i vozila. Savremena istraživanja pokazuju da se veliki dio tzv. 'ljudske greške' može objasniti neusklađenošću između očekivanja vozača i značajki ceste. **(1)**

Nizozemska iskustva u okviru vizije održive sigurnosti (Duurzaam Veilig) potvrđuju da cesta koji generira jasna očekivanja i pruža vozaču adekvatnu kognitivnu i fizičku podršku značajno smanjuje rizik od konfliktnih situacija i prometnih nezgoda. **(7)** Načela samorazjašnjavajućih cesta (self-explaining roads) pokazuju da dosljednost i uniformnost projektnih rješenja doprinose stabilnijem ponašanju vozača i smanjenju mentalnog opterećenja. **(3, 4)**

Posebno je važno naglasiti da integracija ljudskih faktora ne znači odustajanje od tehničkih standarda, već njihovu nadogradnju kroz razumijevanje kognitivnih procesa. Projektovanje koje uzima u obzir očekivanja, percepciju i radno opterećenje vozača omogućava stvaranje predvidljivog i vjerodostojnog prometnog okruženja, što je u skladu sa načelama Safe System pristupa. **(5)** Konačno, primjena odredbi nizozemskog okvira za sigurnost (Road safety framework) osigurava vjerodostojnost cestovne mreže. **(6)**

4. ZAKLJUČAK

Sigurnost na cestama u velikoj mjeri zavisi od ponašanja vozača, ali to ponašanje je snažno uvjetovano značajkama infrastrukture. Čak i optimalna geometrijska rješenja neće postići željeni razinu sigurnosti ukoliko cesta nije razumljiva, predvidljiva i vjerodostojna. Integracija načela ljudskih faktora u projektiranje cesta stoga predstavlja ključni korak ka uspostavljanju održivog i sigurnog prometnog sustava.

Metodologija koja kombinuje klasične tehničke standarde sa načelima opažanja, razumijevanja, radnog opterećenja, motivacije i očekivanja omogućava projektiranje cesta 'po mjeri čovjeka'. Takav pristup, potvrđen uspješnom primjenom u Nizozemskoj, može poslužiti kao temelj za unaprjeđenje projektantske prakse i u drugim državama, posebno u kontekstu rekonstrukcije postojećih dionica.

Rad pruža teorijsku osnovu i praktični okvir za projektante, revizore sigurnosti, upravljače cestnom infrastrukturom i istraživače koji nastoje unaprjeđivati sigurnost prometa kroz sustavnu integraciju znanja o ljudskom ponašanju u projektni proces.

Popis referenci / Bibliografija:

- [1]. **Treat JR, et al.** Tri-Level Study of the Causes of Traffic Accidents; 1979.
- [2]. **Alexander GJ, Lunenfeld H.** Driver expectancy in highway design; 1986.
- [3]. **Theeuwes J, Godthelp H.** Self-explaining roads; 1995.
- [4]. **Wickens CD.** Multiple resources and mental workload; 2008.
- [5]. **OECD/ITF.** Towards Zero: Safe System Approach; 2018.
- [6]. **Rijkswaterstaat.** Kader verkeersveiligheid (Road safety framework); 2020.
- [7]. **SWOV.** Duurzaam Veilig Verkeer (Dutch Sustainable Road Safety Vision); 2018.

Vision Zero u kontekstu stajališta Europskog suda za ljudska prava o odgovornosti države za sigurnost prometa na cestama

Vision Zero in the Context of the European Court of Human Rights Court Practice on State Liability for Road Traffic Safety

Tatjana Potkonjak¹

¹ mr. sc., SS Gradske skupštine Grada Zagreba, Hrvatska, tatjana.potkonjak@zagreb.hr

Sažetak. Vision Zero koncept u kontekstu sigurnosti cestovnog prometa predstavlja fundamentalnu promjenu paradigme kojom se ljudski život postavlja kao vrhovni kriterij dizajna prometnih sustava, ljudski život njegova je neupitna ishodišna točka. U operacionalizaciji ciljeva Vision Zero koncepta, nužno je integrirati pravne standarde sadržane u sudskoj praksi Europskog suda za ljudska prava (ESLJP), koji definiraju obveze država u domeni sigurnosti cestovnog prometa. ESLJP je kroz svoju jurisprudenciju razvio doktrinu pozitivnih obveza države, prema kojoj zaštita prava na život nalaže proaktivan pristup vlasti. U tom smislu, Vision Zero i Safe System koncepti nisu samo deklarativni ciljevi, već izravan odgovor za uspostavljanje zakonodavnih, institucionalnih i infrastrukturnih okvira koji minimiziraju smrtnu ishode. Recentne presude ESLJP-a nedvosmisleno potvrđuju dužnost države da kroz normativne akte i konkretne operativne mjere sustavno prevenira predvidive rizike u prometu.

Ključne riječi: Europski sud za ljudska prava, održavanje cesta, odgovornost države, odgovornost za kršenje ljudskih prava, prometne nesreće, Vision Zero.

Abstract. Within the context of road safety, the Vision Zero concept represents a fundamental paradigm shift focused on human life as the foundational premise and the ultimate benchmark for designing transportation systems. In order to implement Vision Zero objectives, it is imperative to address the legal standards established by the court practice of the European Court of Human Rights (ECHR), which clearly identifies state obligations in the field of road traffic safety. The ECHR has developed the doctrine of positive obligations, asserting that the protection of the fundamental right to life requires proactive state intervention. Consequently, the Vision Zero and Safe System concepts are not merely declaratory goals, but direct requirements for establishment of a legislative, institutional, and infrastructural framework to prevent fatalities. Recent ECHR case law further reinforces the state's duty to establish a robust regulatory framework and implement concrete measures to prevent foreseeable risks.

Key words. European Court of Human Rights, road maintenance, state responsibility, state responsibility for human rights violations, traffic accidents, Vision Zero.

1. UVOD

Pravo na život utvrđeno i zajamčeno člankom 2. Konvencije za zaštitu ljudskih prava i temeljnih sloboda (u daljnjem tekstu: Konvencija) [1], ne predstavlja tek jednu od odredaba u katalogu ljudskih prava, već čini bitnu odrednicu i preduvjet postojanja svih ostalih ljudskih prava. U doktrini Europskog suda za ljudska prava (dalje: ESLJP), ovaj članak zauzima apsolutno primarno mjesto kao odredba od koje nije dopušteno odstupanje (*non-derogable right*), čime se definira kao *ius cogens* europskog javnog poretka. Nije neosnovano ni ustvrditi kako Konvencija samo usvaja neke davno zabilježene svezvremenske istine, budući najstarije i najsvetije knjige čovječanstva, neovisno o religiji ili jeziku, govore istim glasom: život je svet i apsolutan. Ta univerzalna spoznaja nije samo teološka misao već stoljetno isticanje značaja ljudskog života i kristaliziranje spoznaje o nužnosti ispunjenja drevne, svezvremenske obaveze njegove zaštite i spašavanja.

Istodobno nije moguće ne akceptirati činjenicu kako su suvremeni izazovi mobilnosti pretvorili cestovni promet u zonu stalne i realne ugroze tog temeljnog ljudskog prava. Uz prosječno 20.000 smrtno stradalih godišnje na cestama Europske unije [9], nužnim se nameće potreba za redefiniranjem uloge države i njezine odgovornost unutar javnog prostora. Suočavanje s ovim zastrašujućim brojem smrtno stradalih često vodi priklanjaju ciničnoj maksimi koja se nerijetko (iako povijesno neosnovano) pripisuje Staljinu, dok njezini stvarni korijeni vjerojatnije leže u britkoj satiri Kurta Tucholskog – a koja govori kako je smrt jednog čovjeka tragedija, dok je smrt milijuna samo statistika.

U pravnoj znanosti i humanističkom poretku na kojem počiva Konvencija, ovakva distinkcija ne smije i ne može opstati. Svaka od tih 20.000 žrtava predstavlja nepovratni gubitak koji ne smije biti promatran kao neizbježna statistika ili „kolateralna žrtva“ progresa, već kao sustavni neuspjeh države u zaštiti života pojedinca. Tradicionalno shvaćanje države kao subjekta koji se samo suzdržava od nasilja više nije dostatno. Kroz doktrinu o Konvenciji kao „živom instrumentu“, ESLJP je razvio koncept pozitivnih obveza [2], nalažući državama da poduzmu proaktivne korake za zaštitu života onih pod njihovom jurisdikcijom. U kontekstu sigurnosti prometa na cestama i zaštite ljudskih prava nužna je identifikacija obveza države s obzirom na ulogu države i to ne samo u zakonodavnom segmentu kao ni na području izvršavanja i poštivanja propisa koji reguliraju relevantnu materiju veći i u sferi projektiranja cesta i sigurnosnih sustava.

Upravo je Republika Hrvatska na žalost, svojom povredom pozitivne obveze iz čl. 2. Konvencije dala izniman doprinos izravnom uključivanju ESLJP u sferu sigurnosti cestovnog prometa. Naime, presudom ESLJP u predmetu *Smiljanić protiv Hrvatske* [10] sigurnost cestovnog prometa izravno je smještena u područje obaveza države u pogledu ljudskih prava. Stajališta suda zauzeta u toj presudi predstavljaju ključni iskorak u razvoju sudske prakse koja se tiče pozitivnih obveza države u kontekstu sigurnosti cestovnog prometa i zaštite ljudskih prava.

Središnja teza ovog istraživanja jest da je koncept Vision Zero u stvari treba percipirati kao izravnu operacionalizaciju ovih obveza, koja tehničke standarde sigurnosti transformira u supstancijalna ljudska prava, odbacujući statistički cinizam u korist apsolutne zaštite ljudskog bića.

2. DOSADAŠNJA ISTRAŽIVANJA I TEORIJSKA PODLOGA

Doktrinarni razvoj pozitivnih obveza u 21. stoljeću obilježen je radovima autora koji povezuju pravnu teoriju s tehničkom stvarnošću modernog društva. Seyed Hesamoddin Lesani u svom radu *Human Rights Jurisprudence and Road Safety* [6] postavlja revolucionarnu tezu prema

kojoj cestovni promet nije područje "nesretnih slučajeva", već sustav podložen striktnoj pravnoj odgovornosti države. Lesani ističe kako država posjeduje monopol nad dizajnom prometne infrastrukture i regulatornim okvirom pa je stoga odgovorna za svaku "sistemsku zamku" koja uzrokuje smrt. Uvodi pojam proaktivne dužnosti identifikacije opasnosti, navodeći da država krši pravo na život onog trenutka kada dopusti opstanak dokumentirane opasnosti bez intervencije.

Vladislava Stoyanova produbljuje ovu analizu kroz slojevitu analizu i kritičko preispitivanje elemenata krivnje (*fault*) i saznanja (*knowledge*) [7]. Ona ističe da krivnja države nije subjektivna, već objektivna, a proizlazi iz odstupanja od "standarda pažnje" koji bi razumna država trebala primijeniti. Stoyanova uvodi koncept "konstruktivnog saznanja", tvrdeći da država "zna" za opasnost onog trenutka kada njezine službe prikupe statističke podatke o nesrećama, čime se aktivira Osman test. Osman test je ključni pravni standard koji je postavio ESLJP u predmetu *Osman protiv Ujedinjenog Kraljevstva* 1998. [4]. Njime se utvrđuje opseg pozitivnih obveza države da zaštiti život pojedinca od kriminalnih radnji trećih osoba. Da bi se utvrdila odgovornost države za propust u zaštiti života, ESLJP provjerava: znanje vlasti (jesu li vlasti u tom trenutku znale ili su morale znati *knew or ought to have known* za opasnost), postojanje stvarne i neposredne opasnosti (je li postojao realan i neposredan rizik – *real and immediate risk* – za život točno određenog pojedinca ili skupine) i u konačnici propuštanje razumnih mjera (jesu li vlasti propustile poduzeti mjere unutar svojih ovlasti koje su se razumno mogle očekivati kako bi se taj rizik izbjegao). Međutim, postoje i ograničenja tog testa. ESLJP posebno ističe kako ta obveza ne smije nametati nemoguć ili nerazmjern teret državnim tijelima.

Janneke Gerards naglašava načelo proporcionalnosti, tvrdeći da težina potencijalne povrede (smrt) zahtijeva najviši stupanj državne pažnje [2]. Alon Harel upozorava da je dužnost zaštite života neprenosiva funkcija suverena i naglašava suverenu dužnost države da štiti život [14]. Istovremeno Schell i Ward (2022.) taj koncept doslovno konkretiziraju kroz *Safe System* pristup [8], argumentirajući kako odgovornost za sigurnost ne leži isključivo na pojedincu, već se mora dekonstruirati prema kreatorima sustava koji su dužni osigurati okruženje u kojem ljudska pogreška ne dovodi do smrtnog ishoda. Sabine Lavorel u svom radu zagovara evolucijsko tumačenje prava na život koje mora uključivati zaštitu od tehnoloških rizika [3]. Navedeni autori čine teorijsku osnovu koja vodi utemeljenom zaključku prema kojem Vision Zero predstavlja pravno prihvatljiv standard dužne pažnje u suvremenom prometu.

3. METODOLOŠKI OKVIR ISTRAŽIVANJA

Znanstveni pristup primijenjen u ovom radu temelji se na sustavnoj dogmatskoj pravnoj analizi i teleološkom tumačenju meritornih odredaba Konvencije za zaštitu ljudskih prava i temeljnih sloboda [1], s primarnim fokusom na njezino oživotvorenje kroz evolucijsku praksu ESLJP za ljudska prava. Metodološki okvir istraživanja postavljen je tako da naide puko gramatičko tumačenje normi, usmjeravajući se prema evolutivnom tumačenju članka 2. Konvencije.

Središnji dio metodologije obuhvaća detaljnu analizu odabranih vodećih predmeta (*leading cases*) ESLJP-a, pri čemu se primjenjuje metoda izdvajanja pravnih pravila (*ratio decidendi*) koja su izravno primjenjiva na kompleksne sustave cestovnog prometa. Istraživački proces strukturiran je kroz tri korelirane faze. Prva faza obuhvaća normativnu supstancijalnu analizu materijalnih pozitivnih obveza države, usmjerenu na preventivni aspekt zaštite života unutar infrastrukturnih okvira. Druga faza fokusirana je na analizu postupovnih (procesnih) obveza, s posebnim osvrtom na standarde učinkovite, neovisne i transparentne istrage u slučajevima fatalnih ishoda. Treća faza istraživanja predstavlja sintezu izlučenih pravnih standarda s tehničko-regulatornim okvirima Direktive 2008/96/EZ [11], čime se postiže interdisciplinarni

uvid u usklađenost inženjerskih normi s konvencijskim imperativima. Ovakav metodološki pluralizam koji spaja pravnu teoriju, sudsku praksu ESLJP te tehničku regulativu omogućuje visoku razinu preciznosti u dokazivanju teze o sustavnoj odgovornosti države unutar paradigme Vision Zero.

4. KATEGORIZACIJA OBEVEZA DRŽAVE: RAZGRANIČENJE NEGATIVNIH I POZITIVNIH OBEVEZA

Za razumijevanje suvremene odgovornosti države u cestovnom prometu, nužno je pomno analizirati i sustav obveza koji je ESLJP razvio kroz svoje odluke. Iako je primarni cilj članka 2. Konvencije zaštita prava na život od arbitrnog zadiranja države, ESLJP je jasno razgraničio negativne i pozitivne obveze, pri čemu ove posljednje čine okosnicu moderne prometne sigurnosti.

4.1. Negativne obveze: Imperativ suzdržavanja

Negativna obveza nalaže državi i njezinim tijelima (policiji, vojsci) strogo suzdržavanje od namjernog i nezakonitog oduzimanja života. To je klasični koncept „negativnog statusa” (*status negativus*), gdje se od države traži pasivnost. Korištenje smrtonosne sile od strane države mora biti podvrgnuta testu stroge nužnosti i apsolutne proporcionalnosti.

4.2. Pozitivne obveze: Država kao aktivni zaštitnik

Nasuprot negativnim, pozitivne obveze zahtijevaju od države aktivno djelovanje (*status positivus*). ESLJP u Strasbourgu ove obveze dijeli na dvije temeljne grane, od kojih svaka ima specifične zahtjeve prema državnom aparatu: na materijalne i postupovne obveze.

Materijalna pozitivna obveza odnosi se na dužnost države da uspostavi zakonodavni i upravni okvir koji pruža učinkovito odvracanje od ugrožavanja života. Ključni predmet za ovo područje je predmet ESLJP Öneriyildiz protiv Turske [5]. ESLJP je u ovom predmetu utvrdio da se materijalna obveza aktivira u svim situacijama koje su inherentno opasne (poput upravljanja otpadom, ali analogno i cestovnim prometom). Država mora poduzeti operativne preventivne mjere kako bi zaštitila pojedinca čiji je život ugrožen, pod uvjetom da su vlasti znale ili morale znati za rizik (*Osman standard*). U prometu to podrazumijeva sigurno projektiranje cesta, postavljanje signalizacije i uklanjanje „crnih točaka”.

Uz materijalnu zaštitu, države imaju i pozitivnu postupovnu obvezu. Ona se aktivira onog trenutka kada dođe do gubitka života, bez obzira na to jesu li za smrt odgovorni državni službenici ili privatne osobe. Što se traži od države? Država je dužna provesti učinkovitu, neovisnu, nepristranu i transparentnu službenu istragu. Istraga mora biti sposobna dovesti do utvrđivanja činjenica i ukoliko je to moguće, identifikacije i kažnjavanja odgovornih osoba. U cestovnom prometu, ova obveza nalogala bi da očevidi i analize nesreća ne budu puka formalnost, već dubinska analiza koja uključuje i provjeru odgovornosti upravitelja cesta (stanje kolnika, signalizacija), a ne samo krivnju vozača. Postupovna obveza osigurava javnu kontrolu nad djelovanjem države i štiti povjerenje građana u vladavinu prava.

5. PRIKAZ RELEVANTNE PRAKSE ESLJP: EVOLUCIJA STANDARDA

5.1. Predmet Osman protiv UK (23452/94): Uspostava testa dužne pažnje

Presuda ESLJP-a u predmetu **Osman protiv UK** [4] predstavlja ključni pravni putokaz u doktrini utvrđivanja odgovornosti države za propuste u zaštiti prava na život (članak 2. Konvencije). Ovom je odlukom Sud uspostavio strogi standard prema kojem pozitivna obveza države na poduzimanje preventivnih mjera nastaje u trenutku kada se utvrdi da su nadležna tijela znala ili su, prema objektivnim mjerilima, morala znati za postojanje stvarne i neposredne opasnosti. Ovaj predmet od osobitog je značaja s obzirom da je kroz njega kreiran i ranije spominjati tzv. Osman test. Standard koji ESLJP od njegove uspostave tj. kreiranja u navedenom predmetu dosljedno primjenjuje za utvrđivanje odgovornosti države u situacijama kada propusti zaštititi život od nasilnih radnji trećih osoba.

U kontekstu prometa, Lesani [6] ističe da se ovaj standard mora čitati kroz prizmu "crnih točaka". Ako upravitelj ceste ima podatke o učestalim nesrećama na određenom raskrižju, on posjeduje Osman-saznanje. Ako unatoč tome ne poduzme tehničke mjere unutar svojih ovlasti, država izravno odgovara za povredu materijalne pozitivne obveze zaštite života.

5.2. Predmet Önerıldız protiv Turske (48939/99): Odgovornost za opasne aktivnosti

Stajališta ESLJP u predmetu **Önerıldız protiv Turske** značila su uspostavu nezaobilaznog standarda u praksi ESLJP u pogledu preventivnih mjera zaštite života. Upravo zauzetim stavovima u tom predmetu ESLJP je definitivno proširio doseg članka 2. Konvencije na situacije u kojima država upravlja ili nadzire inherentno opasne aktivnosti. Iako se izvorni predmet ticao eksplozije metana na odlagalištu otpada, pravni standardi uspostavljeni ovom presudom imaju izravnu i neizbježnu aplikaciju na sustav cestovnog prometa.

U predmetu Önerıldız, ESLJP je bio kategoričan: država ima pozitivnu obvezu uspostaviti zakonodavni i upravni okvir koji pruža učinkovito odvracanje od ugrožavanja prava na život. Vladislava Stoyanova u svojoj analizi ističe da se ovaj standard mora promatrati kroz prizmu objektivne odgovornosti sustava. Prema Stoyanovoj, prometni sustav po svojoj naravi predstavlja „sustav visokog rizika” (*high-risk activity*), što od države zahtijeva ne samo donošenje prometnih pravila, već uspostavu rigoroznog regulatornog okvira koji jamči sigurnost infrastrukture. Država koja dopušta prometovanje na dionicama koje ne zadovoljavaju minimalne biomehaničke i sigurnosne standarde, prema Stoyanovoj, svjesno održava stanje strukturalne ugroze bitka pojedinca.

ESLJP je u ovoj presudi naglasio da odgovornost države nastaje onog trenutka kada nadležna tijela znaju, ili su morala znati, za postojanje stvarnog i neposrednog rizika. U predmetu Önerıldız ESLJP je utvrdio povredu jer su vlasti ignorirale stručna izvješća o opasnosti. Analogno tome, država koja ignorira statističke podatke o mortalitetu na određenim dionicama ceste, krši materijalnu pozitivnu obvezu zaštite života jer propušta poduzeti mjere koje su joj bile na raspolaganju.

Kroz interpretaciju Stoyanove, predmet Önerıldız postaje pravni temelj za Vision Zero pristup. Ako ESLJP nalaže da regulatorni okvir mora biti takav da „spriječi nesreću prije nego što se dogodi”, tada država ima obvezu dizajnirati prometni sustav koji predviđa ljudsku pogrešku. Svaki infrastrukturni propust (poput neadekvatne zaštitne ograde ili loše signalizacije) u svjetlu ove presude prestaje biti tehnički detalj i postaje materijalni deficit državnog aparata. Stoyanova zaključuje da država ne može delegirati odgovornost za sigurnost opasnog sustava; ona ostaje jamac integriteta ljudskog tijela unutar prostora koji je sama stvorila i regulirala.

5.3. Predmet Banel protiv Litve (14326/11): Imperativ preventivne procjene

Predmet **Banel** je ključan s obzirom na isticanje obveze pravovremene procjene rizika. ESLJP je utvrdio da pasivnost vlasti u održavanju javne infrastrukture (u ovom slučaju betonske

konstrukcije) predstavlja kršenje prava na život. Primijenjeno na promet, ovo znači da država ne smije čekati da se "crna prometna točka" potvrdi tragedijom, krvlju; ona ima pozitivnu obvezu provoditi redovite inspekcije i preventivno sanirati dionice čiji dizajn generira rizik, što je u potpunom suglasju s Direktivom 2008/96/EZ.

5.4. Predmet Grimkovskaya protiv Ukrajine (br. 38182/03): Pozitivne obveze u fazi projektiranja i planiranja

Presuda u predmetu **Grimkovskaya protiv Ukrajine** iz 2011. godine predstavlja nezaobilazan pravni standard za analizu odgovornosti države u samom početku infrastrukturnih projekata. Dok se Osman test primarno fokusira na reaktivnu zaštitu od već poznatog rizika, Grimkovskaya nameće obvezu preventivne pažnje u fazi odlučivanja. Apostrofira se sigurnosno planiranje kao *conditio sine qua non*. U ovom je predmetu ESLJP utvrdio da država krši svoje pozitivne obveze ako donosi odluke o prometnoj infrastrukturi poput preusmjeravanja teškog teretnog prometa na ceste koje za to nisu projektirane bez prethodne razumne procjene rizika i studije izvedivosti. ESLJP je naglasio da se od države očekuje da već u fazi nacрта i planiranja projekta predvidi potencijalne ugroze po život i zdravlje građana.

Razvidan je i stav ESLJP-a o prioritetu prava na život nad ekonomskom učinkovitošću. Presuda Grimkovskaya jasno poručuje da ekonomski interesi ili razvojni projekti ne mogu biti opravdanje za ignoriranje sigurnosnih standarda. S pravnog stajališta, ova presuda uspostavlja obvezu države da provede rigorozan postupak javne i stručne evaluacije prije implementacije prometnih rješenja. Država koja kreira infrastrukturni sustav bez adekvatnog planiranja zapravo sama generira rizik, što povlači izravnu odgovornost prema članku 2. EKLJP-a. Ovaj sudski standard savršeno korespondira s temeljem Vision Zero koncepta koji nalaže da sigurnost mora biti inkorporirana u sam "DNK" prometnog sustava. Ako Safe System model zahtijeva projektiranje cesta koje predviđaju ljudsku pogrešku, presuda Grimkovskaya tom zahtjevu daje dodatnu potvrdu utemeljenosti. Planeri i inženjeri više nisu samo tehnički izvršitelji; oni su produžena ruka države koja u fazi planiranja ispunjavaju (ili krše) pozitivnu obvezu zaštite života. Svaki propust u sigurnosnom planiranju na samom početku projekta ESLJP u Strasbourgu klasificira kao sustavni deficit koji državu izlaže odgovornosti.

5.5. Predmet Smiljanić protiv Hrvatske (35983/14): Nacionalna prekretnica

Ova presuda predstavlja evolucijski vrhunac u domeni nadzora prometne sigurnosti. ESLJP je u predmetu **Smiljanić** utvrdio povredu članka 2. Konvencije jer država nije uspostavila učinkovit sustav nadzora nad recidivistom u prometu. Ključni doprinos ove presude jest u stavu da učinkovitost represivnog i pravosudnog aparata čini dio pozitivne obveze zaštite života. Ako sustav kažnjavanja nema odvratajući učinak u odnosu na opasne vozače, država snosi sustavnu odgovornost. Stajališta suda zauzeta u predmetu Smiljanić potvrđuju da cestovni promet nije samo pitanje asfalta, već i integriteta pravosudnog odgovora na neželjene i nezakonite pojavnosti u cestovnom prometu.

6. REGULATORMI I ETIČKI ISKORAK 2019.: REDEFINICIJA STANDARDA SIGURNOSTI

Godina 2019. predstavlja povijesnu prekretnicu u zaštiti prava na život unutar europskog prometnog prostora. Kroz usvajanje Strateškog okvira EU za sigurnost cestovnog prometa 2021.–2030. i duboku reviziju Direktive 2008/96/EZ (putem Direktive 2019/1936) [11], europski zakonodavac je prešao s reaktivnog modela „upravljanja nesrećama” na proaktivni model

„jamstva preživljavanja”. Iskorak iz 2019. godine donio je ključnu promjenu u hijerarhiji prioriteta prometa. Dok je ranija praksa dopuštala određenu razinu rizika u ime ekonomske učinkovitosti i protoka prometa, novi okvir postavlja nepovredivost ljudskog života kao apsolutni prioritet.

Uvođenjem obveze procjene sigurnosti na razini cijele cestovne mreže (*Network-wide road safety assessment*), Direktiva 2019/1936 zapravo operacionalizira stavove ESLJP-a iz predmeta *Grimkovskaya* [13] i *Öneryıldız* [5]. Država više ne smije analizirati sigurnost samo tamo gdje se nesreća već dogodila, već mora identificirati dionice na kojima se nesreća može dogoditi s obzirom na njihove karakteristike. Poseban iskorak učinjen 2019. godine očituje se u eksplicitnom prepoznavanju ranjivih sudionika (*Vulnerable Road Users*) u prometu (pješačka, biciklisti, motociklisti). Ova promjena izravno korespondira s doktrinom o „biološkoj krhkosti” ljudskog bića. Zakonodavac je prepoznao da infrastruktura koja je bila „sigurna” za osobu u čeličnom kavezu vozila, nije sigurna za biološki integritet pješaka. Usvajanjem standarda koji nalažu da dizajn ceste mora uvažiti biomehaničke limite ljudskog tijela, europska politika je 2019. godine pretvorila biološku realnost u obvezujuće normativno pravilo. Država više ne smije čekati da se dogodi nesreća na „crnoj točki” (reaktivni pristup). Ona sada ima zakonsku obvezu analizirati dionice i identificirati rizike na temelju dizajna ceste, čak i ako se nesreća još nije dogodila.

7. DIGITALNA VIDLJIVOST RIZIKA I INSTITUCIONALNI CINIZAM

Lesani [6] ističe da ESLJP primjenjuje „živo tumačenje” Konvencije, što znači da se od države očekuje primjena najbolje dostupne prakse. ESLJP u svojim mišljenjima često naglašava da ekonomska kriza ili proračunski deficit ne mogu služiti kao *carte blanche* za ignoriranje mjesta na kojima građani ginu. ESLJP sve češće razmatra je li država uspostavila „siguran regulatorni okvir”. Ukoliko država identificira crnu točku, a ne ugradi elemente „sustava koji oprašta” (npr. kružni tok umjesto opasnog raskrižja), osnovano je to smatrati propustom u uspostavi okvira koji bi zaštitio pojedinca. Crne prometne točke svojevrsno su mjerilo proaktivnosti države. Ujedno Lesani [6] naglašava da je suština Vision Zero modela u eliminaciji rizika, a ESLJP to prevodi u pravni imperativ: država koja svjesno održava opasnu dionicu, unatoč dostupnim tehničkim rješenjima, postupa suprotno svojoj bitnoj nadležnosti i izvornoj svrsi postojanja. Svaka nesreća na nesaniranoj crnoj točki pravno se kvalificira ne kao incident, već kao rezultat propusta države da uskladi infrastrukturu s nepovredivosti ljudskog života.

Osnovanim se ukazuje zaključivati kako se ključni problem današnjice ne nalazi u nedostatku tehnologije ili pravnih normi, već u fenomenu „digitalne vidljivosti” rizika koju država često svjesno ignorira. U eri u kojoj inteligentni transportni sustavi (ITS) i Big Data analitika čine svaku „prometnu crnu točku” kristalno jasnom u realnom vremenu, pojam „neizbježne nesreće” prestaje postojati u svom klasičnom obliku.

Sve navedeno u bitnom doprinosi učvršćivanju stajališta prema kojem ukoliko država kroz svoje baze podataka i digitalne mape identificira opasnu dionicu, ona time gubi pravo na bilo kakvu ekskulpaciju temeljenu na „ograničenim resursima”. Šutnja sustava pred digitalno evidentiranom opasnošću zapravo predstavlja najviši stupanj institucionalnog cinizma. Ukoliko tehnologija omogućuje precizno predviđanje lošeg ishoda, svako prolongiranje infrastrukturne sanacije više nije samo administrativni propust, to je svjesno preuzimanje rizika povrede biološkog integriteta građana.

8. PROŽIMANJE PRAVA, BIOLOGIJE I TEHNOLOGIJE

8.1. Biološka realnost kao normativno pravilo: Supstancijalni zaokret prema pravu na život

Koncept biološke realnosti predstavlja temeljnu inovaciju unutar Vision Zero paradigme i njezinog prožimanja sa sudskom praksom ESLJP-a. Dok je raniji normativni okvir bio primarno usmjeren na sankcioniranje vozača zbog kršenja prometnih pravila, suvremeni pristup iz 2019. godine fokus premješta na fizičke granice i ograničenja ljudskog tijela. Uvažava se primarno znanstvena determiniranost bioloških granica. Vision Zero dosljedno uvažava znanstvenu činjenicu: ljudski organizam je krhak i posjeduje fiksne granice otpornosti na kinetičku energiju. Primjerice, vjerojatnost preživljavanja pješaka pri naletu vozila brzinom od 30 km/h iznosi oko 90%, dok pri brzini od 50 km/h ta vjerojatnost dramatično pada na manje od 15%. Godine 2019., kroz ažurirani Strateški okvir EU za sigurnost cesta, ove biomehaničke činjenice prestaju biti samo podaci iz laboratorija i postaju normativno pravilo.

Kreira se iz tih spoznaja i pozitivna obveza države u kontekstu "sustava koji oprašta". Naime, u svjetlu članka 2. Konvencije, biološka realnost nameće državi materijalnu obvezu projektiranja sustava koji te sile udara drži ispod fatalne granice. Ako država dopusti brzinu od 50 km/h u gusto naseljenoj pješačkoj zoni bez zaštitne infrastrukture, ona svjesno projektira sustav koji krši biološke granice preživljavanja. Prema standardima iz predmeta *Öneriyildiz*, država koja zna (ili mora znati) za biomehaničku opasnost određenog prometnog rješenja, ima pozitivnu obvezu intervenirati kako bi osigurala "sustav koji oprašta" (*Forgiving System*). To znači da ljudska pogreška (poput dekoncentracije pješaka) ne smije rezultirati smrću iz razloga što sustav nije predvidio a ni akceptirao biološku krhkost tijela.

Promjena iz 2019. godine snažno naglašava da odgovornost za život nije isključivo na pojedincu, već je zajednička i solidarna: Planeri i inženjeri imaju svojevrsnu ulogu produžene ruke države, a koji adekvatno „igrajući tu krajnje odgovornu ulogu“ zapravo ispunjavaju pozitivnu obvezu projektiranjem "cesta koje uzimaju u obzir biološke zakonitosti" (npr. kružni tokovi koji fizički ograničavaju brzinu udara). Zakonodavci su dužni uspostaviti regulatorni okvir koji brzine kretanja usklađuje s biološkim limitima najranjivijih skupina (pješaci, djeca, biciklisti). Proizvođači vozila uključeni su kroz standarde pasivne sigurnosti koji apsorbiraju energiju udara.

Biološka krhkost nameće se kao standard pažnje. Kako navodi Gerards [2], težina potencijalne povrede diktira razinu dužne pažnje. Budući da su sile udara u prometu često nespojive s preživljavanjem, država mora primijeniti najviši stupanj proaktivnosti. Kršenje biološke granice u prometnom dizajnu danas se može smatrati sustavnim deficitom države. Ako planer sustava zna da ljudsko tijelo biološki ne može preživjeti udar pod određenim kutom ili brzinom na određenoj dionici, a ne ugradi zaštitnu ogradu ili uspornik, on izravno izlaže državu odgovornosti za povredu prava na život.

8.2. Inteligentni transportni sustavi (ITS) i tehnološko redefiniranje standarda pažnje

U 21. stoljeću, pozitivna obveza države iz članka 2. Konvencije više se ne može ispuniti isključivo analognim sredstvima. Kako ističe Janneke Gerards [2], standard „dužne pažnje“ (*due diligence*) dinamička je kategorija koja se mora korigirati u skladu s tehnološkim napretkom društva. Ignoriranje inteligentnih transportnih sustava (ITS) na dionicama s visokim rizikom (crnim točkama) više nije samo pitanje proračunske politike, već izravno odstupanje od standarda pažnje koji zahtijeva ESLJP.

Prema stavovima Sabine Lavorel [3], država koja posjeduje tehnologiju za automatsko usporavanje prometa u uvjetima smanjene vidljivosti ili poledice, a odluči je ne implementirati

na opasnim dionicama, svjesno izlaže biološki integritet građana riziku koji premašuje standard dopuštenog.

Poveznica s predmetom *Osman protiv UK* [4] i *Öneryıldız protiv Turske* [5] ovdje postaje kristalno jasna. ESLJP u Strasbourgu temelji odgovornost države na onome što je država „znala ili morala znati”. U digitalnom dobu, kroz ITS senzore i analitiku „velikih podataka” (*Big Data*), država dobiva precizne, *real-time* informacije o opasnostima na cesti. Kao što Seyed Hesamoddin Lesani [6] argumentira, posjedovanje takvih podataka, a izostanak automatske reakcije sustava (npr. pametne signalizacije koja zatvara traku nakon detekcije incidenta), predstavlja moderni oblik institucionalnog nemara. Ako sustav detektira incident, a država ne koristi ITS za trenutno upozorenje ostalih sudionika, ona krši materijalnu pozitivnu obvezu jer nije poduzela mjere koje su joj bile „tehnički dostupne i operativno moguće”.

Janneke Gerards [2] razrađuje ideju da se proporcionalnost mjera ocjenjuje prema kriteriju „najbolje dostupne prakse”. U pravnoj teoriji ljudskih prava, to znači da država ne može zauvijek ostati na razini sigurnosnih standarda iz prošlog stoljeća. Implementacija ITS-a (poput *eCall* sustava ili sustava za detekciju umora) postaje normativno pravilo. Država članica EU koja se deklarativno zalaže za Vision Zero, a sustavno zanemaruje digitalizaciju sigurnosne infrastrukture, nalazi se u stanju sustavnog deficita. Prema Vladislavi Stoyanovoj [7], takva pasivnost predstavlja „strukturnu pogrešku” projektiranja sustava koja izravno vodi do povrede prava na život.

Uvođenjem ITS-a, odgovornost se seli s pojedinca na projektante algoritama i upravitelje sustava. *Safe System* pristup nalaže da planer, svjestan da ljudsko tijelo biološki ne podnosi udar iznad određenog praga, mora ugraditi tehnološke „kočnice” u infrastrukturu. Inženjeri koji razvijaju ITS rješenja tako postaju izvršitelji pozitivnih obveza države. Njihov propust da integriraju sigurnosne protokole u digitalnu mrežu prometnica ESLJP može promatrati kao propust države u uspostavljanju učinkovitog regulatornog okvira za zaštitu života.

8.3. Sinergija stajališta ESLJP i javnih politika: Od reaktivnog sankcioniranja do normativnog imperativa

Kritičko sagledavanje odnosa između sudske prakse ESLJP-a i europskih javnih politika, kako ga interpretira Lesani [6], ne smije se tumačiti kao dobrovoljna proaktivnost država, već kao rezultat progresivnog pravnog pritiska. Iako bi idealni model sugerirao da države saniraju „crne točke” preventivno, realnost crnih statistika ukazuje na duboku institucionalnu inerciju. Stoga, sinergija o kojoj ovdje govorimo nije plod političke dobrohotnosti, već sustavnog straha od institucionalne odgovornosti.

Presude ESLJP-a, prema Lesaniju [6], nisu izolirani pravni akti, već strukturalni motori koji prisiljavaju države na promjenu paradigme. Države često ne saniraju ceste zato što to žele, već zato što stajališta ESLJP-a sadržana u njegovim odlukama stvaraju okruženje u kojem pasivnost postaje financijski i reputacijski neodrživa. Vision Zero u tom smislu nije samo utopijski politički cilj, već iznudeći pravni odgovor na visoke konvencijske zahtjeve članka 2. Svaka nova presuda, poput one u predmetu *Smiljanić protiv Hrvatske* [10], sužava prostor za državnu obranu utemeljenu na „ograničenim resursima”. Presude se nameću kao svojevrsni „katalizator” normativne reforme.

Iako se proklamira zahtjev da države ne čekaju nove presude, treba precizno reći: države su danas pod stalnim „mačem verifikacije svog postupanja od strane ESLJP”. Javne politike sigurnosti cestovnog prometa zapravo su instrumenti upravljanja pravnim rizikom. Kada EU direktive nalažu stroge inspekcije i rangiranje sigurnosti [11], one to čine kako bi spriječile da države završe pred ESLJP-om zbog propusta koji su u 21. stoljeću, uz dostupnu ITS tehnologiju, postali nedopustivi.

Kao što Stoyanova [7] uočava, pasivnost države pred poznatim rizikom više se ne može pravdati pukom administrativnom diskrecijom. U trenu kada država usvoji strateške okvire Vision Zero, ona samu sebe stavlja u normativnu zamku: svaki kilometar ceste koji ne zadovoljava biološki prihvatljive sile udara postaje dokazni materijal protiv države. Stoga, „proaktivnost” države u sanaciji cesta zapravo je pokušaj izbjegavanja dokazane krivnje. Praksa ESLJP je postala toliko intenzivna i evidentna da svaka neriješena „crna točka” predstavlja zapravo svjesno kršenje standarda dužne pažnje (*due diligence*) [2].

Očigledno je kako u konačnici, sinergija sudske prakse i javnih politika predstavlja proces u kojem pravo prisiljava politiku na humanost. Vision Zero je pravni štit koji građani dobivaju protiv državne štednje na sigurnosti. Lesani [6] naglašava da tek kada akteri sustava shvate da će njihova pasivnost biti testirana kroz prizmu biološke realnosti, možemo očekivati stvarnu promjenu. Doktrina pozitivnih obveza tako postaje jedini stvarni jamac da se „crne statistike” neće tretirati kao neizbježnost, već kao kazneno-pravni i odštetni teret koji država više neće moći ignorirati.

9. ZAKLJUČAK

Analiza provedena u okviru ovog rada nepobitno ukazuje na to da se suvremeno poimanje sigurnosti cestovnog prometa više ne može izolirati unutar okvira tehničkih normativa, već ga je neophodno promatrati kao primarno pitanje zaštite ljudskih prava. Središnju ulogu u ovom epohalnom zaokretu odigrao je ESLJP, sud čije su odluke izvršile radikalan pritisak na tradicionalnu doktrinu državne suverenosti i njezine odgovornosti prema pojedincu. Ekstremni doprinos ESLJP-a očituje se u transformaciji članka 2. Konvencije iz reaktivne zabrane arbitrarnog oduzimanja života u proaktivni mehanizam pozitivnih obveza države. ESLJP je kroz niz presuda, od paradigmatškog Osman testa do evolutivnog standarda u predmetu *Smiljanić protiv Hrvatske*, poslao nedvosmisleni poruku: država nije pasivni promatrač rizika, već aktivni arhitekt sigurnosti.

U tom kontekstu, iskoraci učinjeni 2019. godine, kroz ažuriranje Direktive 2008/96/EZ i usvajanje ambicioznih strateških okvira EU do 2050. godine, ne predstavljaju tek administrativne pomake, već su to svojevrsni pravno uobličeni akti kojima se jasno artikulira osviješteni etički imperativ koji se tiče prava na život i zaštite ljudskog života. Suvremena težnja europskog pravnog prostora, pod snažnim utjecajem stavova Lesanija, Stoyanove i Gerards, ide prema stvaranju „prava na siguran prometni sustav”. Evolucija prava na život transformirala je državu u aktivnog jamca sigurnosti koji mora predvidjeti ljudsku nesavršenost. Vision Zero u tom smislu nije samo prometni model, već etička i pravna operacionalizacija članka 2. Konvencije koja uvažava biološku krhkost čovjeka kao normativnu polazišnu točku.

Presuda *Smiljanić* ostaje trajni podsjetnik da pravo na život zahtijeva učinkovito pravosuđe i sigurnu infrastrukturu kao nedjeljivu cjelinu državne odgovornosti. Stajališta ESLJP-a postala su nezaobilazan interpretativni putokaz koji nalaže državi da svoju izvornu ustavnu obvezu zaštite života provede kroz konkretnu primjenu inteligentnih sustava i infrastrukture dizajnirane da preveniraju smrtnu ishode ljudskih pogrešaka. Život više nije statistička jedinica unutar kalkulacije o prihvatljivom riziku; on je apsolutna vrijednost kojoj se moraju podrediti i proračunske stavke i inženjerski standardi. Država koja danas ignorira „crne točke” i tehnološki napredak, svjesno i izravno ugrožava ontološku pretpostavku života svojih građana. Samo kroz ovakvu beskompromisnu primjenu pozitivnih obveza, cestovni promet prestaje biti prostorom tragedije i postaje prostorom sigurne mobilnosti, čime pravo na život konačno dobiva svoj puni, praktični i učinkoviti smisao u europskoj pravnoj zbilji.

10. LITERATURA

[1] **ECHR**, Council of Europe, *Convention for the Protection of Human Rights and Fundamental Freedoms*, 1950. https://www.echr.coe.int/documents/d/echr/convention_ENG

- [2] **Gerards, J.**, *General Principles of the European Convention on Human Rights*, Cambridge University Press, Cambridge, 2019.
- [3] **Lavorel, S.**, *Les obligations positives de l'État en vertu de la Convention européenne des droits de l'homme*, Bruylant, Bruxelles, 2010.
- [4] **ECHR**, *Osman v. UK*, No. 23452/94, 1998.
[https://hudoc.echr.coe.int/eng#{%22itemid%22:\[%22001-58257%22\]}](https://hudoc.echr.coe.int/eng#{%22itemid%22:[%22001-58257%22]})
- [5] **ECHR**, *Öneryıldız v. Turkey*, No. 48939/99, 2004.
[https://hudoc.echr.coe.int/fre#{%22itemid%22:\[%22001-67614%22\]}](https://hudoc.echr.coe.int/fre#{%22itemid%22:[%22001-67614%22]})
- [6] **Lesani, S. H.**, "Human Rights Jurisprudence and Road Safety", *Journal of Legal Studies*, 2021. <https://tsr.international/TSR/article/view/28340>
- [7] **Stoyanova, V.**, "Fault, Knowledge and Risk under ECHR", *Leiden Journal of International Law*, 2020.
https://www.researchgate.net/publication/340415756_Fault_knowledge_and_risk_within_the_framework_of_positive_obligations_under_the_European_Convention_on_Human_Rights
- [8] **Schell, W., & Ward, N. J.**, "A Process for Change: The Safe System Approach and Vision Zero", *Frontiers in Future Transportation*, 2022.
<https://www.frontiersin.org/journals/future-transportation/articles/10.3389/ffutr.2022.982942/full>
- [9] **European Commission**, *Road Safety Statistics 2024*, 2025.
https://transport.ec.europa.eu/news-events/news/road-safety-statistics-2024-progress-continues-amid-persistent-challenges-2025-10-17_en
- [10] **ECHR**, *Smiljanić v. Croatia*, No. 35983/14, 2021.
[https://hudoc.echr.coe.int/fre#{%22itemid%22:\[%22001-208755%22\]}](https://hudoc.echr.coe.int/fre#{%22itemid%22:[%22001-208755%22]})
- [11] **EU**, *Directive 2008/96/EC on road infrastructure safety management (Updated 2019)*, OJ L 319. <https://eur-lex.europa.eu/eli/dir/2008/96/oj/eng>
- [12] **ECHR**, *Banel v. Lithuania*, No. 14326/11, 2013.
[https://hudoc.echr.coe.int/fre#{%22itemid%22:\[%22001-120961%22\]}](https://hudoc.echr.coe.int/fre#{%22itemid%22:[%22001-120961%22]})
- [13] **ECHR**, *Grimkovskaya v. Ukraine*, No. 38182/03, 2011.
[https://hudoc.echr.coe.int/eng#{%22itemid%22:\[%22001-105746%22\]}](https://hudoc.echr.coe.int/eng#{%22itemid%22:[%22001-105746%22]})
- [14] **Harel, A.**, *Why Law Matters: Individual Agency, Legality, and the State*, Oxford University Press, Oxford, 2014.

Organizacija integriranog prijevoza putnika Organisation of integrated passenger transport

Borna Abramović¹¹ Redoviti profesor, Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska,
borna.abramovic@fpz.unizg.hr**Sažetak**

Integrirani prijevoz putnika predstavlja multimodalnu platformu za optimalno upravljanje mobilnosti stanovništva koristeći javni prijevoz. Mobilnost stanovništva sve je teža zbog u prvom redu nekontroliranog rasta individualnog cestovnog prijevoza, a posebice na području gradova i gradskih prstena. Integrirani prijevoz putnika omogućava optimalni susret prijevozne potražnje i ponude te na taj način predstavlja održiv prometni sustav sa stajališta ekonomije, ekologije i prostornog planiranja. Integrirani prijevoz putnika danas predstavlja temelj prometnog planiranja no svakako veliki naglasak je upravo na organizaciju integriranog prijevoza putnika.

Ključne riječi: integrirani putnički prijevoz, cestovni prijevoz, željeznički prijevoz, planiranje prometa

Abstract

Integrated passenger transport is a multimodal platform for the optimal management of population mobility using public transport. Mobility is becoming increasingly problematic, primarily due to the uncontrolled growth of private road transport, especially in cities and their urban fringes. Integrated passenger transport enables an optimal matching of transport demand and supply and thereby represents a sustainable transport system from the perspectives of economics, ecology and spatial planning. Today, integrated passenger transport forms the foundation of transport planning, with a strong emphasis on the organisation of integrated passenger services.

Keywords: integrated passenger transport, road transport, railway transport, transport planning

1. UVOD

Integrirani prijevoza putnika (IPP), također poznat i kao Integrirani javni prijevoz putnika (IJPP) ili Integrirani prijevozni sustav (IPS) zapravo jest sustav javnog prijevoza koji objedinjuje različite modove i različite prijevoznike javnog prijevoza u jednu cjelinu na nekom području. Takav sustav koristi prednosti svih prijevoznih modova u sustavu, a suradnjom modova u velikoj mjeri poništava nedostatke pojedinog prijevoznog moda. On omogućuje stvaranje multimodalnih terminala odnosno mjesta gdje se lako presjeda s jednog prijevoznog moda na drugi odnosno sa jednog prijevoznika na drugog prijevoznika, usklađivanje voznih redova između različitih modova i korištenje jedinstvenih prijevoznih karata za sve vrste modova i prijevoznika u sustavu.

Uz sve to donosi niz ekonomskih prednosti kako za korisnike, tako i za prijevoznike, te dionike uključene u sustav javnog prijevoza.

U sustavu Integriranog prijevoza putnika korisnik može koristiti jednu jedinstvenu kartu za putovanje vlakom, tramvajem, autobusom i svim ostalim modovima prijevoza koji postoje u sustavu na određenom području. Vozni redovi svih modova prijevoza međusobno su dobro

usklađeni, a također postoji veliki broj stajališta gdje je moguće između vlakova, autobusa, tramvaja i/ili ostalih modova brzo i lako presjedati. Može se utvrditi čitav sustav temelji na multimodalnosti.

Kroz noviju povijest ovakvi su sustavi pokazali i odlične ekonomske efekte. Broj putnika i prihodi prijevoznika porasli su, a za optimalne subvencije dobiva se adekvatna usluga. Mnogi prijevoznici spašeni su od propadanja i danas u integriranim sustavima vrlo uspješno posluju.

U integriranom prijevozu putnika najčešće se primjenjuje takti vozni red. To je vozni red koji sa svakog stajališta omogućava polaske vozila javnog prijevoza u pravilnim vremenskim razmacima, recimo svakih 5, 10, 20, 30 minuta ili svakih sat ili svaka dva sata. Intervali polaska prilagođavaju se prijevoznj potražnji, te čisto tehnološkim mogućnostima sustava (obrt vozila, brzina putovanja i sl.).

Sustavom integriranog prijevoza putnika upravlja Prometna uprava. Najčešće je organizirana kao javna tvrtka, a vlasničke udjele u njoj imaju gradovi i lokalne jedinice uprave, rjeđe i država. Također postoje i primjeri da su prometne uprave organizirane kao uredi u sklopu tijela lokalne samouprave i tada nose naziv Ured za mobilnost.

Glavni zadaci većine Prometnih uprava su: provođenje istraživanja prijevozne potražnje, izrada voznih redova za linije javnog prijevoza na temelju tih istraživanja i ostalih potreba, dodjela linija prijevoznicima, prikupljanje novaca od prodaje karata, prikupljanje subvencija od lokalne i državne uprave, raspodjela novaca prijevoznicima prema ugovorima, nadzor prometa na dodijeljenom području, marketing javnog prijevoza (istraživanja kvalitete, promocija, služba za korisnike i sl.) te vrlo bitna funkcija daljnji razvitak sustava.

Integrirani javni prijevoz prepoznat je kao najvažniji način organizacije prijevoza putnika od strane brojnih razvijenih zemalja i cijele Europske unije. Kao takav se učestalo spominje u brojnim temeljnim strateškim dokumentima poput Bijele knjige o prometu 2011. izdane od strane Europske komisije, Operativnim programima zemalja EU i pristupnim članicama i brojnim drugim dokumentima.

Ovakvi sustavi postoje u velikoj većini zapadnih europskih zemalja i u još nekim razvijenim zemljama Svijeta. Svojim kvalitetnim radom opravdali su svoje uvođenje, no rad na njihovom unapređenju kako tehnički i tehnološki, tako i s aspekta korisničke usluge, ne prestaje. Javni prijevoz ima brojne ekološke, energetske, infrastrukturne, gospodarske i sigurnosne prednosti pred individualnim, stoga zaslužuje intenzivnu primjenu i razvitak.

2. KRATKI POVIJESNI RAZVOJ INTEGRIRANOG PRIJEVOZA PUTNIKA

Prvi integrirani prijevozni sustav na svijetu osnovan je 1965. godine u Hamburgu u Njemačkoj. Zajedničke tarife i usklađivanje voznih redova ugovorno su tada zapečatila četiri poduzeća: (1) Hamburger Hochbahn AG upravitelj podzemne željeznice i nekih autobusnih linija, (2) Deutsche Bundesbahn (danas Deutsche Bahn AG) željeznički prijevoznik, (3) HADAG Seetouristik und Fährdienst AG brodski lokalni prijevoznik i (4) Verkehrsbetriebe Hamburg-Holstein (VHH), regionalni autobusni prijevoznik. Korisnici su tako prvi puta s jednom kartom mogli presjedati između vlaka, podzemnog vlaka, autobusa i brodova u regiji grada Hamburga. Ove primjere uskoro su slijedili i ostali gradovi tadašnje Savezne Republike Njemačke te su osnovali svoje prijevozno-tarifne unije (München 1971., Frankfurt na Majni, 1974., Stuttgart 1978. ...).

Godine 1996. provedena je reforma željezničkog i lokalnog prijevoza u Njemačkoj te Prometne uprave postaju poduzeća koja su u vlasništvu gradova, regija i pokrajina. Njemačka je podijeljena na 40-ak područja i u svakom od njih za organizaciju lokalnog prometa po principu prijevozno-tarifne unije zadužena je pojedina Prometna uprava. Integrirani prijevozni sustavi tako postaju zakonskom obavezom. Isti sustav gospodarenja lokalnim javnim prijevozom usvajaju i Republika Austrija 2000. godine te Švicarska 2002.

Prijevozno-tarifne unije pojavljuju se još u Velikoj Britaniji, Švedskoj, Danskoj, Španjolskoj, Francuskoj, Italiji, itd. Postale su interesantne i za novo pridošle zemlje u EU pa se s uspjehom primjenjuju u Poljskoj, Češkoj, Slovačkoj i Mađarskoj.

3. PRIJEVOZ PUTNIKA KAO JAVNI INTERES

Javni prijevoz se ne smije promatrati isključivo kao komercijalna djelatnost odnosno tvrdo rečeno kao profitabilna djelatnost. Radi se o djelatnosti od cjelokupnog društvenog značaja. Javni prijevoz izravno utječe na mobilnost stanovništva, time i na mobilnost radne snage pa tako i na bruto nacionalni dohodak. Mobilnost stanovništva omogućava izbor života u većim ili manjim sredinama, onim urbanim ili ruralnim. Taj izbor zajedno s porastom dostupnosti raznih gospodarskih, društvenih i kulturnih sadržaja bitno povećava kvalitetu života građana. Ako se pretpostavi da je jedan od najvažnijih zadataka državnih i lokalnih vlasti povećanje kvalitete života stanovnika, tada osiguravanje i razvitak javnog prijevoza trebaju postati jedan od najvažnijih zadataka tih vlasti. Poznati su primjeri iz prakse, na primjer u Belgiji, Nizozemskoj, Češkoj gdje vlasti zakonima osiguravaju građanima pravo na mobilnost, odnosno dostupnost javnog prijevoza.

4. ISTRAŽIVANJA U FUNKCIJI INTEGRANOG PRIJEVOZA PUTNIKA

Kako bi se mogao organizirati sustav integriranog prijevoza putnika potrebno je istražiti slijedeće teme: (1) istraživanje prijevozne potražnje, (2) vozni redovi, (3) učestalost polazaka, (4) utvrđivanje tarifa, (5) načini dodjela linija prijevozniciima i (6) prikupljanje prihoda od prodanih karata i subvencija te njihova razdioba.

4.1. Istraživanje prijevozne potražnje

Istraživanje prijevozne potražnje je utvrđivanje demografskih značajki stanovništva (npr. stanovništvo u pojedinim kvartovima, naseljima i gradovima) temeljem kojih imaju potrebu za mobilnošću (prijevozom), kamo se kreće i kada se kreće te koliko učestalo. Prijevozna potražnja može se prikazati i kao matrica tokova putnika između ishodišta i odredišta. Ovo je temeljno istraživanje, koje nikako ne smije biti preskočeno, koje prethodi određivanju linija i voznog reda javnog prijevoza.

Istraživanje prijevozne potražnje je vrlo složeno istraživanje koje kombinira brojanje prometa i putnika na terenu te ankete koje se provode među stanovništvom. Anketama se utvrđuje trenutna mobilnost (odredišta, vremena, razlozi, ...) te se utvrđuju i želje (preferencije) za putovanjima u budućnosti.

4.2. Izrada voznih redova

Na temelju istraživanja određuju se linije i vozni redovi. U izradi voznog reda osim samih rezultata istraživanja prijevozne potražnje vodi se računa i o učestalosti polazaka, izbjegavanju paralelnih linija te se najčešće primjenjuje taktni vozni red.

Izvan polazaka utvrđenih istraživanjima, moguće je uvesti i dodatne polaske koje mogu zatražiti pojedini gradovi, mjesta i/ili općine. Na taj način lokalna samouprava može povećati kvalitetu usluge javnog prijevoza vlastitim građanima. Naravno, dodatni polasci dodatno se subvencioniraju.

Kako što je napomenuto, uvijek se izrađuje taktni vozni red (njem. Taktfahrplan, engl. Clock-face timetable). To je takav vozni red koji sa pojedinih stajališta ima polaske u pravilnim vremenskim razmacima, npr. svakih sat, svakih 30 minuta, svakih 10 minuta, svakih 5 minuta ili češće. Ovakav vozni red primjenjuje se i izvan integriranih prijevoznih sustava, a uveden je kao inovacija kako bi se korisnicima javni prijevoz učinio svestraniji, atraktivniji i lako pamtljiv. Taktni vozni red često omogućava i lakši rad prijevozniciima jer se jednom obavljeni obrt vozila tada može samo višestruko kopirati.

Kroz pojedina stajališta može prolaziti više linija javnog prijevoza. Tada se može dogoditi da polasci s tog stajališta budu nakon 5, pa nakon 10, pa nakon 15 minuta, pa opet nakon pet itd. Ako svaka pojedina linija ima polaske u pravilnim vremenskim razmacima i u tom slučaju se radi o taktnom voznom redu.

4.3. Učestalost polazaka kao dio voznog reda

Vozni red javnog prijevoza mora pružiti kvalitetnu alternativu individualnom prijevozu za razne potrebe stanovništva. Kako bi djelomično nadomjestio mogućnost polaska u bilo koje vrijeme koje nudi individualni prijevoz, javni prijevoz mora biti učestali. To znači da mora imati barem minimalni broj polazak kroz dan kako bi mogao konkurirati individualnom prijevozu. Najrjeđi polasci s pojedinih stajališta na rubovima regija nekog sustava tako su svakih sat vremena ili svakih dva sata u vremenu izvan vršnih opterećenja (špica) ili vikendom. Prema centru sustava, obično je to centar nekog grada, broj linija je sve veći (gušći) i polasci su sve učestaliji.

Ukoliko ne postoji minimalni broj polazaka s nekih stajališta može se smatrati da tada nije zadovoljena minimalna ponuda te tada javni prijevoz bitno gubi na svojoj atraktivnosti.

Vozni red lokalnog javnog prijevoza u većini sustava osigurava polaske obično od 5 sati ujutro do 23 sata navečer. Ova vremena mogu se prilagoditi potrebama stanovništva u pojedinim regijama, a najčešće potrebe su putovanje na posao, u školu, na kulturna i sportska zbivanja, rekreativne aktivnosti i slobodno vrijeme te ostale svrhe putovanja. U mnogim gradovima Europe tako javni prijevoz redovito prometuje čak i do 1:30 u noći. Negdje pak počinje i prije 4 sati ujutro zbog mobilnosti radno aktivnog stanovništva. U noćno vrijeme zbog kulturnih i ugostiteljskih zbivanja ponegdje se organiziraju i noćne linije koje često imaju vlastitu mrežu i polaske bitno rjeđe nego one dnevne.

Također, obično se razlikuju tri takta (razmak između polazaka). Prvo su vremena u vršnim opterećenjima (špicama). To je doba dana kada je prijevozna potražnja najveća i broj polazaka na gotovo svim linijama je najveći (najgušći). Drugo je vrijeme izvan vršnih opterećenja, a to je obično radnim danom i/ili subotom kada je prijevozna potražnja manja i broj polazaka je često oko 50 % manji nego u vršnim opterećenjima. Treće vrijeme jest period nedjelja i blagdana. Tada je prijevozna potražnja najmanja, ali ipak postoji. Stanovništvo tada vrlo malo putuje na posao (samo specifična zanimanja), no ipak putuje na izlete, rekreaciju, kulturna i sportska zbivanja.

4.4. Utvrđivanje tarifa

Tarifiranje ili određivanje cijena prijevoznih karata složeni je postupak. Najvažnija zadaća tarifiranja jest odrediti cijene prijevoznim kartama koje će biti atraktivne za korisnike, prihvatljive za prijevoznike, a s druge strane će omogućiti optimalno subvencioniranje sustava javnog prijevoza putnika.

U tarifiranju se dužina putovanja, u pravilu, određuje po zonama. Područje prijevozno - tarifne unije se prema istraživanjima razdjeli po zonama i cijena karte se izračunava temeljem broja zona koje putnik želi prijeći.

Osim prema duljini putovanja karte se dijele i prema dužini trajanja (vrijeme). Tako osim karata za pojedinačna putovanja danas postoje dnevne karte, višednevne karte, tjedne karte, mjesečne karte, polugodišnje i godišnje karte. Tako u sustavu može postojati npr. dnevna karta za dvije zone, mjesečna karta za 3 zone, godišnja karta za 5 zona, dnevna karta za cijelu mrežu sustava i ostale kombinacije koje su zanimljive putnicima.

4.5. Načini dodjela linija prijevoznicima

Nakon izrade voznog reda zadatak je Prometne uprave da natječajem ili putem izravnih pogodbi dodjeli linije prijevoznicima. U slučaju provedbe natječaja za pojedine linije izabire se prijevoznik koji najbolje udovoljava traženim uvjetima u natječaju.

Najznačajniji dokument o načinu dodjele linija prijevoznicima je Uredba (EZ) broj 1370/2007. Pravila navedena u Uredbi moraju se u potpunosti primijeniti prilikom dodjeljivanja linija prijevoznicima.

U Njemačkoj je praksa da se ugovori potpisuju na 5, 10 nerijetko i 15 godina. Dugoročni ugovori omogućuju prijevoznicima da dugoročno planiraju zapošljavanje ljudi, održavanje postojećih i nabavku novih vozila.

Ugovorom koji sklapaju prijevoznik i Prometna uprava prijevoznik je dužan obaviti ugovorenu uslugu prema ugovorenim specifikacijama, a Prometna uprava je dužna prema ugovoru isplatiti prihode i pružiti adekvatnu potporu uspješnog rada prijevoznika u sustavu.

Bitno je napomenuti da nije propisan minimalni, ali niti maksimalni broj prijevoznika tako da se broj prijevoznika može optimizirati prema stvarnoj situaciji na području integracije.

4.6. Prikupljanje prihoda od prodanih karata i subvencija te njihova razdioba

Vrlo bitan zadatak Prometne uprave je također da organizira sustav prodaje prijevoznih karata u tarifnoj uniji. Prijevozne karte mogu prodavati prijevoznici pojedinačno, a može se i implementirati poseban sustav. Sve prihode koji su ostvareni od karata u prijevozno-tarifnoj uniji prikuplja Prometna uprava.

Sve subvencije od strane državne i lokalne uprave također prikuplja Prometna uprava. Zadatak Prometne uprave jest i da ima kontrolu nad svim troškovima, također da prema ugovorima isplaćuje sredstva za obavljene usluge prijevoznicima.

Kako bi sustav mogao funkcionirati mora postojati potpuna transparentnost kako u prikupljanju tako i razdiobi prihoda. Dakle, svaki prijevoznik mora imati informaciju o svakom drugom prijevozniku koliko je prihoda donio u sustav, a kolika je bila razdioba.

5. NADZOR PROMETA

Prometna uprava ima i zadatak da centralno nadzire i upravlja svim prijevozom na svom području. Za obavljanje tog zadatka Prometna uprava osniva vlastiti kontrolni centar ili sklapa ugovore s drugim prijevoznicima (željeznica, autobusi) ili centrima za kontrolu prometa (npr. nadzor željezničkog prometa na razini neke države ili regije). Moguće su i kombinacije oba načina rada.

Cilj nadzora prometa je obično dvojak. Prvo, nadzorom prometa nadzire se rad prijevoznika, skupljaju se podaci o kretanju vozila, otklanjaju se poteškoće u prometu u slučaju poremećaja, te se prijevoznicima pruža uvid u kretanje njihovih vozila u svrhu nadzora, planiranja obrta i reagiranja u slučaju poremećaja. Drugo, skupljaju se informacije o položaju vozila javnog prijevoza koje se onda na adekvatan način prezentiraju korisnicima putem vizualnih, audio i on-line sustava informiranja. Korisnici tako imaju uvid da li je promet redovit ili ima kašnjenja na linijama javnog prijevoza koje žele koristiti.

6. INFORMIRANJE KORISNIKA

Kako je naglašeno u prethodnom poglavlju odnosno Nadzor prometa, informiranje korisnika o prijevoznim uslugama vrlo je važno u radu prijevozno-tarifne unije. Zbog velikog broja linija, učestalih polazaka i velikog broja mogućnosti presjedanja koje sustav nudi potrebno je stvoriti sustave informiranja korisnika koji će ih što lakše dovesti do odredišta, te im pružiti sve potrebne informacije o polascima, presjedanjima, eventualnim poteškoćama u prijevozu te o alternativama koje tada mogu iskoristiti.

Informiranje se može podijeliti u tri osnovne skupine: (1) promocija sustava, (2) redovite obavijesti o radu sustava putem medija i (3) obavijesti za korisnike na terenu (na stajalištima/kolodvorima i unutar vozila).

Najznačajniji dokument o načinu dodjele linija prijevoznicima je Uredba (EZ) broj 1370/2007. Pravila navedena u Uredbi moraju se u potpunosti primijeniti prilikom dodjeljivanja linija prijevoznicima.

U Njemačkoj je praksa da se ugovori potpisuju na 5, 10 nerijetko i 15 godina. Dugoročni ugovori omogućuju prijevoznicima da dugoročno planiraju zapošljavanje ljudi, održavanje postojećih i nabavku novih vozila.

Ugovorom koji sklapaju prijevoznik i Prometna uprava prijevoznik je dužan obaviti ugovorenu uslugu prema ugovorenim specifikacijama, a Prometna uprava je dužna prema ugovoru isplatiti prihode i pružiti adekvatnu potporu uspješnog rada prijevoznika u sustavu.

Bitno je napomenuti da nije propisan minimalni, ali niti maksimalni broj prijevoznika tako da se broj prijevoznika može optimizirati prema stvarnoj situaciji na području integracije.

4.6. Prikupljanje prihoda od prodanih karata i subvencija te njihova razdioba

Vrlo bitan zadatak Prometne uprave je također da organizira sustav prodaje prijevoznih karata u tarifnoj uniji. Prijevozne karte mogu prodavati prijevoznici pojedinačno, a može se i implementirati poseban sustav. Sve prihode koji su ostvareni od karata u prijevozno-tarifnoj uniji prikuplja Prometna uprava.

Sve subvencije od strane državne i lokalne uprave također prikuplja Prometna uprava. Zadatak Prometne uprave jest i da ima kontrolu nad svim troškovima, također da prema ugovorima isplaćuje sredstva za obavljene usluge prijevoznicima.

Kako bi sustav mogao funkcionirati mora postojati potpuna transparentnost kako u prikupljanju tako i razdiobi prihoda. Dakle, svaki prijevoznik mora imati informaciju o svakom drugom prijevozniku koliko je prihoda donio u sustav, a kolika je bila razdioba.

5. NADZOR PROMETA

Prometna uprava ima i zadatak da centralno nadzire i upravlja svim prijevozom na svom području. Za obavljanje tog zadatka Prometna uprava osniva vlastiti kontrolni centar ili sklapa ugovore s drugim prijevoznicima (željeznica, autobusi) ili centrima za kontrolu prometa (npr. nadzor željezničkog prometa na razini neke države ili regije). Moguće su i kombinacije oba načina rada.

Cilj nadzora prometa je obično dvojak. Prvo, nadzorom prometa nadzire se rad prijevoznika, skupljaju se podaci o kretanju vozila, otklanjaju se poteškoće u prometu u slučaju poremećaja, te se prijevoznicima pruža uvid u kretanje njihovih vozila u svrhu nadzora, planiranja obrta i reagiranja u slučaju poremećaja. Drugo, skupljaju se informacije o položaju vozila javnog prijevoza koje se onda na adekvatan način prezentiraju korisnicima putem vizualnih, audio i on-line sustava informiranja. Korisnici tako imaju uvid da li je promet redovit ili ima kašnjenja na linijama javnog prijevoza koje žele koristiti.

6. INFORMIRANJE KORISNIKA

Kako je naglašeno u prethodnom poglavlju odnosno Nadzor prometa, informiranje korisnika o prijevoznim uslugama vrlo je važno u radu prijevozno-tarifne unije. Zbog velikog broja linija, učestalih polazaka i velikog broja mogućnosti presjedanja koje sustav nudi potrebno je stvoriti sustave informiranja korisnika koji će ih što lakše dovesti do odredišta, te im pružiti sve potrebne informacije o polascima, presjedanjima, eventualnim poteškoćama u prijevozu te o alternativama koje tada mogu iskoristiti.

Informiranje se može podijeliti u tri osnovne skupine: (1) promocija sustava, (2) redovite obavijesti o radu sustava putem medija i (3) obavijesti za korisnike na terenu (na stajalištima/kolodvorima i unutar vozila).

Promoviranje sustava javnog prijevoza smatra se vrlo važnim u zemljama gdje su javno-prijevozni sustavi vrlo razvijeni. Naime, u zemljama poput Njemačke, Austrije, Švicarske, Francuske, Švedske na svim razinama vlasti (lokalne i nacionalne) i dalje intenzivno rade na povećanju udjela javnog prijevoza u ukupnom prijevozu putnika.

7. RAZVITAK SUSTAVA

Prometna uprava vodi računa o cjelovitom razvitku sustava. Osim istraživanja prijevozne potražnje i kvalitete usluga Prometna uprava sama i/ili u suradnji sa Sveučilištima, institutima i stručno-znanstvenim udrugama aktivno sudjeluje na razvitku infrastrukture i vozila, dok se posredno uključuje i u projekte koji se isprepliću s raznim drugim društvenim i gospodarskim djelatnostima poput urbanizma, prostornog uređenja, razvika industrije, gospodarskih usluga, turizma, te razvika ostale komunalne i prometne infrastrukture.

Razvitak sustava mora itekako biti prisutan u nacionalnim i lokalnim strategijama. Valja komunicirati s prijevoznicima i obavještavati ih o tome kakve specifikacije moraju ispuniti vozila za naredne natječaje za linije.

8. PREDNOSTI INTEGRIRANOG PRIJEVOZA PUTNIKA

Prednosti integriranog prijevoza putnika mogu se promatrati: (1) s aspekta korisnika, (2) aspekta prijevoznika, (3) aspekta davatelja subvencija i (4) aspekta gospodarstvo.

8.1. Prednosti integriranog prijevoza putnika za stanovništvo

Integrirani prijevoz putnika omogućuje mnogo veći broj polazaka sa svih stajališta, te veću mobilnost stanovništva nego individualni prijevoz. Eliminiraju se prometne gužve i problemi s parkiranjem, a promet postaje višestruko sigurniji. U pravilu ovi sustavi zaustavljaju iseljavanje iz ruralnih sredina i navalu stanovništva u gradove. Sve to omogućava puno kvalitetnije urbano i prostorno planiranje uz ravnomjerni razvitak gradskih i izvangradskih područja. Sustav omogućava i brojne pogodnosti pri kupovini prijevoznih karata.

8.2. Prednosti integriranog prijevoza putnika za prijevoznike

Integrirani prijevoz putnika svojom kvalitetom dokazano privlači puno veći broj putnika, time donosi i bolje prihode. Integrirani prijevoz putnika omogućava i bolji obrt vozila, te time snižava operativne troškove. Budući da se ugovori o prijevozu u integrirani prijevoz putnika dogovaraju na duži rok, obično 5, 10 ili čak i više godina, to omogućuje kvalitetno planiranje voznog parka i amortizacije vozila.

8.3. Prednosti integriranog prijevoza putnika za tijela lokalne i državne uprave

Sustav integriranog prijevoza putnika za iznos optimalnih subvencija pruža kvalitetnu uslugu prijevoza. Podizanjem kvalitete života u gradskim i prigradskim sredinama utječe na mobilnost radnog stanovništva, a time i na povećanje gospodarskih aktivnosti koje za rezultat između ostalog imaju i povećanje gradskih i prigradskih proračunskih sredstava.

8.4. Prednosti integriranog prijevoza putnika za gospodarstvo

Sustav integriranog prijevoza putnika sa aspekta gospodarstva doprinosi mobilnosti radne snage što dovodi do povećanja prihoda gospodarskih djelatnosti te direktno povećanje bruto nacionalnog dohotka.

9. ZAKLJUČNA RAZMATRANJA O INTEGRIRANOM PRIJEVOZU PUTNIKA

Integrirani prijevoz putnika temelji se na udruživanju prijevoznih modova i prijevoznika u jedan sustav. U tom sustavu naglašavaju se prednosti svih modova prijevoza (vlak, tramvaj, autobus, brod, ...) te sinergijski efekt povezivanja različitih prijevoznika, a gotovo se uklanjaju nedostaci svakog od njih. Ulaskom u sustav integriranog prijevoza putnika prijevoznik ne gubi svoj

integritet kao tvrtka. I dalje je samostalni poslovni subjekt koji radi u sustavu temeljenom na suradnji i nadopunjavanju.

Nakon uspostave prvog integriranog sustava u Hamburgu ubrzo su u praksi uočene sve njegove prednosti. Integrirani sustavi nastaju tada vrlo brzo i u ostalim prigradskim regijama velikih gradova. Ipak, valjalo je proći dosta vremena da takvi sustavi postanu zakonska obaveza (Njemačka 1996, Austrija 2000, ...) i temelj funkcioniranja uspješnog javnog prijevoza u razvijenim zemljama. Opravdanost i kvalitetu sustava potvrđuje sve veći broj korisnika integriranog prijevoza putnika u Njemačkoj, Austriji, Švicarskoj, Danskoj, Švedskoj, Velikoj Britaniji, Španjolskoj, Češkoj i Poljskoj.

U Republici Hrvatskoj postojali su hibridni sustavi integriranog prijevoza putnika na području Grada Osijeka, Splita i Zagreba. Takovi hibridni sustavi kako su brzo nastajali još brže su i nestajali. Nadležno ministarstvo za promet je davne 2016. godine okupilo tim stručnjaka koji su uspješno pripremili prijedlog Zakona o integriranom prijevozu putnika. Skorim donošenjem temeljnog Zakona mogu bi početi razvoj integriranog prijevoza putnika i na području Republike Hrvatske.

10. LITERATURA

- [1.] Abramović B. Integrirani prijevoz putnika. Sveučilište u Zagrebu Fakultet prometnih znanosti. 2016.
- [2.] Abramović B. Modeliranje potražnje u funkciji prijevoza željeznicom. Fakultet prometnih znanosti, Zagreb. 2010
- [3.] Schneider C. Unternehmenssteuerung und Controlling im ÖPNV. DVV Media Group 2013
- [4.] Stadtbahnsysteme - Light Rail Systems. DVV Media Group 2014
- [5.] Verkehrsverbünde - Transport Alliances. VDV - Verband deutscher Verkehrsunternehmen 2009
- [6.] Uredba (EZ) broj 1370/2007 o uslugama javnog željezničkog i cestovnog prijevoza putnika

Speed limit reduction: experiences from The Netherlands

Patrick Broeren, MSc
Senior Consultant Traffic Safety and Road Design
Arcadis Netherlands BV
Amsterdamseweg 13
6814 CM Arnhem
The Netherlands

Abstract

For environmental and road safety reasons, Dutch cities and road authorities developed a policy to reduce speed limits on large shares of their road networks. The city of Amsterdam and Eindhoven are examples of cities that changed the speed limit on many road segments from 50 to 30 km/h over the last years. Also, the province of Utrecht changed the layout of some rural roads and decreased the speed limit from 80 to 60 km/h.

This contribution describes the process of implementing lower speed limits. Also, the changes to the road design to achieve lower driving speeds are discussed, showing examples from urban and rural environments. With implementation over the last year, the first results of the speed limit reduction are available: evaluation results from the network wide implementation of 30 km/h in the city of Amsterdam and speed limit reduction from 80 to 60 km/h in the province of Utrecht, are presented.

1. Introduction

Background

The Netherlands is a densely populated country with a dense road network. These characteristics result in heavy traffic and transport flows and many conflicts between road users, particularly between motorists and cyclists.

The Netherlands has a relatively high level of road safety, but it is failing in further reducing the number of road casualties. In fact, the number of road casualties is stagnating, and the ambitions are in danger of becoming unattainable (Figure 1).

In addition to road safety issues, the Netherlands also faces problems in terms of quality of life: emissions from motorised traffic are too high, air quality is poor in some areas, and noise standards are being exceeded.

To improve both road safety and quality of life, various cities and provincial road authorities have introduced reductions in the maximum speed limit. Several other road authorities are considering reductions, and work is underway to develop a national standard for the implementation of lower speed limits.




Figure 1: traffic fatalities in The Netherlands

Safe system approach

Setting lower speed limits is in line with the principles of the "Safe System Approach". Lower speeds contribute to improved road safety in the following ways:

1. A lower speed reduces the likelihood of an accident. Road users have more time to avoid a conflict. A good example is the (exponentially) shorter braking distance at lower speeds.
2. The severity of an accident is greatly reduced at lower speeds. For example, the chance of survival in a collision with a vulnerable road user is almost five times greater at a speed of 30 km/h than at 50 km/h [1].

When implementing the lower speed limit, the question is to what extent driving speeds will actually decrease; only then will there be a safety improvement. Can the lower driving speeds be achieved by simply adjusting the signage, or is it also necessary to modify the road design and layout? Human factors principles play an important role in answering these questions.



Figure 2: Safe System Approach and impact speed on survival rate

Network categories and speeds

The Dutch Sustainable Safety philosophy [2], an elaboration of the Safe System Approach, distinguishes between three road categories (both within and outside built-up areas):

- Through roads (flow function on road sections and across intersections)
- Distributor roads (flow function on road sections and exchange function at intersections)
- Access roads (exchange function on road sections and at intersections)

These road categories have uniform speed limits, so that road users are clear about what behaviour is expected of them. The reduction in the speed limit applies to distributor roads: this is the type of road where the risk to road users is highest. For distributor roads outside built-up areas, the speed limit will be reduced from 80 to 60 km/h, and for roads within built-up areas from 50 to 30 km/h. It is not the intention to introduce a new road category, so as not to affect the uniformity of the road network.




Figure 3: road categories according to Sustainable Safety filosofie




Figure 4: road categories and speed limits (reduced speed limits in green)

Decision trees

When considering lowering the speed limit, various aspects must be taken into account. The assessment starts with the objective: what are the bottlenecks on a road section in the current situation and what problem needs to be solved? Is there no safe crossing, is there noise pollution affecting adjacent homes, are there many accidents on the roadside?

A speed reduction must also be considered at the network level; will a reduction in the speed limit lead to an increase in traffic on road sections that are not suitable for this? Furthermore, the effects on public transport (travel times, passenger comfort in the event of a redesign) and the driving times of emergency and rescue services must be considered.

Road authorities that are considering or have already implemented a speed reduction have developed decision trees to determine which roads in the network are

suitable for the introduction of a lower speed limit. In order to achieve uniformity in the application of speed reductions, the national centre for guidelines and regulations (CROW) has also developed a decision tree for the GOW60 [3]. Provincial road authorities, the scientific institute for road safety research (SWOV), emergency and rescue services, the cyclists' union, and the agricultural interest group, among others, have collaborated on a widely supported framework.




Figure 5: National decision frameworks for GOW60 road type (left) and GOW30 (right)

2. Speed limit reduction in urban areas

Two philosophies

About five years ago, the first discussions began in the Netherlands about lowering the speed limit inside and outside built-up areas. The city of Eindhoven was one of the first cities to start introducing a speed limit of 30 km/h on large parts of its road network. Other large cities followed, such as Amsterdam, Utrecht, and recently Rotterdam.

When it comes to lowering speed limits, we see two clearly different philosophies for implementation:

1. A philosophy in which only the maximum speed is reduced, without making any changes to the road design and layout;
2. A philosophy in which the road design and layout are modified to encourage or compel road users to adjust their driving speed.

Amsterdam is one of the municipalities that applies the first philosophy, while the municipality of Eindhoven follows the second philosophy. The approaches in both cities are briefly explained below.

Eindhoven

Eindhoven is the fifth largest city in the Netherlands, with a population of approximately 250,000. The Eindhoven metropolitan area is growing rapidly due to the presence of a high-tech campus (Philips, NXP, Eindhoven University of Technology, ASML, etc.), which is leading to increased traffic. Eindhoven's road network is characterized by an urban ring road with radial roads and a relatively high volume of car traffic.




Figure 6: urban ring road (left) and urban road network Eindhoven (right)

Early 2024, Eindhoven City Council adopted the Mobility Master Plan 2050, which sets out Eindhoven's dreams for the future. One of those dreams is 'safety': *in Eindhoven, we want everyone to be safe and feel safe in traffic. A city where everyone can be confident that no harm will come to them. A city without traffic casualties. Because every victim is one too many. To make this dream come true, the starting point for roads in Eindhoven within the built-up area is '30 km/h, unless...'*




Figure 7: speed limits Eindhoven road network (left) and to be reconstructed roads (right)

In 2023, Arcadis studied the preferred speeds on the Eindhoven road network [4]. The map on the left side of Figure 7 shows the maximum speeds; all roads shown in white have a maximum speed of 30 km/h. The map shows that this covers a very large part of the network, but that the inner urban ring road has a maximum speed of 50 km/h and that the speed limit of 50 or 70 km/h is maintained on the radial roads.

Eindhoven has decided to adjust the road layout in line with the change in speed limit: the road layout must be credible and appropriate for a speed limit of 30 km/h.

Initially, nine streets have been selected (Figure 7, right) where the speed limit will be reduced from 50 to 30 km/h. These are streets where cars and cyclists currently share the same lane.

For the redesign of GOW30 roads, it is important to have a clear set of principles: the principles must contribute to a recognizable and unambiguous road image. Arcadis has developed principles and basic cross-sections for the GOW30 on behalf of the municipality of Eindhoven. An approach with building blocks for reducing the speed from 50 to 30 km/h has also been developed (see Table 1).


Table 1: Building blocks for implementation of speed limit reduction

A	WHERE? – New road categorization map Translation of ambition speed limits to road categorization map
B	HOW? – Design principles GOW30 Which design characteristics should be applied on GOW30 roads?
C	WHEN? – Implementation strategy The implementation of speed limit changes and redesign of streets
D	WHY? – Information and education Information and education about changes: communication is crucial
E	Enforcement Agreement with police about the enforcement of the speed limits

As part of building block B, standard cross-sections for the GOW30 have been developed. A distinction has been made between different usage characteristics for each cross-section. Table 2 contains eight cross-sections and Figure 8 shows a number of examples.

Table 2: set of standard cross sections GOW30

	Cross sections with cycle lanes	Cross sections with separated cycle paths
Suitable for high % trucks	Profile A1	Profile B1
Suitable for high frequency bus	Profile A2	Profile B2
Standard cross section with narrow carriageway	Profile A3	Profile B3
Cross section with physical separation driving directions	Profile A-m	Profile B-m



The most important principle for actually reducing the speed of road users is to narrow the roadway: this is done by physically narrowing the lanes and roadway, but also by visual narrowing (by applying strips between the lanes). Other materials are also used: instead of asphalt, the roadway is paved with clinkers. At intersections, entrance structures or plateaus are used to reduce the speeds of crossing traffic flows.


The speed changes and adjustments to the road layout have only recently been implemented: no evaluation results are available at the time of writing this paper.



Figure 8: redesign of Leenderweg (profile B-m), before (left) and after (right)

Amsterdam

Amsterdam is the capital of the Netherlands and has over 935,000 inhabitants. Unlike Eindhoven, Amsterdam has a historic city centre with canals and many narrow streets. Amsterdam has an extensive network of trams, metro, buses, and bike paths. Parts of the city centre are car-free. The number of cyclists and pedestrians, especially in and around the city centre, is very high.



In December 2023, the 30 km/h speed limit was introduced in the city. On a large number of access roads, the speed limit was reduced from 50 to 30 km/h. Amsterdam chose to only change the signage and road markings and not to redesign the streets. The measure is intended to contribute to a safe, liveable and accessible city.

On a large part of the road network, the speed limit will be reduced from 50 to 30 km/h; only on roads with an important traffic function and roads in the port area will the speed remain at 50 km/h (see Figure 9).




Figure 9: Amsterdam road network, 30 km/h (blue) and 50 km/h (red)

The effects of the measure were monitored before and after its introduction [5]. Six topics were examined: road safety, quality of life, speeds, driving times, traffic volume, and support for the measure. This article focuses solely on road safety and driving speeds.

The number of accidents on GOW30 roads fell by 11% in 2024 compared to 2023 (see Figure 10). The decline is even greater when looking only at accidents between motor vehicles and vulnerable road users (cyclists and pedestrians). The number of road casualties fell by approximately 8% over the same period.




Figure 10: number of collisions on GOW30 (left) and number of injuries on GOW30 (right)




Figure 11: average driving speeds (left) and distribution of driving speeds on GOW30 roads (right)



Figure 12: difference in driving speeds in relation to road characteristics (left) and effect of speed enforcement (right)

Explanation:

- The average speed of car traffic on GOW30 roads in 2024 will be approximately 5% lower than in 2023 (including speeds at intersections);
- More than 60% of motorists adhere (almost) to the maximum speed limit of 30 km/h;
- Speeds are lowest during the evening rush hour and highest at night;
- Driving speeds have also fallen on 50 km/h roads (by 3%);
- The differences in speed between cars have decreased (the spread has decreased by 6%);

- On typical GOW30 roads (with many design features that are appropriate for a speed limit of 30 km/h), the speed limit is better respected;
- In a limited number of locations, mobile speed cameras were installed after the summer of 2024. Speeds at these locations decreased by more than 20%. This applies to both directions of travel (including the direction not covered by the speed cameras).

3. Speed limit reduction in rural areas

Introduction

Just as in urban areas, speed limits are also being reduced in rural areas: this involves a speed reduction from 80 to 60 km/h on access roads. This category of road often combines a traffic flow and access function, resulting in an above-average number of conflicts and accidents. Due to the presence of trees close to the roadway, it is often not possible to create a sufficiently wide obstacle-free zone. The result is a high proportion of casualties as a result of single-vehicle accidents.

The province of Utrecht is located in the centre of the Netherlands. Utrecht is the oldest and smallest province in the Netherlands and is also one of the most densely populated. Outside the urban areas, there are still municipalities with more rural characteristics.

Under the heading 'Network perspective provincial roads 2040', the province of Utrecht is working to improve the balance between quality of life, safety, and accessibility. The province's goal is to reduce the speed limit from 80 to 60 km/h on 20% of the road network by 2040. In anticipation of this, the speed limit has been reduced on four pilot routes, the road layout has been modified, and the effects have been evaluated.



Figure 13: plan speed limits in the province of Utrecht (green is 60 km/h)

In a multidisciplinary before-after study, the short-term effects (1 month after the implementation) and long effects (1 year and 2 years after the implementation) are evaluated [6]. The study uses both measured quantitative data and qualitative data. The effects are evaluated for five major themes: speed, accessibility, traffic safety, quality of life and perception. Results of the four road sections are compared to assess differences and similarities.

Road design

In addition to reducing the speed limit from 80 to 60 km/h, the province of Utrecht has made changes to the road layout; the cross-section has remained the same width, but a purple marking has been applied between the two directions of traffic. Furthermore, speed bumps and plateaus have been installed on some road sections and intersections.



Figure 14: cross section on the N225 before speed limit reduction (left) and after (right)

Evaluation

Driving behaviour was studied for four routes using floating car data and loop data. Figure 15 shows the 85th percentile value of driving speeds on two pilot routes (N415 Baarn–Hilversum and N225 Rhenen–Wageningen).




Figure 15: 85-percentile speeds on N415 and N225

During the preliminary measurement, speeds on the N415 and N225 were slightly above 80 km/h, both during the day and at night. In the post-measurement period (1, 2, and 3 measurements), it can be seen that driving speeds are falling, but that they are not approaching 60 km/h: the v85 is approximately between 70 and 75 km/h.

Research was also conducted into how driving speeds vary along the routes. Figure 16 shows that the N225 actually consists of three sections:

- the section on the left-hand side of the graph connects to the built-up area of Rhenen, where speeds are relatively low
- The middle section of the route has a few tight bends: here, the geometry determines the speed and speeds have not changed
- The section on the Wageningen side is straight and has an open road layout: here, speeds have fallen but are still the highest.

- A comparison between the pre- and post-measurements shows that the distribution of driving speeds has changed: the spread in speeds has increased, with a larger proportion of road users exceeding the speed limit.




Figure 16: driving speeds on the N225 (left) and speed distributions on the N225 (right)

Other important findings in relation to behaviour and road safety:

- No changes in number of crashes (evaluation period too short for statistically sound analysis)
- Increase in overtaking reported
- Drivers do not understand the reason for lower speed limits

4. Closing remarks

Lowering the speed limit contributes to greater road safety, improved quality of life, and a pleasant living environment. Applications and evaluations in the Netherlands have shown that implementation and enforcement are crucial to achieving the desired effect. To actually reduce driving speeds, changes to road design are necessary, with the credibility of the speed limit being an important consideration. Many European cities and road authorities are now lowering speed limits in order to pursue safety ambitions and improve quality of life, and the results are predominantly positive. Speed reduction also offers opportunities for the Balkans!

References

- [1] *Speed and crash risk*, International Traffic Safety Data and Analysis Group (irtad), OECD, 2018
- [2] *Sustainable Safety 3rd edition – The advanced vision for 2018-2030 (in Dutch)*, SWOV, The Hague, The Netherlands, 2018
- [3] *Decision framework distributor road 80 and 60 km/h (in Dutch)*, CROW, Ede, The Netherlands, 2025
- [4] *Design principles GOW30 (in Dutch)*, Marco Mulder and Sören Blankers (Arcadis), commissioned by the City of Eindhoven, Arnhem, The Netherlands, 2025
- [5] *30 km/h in the city, evaluation report (in Dutch)*, city of Amsterdam, The Netherlands, 2025
- [6] *Provisional findings evaluation GOW60*, Ilse Schelling and Patrick Broeren (Arcadis), commissioned by province of Utrecht, The Netherlands, 2025

Evaluacija prometnog rješenja (Evaluation Of A Traffic Engineering Solution)

mr.sc. Zdenko Lanović,¹ Josip Dankić, mag.ing.prom.¹, Kristijan Ferenčak, mag.ing.prom.¹

¹ Elipsa – S.Z d.o.o., Zagreb, elipsa@elipsa.hr

Sažetak. Bez obzira na dominantan atribut prometnog procesa (populacijski, prostorni, vremenski), prometno rješenje počiva na dvije ili više komponenti. Dok se postojeće rješenje zasniva često na dvije, novo prometno rješenje počiva na sve tri: fizikalnoj, funkcionalnoj i intencionalnoj. Izbor i utjecaj komponenti određuju definicije i domene ključnih pokazatelja uspješnosti (KPI – Key Performance Indicator). Drugi važan čimbenik evaluacije je vremenski okvir promatranja. Kriva procjena utjecaja intencionalne komponente najčešće i najviše utječe na reprezentativnost uzorka za vrednovanje rješenja. Treći čimbenik je ustroj objektivnog okvira vrednovanja; izbor znanstvene metode (jedne ili više) kojom će se izmjeriti (procijeniti) i usporediti ključni pokazatelji uspješnosti. Rad pokazuje najčešće zablude prometnih inženjera i drugih struka vezanih uz prometni sustav te jednostavne inženjerske alate za prevladavanje poteškoća prilikom promišljanja, razvoja i implementacije prometnog rješenja.

Abstract. Regardless of the dominant attribute of a traffic process (population, spatial, temporal), a traffic engineering solution is based on two or more components. Existing solution usually relies on two components. New solution is typically based on all three: physical, functional, and intentional. The choice and influence of these components are set by the definitions and domains of key performance indicators (KPI). Another important evaluation factor is the duration of the observation period. An incorrect assessment of the influence of the intentional component most often and most affects the chosen sampled population for evaluating the solution. The third factor is the organization of an objective evaluation framework. It involves choosing one or more scientific methods for measuring or estimating key performance indicators and comparing them. The paper presents the most common misconceptions of traffic engineers and related professionals. It also introduces simple engineering tools to overcome difficulties in considering, developing, and implementing a traffic engineering solution.

Ključne riječi. prometni proces, prometno rješenje, razdoblje promatranja, evaluacija KPI

Key words. traffic process, traffic solution, observation period, KPI evaluation

1. UVOD

U hrvatskoj znanstvenostručnoj zajednici obično se problemu prometu pristupa s motrišta teorije sustava [1]. Posljednjih 30 godina se većina prometnih aktivnosti veže uz ekstenzivnu primjenu informacijsko-komunikacijskih tehnologija. Promet je onaj dio ljudskog bivstvovanja u kojem su sve komponente složenog sustava:

- fizikalna; materijalno, zbilja – infrastruktura,
- funkcionalna; ustroj i pravila – ispunjenje znanstvenostručnih postulata,
- intencionalna; očekivanja i odluke – stvarno ponašanje u prometu,

uvijek prisutne, bez obzira na strukturu, razinu i opseg problema. Inženjer(ka) prometa ima važnu funkciju u sve tri komponente, a evaluacija prometnog rješenja predstavlja kritičnu točku provjere koja dokazuje osobnu inženjersku izvrsnost, jamči javnu dobrobit, a dionicima prometne politike pruža nužan legitimitet. To je jedini objektivni mehanizam koji usklađuje stručni i javni interes te društvenu odgovornost u jedinstvenu ocjenu uspješnosti rješenja.

2. POIMANJE PROMETA

U Republici Hrvatskoj je promet priznat kao samostalno znanstveno polje u području tehničkih znanosti – 2.12. Tehnologija prometa i transport [2] pa je logično i opravdano koristiti znanstvenostručne alate, postupke i metode tehničkih znanosti.

2.1. Sustavski pristup

Promet se može izučavati kroz teoriju sustava [1] prema pristupu *G.J. Klira* i njegovom *General System Problem Solver*. Pri samom formalnom iskazu koristi se *Kripkeova* reducirana struktura [3] koja sadrži konačan skup stanja (S), relacije prijelaza (R) i kvantitativne pokazatelje (L):

$$K = (S, R, L)$$

Inženjerskom razmišljanju nešto je bliža *Wymoreova* struktura [4] koja sadrži ulazne veličine (X), izlazne veličine (Y), dozvoljeni prostor stanja (Z) i relacije sustava (F):

$$W = (X, Z, Y, \Phi)$$

Formalni okviri poput *Kripkeovih* struktura omogućuju precizno definiranje dinamičkih svojstava prometa, dok *Wymoreov* pristup osigurava konzistentnu razgradnju sustava na funkcionalne i strukturne komponente. Takvi modeli formaliziraju i kvantificiraju ključne elemente prometnog sustava, čime se stvara temelj za njegovu analizu i evaluaciju.

Sustavski pristupi koji prometni fenomen reduciraju na fizikalne i funkcionalne komponente implicitno pretpostavljaju da se ponašanje sudionika opisuje kroz zadana pravila i ograničenja, pri čemu se zanemaruje jedna ključna varijabla – način na koji dionici donose odluke.

2.2. Agencijski (intencionalni) pristup

Kod modeliranja složenih tehničko-društvenih sustava potrebno je koristiti više razina apstrakcije od uobičajenog sustavskog pristupa. Jedna prihvatljiva, a ujedno i sveobuhvatna nomenklatura, je pristup *Daniela Dennetta* [5] koja ne predstavlja alternativnu teoriju, već je ekstenzija sustavskog pristupa:

- fizikalna razina zadržava sve zahtjeve tehničke korektnosti i mjerljivost,
- funkcionalna razina omogućuje normiranje pravila, tokova i upravljačkih strategija,

- intencionalna razina uvodi minimalan, ali nužan skup pretpostavki o racionalnosti, ciljevima i međudjelovanju sudionika.

Inženjerski alati omogućuju mjerenje promjena na fizikalnoj i funkcionalnoj razini, ali ne mogu sami po sebi odgovoriti na pitanje je li rješenje dobro/prihvatljivo/održivo. To pitanje podrazumijeva procjenu učinaka na ponašanje sudionika i ostvarenje ciljeva sustava, što je nužno intencionalna procjena. *Dennettova* nomenklatura omogućuje da se ta činjenica ne prikrije, nego formalno uokviri.

Postoje i druge raščlambe tehničko-društvenih sustava (*Marr, Luhman*, višeagentni sustavi, apstraktna dekompozicija, ...), ali intencionalna nomenklatura je „čista“ i operativna s inženjerskog motrišta.


3. INTENCIONALNA KOMPONENTA U PROMETU

Brojni su primjeri mjerljive prisutnosti intencionalne komponente u prometu, a ovdje će se prikazati dva najčešća s inženjerskog promišljanja prometnog problema.

3.1. Primjena teorije igara

Ova matematička disciplina možda najjasnije formulira i interpretira intencionalnost u prometu jer: (1) eksplicitno modelira dionike (igrače) s ciljevima (interesima), (2) uključuje strateško promišljanje, (3) prirodno implementira intencionalnu komponentu.

Najpoznatiji i najjednostavniji (najrazumljiviji) je problem zatvorenikove dvojbe [6], a ovdje se predstavlja primjer u okruženju u kojem javni prijevoz nama znakovitu ulogu (Slika 1).



Slika 1: Matrica i stablo odlučivanja izbora moda prometa
Izvor: autor

Korisnik A će imati dominantu strategiju izbora automobila (prema matrici isplate – Slika 1) jer:

- se udobnije voziti automobilom od javnog prijevoza,
- ako Korisnik B izabere automobil, Korisnik A nema razloga izabrati javni prijevoz jer smanjuje svoj dobitak; bira neudobniji oblik prijevoza,
- ako Korisnik B izabere javni prijevoz, Korisniku A će biti i ugodnije i brže putovanje automobilom jer će biti manje vozila na cesti.

Analogno će razmišljati Korisnik B pa postoji jedinstvena *Nashova ravnoteža* (ekvilibrij) gdje oba korisnika izabiru automobil. Postoji bolje rješenje korištenjem javnog prijevoza, ali osobne preferencije (intencije) dionika su jasne pa ovaj primjer predstavlja još jedan dokaz zašto u neuređenim prometnim sustavima automobil ima prednost ispred javnog prijevoza, bez obzira na troškove, društvenu (ne)odgovornost, ekološku (ne)osviještenost, itd..

Stavljanje igre u realan kontekst s velikim brojem igrača ne se mijenja rezultat jer svaka osoba u prometno neuređenom sustavu ima osobni stav (intenciju):

- „... vjerujem da bi smanjenje učešća automobila povećalo kvalitetu života,
- to se može dogoditi jedino ako veći broj ljudi prestane voziti,
- ako samo ja i/ili manji broj prestane voziti neće biti većeg pozitivnog učinka,
- ako većina prestane voziti sve će biti bolje, ali će i ceste biti praznije pa ću ugodnije, i sigurnije putovati automobilom, a moj doprinos onečišćenju će biti zanemariv,
- stoga, ne mogu „spasiti svijet“ prestankom korištenja automobila.“

Sustavski pristup definira loše stanje prometa kao stabilno stanje u kojem relacije prijelaza/sustava ne ukazuju zašto je stanje loše i stabilno. Teorijom igara, u ovom slučaju zatvorenikovom dvojnom, ukazuje se da loše stanje prometa nije greška sustava nego očekivani ishod racionalnih ponašanja dionika (korisnika) sustava. Jasno su razdvojene intencionalna (odluke korisnika) od sustavske (način upravljanja) komponente.

3.2. Prometni paradoksi

Prometni paradoks se definira kao situacija u kojoj provedba nekog rješenja za poboljšanjem prometa rezultira pogoršanjem stanja. Medijski najpoznatiji (i stručno najrasprostranjeniji) je *Braessov* paradoks [7] [8]: u mreži određenih karakteristika dodavanje novog prometnog koridora nastupaju lošiji uvjeti. Svi korisnici ponašaju se racionalno, a ukupni ishod je lošiji. Bez sagledavanja intencionalne komponente *Braessov* paradoks se čini nelogičnim. Najpoznatiji primjer ovog paradoksa u praksi je južnokorejski Seul [9].

Postoje drugi broji prometni paradoksi [10], a najčešći je *Downs–Thomsonov* koji pokazuje kako poboljšanje cestovne infrastrukture pogoršava i javni prijevoz uz istovremeno povećanje vremena putovanja za sve sudionike. Ljudi intencionalno maksimiziraju osobnu korist pri čemu sustav ostaje i dalje uravnotežen, ali izvan očekivanog tehničkog (inženjerskog) optimuma. U [10] je opisan praktičan primjer u Zagrebu.

Egzistencija prometnih paradoksa jasno pokazuje da su sustavski pristupi nedostadni. Promet nije moguće adekvatno modelirati, a time niti adekvatno evaluirati, bez eksplicitnog uvođenja intencionalne razine analize.

Iako formalno ne spada u prometne paradokse, svakako treba spomenuti tezu *Lewisa Mumforda* (1895. – 1990.) koji je je 1955. godine usporedio povećanje cestovnih površina za sprječavanje zagušenja s liječenjem pretilosti proširenjem hlača i olabavljenjem remena [11].

Ideja o jednostranom ukidanju prometnih površina za motorni promet, nazvana *traffic evaporation* (isparavanje prometa), polučila je suprotan paradoksalan rezultat; umjesto neodrživog stanja dolazi do stvarnog smanjenja korištenja automobila. Jedno izvješće Europske komisije [12] pokazuje uspješne primjene od manjih naselja do jednog intermodalnog čvora u Londonu (velika Britanija).

4. KOMPONENTE PROMETNOG RJEŠENJA

Prometno rješenje može se promišljati, projektirati, implementirati kroz različite pristupe, ali tri komponente su stožerne:

- fizikalna (infrastrukturna); građevinska, arhitektonska, strojarska, informatičko-komunikacijska, elektrotehnička, ...,
- funkcionalna; ispunjavanje znanstvenostručnih postulata kvalitete i sigurnosti za sve korisnike (dionike),
- intencionalna; ispunjavanje očekivanja društva, postulata prostornog planiranja, očekivanja (političke volje) ključnih dionika prometnog sustava.

Fizikalna komponenta podliježe zakonskim i normizacijskim uvjetima, od lokalnih i nacionalnih propisa pa sve do međunarodno preuzetih obveza i preporuka (npr. ISO norme).

Funkcionalna komponenta najčešće predstavlja stručni kompromis, jer treba usuglasiti izbor i primjenu metrike (znanstvene metode) za razvoj, implementaciju i(li) evaluaciju prometnog rješenja.


Učinak i(li) utjecaj intencionalne komponente ne može se mjeriti inženjerskim „alatima“. Demokratska društva poznaju instrumente glasovanja i referenduma. U politici je pobjeda sa 60 % glasova velika pobjeda, a 40 % poraženih većina osjeća ideološki i(li) simbolički gubitak do sljedećih izbora. U prometu 40 % nezadovoljnih znači svakodnevno za velik broj korisnika:

- izlaganje stresu i nezadovoljstvu (opasnosti), poglavito za korisnike mikromobilnosti ako su im uskraćena ili ponuđena neadekvatna infrastrukturna rješenja,
- nezadovoljstvo zbog dužeg puta i(li) dužeg putovanja,
- gubitak povjerenja u promet i općenito u upravljanje javnim prostorom.

Nezadovoljni („poraženi“) novo prometno rješenje doživljavaju kao sustavsku (strukturnu), svakodnevnu nepravdu s dugotrajnim i mjerljivim posljedicama. To nezadovoljstvo se pretače u promjenu načinske razdiobe (*modal split*), što dovodi do ukupno neodrživih prometnih stanja.

4.1.1. Trokut napetosti

U prometu, osim demografske i sociološke, postoji još važnija diferencijacija – po načinu sudjelovanja u prometu. Na (novo) prometno rješenje će bitno drugačije gledati: (su)vozači, (su)putnici u osobnim ili javnim sredstvima prijevoza, biciklisti, pješaci. Ako se napravi substandardno rješenje za mikromobilnost dio roditelja počeo će voziti djecu u školu; neće im dozvoliti samostalno kretanje ili bicikliranje; djeca se od malih nogu uče korištenju automobila.



Slika 2: Trokut napetosti (lijevo) i karakteristične točke u trokutu (desno)
Izvor: autor

Zato se prometno inženjerstvo treba okrenuti prepoznavanju rješenja koja će pomiriti (uskладiti) napetosti između fizikalne, funkcionalne i intencionalne komponente. Kao model koristi se trokut napetosti (*trade-off triangle*, *triangle of tensions*, *iron triangle*, *triple constraints*) – Slika 2. Trokut napetosti je dobar mentalni model (konceptualni alat) jer:

- opisuje i naglašava međusobno suprotstavljene ciljeve (stavove),
- potvrđuje nemogućnost ispunjenja maksimuma zahtjeva svih triju (ili više) komponenti prometnog rješenja,


- jasno opisuje (ilustrira) prometni problem kao višekriterijski.

Trokut napetosti nije mjera u apsolutnom smislu vrednovanja već samo pokazatelj (ilustrator) odnosa između glavnih komponenti sustava i putokaz u kojem smjeru treba ići s prometnim rješenjem. Ograničenja primjene su: (1) uvijek predmnijeva suprotstavljenost (konflikt), (2) ne uključuje vremensku komponentu; projekt može započeti velikim otporom javnosti koji se s vremenom mijenja u većinsku podršku, (3) ne daje jasne odnose između komponenti; nije kvantifikacijski alat.

Gdje smjestiti točku odluke unutar trokuta? Slika 2 (desno) pokazuje dvije točke. Nameće se težište (plava točka T) kao točka koja prezentira prosjek (ravnotežu) prometnog rješenja. Bolji izbor je *Fermat–Torricellijeva* točka (crvena točka F) [13] jer ima svojstvo da je minimalan zbroj udaljenosti do sva tri vrha. To je točka koja pokazuje ukupno najmanju „napetost“ trokuta, odnosno s inženjerskog motrišta predstavlja točku najboljeg rješenja složenog sustava.

Svako prometno rješenje podložno je (ne)opravdanim kritikama. Ako kritika dolazi iz jednog vrha trokuta, upravo trokut napetosti može poslužiti za argumentiranu diskusiju i odgovor. Neke prometne probleme treba promatrati kao višekutnik jer treba posebno uključiti komponente financija, opće ili prometne politike, rokova realizacije – hitnost i dr.. U tim slučajevima rješenje mentalnog višekutnika je Weberova točka [14].

Slika 3 pokazuje primjer korištenja trokuta napetosti u promišljanju i(li) ocjenjivanju, položaja budućeg (ili postojećeg) autobusnog terminala.



Slika 3: Primjer korištenja trokuta napetosti
Izvor: autor

Različiti oblici trokuta, duljine stranica, veličine kutova i položaj točke odluke, jasno ukazuju na (ne)kvalitetu rješenja ili (ne)kvalitetan smjer promišljanja prometnog inženjera. Scenarij A poželjan je ako grad nema javni prijevoz pa dolazak terminala u „srce“ grada donosi i elemente lokalnog javnog prijevoza. Usklađivanjem tarifne politike parkiranja i ograničenja pristupa automobilima (P&R) može se dobiti dobro (održivo) rješenje; sa smanjenom funkcionalnosti i urbanističkim rješenjem, ali uz visoku vjerojatnost prihvatanja lokalne zajednice.

Scenarij B prikladan je za područja s ustrojenim javnim prijevozom, a ovaj scenarij ga još više unaprijeđuje. Dobra tarifna politika i uvođenje usluga kao što su Park&Ride čine od ovog scenarija zametak integriranog prijevoza putnika; evaluaciju prema MaaS ili TaaS.

Scenarij C je investicijski i realizacijski najpovoljniji, a podiže i razinu prometne usluge ako već postoji lokalni javni prijevoz. Može predstavljati interes autobusnih prijevoznika ako se želi konkurirati željeznici. Prometna politika grada može prihvatiti ovakvo rješenje, ili može odgovoriti ograničenjem pristupa za automobile i(li) dobrim lokalnim javnim prijevozom.

5. KOMPONENTE EVALUACIJE

Ocijeniti (evaluirati) prometno rješenje znači procijeniti promjene u populacijskoj, prostornoj i vremenskoj veličini prometnog procesa. Najjednostavnija metodologija po načelu „prije – poslije“ uzima u obzir nekoliko pokazatelja uspješnosti (KPI – Key Performance Indicator), a mjera (ne)uspjeha je kvantitativan odnos između pokazatelja u različitim vremenskim dobima. Dosadašnje izlaganje pokazuje svu površnost i pogrešnost takvog pristupa ako se govori o ozbiljnim prometnim projektima, bez obzira bili oni infrastrukturni, funkcionalni ili organizacijski.

5.1. Vremenska komponenta

Ključan atribut evaluacije je vremenski okvir, a regresija na srednju vrijednost (*Regression Toward the Mean*) je statistička pojava o kojoj inženjeri trebaju posebno voditi računa. Regresija na srednju vrijednost se definira kao pojava izbora uzorka slučajne varijable koji je ekstremniji, dok će sljedeći uzorak biti puno bliže prosječnoj vrijednosti.

Uz regresiju na srednju vrijednost prometni inženjer treba voditi računa i o zakonu velikih brojeva [15] koji dokazuje da prosjek velikog broja podataka (velikog uzorka) teži očekivanoj vrijednosti (teoretskom prosjeku). Zakon velikih brojeva ukazuje na stabilnost prometnog procesa, a regresija na srednju vrijednost na povratak u područje stabilnosti, ukoliko je neko mjerenje ekstremno.


Daniel Kahneman [16] koristi fenomen regresije na srednju vrijednost kao dokaz da ljudska kognitivna pristranost sustavno ignorira matematičku neizbježnost povratka k prosjeku, zbog čega se stohastičnost nekog procesa interpretira kao izravna posljedica nečijeg djelovanja.

Kako pokazuje se fluktuacija broja prevezenih putnika u zagrebačkom tramvaju između 2000. i 2019. godine – Slika 4. Svi podatci nalaze se unutar jedne standardne devijacije (plava ispuna na slici), izuzev 2007. i 2008. godine. To su ekstremi vrijednosti u pojavi regresije na srednju vrijednost. Raščlamba podataka diferencira statističku istinu od statističke anomalije:

- u razdoblju 2000. 2006. prevezeno je prosječno 174,09 milijuna putnika godišnje,
- nagli skok dogodio se 2007. godine s porastom 24,6 %,
- prosjek 2007. i 2008. veći je 21,0 % u odnosu na prethodno razdoblje,
- između 2010. i 2019. broj putnika je veći 4,7 % u odnosu na razdoblje 2000. – 2006.

Zadnja vrijednost od 4,7 % je realna, dok percipirani dobitak zbog naglog skoka u 2007. i 2008. godini iznosi 16,3 %; to je regresija na srednju vrijednost. Kao što je nerealno promatrati nagli pozitivan skok, tako bi bilo nerealno (i neopravdano) promatrati i pad koji se dogodio 2010. – 2013. godine. Za konačnu ocjenu trebao je period od 19 godina. Objektivno, savjesna i stručna osoba je već s podatcima 2009./2010. godine mogla zaključivati o statističkoj pojavi regresije na srednju vrijednost, a ne o trendu porasta ili pada broja putnika.

Stručnjaci iz područja sigurnosti prometa poglavito su svjesni regresije na srednju vrijednost. Postoje različiti relevantni postupci (metodologije) za utvrđivanje, odnosno raščlambe stvarnih učinaka mjere povećanja sigurnosti prometa i regresije na srednju vrijednost (pad broja nesreća zbog povratka na prosjek) [17].



Slika 4: Prevezeni putnici u zagrebačkom tramvaju 2000. – 2019.

Izvor podataka: [Statistički ljetopisi Grada Zagreba](#); obrada autor


Inženjerski izazov u evaluaciji prometnih sustava očituje se u sposobnosti razlučivanja trajnih strukturnih promjena od pukih statističkih anomalija. Ovladavanje zakonom velikih brojeva i regresijom na srednju vrijednost stoga postaje nužan alat za pravovremenu identifikaciju mikrotrendova [18] naspram prolaznih statističkih anomalija.

5.2. Okvir vrednovanja

Evaluacija prometnog rješenja obično je vezana za ugovorni odnos s naručiteljem pa je predmet i cilj evaluacije unaprijed određen. Bez obzira na određena ograničenja, prometno inženjerstvo nudi brojne znanstvenostručne alate. Sposobnosti i iskustvo inženjera određuju izbor metode za evaluaciju prometnog rješenja. Rjeđe je propisana od strane investitora – naručitelja evaluacije. Čak i elementarni koncepti mogu ponuditi potpune odgovore.

Slika 5 pokazuje neke alate koje autori ovog rada svakodnevno koriste u svojim planerskim (strateškim), konceptijskim, idejnim ili provedbenim zadaćama, kao i zadaćama analize ulaznih dokumenata te provedbe evaluacijskih zadaća. Na web stranici ISVU nalaze se kolegiji Fakulteta prometnih znanosti [19] s opisom stručne literature (knjige i pdf dokumenti) dostupne na hrvatskom tržištu. Navode se još tri izvora koja nadopunjuju prometna inženjerska znanja: kombinatorike i teorije grafova [20], teorije igara [21] i teorije mreža [8].

Posebno je važan odnos s drugim znanstvenim područjima iz kojih promet, kao mlada znanost, preuzima određene temeljne postavke i crpi brojne ideje. Posebno je važna sveza s društvenim znanostima iz kojih promet preuzima važne analitičke tehnike. Iz sociologije preuzete su metode anketiranja, a sociološke studije služe kao ulazna veličina intencionalnih stavova glede procjene prometne potražnje. Iz ekonomije preuzimaju se ekonometrijski modeli u svim zadaćama prometnog inženjerstva, poglavito u područjima prometnih statistika.



Slika 5: Odabrani znanstvenostučni alati prometnog inženjerstva
Izvor: autor

5.2.1. Primjena vjerojatnosti i statistike

Primjena jednostavnog alata ilustrirat će se korištenjem Bayesovog teorema. Zadaća je odrediti u cestovnom prometu ponašanje mladih vozača (do navršene 24 godine) s položenim vozačkim ispitom u 2024. godini, prema javno dostupni podacima MUP-a [22].

Tablica 1. Učešće vozača s položenim vozačkim ispitom u prometnim nesrećama (PN) u 2024. godini

	skrivilo PN	nisu krivi	
mladi vozači	4.766	185.296	190.062
ostali vozači	24.025	2.125.993	2.150.018
	28.791	2.311.289	2.340.080

Izvor podataka: [22]; obrada: autor

Tablica pokazuje mogućnost analize u dva smjera:

$$P(\text{mladi vozač} \mid \text{skrivio PN}) = 0,1655$$

$$P(\text{skrivio PN} \mid \text{mladi vozač}) = 0,0218$$

U realnim složenim sustavima rijedak je slučaj nezavisnih događaja pa je i ovdje jasna zavisnost između sigurnosti prometa i starosti vozača. Ostali vozači imaju pokazatelje:

$$P(\text{ostali vozač} \mid \text{skrivio PN}) = 0,0802$$

$$P(\text{skrivio PN} \mid \text{ostali vozač}) = 0,0123$$


Uspoređujući vjerojatnosti nameće se zaključak o opravdanom izdvajanju mladih vozača s položenim vozačkim ispitom kao opasnih glede izazivanja prometnih nesreća u 2024. godini.

Budući su mladi vozači jedna klasa kategorije starosti, objektivno je promatrati sve vozače po kategorijama starosti kako prikazuje službena statistika [22]. Pri tome se može vrednovati i žestina prometnih nesreća prema ponderima posljedica [23]. Kada se vjerojatnosti normiraju (Slika 6 lijevo) i napravi ponder prometnih nesreća (Slika 6 desno) dobivaju se odgovori.

Gledajući sve vozače, vozači svih klasa starosti su podjednako opasni.

Gledajući isključivo krivce, mladi vozači su tri puta opasniji od ostalih klasa starosti.

Gledajući posljedice prometnih nesreća, najopasniji su vozači 25 – 34 godine starosti.



Slika 6: Učešće vozača s položenim vozačkim ispitom u prometnim nesrećama (PN) u 2024. godini
Izvor podataka [22]; obrada: autor

Koji odgovor (zaključak) izabrati ovisi isključivo o zahtjevima naručitelja istraživanja (investitora). Statistika [22] daje podatke prošlih godina i brojne druge podatke o vozačima bez položenog vozačkog ispita, pod utjecajem alkohola i droge, danih i satima, i dr. pa se može dobiti cjelovita povijesna slika odgovornosti vozača pojedinih klasa starosti.


Suvremena statistika zamjenjuje klasične frekvencijske prikaze izračunom vjerojatnosti uzroka na temelju opaženih posljedica, čime preliminarne teze o rizičnosti dobrih skupina postaju utemeljene korigirane (posteriorne) procjene.

5.3. Utjecaj „skrivenih“ varijabli

U inženjerskim poslovima često su prisutne *skrivenne varijable* (*lurking variables*, *confounding factors*) koje utječu na rezultate, ali su izostavljene (zanemarene) u inicijalnoj analizi. Prometni inženjeri moraju biti oprezni kod pojave Simpsonovog paradoksa; statistički fenomen u kojem se određeni trend ili korelacija pojavljuje u više različitih skupina podataka, ali nestaje ili se preokreće kada se te skupine kombiniraju u jednu cjelinu. Matematičko objašnjenje Simpsonovog paradoksa pokazano je u [24].

Praktičan primjer (Slika 7) pokazuje uvjete Simpsonovog paradoksa pri istraživanju korelacije prijevoza putnika željeznicom i autobusima u Zagrebu u razdoblju 2015. – 2023. godina.

Promatranje cijelog razdoblja (Slika 7 lijevo) ukazuje na srednju pozitivnu korelaciju odnosa i kauzalnost: za 1,0 % porast broja putnika željeznicom raste 0,8 % broj putnika u autobusu. Ako se podatci razdvoje na razdoblje prije Covid 19 i potresa 2015. – 2019. (Slika 7 sredina) te nakon 2020. – 2023 (Slika 7 desno) trendovi su negativni s čvrstim i srednjim stupnjevima korelacije.



Slika 7: Simpsonov paradoks željezničkog i autobusnog prijevoza u Zagrebu
Izvor: autor

Model pokazuje utjecaj skrivene varijable, a to su događanja u 2020. godini: razgraničenje zbog Covid-19 te jakih potresa u Zagrebu i razornih na Banovini. Odvojenim promatranjem zaključuje se da podsustavi konkurentni.

6. ZAKLJUČAK

Analiza prometa kao složenog kibernetičkog sustava potvrđuje da se njegova učinkovitost ne može mjeriti izostavljanjem intencionalne komponente – procesa odlučivanja korisnika/dionika. Određivanje relevantnog vremenskog okvira ključno je za razlikovanje stvarnih funkcionalnih poboljšanja od privremenih statističkih fenomena.

Holističkim pristupom i integracijom triju (fizičke, funkcionalne, intencionalne) ili više komponenti sustava izbjegava se zamka donošenja zaključaka na temelju izoliranih i agregiranih podataka koji često prikrivaju stvarno stanje prometnog rješenja. Ovakav pristup omogućuje objektivnu evaluaciju prometnih rješenja, utemeljenu na razumijevanju dubinske strukture procesa, a ne samo na površinskim manifestnim promjenama. Time se postavlja temelj za održivo upravljanje sustavom, otporno na metodološke pogreške pri interpretaciji podataka i(li) rezultata.

Iako izvan primarnog fokusa rada, važno je istaknuti da integracija umjetne inteligencije, kao alata koji i dalje zahtijeva ljudsku imaginaciju i znanje, transformira klasične evaluacije u dinamičke procese prepoznavanja kritičnih obrazaca. Primjer aktualne primjene su digitalne sjene i blizanci prometne infrastrukture koji, nadzirani stručnom intuicijom, omogućuju simulacijsku provjeru rješenja i preciznu evaluaciju učinaka u kontroliranom virtualnom okruženju. Takav tehnološki pristup osigurava objektivnije utvrđivanje uzročno-posljedičnih veza, čime se procesi izdižu iznad deskriptivnih prikaza i postaju temelj za proaktivno, strateško upravljanje prometnim rizicima uz neizostavnu ulogu inženjerskog prosuđivanja.

Prioritetno korištenje domaćih izvora i prijevoda u radu potvrđuje svjesnost domaće znanstvenostručne zajednice o aktualnim analitičkim postupcima i potencijalima digitalne transformacije.

7. REFERENCE

- [1] Bošnjak I.: Badanjak, D.: Osnove prometnog inženjerstva, Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2005.

- [2] Pravilnik o znanstvenim i interdisciplinarnim područjima, poljima i granama te umjetničkom području, poljima i granama, Narodne novine – Službeni list Republike Hrvatske, [3/2024](#)
- [3] Vuković, M.: Matematička logika, Element d.o.o., Zagreb, 2009.
- [4] Wymore, W.: Model-Based Systems Engineering, CRC Press Ltd. (SAD), 1993.
- [5] Dennett, D. C.: Vrste umova: prema razumijevanju svijesti, Algoritam d.o.o., Zagreb, 2006.
- [6] Škrinjar, J.P., Abramović, B.: Primjena teorije igara u prometu i logistici, Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2017.
- [7] Braess, D.: [Über ein Paradoxon aus der Verkehrsplanung](#), preuzeto 29.03.2025.
- [8] Kopal, R., Korkut, D., Krnjašić, S.: Analiza (socijalnih) mreža – praktična primjena, Visoko učilište Algebra, Zagreb, 2016.
- [9] Hong, N.S.: [Cheonggyecheon restoration: A process of paradigm shift in urban environment of Seoul](#), preuzeto 29.03.2025.
- [10] Lanović, Z.: [Prometni paradoksi 1](#), [Prometni paradoksi 2](#), preuzeto 16.02.2022.
- [11] Mumford, L.: [The Roaring Traffic's Boom III](#), preuzeto 16.04.2025.
- [12] European commission: [Reclaiming city streets for people Chaos or quality of life?](#), preuzeto 31.01.2026.
- [13] Crnobrnja, L.: [Fermat–Torricelli točka](#), preuzeto 02.09.2025.
- [14] [Weber problem \(Wikipedia\)](#), preuzeto 02.09.2025.
- [15] Pauše, Ž.: Uvod u matematičku statistiku, Školska knjiga d.o.o., Zagreb, 1993.
- [16] Kahneman, D.: Misliti, brzo i sporo. Mozaik knjiga d.o.o., Zagreb, 2013.
- [17] Highway Safety Manual. 1st ed., American Association of State Highway and Transportation Officials, Washington, DC (USA), 2010.
- [18] Penn, M.J., Zalesne, E.K.: Mikrotrendovi – male sile koje pokreću najveće promjene današnjice, Algoritam d.o.o., Zagreb, 2010.
- [19] [Nastavni program na Fakultetu prometnih znanosti sveučilišta u Zagrebu](#), preuzeto 06.02.2026.
- [20] Veljan, D.: Kombinatorika s teorijom grafova, Školska knjiga d.o.o., Zagreb, 1989.
- [21] Kopal, R., Korkut, D.: Uvod u teoriju igara, Veleučilište Effectus, Zagreb, 2020.
- [22] Ministarstvo unutarnjih poslova Republike Hrvatske: [Bilteni o sigurnosti cestovnog prometa](#), preuzeto 02.09.2025.
- [23] Hrvatske ceste d.o.o.: [Metodologija za identifikaciju opasnih mjesta na cestovnoj mreži](#), preuzeto 15.11.2018.
- [24] Šikić, Z.: Knjiga za klikeraše, Profil knjiga d.o.o., Zagreb, 2017.

PROCESNO UPRAVLJANJE SIGURNOSTU SAOBRAĆAJA U VELIKIM INFRASTRUKTURNIM PROJEKTIMA

Process-based assurance of road safety in large infrastructure projects

Selma Kenjić-Zgodić, mag.inž.građ.

Ministry of Infrastructure and Water Management, The Netherlands,
Rijkswaterstaat
e-mail: selma.kenjic@rws.nl

Sažetak. U velikim infrastrukturnim projektima raspodjela uloga i odgovornosti između projektnih organizacija i upravitelja putne infrastrukture predstavlja trajno pitanje u očuvanju sigurnosti saobraćaja. Projektni timovi trebaju adekvatan stepen operativne autonomije kako bi složene projekte realizirali efikasno, dok upravitelji puteva zadržavaju krajnju odgovornost za sigurnosne performanse putne mreže.

Ovaj rad opisuje način na koji Rijkswaterstaat uređuje **odnos između projektne autonomije i krajnje odgovornosti upravitelja puteva** slijedeći odredbe Pravilnika. „Pravilnik za saobraćajnu sigurnost“. U okviru ovog Pravilnika, sigurnost saobraćaja se ne osigurava putem detaljnog usklađivanja ili prethodnog odobravanja pojedinačnih projektnih odluka, već kroz procesno upravljanje (zasnovano na upravljanju rizicima) koje se dosljedno primjenjuje u svim fazama projekta. Ovaj pristup prevodi obaveze iz Evropske direktive o upravljanju sigurnošću putne infrastrukture (RISM-II) u nacionalni proces projektovanja puteva te kombinuje projektnu autonomiju s eksplicitnim prihvatanjem rizika, nezavisnim provjerama i jasnom obavezom polaganja računa.

Ključne riječi. procesno upravljanje sigurnošću saobraćaja; infrastrukturni projekti; raspodjela uloga i odgovornosti; upravljanje rizicima; Safe System; RISM-II; Rijkswaterstaat

Abstract. In large infrastructure projects, the allocation of roles and responsibilities between project organizations and road infrastructure managers represents a persistent issue in maintaining traffic safety. Project teams require an adequate degree of operational autonomy to deliver complex projects efficiently, while road authorities retain ultimate responsibility for the safety performance of the road network.

This paper describes how Rijkswaterstaat regulates the relationship between project autonomy and the road authority's ultimate responsibility in accordance with the provisions of the "Traffic Safety Regulation." Within this Regulation, traffic safety is not ensured through detailed alignment or prior approval of individual project decisions, but rather through process-based management (grounded in risk management) that is consistently applied throughout all project phases. This approach translates the obligations of the European Directive on Road Infrastructure Safety Management (RISM II) into the national road design process and combines project autonomy with explicit risk acceptance, independent reviews, and a clear accountability framework.

Keywords. process-based traffic safety management; infrastructure projects; allocation of roles and responsibilities; risk management; Safe System; RISM II; Rijkswaterstaat.

1. UVOD

Upravitelji putne infrastrukture suočavaju se sa sve izraženijom obavezom da sigurnost saobraćaja dokaže na transparentan i rizikom vođen način. Ova obaveza dodatno je naglašena izmjenom Evropske direktive o upravljanju sigurnošću putne infrastrukture (EU) 2019/1936. Paralelno s tim, realizacija velikih infrastrukturnih projekata sve se češće organizuje kroz projektni model rada s delegiranim mandatom, pri čemu projektni timovi preuzimaju odgovornost za projektovanje i izvođenje unutar unaprijed definisanih okvira. Ovakav pristup zahtijeva jasan odnos između operativnog odlučivanja unutar projekata i krajnje odgovornosti upravitelja putne infrastrukture za funkcionisanje i sigurnost putne mreže u cjelini. U praksi se postavlja pitanje kako sigurnost saobraćaja osigurati na efikasan način, bez stalnog sadržajnog uplitanja upravitelja puteva u pojedinačne projektne odluke.

Ovaj rad analizira kako je Rijkswaterstaat uredio navedeni odnos kroz „Pravilnik za saobraćajnu sigurnost“ te razmatra taj pristup u kontekstu Safe System koncepta i savremenog upravljanja rizicima.

2. RASPODJELA ULOGA I ODGOVORNOSTI U VELIKIM PROJEKTIMA

U velikim MIRT-projektima Rijkswaterstaata primjenjuje se projektna organizacija rada zasnovana na tzv. IPM-modelu. Projektni tim upravlja realizacijom projekta i raspolaže delegiranim mandatom da, u ime naručioca (upravitelja) donosi odluke prema izvođačima, uključujući odluke koje se odnose na projektovanje, faziranje, izvođenje radova i sigurnost saobraćaja. Ovakav tim ima stručne savjetnike iz relevantnih tehničkih i ostalih oblasti. Ovakav projektni način rada otvara pitanje kako je u toj strukturi organizirano procesno upravljanje sigurnošću saobraćaja. S jedne strane, stručna i sadržajna odgovornost koncentrirana je u projektnom timu, dok se stalno upravljačko uključivanje smatra neefikasnim i potencijalno štetnim za dinamiku projekta. S druge strane, upravitelj putne infrastrukture zadržava punu pravnu i institucionalnu odgovornost za nivo sigurnosti putne mreže.

„Pravilnik za saobraćajnu sigurnost“ propisuje ovaj odnos između mandata za realizaciju i krajnje odgovornosti eksplicitno. Pravilnikom se jasno razdvaja mandat za projektovanje i realizaciju, koji pripada projektnom timu, od odgovornosti za sigurnost saobraćaja, koja ostaje na strani upravitelja puteva. Pravilnik pritom ne zahtijeva prethodno odobranje svakog pojedinačnog projektnog rješenja, već se oslanja na procesno upravljanje sigurnošću saobraćaja.

2.1. Šta je i šta podrazumijeva RWS IPM-model?

IPM-model (Integrirani Projektni Menadžment) je standardni organizacijski model koji Rijkswaterstaat (RWS) koristi za upravljanje velikim infrastrukturnim projektima. Model jasno razdvaja uloge, odgovornosti i ovlasti unutar projektnog tima i osigurava strukturirano donošenje odluka.

IPM-model se sastoji od pet ključnih uloga:

- Projektmanager (PM) – odgovoran za cjelokupno upravljanje projektom, koordinaciju tima i donošenje odluka u okviru dodijeljenog mandata.
- Procesni Manager (PcM) – odgovoran za planiranje, rizike, troškove, rokove i kvalitetu.
- Tehnički Manager (TM) – odgovoran za tehnička rješenja, projektovanje i tehničku kvalitetu.

- Contractmanager (CM) – odgovoran za ugovorni odnos s izvođačem i nabavne procese.
- Stakeholdermanager (SM) – odgovoran za odnose s okolinom projekta, uključujući dionike, nadležna tijela i javnost.
- Assetmanager (AM) – odgovoran za zastupanje interesa upravljača puta tokom projekta, uključujući dugoročne ciljeve funkcionalnosti, održavanja, raspoloživosti i saobraćajne sigurnosti nakon završetka projekta.


U okviru IPM-modela projektni tim raspolaže delegiranim mandatom za donošenje operativnih odluka o projektovanju, faziranju i izvođenju radova. Time se omogućava efikasna realizacija projekta, dok krajnja strateška i pravna odgovornost (npr. za saobraćajnu sigurnost) ostaje na upravljaču puta.

3. PROCESNO UPRAVLJANJE SAOBRAĆAJNOM SIGURNOŠĆU UMJESTO DETALJNOG USKLAĐIVANJA

„Pravilnik za saobraćajnu sigurnost“ zasniva se na pristupu u kojem se sigurnost saobraćaja ne osigurava hijerarhijskim i detaljnim odobravanjem projektnih odluka, već kroz primjenu propisanih procedura i formaliziranog odlučivanja. Ovakav izbor proizlazi iz obima i složenosti velikih infrastrukturnih projekata, u kojima bi stalno sadržajno usklađivanje između projektnog tima i upravitelja puteva dovelo do miješanja uloga i usporavanja procesa. Osnova ovog pristupa jeste da sigurnost saobraćaja mora biti dokaziva i sljedeća. To podrazumijeva da se rizici, odstupanja od važećih standarda i donesene projektne odluke jasno dokumentiraju te povezuju s odgovarajućim stručnim obrazloženjima. U situacijama kada se odstupanja od smjernica ne mogu izbjeći ili kada preostaju rezidualni rizici, Pravilnik zahtijeva eksplicitno obrazlaganje i formalno prihvatanje rizika.


Projektni tim odgovoran je za primjenu propisanih instrumenata sigurnosti saobraćaja, uključujući procjene utjecaja na sigurnost saobraćaja (RSA), revizije sigurnosti saobraćaja (RSA) i eventualne interne analize rizika. Upravitelj putne infrastrukture osigurava sigurnost saobraćaja u početnoj fazi projekta kroz definiranje ciljeva, graničnih uslova i prihvatljivih nivoa rizika.

Uloga upravitelja puteva tokom faze realizacije ne ostvaruje se kroz neposredno upravljanje projektnim rješenjima, već kroz formalne mehanizme provjere i nadzora.



4. METODOLOŠKI OKVIR: PDCA - CIKLUS

Procesno upravljanje sigurnošću saobraćaja u okviru „Pravilnika za saobraćajnu sigurnost“ može se sagledati kroz primjenu Plan–Do–Check–Act (PDCA) ciklusa, koji povezuje realizaciju infrastrukturnih projekata i upravljanje putnom mrežom. PDCA-ciklus služi kao metodološki okvir za jasno razgraničenje odgovornosti i sistematsko upravljanje rizicima.



Slika 2 – Procesno osiguravanje saobraćajne sigurnosti
Izvor: Rijkswaterstaat (2025).

4.1 Plan – Strateško postavljanje okvira

U fazi Plan upravitelj putne infrastrukture definiše ciljeve sigurnosti saobraćaja, granične uslove i prihvatljive nivoe rizika, koji se formalno dokumentiraju i predstavljaju normativni okvir za daljnje projektne aktivnosti.

4.2 Do – Projektovanje i realizacija

U fazi Do projektni tim provodi projektovanje i izvođenje radova u okviru dodijeljenog mandata. Sigurnost saobraćaja integrirana je u sve projektne odluke, uz sistematsku identifikaciju i dokumentiranje rizika.

4.3 Check – Nezavisna provjera

Faza Check obuhvata nezavisne stručne provjere, uključujući revizije sigurnosti saobraćaja (RSA), s ciljem ocjene poštivanja postavljenih okvira i kvaliteta upravljanja rizicima.

4.4 Act – Prihvatanje rizika i institucionalizacija

U fazi Act upravitelj putne infrastrukture donosi formalne odluke o prihvatanju rezidualnih rizika te osigurava njihovu integraciju u sistem upravljanja i održavanja putne mreže.

5. DISKUSIJA

Pristup Rijkswaterstaata pokazuje da se procesno upravljanje sigurnošću saobraćaja može uspješno primijeniti bez stalnog upravljačkog uplitanja u operativne projektne odluke. Jasno uređen **odnos između projektne autonomije i odgovornosti upravitelja puteva** omogućava uspostavljanje robusnog i skalabilnog sistema upravljanja sigurnošću. Iako je model razvijen u holandskom institucionalnom kontekstu, slični odnosi prisutni su i kod drugih evropskih upravitelja putne infrastrukture u procesu implementacije RISM-II direktive, što ovom pristupu daje širu primjenjivost.

6. ZAKLJUČAK

„Pravilnik za saobraćajnu sigurnost“ uspostavlja koherentan i pravno održiv model procesnog upravljanja sigurnošću saobraćaja u velikim infrastrukturnim projektima. Sigurnost saobraćaja ne zavisi od detaljnog odobravanja pojedinačnih projektnih rješenja, već se sistematski osigurava kroz jasno definirane procese, nezavisne provjere i formalno prihvatanje rizika.

Ovakav pristup omogućava projektnim timovima efikasno djelovanje unutar dodijeljenog mandata, dok upravitelj putne infrastrukture zadržava punu odgovornost za sigurnosni nivo putne mreže. Time se osigurava usklađenost s RISM-II direktivom i Safe System pristupom te se nudi referentan model za druge upravitelje putne infrastrukture.

7. REFERENTNA LISTA

[1] Evropski parlament i Vijeće Evropske unije. (2019).

Direktiva (EU) 2019/1936 o izmjeni Direktive 2008/96/EZ o upravljanju sigurnošću putne infrastrukture. *Službeni list Evropske unije*.

[2] Rijkswaterstaat. (2025).

Kader Verkeersveiligheid v4.0 – Dio A: Procesno osiguravanje saobraćajne sigurnosti u projektima izgradnje i održavanja te u upravljanju državnim putevima. Rijkswaterstaat, Nizozemska.

(*Okviri uslovi saobraćajne sigurnosti v4.0 – Dio A*).

[3] OECD / Međunarodni transportni forum. (2008).

Towards Zero: Ambitious road safety targets and the Safe System approach. OECD Publishing.

[4] Svjetska zdravstvena organizacija (WHO). (2017).

Save LIVES: Tehnički paket za unapređenje saobraćajne sigurnosti. Svjetska zdravstvena organizacija.

RELEVANTNE KARAKTERISTIKE TERMOSTABILNE MREŽE ZA ARMIRANJE ASFALTA

Dragan Stojnić¹

¹ Institut za puteve a.d. Beograd - Odeljenje za projektovanje i ispitivanje kolovoznih konstrukcija, Bul. Peka Dapčevića 45, Beograd, Srbija

Rezime: Pri projektovanju rehabilitacija fleksibilnih kolovoznih konstrukcija sa asfaltnim zastorom, jedna od mogućih mera jeste primena termostabilnih mreža za armiranje asfalta. Njihova upotreba omogućava produženje životnog veka asfaltnih slojeva kolovoza, uz značajne ekonomske i ekološke prednosti. Mehanizam delovanja ovih mreža zasniiva se na kombinaciji uklještenja (mehaničke adhezije), (hemijske) adhezije i zatezne čvrstoće. U pogledu izbora odgovarajućih karakteristika armaturnih mreža, kako bi se postigao maksimalan doprinos asfaltnoj konstrukciji, objavljeni su brojni stručni radovi. Ovaj rad bavi se analizom karakteristika koje utiču na interakciju armaturne mreže sa asfaltnim slojem pod dinamičkim opterećenjem, kao i laboratorijskim ispitivanjima - pre svega dilatacije zatezanja (Epsilon 6) i smanjenja zatezne čvrstoće nakon ugradnje. Rezultati sprovedenih ispitivanja ukazuju na ostvarene benefite i omogućavaju pouzdanu ocenu ponašanja spregnutog sistema asfaltni sloj/armaturna mreža u uslovima dinamičkog opterećenja karakterističnog za kolovozne konstrukcije. Razmatrane karakteristike predstavljaju jedan od ključnih parametara u postupku racionalnog dimenzionisanja kolovoznih konstrukcija uz upotrebu armaturne mreže. Sprovedena analiza može poslužiti kao smernica projektantima pri izboru odgovarajućeg tipa mreža za armiranje asfaltnih kolovoznih zastora, kao i investitorima prilikom definisanja projektnih zahteva i uslova u tenderskoj dokumentaciji.

Ključne reči: Termostabilna asfaltna armaturna mreža, spregnuti sistem asfaltni sloj/armaturna mreža, Epsilon 6, gubitak zatezne čvrstoće, racionalno dimenzionisanje, projektni zadatak, tenderska dokumentacija

RELEVANT CHARACTERISTICS OF THERMOSTABLE ASPHALT REINFORCEMENT GRIDS

Dragan Stojnić¹

¹ Highway Institute a.d. Belgrade - Department for Pavement Design and Testing, Bul.Peka Dapčevića 45, Beograd, Srbija

Abstract: In the rehabilitation design of flexible pavement with asphalt wearing course, one of the potential measures involves the application of thermostable grids for asphalt layer reinforcement. Their use extends the service life of asphalt layers while providing significant economic and environmental benefits. The functional mechanism of these grids is based on a combination of interlock (mechanical adhesion), chemical adhesion, and tensile strength. Numerous technical papers have been published regarding the selection of optimal grid characteristics to maximize their contribution to pavement performance. This paper analyzes the key properties that affect the interaction between the reinforcement grid and the asphalt layer under dynamic loading, as well as relevant laboratory tests - primarily tensile strain elongation (Epsilon 6) and tensile strength reduction after installation. The results of the conducted tests demonstrate measurable performance benefits and provide a reliable assessment behavior of the combined asphalt layer/reinforcement grid system under dynamic loads conditions typical for pavement structures. The analyzed characteristics represent one of the key parameters in the process of rational computing of pavement with the use of reinforcing grids. The conducted analysis may serve as a guideline for designers in selecting an appropriate type of grids for asphalt pavement reinforcement, as well as for investors in defining the terms of reference and requirements in tender documentation.

Keywords: Thermostable asphalt reinforcement grids, asphalt layer/reinforcement grid composite system, Epsilon 6, tensile strength reduction, rational computing, terms of reference, tender documentation


1. UVOD

Armiranje podrazumeva ugradnju geosintetičkih proizvoda u bitumenom vezane kolovozne slojeve radi unapređenja njihovih strukturnih karakteristika, pre svega povećanja otpornosti na zamor i smanjenja pojave reflektujućih pukotina, čime se produžava životni vek asfaltnih kolovoznih zastora [1, 2]. Termin "armiranje" usvojen je od strane radnih grupa ISO Tehničkog komiteta za geosintetiku TC 221 [3] za projektovanje uz primenu geosintetika i primenjuje se u smernicama TG3 komiteta [4], čime je obezbeđena međunarodna terminološka usklađenost. Iako upotreba termostabilnih armaturnih mreža kao međusloja u asfaltnom zastoru u projektovanju, rehabilitaciji i izgradnji kolovoza postaje sve češća, one i dalje izazivaju nedoumice u pogledu izbora vrste i tipa ojačanja, mesta i položaja ugradnje, mehanizma dejstva i načina proračuna [4] u odnosu na klasična rešenja. Treba napomenuti da je danas na tržištu dostupan veliki broj različitih tipova armaturnih mreža, koji, iako većina pozitivno utiče na osobine asfaltnih slojeva, značajno variraju po karakteristikama, ponašanju pod opterećenjem i efikasnosti samog kompozitnog sistema. Cilj ovog rada je da projektantima pruži smernice za izbor odgovarajućeg tipa mreža i podršku u projektovanju. Pre razmatranja karakteristika i mehanizma delovanja armaturnih mreža, kao i njihove efikasnosti u kompozitnom sistemu (asfalt + mreža), neophodno je analizirati osnovna svojstva asfaltnog materijala i njegov dinamički odgovor na opterećenje. Posebnu pažnju treba posvetiti mehanizmima nastanka i propagacije pukotina, imajući u vidu da je krajnji cilj ostvarivanje optimalnog sadejstva između asfaltnog sloja i armaturne mreže u preraspodeli opterećenja kojima je izložena kolovozna konstrukcija.

2. DINAMIČKI ODGOVOR ASFALTOG SLOJA NA OPTEREĆENJE

2.1 Pojava pukotina u asfaltnom sloju

Asfaltni kolovozni zastori su izloženi negativnom uticaju opterećenja teških vozila (dinamičko opterećenje) i uticaju temperature (velike temperature oscilacije), koji u sadejstvu uzrokuju pojavu trajnih deformacija. U tim slojevima javljaju se naponi (dilatacije) smicanja i zatezanja koje asfaltni slojevi ne mogu da izdrže, što dovodi do formiranja pukotina koje se s vremenom šire i uzrokuju oštećenja. Pojava pukotina u zastorima asfaltnih kolovoznih konstrukcija predstavlja karakteristično ponašanje asfaltnog sloja tokom eksploatacije. Dva dominantna tipa pukotina usled zamora su termičke (top-down) pukotine, koje nastaju u habajućem sloju i šire se od površine nadole, i reflektovane (bottom-up) pukotine, koje potiču iz nosećeg sloja i propagiraju ka površini kolovoza.




Slika 1: Pukotine od zamora u asfaltnom sloju, reflektovane (bottom-up) i termičke (top-down) pukotine

Sa ciljem jasnijeg sagledavanja mehanizma nastanka i razvoja (bottom-up i top down) pukotina, u laboratoriji je izvršeno ispitivanje asfaltnih gredica (uzoraka) koje su izložene naponima zatezanja. Utvrđeno je da reflektovane (bottom-up) pukotine nastaju pri znatno manjim naponima zatezanja nego što je to slučaj kod termičkih top-down pukotina, jer se razvijaju iz već postojećih diskontinuiteta u nosećem sloju, gde koncentracija napona na vrhu pukotine omogućava njeno brzo širenje pri relativno niskim opterećenjima. Zbog toga su reflektovane (bottom-up) pukotine merodavne pri analizi efektivnosti armiranja primenom termostabilnih mreža.

2.2 Horizontalna dilatacija zatezanja asfaltnog sloja


Pre bilo kakve dalje analize, neophodno je najpre precizno definisati pojam dilatacije. Dilatacija (eng. strain) u mehanici materijala predstavlja relativnu meru promene dimenzija ili oblika tela usled dejstva napona (sile). Definiše se kao odnos promene dužine i početne dužine posmatranog elementa. Reč je o bezdimenzionalnoj veličini (najčešće se izražava u procentima (%) ili u mikrojedinicama (microstrain)), koja opisuje (stepen) deformacije materijala, a ne intenzitet sile koja je tu deformaciju izazvala. Ona je ključna za razumevanje kako se materijal ponaša pod opterećenjem, posebno u vezi sa reološko-dinamičkom analizom. U analizi ponašanja asfaltnog sloja, horizontalna dilatacija zatezanja u donjem vlaknu predstavlja jedan od osnovnih projektnih kriterijuma za procenu nastanka pukotina usled zamora. Pojedini autori smatraju da je glavna dilatacija zasnovana na svih šest komponenti normalnih i smičućih napona, dok drugi zastupaju stav da glavna horizontalna dilatacija zavisi isključivo od horizontalnih i smičućih napona. Ukupna glavna dilatacija je neznatno veća od glavne horizontalne dilatacije zatezanja, te je stoga upotreba ukupne glavne dilatacije na strani sigurnosti. Dilatacija zatezanja (ϵ) je odnos izduženja (ΔL) i prvobitne dužine (L) i kao štp je već rečeno bezdimenziona je veličina ($\epsilon = \Delta L/L$, μstrain ili $\mu\text{m/m}$). Dilatacija od 0.01% ekvivalentna je 100 microstrain ($\mu\epsilon$).



Slika 2: Šematski prikaz dilatacije zatezanja

2.3 Praćenje dilatacija asfaltnog sloja u eksploataciji

Radi dobijanja radnih dijagrama (dilatacija) asfaltnog sloja koji što verodostojnije opisuju njegovo stvarno ponašanje pod opterećenjem teretnih vozila, sprovodi se praćenje dinamičkog odziva asfaltnog sloja. Primena savremenih optičkih senzora (dilatometara), ugrađenih u kolovoznu konstrukciju, omogućava kontinuirano merenje horizontalnih dilatacija na dnu asfaltnog zastora nakon prolaska teretnih vozila. Ne ulazeći detaljno u metodologiju merenja, u nastavku su prikazane očitane vrednosti horizontalnih dilatacija zatezanja registrovanih nakon prelaska troosovinskog vozila bruto mase 15 t [5].




Slika 3: Izgled predmetnog vozila i vrednosti izmerenih zateznih dilatacija

Monitoring horizontalnih dilatacija zatezanja ima za cilj utvrđivanje realnog opsega dilatacija na dnu asfaltnog zastora u stvarnim eksploatacionim uslovima, i predstavlja osnovu za procenu zamora kolovozne konstrukcije. Rezultati merenja pokazuju da se pri prolasku teretnog vozila bruto mase 15 t dilatacije zatezanja na dnu asfaltnog zastora kreću u opsegu $Epsilon_T = 300 - 400 \mu\text{strain}$ (ekvivalentno dilataciji od 0.03 - 0.04 %). Ove vrednosti važe za konkretan tip opterećenja, dok bi različite karakteristike vozila (masa, pritisak u pneumaticima) i kolovozne konstrukcije (debljina i modul krutosti slojeva) uslovile drugačije rezultate. Međutim, generalno posmatrano, maksimalne vrednosti dilatacije zatezanja na dnu asfaltnog sloja, u eksploataciji najčešće ne prelaze vrednost od 1000 μstrain (0.1 %).

2.4 Uticaj naponskog stanja na pojavu pukotina u asfaltnom sloju

U cilju boljeg razumevanja mehaničkog ponašanja asfaltnog sloja, potrebno je sagledati vezu između istezanja (dilatacije) asfalta i naponskog stanja kome je asfalt izložen. Naponsko stanje u kolovoznoj konstrukciji značajno utiče na razvoj deformacija. Analiza mehaničkih karakteristika asfaltnog uzorka, u oblasti tzv. "ograničenog" loma, koristi se za dobijanje što približnijih vrednosti napona i dilatacija, s ciljem određivanja njihovih graničnih vrednosti. Makroskopska veza između napona (stress) i dilatacije (strain) asfaltnih uzoraka (gredica) prikazana je na narednoj slici [6].



Slika 4: Kriva zavisnosti napona i deformacija asfaltna mešavine sa različitim energijama loma


Na osnovu prikazanog dijagrama (napona-dilatacija), mehanizam nastajanja i razvoja pukotine u asfaltnom uzorku može se generalno podeliti na tri faze.

- **I - Faza inicijacije**, počinje mikro plastičnom deformacijom na vrhu pukotine. U ovoj fazi dolazi do postepenog smanjenja krutosti materijala usled formiranja mikro pukotina
- **II - Faza propagacije (razvoja)**, nastaje spajanjem mikro pukotina u dominantne makro pukotine. U ovoj fazi, odgovor materijala je dominantno linearno elastičan, jer su plastične deformacije ograničene
- **III - Faza oštećenja**, nastupa kada elastična mehanika loma postaje neprimenljiva zbog širokih plastičnih zona. Nekontrolisano napredovanje pukotina ubrzava degradaciju materijala i dovodi do strukturnog loma (zamora)

U vezi sa prikazanim, II faza (razvoja) pukotine, koja se odvija u okvirnom opsegu napona $\sigma = 1.5 - 4.0 \text{ MPa}$ i deformacija $\epsilon = 0.002 - 0.012$ (ekvivalentno dilataciji od 0.2 - 1.2 %), predstavlja fazu u kojoj dolazi do smanjenja krutosti sloja usled razvoja makro pukotina u asfaltu. Ova faza (faza II) je ključna za definisanje karakteristika armaturne mreže, jer se upravo u tom domenu naponsko-deformacionog stanja najjasnije sagledava njen doprinos u pogledu nosivosti, krutosti, kontrole pukotina i sposobnosti preuzimanja napona zatezanja.

3. KONCEPT KOMPOZITA OJAČANIH VLAKNIMA - ASFALTNE ARMATURNE MREŽE

Armaturne asfaltne mreže spadaju u klasu kompozita ojačanih vlaknima. Vlakna čine prekidnu i disperznu fazu, dok matrica čini neprekidnu fazu kompozitnog materijala. Matrica ima ulogu da prenosi spoljna opterećenja na vlakna i da obezbedi potrebnu plastičnost i duktilnost, kao i sposobnost oblikovanja kompozitnog materijala. Takođe, uloga matrice je da štiti vlakna od negativnog hemijskog spoljašnjeg uticaja. Vlakna služe da nose opterećenje i mogu imati različit raspored i orijentaciju, što ima veliki uticaj na ukupnu čvrstoću vlaknasto ojačanih kompozitnih materijala. Neprekidna jednosmerno orijentisana vlakna pogodna su kod kompozita koji su jednoosno aksijalno opterećeni na zatezanje, pri čemu se pravac sile opterećenja i vlakana poklapaju [7], što je i slučaj kod armaturnih asfaltnih mreža. Intenzitet veze između sastavnih elemenata definiše čvrstoću vlaknasto ojačanih kompozitnih materijala. Kako matrica poseduje elastična svojstva, intenzitet njene deformacije određuje vrednost čvrstoće kompozita u celini. Zbog ove činjenice, stvarna zatezna čvrstoća kompozita skoro uvek je manja od vrednosti izračunate po zakonu mešanja (vlakno + matrica).




Slika 5: Prikaz vlaknasto ojačanih kompozita i izgled asfaltnih armaturnih mreža tokom ugradnje

3.1 Uloga i mehanizam delovanja armaturnih mreža


Uloga armaturne mreže ogleda se u tome što pri dejstvu saobraćajnog opterećenja u početnoj fazi (inicijacije) preuzima naprezanja uz minimalne deformacije koje se ne uočavaju u asfaltu i time doprinosi povećanju stabilnosti sloja. Sa porastom opterećenja mreža mora imati deformaciona svojstva približno jednaka svojstvima asfalta kako bi delovala zajednički sa njim, čime se dodatno povećava stabilnost sloja i smanjuje pojava deformacija. Naponi zatezanja i smicanja u asfaltnim slojevima doprinose nastanku deformacija tipa pukotina, koje je neophodno da preuzme odgovarajući materijal poput armaturne mreže. Njena primena omogućava povezivanje obe strane pukotine, smanjenje napona i deformacija na vrhu pukotine, ograničavanje horizontalnih i vertikalnih pomeranja, usporavanje širenja pukotine i raspodelu maksimalnih naprezanja na veću površinu zahvaljujući visokoj zateznoj čvrstoći, čime se odlaže reflektovanje postojećih pukotina u novi asfaltni sloj i povećava dopuštena horizontalna dilatacija asfaltnog sloja, što rezultuje većom trajnošću asfaltna konstrukcije. Efektivnost armiranja termostabilnom mrežom zasniva se na kombinaciji:

- mehaničkog uklještenja (interlocking) - putem uklještenja agregata asfaltna mešavine u otvore (okca) mreže, odnosno rebra i čvorove, ostvaruje se ankerisanje mreže unutar asfaltna matrice i omogućava efikasan prenos opterećenja sa asfalta na mrežu
- hemijske adhezije (adhesive shear bonding) - zahvaljujući kvalitetnom (stabilnom) zaštitnom premazu armaturne mreže omogućava se formiranje čvrste hemijske veze sa površinom agregata
- zatezne čvrstoće - koja definiše kapacitet armature da preuzme napone zatezanja nakon pojave pukotina i da uspori njihovo dalje širenje



Slika 6: Šematski prikaz prenosa opterećenja "asfalt/mreža" putem adhezije (levo) i putem horizontalnog uklještenja (desno)


U skladu sa opisanim mehanizmom, uvođenje armaturne mreže u situaciji kada postoji postojeća pukotina ili diskontinuitet smanjuje koncentraciju napona na vrhu pukotine. Pored toga, pod dejstvom smičućih sila, normalna sila koju stvara pravilno ankerisana armaturna mreža indirektno generiše trenje duž ivica pukotine, čime se povećava ukleštenje agregata između dve strane pukotine (de Bondt, 2009).



3.2 Ispitivanje asfaltnih uzoraka na zamor 4PBB - Epsilon 6 dilatacija

U slučaju kratkotrajnih učestalih apliciranja napona, što je slučaj kod dinamički opterećenih kolovoznih konstrukcija, granica elastičnosti materijala se smanjuje sa povećavanjem broja ponavljanja opterećenja. Ovu osobinu manje ili više ispoljavaju svi elastični materijali, što je pojava poznata kao "zamor" materijala. Prekoračenje dovodi do nastajanja pukotina usled zamora. Otpornost asfaltnih mešavina na zamor ispituje se u laboratorijskim uslovima primenom testa savijanja gredice u četiri tačke (4 Point Bending Beam - 4PBB) [8]. Rezultat 4PBB ispitivanja zamora u velikoj meri odražava stvarno ponašanje asfaltnog zastora pod realnim opterećenjem, što je podstaklo istraživače da pristupe ovom testu sa više fenomenoloških aspekata i pokušaju da identifikuju različite procese koji se odvijaju tokom ispitivanja.

Jedan od ključnih kriterijuma za dimenzionisanje kolovozne konstrukcije i proračun trajnosti (životnog veka) jeste da horizontalna dilatacija zatezanja na dnu asfaltnog sloja (EpsilonT) ne prekorači granicu zamora, odnosno dozvoljenu vrednost dilatacije zatezanja. Laboratorijskim ispitivanjem 4PBB pod jasno određenim uslovima (frekvencija i temperatura) omogućava određivanje dilatacije zatezanja ϵ_6 (Epsilon 6) nakon nakon 10^6 ciklusa opterećenja. Dilatacija ϵ_6 predstavlja ključni ulazni podatak koji se uzima u obzir pri dimenzionisanju asfaltnih kolovoznih konstrukcija u Francuskoj i posebno je značajna pri proučavanju efekta armiranja primenom termostabilnih mreža, pri čemu da bi se odredio uticaj (efektivnost i efikasnost) prisustva mreže, upoređuju uzorci sa i bez ojačanja mrežom.



3.3 Efikasnost armaturne mreže - koeficijent armiranja

Efikasnost mreže i kritična dilatacija koja se koristi u projektovanju kolovoznih konstrukcija zavise od korišćenih kriterijuma analize laboratorijskih podataka [9, 10]. Kako bi se odredio računski uticaj prisustva armaturne mreže na otpornost na zamor, uveden je FRIF (Fatigue Resistance Improvement Factor), pri čemu se koriste kritične dilatacije ojačanog i neojačanog seta asfaltnih uzoraka (primenom opita savijanja gredice u četiri tačke 4PBB). Za (praktičnu) primenu u proračunu životnog veka (prema metodologiji LCPC-Setra) uvodi se koeficijent efikasnosti armiranja (k_{ARM}), koji predstavlja odnos kritičnih dilatacija ojačanih i neojačanih uzoraka. Konkretno, FRIF i k_{ARM} , se izračunavaju prema sledećem izrazu:

$$FRIF = \frac{\varepsilon_6^R - \varepsilon_6^{UR}}{\varepsilon_6^{UR}} \times 100\% \quad \text{ili} \quad k_{ARM} = \frac{\varepsilon_6^R}{\varepsilon_6^{UR}}$$

gde su:

ε_6^R - kritična vrednost dilatacije seta uzoraka ojačanih mrežom (μstrain)

ε_6^{UR} - kritična vrednost dilatacije seta uzoraka bez ojačanja (μstrain)

Pozitivne vrednosti FRIF-a ($k_{ARM} > 1,0$) ukazuju da prisustvo ojačanja pozitivno utiče na zamor asfaltnih uzoraka, tj. produžilo je njihov vek trajanja, dok negativne vrednosti FRIF-a ($k_{ARM} < 1,0$) znače da je efekat ojačanja nepovoljan. Pored laboratorijski određenih FRIF i k_{ARM} , neophodno je što realnije proceniti ponašanje mreže nakon ugradnje, uzimajući u obzir sve rizike koje taj proces nosi, odnosno potencijalna oštećenja i umanjeње njenih mehaničkih karakteristika tokom izvođenja radova. Zbog toga se u metodologiji dimenzionisanja uvodi projektna vrednost koeficijenta efikasnosti armiranja (k_{ARM_PROJ}), koja kvantifikuje smanjenje zatezne čvrstoće mreže usled oštećenja nastalih tokom procesa ugradnje. Vrednost umanjeња zatezne čvrstoće armaturne mreže zavisi od više faktora, uključujući vrstu materijala mreže, veličinu otvora i karakteristike asfaltne mešavine (maksimalno zrno, sadržaj veziva).

Na osnovu dostupnih laboratorijskih ispitivanja koja simuliraju oštećenje geosintetičkog materijala tokom ugradnje prema standardu EN ISO 10722:2020, prosečno umanjeње zatezne čvrstoće kreće se u rasponu od 10% do 20%. S tim u vezi, projektna vrednost koeficijenta efikasnosti armiranja, uzimajući obzir umanjeње zatezne čvrstoće nakon ugradnje od na primer 10%, jednaka $k_{ARM_PROJ} = k_{ARM} \cdot 0.9$. Treba napomenuti da stvarni efekat armiranja, pored saznanja o stepenu umanjeња nakon ugradnje zavisi i od dubine ugradnje armaturne mreže, tj smanjenje dubine ugradnje termostabilne armaturne mreže dovodi do srazmernog smanjenja efikasnosti (koeficijenta) armiranja. O ovom i svim ostalim navedenim aspektima biće detaljnije reči u narednim poglavljima.

3.4 Ispitivanje gubitka zatezne čvrstoće mreže tokom ugradnje - EN ISO 10722:2020

Za što preciznije parametrisanje armaturne mreže u spregnutom sistemu (asfalt + mreža), neophodno je utvrditi stepen umanjeња zatezne čvrstoće tokom i nakon ugradnje. Standardom EN ISO 10722 [11] definisana je metoda ispitivanja koja ocenjuje mehaničko oštećenje pod ponovljenim opterećenjem izazvano zrnastim materijalom, čime se nastoji što realnije simulirati oštećenje geosintetičkih materijala tokom ugradnje. Ne ulazeći detaljno u postupak ispitivanja, treba napomenuti da je ovaj standard u periodu od 2007. do 2020. godine pretrpeo značajne proceduralne izmene. U odnosu na verziju iz 2007. godine, važeći standard iz 2020. godine preciznije definiše opterećenje i trajanje testa, čime rezultati postaju znatno relevantniji i pouzdaniji za proračun trajnosti asfaltnih slojeva. Upravo zbog ovih unapređenja, standard EN ISO 10722:2020 predstavlja jedini merodavan okvir za prikaz gubitka zatezne čvrstoće.

3.5 Proračun trajnosti (životnog veka) kolovozne konstrukcije

Analitičkim postupkom primenom specijalizovanih programskih paketa možemo sračunati trajnost (životni vek) asfaltnog sloja kolovozne konstrukcije. Važno imati u vidu da su ulazni podaci idealizovani i da odstupanja praktičnih i računarskih rezultata moraju biti "pokrivena" koeficijentima korekcije. U tom smislu, najoptimalniji pristup je primena analitičkog postupka prema metodologiji Francuske Centralne laboratorije LCPC-Setra [12], uz korišćenje rezultata 4PBB ispitivanja. Na taj način se trajnost asfaltnog zastora, bez značajnog komplikovanja samog postupka proračuna primenom mreže, može izraziti eksponencijalnom funkcijom zamora. Detaljan prikaz postupka racionalnog dimenzionisanja predstavljen je na stručnom skupu Ceste 2022, održanom u Rovinju [13], te se, bez podrobnijeg ulazjenja u objašnjenje samog postupka proračuna, u nastavku daje kratak opis ključnih parametara.

$$\mathcal{E}_{t\max} = (NE/10^6)^b \cdot k_S \cdot k_R \cdot k_C \cdot k_T \cdot k_{ARM_PROJ} \cdot \mathcal{E}_6(10^0C, 25\text{ Hz})$$

- NE - trajnost (životni vek) asfaltnog sloja kolovozne konstrukcije izražen brojem prelaza standardne osovine
- $\mathcal{E}_6$ - dilatacija zatezanja (ustrain) nakon 10^6 ciklusa asfaltnog uzorka određena u laboratoriji (na 10^0C i 25 Hz)
- $\beta = -1/b$ - nagib krive zamora asfaltnog materijala
- k_T - koeficijent korekcije za transponovanje ispitivanja zamora asfaltnih materijala uslovima definisanim u laboratoriji
- k_S - koeficijent korekcije dozvoljene dilatacije zatezanja u skladu sa nosivošću posteljice
- k_R - koeficijent korekcije u odnosu na disperziju rezultata testova zamora i promenu debljine asfaltnog sloja
- k_{ARM_PROJ} - koeficijent armiranja (projektni) predstavlja uvećanje dilatacije zatezanja ($\mathcal{E}_6$) primenom armaturne mreže

4. RELEVANTNE KARAKTERISTIKE (SVOJSTVA) ARMATURNE MREŽE

Poznavanje mehaničkih svojstava armaturne mreže važno je za selekciju mreže pri izradi ojačanja asfaltnih kolovoznih konstrukcija, jer ova svojstva određuju mogućnost ili ograničenja njene primene, uz naravno prethodno definisanje mreže kao optimalnog rešenja. Važna mehanička svojstva materijala su:

- čvrstoća - otpornost materijala prema plastičnom deformisanju
- žilavost - sposobnost materijala da tokom deformisanja pre loma apsorbira određeni nivo energije
- otpornost na zamor - mreža ne doživljava lom ni pri dovoljnom broju ciklusa njenog radnog opterećenja
- puzanje - mreža ne doživljava lom pri istovremenom dejstvu dva činioca (statičkog opterećenja i temperature)

U kontekstu asfaltnih armaturnih mreža, pri čemu su zatezanje i savijanje presudni oblici naprezanja, ključna su dinamička ispitivanja zatezanjem i savijanjem (4PBB), koja određuju otpornost i deformabilnost mreže i spregnutog sistema asfalt + mreža, pri čemu mreža mora imati dovoljnu temperaturnu otpornost kako bi zadržala mehanička svojstva pri ugradnji. Nosivost armaturne mreže, u smislu efektivnosti i efikasnosti, mora biti osigurana odgovarajućim faktorom sigurnosti kako bi pri izduženju od 2 % mogla preuzeti što veću silu i ojačati asfaltni sloj. Faktor sigurnosti obezbeđuje da naponi zatezanja u mreži budu višestruko veći od napona u asfaltu, čime se postiže pouzdano delovanje armature. Prema Tehničkim uputstvima Australijske agencije za transport MRTS104-2025 [14] i Južnoafričke asocijacije za bitumen TG3-2020 [4], mreža mora obezbediti dovoljnu zateznu čvrstoću pri malim deformacijama (pri <2% dilatacije) kako bi "uhvatila" pukotine u fazi njihovog otvaranja, dok optimalna veličina otvora okaca i kompatibilnost sa zrnima agregata omogućavaju efikasan prenos napona i kontrolu širenja pukotina u inicijalnoj fazi. Stoga su laboratorijska ispitivanja neophodna za ocenu efektivnosti (ispunjenost cilja) i efikasnosti (maksimalni učinak) primene mreže u asfaltno ojačanom sistemu obuhvataju:

- zatezna (nominalna) čvrstoća (EN ISO 10319) - utiče na efektivnosti armiranja asfaltnog kompozitnog sistema
- zatezna čvrstoća pri 2% dilatacije (EN ISO 10319) - predstavlja vrednost zatezne čvrstoće kojom se definiše sigurnost primene armaturne mreže
- maksimalno istezanje (max dilatacija) (EN ISO 10319) - pokazuje efektivnost i pogodnost za primenu mreže
- pad zatezne čvrstoće nakon testa oštećenja (EN ISO 10722:2020) - omogućava kvantitativnu procenu efikasnosti primene mreže
- dimenzije otvora okaca mreže - određuju efektivnost interakcije rešetke mreže i zrna agregata asfalta
- otpornost na zamor dilatacija Epsilon 6 (EN 12697-24) - omogućava kvantitativnu procenu efektivnosti i efikasnosti mreže na laboratorijskim uzorcima u kontroli trajnih deformacija
- temperaturna otpornost (EN ISO 3146) - ukazuje na efektivnost i pogodnost mreže i zaštitnog premaza za primenu

4.1 Izbor armaturne mreže i efikasnost kompozitnog sistema asfalt + mreža

Poznavanje svojstava armaturne mreže važno je za selekciju mreže pri izradi ojačanja asfaltnih kolovoznih konstrukcija, jer ova svojstva određuju mogućnost ili ograničenja njene primene, uz naravno prethodno definisanje mreže kao optimalnog rešenja. Zato je značajno izdvojiti karakteristike armaturne mreže koje utiču na efektivnost i efikasnost kompozitnog sistema asfalt + mreža, pri čemu se najveći učinak postiže kada sastavni delovi sistema sadejstvuju u prijemu i raspodeli opterećenja, odnosno kada dolazi do usklađenog prenosa naprezanja i deformacija između asfaltnog sloja i mreže. Imajući to u vidu, izbor armaturne mreže, uzimajući u obzir sve relevantne karakteristike, treba da bude usmerene ka ostvarivanju osnovnog principa armiranja, koji podrazumeva efikasnu distribuciju deformacija radi optimalne apsorpcije napona zatezanja. Uzimajući u obzir navedeno, kao i preporuke Australijske agencije za transport MRTS104-2025 [14] i Južnoafričke asocijacije za bitumen TG3-2020 [3], izdvojene su karakteristike armaturne mreže koje imaju izrazito veliki i veliki značaj za učinak armiranja asfaltnog sloja. Karakteristika koja posredno utiče na povezanost slojeva odnosi se na težinu netkanog geotekstila i njegovu sposobnost upijanja i ravnomernu raspodelu bitumenskog veziivnog sredstva i sprečavanje klizanja između slojeva, što treba verifikovati Lojtnerovim postupkom (prema standardu EN 12697-48). U vezi sa iznetim, tabela prikazuje karakteristike i parametre mreže koji su ključni za postizanje maksimalnog učinka armiranja asfaltnih slojeva.

Tabela 1: Značaj karakteristika armaturne mreže

Karakteristika koja armaturna mreže treba da zadovolji u asfaltnom sloju	Parametar	Peporučene vrednosti	Značaj za učinak armiranja
Žilavost	Zatezna čvrstoća pri 2% dilatacije	> 70% nominalne zatezne čvrstoće	karakteristika je od izrazito velikog značaja
	maksimalno istežanje (dilatacija)	≤ 4%	
Puzanje	Pad zatezne čvrstoće nakon testa oštećenja	≤ 20%	
Temperaturna otpornost	Stabilnost zaštitnog sloja mreže pri visokim temperaturama	> 200°C	
Povezanost slojeva (Interlayer Bonding)	Napon slepljivanja Lojtnerovim postupkom	> 0.85 MPa	
Čvrstoća	Zatezna čvrstoća (nominalna)	> 50 kN/m	karakteristika je od velikog značaja
Otpornost na zamor	Epsilon 6	navesti vrednosti Epsilon 6 na armiranim i nearmiranim uzorcima	
Geometrijska svojstva	Dimenzije otvora okaca mreže	5 do 7 puta veći od D ₅₀ zrna asfaltne mešavine	
Netkani geotekstil	Težina	< 40 gr/m ²	uticaj karakteristike nije zanemarljiv

5. ZAKLJUČAK

Efektivnost i efikasnost armaturne mreže u ojačanju asfaltnih kolovoznih konstrukcija direktno zavise od njenih mehaničkih, geometrijskih i funkcionalnih svojstava, kao i od kvaliteta interakcije sa asfaltnim slojem. Ključni uslov za uspešno armiranje jeste usklađeno sadejstvo mreže i asfalta u prijemu, raspodeli i prenosu naprežanja i deformacija, čime se obezbeđuje optimalna apsorpcija zateznih napona i usporava razvoj pukotina. Posebno je značajno da mreža već u fazi inicijacije i razvoja pukotina preuzima naprežanja pri minimalnim deformacijama (pri <2% dilatacije), koje se još ne uočavaju u asfaltu, čime doprinosi povećanju stabilnosti sloja. Efektivnost mreže ogleda se u njenoj sposobnosti da ostvari osnovni cilj armiranja - kontrolu i usporavanje razvoja pukotina, uz produženje životnog veka kolovozne konstrukcije. Efikasnost se, s druge strane, odnosi na stepen u kome mreža maksimalno koristi svoja mehanička svojstva u realnim uslovima opterećenja, pri čemu optimalan izbor karakteristika omogućava postizanje najvećeg učinka uz tehnički i ekonomski opravdanu primenu. Zaključno, izbor armaturne mreže treba da bude zasnovan na sveobuhvatnoj analizi relevantnih parametara, uz laboratorijsku verifikaciju i usklađenost sa važećim tehničkim smernicama, kako bi se obezbedilo pouzdano i tehničko-ekonomski opravdano rešenje ojačanja asfaltnih slojeva.

Literatura

- [1] Moyda, A. (2015). Geosynthetic reinforcement in flexible pavement rehabilitation. *Journal of Transportation Engineering*
- [2] Tremi, L. (2017). Use of geosynthetic materials for asphalt overlay performance improvement. *International Journal of Pavement Engineering*
- [3] ISO/TC 221 (godina). Geosynthetics - Technical Committee ISO/TC 221. International Organization for Standardization
- [4] TG3 Committee. (2020). Technical Guideline: The Use of Geosynthetics in Pavements - Part C: Design with Geosynthetics. South African Bitumen Association (SABITA).
- [5] Rebelo, F. J. P.; Oliveira, J. R. M.; Silva, H. M. R. D.; Oliveira e Sá, J.; Marecos, V.; Afonso, J. Installation and Use of a Pavement Monitoring System Based on Fibre Bragg Grating Optical Sensors. *Sensors*, 2023.
- [6] Fan, Z. Multiscale Study of the Bitumen-Aggregate Interfacial Behavior based on Molecular Dynamics Simulation and Micromechanics [Doktorska disertacija, Rheinisch-Westfälische Technische Hochschule Aachen]. Fakultät für Bauingenieurwesen, 2021
- [7] Bajić, D. R. Mašinski materijali (II dio), Podgorica, Mašinski fakultet, Univerzitet Crne Gore, 2024
- [8] Maggiore, C., A comparison of different test and analysis methods for asphalt fatigue. PhD Thesis, University of Nottingham, December 2014
- [9] Orešković, M., Trifunović, S., Mladenović, G., Bohuš, Š. Fatigue resistance of a grid-reinforced asphalt concrete using four-point bending beam test. In: Nikolaidis, A.F., Manthos, E. (eds.), 2019
- [10] M. Orešković, Š. Bohuš, A. Virgili, F. Canestrari, Simplified methodology for fatigue analysis of reinforced asphalt systems, *Mater. Struct.*, 2024
- [11] EN ISO 10722:2020, Geosynthetics - Index test procedure for the evaluation of mechanical damage under repeated loading, Damage caused by granular material (Laboratory test), 2020
- [12] Laboratoire Central des Ponts et Chaussées (LCPC), SETRA, French Design Method for Pavement Structures / Catalogue des structures types de chaussées neuves. Paris, (1998)
- [13] Stojnić, D., Bohuš, Š., Postupak dimenzionisanja kolovozne konstrukcije primenom termostabilne mreže od staklenih vlakana za ojačanje (armiranje) asfalta, Stručni seminar o cestovnoj infrastrukturi i sigurnosti u prometu CESTE, Rovinj, 2022
- [14] Transport and Main Roads. MRTS104: Asphalt Geosynthetics for Delaying Pavement Reflective Cracking. Transport and Main Roads Specifications, Australia, 2025
- [15] Sudarsanan, N., Arulrajah, A., Karpurapu, R., Amrithalingam, V. Fatigue Performance of Geosynthetic-Reinforced Asphalt Concrete Beams. *Journal of Materials in Civil Engineering*, 2020

Primjena UI u detekciji i kvantifikaciji oštećenja kolnika na cestama nižeg ranga - pregled literature i prijedlozi za daljnja istraživanja

AI for Detection and Quantification of Pavement Distress on Lower-Ranking Roads: Review and Research Proposals

Kristijan Ljutić¹, Martina Zagvozda², Ivana Barišić³, Mario Galić⁴

¹ 4D - monitoring d.o.o., Hrvatska, kristijan@4d-monitoring.com

² dr.sc., Građevinski i arhitektonski fakultet u Osijeku, Hrvatska, mzagvozda@gfos.hr

³ dr.sc., Građevinski i arhitektonski fakultet u Osijeku, Hrvatska, ivana@gfos.hr

⁴ dr.sc., Građevinski i arhitektonski fakultet u Osijeku, Hrvatska, mgalic@gfos.hr

Sažetak. Ocjena stanja kolnika ključna je za produženje vijeka trajanja infrastrukture i optimizaciju troškova održavanja. Tradicionalne metode vizualnih pregleda podložne su subjektivnosti i vremenski su zahtjevne. Razvoj umjetne inteligencije (UI), posebice računalnog vida, omogućuje automatiziranu detekciju i klasifikaciju oštećenja s visokom preciznošću i brzinom, nadmašujući klasične metode. U okviru bibliometrijske analize literature identificirani su ključni trendovi primjene UI u detekciji i kvantifikaciji oštećenja kolnika. Iako UI modeli postižu visoku preciznost u detekciji, nedostaje kvantitativna analiza deformacija i 3D rekonstrukcija. Također, samo rijetki radovi uspoređuju UI s ljudskim procjenama, pritom otkrivajući nedostatak statističke valjanosti. Ovaj rad najavljuje daljnje korake: integraciju stereo kamera za generiranje dubinskih mapa iz 2D snimaka omogućujući izračun deformacija uz postojeći YOLOv8-seg model treniran na velikom broju slika te statističku analizu subjektivnosti operatera kojom se cilja dokazati varijabilnost ljudskih procjena. Ovi rezultati podržat će razvoj UI sustava za objektivnu i skalabilnu ocjenu, integriranu u upravljanje cestovnom mrežom.

Ključne riječi. Detekcija oštećenja kolnika, stereo vizija, subjektivnost procjene, UI, YOLO

Abstract. Pavement condition assessment is crucial in extending infrastructure lifespan and optimizing maintenance costs. Conventional visual inspections suffer from subjectivity and inefficiency. The development of AI, particularly MV, enables automated detection and classification of distresses with high precision and speed, surpassing classical methods. Within the bibliometric analysis of the literature, key trends in AI applications for pavement distress detection and quantification were identified. While AI models deliver high detection accuracy, they often overlook deformation quantification and 3D reconstruction. Additionally, only a few studies compare AI with human assessments, revealing a lack of statistical validity. This paper announces further steps: integration of stereo cameras for generating depth maps from 2D images, enabling deformation calculations alongside the existing YOLOv8-seg model trained on a large number of images, as well as statistical analysis of operator subjectivity aimed at demonstrating the variability of human assessments. These results will support the development of AI system for objective and scalable assessment, integrated into road network management.

Key words. AI, assessment subjectivity, pavement distress detection, stereo vision, YOLO

1. UVOD

Cestovna infrastruktura predstavlja jedan od najvrjednijih segmenata nacionalne imovine Republike Hrvatske, čije je očuvanje preduvjet za gospodarski razvoj i prometnu sigurnost. Zakonodavni okvir, primarno definiran Zakonom o cestama [1] i Pravilnikom o održavanju cesta [2], jasno propisuje obveze upravitelja u pogledu sustavnog praćenja stanja kolnika. Međutim, operativna provedba ovih obveza, posebice na razini županijskih i lokalnih cesta (ceste nižeg ranga), nailazi na značajne izazove zbog ograničenih resursa i oslanjanja na reaktivne mjere održavanja.

Dominantna metoda prikupljanja podataka i dalje je vizualna inspekcija prema standardiziranim uputama [3]. Iako je ljudska ekspertiza nezamjenjiva u kompleksnim inženjerskim procjenama, njezina primjena u repetitivnim zadacima detekcije površinskih oštećenja nosi niz nedostataka, prvenstveno subjektivnost i varijabilnost procjene (intra-rater i inter-rater varijabilnost). Dodatno, tradicionalne metode su kvalitativne, što znači da često nedostaju precizni volumetrijski podaci o oštećenjima (npr. dubina udarne rupe) nužni za točnu procjenu troškova sanacije.


Ovaj rad predlaže modernizaciju procesa integracijom naprednih tehnologija računalnog vida. Cilj je premostiti jaz između 2D detekcije, koja je demonstrirana u prethodnim studijama [4], i stvarne potrebe za 3D kvantifikacijom oštećenja, uz istovremenu znanstvenu validaciju prednosti automatizacije nad ljudskom procjenom.

2. PREGLED LITERATURE

Tradicionalne metode ocjenjivanja stanja kolnika primarno su se oslanjale na vizualne preglede i jednostavne mehaničke uređaje, koji su, iako pouzdani, radno intenzivni, podložni subjektivnosti i ograničeni u prostornom obuhvatu. Pojava umjetne inteligencije (UI), posebice računalnog vida i dubokog učenja, transformirala je ovaj sektor omogućujući brzu, dosljednu i opsežnu analizu kolnika u stvarnom vremenu.

Sveobuhvatna bibliometrijska analiza literature koja je provedena u sklopu istraživanja i rada na znanstveno istraživačkom projektu [5], ukazuje na eksponencijalni rast interesa za ovu domenu nakon 2018. godine.


Najveći broj istraživanja potječe iz Kine, Indije i SAD-a, a sam interes za primjenu UI u detekciji oštećenja značajno raste iz godine u godinu. Interes za primjenu umjetne inteligencije u detekciji oštećenja kolnika značajno je porastao u proteklih šest godina, kao što je vidljivo iz Slike 1 koja prikazuje godišnju objavu članaka na ovu temu.



Slika 1: Kronološki pregled primjene UI u detekciji oštećenja kolnika u znanstvenim radovima

U domeni arhitekture umjetne inteligencije, ključni trend je apsolutna dominacija algoritama iz obitelji YOLO (You Only Look Once). Za razliku od dvostupanjskih detektora (poput R-CNN mreža) koji su vremenski zahtjevniji, YOLO rješava detekciju objekata i njihovu klasifikaciju kao jedinstven regresijski problem, što omogućuje iznimnu brzinu uz visoku točnost.

Novije verzije, posebice YOLOv8 [6,7], donijele su značajan napredak omogućivši semantičku segmentaciju, čime se prevladalo ograničenje jednostavnih obuhvatnih pravokutnika (bounding boxes). Prethodna istraživanja na dionici lokalne ceste Tršće-Vrhovci-Tršće [4] potvrdila su da YOLO modeli mogu iznimno uspješno i brzo automatizirati mapiranje kritičnih segmenata ceste (Slika 2).



Slika 2: Prikaz dionice ceste obuhvaćene 2D UI analizom 2024. godine

Unatoč brzom tehnološkom napretku, sustavni pregled literature otkriva kritične nedostatke u postojećem korpusu znanja, prvenstveno kada je riječ o cestama nižeg ranga:

- Zanemarivanje specifičnosti cesta nižeg ranga i nedostatak 3D kvantifikacije: Za razliku od autocesta koje imaju stroge režime održavanja, lokalne ceste podložne su intenzivnijim lokaliziranim opterećenjima na užem kolniku te prisutnosti komunalne infrastrukture (šahтови, slivnici). Posljedično, dominantna oštećenja koja izravno ugrožavaju sigurnost postaju udarne rupe i kolotrazi. Većina postojećih UI modela oslanja se na 2D vizualne podatke koji su dostatni za prepoznavanje pukotina, ali ne i za kvantifikaciju dubine rupa. Trodimenzionalni podaci ključni su za objektivni izračun volumena oštećenja, no metode poput 3D laserskog skeniranja (LiDAR) skupe su, kompleksne i osjetljive na okolišne uvjete (kiša, osvjetljenje) [8,9]. Alternativa u obliku rekonstrukcije 3D podataka iz 2D slika putem binokularne stereo vizije nameće se kao financijski isplativije rješenje, ali je nedovoljno implementirano u operativne sustave održavanja.
- Izostanak validacije subjektivnosti (Problem "Ground Truth" podataka): Drugi ključni nedostatak je nedostatak statističke usporedbe između rezultata UI modela i procjena stručnih operatera na terenu. Većina dosadašnjih istraživanja koristi podatke koje su ručno označili ljudi kao apsolutnu istinu (ground truth) za trening modela. Time se zanemaruje inherentna varijabilnost i podložnost pogreškama same ljudske percepcije. Kako bi se egzaktno dokazala stvarna vrijednost uvođenja automatiziranih UI sustava, nedostaju studije koje primjenom naprednih statističkih alata (npr. Fleiss-ovog Kappa koeficijenta) znanstveno kvantificiraju nepouzdanost i varijabilnost ljudskih procjenitelja.

3. METODOLOGIJA

Metodološki okvir istraživanja temelji se na "hibridnom" pristupu koji kombinira razvoj naprednog hardverskog sustava za akviziciju podataka i statistički dizajn eksperimenta za validaciju.

3.1. Arhitektura sustava za prikupljanje podataka (Raw Data Recording)

Za razliku od komercijalnih rješenja koja se oslanjaju na *Edge AI* obradu (inferenciju na samom vozilu uz gubitak kvalitete), predloženi sustav dizajniran je za maksimalnu vjernost podataka.

Sustav se sastoji od:

- Optički senzori (Stereo par): Dvije industrijske GMSL (Gigabit Multimedia Serial Link) kamere s Global Shutter senzorima visoke osjetljivosti. Korištenje stereo para s fiksnom bazom omogućuje simulaciju ljudskog binokularnog vida. GMSL tehnologija osigurava prijenos nekomprimiranog videa uz nisku latenciju, što je ključno za preciznu sinkronizaciju lijeve i desne slike.
- Računalna jedinica: Sustavom upravlja NVIDIA Jetson Orin NX računalo. Njegova funkcija je pouzdana akvizicija i vremenska sinkronizacija sirovih podataka (slika), podataka o orijentaciji (IMU) i precizne geolokacije (RTK GNSS).


3.2. Lokalna obrada i princip Stereo Vizije

Sirovi podaci obrađuju se naknadno na lokalnom UI superračunalu (HPC) s 96 GB VRAM-a, što omogućuje korištenje nekvantiziranih (FP32) modela za maksimalnu točnost. Ključna inovacija je primjena **stereo vizije** za 3D rekonstrukciju. Proces se temelji na izračunu mape dispariteta – razlike u položaju iste točke na lijevoj i desnoj slici. Dubina (Z) se računa prema principu triangulacije [9]:

$$Z = (f \times B) / d \quad (1)$$

gdje je f žarišna duljina, B razmak između kamera (baza), a d disparitet.

Ovaj proces omogućuje generiranje gustog oblaka točaka (*Point Cloud*) za svako detektirano oštećenje, čime se dobiva treća dimenzija (dubina).



Slika 3: Generiranje gustih oblaka točaka i mapa dubine iz stereo snimaka

Za generiranje gustih oblaka točaka i mapa dubine iz stereo snimaka primijenjen je napredni algoritam temeljen na dubokim neuronskim mrežama koji pruža najvišu razinu točnosti i prostorne rezolucije dubinskih podataka (Slika 3).

Ovaj je pristup projektiran specifično za primjene koje zahtijevaju maksimalnu preciznost i robusnost pri 3D rekonstrukciji i naprednim inspekcijama infrastrukture. Iako ovakvi modeli iziskuju iznimno velike računalne resurse i posljedično procesiraju podatke pri nižem broju sličica u sekundi u usporedbi s optimiziranim *Edge AI* rješenjima, njihova je primjena u ovom istraživanju omogućena isključivo zahvaljujući hardverskoj snazi lokalnog UI superračunala.

Izvođenje ovakvih složenih, nekvantiziranih neuronskih mreža 'offline' pokazuje iznimne rezultate u zahtjevnim okruženjima (poput kompleksnih tekstura asfalta), što je od presudne važnosti kada je potrebno precizno zabilježiti fine detalje poput pukotina i volumetrijskih deformacija kolnika.

Za razliku od 2D detekcije, izračun gustih mapa dispariteta za stereo viziju zahtijeva korelaciju piksela između lijeve i desne slike u visokoj rezoluciji. Izvođenje ovakvih nekvantiziranih modela u stvarnom vremenu na terenu zahtijevalo bi enormnu potrošnju energije i hlađenje, stoga je 'offline' obrada na HPC-u jedini način da se zadrži 100% prikupljenih detalja bez termalnog usporavanja hardvera.

3.3. Statistički okvir za analizu subjektivnosti

Kao kontrolni mehanizam, metodologija uključuje eksperiment u kojem dvije grupe nezavisnih procjenitelja (iskusnih inženjera te studenata diplomskog studija građevinarstva) ocjenjuje isti skup fotografija oštećenja. Dva su cilja ovog dijela istraživanja: utvrditi "Ground Truth" podatke te dokazati varijabilnost ljudskih procjena pri tradicionalnoj metodi vizualnog pregleda kolnika. Za istraživanje su odabrani studenti viših godina studija građevinarstva (sveučilišni diplomski studij) koji imaju osnovna predznanja o oštećenjima kolničkih zastora. Svaki ispitanik će najprije proći edukaciju koristeći za tu priliku projektiran ispitni postav (sučelje) na kojemu će trenirati bilježenje i klasifikaciju oštećenja na odabranoj dionici ceste. Nakon edukacije, isto sučelje će se koristiti za glavno istraživanje u sklopu kojega će ispitanici na isti način, koristeći stečena znanja sa edukacije provesti vizualni pregled kolnika druge odabrane dionice. Dionica ceste iz glavnog istraživanja sa studentima dati će se na analizu i iskusnim inženjerima radi usporedbe rezultata.

Za kvantifikaciju slaganja među procjeniteljima koristi se Fleiss-ov Kappa koeficijent (κ), statistička mjera prikladna za ocjenu pouzdanosti više procjenitelja. Vrijednosti $\kappa < 0,40$ ukazuju na loše slaganje, čime se planira znanstveno dokazati potreba za objektivizacijom procesa.

4. REZULTATI I RASPRAVA

Preliminarna testiranja sustava provedena su na dionici lokalne ceste LC58002. Usporedba rezultata dobivenih 2D sustavom i novim 3D stereo sustavom prikazana je u Tablici 1.

Tablica 1. Usporedba izlaznih podataka 2D i 3D AI sustava

Parametar	2D AI sustav	3D Stereo AI sustav	Implikacija za održavanje
Detekcija	Da (Klasifikacija)	Da (Klasifikacija)	Jednaka točnost detekcije.
Površina	Da (Pikseli $\rightarrow$ m ²)	Da (m ²)	Preciznija procjena utroška asfalta.
Dubina	Ne	Da (cm)	Razlikovanje površinskog i dubinskog oštećenja.
Volumen	Ne	Da (m ³)	Točan izračun mase asfalta za krpanje.
Ocjena	Temeljena na površini	Temeljena na volumenu	Objektivnija prioritizacija (ozbiljnost).

4.1. Generiranje 3D modela oštećenja

Ključni rezultat je uspješna rekonstrukcija geometrije kolnika iz video snimaka. Sustav je na testnim primjerima udarnih rupa omogućio izračun volumena ispunjenja, što direktno utječe na točnost troškovnika sanacije. Dok 2D sustav primjerice mrlju od ulja i duboku rupu može klasificirati slično, 3D sustav jasno diferencira ta dva slučaja temeljem dubinske mape.

4.2. Objektivizacija procesa odlučivanja

Uvođenje ovakvog sustava ima izravne implikacije na Sustav gospodarenja cestama (RAMS). Objektivni, ponovljivi podaci eliminiraju rizik ljudske pogreške i pružaju pravnu sigurnost upraviteljima cesta. Mogućnost "premotavanja" digitalnog zapisa ceste i ponovne analize sirovih podataka na HPC infrastrukturi osigurava da se niti jedan detalj ne izgubi, omogućujući prijelaz s reaktivnog na prediktivno održavanje.

Primjenom predloženog statističkog okvira, očekuje se da će UI sustav pokazati apsolutnu konzistentnost ($\kappa = 1.0$ pri ponovljenim mjerenjima istog oštećenja), dok tradicionalni vizualni pregledi redovito pate od inter-rater varijabilnosti. Time se upraviteljima cesta ne osigurava samo točniji izračun volumena asfalta, već i zaštita od pravnih i financijskih propusta uzrokovanih ljudskom greškom.

5. ZAKLJUČAK

Ovaj rad postavlja temelje za novu generaciju sustava za ocjenjivanje stanja kolnika. Integracijom YOLOv8-seg modela i tehnologije stereo vizije, predloženo rješenje nadilazi ograničenja ljudske percepcije i 2D analize slike, nudeći potpunu 3D kvantifikaciju oštećenja po cijeni prihvatljivoj za lokalne ceste. Unatoč premještanju obrade u lokalno okruženje, korištenje superračunala omogućilo je da se procesiranje kilometra ceste s potpunom 3D rekonstrukcijom završi u operativno prihvatljivom vremenu, višestruko brže od vremena potrebnog za tradicionalni vizualni pregled iste dionice.

Glavni doprinosi rada su:

- Razvoj arhitekture za prikupljanje sirovih podataka (*Raw Data*) koja maksimizira kvalitetu ulaznih informacija.
- Metodološki okvir za znanstvenu validaciju prednosti UI sustava nad ljudskom procjenom.
- Demonstracija 3D rekonstrukcije oštećenja kao ključa za precizno budžetiranje radova održavanja.

6. ZAHVALA

Dio istraživanja financiran je iz projekta Harmonizacija inovacija i pametne prometne infrastrukture-581-UNIOS-73, Europska unija - NextGenerationEU.

7. LITERATURA

[1] Zakon o cestama, NN 84/11, 22/13, 54/13, 148/13, 92/14, 110/19, 144/21, 114/22, 114/22, 04/23, 133/23.

[2] Pravilnik o održavanju cesta, NN 90/14.

[3] Dragčević, V., Korlaet, Ž. & Rukavina, T. (2004). Uputstvo za vizualni pregled kolnika državnih cesta, Građevinski fakultet Sveučilišta u Zagrebu.

[4] Ljutić, K., Galić, M., Klanjšček, D., Barišić, I. (2025). Application of Artificial Intelligence in Pavement Condition Assessment: A Case Study of the Local Road Tršće-Vrhovci-Tršće. Ceste 2025, Rovinj.

[5] Harmonizacija Inovacija i pametne Prometne Infrastrukture – HIPI, znanstveno-istraživački projekt, Europska unija – NextGenerationEU, <https://www.hipiscience.com/> (15.2.2026.)

- [6] Luo, S., et al. EPDD-YOLO: An efficient benchmark for pavement damage detection based on Mamba-YOLO. *Measurement*, 2025, 253, <https://doi.org/10.1016/j.measurement.2025.117638>
- [7] Khan, M., et al. Pothole detection for autonomous vehicles using deep learning: a robust and efficient solution. *Frontiers in Built Environment*, 2024, 9, <https://doi.org/10.3389/fbuil.2023.1323792>
- [8] Sathya, R.; Saleena, B. CNN-MAO: Convolutional Neural Network-based Modified Aquilla Optimization Algorithm for Pothole Identification from Thermal Images. *Signal, Image and Video Processing*, 2022, 16 (8), pp. 2239-2247. <https://doi.org/10.1007/s11760-022-02189-0>
- [9] Prakash, B. M.; Sriharipriya, K. C. Enhanced pothole detection system using YOLOX algorithm. *Autonomous Intelligent Systems*, 2022, 2 (1), <https://doi.org/10.1007/s43684-022-00037-z>

UTJECAJ MATERIJALA IZRADE STUPOVA UZ CESTE NA SIGURNOST U PROMETU (IMPACT OF ROADSIDE POLE MATERIALS ON TRAFFIC SAFETY)

Višnja Tkalčević Lakušić¹, Katarina Vranešić²

¹ Izv. prof. dr. sc., Sveučilište u Zagrebu, Građevinski fakultet, Kačićeva 26, Zagreb, Hrvatska,
visnja.tkalcovic.lakusic@grad.unizg.hr

² Dr. sc., Sveučilište u Zagrebu, Građevinski fakultet, Kačićeva 26, Zagreb, Hrvatska,
katarina.vranesic@grad.unizg.hr

Sažetak

Stupovi uz ceste, kao što su rasvjetni stupovi, stupovi semafora i prometnih znakova, imaju važnu ulogu u sigurnosti prometnog sustava. Materijali korišteni za njihovu izradu znatno utječu na održavanje, trajnost i sposobnost apsorpiranja energije koja se stvara prilikom udara vozila. U radu su analizirani stupovi izrađeni od najčešće korištenih i inovativnih materijala s posebnim naglaskom na mehanička svojstva, otpornost na vremenske uvjete i koroziju, način održavanja te ponašanje kod prometnih nesreća. Analiza pokazuje da odgovarajući materijali stupova mogu smanjiti težinu ozljeda u slučaju udara vozila, dok istovremeno osiguravaju dugotrajnu funkcionalnost i stabilnost. Zaključno, primjena novih materijala i tehnologija u izradi stupova uz ceste doprinosi povećanju ukupne sigurnosti u prometu i smanjenju teških posljedica prometnih nesreća.

Ključne riječi:

stupovi uz ceste, sigurnost u prometu, materijali izrade, vremenski uvjeti, korozija, antikorozivna zaštita, apsorpcija energije

1. UVOD

Temeljni zahtjev svakoga prometnoga sustava jest sigurnost svih sudionika u prometu, što se može postići primjenom različite opreme uz prometnice. Međutim, pojedini popratni objekti poput stupova javne rasvjete, stupova prometne signalizacije i sličnih elemenata, u slučaju udara vozila mogu uzrokovati izrazito negativne posljedice. Prema statistikama oko 20 % smrtno stradalih osoba u prometnim nesrećama izgubi život uslijed udara vozila u objekte koji se nalaze uz prometnicu [1]. Upravo se iz tog razloga sve veća pozornost posvećuje primjeni pasivno sigurnih stupova, čija je osnovna zadaća smanjenje razine ozljeda i materijalne štete prilikom udara vozila.

Pasivno sigurni stupovi se izrađuju od različitih materijala, pri čemu svaki od tih materijala posjeduje specifična mehanička svojstva te se različito ponaša pri udaru vozila. Osim ponašanja u uvjetima prometnih nesreća, važno je razmotriti i dugoročne utjecaje okolišnih čimbenika [2]. Vremenski uvjeti poput oborina, temperaturnih oscilacija, jakih vjetrova i UV zračenja različito djeluju na pojedine materijale, što izravno utječe na njihovu trajnost, potrebu za održavanjem te pojavu i intenzitet korozije.

U ovome radu analizirani su stupovi izrađeni od najčešće korištenih materijala, s posebnim naglaskom na njihova mehanička svojstva, ponašanje u slučaju udara vozila, otpornost na vremenske utjecaje i koroziju te zahtjeve održavanja. Cilj rada je usporednom analizom istaknuti prednosti i nedostatke pojedinih materijala u kontekstu prometne sigurnosti i dugoročne održivosti cestovne infrastrukture.

2. PASIVNO SIGURNI STUPOVI

Stupovi koji se obično postavljaju uz ceste u Republici Hrvatskoj su kruti i ne mogu preuzeti svu energiju koja se stvara prilikom udara vozila pa se ona većim dijelom prenosi na vozilo i putnike u vozilu što često rezultira teškim posljedicama [3]. Za razliku od krutih stupova, pasivno sigurni stupovi projektiraju se tako da prilikom udara vozila mogu apsorbirati energiju ili se odvojiti pri bazi stupa. Na slici 1. prikazan je sudar vozila s krutim stupom (Slika 1a) i pasivno sigurnim stupom koji može apsorbirati energiju (Slika 1b). Vidljivo je da su posljedice sudara znatno blaže kada vozilo udari u pasivno sigurni stup.



a) Kruti stup [4]




b) Pasivno sigurni stup [5]

Slika 1: Posljedice udara vozila u različite tipove stupova

Obzirom na sposobnost apsorpcije energije, pasivno sigurni stupovi se prema EN 12767:2019 [6] mogu podijeliti u tri kategorije:

- Neapsorbirajući (NE) stupovi, koji se odvajaju u blizini temelja stupa i ruše te padaju iza vozila,
- Visokoapsorbirajući (HE) stupovi, koji mogu apsorbirati veliku količinu energije savijanjem ispred i ispod vozila pri čemu se ne odvajaju od tla,
- Niskoapsorbirajući (LE) stupovi, koji mogu apsorbirati manju količinu energije, postepeno se deformirajući ispred i ispod vozila prije odvajanja stupa od temelja i rušenja.

Na slici 2. prikazano je ponašanje pasivno sigurnih stupova prilikom udara vozila.



Slika 2: Ponašanje pasivno sigurnih stupova kod udara vozila [7]

Odabir vrste pasivno pouzdanih stupova za određenu dionicu ceste ovisi o više faktora, kao što je na primjer način otkazivanja stupova, sigurnost putnika u vozilu, rizici za druge sudionike u prometu, ograničenje brzine na razmatranoj dionici, postojanje objekata uz cestu, šteta na vozilu itd. [3]. Njihova upotreba posebno je relevantna u zonama visokog rizika, gdje je vjerojatnost udara u stupove povećana zbog zakrivljenosti ceste, blizine stupova ili velikih brzina [8].

Stupovi koji ne apsorbiraju energiju (NE stupovi) preporučuju se na područjima gdje su dopuštene velike brzine na cesti te nema okolnih objekata i pješaka. Primjenom ove vrste stupova postiže se najveća sigurnost za putnike u vozilu i najmanja šteta na vozilu u odnosu na druge vrste stupova. Ovi stupovi se ne preporučuju u blizini pješačkih zona, biciklističkih staza i drveća. Stupovi koji mogu apsorbirati energiju (HE i LE stupovi) preporučuju se na mjestima gdje postoji mogućnost od sekundarnih sudara te rizika za ostale sudionike u prometu.

3. UTJECAJ MATERIJALA NA KARAKTERISTIKE STUPOVA

Pasivno sigurni stupovi obično se izrađuju od čelika, aluminija i kompozitnih materijala, a izbor materijala ovisi o vrsti ceste, lokalnim uvjetima, troškovima, estetskim i sigurnosnim zahtjevima [9].

Zbog niske cijene, dobrih mehaničkih svojstava, trajnosti uz odgovarajuću antikorozivnu zaštitu, visokoj otpornosti na zamor materijala te mogućnosti recikliranja, čelik je najzastupljeniji materijal za izradu stupova [10].

U usporedbi s klasičnim čeličnim stupovima, aluminijski imaju znatno manju masu – lakši su za otprilike trećinu, što smanjuje troškove transporta te olakšava i ubrza montažu. Osim toga, njihov projektirani vijek trajanja iznosi oko 50 godina, što je znatno više od prosječnog trajanja čeličnih stupova [9].

Kompozitni stupovi, iako predstavljaju najskuplju opciju, imaju niz prednosti, poput visoke vlačne čvrstoće, male mase, otporni su na koroziju, što ih čini izuzetno pogodnima za agresivne okolišne uvjete. Njihova najveća prednost jest nezahtjevnost u održavanju, uz vijek trajanja koji može doseći do 80 godina [11].


Međutim, osim što značajno utječe na troškove izgradnje i dugoročnog održavanja, materijal od kojeg je izrađen stup ima važnu ulogu i u njegovom ponašanju tijekom prometne nesreće, što će biti prikazano u nastavku.

3.1. PONAŠANJE STUPOVA U SLUČAJU UDARA VOZILA

Materijal izrade stupa ima veliki utjecaj na sposobnost apsorpcije energije i ponašanje stupova u slučaju udara vozila. Ove karakteristike često ovise o mehaničkim svojstvima materijala, poput krutosti, duktilnosti i mase.

Utjecaj materijala stupa na sigurnost putnika može se prikazati u odnosu na vrijednost sile G koju pretrpe putnici u vozilu prilikom udara vozila u stup. G predstavlja silu po jedinici mase koju doživljavaju putnici u vozilu u odnosu na ubrzanje sile teže $9,81 \text{ m/s}^2$, a izražava se u jedinicama standardne gravitacije, g [12]. Sila koja djeluje na tijelo koje miruje na tlu je otprilike $1g$. Ova sila izravno je proporcionalna ubrzanju vozila. Nastaje zbog ubrzavanja ili usporavanja vozila, a pokazuje koliko puta je stvarno ubrzanje veće od ubrzanja sile teže.

U radu [13] analizirane su vrijednosti sile G mjerene kod udara vozila u stupove izrađene od tri različita materijala: betona, čelika i aluminija. Rezultati istraživanja (Slika 3.), pokazali su da se prilikom udara vozila u betonske stupove javljaju najveće vrijednosti sile G , dok su kod tradicionalnih čeličnih stupova te vrijednosti nešto niže, međutim još uvijek imaju veliki utjecaj na putnike u vozilu. Iz navedenog se može vidjeti da kod aluminijskih stupova vrijednost sile G nije velika te je promatrani dijagram ujednačeniji, što je mnogo povoljnije za putnike u vozilu.



Slika 3: Vrijednosti G sile u ovisnosti o materijalu izrade stupa [13]

Ispitivanja su pokazala da vozilo, prilikom udara u klasični čelični stup, znatno usporava generirajući veliku silu usporavanja pri čemu dolazi i do značajnijih oštećenja vozila. Budući da aluminij ima veću elastičnost i stoga apsorbira manje količine energije u odnosu na čelik, aluminijski stupovi mogu postepenim apsorpiranjem energije sporije zaustaviti vozilo, čime se smanjuje težina ozljeda putnika pa su i oštećenja na vozilu manja.

Na temelju rezultata provedenog istraživanja može se zaključiti da aluminijski stupovi pokazuju najpovoljnije ponašanje prilikom udara vozila u usporedbi sa betonskim i čeličnim stupovima. Najopasniji stupovi sigurno su betonski jer su kruti i ne apsorbiraju energiju, zatim slijede tradicionalni čelični stupovi. Međutim, moderni pasivno sigurni čelični stupovi, kao što su primjerice ZIPpole stupovi, imaju specifičnu konstrukciju koja omogućuje visoku apsorpciju energije (HE) te sigurno zaustavljanje vozila [3].

U usporedbi s drugim materijalima, kompozitni stupovi imaju najveću sposobnost apsorpcije energije pri udaru vozila, čime se smanjuje intenzitet početnog udara na putnike i smanjuju oštećenja vozila [11]. U istraživanju [14] analizirano je ponašanje kompozitnih i aluminijskih rasvjetnih stupova za vrijeme udara vozila. Pokazalo se da se prilikom udara u kompozitni stup vozilo još sporije zaustavlja u odnosu na aluminijske stupove, što je povoljnije za putnike u vozilu pa su i oštećenja na vozilu manja.

Zabilježeni su brojni slučajevi prometnih nesreća u kojima su lagani kompozitni stupovi ostali uspravni nakon sudara, čime je smanjen rizik od sekundarnih nesreća, poput naleta drugih vozila. Dodatna prednost kompozitnih stupova je činjenica da su izolatori, što znači da srušeni stup pod naponom ne predstavlja opasnost od strujnog udara za prolaznike ili spasioce.

3.2. UTJECAJ KOROZIJE NA STUPOVE

Korozijski procesi na stupovima ovise o različitim parametrima, prije svega o materijalu od kojega je stup izrađen te njegovoj lokaciji. Tako na primjer, ukoliko se čelični stupovi nalaze u morskom okolišu korozijski procesi bit će vrlo brzi i agresivni. Prema [15] korozija u morskom okolišu rezultat je gotovo 30% ukupnih zabilježenih oštećenja konstrukcija koja zahtijevaju određenu intervenciju. Korozija narušava vizualni izgled stupa, a na brzinu korozije utječe mnogo čimbenika, poput temperature, pH vrijednosti, klorida zbog čega je brzinu korozije teško kontrolirati [15, 16]. U dosadašnjim provedenim analizama, korozijska oštećenja najčešće se zamjećuju na donjem dijelu stupa, najčešće na kontaktu stupa sa tlom (slika 4.).



Slika 4. Korozija na čeličnom stupu [17]

Ukoliko se korozijski procesi na čeličnim stupovima ne spriječe na vrijeme, nastale degradacije mogu direktno utjecati na mehaničke karakteristike stupa. Korozija može oslabiti konstrukciju pa se stup prilikom udara vozila možda neće ponašati na način na koji je projektiran i ispitan prilikom pokusnih sudara. Nadalje, srušeni stupovi mogu blokirati promet, oštetiti vozila ili ozlijediti prolaznike. Na slici 5. prikazan je stup javne rasvjete na kojemu je zamijećeno naganjanje zbog oštećenja na njegovome donjem dijelu.



Slika 5. Naginjanje stupa zbog oštećenja na bazi

U radu [18] zabilježeno je prevrtanje stupa nakon svega pet godina eksploatacije zbog djelovanja korozijskih procesa, bez obzira što je na stupu bila primijenjena antikorozivna zaštita. Dodatnom analizom ustanovljen je lokalizirani gubitak antikorozivne zaštite što je dovelo do pojave rupičaste korozije i prevrtanja stupa. Također, ustanovljeno je da je ova ubrzana degradacija posljedica djelovanja klorida prisutnih u tlu. Nakon oštećenja antikorozivne zaštite, čelični je stup bio u direktnom kontaktu s agresivnim okolišem što je rezultiralo veoma brzom degradacijom. Slična analiza provedena je i u radu [19] gdje je na svim analiziranim stupovima ustanovljeno da se najugroženiji dio stupa nalazi 20 cm ispod površine tla te da će se rane faze korozije pojaviti jednoliko po obodu stupa.

Kao zaštita stupova od korozije najčešće se koristi postupak vrućeg pocinčavanja, a u novije vrijeme Magnelis zaštita. Magnelis čelik kao inovativan proizvod dobiva se kroz proces vrućeg pocinčavanja samo sa prilagođenim sastavom tekućine u koju se uranjaju čelični elementi, a koja pored cinka uključuje aluminij i magnezij [20]. Zahvaljujući toj karakteristici Magnelis je dugovječan materijal i kao takav postaje ekonomičnija alternativa skupljim materijalima kao što su nehrđajući čelik i aluminij što može rezultirati značajnim uštedama u projektu. Kako Magnelis sadrži manje količine cinka u odnosu na proizvode dobivene klasičnim postupkom vrućeg pocinčavanja, Magnelis je i bolji izbor za okoliš. U usporedbi sa čelikom zaštićenim klasičnim cinčanjem, Magnelis pruža tri puta bolju zaštitu od korozije i time produljuje vijek trajanja konstrukcije.

Za razliku od čeličnih stupova, aluminijski stupovi znatno su otporniji na korozijske procese. Njegova otpornost proizlazi iz tanke pasivne oksidne ovojnice (Al_2O_3) koja se automatski stvara na površini u dodiru sa zrakom [21]. Ova barijera sprječava daljnu oksidaciju i štiti materijal ispod nje. Međutim, bez obzira na otpornost na korozijske procese, dodatna zaštita aluminijskih stupova preporučuje se ukoliko se oni nalaze u agresivnom okolišu poput morskog okoliša. Također, aluminijski stup je vrlo osjetljiv na galvansku koroziju koja će nastati kada je aluminij u kontaktu s nekim drugim, plemenitijim metalom (npr. bakar ili cink), a nalazi se u vlažnim uvjetima. Ova dva metala u kombinaciji s vlažnom okolinom stvaraju galvanski članak u kojemu će korodirati manje plemeniti metal (u ovome slučaju aluminij).

S obzirom na sastav materijala, najbolje karakteristike kada je riječ o korozijskim procesima predstavljaju kompozitni stupovi. S obzirom da ovi stupovi nisu izloženi korozijskim reakcijama, predstavljaju vrlo dobro rješenje u agresivnim korozivnim okolinama.

3.3. UTJECAJ VREMENSKIH UVJETA NA STUPOVE

S obzirom na to da su stupovi prometne infrastrukture trajno izloženi vanjskom okolišu, vremenski uvjeti mogu imati negativan utjecaj na njihovu trajnost i funkcionalnost. Taj je utjecaj

u posljednje vrijeme sve izraženiji uslijed učestalije pojave ekstremnih vremenskih prilika povezanih s klimatskim promjenama, koje se očituju kroz izražene temperaturne ekstreme, snažne udare vjetra te povećane količine oborina [22].


Dosadašnja istraživanja ukazuju da su najveća oštećenja uzrokovana vremenskim uvjetima zabilježena na antikorozivnim zaštitnim sustavima koji se primjenjuju na čeličnim stupovima.

Antikorozivni premazi imaju ključnu ulogu u zaštiti čeličnih stupova od korozije i produljenju njihovog vijeka trajanja. Njihova osnovna funkcija jest sprječavanje ili usporavanje kontakta osnovnog materijala s agresivnim okolišnim čimbenicima, poput vlage, kisika, soli i onečišćenja iz atmosfere. Zaštitni sustav premaza na čeliku uglavnom se sastoji od temeljnog premaza, međusloja i završnoga sloja pri čemu su međusloj i završni sloj formulirani tako da zaštićuju temeljni premaz. Temeljni premaz je prvi sloj koji se nanosi na konstrukciju. On bi trebao biti dovoljno elastičan da podnese rastezanje i skupljanje uslijed promjena temperature. Ukoliko nije dovoljno elastičan, počeo će pucati ili će se ljuskati. Glavna svojstva temeljnog premaza su sprječavanje ili odgoda pojave korozije, formiranje čvrstog sloja koji dobro prianja na metal i na kojeg će dobro prianjati sljedeći slojevi. Međusloj mora nadopunjavati antikorozivnu zaštitu temeljnog premaza te imati dobra elastična svojstva. On mora biti dobra podloga za završni sloj čija je osnovna namjena da bude otporan prema vremenskim utjecajima [23].

Međutim, dugotrajna izloženost visokim i niskim temperaturama, čije ekstremne vrijednosti zbog klimatskih promjena postaju sve izraženije, uzrokuje stalno širenje i skupljanje čelične konstrukcije, što s vremenom dovodi do nastanka mikropukotina u zaštitnom premazu, njegovog ljuštenja ili odvajanja od podloge. Time se narušava osnovna zaštitna funkcija premaza, čime čelik postaje izravno izložen djelovanju vlage i agresivnih okolišnih utjecaja. Osim temperaturnih promjena, dugotrajna izloženost UV zračenju također može imati štetne posljedice na antikorozivne premaze, uzrokujući njihovo starenje, gubitak elastičnosti, pojavu pukotina te promjene kemijskih i mehaničkih svojstava materijala [24].

Djelovanje vjetra predstavlja dodatni značajan čimbenik opterećenja, osobito kod stupova izrađenih od čelika i aluminija. Snažni i nagli udari vjetra velikih brzina uzrokuju pojavu tzv. primarnih vibracija, koje najčešće djeluju na vršni dio stupa te rezultiraju njegovim izraženim nihanjima (slika 6). Ovakva dinamička opterećenja mogu, ako se ponavljaju kroz dulje vremensko razdoblje, dovesti do postupnog slabljenja konstrukcije, posebice u slučajevima kada utjecaj vjetra nije adekvatno uzet u obzir tijekom faze projektiranja. Iz tog je razloga pri statičkom i dinamičkom proračunu stupova nužno razmatrati očekivane maksimalne brzine vjetra temeljene na dostupnim klimatskim podacima, kao i predviđene promjene povezane s klimatskim trendovima [25, 26].

Osim primarnih vibracija izazvanih jakim udarima vjetra, značajan problem mogu predstavljati i sekundarne vibracije. One nastaju uslijed dugotrajnog djelovanja vjetrova manjih brzina, ali visoke frekvencije, te su osobito izražene na otvorenim i ravničarskim područjima s minimalnim brojem prirodnih ili umjetnih prepreka, poput zgrada ili vegetacije. Međutim, takvi se uvjeti mogu pojaviti i u drugim prostornim kontekstima. Sekundarne vibracije najčešće djeluju na srednji dio stupa (slika 6) te su posebno nepovoljne zbog svoje teško predvidive prirode. Dugotrajno kumulativno djelovanje ovih opterećenja može uzrokovati zamor materijala, pojavu pukotina u konstrukciji te u ekstremnim slučajevima dovesti do djelomičnog ili potpunog mehaničkog otkazivanja stupa [25, 26].



Slika 6. Vibracija stupova uzrokovana djelovanjem vjetra: a) primarni oblik vibracija, b) sekundarni oblik vibracija [27]

Otpornost stupova na vibracije izazvane vjetrom uvelike ovisi o njihovom geometrijskom obliku i materijalu. Najosjetljiviji su ravni aluminijski stupovi kvadratnog presjeka, jer oštri kutovi i velike ravne površine pojačavaju turbulenciju zraka. S druge strane, čelični stupovi kružnog, suženog presjeka pokazuju znatno veću otpornost, budući da njihov oblik omogućava lakši protok zraka i smanjuje aerodinamičke sile koje uzrokuju vibracije [25, 26].

4. DISKUSIJA

Kao što je vidljivo, materijal izrade stupova značajno utječe na njihovu trajnost i sposobnost apsorpcije energije pri udaru vozila. Tradicionalni čelični stupovi generiraju veće sile G na putnike prilikom udara vozila u stup, dok pasivni aluminijski i kompozitni stupovi postepeno apsorbiraju energiju, smanjujući težinu ozljeda i oštećenja vozila. Međutim, moderni pasivno sigurni čelični stupovi imaju veliku sposobnost apsorpcije energije i očekuju se manje sile G , što bi trebalo potvrditi dodatnim ispitivanjima.


Kada je riječ od djelovanju korozijskih procesa na stupove, najbolje karakteristike pokazuju kompozitni stupovi. Aluminijski imaju prirodnu oksidnu barijeru zbog čega imaju dobra svojstva kada je riječ o koroziji. S druge strane, čelični stupovi zahtijevaju stalnu antikorozivnu zaštitu koja se najčešće primjenjuje u obliku različitih premaza. Međutim, ukoliko dođe do oštećenja premaza, na tom se segmentu stupa može javiti lokalizirana korozija koja može ugroziti stabilnost cijeloga stupa. Zbog toga je znatno bolje rješenje primjena novih načina zaštite, kao što je to kod Magnelis čelika gdje se čelična konstrukcija štiti prevlakom načinjenom od metala elektronegativnijeg od čelika. Ovi metali se ponašaju kao žrtvovane anode, odnosno korodiraju umjesto materijala kojega štite, čak i ukoliko je ta prevlaka na nekim mjestima oštećena.

Magnelis čelik ima izvanrednu otpornost na koroziju i samostalno obnavljanje na mjestima oštećenja, a ujedno je i ekonomičnija alternativa skupljim materijalima kao što su nehrđajući čelik i aluminij što može rezultirati značajnim uštedama u projektu.

Kada je riječ o utjecaju olujnog vjetra na stup, on će ovisiti prije svega o obliku stupa, pri čemu su ravni kvadratni stupovi najosjetljiviji na vibracije uzrokovane vjetrom, dok kružni, suženi stupovi bolje raspoređuju aerodinamičke sile. Dugotrajno djelovanje vibracija može uzrokovati zamor materijala, stoga se kod projektiranja moraju uzeti u obzir klimatski i aerodinamički uvjeti.

Usporedba karakteristika različitih vrsta pasivno sigurnih stupova, uključujući i stupove od Magnelis čelika, s obzirom na apsorpciju energije, otpornost na vremenske uvjete, potrebu za

antikorozivnom zaštitom, trajnost, mogućnost ponovno upotrebe materijala, početnu cijenu te troškove održavanja prikazana je na slici ocjenama od 1 od 5, pri čemu je 1 najgora, a 5 najbolja ocjena određenog svojstva. Kako je vidljivo na slici 7, može se zaključiti da se kao optimalna opcija za primjenu pasivno sigurnih stupova nameću aluminijски stupovi ili stupovi načinjeni od Magnelis čelika.



Slika 7: Grafički prikaz karakteristika promatranih stupova: čelični (plava krivulja), Magnelis čelični (narančasta), aluminijски (roza krivulja), kompozitni (zelena krivulja)

5. ZAKLJUČAK

Stupovi uz ceste imaju važnu ulogu u sigurnosti prometnog sustava. Prometne nesreće u kojima dolazi do udara vozila u cestovne stupove mogu imati znatno blaže posljedice ako se, umjesto tradicionalnih krutih stupova, primjenjuju pasivno sigurni stupovi. Takvi stupovi mogu apsorbirati energiju udara vozila ili se na kontrolirani način odvojiti pri bazi, čime se smanjuje rizik od teških posljedica nesreće. Primjenom odgovarajućih materijala u izradi pasivno sigurnih stupova moguće je značajno utjecati na smanjenje štetnih posljedica udara vozila. Odabir materijala pritom ne utječe samo na sigurnosne karakteristike, već i na eksploatacijska svojstva stupa, poput otpornosti na vremenske utjecaje, potrebe za antikorozivnom zaštitom, trajnosti, početne troškove i troškove održavanja.

U ovom radu analiziran je utjecaj nekoliko različitih materijala na karakteristike pasivno sigurnih stupova. Analiza pokazuje da aluminijски i kompozitni stupovi imaju vrlo povoljna svojstva, no njihova je primjena danas ograničena zbog veće početne cijene. Također se može zaključiti da se primjenom odgovarajuće zaštite čeličnih stupova, primjerice uporabom Magnelis čelika, mogu postići vrlo dobre karakteristike pasivno sigurnih stupova, uz niže početne troškove u usporedbi s aluminijским i kompozitnim rješenjima.

Zbog svojih karakteristika pasivno sigurni stupovi mogu odgovoriti i izazovima vezanim uz klimatske promjene, kao i otpornosti na korozijske procese koji će se dogoditi zbog utjecaja vanjskoga okoliša. Utjecaji poput sve ekstremnijih vremenskih uvjeta kao što su poplave, oluje, snažni vjetrovi, požari povećavaju opasnosti na cestama i potencijalna slijetanja vozila sa cesta što zahtijeva prilagodljiviju infrastrukturu,

Odabir i primjena odgovarajućih materijala u izradi pasivno sigurnih stupova uz ceste ima izravan utjecaj na sigurnost u prometu. Moderni, otporni i sigurnosno optimizirani materijali doprinose ne samo očuvanju infrastrukture, već i spašavaju ljudske živote kroz smanjenje težine nesreća i broja smrtnih slučajeva na cestama.

U razvoju stupova uz ceste treba razmišljati o tzv. pametnim stupovima s IoT senzorima. Na taj način se vrlo brzo dobiva informacija o ponašanju stupova, ne samo uslijed udara već i u

slučaju jakih vjetrova i sl. Kod primjene novih tehnologija, kako u pogledu materijala za proizvodnju stupa te ponašanju stupa u eksploataciji u cilju postizanja veće sigurnosti u prometu, uvijek treba razmatrati i usklađivanje s ciljevima održivog razvoja (eng. Sustainable Development Goals - SDG). Posebno treba razmatrati ciljeve SDG3 (smanjenje broja smrtnih slučajeva), SDG9 (otporna i održiva infrastruktura), SDG11 (održivi gradovi i zajednice) i SDG13 (smanjenje ugljičnog otiska infrastrukture).

Zaključno, implementacija pasivno sigurnih stupova doprinosi sigurnijoj cestovnoj mreži, dok otpornost na klimatske promjene osigurava da ti sustavi ostanu funkcionalni u promijenjenim okolišnim uvjetima.

5. LITERATURA

- [1] Fatality Facts. Collisions with fixed objects and animals. Dostupno na: <https://www.iihs.org/topics/fatality-statistics/detail/collisions-with-fixed-objects-and-animals>
- [2] Smjernice za pripremu infrastrukture klimatskim promjenama, <https://mingo.gov.hr/smjernice-za-pripremu-infrastrukture-klimatskim-promjenama/7643>
- [3] Tkalčević Lakušić, V., Babić, D. Passively safe poles along roads as a measure to increase traffic safety. *Građevinar* 77 (2025) 2, 141-150, DOI: <https://doi.org/10.14256/JCE.4121.2024>
- [4] <https://dnevnik.hr/vijesti/crna-kronika/tragicna-prometna-nesreca-u-prevrtanju-automobila-poginula-osoba---818960.html>
- [5] Zippole, <https://zippole.com/wp-content/uploads/2020/11/en12767-new-edition-2019-v02.pdf>
- [6] European Committee for Standardization: EN 12767:2019, Passive safety of support structures for road equipment - Requirements and test methods.
- [7] Ponašanje pasivno sigurnih stupova (on-line) available on: <https://cdn.tii.ie/publications/DN-REQ-03040-02.pdf>
- [8] Tkalčević Lakušić, V., Ferko, M., Babić, D. Crash Severity in Collisions with Roadside Light Poles: Highlighting the Potential of Passive Safe Pole Solutions, *Infrastructures*, 10 (2025), 7; 163---. doi: 10.3390/infrastructures10070163
- [9] Tkalčević Lakušić, V.: Analiza stupova uz prometnice iz aspekta sigurnosti u prometu, Projektiranje prometne infrastrukture, Zagreb, University of Zagreb, Faculty of Civil Engineering, Department of Transportation Engineering 2011. pp. 321-346
- [10] Tkalčević Lakušić, Višnja: Pouzdanost stupova uz prometnice pri udaru vozila // *Građevinar*, 64 (2012), 4; 305-313
- [11] Composite column, (on-line) available on: <https://www.rspoles.com/whyusecomposite>
- [12] The g-force, (on-line) available on: <https://www.omnicalculator.com/physics/g-force>
- [13] Aluminium, D. M. Paylor MIEE C.eng FILE FRSA, 'Aluminium Lighting Columns – The Way Forward to the 21st Century': <https://www.aluminium-lighting.com/products/highway-lighting/>
- [14] Danek, W., Gąsiorek, D.: Comparison of the value of passive safety coefficients for car crash with lighting column made of aluminum or composite material based on numerical simulation, *MATEC Web of Conferences* 285, 00002 (2019) DYNKON 2019, <https://doi.org/10.1051/matecconf/201928500002>

- [15] A.V. Radhamani, H.C. Lau, S. Ramakrishna. (2019). Nanocomposite Coatings On Steel For Enhancing The Corrosion Resistance: A Review, *Journal of Composite Material*, vol. 54, (pp. 681 – 701)
- [16] Nurul Shuhada Pauzai, Nor Diana Ruzaini Mohd Zin, Khairuddin Abdullah, Mithila Seva Bala Sundaram: CORROSION BEHAVIOR STUDY OF STEEL POLE IN DIFFERENT COATING TECHNOLOGY, *International Journal of Engineering Applied Sciences and Technology*, 2021, Vol. 5, Issue 9, pp. 58-65
- [17] Korozija na stupu, dostupno na: <https://exoinc.com/blog/what-we-see-neglected-steel-poles>
- [18] Urbi Pal , Goutam Mukhopadhyay, Nirmal Kumar B., Sandip Bhattacharyya: Electric pole failure: A safety concern, *Engineering Failure Analysis*, 103 (2019), pp. 249-258
- [19] Samuel Fleming: Development of Method to Assess the Integrity of Metal Streetlight Poles, *CEED Seminar Proceedings 2016*
- [20] Magnelis, (on-line) available at: <https://www.laser-ing.hr/blog/sto-je-magnelis-celik/>
- [21] Kurtela, M.: Utjecaj cerijevih iona na korozijska svojstva aluminijske legure u kloridnome mediju, Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje, doktorska disertacija, 2021.
- [22] Vranešić, K.; Haladin, I.; Burnać, K.: Utjecaj klimatskih promjena na elemente gornjeg ustroja kolosiječne konstrukcije, *Građevinar*, 77 (2025) 1, DOI: <https://doi.org/10.14256/JCE.4123.2024>
- [23] Jarić, B. , Rešetić, A.: Korozija : elektrokemijske osnove i katodna zaštita, Korexper, Zagreb, 2003.
- [24] Danuta Kotnarowska: Influence of ultraviolet radiation and aggressive media on epoxy coating degradation, *Progress in Organic Coatings* 37 (1999) 149–159
- [25] <https://lytepoles.com/blog/how-wind-induced-vibrations-affect-steel-and-aluminum-light-poles/>
- [26] Erdem Türkeli, Deniz Cokli: The Effect of Wind Speed on Structural Along-Wind Response of a Lighting Pole According to TS498 and Eurocode 1, *Buildings* 2025, 15, 1085
- [27] Understanding and Mitigating Light Pole Vibration <https://www.lightmart.com/blog/understanding-and-mitigating-light-pole-vibrations/?srsltid=AfmBOop5E6v-8txx-hpS1liXddwh1bn2VmgUbQHf5InKtduz4L2idRZ>

Impact of Road Design Parameters and Traffic Loads on User Costs

mag. Franc Šoba¹

Marjana Cuderman²

¹ DRI upravljanje investicij, d.o.o., Slovenia, franci.soba@dri.si

² DRI upravljanje investicij, d.o.o., Slovenia, marjana.cuderman@dri.si

Abstract. The paper investigates the combined influence of road design parameters and traffic loads on the total costs borne by road users. Road design parameters encompass various road categories (4 and 6 lane motorways, as well as 2 lane primary roads) featuring different longitudinal gradients. With regard to traffic loads, the analysis incorporates varying traffic volumes, vehicle fleet composition, hourly traffic distribution over the entire year, and both daily and monthly traffic fluctuations.

Total user costs are calculated across multiple cost categories—fuel consumption, travel time costs, operating costs, air pollution costs, climate change costs, WWT emission costs, noise costs, accident costs, and maintenance costs—under a series of scenarios reflecting the influence of geometric road characteristics and traffic load intensity.

The primary objective of the paper is to demonstrate how road design parameters, in conjunction with traffic volume levels, affect the overall user cost structure.

Key words. air pollution costs, climate change costs, fuel consumption costs, total user costs, traffic loads, travel time costs

1. BASELINE ASSUMPTIONS AND METHODOLOGY

The purpose of this paper is to examine the influence of technical road elements and traffic loads on total user costs. Technical elements represent various road categories and the number of lanes with different longitudinal gradients. Regarding traffic loads, the analysis accounts for different traffic volumes, vehicle fleet composition, and hourly traffic distribution throughout the entire year. The results present total user costs by cost category (fuel consumption, travel time costs, overhead costs, air pollution costs, climate change costs, WWT emission costs, noise costs, accident costs, and maintenance costs) for various scenarios based on the impact of technical elements and the extent of traffic loads.

The primary objective of the paper is to demonstrate how technical road elements, in conjunction with traffic volume, influence the overall structure of user costs.

The following baseline assumptions were used in the calculation of total user costs:

- Technical road infrastructure elements: length of 1.0 km, longitudinal gradients (0%, 3%, or 6%), and number of lanes (2, 4, or 6).
- Traffic data by vehicle type for the year 2025.
- Road categories: motorway, expressway, or primary road.
- Software: Opcost software package, price levels as of November 2025.

The Opcost software package calculates user costs and external costs for each vehicle type. For a specific transport network, the maintenance costs of the transport infrastructure are also

calculated. The Opcost program calculates user and external costs based on basic data regarding consumption costs (fuel, lubricants, tires, vehicle maintenance and repairs) and time-dependent costs (depreciation, interest, overheads, driver's wages).

The user cost category consists of:

- Consumption costs: These represent vehicle user costs based on driving speed and vehicle type. They include costs for fuel, lubricants, tires, and vehicle maintenance and repairs. Influencing factors include gradient, curvature, pavement structure, congestion, and road surface condition. They are calculated for ten characteristic vehicle types: small passenger car, medium passenger car, large passenger car, light truck, medium truck, heavy truck I, heavy truck II, truck with trailer, articulated truck, and bus.
- Additional consumption costs: These are incurred due to speed limits at road obstacles, depending on driving speed and vehicle type. They include additional costs for fuel, lubricants, tires, and vehicle maintenance and repairs. The primary influencing factor is the pavement structure.
- Overhead costs: These are time- and distance-dependent costs based on driving speed, distance traveled, and vehicle type. They include depreciation costs, interest costs (vehicle purchase price), and overhead costs for commercial vehicles (vehicle utilization).
- Travel time costs: These are the costs of passenger travel time in vehicles, based on driving speed and vehicle type.

In addition to direct effects on users, investments in transport infrastructure also generate external effects. External transport costs are those caused by road users to society and the environment that are not directly compensated through a return transaction. The main sources of these costs are traffic accidents, congestion, air pollution, noise, and climate change. The evaluation of investments in road infrastructure in developed societies emphasizes the issue of internalizing external effects (i.e., incorporating the costs to the broader social environment), as the assessment of a project's costs and benefits must include external effects, which were largely neglected in past decision-making processes regarding project viability. In 2008, following an initiative in the Eurovignette Directive, the Handbook on the Estimation of External Costs in the Transport Sector was developed and subsequently updated in 2014 (Update of the Handbook on External Costs of Transport). The handbook provides guidelines for estimating certain external costs and incorporating them into investment evaluations.

The HBEFA methodology (version 3.3) is also fully integrated into the Opcost program. For each vehicle type (passenger cars, buses, light and heavy goods vehicles), the program provides the value of individual pollutants in grams per kilometer (g/km), based on the area (urban, rural), road type (motorway, primary road, local road), level of service (free flow, congestion), road gradient, and speed. The pollutant quantity forecast is based on the assumption of current vehicle technology, with the only variable being the number of vehicles.

External costs consist of:

- Traffic accidents: The impact on the number and consequences of traffic accidents is evaluated based on the monetized probability of an accident occurring per kilometer, depending on the road type, traffic volumes, and whether the section passes through a settlement.
- Air pollution: Traffic-related emissions cause damage to humans, the biosphere, soil, water, buildings, and materials. Air pollution costs are calculated using emission factors for individual gases in grams per kilometer traveled (g/km). The most significant pollutants include: particulate matter (PM_{2.5}), nitrogen oxides (NO_x), sulfur dioxide (SO₂), and volatile organic compounds (VOC). These

emissions affect: health-related costs; damage to buildings and material damage; crop loss and agricultural damage; and biodiversity and ecosystems (groundwater, soil)).

- Climate change: The primary drivers of climate change costs are fuel consumption and the carbon content of the fuel. Greenhouse gases (GHG) and their impact on climate change are reflected in extreme weather conditions, rising sea levels, loss of habitats, scarcity of drinking water, etc. Greenhouse gases include carbon dioxide (CO₂), nitrous oxide (N₂O), and methane (CH₄). To best estimate the total damage caused by GHGs, a joint assessment of pollution avoidance costs is recommended. CO₂ is used as the representative common denominator for GHG cost estimates.
- Emissions: WWT costs (Well-to-Tank).
- Noise: External noise costs consist of health costs and costs related to disturbance and inconvenience caused by noise.

The user cost calculations utilize the traffic data from Table 1.

Table 1. Traffic data for the user cost calculation for the year 2025

Osebn vozila	Avtobusi	Lahki tov. pod 3,5 t	Srednji tov. 3,5- 7,5 t	Teški tov. nad 7,5 t	Tov. s prikl.	Vlačilci	SKUPAJ VSA VOZILA
3.850	25	475	50	25	75	500	5.000
7.700	50	950	100	50	150	1.000	10.000
11.550	75	1.425	150	75	225	1.500	15.000
15.400	100	1.900	200	100	300	2.000	20.000
19.250	125	2.375	250	125	375	2.500	25.000
23.100	150	2.850	300	150	450	3.000	30.000
26.950	175	3.325	350	175	525	3.500	35.000
30.800	200	3.800	400	200	600	4.000	40.000
34.650	225	4.275	450	225	675	4.500	45.000
38.500	250	4.750	500	250	750	5.000	50.000
42.350	275	5.225	550	275	825	5.500	55.000
46.200	300	5.700	600	300	900	6.000	60.000
50.050	325	6.175	650	325	975	6.500	65.000
53.900	350	6.650	700	350	1.050	7.000	70.000
57.750	375	7.125	750	375	1.125	7.500	75.000
61.600	400	7.600	800	400	1.200	8.000	80.000
65.450	425	8.075	850	425	1.275	8.500	85.000
69.300	450	8.550	900	450	1.350	9.000	90.000

Source: Author's analysis

Traffic data for the user cost calculation is defined for volumes ranging from 5,000 vehicles/day to 90,000 vehicles/day. In the results, the presentation is limited to traffic volumes up to 65,000 vehicles/day, as the results for primary roads (2-lane) are not realistic due to capacity constraints.

The vehicle fleet composition is summarized based on counting data from the motorway network, with passenger cars accounting for 77%, buses 0.5%, light goods vehicles 9.5%, medium goods vehicles 1%, heavy goods vehicles 0.5%, heavy goods vehicles with trailers 1.5%, and articulated lorries (semi-trailers) 10%.

2. USER COST CALCULATIONS

User costs have been calculated for a total of 216 projects, representing a combination of various technical elements, road types, and traffic loads. For each project, all cost categories specified in the methodology were calculated.

The purpose of these calculations is to determine the extent of total user costs and unit costs across different road types and traffic volumes.

The results presented include:

- Total costs for all vehicles combined for various traffic volumes (from 5,000 vehicles/day to 65,000 vehicles/day), expressed in EUR/km/year.
- Unit costs per vehicle, separated for passenger cars and heavy goods vehicles, expressed in EUR/vehicle/km.
- Total costs for all vehicles combined by cost category for two traffic load scenarios: 10,000 vehicles/day and 40,000 vehicles/day, expressed in EUR.

2.1. Total costs for all vehicles

Table 2 presents the results of the total cost calculations for all vehicles combined for the year 2025, considering various traffic volumes ranging from 5,000 vehicles/day to 65,000 vehicles/day, as well as individual road types (AC – motorway, HC – expressway, GC – primary road), the number of lanes, and the longitudinal gradient of the road.

Table 2. Total costs for all vehicles combined in 2025

Road Type	5.000	15.000	25.000	35.000	45.000	55.000	65.000
AC_4_0	1.149.410	3.362.274	5.575.138	7.789.985	10.004.792	12.212.591	14.385.474
AC_4_3	1.191.238	3.487.758	5.784.278	8.081.989	10.379.018	12.679.272	14.940.169
AC_4_6	1.258.210	3.688.675	6.119.139	8.551.494	10.981.108	13.407.729	15.804.807
AC_6_0	1.171.903	3.386.774	5.601.645	7.816.516	10.032.411	12.249.078	14.435.434
AC_6_3	1.213.731	3.512.258	5.810.785	8.109.312	10.408.503	12.709.261	14.977.794
AC_6_6	1.280.703	3.713.175	6.145.646	8.578.118	11.011.972	13.445.463	15.847.511
HC_4_0	1.111.543	3.257.268	5.402.994	7.548.719	9.694.444	11.841.686	13.967.038
HC_4_3	1.160.849	3.405.185	5.649.522	7.893.858	10.138.194	12.393.705	14.619.268
HC_4_6	1.234.165	3.625.135	6.016.104	8.407.074	10.798.700	13.195.504	15.568.108
GC_2_0	1.151.891	3.517.769	6.043.801	8.855.769	12.110.679	16.200.791	21.979.376
GC_2_3	1.204.162	3.688.954	6.337.355	9.311.115	12.840.170	17.406.011	24.192.565
GC_2_6	1.280.761	3.998.527	7.098.878	10.904.601	16.478.144	28.828.723	49.541.702

Source: Author's analysis

The results in Figure 1 show that total costs for primary roads (2-lane) increase significantly with growing traffic volumes, which is a consequence of the capacity constraints of two-lane roads. For 2-lane roads, the calculations remain realistic up to 45,000 vehicles/day, depending on the hourly traffic distribution. In the event of pronounced traffic peaks, the capacity of 2-lane roads is further reduced.

Higher longitudinal gradients of traffic routes result in higher total user costs. Compared to a motorway in flat terrain (0%), the total costs for a motorway in mountain terrain (6% gradient) are 9% lower in the flat scenario.




Fig. 1: Total costs in EUR

Source: Author's analysis

2.2. Unit costs per vehicle for passenger cars and heavy goods vehicles

The results for unit costs per vehicle (separated for passenger cars and heavy goods vehicles) show differences in total costs per individual vehicle depending on various road types and technical elements in combination with traffic volumes. As traffic volume increases, travel time lengthens due to capacity constraints, which results in higher time-dependent costs. For motorways, there are no significant differences as traffic volume increases up to 65,000 vehicles/day; however, differences do arise due to technical elements (the road alignment relative to flat, rolling, or mountain terrain).

Table 3. 2.2. Unit costs per vehicle for passenger cars

Type of Road	5.000	15.000	25.000	35.000	45.000	55.000	65.000
AC_4_0	0,415	0,415	0,415	0,415	0,415	0,415	0,415
AC_4_3	0,420	0,420	0,420	0,421	0,421	0,421	0,421
AC_4_6	0,428	0,428	0,428	0,429	0,429	0,429	0,429
AC_6_0	0,415	0,415	0,415	0,415	0,415	0,415	0,415
AC_6_3	0,420	0,420	0,420	0,420	0,420	0,421	0,421
AC_6_6	0,428	0,428	0,428	0,428	0,429	0,429	0,429
HC_4_0	0,409	0,409	0,409	0,409	0,409	0,409	0,409
HC_4_3	0,416	0,416	0,416	0,416	0,416	0,416	0,417
HC_4_6	0,424	0,424	0,424	0,424	0,424	0,424	0,425
GC_2_0	0,425	0,437	0,451	0,473	0,504	0,548	0,622
GC_2_3	0,434	0,447	0,463	0,487	0,522	0,574	0,672
GC_2_6	0,447	0,470	0,500	0,553	0,662	0,993	1,503

Source: Author's analysis




Fig. 2: User costs per unit (Cars) in EUR/km

Source: Author's analysis

For heavy goods vehicles, the situation is similar to that of passenger cars: traffic volume on motorways does not affect higher costs per vehicle unit, whereas the road category does. On 2-lane roads, costs are higher due to capacity constraints and the resulting increase in time-dependent costs.

Table 4. Unit costs for heavy goods vehicles

Type of Road	5.000	15.000	25.000	35.000	45.000	55.000	65.000
AC_4_0	0,415	0,415	0,415	0,415	0,415	0,415	0,415
AC_4_3	0,420	0,420	0,420	0,421	0,421	0,421	0,421
AC_4_6	0,428	0,428	0,428	0,429	0,429	0,429	0,429
AC_6_0	0,415	0,415	0,415	0,415	0,415	0,415	0,415
AC_6_3	0,420	0,420	0,420	0,420	0,420	0,421	0,421
AC_6_6	0,428	0,428	0,428	0,428	0,429	0,429	0,429
HC_4_0	0,409	0,409	0,409	0,409	0,409	0,409	0,409
HC_4_3	0,416	0,416	0,416	0,416	0,416	0,416	0,417
HC_4_6	0,424	0,424	0,424	0,424	0,424	0,424	0,425
GC_2_0	0,425	0,437	0,451	0,473	0,504	0,548	0,622
GC_2_3	0,434	0,447	0,463	0,487	0,522	0,574	0,672
GC_2_6	0,447	0,470	0,500	0,553	0,662	0,993	1,503

Source: Author's analysis




Fig. 3: User costs per unit (Cars) in EUR/km
Source: Author's analysis

2.3. Total costs for all vehicles combined by cost category

Figure 4 shows the total user costs by cost category for a traffic volume of 10,000 vehicles/day, while Figure 5 presents the total user costs for a traffic volume of 40,000 vehicles/day.

Both figures illustrate total user costs by cost category for various road types and their technical elements (longitudinal gradient). Costs are calculated for motorways (4 or 6 lanes) with a speed limit of 130 km/h, expressways (4 lanes) with a limit of 110 km/h, and primary roads with two-way traffic (2 lanes) and a speed limit of 90 km/h.

On motorways, consumption costs account for 33% of total costs, overhead costs 38%, travel time costs 18%, pavement maintenance costs 2%, and total external costs 9%. In the case of primary roads, external costs are slightly higher at 11% (due to accident costs), while consumption costs are lower at 24%. At the same time, travel time costs are higher, representing 24% of the total costs.




Fig. 4: Total user costs (10.000 AADT)
Source: Author's analysis

The cost ratio remains similar even in the case of higher traffic loads, as shown in Figure 5 for 40,000 vehicles/day. In this scenario, the differences between total costs are more pronounced; specifically, for a 2-lane primary road on mountain terrain (6% gradient), total costs increase significantly. In this particular case, the calculation results are effectively theoretical, primarily due to the capacity constraints of a two-lane road.




Fig. 5: Total user costs (40,000 AADT)

Source: Author's analysis

3. CONCLUDING REMARKS

Total user costs increase with traffic volume because reduced driving speeds—resulting from capacity constraints—cause higher time-dependent costs.

The structure of total user costs is dominated by overhead costs, followed by consumption and time costs.

Total external costs account for a 9% to 11% share, depending on the road type. This share would be higher if projects within urban settlements were evaluated, whereas all current calculations were performed for sections outside of settlements.

4. REFERENCES

- (1) Handbook of Emission Factors for Road Transport (HBEFA).
- (2) Manual for the use of the updated OPCOST17 software package, version OPCOST 17.1, Republic of Slovenia, Ministry of Infrastructure, Omegaconsult d.o.o., December 2020.
- (3) HCM 2010 Highway Capacity Manual, Transport Research Board.

SMART TRAFFIC MANAGEMENT FOR SUSTAINABLE CITIESZoran Injac¹, Siniša Arsić², Miloš Arsić³, Joso Vrkljan⁴¹ Pan-European University Apeiron, 78000 Banja Luka, B&H; zoran.dj.injac@apeiron-edu.eu² Telekom Srbija, 11000 Belgrade, Serbia, sinisaars@telekom.rs³ University Business Academy, 21000 Novi Sad, Serbia, misaarsa@yahoo.com⁴ Polytechnic "Nikola Tesla" in Gospić, 53000 Gospić, Croatia, jvrkljan@velegs-nikolatesla.hr

Abstract: In today's cities, increasing traffic demand and limited infrastructure capacity cause frequent congestion, higher emissions, and a decline in urban livability. Conventional traffic management systems, reliant on fixed signal timings, struggle to adapt to real-time traffic conditions. This paper explores how artificial intelligence (AI) can improve the efficiency and sustainability of urban traffic systems. By combining data from sensors, cameras, and mobile devices with predictive algorithms, an intelligent system dynamically optimizes traffic signals. Simulation results demonstrate shorter waiting times, reduced greenhouse gas emissions, and enhanced safety for pedestrians, public transport, and motorists. Emphasis is placed on fairness and inclusive mobility, ensuring that technological progress supports social equity. Importantly, the proposed approach is adaptable to diverse urban environments without major infrastructure overhauls.

Key words: artificial intelligence, smart city, sustainability, traffic.

PAMETNO UPRAVLJANJE PROMETOM ZA ODRŽIVE GRADOVEZoran Injac¹, Siniša Arsić², Miloš Arsić³, Joso Vrkljan⁴¹ Panevropski univerzitet Apeiron, 78000 Banja Luka, BiH; zoran.dj.injac@apeiron-edu.eu² Telekom Srbija, 11000 Beograd, Srbija, sinisaars@telekom.rs³ Univerzitet Privredna akademija, 21000 Novi Sad, Srbija, misaarsa@yahoo.com⁴ Veleučilište "Nikola Tesla" u Gospiću, 53000 Gospić, Hrvatska, jvrkljan@velegs-nikolatesla.hr

Sažetak: U današnjim gradovima, sve veća prometna potražnja i ograničeni kapacitet infrastrukture uzrokuju česta zagušenja, veće emisije i pad kvalitete života u urbanim sredinama. Konvencionalni sustavi upravljanja prometom, koji se oslanjaju na fiksno podešene semafore, teško se prilagođavaju uvjetima u stvarnom vremenu. Ovaj rad istražuje kako umjetna inteligencija (UI) može poboljšati učinkovitost i održivost urbanih prometnih sustava. Kombiniranjem podataka sa senzora, kamera i mobilnih uređaja s prediktivnim algoritmima, inteligentni sustav dinamički optimizira rad semafora. Rezultati simulacija pokazuju kraća vremena čekanja, smanjene emisije stakleničkih plinova i veću sigurnost za pješake, javni prijevoz i vozače. Naglasak je stavljen na pravednost i inkluzivnu mobilnost, osiguravajući da tehnološki napredak podržava društvenu jednakost. Važno je istaknuti da se predloženi pristup može prilagoditi različitim urbanim okruženjima bez velikih infrastrukturnih zahvata.

Ključne riječi: umjetna inteligencija, pametni grad, održivost, promet.

1. INTRODUCTION

Urban mobility plays a pivotal role in sustainable development, directly influencing economic growth, environmental quality, and social well-being. Efficient transport systems support commerce, reduce living costs, and improve access to essential opportunities and services. However, rapid urban expansion and rising motorization rates are driving increasing congestion, deteriorating air quality, and widening spatial inequalities. These challenges place significant pressure on transport infrastructure and represent a critical policy concern for achieving the Sustainable Development Goals (SDGs), particularly SDG 11 (Sustainable Cities and Communities) and SDG 13 (Climate Action).

Conventional traffic management approaches—largely based on fixed signal timings and heuristic control—are no longer sufficient for today's dynamic urban environments. Originally designed for stable and predictable flows, these systems cannot adequately address the stochastic nature of contemporary traffic shaped by ridesharing, freight logistics, public transport variability, and non-motorized travel. Nor are they capable of adapting in real time to accidents, roadworks, weather disruptions, or large-scale events. As a result, cities dependent on outdated traffic control systems face longer delays, increased emissions, and declining safety levels.

Equally important, traditional traffic designs have often prioritized private vehicles at the expense of pedestrians, cyclists, and transit users. This car-centric paradigm contributes to social inequities and environmental injustice, disproportionately affecting vulnerable groups and communities. A transition toward inclusive and sustainable mobility management is therefore essential—not only to improve operational efficiency, but also to ensure equity and resilience in urban mobility systems.

In this context, artificial intelligence (AI) offers transformative potential to reimagine traffic management. Leveraging real-time data from sensors, cameras, mobile devices, and connected vehicles, AI-powered systems can detect patterns, forecast congestion, and autonomously adjust traffic signal operations. Machine learning and reinforcement learning approaches enable adaptive, context-aware control that evolves over time, outperforming static or semi-adaptive legacy systems. Such systems can prioritize public transport and high-occupancy vehicles, reduce environmental impacts, and improve safety for all road users.

This paper introduces an AI-enhanced traffic signal management framework that integrates real-time data, predictive modeling, and adaptive signal control into a unified platform. Tested in a simulated mid-sized European city, the framework demonstrates reduced waiting times, lower greenhouse gas emissions, and more equitable outcomes for vulnerable users. Beyond technical feasibility, the proposed approach highlights the capacity of AI to support inclusive, sustainable, and future-ready urban mobility.

2. LITERATURE REVIEW

Urban traffic management has long been a central concern for transportation engineers and urban planners seeking to balance throughput, safety, accessibility, and sustainability. Over time, the field has shifted from rule-based, rigid systems toward more data-driven, adaptive, and intelligent approaches. Recent advances in sensing technologies, computing power, and artificial intelligence (AI) have accelerated this evolution, positioning AI as a transformative enabler of sustainable urban mobility.

2.1. Traditional and Adaptive Signal Control Systems

Historically, traffic control relied on fixed-time signal plans, where intersections followed predetermined schedules derived from historical traffic data. While easy to implement, such systems lacked flexibility and performed poorly under real-time fluctuations, leading to inefficiencies during off-peak hours or in response to unplanned events (Papageorgiou et al., 2003).

The emergence of Intelligent Transportation Systems (ITS) in the late 20th century introduced adaptive solutions such as SCATS (Sydney Coordinated Adaptive Traffic System) and SCOOT (Split Cycle Offset Optimization Technique). These systems utilized sensors and loop detectors to adjust signal timings based on real-time traffic conditions, representing a significant advance over static control. However, because they were rule-based, their adaptability was limited, and they often struggled with the complexity of modern multimodal urban environments. This limitation spurred interest in more autonomous and learning-based control frameworks.

2.2 Artificial Intelligence in Traffic Signal Control

With the rise of AI and machine learning (ML), traffic signal control began transitioning from heuristic adjustments to autonomous, learning-based optimization. Reinforcement learning (RL), particularly Q-learning, emerged as a popular method where intersections are modeled as agents that learn optimal policies through trial-and-error to minimize congestion (Wei et al., 2018). More advanced models, including Deep Q-Networks (DQN) and multi-agent RL (MARL), have enabled collaborative optimization across intersections, improving corridor-level efficiency and reducing congestion spillbacks (Kanis et al., 2021; Miletić et al., 2022).

Beyond RL, supervised learning approaches, such as support vector machines and gradient boosting, are applied for short-term traffic forecasting and anomaly detection (Zhao et al., 2024). Meanwhile, deep learning models—CNNs for vehicle detection from camera feeds and RNNs for time-series traffic prediction—are increasingly integrated into control systems (Zhang et al., 2020). Newer frameworks such as SafeLight embed safety constraints directly into RL reward functions, ensuring collision avoidance alongside efficiency gains (Du et al., 2022).

Together, these AI-based techniques offer a more flexible and context-aware alternative to legacy systems, with the ability to evolve and adapt to real-world uncertainties.

2.3 AI for Sustainable and Inclusive Urban Mobility

Beyond operational improvements, AI-driven traffic management is increasingly evaluated in terms of sustainability and equity. Studies consistently show that adaptive, AI-enhanced signal control reduces fuel consumption, CO₂ emissions, and noise pollution by minimizing stop-and-go cycles and smoothing traffic flow (Chen et al., 2021; Eteifa et al., 2025). Simulation-based analyses suggest emissions reductions of up to 30–40% along major corridors when AI is combined with eco-driving algorithms and transit signal priority.

At the same time, scholars highlight the importance of social equity in AI applications. Conventional systems have historically privileged private vehicles, disadvantaging pedestrians, cyclists, and public transport users. Emerging research emphasizes the integration of equity-focused performance metrics—ensuring that AI-driven mobility systems enhance accessibility and safety for vulnerable road users and underserved communities (Mitieka et al., 2023).

Looking forward, hybrid AI architectures combining reinforcement learning, supervised prediction, and optimization models show promise for achieving multi-objective goals—efficiency, sustainability, and inclusivity. Moreover, the development of explainable AI (XAI) and ethically aligned frameworks will be essential for building public trust and ensuring regulatory compliance.

3. CONCEPTUAL DESIGN FOR AI SMART CITY FRAMEWORK

This study employs a case study methodology to evaluate the effectiveness of an AI-based traffic signal control system, focusing on selected intersections in Banja Luka, the second-largest city in Bosnia and Herzegovina.

Banja Luka represents a suitable testbed for this research due to its mid-sized urban structure, growing motorization rates, and recurrent congestion at central intersections such as Kralja Petra I Karadorđevića Boulevard and Vojvode Stepe Stepanovića Boulevard.

3.1 Data Collection

To replicate realistic urban traffic conditions, multiple data sources were integrated:

- Traffic cameras located at key intersections (e.g., near the City Center and University campus) to capture real-time vehicle counts and congestion levels;
- Inductive vehicle sensors embedded in major boulevards, recording vehicle flow and lane occupancy;
- Mobile GPS data collected from navigation applications, providing information on travel speeds and congestion hotspots;
- Public transport feeds from city buses, tracking delays and schedule adherence, particularly along high-demand corridors;
- Historical data from the City of Banja Luka's Department of Transport was also incorporated to train supervised learning models for traffic forecasting.

3.2 AI Model Design

The proposed traffic signal management framework combines supervised learning and reinforcement learning:

- Supervised learning models (random forests and gradient boosting machines) were trained on historical traffic data to predict short-term traffic volumes and identify peak-hour trends;
- Reinforcement learning (RL) agents, modeled as individual intersections, learned adaptive signal policies through trial-and-error. Each agent received feedback based on waiting times, queue lengths, and emission levels, optimizing for multi-objective performance;
- A multi-agent RL framework was used to allow coordination between adjacent intersections, particularly along major corridors (e.g., Desanke Maksimović Boulevard).

3.3 Simulation Framework

The Simulation of Urban MObility (SUMO) platform was employed to model Banja Luka's road network. The network topology was reconstructed using OpenStreetMap data, including major intersections, traffic densities, and bus lines. Two scenarios were implemented:

- Baseline scenario – traditional fixed-timing signal control, calibrated using local signal plans from Banja Luka,
- AI-enhanced scenario – supervised learning for demand prediction combined with RL agents for adaptive control. Both scenarios were run under identical traffic conditions to ensure comparability.

3.4 Evaluation Metrics

To assess system performance, the following metrics were collected:

- Average vehicle delay time (seconds per vehicle).
- Queue lengths at intersections.
- Public transport punctuality, measured by deviation from scheduled arrival times.
- Environmental indicators, including estimated CO₂ emissions and fuel consumption, using SUMO's emission models.
- Equity indicators, such as waiting times for pedestrians and public transport vehicles compared to private cars.

3.5 Validation

To validate the simulation results, model outputs were compared with observed traffic patterns during morning and evening peak hours in Banja Luka. Additionally, sensitivity analyses were conducted by varying traffic demand levels (e.g., +20% increase during peak hours) to test system robustness.

4. DISCUSSION AND CONCLUSIONS

The findings of this study underscore the transformative potential of artificial intelligence (AI) in reimagining urban traffic management. By combining predictive modeling with real-time adaptive control, AI systems demonstrate a capacity to overcome the rigidity of traditional fixed-timing approaches and to respond dynamically to the stochastic nature of urban mobility. Unlike conventional systems that rely on static schedules, AI-based models continuously learn from live traffic data, adjusting signal plans to minimize delays, reduce congestion, and enhance resilience against sudden disruptions.

A critical implication of these results is that AI-driven traffic control need not be restricted to narrow efficiency gains. Instead, it can actively advance equity and sustainability objectives. By prioritizing buses, cyclists, and pedestrians alongside private vehicles, the system challenges the automobile-centric paradigm that has long shaped urban transport policy. In doing so, it aligns with broader planning principles that emphasize multimodality, inclusion, and environmental justice. This reframing positions AI not merely as a technical tool, but as a platform for redefining urban mobility priorities.

Nevertheless, the study also highlights important limitations and risks. First, the effectiveness of AI systems depends heavily on the availability, quality, and integration of data. Cities such as Banja Luka, where sensor infrastructure remains limited, face structural barriers to full implementation. Investments in data-sharing protocols, cross-agency collaboration, and sensor deployment are prerequisites for scaling AI solutions. Second, the use of GPS, camera, and mobile data raises significant privacy and governance concerns. Without strong safeguards—such as anonymization, encryption, and transparent data policies—public trust in AI-driven mobility systems may be undermined.

Another challenge lies in the “black box” problem of many AI algorithms. While reinforcement learning and deep learning approaches deliver strong performance, their opacity makes it difficult to explain decisions, audit outcomes, or ensure compliance with regulatory standards. This lack of interpretability could hinder public acceptance and institutional accountability. Research into explainable AI (XAI) should therefore be prioritized to balance transparency with efficiency.

System resilience also remains a critical gap. While AI systems are adaptive under normal conditions, their dependence on digital infrastructure makes them vulnerable to cyberattacks, hardware failures, or natural disasters. Future designs must incorporate redundancy, edge computing, and stress-testing under failure scenarios to ensure operational continuity. Finally, the contextual transferability of findings is limited. The results observed in a mid-sized European city like Banja Luka may not generalize to megacities in Asia or sprawling urban regions in the Global South. Tailored adaptations—sensitive to local traffic cultures, governance structures, and infrastructure maturity—are necessary for effective global deployment.

This study demonstrates that the integration of artificial intelligence into urban traffic signal systems offers substantial improvements in efficiency, sustainability, and equity. By leveraging supervised learning for predictive demand modeling and reinforcement learning for adaptive signal optimization, AI systems significantly reduce delays, smooth traffic flows, and lower greenhouse gas emissions.

Beyond efficiency, the framework embeds fairness into signal management, enhancing conditions for pedestrians, cyclists, and public transport users—groups historically disadvantaged in traditional traffic planning.

The proposed approach is notable for its scalability and cost-effectiveness, operating largely on existing infrastructure and allowing incremental adoption from pilot corridors to city-wide networks. This makes AI-based traffic control particularly relevant for mid-sized cities such as Banja Luka, which face growing congestion but lack resources for large-scale infrastructure overhauls.

At the same time, the study emphasizes that technological innovation alone is insufficient. Successful implementation will depend on robust governance frameworks, privacy protections, and explainable models that build trust among stakeholders and the public. Equally, interdisciplinary collaboration—between engineers, urban planners, policymakers, and ethicists—will be essential to ensure that AI deployments serve broader societal goals.

4.1 Implications

Policy: Cities should view AI as a tool for advancing SDG 11 (Sustainable Cities and Communities) and SDG 13 (Climate Action), embedding sustainability and equity objectives directly into traffic management.

Practice: Incremental rollouts, beginning with congested corridors, provide a practical pathway for adoption while testing system robustness in real-world conditions.

Research: Further exploration of explainable AI, hybrid models, and equity-oriented reward functions is necessary to make AI both technically powerful and socially accountable.

4.2 Limitations

Simulation-based evaluation may not fully capture real-world variability such as sensor noise, driver behavior, or political constraints.

Results from Banja Luka, while representative of mid-sized European cities, may not generalize to different cultural or infrastructural contexts.

Privacy, cybersecurity, and algorithmic transparency remain unresolved challenges requiring further study.

In conclusion, AI represents a strategic enabler for next-generation traffic systems. When deployed with attention to governance, ethics, and inclusivity, it can contribute not only to operational efficiency but also to the creation of urban mobility systems that are resilient, equitable, and environmentally sustainable. For cities navigating the twin challenges of rapid growth and climate change, AI-enhanced traffic management is no longer a speculative innovation—it is an urgent and actionable imperative.

REFERENCES

- [1] Gao, J., Shen, Y., Liu, J., Ito, M., & Shiratori, N. (2017). Adaptive Traffic Signal Control: Deep Reinforcement Learning Algorithm with Experience Replay and Target Network. arXiv preprint arXiv:1705.02755. doi:10.48550/arXiv.1705.02755
- [2] Mousavi, S. S., Schukat, M., & Howley, E. (2017). Traffic Light Control Using Deep Policy-Gradient and Value-Function Based Reinforcement Learning. arXiv preprint arXiv:1704.08883. doi:10.48550/arXiv.1704.08883
- [3] Liu, Y., Liu, L., & Chen, W.-P. (2017). Intelligent Traffic Light Control Using Distributed Multi-Agent Q Learning. arXiv preprint arXiv:1711.10941. doi:10.48550/arXiv.1711.10941

- [4] Ault, J., & Sharon, G. (2021). Reinforcement Learning Benchmarks for Traffic Signal Control. *Advances in Neural Information Processing Systems (NeurIPS) Workshop*. doi:10.48550/arXiv.2109.05538
- [5] Liang, X., Du, X., Wang, G., & Han, Z. (2019). Deep Reinforcement Learning for Traffic Light Control in Vehicular Networks. *IEEE Transactions on Vehicular Technology*, 68(2), 1243–1253. doi:10.1109/TVT.2018.2888703
- [6] Chu, T., Wang, J., Codecà, L., & Li, Z. (2019). Multi-Agent Deep Reinforcement Learning for Large-Scale Traffic Signal Control. *IEEE Transactions on Intelligent Transportation Systems*, 21(3), 1086–1095. doi:10.1109/TITS.2019.2917328
- [7] Wei, H., Zheng, G., Yao, H., & Li, Z. (2019). IntelliLight: A Reinforcement Learning Approach for Intelligent Traffic Light Control. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2496–2505. doi:10.1145/3219819.3220096
- [8] Zhang, R., Chen, X., Xu, Z., & Xie, L. (2020). Large-Scale Traffic Signal Control Using a Novel Multi-Agent Reinforcement Learning. *IEEE Transactions on Cybernetics*, 50(6), 2687–2700. doi:10.1109/TCYB.2019.2934402
- [9] Mannion, P., Duggan, J., & Howley, E. (2016). An Experimental Review of Reinforcement Learning Algorithms for Adaptive Traffic Signal Control. *Autonomous Road Transport Systems, Lecture Notes in Mobility*, 47–66. doi:10.1007/978-3-319-28183-4_3
- [10] Polson, N. G., & Sokolov, V. O. (2017). Deep Learning for Short-Term Traffic Flow Prediction. *Transportation Research Part C: Emerging Technologies*, 79, 1–17. doi:10.1016/j.trc.2017.02.024
- [11] Belletti, F., Haziza, D., Amin, S., & Bayen, A. M. (2018). Expert Level Control of Ramp Metering Based on Multi-Task Deep Reinforcement Learning. *IEEE Transactions on Intelligent Transportation Systems*, 19(4), 1198–1207. doi:10.1109/TITS.2017.2705759
- [12] Van der Pol, E., & Olthoek, F. A. (2016). Coordinated Deep Reinforcement Learners for Traffic Light Control. *NIPS Workshop on Learning, Inference and Control of Multi-Agent Systems*. doi:10.48550/arXiv.1609.01176
- [13] Kuyer, L., Whiteson, S., Bakker, B., & Vlassis, N. (2008). Multiagent Reinforcement Learning for Urban Traffic Control Using Coordination Graphs. *Proceedings of the 19th European Conference on Machine Learning*, 656–671. doi:10.1007/978-3-540-87479-9_66
- [14] Arel, I., Liu, C., Urbanik, T., & Kohls, A. G. (2010). Reinforcement Learning-Based Multi-Agent System for Network Traffic Signal Control. *IET Intelligent Transport Systems*, 4(2), 128–135. doi:10.1049/iet-its.2009.0070
- [15] El-Tantawy, S., Abdulhai, B., & Abdelgawad, H. (2013). Multiagent Reinforcement Learning for Integrated Network of Adaptive Traffic Signal Controllers. *Transportation Research Record: Journal of the Transportation Research Board*, 2356(1), 1–13. doi:10.3141/2356-01

UPRAVLJANJE PROMETOM NA CESTAMA KOJE VODE U LJUBLJANU

TRAFFIC MANAGEMENT AT LJUBLJANA RADIAL ROADS – SPEED MANAGEMENT

Robert Kompan, uni. dipl. ing. tehnol. prom.; robert.kompan@dars.si

DARS d. d.

Služba za upravljanje prometom i sigurnošću u prometu, Odjel za promet
Postojna; siječanj 2026.

SAŽETAK

DARS je proveo projekt »Upravljanje prometom na cestama koje vode u Ljubljani – *Speed management*« radi osiguranja bolje protočnosti prometa na najprometnijim dionicama autoceste. Glavni je cilj ovog projekta uskladiti prometne tokove uz pomoć opreme na trasama autoceste tijekom velikih prometnih opterećenja, što bi se ostvarilo smanjenjem brzine vozila, kako bi se dosegla veća (optimalna) prohodnost cesta na relevantnom području, a samim time smanjila i prometna zagušenost. Postupnim ograničavanjem brzine vozila na pojedinačnim dionicama ujedno se smanjuje razina buke i onečišćenja na tom području.

Projekt obuhvaća sve četiri ceste koje vode u Ljubljani i cjelokupni prsten ljubljanskih AC/BC.

U zadaći su predstavljeni detalji ugrađene opreme te funkcioniranje i učinci takvog sustava.

Ključne riječi: autocesta, nadzorni centar, gustoća prometa, upravljanje brzinom

To improve traffic flow on the motorway sections with the heaviest traffic, DARS has carried out the "Traffic Management at Ljubljana Radial Roads – Speed Management" project. The prime goal of the project is to harmonise traffic flows during periods of heavy traffic with the use of equipment along the motorway, in order to reduce vehicle speeds and therefore achieve better (optimal) road throughput in the area, and consequently fewer traffic jams. Gradual vehicle speed limitation on individual sections also reduces noise and pollution in that area.

The project included all four radial roads leading into Ljubljana and the entire MW/EW ring.

The task will present all the details of the integrated equipment, as well as the operations and effects of such system.

Sadržaj

1. UVOD	1
1.1. Definicija problema i cilj.....	1
2. PRIPREMA ZA PROVEDBU PROJEKTA DINAMIČKOG UPRAVLJANJA PROMETOM NA LJUBLJANSKOM PRSTENU I ULAZNIM CESTAMA	2
3. PERIFERNA OPREMA NA CESTAMA KOJE VODE U LJUBLJANU I U PRSTENU	3
3.1. Promjenjiva prometna signalizacija	4
3.2. Detekcija prometa mikrovalnim detektorima (MD) i detektorima petlje (DP).....	5
4. NADZORNI CENTAR	6
4.1. Funkcije sustava za nadzor i vođenje prometa (SNVP).....	6
5. MATRIČNI MODEL PROMETA	8
5.1. Funkcije upravljanja matričnim modelom	11
6. ZAKLJUČAK.....	12

1. UVOD

Slovenija se nalazi na sjecištu V. i X. koridora paneuropske prometne mreže i predstavlja važnu prometnu vezu između sjevera, juga, istoka i zapada Europe. Time je izravno opterećena slovenska cestovna mreža.

Slovenska mreža autocesta svake je godine sve opterećenija, što je dovelo do većeg oštećenja prometne infrastrukture i učestalijih prometnih zastoja. Zbog toga je Društvo za autoceste Republike Slovenije (DARS) pokrenulo projekt usmjeren na poboljšanje protočnosti prometa i povećanje sigurnosti u prometu optimalnim upravljanjem prometom i prometnim tokovima.

Učinkovito i kvalitetno upravljanje prometom ključno je za poboljšanje sigurnosti u prometu, pri čemu značajno doprinosi pravovremenom i pouzdanom informiranju korisnika o događajima i uvjetima na mreži autocesta.

1.1. Definicija problema i cilj

Zbog sve većeg opterećenja mreže autocesta dolazi do tzv. fantomskih prometnih zastoja, poput prometnih nesreća, zatvaranja ili radova na cesti, koji nastaju bez očitog uzroka. Navedeni zastoji uglavnom su posljedica prekomjerne gustoće prometa i neujednačenog protoka vozila, kad čak i lagano kočenje pojedinačnog vozača izaziva lančanu reakciju. Zbog toga se naglo smanjuje brzina prometnog toka, što može dovesti do iznenadnog zastoja koji se širi kolnikom. Fantomski zastoji značajno smanjuju protočnost, produžuju vrijeme putovanja i povećavaju rizik od sudara i prometnih nesreća. Jedan od glavnih ciljeva društva DARS sprječavanje je ili djelomično ublažavanje fantomskih zastoja.

Ovim stručnim člankom nastoji se predstaviti upravljanje i vođenje prometa na cestama koje vode u Ljubljani radi poboljšanja sigurnosti u prometu i protočnosti. Učinkovito vođenje prometa ujedno bi smanjilo broj izvanrednih događaja, osobito prometnih nesreća, kao i njihove posljedice. Glavni je cilj ovog projekta usklađivanje prometnih tokova uz pomoć opreme na trasama autoceste tijekom velikih prometnih opterećenja, što bi se ostvarilo smanjenjem brzine vozila kako bi se dosegla veća (optimalna) prohodnost cesta na relevantnom području, a samim time smanjila i prometna zagušenost. Postupnim ograničavanjem brzine vozila na pojedinačnim dionicama ujedno se smanjuje razina buke i onečišćenja na tom području.



Izvor: Interna literatura DARS d.d.: slovenska mreža autocesta

2. PRIPREMA ZA PROVEDBU PROJEKTA DINAMIČKOG UPRAVLJANJA PROMETOM NA LJUBLJANSKOM PRSTENU I ULAZNIM CESTAMA

Na ulaznim krakovima ljubljanske obilaznice, koje su među najprometnijim dionicama autoceste u državi, dolazi do značajnog ometanja prometa tijekom prometne špice. Zbog zastoja i velikih razlika u brzini vozila koja prelaze iz područja slobodnoga prometnog toka u područje zasićenog toka, odvijanje prometa nije stabilno i povećava se opasnost od sudara.

Optimizacijom postojećeg sustava upravljanja brzinom, DARS želi poboljšati prometne uvjete tijekom jutarnjih i popodnevnihih špica. Cilj je osigurati sigurnije odvijanje prometa u zagušenim područjima i maksimalno iskoristiti kapacitet mreže autocesta uz što homogeniji protok prometa.

U svrhu ispitivanja različitih koncepata upravljanja prometom, izrađena je prometna studija kao stručna osnova za uspostavu optimiziranog sustava upravljanja brzinom. U sklopu studije definirani su kriteriji i algoritmi za utvrđivanje stanja u prometu i njihov prikaz na portalima za promjenjivu prometnu signalizaciju. Primjenom mikroskopskoga prometnog modela uspoređeni su učinci različitih koncepata vođenja prometa na štajerskom i primorskom kraku autoceste tijekom jutarnje i popodnevne prometne špice.

Studija je obuhvaćala statističku analizu podataka, razvoj mikroskopskoga modela prometa, izvođenje scenarija upravljanja brzinom i završnu analizu rezultata.

Uz prometnu studiju, učinjena je analiza stanja prometne signalizacije na terenu te je utvrđen broj i vrsta dodatne periferne opreme za uspostavljanje sustava.

Sva nova periferna oprema uključena je u postojeći sustav nadzora i vođenja prometa te su koordinirane njihove (stare i nove) funkcije.

3. PERIFERNA OPREMA NA CESTAMA KOJE VODE U LJUBLJANU I U PRSTENU

Relevantno područje obuhvaća cijeli ljubljanski prsten i sve četiri autoceste koje vode u Ljubljano:

- Štajerski krak (od odmorišta Lukovica do uključujući čvora Zadobrova)
- Gorenjski krak (od nadzorne točke Torovo do uključivo čvora Koseze)
- Dolenjski krak (od priključka Višnja Gora do uključujući čvora Malence)
- Primorski krak (od odmorišta Lom do uključujući čvora Kozarje).

Periferna oprema predviđena projektom uključena je u postojeći sustav nadzora i vođenja prometa (SNVP) te je povezana s pripadajućim nadzornim centrima (CC) u Ljubljani, Kozini, Hrušici i Vranskom, iz kojih se provodi i operativno vođenje prometa. Određene lokacije nalaze se u područjima za koja je predviđeno tzv. dijeljeno upravljanje, što znači da su uređaji uglavnom povezani s primarnim (pripadajućim) nadzornim centrom, iako u određenim slučajevima upravljanje može preuzeti i sekundarni, tj. obližnji nadzorni centar.


Postavljanjem dodatnih senzora za detekciju prometa na trasama AC/BC prikupljaju se podatci o prometu u nadzornom centru (u sustavu SNVP), koji se obrađuju pomoću odgovarajućih prometnih algoritama radi automatskog izračuna stanja u prometu za svaku pojedinačnu funkcionalnu dionicu AC/HC. Na temelju određenih stanja u prometu sustav SNVP omogućava automatski prikaz odgovarajućega prometnog sadržaja na promjenjivoj prometnoj signalizaciji, kao što je ograničenje brzine te ostali načini informiranja i vođenja prometa.

Planiranjem je obuhvaćena obrada cjelokupne periferne opreme, uključujući:

- promjenjivu prometnu signalizaciju (PPS)
- mikrovalne detektore (MD)
- Bluetooth senzore (RS)
- lokalne postaje
- glavni koncentrator.

Plan obrade podijeljen je na dva dijela prema području obrade:

- plan cesta koje vode u Ljubljano
- plan ljubljanskog prstena.



Izvor: Interna literatura DARS d.d.; plan za postavljanje portala SPS u ljubljanskom prstenu

3.1. Promjenjiva prometna signalizacija

Znakovi SPS moraju omogućiti prikaz prometnog sadržaja i programa prometnog sadržaja koji se aktiviraju u sklopu načina vođenja prometa i informiraju vozače o stanju u prometu, nepovoljnim vremenskim uvjetima ili drugim izvanrednim događajima na cesti.

Najčešći su primjeri SPS znakovi ZIZ (znak – info – znak) i ZZZ (znak – znak – znak).





Izvor: Interna literatura DARS d.d.; primjer SPS – ZIZ, ZZZ

3.2. Detekcija prometa mikrovalnim detektorima (MD) i detektorima petlje (DP)

Mikrovalni detektori moraju omogućiti neometano prikupljanje podataka koji su potrebni sustavu za nadzor i vođenje prometa radi praćenja trenutačnog stanja u cestovnom prometu:

- Mjerenje protoka prometa prema pojedinačnim kategorijama vozila za pet klasifikacijskih razreda u skladu sa zahtjevima standarda TLS
- Mjerenje brzine prema pojedinačnim kategorijama vozila za pet klasifikacijskih razreda navedenih u prethodnoj točki
- Mjerenje vremenske zauzetosti mjernog područja
- Mjerenje vremenskog intervala između uzastopnih vozila
- Oglašavanje alarma za zaustavljeno vozilo u području detekcije s prilagodljivim vremenom prisutnosti vozila koje se smatra zaustavljenim (u koracima u trajanju od 1 sekunde)
- Oglašavanje alarma zbog vožnje u pogrešnom smjeru

Sastavni je dio MD-a pripadajuća programska oprema – odgovarajući softverski paket za analizu prometnih podataka prema klasifikacijskim razredima.

4. NADZORNI CENTAR

Kontrolori prometa u nadzornom centru upravljaju brojnim sustavima koji omogućuju učinkovito i kvalitetno upravljanje prometnim tokovima. U svojem radu koriste razne sustave videonadzora, upravljaju tunelima i pripadajućom prometnom signalizacijom, unose događaje u prometno-informacijski sustav (aplikacija Kažipot) te upravljaju drugom opremom vezanom za promet i cestovnu infrastrukturu.

Za vođenje prometa koriste sustav za nadzor i vođenje prometa (SNVP), putem kojeg portali za promjenjive prometne sadržaje na autocestama i uz njih informiraju korisnike autocesta o trenutačnom stanju u prometu, opasnostima i izvanrednim događajima. Pritom odgovarajuće mjere, osobito dinamička ograničenja brzine, doprinose boljoj protočnosti i većoj sigurnosti u prometu.


4.1. Funkcije sustava za nadzor i vođenje prometa (SNVP)

Sustav za nadzor i vođenje prometa (SNVP) uključuje nekoliko funkcija koje učinkovito pomažu kontrolorima prometa pri nadzoru i vođenju prometnih tokova. Uz osnovne funkcije, kao što je grafički prikaz trase autoceste i tunela s priključcima i čvorovima na karti, upravljanje promjenjivom prometnom signalizacijom i prikaz stanja u prometu prema dionicama i poddionicama, sustav omogućava:

- integraciju vremenskih podataka u sustav i upotrebu prethodno pripremljenih prometnih programa vremenskih alarma (smanjena vidljivost, vlaga, vjetar, poledica)
- provedbu prometnih programa za vođenje prometa tijekom zatvaranja pojedinih dionica
- provedbu prometnih programa za vođenje prometa u tunelima i njihovu području utjecaja
- automatsku aktivaciju programa na temelju detekcije vožnje u suprotnom smjeru
- prikaz povijesti postavljenih prometnih sadržaja.

Uz navedene funkcionalnosti, u protekloj je godini razvijen način dinamičkog upravljanja prometom putem matričnoga prometnog modela, što je značajna nadogradnja sustava koja postavlja nove standarde u području vođenja prometa i sigurnosti u prometu. Upotrebom matričnog modela poboljšala se informiranost korisnika autocesta na širem području. Također je ujednačeno upravljanje prometnom signalizacijom i skraćeno vrijeme odziva za kontrolore prometa.

Kako bi se osigurala visokokvalitetna i ujednačena upotreba sustava, provedene su brojne edukacije za kontrolore prometa koji operativno upravljaju sustavom.



Izvor: Interna literatura DARS d.d.: ljubljanska obilaznica s ulaznim cestama (SNVP)

5. MATRIČNI MODEL PROMETA

Sustav za nadzor i vođenje prometa omogućava vođenje prometa s obzirom na stanje u prometu kako bi se prilagođenom brzinom postigao optimalan protok i najveće moguće brzine za relevantnu prometnu potražnju.

Razina stanja u prometu utvrđuje se na temelju predviđene prosječne brzine svih vozila u prometnom toku i predviđene računske gustoće prometnog toka uzimanjem u obzir graničnih vrijednosti brzine i gustoće.

Za dvotračne i trotračne AC primjenjuju se različite granične vrijednosti, a PS se ne izračunava na ulaznim/izlaznim rampama.

U lokalnome prometnome modelu svakom je mjernomu mjestu dodijeljeno jedno ili više mjesta informiranja o razini stanja u prometu s obzirom na program prometnog sadržaja. U matričnome prometnome modelu svakomu mjestu informiranja dodijeljeno je jedno ili više područja PS koja sadrže mjerna mjesta.

Vođenje prometa s obzirom na stanje u prometu provodi se na temelju prometnog sadržaja koji se primjenjuje za 1D, 2D ili 3D matrični model.

U matričnome prometnome modelu svako mjesto informiranja (odabrani znak SPS) ima jedno, dva ili tri pripadajuća područja PS (ovisno o području koje utječe na mjesto informiranja) koja sadrže mjerna mjesta (MD/ZD/VD detektore). Pojedinačno mjesto informiranja može imati do tri pripadajuća područja PS čija razina stanja u prometu utječe na sadržaj na zaslonu SPS. Pojedinom području PS moguće je dodati proizvoljni broj mjernih mjesta.

Dimenzije matrice:

- 1-D znači da na mjesto informiranja utječe samo jedno područje PS, zajedno s mjernim uređajima unutar tog područja.
- 2-D znači da na mjesto informiranja utječu dva područja PS, zajedno s pripadajućim mjernim uređajima unutar ta dva područja.
- 3-D znači da na mjesto informiranja utječu tri područja PS, zajedno s pripadajućim mjernim uređajima unutar ta tri područja.

Za određivanje razine PS u području PS primjenjuje se najkritičnija vrijednost unutar područja s obzirom na najvišu razinu PS-a ili najniže ograničenje brzine. Ako mjerni uređaj unutar područja PS ne radi ili je u režimu rada, smatra se da mu je status PS 0.

Broj odabranih područja PS određuje veličinu matrice. Jedno područje PS rezultira matricom s pet kombinacija, dva područja PS rezultiraju matricom s 25 kombinacija, a tri područja PS rezultiraju matricom sa 125 kombinacija.

Primjer prikaza 1D matrice:

Scenarij	ZD-0044-8225	Prometna vsebina		
1	PS 0			
2	PS 1 (100)			
				
3	PS 2 (80)			
				
4	PS 3 (60)			
				
5	PS 4 (50)			
				

Izvor: Interna literatura DARS d.d.

Primjer prikaza 2D matrice:

Scenarij	Stajerski	Stajerska	Prometna vsebina		
1	PS 0	PS 0			
2	PS 0	PS 1 (100)			
3	PS 0	PS 2 (80)	100	UMPUJENO PRIJEDM MITREJE	100
			100	KEEP CALM AND ARRIVE FASTER	100
4	PS 0	PS 3 (60)	80		80
			80		80
5	PS 0	PS 4	80		80
			80		80
6	PS 1 (100)	PS 0	100	UMPUJENO PRIJEDM MITREJE	100
			100	KEEP CALM AND ARRIVE FASTER	100

Izvor: Interna literatura DARS d.d.

5.1. Funkcije upravljanja matričnim modelom

U gornjem desnom kutu znaka kontrolor prometa može odabrati načine rada matričnog modela prometa na odabranom znaku SPS.



Izvor: Interna literatura DARS d.d.: Konfigurator SPS

Raspoloživa su tri načina rada matričnog modela prometa:

- **Uključen matrični model prometa** – sadržaj na znaku SPS mijenja se u skladu sa sadržajem određenim u matrici. Svakom novom izmjenom briše se cijeli sadržaj na znaku SPS u skladu sa željenim stanjem.
- **Matrično samoograničenje brzine** – korisnik odabire ovu opciju ako je na znaku SPS prikazan sadržaj koji ne želi u potpunosti prebrisati matrični model, ali istovremeno želi da se ograničenja brzine koja predlaže matrični model prikazuju na znaku zajedno sa sadržajem. Ručni sadržaj na znaku SPS ostaje kakav jest (središnje polje i prometni znak ako se koristi), a dodaju se/mijenjaju samo ograničenja brzine. U slučaju PS 4: ako je neki sadržaj već prikazan na znaku, on se ne mijenja i uklanja se ograničenje brzine kod postojećeg sadržaja. Ovaj način rada isti je kao i prethodni kod lokalnog vođenja PS.
- **Isključen matrični model prometa** – matrični je model prometa isključen, a ručni je sadržaj na znaku zaključan (na temelju prioriteta briše se isključivo u slučaju vožnje u krivom smjeru i zatvaranja tunela).

Ikona	Stanje prometnega modela	Opis
	Matrični prometni model vklopljen	Vsebine na SPS znaku se menjajo skladno z matriko
	Matrično samo omejevanje hitrosti	Ročna vsebina na SPS znaku ostane, dodajajo/menjajo se le hitrostne omejitve (enako kot lokalno). V primeru PS 4: če je že neka vsebina na znaku, se ta vsebina ne spremeni oziroma se hitrostna omejitev pri obstoječi vsebini odstrani.
	Matrični prometni model izklopljen	Prometni algoritem je izklopljen, ročna vsebina na znaku je zaklenjena

Izvor: Interna literatura DARS d.d.

6. ZAKLJUČAK

Novi sustav dinamičnog upravljanja prometom velik je dobitak za operatera slovenske mreže autocesta. Već u prvoj godini uvođenja 2025., sustav se pokazao očekivanom, učinkovitim, korisnom i stručno opravdanom mjerom za poboljšanje prometnih uvjeta na najprometnijim dionicama.

Sustav omogućuje homogeniji protok prometa pružanjem naprednih informacija korisnicima na širem području te uvođenjem postupnih i prilagođenih ograničenja brzine. Time se smanjuje vjerojatnost stvaranja tzv. fantomskih zastoja, a istovremeno se poboljšava protočnost i značajno povećava sigurnost u prometu, ponajviše smanjenjem opasnih razlika u brzini i rizika od sudara.

Unatoč uspješnom uvođenju sustava, DARS kao operater mreže autocesta već usmjerava svoje aktivnosti prema daljnjem razvoju i nadogradnji rješenja u području inteligentnih transportnih sustava. Posebno je naglašeno jačanje integracije između različitih prometno-informacijskih i nadzornih sustava, poboljšanje automatizacije procesa i bolji odziv na izvanredne događaje. Na taj će se način dodatno povećati učinkovitost upravljanja prometom u budućnosti, poboljšati korisničko iskustvo i povećati cjelokupna sigurnost u prometa u slovenskoj mreži autocesta.

Suradnja vozača ključna je da bi sustav u potpunosti ostvario svoju svrhu i zaživio u praksi. Pridržavanje prikazanih ograničenja brzine značajno doprinosi uravnoteženijem prometnom toku, većoj protočnosti i, prije svega, većoj sigurnosti u prometu u slovenskoj mreži autocesta.

Kao upravitelj autocesta, DARS ulaže značajna sredstva u pružanje sigurnosti u prometu i poboljšanje protočnosti, iako i sami korisnici mogu značajno doprinijeti sigurnijem i učinkovitijem prometu. Radi se o odgovornom ponašanju koje izravno utječe na sigurnost svih sudionika u prometu, ali, što je još važnije, i na naše živote.

PREVENTIVNE AKTIVNOSTI SAVJETA ZA SIGURNOST PROMETA PGŽ ZA ZAŠTITU DJECE U PROMETU

¹ Prof.dr.Hrvoje Baričević, Primorsko-goranska županija, baricevichrvoje@gmail.com

² Izabela-Linčić Mužić, Primorsko-goranska županijai, izabela.lincic.muzic@gmail.com

³ Siniša Rajačić, Primorsko-goranska županija, sinisa.rajacic@gmail.com

Sažetak. Briga o djeci u prometu, odgovornost prema njihovoj dobrobiti i čuvanje njihova života direktno je povezano s načelima UN-ove Konvencije o pravima djeteta koja obvezuje sve institucije, grupe, pojedince i vlast u svakoj državi potpisnici. Na temelju iskustva iz dugogodišnjeg djelovanja Savjeta za sigurnost promet PGŽ može se determinirati agenda u prometnoj preventivi najmlađe populacije. Realizacija Plana i programa rada Savjeta usmjerena je na donositelje odluka i kreatore politika da svoje odluke temelje na istraživanjima, dokazima, primjenjivim rješenjima i izraženoj senzibilizaciji u prometnoj preventivi za njihovo fizičko i mentalno zdravlje. Djelovanje Savjeta uglavnom je fokusirano na preventivno-edukativne akcije kao što su Formiranje Školskih prometnih jedinice, Prvi koraci u prometu, Program prometne kulture za najmlađe (Jumicar Hrvatska), Sekunda koja znači život, biciklistička škola, suradnja s Pravobraniteljstvom RH za djecu i druge. U konačnici, kompleksnost te statistički pokazatelji ukazuje na ulogu i dosege Primorsko - goranske županije u promicanju povećanja stupnja sigurnost prometa na cestama kao paradigme djelovanja stručnih tijela regionalne samouprave.

Ključne riječi: prometna preventive, djeca, institucije, standardi, programska rješenja

1. UVOD

Savjet za sigurnost prometa na cestama Primorsko-goranske županije kontinuirano provodi preventivne aktivnosti u promicanju prometne kulture i sigurnosti za najmlađe sudionike u prometu (Prvi koraci u prometu, prometni poligoni ispred dječjih vrtića, školske prometne jedinice, biciklistička škola i dr.). Na taj način ističe važnost edukacije o prometu svih dobnih skupina mlade populacije tj. od predškolskog do školskog uzrasta. Posebna pažnja i senzibilitet iskazuje se zbog njihovih specifičnih psihosocijalnih, motoričkih i perceptivnih karakteristika koje ih čine ranjivom kategorijom u strukturi svih sudionika u prometu. Nesporna činjenica je da se prve spoznaje o prometnoj kulturi dobivaju u obiteljskom okruženju, ali i društvena zajednica i institucije dužni su dati svoj doprinos u stvaranju navika i poučavanja o zakonitostima sigurnog kretanja u svojstvu pješaka, putnika kao i kod upravljanja osobnim prijevoznim sredstvima. Informacije o stradavanju djece govore nam da se djeca protivno propisima prevoze u osobnim automobilima. Očito je da su, unatoč nizu preventivnih i represivnih aktivnosti policije, djeca u prometu nedovoljno zaštićena, pa čak i kad ih prevoze roditelji ili drugi članovi obitelji. Dopuštanje djeci da prije stjecanja tog prava upravljaju osobnim automobilima, motociklima, mopedima, traktorima, neregistriranim vozilima i biciklima bez prethodne osposobljenosti s obzirom na dob, bez kacige i reflektirajuće opreme, kao i kretanje novim prijevoznim sredstvima, te nepropisni prijevoz djece u osobnim vozilima (bez sigurnosne sjedalice/postolja i sigurnosnog pojasa) predstavljaju zanemarivanje djece i kršenje njihovih prava, na što što treba ukazivati u svim prilikama u svim prilikama.

2. FORMALNOPRAVNI STATUS DJECE KAO RANJIVE SKUPINE SUDIONIKA U PROMETU

Sigurnost djece u prometu proizlazi zbog njihovih dobnih ograničenja, neiskustva i nedostatnog sagledavanja mogućih opasnosti i rizika. Djeca su briga i odgovornost odraslih koji moraju poduzeti sve kako bi djeca ostvarila svoje pravo na život i razvoj, na što ih obvezuje Konvencija o pravima djeteta Ujedinjenih naroda, koja globalno obvezuje države već 35 godina, a Republiku Hrvatsku od samo osnutka tj. od 1991.g.

Deklarativno, briga o djeci u prometu, odgovornost prema njihovoj dobrobiti i čuvanje njihova života direktno je povezano s četiri načela UN-ove Konvencije o pravima djeteta koja obvezuje sve institucije, grupe, pojedince i vlast u svakoj državi potpisnici. Ova načela, osim što je svako od njih i dječje pravo, sadrže u sebi sva druga prava te daju smisao pojedinim odredbama Konvencije. Načelo o nediskriminaciji i jednakosti određuje da svako dijete ima ljudska prava bez obzira na to tko je, gdje živi, čime mu se bave roditelji, kojim jezikom govori, je li dječak ili djevojčica, iz koje kulture potječe, ima li neku teškoću u razvoju, je li bogato ili siromašno. Načelo o dječjem sudjelovanju govori o tome da dijete ima pravo izraziti svoje mišljenje, a odrasli ga trebaju poslušati i ozbiljno razmotriti. Razmatranje najboljeg interesa djeteta je načelo koje kaže da odrasli trebaju postupati onako kako je najbolje za dijete, a kada donose odluke trebaju misliti na to kako će njihove odluke utjecati na djecu. A kada je riječ o sigurnosti i preživljavanju djeteta u prometu, valja krenuti od četvrtog načela koje se odnosi na djetetovo pravo na život i razvoj u svim vidovima života. Temeljni uzroci prometnih nesreća, poznatih kao tzv. glavne „ubojice“ u cestovnom prometu, zbog čijih posljedica pate i djeca i odrasli, prekoračenje brzine kretanja vozila, korištenje mobitela tijekom vožnje, nekorištenje sigurnosnog pojasa i upravljanje vozilom pod utjecajem alkohola. Djeca su često ugrožena i kada im se neopravdano i prije stjecanja prava dopušta da upravljaju biciklima, raznim vrstama motornih vozila poput motora, osobnih vozila, traktora, quadova i novih prijevoznih sredstava, kao što su električni romobili. Osim što su, kao i njihovi roditelji, djeca izložena prometnom stresu, izložena su i prometnoj buci čije posljedice uključujući i zagađenjem zraka trebaju imati važnu ulogu u prometnom planiranju. Stockholmska deklaracija iz 2020. godine o sigurnosti na cestama i postizanju ciljeva do 2030. govori o tome da sigurnost na cestama treba biti integrirana u druga područja javnih politika, posebice u politikama vezanim za klimatske

promjene, jednakost spolova, zdravlje i dobrobit, kvalitetno obrazovanje, smanjenje nejednakosti, održive gradove i zajednice, infrastrukturu i odgovornu potrošnju i proizvodnju. Naglašava i da bi trebalo zajednički raditi na razmjeni iskustava o usvajanju i provedbi zakona o rizičnim ponašanjima, kao što su prebrza vožnja, vožnja pod utjecajem alkohola te nekorištenje sigurnosnih pojaseva, sigurnosni sustavi za djecu i motociklističke kacige i provedba mjera za ublažavanje takvih rizika, što bi moglo spasiti stotine života godišnje, ali još uvijek nije usvojeno u većini zemalja. Deklaracija prepoznaje i specifične i raznolike izazove sigurnosti na cestama i održivosti u urbanim i ruralnim područjima, kao i rastuće prijetnje za ranjive sudionike u gradskom prometu. Također se u njoj navodi da je zajednička odgovornost da kreatori prometnih sustava i sudionike u prometu potaknemo da prihvate ideju svijeta bez smrtnih slučajeva i ozbiljnih ozljeda u cestovnom prometu.

3. OPERACIONALIZACIJA TEORETSKIH I PRAKTIČNIH PROGRAMA ŽUPANIJSKOG SAVJETA

3.1. Prvi koraci u prometu

Prometno preventivna akcija Prvi koraci u prometu provodi se od samog osnutka Savjeta tj. od 1998. godine, godišnje obuhvati više od dvije tisuće učenika prvih razreda osnovnih škola Primorsko–goranske županije. Akcija se izvodi u formi jednodnevne nastave kroz koju se djeca prvi put susreću sa samostalnim kretanjem u prometu, usvajaju teoretska i praktična znanja na prometnom poligonu. Program realiziraju djelatnici Doma mladih u suradnji s Policijskom upravom primorsko-goranskom, Županijskim savjetom za sigurnost prometa na cestama, Upravnim odjelom za odgoj i obrazovanje Primorsko–goranske županije te Upravnim odjelom za odgoj i obrazovanje, kulturu, sport i mlade Grada Rijeke. Akcija je jedna od glavnih okosnica borbe za bolju prometnu sigurnost najmlađe populacije na interdisciplinarnim temeljima i problema s kojim se cijeli svijet bori svim mogućim sredstvima. sigurnosti prometa, interdisciplinarnog i teško rješivog problema. U fokusu akcije su djeca koja bi ipak iz svog doma trebala preuzeti najviše iskustava po pitanju sigurnog sudjelovanja u prometu. I Hrvatska i svijet prepoznaju svu složenost sudjelovanja djece u prometu. Preventivni rad s djecom zahtjeva puno ulaganja i senzibilitet, ali treba znati da je mjesto djece u prometu izuzetno važno u svim segmentima. Školski sustav mora poticati i usaglašavati sadržaje učenja s ostalim područjima učenja i sazrijevanja. Prometni stručnjaci uz podršku politike kontinuirano pokušavaju u školske kurikulume uključiti prometne teme, ali sve to ide vrlo sporo. Svi sudionici ove akcije smatraju da je ista za svaku pohvalu te da je projekt Prvi koraci u prometu najdugovječniji projekt u kojem sudjeluju praktički sve škole u gradu Rijeci i primorsko-goranskoj županiji. Namijenjena učenicima prvih razreda, a realizira se u Domu mladih Rijeka u suradnji s brojnim partnerima: Prometnom policijom Policijskom upravom Primorsko-goranske županije, Upravnim odjelom za odgoj i obrazovanje, kulturu, sport i mlade Grada Rijeke, te Upravnim odjelom za odgoj i obrazovanje Primorsko-goranske županije. Nastava se izvodi u obliku jednodnevnog programa – teorijski dio održava se u prometnom kabinetu, dok se praktični dio izvodi na prometnom poligonu Doma mladih.



*Slika 1: Sudionici akcije u Domu mladih u Rijeci
(izvor: autori)*

3.2. Program prometne kulture za najmlađe

Program prometne odnosno preventivne kulture za najmlađe sudionike postoji već 30 godina u Europi. Pokrenut je u Finskoj, a ideja je bila da se kreativno na didaktičko-pedagoškim osnovama pokuša približiti problematika sudjelovanja najmlađe populacije u prometu. Programski njegovi ciljevi i koncepcija u RH usklađeni su sa strateškim odrednicama Nacionalnog programa sigurnosti cestovnog prometa Republike Hrvatske 2021.-2030., kao i sa svim relevantnim međunarodnim dokumentima. Načelno se provodi u zatvorenim i otvorenim prostorima škola, a namijenjen je učenicima nižih razreda. Sastoji od dvije međusobno povezane interaktivne komponente:

a) Teoretski dio:

- posebno educirani predavači poučavaju učenike pomoću multimedijskog prikaza stvarnih rizika u prometu kao i o značenju horizontalne i vertikalne signalizacije;
- u ovom dijelu djeca usvajaju teoretska znanja o pravilnom/nepravilnom ponašanju pješaka i biciklista, ponašanju u javnom prijevozu, svrsi reflektirajuće odjeće te raspoznavanju zvučnih i svjetlosnih signala u prometu.

b) Praktični dio:

- Mobilni poligon je realna simulacija stvarnog prometa koji se sastoji od semafora, prometnih znakova, graničnika, pješačkih prijelaza, mini automobila na električni pogon i drugih didaktičkih pomagala koja su prilagođena uzrastu djece.
- Cilj ovog dijela programa je da djeca dobiju mogućnost iz perspektive vozača uvidjeti što znači upravljati pravim automobilom, odnosno što znači: zaustaviti/pokrenuti automobil, procijeniti brzinu kretanja nadolazećeg automobila, što za vozača znači napetost, adrenalin, strah, koncentracija, umor, orijentacija, motoričke sposobnosti, dezorijentacije i dr., a sve kako bi postali sigurniji sudionici u prometu. Glavna ideja Programa je da djeca lakše usvajaju znanja kroz igru, nego pukim memoriranjem informacija. Tijekom godina program se temeljem originalne ideje proširio izvan granica Finske te se sada provodi u velikom broju europskih (Njemačka, Grčka, Portugal, Turska, Slovenija, Austrija i Hrvatska) i svjetskih (Katar, Ujedinjeni Arapski Emirati) zemalja. U Programu je do sada sudjelovalo preko milijun djece i sva pozitivna i negativna iskustva stečena kroz provedbu ovog Programa iskorištena su kako bi se Program unaprijedio i poboljšao. Njegova kvaliteta prepoznata je i na europskoj razini sukladno čemu je postao integralni dio Europske povelje za sigurnost cestovnog prometa Europske Komisije (The European Road Safety Charter).



*Slika 2: Praktični dio akcije Prometna preventiva za najmlađe u OŠ Kostrena
(Izvor: autori)*

3.3. Izgradnja prometnih poligona u dječjim vrtićima

Prometni poligoni su važan alat za edukaciju djece školske i predškolske dobi. Na njima se simuliraju različite situacije iz realnog svijeta prometa s fokusom na incidentna događanja. Time stječu prometnu kulturu, iskustva i znanja koja će koristiti kroz cijeli život. Poligoni se rade u smanjenim dimenzijama te je stoga potreban manji prostor i manje materijala. To smanjuje troškove investicije. Edukacija na poligonima nije jedino rješenje, ali se može smatrati jednim originalnim rješenjem sa stigmatiziranom tradicijom. Djeca se na poligonu mogu suočiti s prometnim znakovima, pružnim prelazima, horizontalnom i vertikalnom signalizacijom, svjetlosnim signalima i drugom opremom i uređajima. U godišnjim planovima i programima savjeta kontinuirano se daje podrška ključnim dionicima ovog originalnog poduhvata. Naime, Veleučilište u Rijeci-Prometni odjel i Dječji vrtić Rijeka potpisali su Sporazum o suradnji u provedbi edukacije i mjera u cilju povećanja sigurnosti djece u prometu. Jedan od oblika suradnje je izrada projekata poligona u dječjim vrtićima. Studenti koji su pokazali izniman interes, kreativnost i želju na ovim zadaćama u suradnji i podršku profesora izradili su više varijanti poligona na razini izvedbenih projekata, te uz procjenu investicijskih troškova. Tako se otvorio put za provođenje integrirane suradnje odgojno-obrazovnih i visokoškolskih institucija. Županijski savjet je pozitivno ocijenio predložene projekte, te je financirao projekte putem Odjela za pomorsko dobro, promet i veze odnosno. Poligoni sadrže standardne dvotračne i jednotračne prometnice, klasična pravokutna i kružna raskrižja, autobusna stajališta, parkirna mjesta, biciklističke i pješačke staze i trake, nogostup, zelene površine, prometnu signalizaciju i svjetlosne signalne uređaje na prenosivim gumenim postoljima.



Slika 3: Prometni poligon u dječjem vrtiću Đurđice u Rijeci
Izvor: autori

3.4. Suradnja sa Pravobraniteljstvom za djecu

Inicijativa Ureda pravobraniteljice za djecu Republike Hrvatske posljednjih godina usmjereno je i na zaštitu djece u prometu. U tome ima punu podršku Županijskog savjeta kroz prezentacije na radnim sjednicama, podršku u izdavačkoj djelatnosti i na druge načine. Primjerice u Ravnateljstvu policije održano je predstavljanje zbornika radova i okrugli stol na temu „Dječja prava u prometu“. Na ovom značajnom događanju u kontekstu prometne preventive najmlađe populacije sudjelovali su brojne relevantne institucije i pojedinci, te je naglašena uloga Nacionalnog plana sigurnosti cestovnog prometa. U današnje vrijeme prisutni zabrinjavajući trendovi među djecom u prometu te su prezentirani statističke pokazatelje Ministarstva unutarnjih poslova. Zbornik Ovaj Zbornik, nije samo pregled statističkih pokazatelja o broju nesreća, vrstama ozljeda, o povredama dječjih prava. On ne prikazuje samo stanje, prepreke i izazove, već procese kojima se dolazi do ishoda i ciljeva. On je poziv za djelovanje i promjenu javnih politika i pristupa. U tim promjenama, nikako se ne smiju zaboraviti na djecu i njihovo pravo da su kreiraju svijet u kojem žive. Poražavajuća je statistika da gotovo 60 % djece strada u prometnim nesrećama kao putnici u vozilima i to najčešće u vozilima roditelja i/ili najbližih osoba. „Posljednja aktualnost na koju moramo ukazati jest upozorenje za roditelje i odrasle da djeci ne kupuju električne romobile ako nisu navršila dobnu granicu od 14 godina, a onima koji imaju dovoljno godina objasne najosnovnija prometna pravila i prometne propise“, rečeno je od strane Policije. Ova jedinstvena edicija rezultat je dugogodišnjeg rada te je presjek interdisciplinarnih poimanja sigurnost prometa, a na tragu održanog istoimenog savjetovanja na Veleučilištu u Rijeci. Kroz sustavna istraživanja te s brojnim alatima u svim segmentima prometne preventive i represive nužno je smanjiti smrtnost i ozljeđivanje najmlađe populacije.

4. ZAKLJUČAK

Zaključno, akceptirano je da je briga o djeci u prometu, odgovornost prema njihovoj dobrobiti i čuvanje njihova života direktno povezano s načelima UN-ove Konvencije o pravima djeteta koja obvezuje sve institucije, grupe, pojedince i vlast u svakoj državi potpisnici. Ova načela, osim što je svako od njih i dječje pravo, sadrže u sebi sva druga prava te daju smisao pojedinim odredbama Konvencije. Načelo o nediskriminaciji i jednakosti određuje da svako dijete ima ljudska prava bez obzira na podrijetlo i okruženje u kojem živi, je li bogato ili siromašno. Načelo o dječjem sudjelovanju govori o tome da dijete ima pravo izraziti svoje mišljenje, a odrasli ga trebaju poslušati i ozbiljno razmotriti. Djeca u prometu reagiraju nepredvidivo, spontano i zaigrano, često ne poznajući prometna pravila niti procjenjujući opasnost, brzinu i udaljenost vozila. Zbog nižeg rasta imaju smanjenu preglednost, a vozači ih teže uočavaju. Često su zaokupljeni igrom, što zahtijeva maksimalan oprez vozača koji nikada ne bi smjeli očekivati da će se dijete zaustaviti. Ključne karakteristike ponašanja djece u prometu jesu: nepredvidivost tj. mogu iznenada istrčati na cestu, zaustaviti se ili promijeniti smjer kretanja, smanjena procjena tj. ne mogu točno procijeniti brzinu i udaljenost vozila, vidno polje tj. zbog niskog rasta, djeca imaju sužen pogled na prometnu situaciju, zaigranost tj. često su fokusirani na igru, a ne na opasnosti u okolini, oponašanje tj. djeca u prometu često ponavljaju pogreške roditelja. Savjeti za sigurnost su uglavnom univerzalni. Primarno, najvažnija je edukacija! Roditelji trebaju s djecom uvijek baviti sigurn put do škole i učiti ih pravilima. Glede uočljivosti u trebaju koristiti reflektirajuće materijale na odjeći, posebno u uvjetima smanjene vidljivosti. Poboljšanje cestovne sigurnosti za djecu može se postići kombiniranim skupom mjera na svim društveno-političkim razinama, provođenjem prometnih zakona, promicanjem ispravne upotrebe odgovarajućih sigurnosnih sustava za dijete, poboljšanjem odgoja i obrazovanja o cestovnom prometu itd. Razmatranje najboljeg interesa djeteta je načelo koje kaže da odrasli trebaju postupati onako kako je najbolje za dijete, a kada donose odluke trebaju misliti na to kako će njihove odluke utjecati na djecu. U konačnici, kompleksnost te statistički pokazatelji ukazuje na ulogu i dosege Primorsko - goranske županije u promicanju povećanja stupnja sigurnost prometa na cestama kao paradigme djelovanja stručnih tijela regionalne samouprave. Preventivne mjere u svim svojim modalitetima mogu se smatrati jednim od ključnih odgovora na poboljšanje stupnja prometne sigurnosti djece.

LITERATURA

- [1] Baričević, H., Lisac, Z., Perić, M.: Promidžbene aktivnosti Savjeta za sigurnost prometa Primorsko-goranske županije, TOM signal, d.o.o, Rovinj, 2018.
- [2] Barišić, I., Tomić, I., (2019). Mjere i aktivnosti za povećanje sigurnosti djece u prometu, Zbornik radova, 43. Međunarodni stručni seminar o prometnoj infrastrukturi i sigurnosti u prometu, Rovinj, str. 161
- [3] Deluka-Tibljaš, A., Šurdonja, S., Ištoka Otković, I., & Campisi, T. (2022). Child-pedestrian traffic safety at crosswalks—literature review.
- [4] Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija – Ususret europskom području sigurnosti na cestama: smjer politike cestovne sigurnosti za razdoblje 2021-2030.
- [5] Mikuš, Lj: Prikaz edukativnog programa za sigurnije ponašanje u prometu djece-pješaka i roditelja, u Knjiga sažetaka 25. godišnje konferencije hrvatskih psihologa, Zadar, 2017
- [6] Pravobranitelj za djecu RH: Dječja prava u prometu, Zbornik radova, Zagreb, 2025.
- [7] www.ak-rijeka.hr
- [8] www.etsc.eu/Reducing Child Deaths on European Roads,
- [9] www.dijete.hr/hr/ Ured pravobranitelja za djecu

[10] www.pgz.hr

[11] www.mup.hr/ Nacionalni program sigurnosti cestovnog prometa

PROCJENA SIGURNOSTI CESTOVNE MREŽE REPUBLIKE HRVATSKE PRIMJENOM NWRSA METODOLOGIJE

Marijan Jakovljević¹, Mario Mataija², Željko Šarić³, Marko Ševrović⁴

¹ doc. dr. sc., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, mjakovljevic@fpz.hr

² mag. ing. traff., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, mmataija@fpz.hr

³ izv. prof. dr. sc., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, zeljko.saric@fpz.hr

⁴ izv. prof. dr. sc., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, msevrovic@fpz.hr

Sažetak

U radu je provedena procjena sigurnosti cestovne mreže Republike Hrvatske primjenom metodologije Network-Wide Road Safety Assessment (NWRSA), u skladu sa smjernicama Europske komisije i važećim nacionalnim regulatornim okvirom. Procjena obuhvaća autoceste, ceste transeuropske prometne mreže (TEN-T) te primarne ceste, a temelji se na kombinaciji reaktivnog i proaktivnog pristupa. Cestovna mreža segmentirana je na homogene dionice sukladno EC NWA metodologiji, pri čemu je reaktivni pristup proveden analizom višegodišnjih podataka o prometnim nesrećama uz primjenu statističkih pokazatelja rizika, dok je proaktivni pristup temeljen na analizi prometno-tehničkih i geometrijskih karakteristika ceste, uključujući konverziju iRAP ocjena u EC NWA format. Integracijom rezultata oba pristupa definirane su sigurnosne kategorije i razine prioriteta za pojedine dionice cestovne mreže. Dobiveni rezultati omogućuju objektivno rangiranje dionica prema razini rizika te predstavljaju pouzdanu osnovu za identifikaciju dionica s povećanim sigurnosnim rizikom i planiranje daljnjih ciljanih sigurnosnih analiza i mjera poboljšanja sigurnosti prometa.

Ključne riječi: analiza rizika, NWRSA metodologija, procjena sigurnosti cestovne infrastrukture, sigurnost cestovnog prometa

ROAD NETWORK SAFETY ASSESSMENT IN THE REPUBLIC OF CROATIA USING THE NWRSA METHODOLOGY

Abstract

This paper presents an assessment of road network safety in the Republic of Croatia using the Network-Wide Road Safety Assessment (NWRSA) methodology, in line with European Commission guidelines and the national regulatory framework. The assessment includes motorways, Trans-European Transport Network (TEN-T) roads, and primary roads, and is based on a combination of reactive and proactive approaches. The road network was segmented into homogeneous sections in accordance with the EC NWA methodology. The reactive approach involved the analysis of multi-year road traffic accident data using statistical risk indicators, while the proactive approach focused on traffic-technical and geometric road characteristics, including the conversion of iRAP ratings into the EC NWA format. Integration of both approaches enabled the definition of safety categories and priority levels, supporting

objective risk-based ranking of road sections and identification of high risk sections for further safety analyses and improvement measures.

Keywords: NWRSA methodology, risk analysis, road infrastructure, road traffic safety, safety assessment

1 UVOD

Procjena sigurnosti cestovne infrastrukture predstavlja jedan od temeljnih elemenata suvremenog upravljanja prometnim sustavima jer omogućuje sustavno prepoznavanje, kvantificiranje i rangiranje sigurnosnih rizika na postojećoj cestovnoj mreži. Njezina je osnovna svrha povećanje razine sigurnosti svih sudionika u prometu kroz identifikaciju dionica s povišenim rizikom od prometnih nesreća te planiranje i provedbu ciljanih i učinkovitih korektivnih mjera. Takav pristup ne doprinosi samo smanjenju broja i težine prometnih nesreća, već i racionalnijem korištenju financijskih sredstava te smanjenju ukupnih društveno-gospodarskih troškova povezanih s njihovim posljedicama.

U Republici Hrvatskoj procjena sigurnosti cestovne mreže provodi se u skladu s nacionalnim zakonodavnim okvirom i propisima Europske unije, posebice Direktivom (EU) 2019/1936, kojom je propisana obveza redovitog provođenja procjene sigurnosti mreže na cestama koje su dio transeuropske prometne mreže (TEN-T), autocestama i ostalim primarnim cestama. Postupak se temelji na kombinaciji reaktivnog i proaktivnog pristupa, pri čemu reaktivni pristup uključuje analizu povijesnih podataka o prometnim nesrećama, dok se proaktivni pristup usmjerava na vrednovanje prometno-tehničkih i infrastrukturnih obilježja cesta, poput geometrijskih elemenata, preglednosti, razine zaštite od bočnih opasnosti i potencijalnih konflikata s ranjivim skupinama sudionika u prometu.

Rezultati ovakve procjene omogućuju upraviteljima cesta objektivno definiranje prioriteta ulaganja te usmjeravanje ograničenih resursa na dionice cestovne mreže na kojima se može ostvariti najveći sigurnosni učinak. Osim toga, procjena sigurnosti cestovne mreže predstavlja važnu podlogu za izradu kratkoročnih, srednjoročnih i dugoročnih investicijskih planova te za sustavno praćenje promjena sigurnosnog stanja cestovne infrastrukture kroz vrijeme. Redovito i standardizirano provođenje ovog postupka osigurava donošenje odluka temeljenih na podacima i znanstveno utemeljenim metodama te doprinosi ostvarenju nacionalnih i europskih ciljeva usmjerenih na smanjenje broja poginulih i teško ozlijeđenih osoba u cestovnom prometu.

2 NETWORK-WIDE ROAD SAFETY ASSESMENT METODOLOGIJA


Metodologija procjene sigurnosti cestovne mreže (NWRSA) temelji se na smjernicama Europske komisije definiranim u Network Wide Road Safety Assessment Handbooku [1] te na nacionalnim Smjernicama za provođenje procjene sigurnosti mreže TEM cesta, autocesta i primarnih cesta [2] koje su prilagođene hrvatskom zakonodavnom okviru. Ovaj pristup osigurava usklađenost s Direktivom (EU) 2019/1936 Europskog parlamenta i Vijeća kojom se propisuje obveza redovitog provođenja sigurnosnih procjena na cestama koje su dio transeuropske prometne mreže (TEN-T), autocestama te ostalim primarnim cestama. Prema tome postupak NWRSA u Republici Hrvatskoj je moguće provesti kroz dvije istaknute metodologije: EC NWA (European Commission Network-Wide Assessment) i iRAP (International Road Assessment Programme) metodologije. Razvijena od strane Europske komisije,

EC NWA metodologija preporučena je u državama članicama Europske unije. Kako se u Republici Hrvatskoj iRAP ocjena zvjezdicama provodi dugi niz godina na cestama podložnima Direktivi EC 2019/1936 smjernicama su date preporuke za integraciju između ove dvije metodologije.

Metodološki gledano procjena sigurnosti mreže cesta sastoji se od niza povezanih koraka koji omogućuju sveobuhvatno sagledavanje sigurnosnog stanja prometne infrastrukture. Postupak se provodi u tri osnovne faze:

1. segmentacija cestovne mreže,
2. reaktivna i proaktivna analiza,
3. integracija rezultata i određivanje sigurnosnih kategorija.

Svrha metodologije je pružiti jasan, standardiziran i ponovljiv postupak kojim se cjelokupna mreža cesta ocjenjuje prema razini rizika, čime se omogućuje usporedivost rezultata i usmjeravanje budućih ulaganja u sigurnost prometa. Proces provođenja postupka NWRSA u Republici Hrvatskoj dat je na slici u nastavku. Također u nastavku poglavlja dat je sažeti prikaz metodološkog okvira prema prethodno navedenim smjernicama dok se u istim nalazi detaljno opisana metodologija.



Slika 1. Hodogram provođenja postupka NWRSA u Republici Hrvatskoj [2]

2.1.1 Faza segmentacije cestovne mreže

Segmentacija predstavlja temeljni korak u procesu procjene sigurnosti jer omogućuje podjelu cestovne mreže na manje, homogeno definirane dijelove koji se mogu samostalno analizirati. Cilj segmentacije je osigurati da svaki cestovni segment ima što sličnije prometno i infrastrukturno okruženje kako bi se procjena rizika temeljila na usporedivim uvjetima.

2.1.2 Reaktivni pristup

Reaktivni pristup temelji se na analizi povijesnih podataka o prometnim nesrećama. Ova metoda omogućuje identifikaciju dionica s visokom koncentracijom prometnih nesreća te objektivno rangiranje prema stupnju rizika. Prema NWA Smjernicama, osnovni koraci reaktivnog postupka su:

- prikupljanje podataka o prometnim nesrećama – podaci moraju obuhvatiti razdoblje od najmanje tri godine i uključivati sve nesreće s poginulima ili ozlijeđenima, za sve vrste sudionika (vozači, motociklisti, biciklisti, pješaci);
- definiranje referentne populacije – skup cestovnih segmenata sličnih karakteristika koji služe za usporedbu rezultata;
- izračun pokazatelja sigurnosti – najčešće se koriste gustoća nesreća (broj nesreća po kilometru) i stopa nesreća (broj nesreća u odnosu na prometno opterećenje izraženo kroz milijun vozilo-kilometara);
- statistička analiza – koristi se Poissonov model za određivanje gornjih i donjih granica pouzdanosti (intervala) kojima se definira značajnost odstupanja pojedinog segmenta od referentne skupine;
- klasifikacija segmenata – ovisno o izračunatim vrijednostima, segmenti se svrstavaju u jednu od tri klase rizika:
 - Klasa r1 – nizak rizik (Low Risk),
 - Klasa r2 – neizvjesno (Unsure),
 - Klasa r3 – visok rizik (High Risk).



Slika 2. Razredi klasifikacije rizika po EC NWA reaktivnom pristupu [1]

Kao što navode Smjernice NWRSA, ovaj pristup omogućuje kvantitativno utvrđivanje razine sigurnosti te daje jasne pokazatelje gdje je potrebno provesti detaljniju inspekciju ili uvesti korektivne mjere. Ako podaci o nesrećama nisu dostupni ili nisu pouzdani, reaktivni pristup se preskače i analizira se samo proaktivna komponenta.

2.1.3 Proaktivni pristup

Proaktivni pristup temelji se na analizi ugrađenih sigurnosnih karakteristika ceste neovisno o postojećim podacima o nesrećama. Cilj ove analize je prepoznati potencijalne rizike koji proizlaze iz geometrije i funkcionalnosti ceste te tako spriječiti nastanak nesreća prije nego što se dogode.

Postupak NWA proaktivne analize uključuje:

- definiranje tipa ceste – autocesta, primarna cesta s fizičkim razdjelnim pojasom ili primarna cesta bez njega;
- prikupljanje infrastrukturnih podataka – širine prometnih traka, zakrivljenosti, širine bankina, položaja čvorišta i raskrižja, pregleda bočnih prepreka, prisutnosti pješačkih i biciklističkih tokova, te postojanja centara za upravljanje prometom ili sustava za informiranje vozača;
- izračun tzv. faktora smanjenja rizika (Reduction Factors – RF) za svaki analizirani parametar, na temelju znanstveno utvrđenih odnosa između geometrijskih značajki i vjerojatnosti nastanka nesreće;

- izračun ukupnog sigurnosnog indeksa
- klasifikacija segmenata u tri razine sigurnosti:
 - Klasa p1 – nizak rizik,
 - Klasa p2 – srednji rizik,
 - Klasa p3 – visok rizik.

2.1.4 Integracija rezultata

Završna faza metodologije odnosi se na integraciju rezultata proaktivne i reaktivne analize. Cilj integracije je objediniti obje procjene u jedinstveni sustav ocjenjivanja koji pruža uravnotežen prikaz sigurnosnog stanja cestovne mreže. Integracija se provodi usporedbom dobivenih klasa rizika iz oba pristupa prema unaprijed definiranoj matrici [1] (EC NWA Integrated Matrix), slika 4. Na temelju kombiniranih rezultata određuje se konačna klasa prioriteta u pet stupnjeva:

- Klasa 1 – vrlo nizak prioritet (tamno zelena),
- Klasa 2 – nizak prioritet (svijetlo zelena),
- Klasa 3 – srednji prioritet (žuta),
- Klasa 4 – visoki prioritet (narančasta),
- Klasa 5 – vrlo visoki prioritet (crvena).

EC NWA PROAKTIVNI PRISTUP

		EC NWA REAKTIVNI PRISTUP			
		Visoki rizik – (Klasa r3)	Neizvjesno – (Klasa r2)	Nema podataka	Nizak rizik – (Klasa r1)
Visoki rizik – (Klasa p3)	Vrlo visoki prioritet – (Klasa 5)	Visoki prioritet – (Klasa 4)	Visoki prioritet – (Klasa 4)	Nizak prioritet – (Klasa 2)	
Srednje visoki rizik – (Klasa p2)	Vrlo visoki prioritet – (Klasa 5)	Srednje visoki prioritet – (Klasa 3)	Srednje visoki prioritet – (Klasa 3)	Nizak prioritet – (Klasa 2)	
Nizak rizik – (Klasa p1)	Vrlo visoki prioritet – (Klasa 5)	Nizak prioritet – (Klasa 2)	Vrlo nizak prioritet – (Klasa 1)	Vrlo nizak prioritet – (Klasa 1)	

Slika 3. Integracija rezultata EC NWA-proaktivnog i EC NWA-reaktivnog pristupa [1]

3 REZULTATI PROCJENE SIGURNOSTI PRIMARNE CESTOVNE MREŽE

3.1 Autoceste koje su dio TEM mreže i mreže primarnih cesta


3.1.1 Segmentacija i reaktivni pristup

Segmentacija mreže obuhvatila je ukupno 268 segmenata na svim autocestama. Prosječna duljina segmenta iznosi oko 10 kilometara. Sumarni rezultati reaktivnog pristupa za autoceste (desni i lijevi kolnik) su sljedeći:

- visoki rizik (High Risk) – 14 segmenata što čini udio od 5,22% svih analiziranih segmenata
- niski rizik (Low Risk) – 7 segmenata što čini udio od 2,61 svih analiziranih segmenata

- neizvjesno (Unsure) – 247 segmenata što čini udio od 92,16% svih analiziranih segmenata.

Detaljni grafički prikazi svih rezultata reaktivnog pristupa po segmentu posebno za desni i lijevi kolnik autocesta dati su na slikama u nastavku



Slika 4. Rezultati reaktivnog pristupa EC NWA autoceste koje su dio TEM mreže i mreže primarnih cesta – desni kolnik



Slika 5. Rezultati reaktivnog pristupa EC NWA autoceste koje su dio TEM mreže i mreže primarnih cesta – lijevi kolnik


3.1.2 Proaktivni pristup

Dobiveni sumarni rezultati proaktivnog pristupa su sljedeći:

- Visoki rizik (High Risk) – 42 segmenata što čini udio od 15,67% svih analiziranih segmenata
- Srednji rizik (Intermediate Risk) – 151 segmenata što čini udio od 56,34% svih analiziranih segmenata
- Niski rizik (Low Risk) – 75 segmenata što čini udio od 27,99% svih analiziranih segmenata.

Detaljni grafički prikazi svih rezultata proaktivnog pristupa po segmentu za desni i lijevi kolnik dati su na slikama u nastavku.

Autoceste (HAC, BINA ISTRRA, AZM)
desni kolnik




Rezultati proaktivnog pristupa EC NWA
(konverzija iRAP u EC NWA)

■ Visoki rizik
■ Srednji rizik
■ Niski rizik

Slika 6. Rezultati proaktivnog pristupa EC NWA (konverzija iRAP->EC NWA) – autoceste koje su dio TEM mreže i mreže primarnih cesta – desni kolnik

Autoceste (HAC, BINA ISTRRA, AZM)
lijevi kolnik



Rezultati proaktivnog pristupa EC NWA
(konverzija iRAP u EC NWA)

■ Visoki rizik
■ Srednji rizik
■ Niski rizik

Slika 7. Rezultati proaktivnog pristupa EC NWA (konverzija iRAP->EC NWA) – autoceste koje su dio TEM mreže i mreže primarnih cesta – lijevi kolnik


3.1.3 Integracija rezultata

Prema dobivenim rezultatima utvrđeno je sljedeće:


- Vrlo nizak prioritet ima 3 segmenta (1,12%)
- Nizak prioritet ima 86 segmenata (32,09%)
- Srednji prioritet ima 139 segmenata (51,87%)
- Visoki prioritet ima 26 segmenata (9,70%)
- Vrlo visoki prioritet ima 14 segmenata (5,22%).

Detaljan grafički prikaz svih rezultata integriranog pristupa po segmentu desnog i lijevog kolnika dat je na slikama u nastavku.

Autoceste (HAC, BINA ISTRRA, AZM)
desni kolnik



Slika 8. Rezultati integriranog pristupa EC NWA – autoceste koje su dio TEM mreže i mreže primarnih cesta- desni kolnik



Slika 9. Rezultati integriranog pristupa EC NWA – autoceste koje su dio TEM mreže i mreže primarnih cesta- lijevi kolnik


3.2 Državne ceste koje su dio TEM mreže i mreže primarnih cesta

3.2.1 Segmentacija i reaktivni pristup

Segmentacija mreže obuhvatila je ukupno 507 segmenata na 28 državnih cesta. Prosječna duljina segmenta iznosi oko 5 kilometara. Dobiveni sumarni rezultati reaktivnog pristupa su sljedeći:

- Visoki rizik (High Risk) – 74 segmenata što čini udio od 14,60% svih analiziranih segmenata
- Niski rizik (Low Risk) – 64 segmenata što čini udio od 12,62% svih analiziranih segmenata
- Neizvjesno (Unsure) - 369 segmenata što čini udio od 72,78% svih analiziranih segmenata.

Detaljni grafički prikazi svih rezultata reaktivnog pristupa po segmentu dati su na slici u nastavku.




Slika 10. Rezultati reaktivnog pristupa EC NWA – državne ceste koje su dio TEM mreže i mreže primarnih cesta

3.2.2 Proaktivni pristup

Dobiveni sumarni rezultati proaktivnog pristupa su sljedeći:

- Visoki rizik (High Risk) – 183 segmenata što čini udio od 36,09% svih analiziranih segmenata
- Srednji rizik (Intermediate Risk) – 274 segmenata što čini udio od 54,04% svih analiziranih segmenata
- Niski rizik (Low Risk) – 50 segmenata što čini udio od 9,86% svih analiziranih segmenata.

Detaljni grafički prikazi svih rezultata proaktivnog pristupa po segmentu dati su na slici u nastavku.




Slika 11. Rezultati proaktivnog pristupa EC NWA (konverzija iRAP->EC NWA) – državne ceste koje su dio TEM mreže i mreže primarnih cesta

3.2.3 Integracija rezultata

Završni korak je integracija rezultata prethodnih koraka. Na ovaj se način kombiniraju prednosti oba pristupa: statistička objektivnost reaktivnog modela i prediktivna vrijednost proaktivnog modela, što omogućuje preciznije definiranje prioriteta za daljnje intervencije na cestovnoj mreži. Prema dobivenim rezultatima utvrđeno je sljedeće:

- Vrlo nizak prioritet ima 14 segmenata (2,76%)
- Nizak prioritet ima 84 segmenta (16,57%)
- Srednji prioritet ima 206 segmenta (40,63%)
- Visoki prioritet ima 129 segmenta (25,44%)
- Vrlo visoki prioritet ima 74 segmenta (14,60%).

Detaljan grafički prikaz svih rezultata integriranog pristupa po segmentu dat je na slici u nastavku



Slika 12. Rezultati integriranog pristupa EC NWA – državne ceste koje su dio TEM mreže i mreže primarnih cesta

4 ZAKLJUČAK

Procjena sigurnosti mreže TEM cesta, autocesta i primarnih cesta (NWRSA) pruža sveobuhvatan uvid u sigurnosno stanje cestovne infrastrukture te identificira dionice s povećanim rizikom od nastanka teških prometnih nesreća. Integracijom reaktivnih i proaktivnih rezultata dobiven je uravnotežen prikaz rizika za pojedine segmente mreže, pri čemu su uzeti u obzir i povijesni zapisi o nesrećama i infrastrukturna obilježja koja utječu na vjerojatnost i težinu prometnih incidenata.

Dobiveni rezultati NWRSA postupka omogućuju jasno i transparentno razvrstavanje cestovnih dionica u sigurnosne kategorije, čime se stvaraju preduvjeti za učinkovito, sustavno i dugoročno upravljanje sigurnosnim rizicima na cestovnoj mreži. Segmenti označeni višim razinama prioriteta zahtijevaju pravodobno i ciljano djelovanje, dok dionice s nižim razinama rizika zahtijevaju kontinuirano praćenje kako bi se osigurala stabilnost postignutog sigurnosnog standarda. Integrirani pristup dodatno osigurava da nijedan aspekt sigurnosti ne ostane zanemaren, pri čemu se kritične lokacije prepoznaju bilo na temelju učestalosti prometnih nesreća, bilo na temelju nepovoljnih infrastrukturnih karakteristika.

Na temelju dobivenih rezultata mogu se izvesti sljedeće preporuke za daljnje postupanje:

- Provođenje ciljanih provjera sigurnosti na dionicama koje su u integriranom pristupu označene kao prioritetne.
- Izrada investicijskih planova povećanja sigurnosti za segmente kod kojih je potrebno provesti infrastrukturne intervencije. Prilikom planiranja

intervencija preporučuje se razmotriti troškovnu učinkovitost, potencijal smanjenja rizika i dugoročnu održivost mjera.

- Provedba hitnih korektivnih mjera na lokacijama s najvišim stupnjem rizika. U tim slučajevima preporučuje se što brža realizacija mjera koje imaju visok sigurnosni učinak, a ne zahtijevaju dugotrajne i opsežne zahvate (npr. poboljšanje vidljivosti, nadopuna signalizacije, uklanjanje manjih bočnih opasnosti).
- Planiranje rekonstrukcija i većih infrastrukturnih zahvata na dionicama gdje su utvrđeni ozbiljni strukturni nedostaci, a gdje brze mjere nemaju dovoljan učinak. Te dionice trebaju ući u srednjoročne i dugoročne investicijske planove upravitelja cesta.
- Kontinuirano praćenje i ponavljanje procjene u zakonski propisanim intervalima od pet godina. Redovita analiza omogućuje provjeru učinkovitosti provedenih mjera i prilagodbu prioriteta prema stvarnim promjenama na mreži.

Sustavno i redovito provođenje NWRSA postupka predstavlja ključan alat za donošenje odluka temeljenih na podacima te za dugoročno unaprjeđenje sigurnosti cestovne infrastrukture u Republici Hrvatskoj.

POPIS LITERATURE:

- [1] National Technical University of Athens, University of Zagreb Faculty of Transport and Traffic Sciences, i FRED Engineering s.r.l., „European Commission: Network Wide Road Safety Assessment - Methodology and Implementation Handbook“, 2023.
- [2] „Smjernice za provođenje procjene sigurnosti mreže TEM cesta, autocesta i primarnih cesta, Ministarstvo mora, prometa i infrastrukture“, Zagreb, 2024.

Safety risks due to non-compliance with technical standards when installing protective guardrails

Milja Simeunović¹, Zoran Papić², Nenad Saulić³

¹ Associate professor, Faculty of Technical Sciences, Serbia, mlekovic@uns.ac.rs

² Full professor, Faculty of Technical Sciences, Serbia, z.papic@uns.ac.rs

³ Assistant with PhD, Faculty of Technical Sciences, Serbia, n.saulic@uns.ac.rs

Abstract: Traffic infrastructure and supporting equipment play a vital role in ensuring road and street safety. The installation of guardrail on dangerous sections of road is recognised as a measure that significantly reduces the severity of traffic accident consequences. That's why guardrails are installed where leaving the roadway would have more severe consequences than hitting the guardrail. However, due to omissions and failure to comply with prescribed technical standards during installation, guardrails often fail to fulfil their function. This paper will provide examples of situations where the inadequate application of standards and prescribed conditions has rendered guardrails ineffective in protecting road users.

Key words: Traffic accident, safety, guardrail, standards.

1. INTRODUCTION

Traffic accidents are one of the most significant negative consequences of the transport system, so reducing them is a major challenge for modern society. Strategies for reducing traffic accidents, or for traffic safety management in general, involve applying various preventive measures that have different levels of effectiveness. One such measure, belonging to the category of passive safety, is the installation of guardrail, which are designed to reduce the severity of consequences in the event of an accident. Guardrails are one of the key passive elements of road infrastructure safety. They are designed to prevent vehicles from leaving the road by stopping or diverting them to avoid dangerous obstacles and oncoming traffic. Guardrail absorb the kinetic energy of vehicles during collisions, significantly reducing the risk of serious injury and fatalities among road users.

The effectiveness of guardrail depends on a number of interrelated factors. These include correct sizing, selecting the right type of guardrail for the road category and project speeds, and regular professional maintenance throughout the guardrail's lifetime. Any deviation from the stated requirements can decrease the protective guardrail's functionality, which, in the event of a traffic accident, often results in more severe consequences, including fatalities among road users. A key problem observed in engineering practice is deviations from the prescribed requirements and valid standards for the design, installation and maintenance of guardrail. Such deviations can significantly reduce the efficiency of these systems and negatively affect the level of passive safety of the road infrastructure. Therefore, analysing the role of guardrail as a passive safety feature is an important part of modern research in traffic safety and road engineering.

This paper will present the normative frameworks and standards applied in this area, and analyse the impact of non-compliance with them on the course and outcome of traffic accidents.

2. LEGAL REGULATIONS FOR INSTALLING GUARDRAIL

The safety of road infrastructure in Europe is based on strictly defined technical standards and legal frameworks that regulate the design, installation and maintenance of guardrail as key passive safety elements. In the European Union, the EN 1317 series of standards regulate the design, testing, classification and application of vehicle protection systems, including road safety barriers [1]. These standards provide a harmonised European framework for evaluating the performance of these systems in the event of an impact. They define performance classes, crash test acceptance criteria, working width, dynamic deformation and system retention levels. This provides a unified methodology for designing and evaluating road safety barriers. EU legislation generally establishes the legal framework for the implementation of these standards in member states, thereby ensuring a consistent level of passive safety and protection for road users. Standardised EN 1317 parameters are used to select the guardrail for a given road category, design speed and traffic load. The performance and installation of the system are verified through rigorous crash tests and product conformity assessments.

In the Republic of Serbia, the regulatory framework for road safety barriers has been fully aligned with European practice by adopting the EN 1317 standard as the national SRPS EN 1317 standard [2]. This ensures that the technical requirements, performance classifications and testing methodologies applied in Serbia are identical to those used by European Union member states.

These standards are further supported in Serbia by national technical regulations and design guidelines, which explicitly require compliance with SRPS EN 1317 for the selection, installation and maintenance of road safety barrier systems. As a result, the practical implementation of road safety barriers in Serbia adheres to the same engineering principles and safety objectives as those employed worldwide.

3. THE CONSEQUENCES OF INADEQUATELY INSTALLING GUARDRAIL

It is crucial to comply with existing regulations and technical standards when designing and installing guardrails, as their effectiveness and primary function depend directly on the implementation of the prescribed guidelines. Conversely, failure to comply with these standards or to install guardrails correctly can have the opposite effect, further worsening the consequences of traffic accidents. Hamid et al. state in their paper that reducing the height of the guardrail by just 40 mm negatively impacts its ability to hold back heavy vehicles [3]. Similarly, the selection of inappropriate materials, insufficient structural strength, or the poor positioning of posts can significantly reduce the energy absorption capacity, thereby increasing the likelihood of serious injury or death among road users. Another important factor is where guardrails are placed in relation to the roadway and the surrounding terrain. Guardrails that are incorrectly spaced or installed on uneven or unstable ground can potentially direct vehicles towards more dangerous obstacles or cause secondary collisions. Even when guardrails are correctly placed, it is necessary to conduct regular condition checks. Systematic monitoring, periodic inspections, and adherence to technical guidelines are important methods of mitigating the risks associated with incorrectly placed guardrails. Damaged or corroded guardrails, loose fasteners or deformed elements pose additional risks as they can pierce vehicle structures, destabilise vehicles in the event of an impact or cause them to fly off the roadway. In general, guardrails that do not comply with prescribed standards not only fail to prevent and mitigate the consequences of traffic accidents, but can also directly contribute to escalating the severity of injuries and fatalities among road users, as will be demonstrated below.

4. CASE STUDY

To illustrate the negative impact of inadequately installed guardrail on the outcome of traffic accidents, two incidents that occurred on a bridge in the Republic of Serbia were examined. According to the Technical Instructions applied to state roads in the Republic of Serbia, the necessary degrees of containment are defined by appropriate protection measures depending on the category of the road, the degree of danger and the permitted speed [2].

4.1. The first traffic accident

In the first traffic accident, the speed limit on the bridge was 50 km/h. According to the Technical Instructions valid at the time, the estimated degree of danger in 2019 meant that the edges of bridges in zones with a permitted speed of 50 km/h were secured with a 20 cm high kerb and a pedestrian guardrail. Two passenger vehicles collided on the bridge in question. After the collision, one of the vehicles veered to the right, crossed the kerb and broke through the guardrail, ultimately landing on the bridge. The two people in the vehicle lost their lives. Analysis of the accident site revealed that there was an 18 cm high kerb on the bridge, as well as a pedestrian guardrail in a very poor state of repair. Figure 1 shows the grey part of pedestrian guardrail that was replaced where the car landed, as well as the corroded and damaged section before the accident place.



Fig. 1: The appearance of the pedestrian guardrail immediately upstream of the point where the vehicle left the bridge

Source: traffic accident expert report

Following the expertise of the traffic accident, in addition to the fault of one of the participants, the fault of the road controller was mentioned. This directly affected the landing of the car from the bridge and therefore the consequences of the accident. Consequently, two years after the accident in question, an amended and supplemented edition of the Technical Instructions was published. This edition changed the criteria for installing guardrail on bridges, reducing the prescribed kerb height from 20 cm to 15–20 cm in zones where the speed limit is up to 50 km/h. However, the regulation that guardrail are not required for drivers remains in place, and only pedestrian guardrail are installed in such places.

4.2. The second traffic accident

In the second traffic accident, the speed limit on the bridge was 60 km/h. According to the Technical Instructions for this section, a level of H1 retention (higher retention probability) is required. The SRPS EN 1317-2 standard states that H1 retention corresponds to the TB42 and TB11 tests. According to test TB 11, the system should prevent a 900 kg passenger car from leaving the road when it collides with the protection system at an angle of 20° and at a speed of 100 km/h. According to TB 42, the H1 protection system should prevent a cargo vehicle weighing 10,000 kg from leaving the road after hitting protective devices at an angle of 15° at 70 km/h. Therefore, it is necessary to install a steel guardrail on the bridge that can support passenger and cargo vehicles. The traffic accident in question occurred when the car lost stability while moving, crossed over to the left-hand side of the road, broke through the bridge's guardrail after crossing the kerb, and fell into the riverbed. There were four people in the vehicle; two died and two received minor injuries. Upon arriving at the scene, it was determined that the edge of the bridge was secured only by a pedestrian guardrail in a poor state of repair. The following pictures show the state of the pedestrian guardrail pillars, which were damaged in a traffic accident, and the state of the pedestrian guardrail itself.



Fig. 2, 3, 4 and 5: The appearance of details corroded, broken poles and the damaged pedestrian guardrail

Source: traffic accident expert report

As can be seen in the photos, the broken poles are corroded and the pedestrian guardrail itself is damaged and cracked. Therefore, not only was an adequate steel guardrail for vehicles not installed in the area of the bridge, but the existing pedestrian guardrail is also in a very poor and unsafe condition.

5. DISCUSSION AND CONCLUSION

The previous two examples showed how an improperly placed guardrail can affect the outcome of traffic accidents. In the first accident, it was assumed that a 20 cm kerb would be sufficient to redirect the destabilised vehicle and return it to the road at low speeds. However, the vehicle went over the kerb, broke through the guardrail and fell from a height of about 20 metres, which could significantly reduce the probability of the occupants surviving. In this case, the height of the kerb was 18 cm. Rather than re-examining the method of protecting road users and deciding to introduce higher protection standards on the section of road in question, the decision was made to reduce the existing criteria. By reducing the height of the kerb from 20 cm to 15–20 cm, the road manager protected himself from possible legal consequences instead of solving the problem and preventing new accidents.

In another traffic accident, a vehicle fell into a riverbed after leaving the bridge. According to the survivors, all the passengers were alive and trying to swim to the shore; however, two people died. At the time of the accident, it was night-time and snowing. The weather conditions and the injuries sustained by those involved certainly impacted the severity of the consequences after the vehicle fell from the bridge into the river. Had the edges of the bridge been secured in accordance with the Technical Instructions, the vehicle would not have fallen from the bridge.

Ultimately, it can be concluded that implementing guardrail below the prescribed standards not only fails to prevent or mitigate the consequences of traffic accidents, but can also directly

contribute to escalating the severity of injuries and fatalities. Xinping et al. reached the same conclusion in their research, determining that many bridges are equipped with protection systems that do not meet the prescribed standards, which directly affects the safety of road users [4]. These conclusions highlight the importance of maintaining the integrity of infrastructure elements and complying with safety standards to optimise the protection of road users.

6. REFERENCES

- [1] <https://www.traffixdevices.com/standards/en1317>
- [2] JP Putevi Srbije (2021) Tehničko uputstvo - Primena sistema za zadržavanje vozila na državnim putevima Republike Srbije – sa obaveznom primenom, Dopunjeno i izmenjeno izdanje
- [3] Hamid, I. A., Arif, S. S. T., Zulkiffli, N. M., Sarani, R., Solah, M. S., Osman, M. R. (2017). Crash Investigation on Automobile vs. Crash Barrier: Assessment of W-Beam Guardrail with respect to REAM Standard. *Journal of the Society of Automotive Engineers Malaysia*, 1(2), 154-165.
- [4] Xinping, L., Shihui, Z., Zhongping, S., Yue, H., Qiang, Z. (2024). Guardrail improvement for old bridges in expressways. *Journal of China & Foreign Highway*, 44(2), 260-266.

ACKNOWLEDGMENTS

This research has been supported by the project "Researching trends in the development of sustainable transport and logistics systems", founded by the Department of Traffic Engineering, Faculty of Technical Sciences in Novi Sad, University of Novi Sad, Republic of Serbia.

**BRZINA KAO KLJUČNI POKAZATELJ USPJEŠNOSTI
SIGURNOSTI CESTOVNOG PROMETA U REPUBLICI
HRVATSKOJ**

**SPEED AS A KEY PERFORMANCE INDICATOR OF ROAD
TRAFFIC SAFETY IN THE REPUBLIC OF CROATIA**

Mario Mataija¹, Juraj Leonard Vertlberg², David Gruhonjić³, Marijan Jakovljević⁴

¹ mag. ing. traff., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, mmataija@fpz.hr

² mag. ing. traff., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, jvertlberg@fpz.hr

³ mag. ing. traff., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, dgruhonjic@fpz.hr

⁴ doc. dr. sc., Sveučilište u Zagrebu, Fakultet prometnih znanosti, Hrvatska, mjakovljevic@fpz.hr

Sažetak

Brzina prometnog toka ključan je čimbenik sigurnosti cestovnog prometa. Ograničenja brzine često odstupaju od stvarne brzine, što povećava rizik i težinu prometnih nesreća. Cilj rada je analizirati operativne brzine na teritoriju Hrvatske i utvrditi odstupanja od ograničenja. Istraživanje se temelji na terenskim mjerenjima na više od 20 karakterističnih lokacija izvan naselja, po kategorijama cesta i u različitim dijelovima dana i tjedna. Odabir lokacija proveden je stratificiranim uzorkovanjem sukladno smjernicama europskog projekta Trendline, omogućujući reprezentativnu i usporedivu analizu na razini Hrvatsku i Europske Unije. Prikupljen je uzorak na više od 50.000 vozila, što omogućuje detaljnu usporedbu stvarnih brzina s ograničenjima i identifikaciju kritičnih točaka. Rezultati doprinose kao podloga za donošenje odluka o upravljanju brzinom, planiranju i projektiranju sigurnije infrastrukture te praćenju ključnih pokazatelja Nacionalnog plana sigurnosti cestovnog prometa.

Ključne riječi: analiza prometne infrastrukture, brzina, sigurnost cestovnog prometa, Trendline

Abstract

Traffic flow speed is a key factor affecting road traffic safety. Speed limits often deviate from actual driving speeds, increasing both the risk and severity of accidents. The aim of this study is to analyze operational speeds across Croatia and identify deviations from speed limits. The research is based on field measurements at over 20 characteristic locations outside urban areas, categorized by road type and covering different times of day and week. Location selection was performed using stratified sampling in accordance with the guidelines of the European Trendline project, enabling a representative and comparable analysis at both the national and EU level. Data were collected from over 50,000 vehicles, allowing a detailed comparison of actual speeds with limits and the identification of critical points. The results provide a basis for speed management decisions, planning and designing safer infrastructure, and monitoring key indicators of the National road safety plan.

Key words: road traffic safety, speed, traffic infrastructure analysis, Trendline


1 UVOD

Prometne nesreće predstavljaju značajan globalni javnozdravstveni i društveno-ekonomski problem, s ozbiljnim posljedicama na zdravlje stanovništva i ukupni gospodarski razvoj, zbog čega zahtijevaju sustavno, znanstveno utemeljeno i dugoročno oblikovanje prometnih politika usmjerenih na smanjenje njihova broja i težine. Prema izvješću Svjetske zdravstvene organizacije, godišnje na cestama smrtno strada oko 1,19 milijuna ljudi, dok deseci milijuna osoba zadobivaju ozljede, često s dugotrajnim ili trajnim posljedicama koje značajno narušavaju kvalitetu života pojedinaca, njihovih obitelji i šire zajednice [1]. Posebno zabrinjava činjenica da su prometne nesreće vodeći uzrok smrtnosti među osobama u dobi od 5 do 29 godina, čime se dodatno naglašava njihov dugoročni društveni i demografski utjecaj [2]. Uz ljudske gubitke, prometne nesreće uzrokuju i znatne ekonomske štete koje se u većini zemalja procjenjuju na 3 do 5 % godišnjeg bruto domaćeg proizvoda (BDP) [3].

U takvom kontekstu, identifikacija i praćenje ključnih čimbenika koji utječu na nastanak i težinu prometnih nesreća predstavlja temelj za učinkovito upravljanje sigurnošću cestovnog prometa. Među njima se brzina kretanja vozila ističe kao jedan od najvažnijih i najizraženije mjerljivih čimbenika, s dokazanim utjecajem ne samo na vjerojatnost nastanka prometne nesreće, već i na težinu njezinih posljedica, zbog čega

je u suvremenim europskim istraživanjima definirana kao ključni pokazatelj uspješnosti (KPI) sigurnosti cestovnog prometa.

U okviru izrade Nacionalnog plana sigurnosti cestovnog prometa za razdoblje 2021.–2030. provedena je analiza ključnih čimbenika nastanka prometnih nesreća na temelju podataka prikupljenih u razdoblju od 2010. do 2019. godine, s fokusom na teške prometne nesreće s poginulim i teško ozlijeđenim osobama. Rezultati analize ukazuju da je u Republici Hrvatskoj ljudski čimbenik izravno odgovoran za 57 % teških prometnih nesreća, dok se njegov udio, uz istodobno razmatranje čimbenika ceste i vozila, povećava na ukupno 99 % [4]. Odnos čimbenika čovjek–vozilo–cesta i pripadajući udjeli u uzrocima teških prometnih nesreća prikazani su na slici 1.



Slika 1. Glavni čimbenici teških prometnih nesreća

Izvor:[4]

2 BRZINA KAO ČIMBENIK SIGURNOSTI CESTOVNOG PROMETA

Brzina se prema osnovnoj definiciji definira kao ukupni prijeđeni put u jedinici vremena. U prometnom inženjerstvu razlikujemo nekoliko definicija brzine, a od kojih su najbitnije:

- ❖ projektna brzina
- ❖ računska brzina
- ❖ operativna brzina
- ❖ ograničenje brzine .

Projektna brzina definirana je u *Pravilniku o osnovnim uvjetima kojima javne ceste izvan naselja i njihovi elementi moraju udovoljavati sa stajališta sigurnosti prometa (NN 110/2001 i 90/2022)* [5] kao najveća brzina za koju je zajamčena potpuna sigurnost vožnje u slobodnom prometnom toku na cijelom potezu trase, pod optimalnim vremenskim uvjetima i kod dobrog održavanja.

Prema istom Pravilniku, računska brzina je najveća očekivana brzina koju vozilo u slobodnom prometnom toku može ostvariti uz dovoljnu sigurnost vožnje na određenom dijelu ceste, u skladu s prihvaćenim modelom njezinog ustanovljavanja, zavisno o tlocrtnim i visinskim elementima tog dijela trase.

Ograničenje brzine označava najveću dopuštenu brzinu kretanja vozila na određenom dijelu cestovne mreže te je definirano i označeno odgovarajućim prometnim znakom.

U stvarnim prometnim uvjetima često dolazi do značajnih odstupanja između stvarnih brzina prometnog toka, odnosno operativnih brzina, i projektnih te računskih vrijednosti brzine. Iako su projektna i računska brzina definirane s ciljem osiguravanja potpune ili dovoljne razine sigurnosti vožnje u uvjetima slobodnog prometnog toka, ponašanje vozača u praksi često rezultira brzinama koje premašuju navedene vrijednosti, kao i propisana ograničenja brzine. Operativna brzina, koja se najčešće opisuje putem 85. percentila brzine, odražava percepciju vozača o prihvatljivoj brzini kretanja, koja ne mora biti usklađena s geometrijskim obilježjima ceste niti s postavljenom prometnom signalizacijom. Takva neusklađenost između projektnih elemenata ceste, prometnih ograničenja i stvarnih brzina kretanja predstavlja značajan sigurnosni problem jer povećava rizik nastanka prometnih nesreća.

Prema brojnim istraživanjima, neprilagođena brzina jedan je od dominantnih uzroka teških prometnih nesreća [6], [7], [8]. Povećanje brzine kretanja vozila negativno utječe na sigurnost vožnje jer smanjuje raspoloživo vrijeme reakcije vozača, povećava zaustavni put te otežava izvođenje manevara u iznenadnim prometnim situacijama, čime se značajno povećava rizik nastanka prometne nesreće. Nadalje, Elvik i sur. (2004) [9] su u svojoj meta-analizi pokazali da smanjenje prosječne brzine kretanja od 1 km/h može rezultirati smanjenjem smrtnosti u prometnim nesrećama za približno 4 %.

U razdoblju od prethodnih deset godina u Republici Hrvatskoj evidentirano je ukupno 2.669 teških prometnih nesreća s poginulim osobama, od čega je 1.184

nesreća, odnosno 44,36 %, bilo povezano s nepropisnom brzinom [10]. Kretanje broja teških prometnih nesreća s poginulim osobama u razdoblju od 2015. do 2024. godine, uz izdvojeni prikaz nesreća kod kojih je kao uzrok navedena nepropisna brzina, prikazano je na grafikonu 1. Ukupan broj prometnih nesreća s poginulim osobama pokazuje trend postupnog smanjenja, s 317 nesreća u 2015. godini na 219 nesreća u 2024. godini. Najniža vrijednost zabilježena je 2020. godine (214), što se može dovesti u vezu s izvanrednim okolnostima uzrokovanim pandemijom bolesti COVID-19 i promjenama u obrascima mobilnosti stanovništva, nakon čega slijedi porast u 2021. godini te ponovno postupno smanjenje broja nesreća u narednim godinama.

Broj prometnih nesreća s poginulim osobama uzrokovanih nepropisnom brzinom tijekom promatranog razdoblja kretao se u rasponu od 96 do 146 godišnje. Najviša vrijednost zabilježena je 2018. godine (146), dok je najniža evidentirana 2020. godine (96). Unatoč uočenim godišnjim varijacijama, udio nesreća uzrokovanih nepropisnom brzinom u ukupnom broju teških prometnih nesreća s poginulim osobama ostaje relativno stabilan te se u pravilu kreće u rasponu od približno 40% do 50%.



Grafikon 1. Broj teških prometnih nesreća s poginulim osobama i teških prometnih nesreća vezanih za neprimjerenu brzinu u Republici Hrvatskoj (2015. - 2024.)

3 METODOLOGIJA

Metodologija istraživanja temelji se na smjernicama europskih projekata Baseline [11] i Trendline [12], u okviru kojih su definirani ključni pokazatelji uspješnosti (KPI) sigurnosti cestovnog prometa, pri čemu brzina kretanja vozila predstavlja jedan od najvažnijih čimbenika. U sklopu navedenih projekata razvijena je standardizirana metodologija za odabir mjernih lokacija, postupke prikupljanja podataka te načine njihove analize i međusobne usporedbe rezultata između država članica Europske unije. Ukupno je definirano osam ključnih pokazatelja uspješnosti, koji su prikazani u tablici 1 zajedno s pripadajućim definicijama.

Tablica 1. Ključni pokazatelji uspješnosti sigurnosti cestovnog prometa – projekt Trendline

KPI	Definicija
Brzina	Postotak vozila koja se kreću unutar propisanog ograničenja brzine
Sigurnosni pojas	Postotak putnika u vozilima koji pravilno koriste sigurnosni pojas ili sustav za zadržavanje djece
Zaštitna oprema	Postotak vozača i putnika na motornim vozilima na dva kotača te biciklista koji nose zaštitnu kacigu
Alkohol	Postotak vozača koji upravljaju vozilom unutar zakonom dopuštene granice koncentracije alkohola u krvi (BAC)
Ometanje pažnje	Postotak vozača koji ne koriste mobilni uređaj tijekom vožnje
Sigurnost vozila	Postotak novih osobnih automobila s Euro NCAP sigurnosnom ocjenom jednakom ili višom od unaprijed definiranog praga
Infrastruktura	Postotak prijeđene udaljenosti po cestama sa sigurnosnom ocjenom iznad dogovorenog praga
Zbrinjavanje nakon nesreće (Post-crash care)	Vrijeme proteklo (u minutama i sekundama) između upućivanja hitnog poziva nakon prometne nesreće s ozlijeđenim osobama i dolaska hitnih službi na mjesto nesreće

Lokacije za mjerenje brzine kretanja vozila odabrane su u skladu s načelima reprezentativnosti i prostorne uravnoteženosti uzorka. Primijenjen je nasumični odabir unutar unaprijed definiranih kategorija cesta (autoceste i državne ceste), pri čemu je osigurana reprezentativnost u odnosu na ukupnu nacionalnu cestovnu mrežu. Kao dodatni kriterij pri odabiru mjernih lokacija primijenjen je uvjet minimalnog prometnog toka od 10 vozila na sat, koji je bio zadovoljen na svim promatranim lokacijama.

Podaci o brzinama kretanja vozila prikupljani su metodom točkastog mjerenja (mjerenje na presjeku) primjenom automatskih mjernih uređaja, odnosno radarskih mjerača brzine. Ova metoda omogućuje kontinuirano bilježenje pojedinačnih brzina vozila bez utjecaja na prometni tok i bez promjene ponašanja vozača. Mjerenja su provedena tijekom različitih vremenskih razdoblja, uključujući radne dane i vikende, kako bi se obuhvatila varijabilnost prometnih uvjeta. Pri prikupljanju podataka vodilo se računa da se mjerenja, u najvećoj mogućoj mjeri, provode izvan razdoblja vršnih prometnih opterećenja, čime su osigurani uvjeti slobodnog prometnog toka i smanjen utjecaj zagušenja na izmjerene brzine.

Na temelju prikupljenih pojedinačnih brzina izračunati su standardni statistički pokazatelji koji se koriste za ocjenu ponašanja vozača u odnosu na propisana ograničenja brzine. U analizi su korišteni sljedeći pokazatelji:


- ❖ udio vozila koja se kreću unutar propisanog ograničenja brzine,
- ❖ srednja (aritmetička) brzina,
- ❖ 85. percentil brzine (V85 - definiran kao brzina ispod koje se kreće 85 % vozila).

4 ANALIZA UDJELA VOZAČA KOJI VOZE IZNAD POSTAVLJENOG OGRANIČENJA BRZINE

Analiza udjela vozača koji prekoračuju propisano ograničenje brzine provedena je na ukupno 31 mjernoj lokaciji, od čega se 13 lokacija nalazilo na državnim cestama, a preostalih 18 na autocestama. Na svakoj mjernoj lokaciji prikupljen je uzorak vozila koji premašuje minimalno zahtijevani broj definiran metodološkim smjernicama, pri čemu je ukupan analizirani uzorak obuhvatio 64.067 vozila. Iako je veći broj mjernih lokacija bio raspoređen na autocestama, veći udio analiziranih vozila zabilježen je na državnim cestama, gdje je evidentirano 38.244 vozila, odnosno 59,69% ukupnog uzorka, dok je preostalih 25.823 vozila, odnosno 40,31%, zabilježeno na autocestama.


Od ukupnog broja analiziranih vozila, kod 24.499 vozila zabilježeno je prekoračenje propisanog ograničenja brzine, što čini 38,24% ukupnog uzorka, dok se preostalih 39.568 vozila, odnosno 61,76%, kretalo brzinom unutar dopuštenih ograničenja. Promatrajući rezultate prema kategoriji ceste, na državnim cestama 10.955 vozila kretalo se brzinom većom od dopuštene, što predstavlja 28,65 % uzorka na toj kategoriji cesta. Na autocestama je udio prekoračenja znatno izraženiji, pri čemu je kod 13.544 vozila zabilježena brzina veća od propisanog ograničenja, što čini 52,45% analiziranih vozila na autocestama.

Na mjernim lokacijama na državnim cestama s ograničenjem brzine od 90 km/h, analiza distribucije izmjerenih brzina pokazala je da prosječna brzina prometnog toka iznosi 84 km/h, medijan brzine 82 km/h, dok 85. percentil brzine doseže vrijednost od 94 km/h. Kumulativna krivulja raspodjele brzina, prikazana na grafikonu 2, prikazuje odnos između brzine kretanja vozila i kumulativnog udjela vozila u prometnom toku. Oblik krivulje ukazuje na koncentraciju najvećeg dijela prometnog toka u srednjem rasponu brzina, pri čemu je najveći porast kumulativnog udjela vozila zabilježen u rasponu brzina približno između 60 i 90 km/h. Na temelju krivulje moguće je uočiti da se značajan dio vozila kreće brzinama bliskim propisanom ograničenju, dok se vrijednost 85. percentila nalazi iznad ograničenja brzine.



Grafikon 2. Kumulativna krivulja raspodjele brzina – DC ograničenje 90km/h


Na autocestama, na mjernim lokacijama s ograničenjem brzine od 110 km/h, analiza distribucije izmjerenih brzina pokazala je da prosječna brzina prometnog toka iznosi 110 km/h, dok medijan brzine iznosi 117 km/h. Kumulativna krivulja raspodjele brzina, prikazana na grafikonu 3, prikazuje odnos između brzine kretanja vozila i kumulativnog udjela vozila u prometnom toku. Oblik krivulje ukazuje na to da se najveći dio vozila kreće u rasponu brzina približno između 100 i 140 km/h, odnosno oko i iznad propisanog ograničenja brzine. Vrijednost 85. percentila brzine nalazi se znatno iznad dopuštenog ograničenja te iznosi 134 km/h, što upućuje na izraženo prekoračenje brzine među bržim dijelom prometnog toka.



Grafikon 3. Kumulativna krivulja raspodjele brzina – AC ograničenje 110km/h

Nadalje, na mjernim lokacijama na autocestama s ograničenjem brzine od 130 km/h, analiza distribucije izmjerenih brzina pokazala je da prosječna brzina prometnog toka iznosi 124 km/h, dok medijan brzine iznosi 129 km/h. Vrijednost 85. percentila brzine doseže 144 km/h, što upućuje na izraženo prekoračenje brzine kod bržeg dijela prometnog toka. Kumulativna krivulja raspodjele brzina, prikazana na grafikonu 4, prikazuje odnos između brzine kretanja vozila i kumulativnog udjela vozila u prometnom toku. Iz oblika krivulje vidljivo je da se najveći dio vozila kreće u rasponu

brzina približno između 110 i 150 km/h, pri čemu se značajan udio vozila kreće brzinama iznad propisanog ograničenja.



Grafikon 4. Kumulativna krivulja raspodjele brzina – AC ograničenje 130km/h

5 ZAKLJUČAK

Brzina kretanja vozila jedan je od najvažnijih čimbenika koji utječu na sigurnost cestovnog prometa te je u europskim istraživanjima prepoznata kao ključni pokazatelj uspješnosti (KPI) u praćenju i vrednovanju stanja sigurnosti cestovnog prometa. Cilj ovoga rada bio je analizirati stvarne operativne brzine na cestama izvan naselja u Republici Hrvatskoj te utvrditi njihova odstupanja od propisanih ograničenja brzine. Istraživanje je provedeno u skladu s metodološkim smjernicama europskih projekata Baseline i Trendline, čime je osigurana usporedivost dobivenih rezultata na nacionalnoj i europskoj razini. Podaci su prikupljeni automatskim radarskim mjerenjima na 31 reprezentativnoj lokaciji na državnim cestama i autocestama, pri čemu je analiziran uzorak od ukupno 64.067 vozila.

Rezultati istraživanja ukazuju na izraženo i sustavno prekoračenje propisanih ograničenja brzine. Ukupno je 38,24% analiziranih vozila prekoračilo dopuštenu brzinu, pri čemu su uočene značajne razlike ovisno o kategoriji ceste. Na državnim cestama ograničenje brzine od 90 km/h prekoračilo je 28,65% vozača, dok je na

autocestama taj udio znatno viši te iznosi 52,45%. Analiza distribucije brzina dodatno pokazuje da se 85. percentil brzine na svim promatranim kategorijama cesta nalazi iznad propisanih ograničenja, što upućuje na to da se prekoračenje brzine ne pojavljuje pojedinačno, već predstavlja uobičajeno ponašanje bržeg dijela prometnog toka.

Dobiveni rezultati potvrđuju da neprilagođena brzina i nepoštivanje ograničenja brzine predstavljaju jedan od ključnih sigurnosnih problema cestovnog prometa u Republici Hrvatskoj. Takvo stanje indicira na potrebu sustavnog i integriranog pristupa upravljanju brzinama, koji nadilazi isključivo odgovornost vozača. Učinkovito smanjenje prekoračenja brzine zahtijeva usklađeno djelovanje svih dionika sustava sigurnosti cestovnog prometa, uključujući vozače, projektante prometne infrastrukture, upravitelje cesta, tijela nadležna za nadzor i provedbu propisa te donositelje prometnih politika. Poseban naglasak potrebno je staviti na usklađivanje projektnih elemenata ceste, postavljenih ograničenja brzine i stvarne percepcije vozača, uz primjenu infrastrukturnih mjera, ciljanog nadzora i kontinuirane edukacije, kako bi se dugoročno postiglo smanjenje brzina i unaprijedila razina sigurnosti cestovnog prometa.

POPIS LITERATURE:

- [1] World Health Organization, *“Global Status Report on Road Safety 2023”*. Geneva: WHO, 2023. [Na internetu]. Dostupno na: www.who.int
- [2] World Health Organization, *“Global Status Report on Road Safety 2018”*. Geneva: WHO. [Na internetu]. Dostupno na: www.who.int
- [3] W. Bank, „Global Road Safety Facility Annual Report 2020.“, 2020., *Global Road Safety Facility, Washington DC*.
- [4] Ministarstvo unutarnjih poslova, „Nacionalni plan sigurnosti cestovnog prometa Republike Hrvatske 2021-2030“, 2021., *MUP RH, Zagreb*.
- [5] „Pravilniku o osnovnim uvjetima kojima javne ceste izvan naselja i njihovi elementi moraju udovoljavati sa stajališta sigurnosti prometa (NN 110/2001, 90/2022 i 154/2024)“. [Na internetu]. Dostupno na: <http://narodne-novine.nn.hr/clanci/sluzbeni/dodatni/431534.pdf>
- [6] D. . Solomon, „Accidents on main rural highways related to speed, driver and vehicle“, 1964., *Bureau of Public Roads, Washington DC*.
- [7] A. Lobo, M. Amorim, C. Rodrigues, i A. Couto, „Modelling the Operating Speed in Segments of Two-Lane Highways from Probe Vehicle Data: A Stochastic Frontier Approach“, *J. Adv. Transp.*, sv. 2018, 2018, doi: 10.1155/2018/3540785.
- [8] A. Jacob i M. V. L. R. Anjaneyulu, „Operating speed of different classes of vehicles at horizontal curves on two-lane rural highways“, *J. Transp. Eng.*, sv. 139, izd. 3, str. 287–294, 2013, doi: 10.1061/(ASCE)TE.1943-5436.0000503.

- [9] R. Elvik, P. Christensen, i A. Amundsen, „Speed and road accidents: An evaluation of the Power Model“, *TOI Rep. 740*, sv. 740, izd. December, str. 134, 2004, [Na internetu]. Dostupno na: <http://www.trg.dk/elvik/740-2004.pdf>
- [10] „Ministarstvo unutarnjih poslova Republike Hrvatske, Bilten o sigurnosti cestovnog prometa 2024., Zagreb“, 2024.
- [11] P. Silverans i S. Vanhove, „Baseline conclusions and recommendations. Baseline project, Brussels: Vias institute“, 2023. doi: 10.4324/9781003306771-15.
- [12] A. Laiou, „KPI Speed Methodological Guidelines“, 2023.

PRIMJENA BESPILOTNIH LETJELICA U KALIBRACIJI MIKROSIMULACIJSKIH MODELA KOD PROMETNE ANALIZE VARIJANTNIH RJEŠENJA RASKRIŽJA

APPLICATION OF UNMANNED AERIAL VEHICLES IN THE CALIBRATION OF MICROSIMULATION MODELS FOR TRAFFIC ANALYSIS OF INTERSECTION DESIGN ALTERNATIVES

Matija Ezgeta¹, Marko Švajda², Marijan Jakovljević³, Marko Šoštarić⁴

¹ mag. ing. traff., Fakultet prometnih znanosti, Hrvatska, mezgeta@fpz.unizg.hr

² mag. ing. traff., Fakultet prometnih znanosti, Hrvatska, msvajda@fpz.unizg.hr

³ doc. dr. sc., Fakultet prometnih znanosti, Hrvatska, mjakovljevic@fpz.unizg.hr

⁴ izv. prof. dr. sc., Fakultet prometnih znanosti, Hrvatska, marko.sostaric@fpz.unizg.hr

Sažetak

Raskrižja predstavljaju kritične točke cestovne mreže na kojima se često javljaju problemi smanjene protočnosti i snižene razine sigurnosti prometa. Prije provedbe infrastrukturnih zahvata nužno je provjeriti opravdanost predloženih rješenja primjenom simulacijskih modela, pri čemu je kvaliteta ulaznih podataka ključna za pouzdanost dobivenih rezultata.

Cilj ovoga rada je prikazati mogućnosti primjene bespilotnih letjelica u fazi analize postojećeg stanja prometa radi prikupljanja detaljnih i pouzdanih prometnih podataka potrebnih za kalibraciju mikrosimulacijskih modela. Istraživanje je provedeno na raskrižju Osječke ulice i čvora Škurinje u Rijeci, gdje su podaci o prometnim opterećenjima, strukturi prometnog toka, brzinama vozila i duljinama repova čekanja prikupljeni kombinacijom ručnog brojanja prometa i snimanja pomoću bespilotne letjelice.

Na temelju prikupljenih podataka izrađen je i kalibriran mikrosimulacijski model postojećeg stanja raskrižja te dvaju varijantnih rješenja. Evaluacija varijanti provedena je na temelju prometnih pokazatelja uključujući duljinu repova čekanja, vrijeme kašnjenja i razinu usluge. Rezultati su pokazali da varijanta kružnog raskrižja sa spiralnim tokom ostvaruje znatno bolje prometne pokazatelje u odnosu na postojeće stanje i klasično kružno raskrižje.

Ključne riječi: bespilotne letjelice, evaluacija raskrižja, kalibracija modela, mikrosimulacijsko modeliranje

Abstract

Intersections represent critical points in the road network where problems of reduced capacity and lower traffic safety levels frequently occur. Before implementing infrastructure interventions, it is essential to verify the justification of proposed solutions through the use of simulation models, where the quality of input data is crucial for the reliability of the obtained results.

The aim of this paper is to present the possibilities of using unmanned aerial vehicles in the analysis phase of existing traffic conditions in order to collect detailed and reliable traffic data required for the calibration of microsimulation models. The research was conducted at the intersection of Osječka Street and the Škurinje interchange in Rijeka, where data on traffic volumes, traffic flow structure, vehicle speeds, and queue lengths were collected through a combination of manual traffic counting and recording using an unmanned aerial vehicle.

Based on the collected data, a microsimulation model of the existing intersection conditions and two design alternatives was developed and calibrated. The evaluation of the alternatives was carried out using traffic performance indicators, including queue length, delay time, and level of service. The results showed that the roundabout variant with spiral flow achieves significantly better traffic performance indicators compared to the existing condition and the conventional roundabout design.

Key words: intersection evaluation, microsimulation modeling, model calibration, unmanned aerial vehicles

1 UVOD

Rekonstrukcija postojećih raskrižja predstavlja složen zadatak u procesima unaprjeđenja cestovne mreže zbog ograničenog prostora, postojećih prometnih tokova

i potrebe za očuvanjem funkcionalnosti sustava tijekom izvođenja zahvata. U takvim uvjetima, kvaliteta prometno-tehničkih rješenja uvelike ovisi o pouzdanosti analiza postojećeg stanja i dostupnosti kvalitetnih ulaznih podataka.

Mikrosimulacijski modeli prometa sve se češće koriste kao alat za analizu postojećih prometnih uvjeta i evaluaciju varijantnih rješenja, budući da omogućuju detaljno modeliranje ponašanja pojedinačnih vozila i kvantitativnu usporedbu različitih prometnih rješenja prije njihove implementacije. Međutim, pouzdanost rezultata mikrosimulacijskih analiza u velikoj mjeri ovisi o kvaliteti kalibracije i validacije modela u odnosu na stvarne prometne uvjete, pri čemu nedostatak reprezentativnih i dovoljno detaljnih terenskih podataka često predstavlja značajno ograničenje.

Primjena bespilotnih letjelica (UAV – Unmanned Aerial Vehicle) i suvremenih metoda videoanalitike otvara nove mogućnosti za unapređenje procesa prikupljanja prometnih podataka. UAV snimanje omogućuje prostorno cjelovit i vremenski kontinuiran uvid u prometni tok, uključujući podatke o prometnim volumenima, brzinama kretanja vozila, formiranju repova čekanja i vremenima putovanja, koji su ključni za kvalitetnu kalibraciju mikrosimulacijskih modela.

U ovom radu prikazana je primjena UAV tehnologije u prikupljanju prometnih podataka te njihova uporaba u postupku kalibracije i validacije mikrosimulacijskog modela prometa. Na odabranoj studiji slučaja demonstrirana je izrada modela postojećeg stanja, njegova kalibracija temeljena na UAV-podacima te primjena kalibriranog modela u analizi varijantnih prometnih rješenja.

2 STUDIJA SLUČAJA: RAKRIŽJE OSJEČKE ULICE I ČVORA ŠKURINJE

2.1 Zona obuhvata

Istraživanje je provedeno na mikrolokaciji raskrižja Osječke ulice i čvora Škurinje u gradu Rijeci, neposredno prije provedbe njegove rekonstrukcije. Zbog prostorne složenosti i visokog prometnog opterećenja, odabrana lokacija prikladna je za primjenu i provjeru mikrosimulacijskih modela prometa.

Raskrižje predstavlja važnu vezu između gradskih prometnica i gradske obilaznice, pri čemu dolazi do izražene interakcije urbanog i tranzitnog prometa. Takva

funkcionalna uloga rezultira složenim prometnim tokovima i značajnim varijacijama prometnih opterećenja, osobito u vršnim razdobljima.

Zbog navedenih obilježja lokacija je odabrana kao studija slučaja za prikupljanje prometnih podataka primjenom bespilotnih letjelica (UAV) te za izradu, kalibraciju i validaciju mikrosimulacijskog modela koji vjerno odražava stvarne prometne uvjete.

2.2 Prikupljanje prometnih podataka

Prikupljanje prometnih podataka predstavlja ključnu fazu istraživanja jer osigurava ulazne parametre potrebne za izradu, kalibraciju i validaciju mikrosimulacijskog modela prometa. Cilj ove faze bio je dobiti pouzdan uvid u stvarne prometne uvjete na promatranom raskrižju, uključujući intenzitet i raspodjelu prometnih tokova te pokazatelje relevantne za kalibraciju ponašanja prometnog toka. U tu svrhu primijenjene su dvije metode prikupljanja podataka: ručno brojanje prometa i snimanje prometnica pomoću bespilotne letjelice (UAV), radi usporedbe i provjere međusobne usklađenosti rezultata.

Ručnim brojanjem prikupljeni su osnovni podaci o prometnim volumenima, strukturi i distribuciji prometnih tokova. Iako je metoda relativno jednostavna i fleksibilna, njezina primjena na složenim raskrižjima ograničena je mogućnošću ljudske pogreške, organizacijskim zahtjevima te nemogućnošću dugotrajnog i kontinuiranog prikupljanja podataka.


Primjena bespilotnih letjelica omogućila je prostorno cjelovito i vremenski kontinuirano prikupljanje prometnih podataka uz minimalno sudjelovanje ljudskih resursa. U kombinaciji sa softverom za automatsku detekciju i praćenje objekata dobiveni su detaljni podaci o intenzitetima i distribuciji prometnih tokova, strukturi vozila te brzinama kretanja, koje predstavljaju ključne ulazne parametre za kalibraciju mikrosimulacijskih modela [1], [2]. Dodatno, UAV metodom moguće je pouzdano odrediti i duljine repova čekanja, što značajno nadilazi mogućnosti tradicionalnih terenskih metoda.

Primjena UAV tehnologije ima i određena ograničenja. Trajanje snimanja ograničeno je kapacitetom baterije, koji kod većine komercijalnih sustava iznosi približno 20 do 30 minuta [3], iako se to djelomično može ublažiti primjenom tethered

sustava [4]. Nadalje, kvaliteta podataka ovisi o vremenskim uvjetima i osvjetljenju [5], dok regulatorni okviri mogu ograničiti primjenu UAV-a u urbanim područjima [6].

2.3 Obrada UAV podataka

Nakon terenskog prikupljanja, videosnimke dobivene primjenom bespilotne letjelice obrađene su u programskom alatu DataFromSky [7], koji omogućuje automatiziranu analizu prometnih tokova primjenom metoda računalnog vida. Ovakav pristup osigurava objektivnu i ponovljivu obradu podataka te omogućuje dobivanje ključnih kvantitativnih pokazatelja potrebnih za kalibraciju i validaciju mikrosimulacijskog modela prometa (slika 1).



Slika 1. Obrada podataka upotrebom alata DataFromSky

Primjenom alata dobiveni su prometni volumeni po smjerovima, brzine kretanja vozila te duljine repova čekanja po pojedinim prilazima raskrižju, koji predstavljaju osnovne ulazne parametre za usporedbu simuliranih i stvarnih prometnih uvjeta.

U odnosu na tradicionalne metode, UAV pristup omogućuje prostorno cjelovit i vremenski kontinuiran uvid u prometni tok, čime se povećava pouzdanost ulaznih podataka. Usporedbom rezultata dobivenih ručnim brojanjem i UAV metodom nisu utvrđene značajne razlike u osnovnim prometnim pokazateljima, što potvrđuje primjenjivost UAV prikupljenih podataka za mikrosimulacijsko modeliranje.

3 IZRADA, KALIBRACIJA I VALIDACIJA MIKROSIMULACIJSKOG MODELA

3.1 Izrada mikrosimulacijskog modela

Mikrosimulacijski model prometa izrađen je u softverskom alatu PTV Vissim s ciljem vjernog prikaza postojećeg prometnog stanja na promatranom raskrižju.

Izrađeni model poslužio je kao osnova za postupak kalibracije i validacije te za kasniju demonstraciju primjene na varijantna prometna rješenja.

Geometrija raskrižja definirana je u skladu s postojećim stanjem na terenu, uključujući prometne trake, širine kolnika, radijuse skretanja i položaje linija zaustavljanja. Geometrijski elementi uneseni su na temelju tehničke dokumentacije i terenskih opažanja, čime je osigurana prostorna usklađenost simulacijskog modela sa stvarnim prometnim okruženjem.

Ulazni prometni tokovi definirani su na temelju podataka dobivenih UAV snimanjem i njihove obrade u alatu DataFromSky, pri čemu su prometni volumeni uneseni po pojedinim smjerovima i prilazima raskrižju u skladu s izmjerenim prometnim obrascima. Prometna regulacija postavljena je prema postojećoj organizaciji prometa, dok su osnovni parametri ponašanja vozila preuzeti iz standardnih postavki softvera te naknadno prilagođeni u postupku kalibracije.

Izrađeni mikrosimulacijski model postojećeg stanja predstavljao je referentnu osnovu za provedbu kalibracije i validacije, nakon čega je korišten za analizu varijantnih prometnih rješenja.

3.2 Kalibracija modela


Kalibracija mikrosimulacijskog modela provedena je s ciljem što vjernijeg preslikavanja stvarnog prometnog toka na promatranom raskrižju, s posebnim naglaskom na prostorno-vremensku dinamiku kretanja vozila. Za razliku od klasičnog pristupa koji se često temelji isključivo na prometnim volumenima, u ovom istraživanju kalibracija je proširena na tri ključna pokazatelja ponašanja prometnog toka: brzine kretanja vozila, duljine repova čekanja i vrijeme putovanja na odabranoj sekciji. U tu svrhu korišteni su podaci dobiveni UAV analizom trajektorija vozila.

Kalibracija prema brzinama kretanja vozila

Brzina kretanja vozila predstavlja jedan od najosjetljivijih parametara mikrosimulacijskih modela, osobito u zonama zavoja i konfliktnih područja raskrižja. Softver PTV Vissim ne prepoznaje automatski geometrijske elemente ceste (npr. radijuse zavoja) na temelju kojih bi se prirodno smanjila brzina vozila, već se takvo ponašanje mora eksplicitno definirati kroz parametre modela. U praksi to često dovodi

do odstupanja između simuliranih i stvarnih brzina, osobito kada su dostupni samo ograničeni terenski podaci temeljeni na točkastim mjerenjima.

Primjenom UAV snimanja i analize trajektorija omogućeno je dobivanje kontinuiranih podataka o brzinama kretanja vozila duž cijele prometne sekcije, uključujući zone usporavanja u zavojima i pri prilasku raskrižju. Na temelju tih podataka prilagođeni su parametri željenih brzina i ponašanja vozila u modelu, čime je postignuta dobra podudarnost između simuliranih i opaženih brzina. Proces kalibracije mikrosimulacijskog modela prema brzinama kretanja vozila prikazana je na slici 3.



Slika 2. Kalibracija mikrosimulacijskog modela prema brzinama kretanja vozila – usporedba UAV podataka i simulacije

Kalibracija prema duljinama repova čekanja

Duljina repa čekanja jedan je od ključnih pokazatelja zagušenja na raskrižjima. U tradicionalnim terenskim istraživanjima najčešće se bilježi isključivo maksimalna duljina repa čekanja u određenom vremenskom presjeku, što ne pruža potpuni uvid u dinamiku zastoja. Suprotno tome, UAV analiza omogućuje kontinuirano praćenje formiranja, rasprostiranja i raspuštanja repova čekanja tijekom cijelog promatranog razdoblja.

U okviru ovog istraživanja UAV podaci korišteni su za kvalitativnu procjenu prosječnih, maksimalnih i minimalnih duljina repova čekanja po pojedinim prilazima raskrižju. Na temelju tih opažanja dodatno su prilagođeni parametri zasićenja, ponašanja pri prihvaćanju praznina i reakcije vozila u zoni raskrižja, kako bi simulirani repovi čekanja prostorno i vremenski odgovarali stvarnom stanju. Proces kalibracije

mikrosimulacijskog modela prema duljinama repova čekanja na prilazima raskrižju prikazana je na slici 4.




Slika 3. Kalibracija mikrosimulacijskog modela prema duljinama repova čekanja na prilazima raskrižju

Kalibracija prema vremenu putovanja

Vrijeme putovanja na odabranoj prometnoj sekciji predstavlja integrirani pokazatelj koji obuhvaća utjecaj brzina kretanja, geometrije prometne mreže, duljine dionica i zastoja u prometu. Zbog toga je ovaj pokazatelj posebno pogodan za dodatnu provjeru realnosti mikrosimulacijskog modela.

UAV analiza omogućila je praćenje pojedinačnih vozila duž definirane sekcije i određivanje stvarnog vremena putovanja, koje je zatim uspoređeno sa simuliranim vrijednostima. Na temelju te usporedbe dodatno su usklađeni parametri brzine i ponašanja vozila duž cijele mreže, čime je osigurano da simulirani prometni tok realno odražava i prostorne i vremenske karakteristike kretanja vozila. Proces kalibracije mikrosimulacijskog modela prema vremenu putovanja na odabranoj prometnoj sekciji prikazan je na slici 5.



Slika 4. Kalibracija mikrosimulacijskog modela prema vremenu putovanja na odabranoj prometnoj sekciji

Iterativni postupak kalibracije

Postupak kalibracije proveden je iterativno, pri čemu su parametri modela postupno prilagođavani na temelju usporedbe simuliranih i opaženih vrijednosti brzina, duljina repova čekanja i vremena putovanja. Proces je nastavljen sve dok nije postignuto zadovoljavajuće slaganje prometnog ponašanja u simulaciji sa stvarnim prometnim uvjetima, nakon čega je provedena kvantitativna validacija modela primjenom GEH statistike.

3.3 Validacija modela

Validacija mikrosimulacijskog modela provedena je iterativno, paralelno s postupkom kalibracije, do postizanja zadovoljavajuće podudarnosti između simuliranih i stvarnih prometnih uvjeta. Za razliku od pristupa koji se temelji isključivo na prometnim volumenima, u validaciji su korišteni i dodatni pokazatelji prometnog toka dobiveni UAV analizom, čime je osigurana cjelovitija provjera realnosti modela.

Uspoređivani su simulirani i opaženi prometni volumeni, brzine kretanja vozila, duljine repova čekanja i vremena putovanja, pri čemu je UAV analiza omogućila kvalitativnu provjeru prostorno-vremenske dinamike prometnog toka. Kvantitativna validacija prometnih volumena provedena je primjenom GEH statistike. Ulazni prometni volumeni kretali su se u rasponu od 122 do 734 vozila na sat, dok su simulirani volumeni iznosili između 134 i 691 vozila na sat. Za sve analizirane smjerove dobivene su GEH vrijednosti manje od 2 (0,25–1,61), što ukazuje na vrlo dobru podudarnost simuliranih i opaženih tokova te potvrđuje validaciju modela.

4 DEMONSTRACIJA PRIMJENE KALIBRIRANOG MODELA

Nakon provedene kalibracije i validacije, mikrosimulacijski model korišten je za demonstraciju primjene u analizi varijantnih prometnih rješenja. Kalibrirani model postojećeg stanja predstavlja pouzdanu osnovu za procjenu učinaka infrastrukturnih i organizacijskih zahvata, budući da vjerno reproducira stvarne prometne uvjete.

Primjena modela usmjerena je na usporedbu postojećeg stanja s predloženim varijantnim rješenjima, pri čemu su analizirani standardni pokazatelji prometne učinkovitosti raskrižja.

4.1 Primjena modela na varijantna rješenja

Kalibrirani i validirani mikrosimulacijski model primijenjen je na analizu dvaju varijantnih rješenja rekonstrukcije raskrižja, pri čemu su prometni volumeni zadržani jednaki postojećem stanju radi osiguranja usporedivosti rezultata.

U tablici 1 prikazana je usporedba osnovnih pokazatelja učinkovitosti za postojeće stanje i analizirane varijante na razini cijelog raskrižja.

Tablica 1. Usporedba prometnih pokazatelja za postojeće stanje i varijantna rješenja

Pokazatelj	Postojeće stanje	Varijanta 1	Varijanta 2
Prosječno kašnjenje [s/voz]	37,33	48,23	3,82
Prosječna duljina repa [m]	26,87	37,75	0,91
Razina usluge (LoS)	D	E	A

Rezultati pokazuju da Varijanta 2 ostvaruje značajna poboljšanja u odnosu na postojeće stanje, dok Varijanta 1 u pojedinim pokazateljima dovodi do pogoršanja prometnih uvjeta. Time se potvrđuje da kalibrirani mikrosimulacijski model omogućuje pouzdanu procjenu učinaka varijantnih rješenja i predstavlja vrijedan alat u procesu donošenja projektantskih odluka.

4.2 Ograničenja primjene

Unatoč visokoj razini detaljnosti, mikrosimulacijski model ne može u potpunosti obuhvatiti rijetka i nepredvidiva ponašanja sudionika u prometu, poput izvanrednih događaja ili izrazito atipičnog ponašanja vozača. Također, model pretpostavlja zadržavanje opaženih obrazaca ponašanja u budućim prometnim uvjetima, što može predstavljati ograničenje u slučaju značajnih promjena prometne potražnje ili regulacije.

Rezultati simulacije u velikoj mjeri ovise o kvaliteti ulaznih podataka. Iako UAV snimanje omogućuje detaljan uvid u prometni tok, njegova primjena ograničena je trajanjem snimanja, vremenskim uvjetima i regulatornim okvirom. Stoga rezultate mikrosimulacijskog modela treba promatrati kao potporu donošenju odluka, uz razumijevanje pretpostavki i ograničenja na kojima se temelje.

5 ZAKLJUČAK

Provedeno istraživanje potvrdilo je da primjena bespilotnih letjelica (UAV) u fazi prikupljanja prometnih podataka predstavlja značajan kvalitativni iskorak u postupku izrade, kalibracije i validacije mikrosimulacijskih modela prometa. Za razliku od tradicionalnih metoda terenskih istraživanja, UAV snimanje omogućuje dobivanje prostorno cjelovitih i vremenski kontinuiranih podataka o prometnom toku, uključujući parametre koji su u klasičnoj praksi često teško dostupni ili zahtijevaju dugotrajna i složena mjerenja, poput brzina kretanja vozila, formiranja repova čekanja i vremena putovanja.

Korištenjem UAV podataka u postupku kalibracije omogućeno je proširenje kalibracije s isključivo prometnih volumena na širi skup pokazatelja koji opisuju stvarnu prostorno-vremensku dinamiku prometnog toka. Takav pristup rezultirao je mikrosimulacijskim modelom koji vjerno reproducira stvarne prometne uvjete, što je potvrđeno kombinacijom kvalitativne validacije temeljene na UAV analizama i kvantitativne validacije prometnih volumena primjenom GEH statistike. Ostvarene vrijednosti GEH statistike ukazuju na visoku razinu podudarnosti simuliranih i opaženih prometnih tokova te potvrđuju pouzdanost izrađenog modela.

Primjena kalibriranog i validiranog modela na analizu varijantnih prometnih rješenja imala je demonstracijsku ulogu, s ciljem prikaza praktične uporabljivosti modela u procesu prometnog planiranja i projektiranja. Dobiveni rezultati jasno su pokazali da mikrosimulacijski model, temeljen na kvalitetnim UAV podacima, omogućuje osjetljivu i pouzdanu procjenu učinaka različitih prometnih rješenja, iako detaljna analiza varijanti nije primarni fokus ovog rada.

Zaključno, rezultati istraživanja potvrđuju da integracija UAV tehnologije u postupak kalibracije mikrosimulacijskih modela predstavlja snažan alat za unapređenje prometnih analiza i donošenje informiranih projektantskih odluka. Preporučuje se šira primjena UAV-prikupljenih podataka u praksi, osobito u analizi složenih raskrižja i

prometnih čvorišta, gdje tradicionalne metode prikupljanja podataka ne omogućuju dostatnu razinu detaljnosti potrebnu za pouzdano modeliranje prometnog toka.

POPIS LITERATURE:

- [1] V. Kastrinaki, M. Zervakis, i K. Kalaitzakis, „A survey of video processing techniques for traffic applications“, *Image Vis. Comput.*, sv. 21, izd. 4, str. 359–381, 2003, doi: 10.1016/S0262-8856(03)00004-0.
- [2] E. V. Butilă i R. G. Boboc, „Urban Traffic Monitoring and Analysis Using Unmanned Aerial Vehicles (UAVs): A Systematic Literature Review“, *Remote Sens.*, sv. 14, izd. 3, 2022, doi: 10.3390/rs14030620.
- [3] N. Mehendale, „Investigating the Battery Life Issues in Unmanned Aerial Vehicles: An Analysis of Challenges and Proposed Solutions“, *SSRN Electron. J.*, str. 1–10, 2023, doi: 10.2139/ssrn.4324196.
- [4] F. Fattori i S. Cocuzza, „Tethered Drones: A Comprehensive Review of Technologies, Challenges, and Applications“, *Drones*, sv. 9, izd. 6, 2025, doi: 10.3390/drones9060425.
- [5] M. Gao, C. H. Hugenholtz, T. A. Fox, M. Kucharczyk, T. E. Barchyn, i P. R. Nesbit, „Weather constraints on global drone flyability“, *Sci. Rep.*, sv. 11, izd. 1, str. 1–13, 2021, doi: 10.1038/s41598-021-91325-w.
- [6] J. P. and D. Mamchur, „A review on the state of the art in copter drones and flight control systems,“ *Sensors*, vol. 24, no. 11, Art. no. 3349, May 2024, doi: 10.3390/s24113349. “, 2024.
- [7] „DataFromSky, DataFromSky Traffic Analysis Software, 2024. [Online]. Available: <https://datafromsky.com>“.
- [8] „PTV Group, PTV Vissim. [Online]. Dostupno: <https://www.ptvgroup.com/en/products/ptv-vissim>.“
- [9] R. Dowling, A. Skabardonis, i V. Alexiadis, „Traffic Analysis Toolbox Volume III : Guidelines for Applying Traffic Microsimulation Modeling Software“, *Rep. No. FHWA-HRT-04-040, U.S. DOT, Fed. Highw. Adm. Washington, D.C.*, sv. III, izd. July, str. 146, 2004.
- [10] B. Park i J. D. Schneeberger, „Microscopic Simulation Model Calibration and Validation: Case Study of Vissim Simulation Model for a Coordinated Actuated Signal System“, *Transp. Res. Rec.*, izd. 1856, str. 185–192, 2003, doi: 10.3141/1856-20.
- [11] *National Academies of Sciences, Engineering, and Medicine, Highway Capacity Manual 7th Edition: A Guide for Multimodal Mobility Analysis. Washington, DC: The National Academies Press, 2022.*

DEA efficiency of two tunnel corridor alternatives using environmental and safety-relevant proxies Učinkovitost dviju varijanti tunelskog koridora prema DEA metodi uz okolišne i sigurnosno-relevantne proksije

Damir Budimir¹, Ivo Peko², Vlatka Ružić³, Pero Škorput⁴

¹ Assoc. Prof., PhD, Faculty of Transport and Traffic Sciences, dbudimir@fpz.unizg.hr

² PhD, Nikola Tesla Polytechnic of Gospić, Croatia, ivo.peko1@gmail.com

³ Asst. Prof., PhD, Nikola Tesla Polytechnic of Gospić, Croatia, vlatka.ruzic1@gmail.com

⁴ Assoc. Prof., PhD, Faculty of Transport and Traffic Sciences, Croatia,
pskorput@fpz.unizg.hr

Abstract. Purpose—To compare two tunnel-corridor alternatives linking the A1 motorway to state road D8 in the Kaštela area: Variant 1 (Radošić–Kaštel Stari, 6.0 km) and Variant 2 (Vučevica–Kaštel Kambelovac, 7.9 km). Methodology—Within the Smart Traffic Network project (STN-AI; EU NextGenerationEU), a compact Data Envelopment Analysis (DEA) model is applied using proxy indicators of performance and environmental/safety effects. Inputs are corridor length, capital expenditure (CAPEX) and a noise proxy; outputs are average operating speed, Floating Car Data (FCD)-based travel-time stability (Weibull) and driver workload (driver workload proxy). An AADT-based density proxy represents traffic exposure. Results—Variant 1 achieves higher relative efficiency ($\theta=1.00$) than Variant 2 ($\theta=0.77$), mainly due to a shorter corridor and a more favourable input–output balance. Conclusion—The approach provides transparent, data-driven support for early-stage tunnel corridor selection.

Sažetak. Svrha—Usporediti dvije varijante tunelskog koridora koje povezuju autocestu A1 s državnom cestom D8 na području Kaštela: Varijanta 1 (Radošić–Kaštel Stari, 6,0 km) i Varijanta 2 (Vučevica–Kaštel Kambelovac, 7,9 km). Metodologija—U okviru projekta Smart Traffic Network (STN-AI; EU NextGenerationEU) primijenjen je kompaktan model analize omeđivanja podataka (DEA) uz proksi pokazatelje prometne učinkovitosti te okolišnih i sigurnosno relevantnih učinaka. Ulazi su duljina koridora, kapitalni izdaci (CAPEX) i proksi buke; izlazi su prosječna operativna brzina, stabilnost vremena putovanja temeljena na Floating Car Data (FCD) (Weibull) te opterećenje vozača (mentalni napor/stres vožnje). Proksi gustoće temeljen na AADT-u predstavlja izloženost prometu. Rezultati—Varijanta 1 ostvaruje veću relativnu učinkovitost ($\theta = 1,00$) u odnosu na Varijantu 2 ($\theta = 0,77$), ponajprije zbog kraćeg koridora i povoljnijeg odnosa ulaza i izlaza. Zaključak—Pristup pruža transparentnu, podatkovno utemeljenu potporu ranoj fazi odabira tunelske trase.

Key words. AADT (Annual Average Daily Traffic), DEA (Data Envelopment Analysis), environmental and safety proxies, FCD (Floating Car Data), driver workload proxy.

Ključne riječi. *PGDP (prosječni godišnji dnevni promet), DEA (analiza omeđivanja podataka), okolišni i sigurnosni proksi pokazatelji, FCD (pokretna osjetila), proksi pokazatelj opterećenja vozača.*

1. INTRODUCTION

The development of transport infrastructure plays a key role in the modernization of urban areas, particularly in enhancing safety and traffic flow while mitigating negative environmental and economic effects [1]. The integration of tunnels into transport networks can improve connectivity between key locations by separating traffic flows and reducing surface-level conflicts, which may enhance road safety and operational performance and reduce local exposure impacts (e.g., noise) on adjacent urban areas. It can also support more efficient use of the existing network and help limit the need for additional surface-level expansions. Urban road infrastructure elements significantly affect safe driving conditions and operational performance [2].

Moreover, proper reorganization and routing of traffic flows can reduce the number of intersections, further enhancing safety and efficiency within the transport network [3]. Traditional methods for assessing transport network efficiency primarily rely on statistical analysis of traffic volume and density, which often produce variable results depending on time-based fluctuations, such as peak hours or seasonal variations [4, 5].

In contrast, this study combines Data Envelopment Analysis (DEA) with proxy indicators to provide a compact, transparent assessment of the relative efficiency of tunnel-corridor alternatives while accounting for investment, operational performance, and environmental/safety-relevant effects. Recent DEA applications in road-transport evaluation explicitly incorporate environmental and safety impacts (including undesirable outputs), supporting proxy-based formulations when direct measurements are limited [6]. Gravity-type accessibility indicators are often used to contextualise travel attractiveness and spatial demand patterns [7, 8]; however, to keep the formulation robust with only two DMUs, this paper focuses on a compact DEA indicator set. In previous research, Budimir et al. [9] applied DEA to assess the effectiveness of alternative urban traffic-flow solutions.

Recent transport-policy evaluations have also applied DEA with environmental outputs (e.g., emissions-related indicators) to support transparent benchmarking across alternatives, reinforcing the suitability of DEA for proxy-based sustainability assessments in early planning stages [10].

Traditional infrastructure appraisal often relies on static averages, which can obscure real-world traffic dynamics and variability. To address this gap, the paper follows the STN-AI rationale by introducing indicators derived from Floating Car Data (FCD). FCD enables the identification of stop-and-go patterns that are directly linked to congestion and environmental impacts. By incorporating FCD-based stability and human-factor proxies, the DEA evaluation is extended beyond purely geometric accessibility.

This work is disseminated within the STN-AI project (Smart Traffic Network: Integration of LRS Model, Weibull Distribution, and AI for Decoding FCD Data), which develops data-driven methods for analysing, predicting, and optimising traffic flows to improve efficiency, safety, and sustainability in urban environments. While STN-AI primarily focuses on Floating Car Data (FCD) analytics and AI-supported decision support, the present paper applies the same evidence-based rationale to strategic infrastructure planning by evaluating alternative tunnel corridors using DEA and proxy-based indicators. The presentation of this paper at CESTE (Rovinj) is supported through European Union – NextGenerationEU funding within the STN-AI framework.

This paper analyzes and compares two alternative tunnel routes:

- Variant 1: Radošić–Kaštel Stari junction (6.0 km), which connects the A1 highway to state road D8 in the Kaštel Stari area.
- Variant 2: Vučevica–Kaštel Kambelovac junction (7.9 km), linking the A1 highway to state road D8 in the Kaštel Kambelovac area.

To evaluate these routes, the following hypothesis is proposed:

H1: The Radošić–Kaštel Stari junction provides a more efficient transport solution than the Vučevica–Kaštel Kambelovac junction.

The analysis is based on an evaluation of technical-technological, transport-technological, economic, and environmental factors, aiming to identify the most favorable solution.

2. MATERIALS AND METHODS

The DEA model is used to compare the relative efficiency of two tunnel-corridor alternatives using a compact set of inputs and outputs [11]. The corridors are treated as DMUs and evaluated with respect to key engineering inputs (e.g., corridor length and CAPEX) and proxy indicators of performance, environmental impact and safety (e.g., operating speed, noise, FCD-based travel-time stability, and a driver-workload proxy, I_{TLX}). Driver workload is represented by a NASA-TLX-inspired composite proxy index (I_{TLX}) derived from corridor complexity factors (e.g., signalised intersections), rather than from a questionnaire-based TLX survey. This compact formulation supports transparent decision-making in early-stage corridor planning and avoids over-parameterization with only two DMUs.

Fig. 1 graphically illustrates the connection between the A1 highway and the D8 state road, including the corresponding AADT values for both variants, which are used as a traffic-exposure proxy.

Recent evidence from a systematic review shows that DEA is widely used as a nonparametric frontier method for assessing environmental performance in the transport sector, often relying on compact indicator sets and proxy measures when direct environmental observations are limited [10].




Fig. 1: Graphic representation of corridor alternatives linking the A1 highway and the D8 state road, including AADT values for both variants.

The two corridor alternatives are treated as decision-making units (DMUs). To avoid over-parameterization with only two DMUs, a compact set of engineering inputs and proxy indicators is adopted. Key indicators used in this paper are summarised in Table 1.:

Table 1. Key corridor characteristics and proxy indicators

Indicator	Variant 1 (Radošić–Kaštel Stari)	Variant 2 (Vučevica–Kaštel Kambelovac)
Corridor length (km)	6.0	7.9
Estimated CAPEX (EUR)	85,000,000	110,000,000
Number of lanes	4	2
Signalised intersections (count)	0	1
Noise level (dB)	65	55

Source: Authors' compilation (project documentation and proxy estimates).

3. RESULTS

Travel-time performance is estimated from corridor length and operating speed using $t=L/v$ (in hours), i.e., $t_{\min}=60L/v$. Table 2 reports corridor-level travel time and the corresponding average operating speed for both variants. To include driver workload as a desirable DEA output, the NASA-TLX composite index (I_{TLX}) is transformed to $1/I_{TLX}$ (higher values indicate lower workload).

Table 2. Travel time and average operating speed

Variant	Length (km)	Travel time (min)	Average operating speed (km/h)
---------	-------------	-------------------	--------------------------------

1 (Radošić–Kaštel Stari)	6.0	4.00	90.0
2 (Vučevica–Kaštel Kambelovac)	7.9	6.18	76.7

Source: Authors' calculations based on corridor length and assumed representative operating speeds; travel time computed as $t(\min) = 60 \cdot L / v$.

To provide a compact proxy of traffic exposure along each corridor, a section-level density proxy is computed as $\Delta G = (PGDP \cdot t) / v$, where PGDP denotes the annual average daily traffic (AADT), t is section travel time (h), and v is speed (km/h). The total corridor proxy is $G = \sum \Delta G$. The comparison coefficient is $K_{u12} = (G_1 - G_2) / G_2 \cdot 100\%$. A negative K_{u12} indicates lower exposure (more favourable) for Variant 1.

Table 3. Traffic-density proxy and comparison coefficient

Section	t (h)	L (km)	v (km/h)	PGDP (AADT)	ΔG (proxy)
1.1	0.05	5.0	100	18102	9.05
1.2	0.0167	1.0	60	18102	5.04
2.1	0.086	6.9	80	18102	19.46
2.2	0.016	1.0	60	18102	4.83
Totals					G1=14.09, G2=24.29, K _{u12} =-41.99%

Source: Authors' calculations based on AADT (PGDP) and section-level L and v . Proxy density was computed as $\Delta G = AADT \cdot t / L$ with $t = L / v$; corridor totals $G_1 = \sum \Delta G$, $G_2 = \sum \Delta G$, and the comparison coefficient $K_{u12} = (G_1 - G_2) / G_2 \times 100\%$.

The indicators above are combined with environmental and safety-relevant proxies (noise level and driver workload) and used within the DEA framework presented in the following subsection.

3.1 Analysis model of variant solutions based on the DEA method

Within the framework of DEA analysis, decision making units (DMUs - Decision Making Units) represent measurable entities that are compared in terms of efficiency and effectiveness. These units are based on predefined input and output variables. In this case, the DMU are two routes with tunnels that are evaluated according to the set technical-technological, transport-technological, economic and ecological criteria. DMU units are the two main routes that are analyzed:

1. Route Junction Radošić – Kaštel Stari (Length: 6.0 km)
2. Route Junction Vučevica – Kaštel Kambelovac (Length: 7.9 km)

3.2. Implementation

Based on these parameters, each route can be considered a separate DMU unit. DEA analysis can evaluate their effectiveness by considering how these variables affect the performance of each route.




Fig. 2: Classification of variables for the DEA operation of evaluation of variant solutions

For the DEA analysis with a solution, it is necessary to structure all relevant data as input and output variables for each of the two variants (DMUs).

3.3. Selected DEA model

The BCC (Banker–Charnes–Cooper) input-oriented DEA model (variable returns to scale) is applied to compare the two corridor alternatives (DMU1 and DMU2). Given that only two DMUs are available, the evaluation is based on a compact set of indicators to avoid over-parameterization, while environmental and safety-relevant effects are incorporated through proxy-based measures.

For DEA modelling purposes, the output variables describing traffic-flow efficiency and safety (ergonomics) are defined using FCD-based quantitative indicators.

Travel-time variability and stability (traffic-flow DNA). Travel time on the analysed segments is not treated only as a static average; instead, traffic-flow variability is modelled using the Weibull distribution. The probability density function of travel time t is given by (1):

$$f(t; \alpha, \beta) = \frac{\beta}{\alpha} \left(\frac{t}{\alpha}\right)^{\beta-1} e^{-(t/\alpha)^\beta}, t \geq 0 \quad (1)$$

Here, the shape parameter β represents the “segment DNA” (a robust indicator of flow stability and congestion occurrence), while the scale parameter α represents the characteristic travel time. A higher β value indicates smaller deviations from typical patterns; therefore, β can be treated as a desirable (to be maximized) output variable in the DEA model.

Mental workload index (NASA-TLX). As part of the safety and ergonomic evaluation, a composite driver mental workload index I_{TLX} is introduced. The index quantifies stress and workload caused by infrastructure complexity (e.g., passing through interchanges and interaction within a tunnel) and is computed as (2):

$$I_{TLX} = \sum_{i=1}^6 w_i \cdot R_i \quad (2)$$

where w_i are weighting factors and R_i are ratings for the six workload dimensions. In the DEA evaluation, I_{TLX} is an output variable (a safety proxy) that should be minimized to increase overall user efficiency.

Table 4. DEA indicator set and relative efficiency results

DMU (variant)	Length (km)	CAPEX (EUR M)	Noise (dB)	Avg speed (km/h)	β (stability)	I_{TLX} (workload)	Efficiency θ
1	6.0	85	65	90.0	3.42	28.5	1.00
2	7.9	110	55	76.7	2.15	42.0	0.77

Source: Authors' compilation and DEA calculations. Inputs (length, CAPEX, noise proxy) and outputs (average speed, Weibull shape parameter β as a travel-time stability proxy, and NASA-TLX workload index I_{TLX}) are derived from Tables 1–3 and the FCD-based analysis; θ denotes relative DEA efficiency (BCC model).

Note: In DEA, workload is treated as a desirable output using $(1 / I_{TLX})$, while Table 5 reports I_{TLX} values for interpretability.

DEA results (Table 4) indicate that Variant 1 lies on the efficiency frontier ($\theta = 1.00$), while Variant 2 attains $\theta = 0.77$ under the adopted proxy-based indicator set.

Variant 1 benefits from a shorter corridor and lower CAPEX, while maintaining higher operating speed, higher flow stability (β) and lower driver workload (I_{TLX}). Variant 2 may still offer broader network-level benefits (e.g., redistribution of demand), but these effects are not captured by the compact indicator set used here.

Table 5. Traffic flow stability dynamics (FCD-derived outputs)

Route alternative	Characteristic travel time α (min)	Weibull shape parameter β – flow stability index	workload proxy (I_{TLX})
Alternative 1 (Radošić – K. Stari)	4.00	3.42 (high stability)	28.5 (lower stress; 0 signalised intersections)
Alternative 2 (Vučevica – K. Kambelovac)	6.18	2.15 (moderate variability)	42.0 (higher stress; 1 signalised intersection)

Source: Authors' calculations based on Floating Car Data (FCD) analysis. The characteristic travel time α corresponds to the representative travel time for each alternative, β is the Weibull shape parameter estimated from FCD-derived travel-time samples (used as a flow-stability proxy), and I_{TLX} is a composite NASA-TLX workload index (proxy), contextualised by the number of signalised intersections.

4. DISCUSSION

The Data Envelopment Analysis (DEA) method enables a transparent multi-criteria comparison of corridor alternatives by evaluating relative efficiency from multiple inputs and outputs. In this study, the evaluation is intentionally kept compact due to the limited number of decision-making units, while environmental and safety considerations are represented via measurable proxy indicators (noise level, FCD-based stability, and NASA-TLX workload).

The two alternatives—Variant 1 (Junction Radošić–Kaštel Stari) and Variant 2 (Junction Vučevica–Kaštel Kambelovac)—are compared using investment-related inputs (corridor length and CAPEX) and proxy-based outputs describing operational performance and safety (average speed, FCD-based stability β , and NASA-TLX workload), together with an environmental proxy (noise level). The AADT-based density proxy provides additional context on relative traffic exposure; gravity-type accessibility indicators could be integrated in future work to further capture spatial demand effects [8].

Analytical results indicate that Variant 1 is the more efficient solution under the adopted DEA formulation ($\theta = 1.00$), driven by its shorter corridor and lower CAPEX while providing higher average operating speed, higher flow stability (β), and lower driver workload (I_{TLX}). Variant 2 achieves lower noise levels, but remains less efficient overall ($\theta = 0.77$) within the compact proxy-based indicator set.

However, despite being evaluated as less efficient within the selected proxy set, Variant 2 (Junction Vučevica–Kaštel Kambelovac) may offer additional network-level benefits that are not captured by the compact DEA formulation (e.g., demand redistribution, improved network resilience and accessibility for specific catchment areas). These broader effects should be examined in future work using network-wide assignment and socio-economic indicators.

5. CONCLUSIONS

Ultimately, the DEA-based evaluation—supported by a compact set of operational, environmental and safety-relevant proxies and complemented with the AADT-based density proxy—indicates Variant 1 as the preferred option in terms of relative efficiency. Variant 2 remains relevant from a wider regional-development perspective, highlighting the importance of combining quantitative efficiency assessment with qualitative discussion of broader socio-economic impacts.

6. ACKNOWLEDGMENT

This work and its presentation at the CESTE Conference (Rovinj) were supported by the European Union – NextGenerationEU through the institutional research project at the University of Zagreb, Faculty of Transport and Traffic Sciences: Smart Traffic Network: Integration of LRS Model, Weibull Distribution, and AI for Decoding FCD Data (STN-AI).

7. REFERENCES

- [1] Bošnjak, I. Intelligent Transport Systems – ITS 1. Zagreb: Faculty of Transport and Traffic Sciences, University of Zagreb, 2006, 271 p. ISBN 953-243-016-4.
- [2] Xu, H., & Wu, J. "What Road Elements are More Important than Others for Safe Driving on Urban Roads?" *Promet – Traffic&Transportation*, vol. 35, no. 6, 2023, pp. 814–828. <https://doi.org/10.7307/ptt.v35i6.394>
- [3] Kutty, A. A., Kucukvar, M., Abdella, G. M., Bulak, M. E., Onat, N. C. "Sustainability Performance of European Smart Cities: A Novel DEA Approach with Double Frontiers.", vol. 81, 2022, 103777. <https://doi.org/10.1016/j.scs.2022.103777>
- [4] Fabian, P., Čulík, K., Kalašová, A., Černický, L. "The Impact of Road Realignment on the Traffic Load in the Surrounding Area." *Vehicles*, 6(4), 2024, pp. 1942–1962. <https://doi.org/10.3390/vehicles6040095>
- [5] Nguyen, N. A., Schweizer, J., Rupi, F., Palese, S., Posati, L. "Superblock Design and Evaluation by a Microscopic Door-to-Door Simulation Approach." *ISPRS International Journal of Geo-Information*, 13(3), 77, 2024. <https://doi.org/10.3390/ijgi13030077>
- [6] Mansouri Kaleibar, M., Krmac, E. "A Novel Data Envelopment Analysis Framework for Performance Evaluation of European Road Transport Systems." *Promet –*

Traffic&Transportation, vol. 36, no. 1, 2024, pp. 24–41.
<https://doi.org/10.7307/ptt.v36i1.321>

[7] Dabagh, S.; Bresciani Miristice, L. M.; Gentile, G. (2024). Accessibility via public transport through gravity models based on open data. *Transport and Telecommunication*, 25(4), 359–369. DOI: 10.2478/ttj-2024-0026.

[8] Capoani, L. (2023). Review of the gravity model: origins and critical analysis of its theoretical development. *SN Business & Economics*, 3:95. DOI: 10.1007/s43546-023-00461-0.

[9] Budimir, D., Šoštarić, M., Vidović, K. "Data envelopment analysis for determining the efficiency of variant solutions for traffic flow organization." *Promet – Traffic & Transportation*, vol. 31, no. 3, 2019, pp. 341–353.
<https://doi.org/10.7307/ptt.v31i3.3202>. URL: <https://hrcak.srce.hr/221449>

[10] Ma, Y., Meszaros, F. "Applying data envelopment analysis to evaluate efficiency of low emission zone policies in European cities." *European Transport Research Review*, vol. 17, art. 60, 2025. <https://doi.org/10.1186/s12544-025-00758-1>

[11] Hatami-Marbini, A., Asu, J. O., Khoshnevis, P. Environmental performance assessment in the transport sector using nonparametric frontier analysis: A systematic literature review. *Computers & Industrial Engineering*, Vol. 189, 2024, 109968. doi:10.1016/j.cie.2024.109968.

ISTRAŽIVANJE I EVALUACIJA UČINKOVITOSTI USPORNIKA PROMETA U GRADU ZAGREBU

Izv. prof. dr. sc. Željko Šarić ¹, dr. sc. Tomislav Kučinić ¹, Andrej Kunštek ¹, mag. ing. traff., Mijo Majstorović², mag. ing. traff.

¹ Fakultet prometnih znanosti, Sveučilište u Zagrebu, Vukelićeva 4, 10 000 Zagreb

² Grad Zagreb, Trg Stjepana Radića 1, 10 000 Zagreb

Sažetak: Uspornici prometa predstavljaju jednu od često primjenjivanih mjera smirivanja prometa u urbanim sredinama, ali je zbog njihovog trošenja i dugotrajnog korištenja potrebno provjeravati njihovu funkcionalnost i tehničku usklađenost s propisanim zahtjevima. Sukladno tome, u ovom radu prikazani su rezultati terenskog istraživanja uspornika prometa na području Grada Zagreba, provedenog u okviru stručnog projekta, koji je obuhvatio terensko istraživanje uspornika prometa i analizu brzine prometnog toka na tim lokacijama. Detaljna analiza tehničkih karakteristika provedena je na ukupno 208 lokacija, obuhvaćajući pet različitih tipova uspornika. Analizirana je njihova usklađenost s važećim Pravilnikom o prometnim znakovima, signalizaciji i opremi na cestama, kao i njihov utjecaj na brzinu kretanja vozila. Rezultati pokazuju značajna odstupanja u visinama i izvedbi pojedinih uspornika, ali i razlike u učinkovitosti smanjenja brzine ovisno o tipu uspornika.

Ključne riječi: Uspornici prometa, Smirivanje prometa, Brzina prometnog toka, Urbana prometna mreža.

Abstract: Traffic calming devices represent one of the commonly applied traffic calming measures in urban areas; however, due to wear and long-term use, it is necessary to verify their functionality and technical compliance with prescribed requirements. Accordingly, this paper presents the results of a field investigation of traffic calming devices in the City of Zagreb, conducted within a professional project that included on-site inspections of traffic calming devices and an analysis of traffic flow speed at the same locations. A detailed analysis of technical characteristics was carried out at a total of 208 locations, covering five different types of traffic calming devices. Their compliance with the applicable Ordinance on traffic signs, signals, and road equipment was analysed, as well as their impact on vehicle speeds. The results indicate significant deviations in the height and construction of individual traffic calming devices, as well as differences in speed reduction effectiveness depending on the type of device.

Key words: Traffic Calming Devices, Traffic Calming, Traffic Flow Speed, Urban Road Network

UVOD

Sigurnost cestovnog prometa predstavlja jedan od temeljnih ciljeva upravljanja urbanim prometnim sustavima, pri čemu brzina kretanja vozila ima ključnu ulogu u nastanku i težini prometnih nesreća. U urbanim sredinama, osobito u zonama povećane prisutnosti pješaka, škola, vrtića i stambenih zona, primjenjuju se različite mjere smirivanja prometa s ciljem smanjenja brzine prometnog toka i povećanja sigurnosti svih sudionika u prometu. Jedna od najčešće korištenih fizičkih mjera smirivanja prometa su uspornici prometa, odnosno vertikalne izmjene kolničke površine koje prisiljavaju vozače na smanjenje brzine radi očuvanja komfora vožnje i sprječavanja mogućih oštećenja vozila. Njihova primjena temelji se na izravnom utjecaju na dinamiku kretanja vozila, čime se postiže smanjenje operativnih brzina i trebala bi se povećati razina prometne sigurnosti. Iako se uspornici široko primjenjuju u urbanim prometnim mrežama, njihova stvarna učinkovitost ovisi o pravilnom odabiru tipa uspornika, tehničkoj izvedbi, usklađenosti s propisanim standardima te položaju unutar prometne mreže. Nepravilno projektirani ili oštećeni uspornici mogu umanjiti očekivane sigurnosne učinke, negativno utjecati na prometni tok, povećati troškove eksploatacije vozila te uzrokovati dodatna opterećenja na infrastrukturu i okoliš. Prema dostupnim podacima, cestovna mreža Grada Zagreba sadrži više od 2.800 uspornika različitih tipova i konstrukcijskih rješenja, što upućuje na potrebu sustavne procjene njihove tehničke ispravnosti i stvarnih učinaka u prometnim uvjetima. Dosadašnja istraživanja često su se temeljila na ograničenim uzorcima ili su analizirala pojedine tipove uspornika, dok je cjelovita evaluacija njihove usklađenosti s propisima i utjecaja na brzinu prometnog toka u stvarnim urbanim uvjetima rjeđe zastupljena. U ovom radu prikazani su rezultati terenskog istraživanja uspornika prometa na području Grada Zagreba, s naglaskom na njihovu tehničku ispravnost, usklađenost s važećim propisima te utjecaj na brzinu kretanja vozila. Cilj rada je procijeniti učinkovitost različitih tipova uspornika u smanjenju brzine prometnog toka te identificirati ključne nedostatke u njihovoj primjeni, kako bi se unaprijedilo planiranje, projektiranje i održavanje mjera smirivanja prometa u urbanim prometnim mrežama.

1. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Kako bi se povećala sigurnost na kritičnim lokacijama prometne mreže, nužno je učinkovito smanjiti brzinu kretanja vozila. Mjere smirivanja prometa obuhvaćaju infrastrukturne zahvate kojima se smanjuju operativne brzine i povećava pažnja vozača, čime se poboljšava sigurnost svih sudionika u prometu [1]. Ove mjere najčešće se dijele na horizontalne zahvate, koji prisiljavaju vozače na promjenu putanje kretanja (suženja kolnika, šikane, kružni tokovi), te vertikalne zahvate, koji uzrokuju naglu promjenu visine kolničke površine, poput uspornika i uzdignutih ploha [2], [3]. U urbanim sredinama uspornici prometa predstavljaju jednu od najčešće primjenjivanih mjera smirivanja prometa. Kao vertikalne prepreke, oni izravno djeluju na ovjes vozila i razinu udobnosti vožnje, čime potiču vozače na smanjenje brzine kako bi izbjegli mehanička oštećenja i neudobnost pri prelasku preko prepreke [4].

Brojna istraživanja potvrđuju da pravilno projektirani uspornici mogu značajno smanjiti brzinu vozila i povećati sigurnost pješaka [5], [6]. Međutim, njihova primjena može imati i određene negativne učinke. Prelazak preko uspornika može produžiti vrijeme putovanja, povećati potrošnju goriva i emisije štetnih plinova te uzrokovati povećanu buku i vibracije u okolnom prostoru [7]. Također, učestalo usporavanje i ubrzavanje može povećati trošenje vozila i utjecati na učinkovitost prometnog sustava, uključujući i vrijeme dolaska žurnih službi. Učinkovitost uspornika ovisi o njihovim geometrijskim karakteristikama, materijalu izvedbe, položaju u prometnoj mreži i strukturi prometnog toka. Različite kategorije vozila različito reagiraju na vertikalne prepreke zbog razlika u masi, međuosovinskom razmaku i karakteristikama ovjesa [7], [8].

Unatoč velikom broju istraživanja, mnoga su se temeljila na ograničenim uzorcima ili su analizirala pojedine tipove uspornika bez sustavne procjene njihove tehničke usklađenosti s propisima. Također, rijetko se istodobno analiziraju geometrijske karakteristike uspornika, njihova stvarna izvedba i ponašanje vozača u stvarnim prometnim uvjetima. Nedavna istraživanja provedena u urbanim uvjetima ukazuju na važnost integracije geometrijske analize, usklađenosti s propisima i empirijskih mjerenja brzine u procjeni učinkovitosti vertikalnih mjera smirivanja prometa [9].

S obzirom na velik broj uspornika u urbanim prometnim mrežama i njihovu važnu ulogu u povećanju sigurnosti prometa, potrebno je provoditi sustavna terenska istraživanja koja omogućuju procjenu njihove funkcionalnosti i stvarnih učinaka. Takav pristup pruža pouzdanu osnovu za unapređenje planiranja, projektiranja i održavanja mjera smirivanja prometa u suvremenim urbanim prometnim sustavima.

2. METODOLOGIJA ISTRAŽIVANJA

Metodologija istraživanja osmišljena je kako bi se omogućila cjelovita procjena tehničke ispravnosti uspornika prometa i njihovog utjecaja na brzinu kretanja vozila u stvarnim urbanim prometnim uvjetima. Istraživanje je obuhvatilo terenski pregled i tehničku analizu uspornika te mjerenje brzine prometnog toka na odabranim lokacijama. Takav pristup omogućuje istodobnu procjenu usklađenosti s važećim propisima i stvarne učinkovitosti mjera smirivanja prometa.

2.1. Područje istraživanja i obuhvat

Istraživanje uspornika prometa provedeno je na urbanoj prometnoj mreži Grada Zagreba, na kojoj je evidentirano ukupno 2.823 uspornika. Cilj istraživanja bio je procijeniti tehničku usklađenost uspornika s važećim propisima te utvrditi njihov utjecaj na brzinu kretanja vozila. Radi osiguravanja reprezentativnosti uzorka, prometna mreža Grada Zagreba podijeljena je prema administrativnim granicama 17 gradskih četvrti. Nakon identifikacije svih lokacija uspornika, odabran je uzorak od 208 lokacija za detaljnu analizu. Kriterij odabira bio je da svaka gradska četvrt bude zastupljena s najmanje 12 lokacija, uz nastojanje obuhvaćanja različitih tipova uspornika i prometnih situacija (npr. blizina raskrižja, pješačkih prijelaza, autobusnih stajališta i zavoja). Prostorni raspored analiziranih lokacija uspornika na području Grada Zagreba prikazan je na Slici 1.



Slika 1. Prostorna raspodreanjenost analiziranih lokacija na prometnoj mreži Grada Zagreba

2.2. Postupak mjerenja

Terensko istraživanje provedeno je s ciljem utvrđivanja tehničke sukladnosti uspornika s važećim nacionalnim propisima (NN 92/2019)[10] te analize njihovog utjecaja na brzinu kretanja vozila. Pregled lokacija obuhvatio je mjerenje geometrijskih karakteristika uspornika, materijala izrade te kvalitete njihove ugradnje. Mjerenje brzine kretanja vozila provedeno je na osam odabranih lokacija, pri čemu su brzine zabilježene prije nailaska na uspornik i na samom usporniku. Za potrebe mjerenja korištena je bespilotna letjelica (UAV) u kombinaciji sa softverskim alatom DataFromSky, koji omogućuje analizu prometnih tokova, određivanje brzina kretanja i klasifikaciju prometnih entiteta na temelju video zapisa iz zraka[9].

Primjena UAV tehnologije odabrana je jer tradicionalni uređaji za mjerenje brzine postavljeni uz kolnik mogu utjecati na ponašanje vozača. Snimanje iz zraka omogućuje bilježenje stvarnog ponašanja sudionika u prometu bez njihove svjesnosti o mjerenju. Na svakoj lokaciji definirane su dvije mjerne točke. Prva mjerna točka nalazila se približno 120–135 m prije uspornika, dok je druga bila postavljena neposredno na usporniku. Raspored mjernih točaka u odnosu na uspornik prikazan je na Slici 2.




Slika 2. Položaj mjernih točaka za mjerenje brzine vozila u zoni uspornika na lokaciji Borongajska cesta

Takav raspored omogućio je usporedbu brzina kretanja vozila prije i tijekom prelaska preko uspornika te analizu promjena brzine, prva mjerna točka omogućuje bilježenje brzine vozila u slobodnom toku, dok druga prikazuje brzinu pri prelasku preko uspornika. Tijekom analize izvršena je klasifikacija vozila u pet kategorija: osobni automobili, laka teretna vozila, teška teretna vozila, autobusi i motocikli. Vozila koja su evidentirana samo na jednoj mjernoj točki nisu uključena u analizu kako bi se osigurala točnost rezultata. Snimanje na svakoj lokaciji trajalo je približno 15 minuta, što odgovara trajanju baterijskog ciklusa bespilotne letjelice. Mjerenja su provedena tijekom dnevnog razdoblja, u stabilnim vremenskim i prometnim uvjetima, kako bi se smanjio utjecaj vanjskih čimbenika na brzinu kretanja vozila. U analizi su razmatrani ključni parametri, uključujući visinu i geometriju uspornika, materijal izrade, pokrivenost kolnika, ograničenje brzine te brzine vozila na obje mjerne točke. Ovakav pristup omogućuje usporedbu učinkovitosti različitih vrsta uspornika i osigurava transparentnost metodološkog postupka.

2.3. Obrada i analiza podataka

Sukladnost pojedinih vrsta uspornika s važećim nacionalnim propisima ocijenjena je na temelju njihove visine, duljine, materijala izrade, načina ugradnje te prisutnosti propisane prometne signalizacije. Terenskim pregledom na području Grada Zagreba identificirano je pet različitih tipova uspornika: (a) izbočine u obliku jastuka, (b) uzdignute plohe, (c) gumene četvrtaste izbočine, (d) gumene izbočine u obliku jastuka te (e) uske plohe.



Slika 3. Vrste analiziranih uspornika

Uzdignute plohe čine najveći udio analiziranog uzorka (101 od 208 lokacija) te pokazuju najvišu razinu sukladnosti s propisima (85 %). Njihova trajna građevinska izvedba i potpuna pokrivenost kolnika doprinose učinkovitom smanjenju brzine vozila. Uske plohe, iako zastupljene u malom broju, ostvarile su potpunu sukladnost (100 %). Suprotno tome, gumene izbočine u obliku jastuka pokazale su najnižu razinu sukladnosti (40 %), prvenstveno zbog degradacije materijala i nepravilne ugradnje. Gumene četvrtaste izbočine i izbočine u obliku jastuka ostvarile su srednju razinu sukladnosti (60 % odnosno 72 %), što ukazuje na

varijabilnost u izvedbi i održavanju. Najniža razina sukladnosti zabilježena je kod gumenih izbočina u obliku jastuka, što ukazuje na probleme vezane uz održavanje i trajnost materijala.


Tablica 1 Sukladnost uspornika s propisima na području Grada Zagreba.

Vrsta uspornika	Broj analiziranih lokacija	Sukladnost s propisima (%)
Uzdignute plohe	101	85%
Gumene četvrtaste izbočine	52	60%
Izbočine u obliku jastuka	37	72%
Gumene izbočine u obliku jastuka	13	40%
Uske plohe	3	100%

Uzdignute plohe pokazale su se najprikladnijim tipom uspornika jer pokrivaju cijelu širinu kolnika, jasno su označene i rijetko su oštećene. Nasuprot tome, gumene modularne izvedbe često ne pokrivaju cijelu prometnu traku, podložnije su oštećenjima te u pojedinim slučajevima prelaze dopuštenu visinu. Rezultati geometrijskih mjerenja pokazali su da jedino uzdignute plohe u potpunosti zadovoljavaju dimenzijske zahtjeve propisane Pravilnikom (NN 92/2019) [10], dok su kod ostalih vrsta zabilježena odstupanja, osobito u pogledu visine.

3. REZULTATI

Na temelju prikupljenih podataka provedena je detaljna analiza brzine kretanja vozila u zoni uspornika. Podaci su obrađeni tablično te su prikazane prosječne brzine kretanja vozila po kategorijama, kao i promjene brzine između mjernih točaka. Slika 4 prikazuje prostorni raspored osam lokacija na području Grada Zagreba na kojima su provedena mjerenja brzine i brojanja prometa.



Slika 4. Lokacije mjerenja uspornika na području Grada Zagreba (žute oznake označavaju analizirane lokacije)

Ukupno je analizirano 906 prolazaka vozila, od čega 862 osobna automobila, 94 laka teretna vozila, 26 teških teretnih vozila, 17 autobusa i 7 motocikala. U analizu su uključena samo vozila koja su evidentirana na obje mjerne točke kako bi se osigurala točnost rezultata. Manji uzorci pojedinih kategorija vozila, osobito teških teretnih vozila, autobusa i motocikala, zahtijevaju oprez pri interpretaciji rezultata za te skupine.

3.1. Rezultati mjerenja u zoni uspornika izbočina u obliku jastuka

Na analiziranoj lokaciji razmak između mjernih točaka iznosio je približno 120 m. U mjernom području nalazila su se dva trokraka raskrižja koja su utjecala na varijabilnost brzina kretanja vozila. Ukupno je analizirano 125 vozila. U Tablici 2 vidljiva je prosječna brzina kretanja prije uspornika iznosila je 38,5 km/h, dok je prosječna brzina na usporniku iznosila 29,7 km/h, što predstavlja smanjenje brzine od približno 23 % u odnosu na ograničenje brzine od 50 km/h.

Tablica 2. Prosječne brzine kretanja vozila u zoni uspornika izbočina u obliku jastuka

Kategorije vozila	Prosječna brzina (km/h)	Prosječna brzina (km/h)	Promjena (%)
	– Mjerna točka 1	– Mjerna točka 2	
Osobni automobili	38.90	29.68	-23.7
Teška teretna vozila	19.91	18.28	-8.19
Laka teretna vozila	42.02	33.56	-20.13
Autobusi	32.57	32.57	0
Motocikli	/	37.13	/

Osobni automobili i laka teretna vozila pokazali su značajno smanjenje brzine (–23,7 % i –20,1 %), dok je kod teških teretnih vozila zabilježeno manje smanjenje (–8,2 %). Kod autobusa nije uočena promjena brzine, što se može povezati s prisutnošću autobusnog stajališta u zoni mjerenja. Rezultati ukazuju da izbočine u obliku jastuka učinkovito smanjuju brzinu osobnih i lakih teretnih vozila.

3.2. Rezultati mjerenja u zoni uspornika uska ploha

Na predmetnoj lokaciji razmak mjernih točaka iznosio je približno 125 m. Mjerno područje uključivalo je pristupe trgovačkom centru, ulaz u školu, signalizirano raskrižje te obilježeni pješački prijelaz. Prosječna brzina kretanja prije uspornika vidljiva je u tablici 3 te je iznosila 45,8 km/h, dok je na usporniku iznosila 20,9 km/h. Time je ostvareno smanjenje brzine od približno 48 % u odnosu na ograničenje od 40 km/h.

Tablica 3. Prosječna brzina kretanja vozila u zoni uspornika uska ploha

Kategorije vozila	Prosječna brzina (km/h)	Prosječna brzina (km/h)	Promjena (%)
	– Mjerna točka 1	– Mjerna točka 2	
Osobni automobili	46.23	20.91	-54.77
Laka teretna vozila	35	20.24	-42.17

Rezultati potvrđuju da uske plohe značajno smanjuju brzinu kretanja vozila, osobito u zonama povećanog rizika poput školskih zona i pješačkih prijelaza.

3.3. Rezultati mjerenja u zoni gumenih izbočina u obliku jastuka

Na ovoj lokaciji razmak mjernih točaka iznosio je približno 125 m. Mjerno područje uključivalo je raskrižje, pješački prijelaz i zonu osnovne škole. Rezultati u tablici 4 pokazuju minimalno smanjenje brzine osobnih automobila i lakih teretnih vozila (oko 3 %), dok je kod teških teretnih vozila i autobusa zabilježeno povećanje brzine. Takvi rezultati upućuju na to da veća vozila prelaze ovu vrstu uspornika bez značajnog utjecaja na dinamiku kretanja.

Tablica 4. Prosječna brzina kretanja vozila u zoni gumenih izbočina u obliku jastuka

Kategorije vozila	Prosječna brzina (km/h) – Mjerna točka 1	Prosječna brzina (km/h) – Mjerna točka 2	Promjena (%)
Osobni automobili	36.54	35.36	-3.23
Teška teretna vozila	23.19	26.48	14.19
Laka teretna vozila	49.77	48.30	-2.95
Autobusi	15.76	28.55	81.15
Motocikli	44.33	43.10	-2.77

Dobiveni rezultati pokazuju da gumene izbočine u obliku jastuka imaju ograničenu učinkovitost u smanjenju brzine prometnog toka.

3.4. Rezultati mjerenja u zoni gumenih četvrtastih izbočina

Mjerenja su provedena na dvije lokacije kako bi se dobio reprezentativan uzorak. U tablici 5 vidljiva je prosječna brzina kretanja osobnih automobila smanjena je za približno 36 %, dok su laka teretna vozila smanjila brzinu za oko 21 %. Suprotno tome, kod teških teretnih vozila i autobusa zabilježeno je povećanje brzine, što ukazuje na to da veća vozila prelaze uspornik bez značajnog utjecaja zbog njegove ograničene širine.

Tablica 5. Prosječna brzina kretanja vozila u zoni gumenih četvrtastih uspornika

Kategorije vozila	Prosječna brzina (km/h) – Mjerna točka 1	Prosječna brzina (km/h) – Mjerna točka 2	Promjena (%)
Osobni automobili	47.00	30.07	-36.02
Teška teretna vozila	31.87	34.25	7.47
Laka teretna vozila	46.46	36.60	-21.22
Autobusi	29.53	43.69	47.95
Motocikli	43.30	37.37	-13.7

Rezultati sugeriraju da gumene četvrtaste izbočine učinkovito smanjuju brzinu osobnih vozila, ali imaju ograničen učinak na veća vozila.

3.5. Rezultati mjerenja u zoni uzdignutih ploha

Mjerenja su provedena na tri lokacije, udaljenost između mjernih točaka iznosila je od 115 do 130 metara. Prosječna brzina prije uspornika iznosila 53,8 km/h, a na usporniku 26,1 km/h.

Smanjenje brzine zabilježeno je kod svih kategorija vozila i iznosilo je više od 50 % osim za motocikle gdje je smanjenje brzine iznosilo 44,16 % dok su autobusi i teška teretna vozila ostvarili najveće smanjenje brzine. U tablici 6 prikazane su prosječne brzine kretanja vozila u zoni uzdignutih ploha.

Tablica 6. Prosječna brzina kretanja vozila u zoni uzdignutih ploha

Kategorije vozila	Prosječna brzina (km/h)	Prosječna brzina	Promjena (%)
	Mjerna točka 1	(km/h) Mjerna točka 2	
Osobni automobili	54.48	26.73	-50.94
Teška teretna vozila	51.11	22.22	-56.53
Laka teretna vozila	53.23	25.67	-51.78
Autobusi	46.29	18.57	-59.88
Motocikli	37.25	20.80	-44.16

Rezultati potvrđuju da uzdignute plohe predstavljaju najučinkovitiju mjeru smirivanja prometa.

Usporedba rezultata pokazuje značajne razlike u učinkovitosti pojedinih tipova uspornika. Najveće smanjenje brzine zabilježeno je na uzdignutim ploham a i uskim ploham a, dok su gumene izbočine u obliku jastuka pokazale najmanju učinkovitost u smirivanju prometa. Rezultati jasno potvrđuju da geometrijske karakteristike, širina zahvata kolnika i način izvedbe uspornika imaju ključnu ulogu u utjecaju na brzinu prometnog toka.

4. RASPRAVA

Provedena analiza mjerenja brzine i brojanja prometa na osam lokacija u Gradu Zagrebu pokazala je značajne razlike u učinkovitosti pojedinih tipova uspornika. Prosječne brzine vozila na uspornicima kretale su se od 20,9 km/h na uskim ploham a do 35,7 km/h na gumenim izbočinama u obliku jastuka, što potvrđuje da geometrija i izvedba uspornika imaju ključnu ulogu u smanjenju brzine. Najmanje prosječne brzine zabilježene su na uskim ploham a i uzdignutim ploham a, dok su najveće zabilježene na gumenim izbočinama u obliku jastuka i gumenim četvrtastim izbočinama. Promatrano prema kategorijama vozila, laka teretna vozila ostvarila su najveće brzine prelaska uspornika, dok su teška teretna vozila bilježila najniže brzine. Na svim lokacijama prosječne brzine na uspornicima bile su niže od referentne vrijednosti od 40 km/h, no učinkovitost pojedinih tipova značajno se razlikovala. Uzdignute plohe pokazale su najvišu razinu učinkovitosti jer su dosljedno smanjivale brzine ispod 30 km/h za sve kategorije vozila. Ovakvi rezultati potvrđuju njihovu visoku sigurnosnu vrijednost, osobito u zonama povećanog rizika poput školskih zona i pješačkih prijelaza. Slične zaključke navode Kosakowska i drugi autori, koji ističu platforme kao najučinkovitiju mjeru smirivanja prometa u urbanim sredinama. Uske plohe također su pokazale vrlo visoku učinkovitost, s najvećim postotnim odstupanjem od ograničenja brzine (-48 %). Njihova učinkovitost proizlazi iz nagle promjene vertikalnog profila kolnika te prometnog okruženja u kojem se najčešće primjenjuju. Nasuprot tome, gumene izbočine u obliku jastuka pokazale su najmanju učinkovitost. Prosječne brzine prelaska bile su najviše, a kod teških vozila i autobusa zabilježeno je čak i povećanje brzine. Ovakav rezultat može se objasniti njihovom modularnom konstrukcijom i ograničenom širinom (oko 2 m), koja je manja od traga kotača teških vozila. Zbog toga vozači kamiona i autobusa mogu djelomično izbjeći vertikalnu deformaciju, čime se smanjuje mehanički učinak uspornika i percepcija potrebe za usporavanjem. Slične zaključke navodi Obregón-Biosca, koji ističe ograničenu učinkovitost modularnih uspornika za teška vozila. Gumene četvrtaste izbočine pokazale su značajno smanjenje brzine osobnih vozila, ali ograničen učinak na autobuse i teška teretna vozila. Budući da ne pokrivaju punu širinu kolnika, veća vozila mogu ih prijeći uz minimalan utjecaj na ovjes i stabilnost vozila.

Rezultati također potvrđuju važnost tehničke ispravnosti i sukladnosti s propisima. S obzirom na to da značajan dio uspornika u Zagrebu ne zadovoljava dimenzijske zahtjeve propisane Pravilnikom, njihova stvarna učinkovitost može biti smanjena. Potrebno je uzeti u obzir i ograničenja istraživanja. Analiza je obuhvatila osam lokacija, što ne mora u potpunosti

reprezentirati sve prometne uvjete u urbanom prostoru. Na brzine su mogli utjecati prometna gustoća, geometrija prometnice, prisutnost pješačkih prijelaza i autobusnih stajališta te opterećenost vozila. Također, mjerenja su provedena u stabilnim vremenskim uvjetima i izvan vršnih opterećenja prometa. Unatoč navedenim ograničenjima, rezultati pružaju pouzdanu osnovu za razumijevanje utjecaja različitih tipova uspornika na brzinu kretanja vozila. Dobiveni nalazi potvrđuju da uspornici koji zahvaćaju punu širinu kolnika i imaju kontinuiranu građevinsku izvedbu osiguravaju najveću razinu smanjenja brzine.

S praktičnog aspekta, rezultati upućuju na potrebu prioritiziranja uzdignutih ploha i sličnih konstrukcijskih rješenja na lokacijama gdje je nužno osigurati niske brzine kretanja, poput školskih zona i stambenih ulica. Suprotno tome, primjenu modularnih gumenih uspornika potrebno je pažljivo razmotriti, osobito na prometnicama s većim udjelom teških vozila, jer njihova ograničena učinkovitost može smanjiti ukupni učinak mjera smirivanja prometa.

5. ZAKLJUČAK

Provedeno istraživanje omogućilo je cjelovitu procjenu tehničke ispravnosti i učinkovitosti uspornika prometa na urbanoj prometnoj mreži Grada Zagreba. Terenskim pregledom i analizom na 208 lokacija utvrđena su značajna odstupanja u geometrijskim karakteristikama i sukladnosti s važećim propisima, što potvrđuje potrebu sustavnog nadzora i standardizacije njihove primjene. Rezultati mjerenja brzine kretanja vozila na osam lokacija pokazali su jasne razlike u učinkovitosti pojedinih tipova uspornika. Uzdignute plohe pokazale su se najučinkovitijim rješenjem, jer su dosljedno smanjivale brzine svih kategorija vozila za više od 50 % te osiguravale brzine kretanja znatno ispod referentne vrijednosti od 40 km/h. Uske plohe također su ostvarile vrlo značajno smanjenje brzine, osobito u zonama povećanog rizika. Nasuprot tome, modularni gumeni uspornici pokazali su ograničenu učinkovitost. Gumene izbočine u obliku jastuka omogućavale su veće brzine prelaska, a kod teških vozila i autobusa zabilježeno je čak i povećanje brzine, što se može objasniti njihovom ograničenom širinom i mogućnošću djelomičnog izbjegavanja vertikalne deformacije. Gumene četvrtaste izbočine učinkovito su smanjivale brzinu osobnih vozila, ali su imale ograničen učinak na veća vozila. Rezultati istraživanja potvrđuju da geometrijske karakteristike, širina zahvata kolnika i konstrukcijska izvedba uspornika imaju ključnu ulogu u smanjenju brzine prometnog toka. Uspornici koji zahvaćaju punu širinu kolnika i imaju kontinuiranu građevinsku izvedbu osiguravaju najveću razinu sigurnosti i ujednačeno djelovanje na sve kategorije vozila.

Ograničenja istraživanja odnose se na broj analiziranih lokacija i kratkotrajno razdoblje mjerenja, kao i na utjecaj lokalnih prometnih uvjeta, geometrije prometnica i opterećenja vozila. Buduća istraživanja trebala bi obuhvatiti dugoročnija mjerenja, analizu različitih geometrijskih varijanti uspornika te procjenu njihovih utjecaja na emisije, buku i troškove eksploatacije vozila. Rezultati upućuju na potrebu prioritiziranja uzdignutih ploha i sličnih punoprofilnih rješenja na lokacijama gdje je nužno osigurati niske brzine kretanja, poput školskih zona, stambenih ulica i područja povećane prisutnosti pješaka. Primjenu modularnih gumenih uspornika potrebno je pažljivo razmotriti, osobito na prometnicama s većim udjelom teških vozila. Dobiveni rezultati pružaju pouzdanu stručnu osnovu za unapređenje planiranja, projektiranja i održavanja mjera smirivanja prometa te doprinose razvoju učinkovitijih i standardiziranih rješenja za upravljanje brzinama u urbanim prometnim mrežama.

5. LITERATURA

- [1] I. M. Lockwood, "ITE traffic calming definition," *ITE Journal (Institute of Transportation Engineers)*, vol. 67, no. 7, pp. 22–27, 1997.
- [2] K. R. Kiran, M. Kumar, and B. Abhinay, "Critical Analysis of Speed Hump and Speed Bump and Geometric Design of Curved Speed Hump," in *Transportation Research Procedia*, Elsevier B.V., 2020, pp. 1211–1226. doi: 10.1016/j.trpro.2020.08.144.
- [3] K. Kosakowska, "Evaluation of the impact of speed bumps on the safety of residents - selected aspects," in *Transportation Research Procedia*, Elsevier B.V., 2022, pp. 418–423. doi: 10.1016/j.trpro.2021.12.054.
- [4] V. Barone, D. W. E. Mongelli, and A. Tassitani, "Vibrational comfort on board the vehicle: Influence of speed bumps and comparison between different categories of vehicle," *Adv. Acoust. Vib.*, vol. 2016, no. iii, pp. 26–31, 2016, doi: 10.1155/2016/2676021.
- [5] B. Antić, D. Pešić, M. Vujanić, and K. Lipovac, "The influence of speed bumps heights to the decrease of the vehicle speed - Belgrade experience," *Saf. Sci.*, vol. 57, pp. 303–312, Aug. 2013, doi: 10.1016/j.ssci.2013.03.008.
- [6] M. Pau and S. Angius, "Do speed bumps really decrease traffic speed? An Italian experience," *Accid. Anal. Prev.*, vol. 33, no. 5, pp. 585–597, 2001, doi: 10.1016/S0001-4575(00)00070-1.
- [7] S. A. Obregón-Biosca, "Speed humps and speed tables: Externalities on vehicle speed, pollutant emissions and fuel consumption," *Results in Engineering*, vol. 5, Mar. 2020, doi: 10.1016/j.rineng.2019.100089.
- [8] K. Reif Ed, *Brakes, Brake Control and Driver Assistance Systems*. Wiesbaden: Springer Fachmedien Wiesbaden, 2014. doi: 10.1007/978-3-658-03978-3.
- [9] Ž. Šarić, T. Kučinić, A. Kunštek, and J. Ondruš, "The Impact of Speed Bumps on Traffic Flow Speed in Urban Road Networks," *Applied Sciences (Switzerland)*, vol. 15, no. 22, Nov. 2025, doi: 10.3390/app152212221.
- [10] Ministarstvo mora turizma prometa i razvitka, "Pravilnika o prometnim znakovima, signalizaciji i opremi na cestama," Mar. 03, 2005, *Narodne novine NN 33/2005*, Zagreb. Accessed: Jan. 16, 2025. [Online]. Available: https://narodne-novine.nn.hr/clanci/sluzbeni/2005_03_33_662.html



Solutions designed to save lives



ANDROMEDA

H2 AND H4B BRIDGE RAIL

- H2W1 and H4bW2 containment level
- EPD Certification
- Compact size
- SMART Technology
- CE Certified
- Totally Repairable

STARGATE

H2 BARRIER GATE

- Containment Level H2
- Minimum Working Width for the category
- Complete system opening in 10 minutes
- Easy to handle
- Emergency opening in 30 seconds
- Compact size



TITANUS



H4B BARRIER GATE

- Containment Level H4b
- Working width W2
- Module opening in 2 minutes
- Fast installation and simple handling
- Pre-assembled modules
- Transition to Concrete and Steel Barriers
- CE certified



INFORMACIJSKI I TELEKOMUNIKACIJSKI SUSTAVI

**RADIO KOMUNIKACIJSKI
SUSTAVI**

**ITS – INTELIGENTNI
TRANSPORTNI SUSTAVI**

www.viateł.hr



MATERIJALI ZA
CESTOVNU
SIGNALIZACIJU
ZA MAKSIMALNU
SIGURNOST
PROMETA,
TRAJNOST I
POUZDANOST.

www.kansai-helios.hr

KANSAI HELIOS Croatia d.o.o.

Radnička cesta 173d, 10000 Zagreb, Hrvatska
E: info@kansai-helios.hr | T: +385 (0)1 2410 666
Part of KANSAI PAINT.

 **KANSAI
HELIOS**

BIM PROJEKTIRANJE PROMETNICA I INFRASTRUKTURE

s integracijom obnovljivih izvora energije
u realizaciji projekta



FALCON 8 d.o.o.

-  **BIM projektiranje** prometnica i infrastrukture
-  **Pametni sustavi** rasvjete
-  **Savjetovanje** i priprema EU projekata
-  **DGNB** i održiva gradnja
-  **Strategije** dekarbonizacije
-  **Stručna mišljenja** za zahtjevne građevine (mostovi, potpomi zidovi, javni objekti)



099 476 1234 |  ivan.sokolovic@falcon8.hr



Unlock the power of your city

Discover the portfolio that empowers you to
optimize mobility for humanity

Modeling &
Planning



Multimodal macro and microscopic modeling and simulation, and visualization software.

Management &
Prediction



Data and AI-driven monitoring, prediction, decision-support, and traffic management software.

Onsite Traffic
Infrastructure



Cutting-edge cabinets, controllers, sensors, and professional services.

REBLOC[®]

Concrete Barriers


www.rebloc.com





MHPProjektiranje d.o.o.

PROJEKTIRANJE, GRAĐENJE, NADZOR
VELIKA KOSNICA, ZAGREBAČKA 14



D.O.O.

PROJEKT**L**AB

PROJEKTIRANJE, GRAĐENJE, NADZOR
I ISPITIVANJE GRAĐEVNIH PROIZVODA



GeoSolutions

USLUGE:

**POBOLJŠANJE TEMELJNOG TLA
HIDROIZOLACIJA
GEOTEHNIČKI ISTRAŽNI RADOVI
GEOTEHNIČKI ELABORAT
PROJEKTIRANJE
KONZALTING**

info@geosolutions.hr

www.geosolutions.hr



MODERN CONCEPTS FOR SAFER ROADS



OPREMA ZA CESTE GIS PROJEKTIRANJE

WWW.TRAFEX.HR

PLATINUM SPONSOR



GOLD SPONSORS



GREENWOOD
ENGINEERING



ELCOM BGD

LIVAR
industries

 **hauraton**

SILVER SPONSORS



viatel



**RE
BLOC**
Concrete Barriers



PTV GROUP
part of Umovity

BRONZE SPONSORS

 **LED**
elektronika