Prognostički model cestovnih prometnih nesreća za urbana područja

Tepeš, Krunoslav

Doctoral thesis / Disertacija

2017

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:785953

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

S v e u č i l i š t e u Z a g r e b u

FAKULTET PROMETNIH ZNANOSTI

KRUNOSLAV TEPEŠ, dipl. ing.

PROGNOSTIČKI MODEL CESTOVNIH PROMETNIH NESREĆA ZA URBANA PODRUČJA

D O K T O R S K I R A D

Zagreb, 2017.

University of Zagreb

FACULTY OF TRANSPORT AND TRAFFIC SCIENCES

KRUNOSLAV TEPEŠ, B. Eng.

FORECASTING MODEL OF ROAD TRAFFIC ACCIDENTS IN URBAN AREAS

DOCTORAL THESIS

Zagreb, 2017.

S v e u č i l i š t e u Z a g r e b u

FAKULTET PROMETNIH ZNANOSTI

Krunoslav Tepeš, dipl. ing.

PROGNOSTIČKI MODEL CESTOVNIH PROMETNIH NESREĆA ZA URBANA PODRUČJA

D O K T O R S K I R A D

Mentor:

prof. dr. sc. Davor Brčić

Zagreb, 2017.

U n i v e r s i t y of Z a g r e b

FACULTY OF TRANSPORT AND TRAFFIC SCIENCES

KRUNOSLAV TEPEŠ, B. Eng.

FORECASTING MODEL OF ROAD TRAFFIC ACCIDENTS IN URBAN AREAS

D O C T O R A L T H E S I S

Supervisor:

prof. Davor Brčić, Ph. D.

Zagreb, 2017.

PODATCI I INFORMACIJE O DOKTORANDU

1. Ime i prezime: **Krunoslav Tepeš, dipl. ing. prom.**
2. Datum i mjesto rođenja: **8. veljače 1983., Zagreb**
3. Naziv završenoga fakulteta i godina diplomiranja: **Fakultet prometnih znanosti Sveučilišta u Zagrebu, 20. studenoga 2006.**

INFORMACIJE O DOKTORSKOM RADU

1. Naziv doktorskoga studija: **Tehnološki sustavi u prometu i transportu**
2. Naziv doktorskog rada: **Prognostički model cestovnih prometnih nesreća za urbana područja**
3. Fakultet na kojem je doktorski rad branjen: **Fakultet prometnih znanosti Sveučilišta u Zagrebu**

INFORMACIJE O DOKTORSKOM RADU

1. Datum prijave doktorskog rada: **11. lipnja 2014.**
2. Datum obrane teme doktorskog rada: **22. rujna 2014.**
3. Mentor: **izv. prof. dr. sc. Davor Brčić**
4. Povjerenstvo za ocjenu i obranu doktorskog rada:
   izv. prof. dr. sc. Goran Zovak, predsjednik
   izv. prof. dr. sc. Davor Brčić, član
   izv. prof. dr. sc. Ljupko Šimunović, član
   doc. dr. sc. Tomislav Fratrović, član
   prof. dr. sc. Stjepan Lakušić (Građevinski fakultet Sveučilišta u Zagrebu), vanjski član
5. Lektorica: **Mateja Šporčić, mag. philol. croat. et mag. litt. comp.**
6. Datum obrane doktorskog rada: **13. lipnja 2017.**

POSVETA

Ovaj doktorski rad posvećen je mojim voljenim roditeljima Božidaru i Branki Tepeš

te

supruzi Ivani, kćerima Vidi i Tonki i sinu Šimunu

za njihovu ljubav, razumijevanje i bezrezervnu podršku.

SADRŽAJ

SAŽETAK

SUMMARY

POJMOVNIK – DEFINICIJE KLJUČNIH POJMOVA I AKRONIMI

1. UVOD 1
   1.1. Problematika istraživanja 4
   1.2. Svrha, ciljevi i znanstvena hipoteza istraživanja 5
   1.3. Metodološki pristup 6
   1.4. Kompozicija doktorskog rada 9
2. ANALIZA PRISTUPA UPRAVLJANJU SIGURNOŠĆU CESTOVNOGA PROMETA 12
   2.1. Pregled strateških dokumenata najrazvijenijih svjetskih zemalja vezanih uz sigurnost cestovnoga prometa 14
      2.1.1. Osnovne komponente strategija sigurnosti cestovnoga prometa 16
      2.1.2. Akcijski planovi djelovanja 18
   2.2. Pregled europskih propisa u području sigurnosti cestovnoga prometa 19
   2.3. Institucionalni okviri upravljanja sigurnošću cestovnoga prometa 23
      2.3.1. Analiza dobre prakse i znanja u razvijenim zemljama članicama Europske unije 23
      2.3.2. Analiza uređenosti sustava sigurnosti cestovnoga prometa na području Republike Hrvatske 25
      2.3.3. Nacionalni program sigurnosti cestovnoga prometa Republike Hrvatske 27
   2.4. Zaključna razmatranja 34
3. ANALIZA ČIMBENIKA CESTOVNIH PROMETNIH NESREĆA 43
   3.1. Sistemska teorija 43
      3.1.1. Čovjek kao čimbenik sigurnosti cestovnoga prometa 43
      3.1.2. Cesta kao čimbenik sigurnosti cestovnoga prometa 47
      3.1.3. Vozilo kao čimbenik sigurnosti cestovnoga prometa 49
   3.2. Relativni čimbenici rizika cestovnih prometnih nesreća 51
      3.2.1. Analiza cestovnih prometnih nesreća u urbanim/ruralnim područjima 56
      3.2.2. Prostorna distribucija cestovnih prometnih nesreća na području Republike Hrvatske 61
   3.3. Kvantitativni socioekonomski i prometni čimbenici 64
      3.3.1. Stupanj motorizacije 64
      3.3.2. Modalna raspodjela 69
   3.4. Zaključna razmatranja 73
4. BAZE PODATAKA O CESTOVNIM PROMETNIM NESREĆAMA 76

4.1. Metode prikupljanja podataka 77
4.1.1. Podatkovne podloge o cestovnim prometnim nesrećama 77
4.1.2. Izvještavanje o cestovnim prometnim nesrećama 84
4.2. Analiza međunarodnih i domaćih baza podataka o cestovnim prometnim nesrećama 88
4.2.1. Analiza međunarodnih statističkih baza podataka o cestovnim prometnim nesrećama 88
4.2.2. Analiza domaćih izvora podataka o cestovnim prometnim nesrećama 94
4.3. Formiranje integrirane baze podataka o cestovnim prometnim nesrećama za urbana područja 100
4.4. Zaključna razmatranja 104
5. DUBINSKA ANALIZA PODATAKA O CESTOVNIM PROMETNIM NESREĆAMA U GRADU ZAGREBU 108
5.1. Analiza trendova sigurnosnih pokazatelja cestovnih prometnih nesreća na području Grada Zagreba 112
5.1.1. Svojstva i starosna struktura nastradalih sudionika u cestovnim prometnim nesrećama 114
5.1.2. Vremenska distribucija cestovnih prometnih nesreća na području Grada Zagreba 117
5.1.3. Analiza vrsta cestovnih prometnih nesreća za urbana područja 119
5.1.4. Analiza uzroka cestovnih prometnih nesreća za urbana područja 121
5.2. Komparativna analiza i zaključna razmatranja 123
6. PROGNOSTIČKI MODEL CESTOVNIH PROMETNIH NESREĆA ZA URBANA PODRUČJA 128
6.1. Pregled dosadašnjih istraživanja 128
6.1.1. Primijenjena istraživanja 131
6.2. Statističke metode predviđanja cestovnih prometnih nesreća 135
6.2.1. Statističke razdiobe cestovnih prometnih nesreća 135
6.2.2. Statistički modeli predviđanja cestovnih prometnih nesreća 138
6.3. Kauzalno-prognostički model prometnih nesreća za urbana područja 142
6.4. Linearni kauzalni model 146
6.5. Bayesove mreže 153
7. IZRADA MODELA CESTOVNIH PROMETNIH NESREĆA ZA URBANA PODRUČJA 159
7.1. Izbor ulaznih varijabli – čimbenika 160
7.2. Varijable modela 164
7.3. Dijagram toka modela 165
7.4. Unos podataka u model 166
7.5. Digitalizacija podataka 167

7.6. Određivanje kauzalne strukture 168
7.7. Karakteristične vrijednosti modela 169
7.8. Izračunavanje modela 170
7.9. Simulacija Bayesova kauzalnog modela 171
8. REZULTATI I EVALUACIJA MODELA 174
8.1. Kvalitativna analiza rezultata modela uzroka prometnih nesreća 174
8.2. Kvantitativna analiza rezultata modela uzroka prometnih nesreća 176
8.3. Kvalitativna analiza rezultata modela vrsta prometnih nesreća 178
8.4. Kvantitativna analiza rezultata modela vrsta prometnih nesreća 180
8.5. Evaluacija prognostičkih modela uzroka prometnih nesreća 182
8.6. Evaluacija prognostičkih modela vrsta prometnih nesreća 183
8.7. Zaključna razmatranja 185
9. ZAKLJUČAK 186
LITERATURA 195
POPIS ILUSTRACIJA 209
Popis slika 209
Popis tablica 210
Popis grafikona 211
PRILOZI 213
ŽIVOTOPIS 237

SAŽETAK

Cestovne prometne nesreće, a posebice teži oblici (sa smrtnim posljedicama i težim ozljedama) na nacionalnom i međunarodnom planu predstavljaju ozbiljan socioekonomski i politički problem. Jedan od pristupa rješavanju toga problema jest razvoj pouzdanih prognostičkih modela CPN-a koji se temelje na atributima koji utječu na nesreće. Njihovom primjenom i kvantifikacijom ostvaruju se saznanja o čimbenicima sigurnosti i posljedicama različitih kategorija CPN-a. Pritom stručnjaci dobivaju pouzdan alat za sustavnu procjenu stanja sigurnosti. S obzirom na velik broj ulaznih parametara, literatura o prometnim nesrećama još uvijek ne pruža univerzalno prihvaćen te znanstveno utemeljen pristup izradi takvih procesa. Prepoznajući važnost statističkih metoda za povezivanje, klasifikaciju te predviđanje stopa kretanja CPN-a, kao i činjenicu da takva istraživanja nisu provedena na prostoru nacionalnoga cestovnog prometnog sustava, cilj je ovoga znanstvenog istraživanja izrada vjerodostojnoga prognostičkog modela CPN-a za urbana gradska područja, odnosno uspostavljanje uzročno-posljedične veze između prometnih nesreća i relevantnih uzroka njihovih nastanka, ljudske i cestovno-prometne varijable. Predloženi model CPN-a u daljnjim istraživanjima služit će kao podloga za izradu detaljnije analize utvrđivanja i rangiranja glavnih uzročnika nastanka prometnih nesreća te korelaciju u pogledu vrsta i posljedica cestovnih nesreća. Osnovnu podlogu na temelju koje su provedena daljnja istraživanja i analize čine statistička izvješća svih registriranih cestovnih prometnih nesreća na području Grada Zagreba i Zagrebačke županije u periodu od 10 godina: od 2004. do 2013. godine, uz interpretaciju tradicionalnih statističkih metoda primjenjivih na obrađenim ulaznim podatcima. Rezultati analize, kao i izrada kauzalnoga prognostičkog modela omogućit će povećanje razine sigurnosti i kontrolu odvijanja cestovnoga prometnog sustava u kontekstu određivanja ciljanih represivnih i preventivnih mjera kako bi se stope CPN-a u urbanim gradskim područjima umanjile te kako bi se anuliralo njihove negativne posljedice te omogućilo sigurnije planiranje gradskih prometnih sustava.

Ključne riječi: sigurnost prometa u urbanim područjima, baze podataka cestovnih prometnih nesreća, rizični čimbenici, kauzalni modeli

SUMMARY

Road traffic accidents, particularly in their severe forms (with fatal consequences and serious injuries) represent a serious socio-economic and political problem on both national and international level. One approach for solving this problem is the development of reliable forecasting models of RTA which are based on attributes that affect accidents. By means of their application and quantification, it is possible to obtain cognizance relating to safety factors and consequences of various categories of RTA's. In doing so, experts receive a reliable tool for systematic assessment of the security situation. Given the large number of input parameters, the literature on traffic accidents still does not provide a universally accepted and scientifically based approach to development of such processes. Recognizing the importance of statistical methods for connecting, classification and RTA's prediction rate movements, and the fact that such studies have not been conducted in the area of national road transport system, the goal of this scientific research is to develop a credible prediction model of RTA for urban metropolitan areas and to establish cause and effect link between accidents and relevant causes of their origin, human and road-traffic variable. In further research, the proposed RTA model will serve as the basis for making a more detailed analysis of determining and ranking the main causes of accidents and correlation in terms of type and consequences of road accidents. The foundation of research and analysis are statistical reports of all registered road accidents in the City of Zagreb and Zagreb County for the period of 10 years, from 2004 to 2013, with interpretation of traditional statistical methods applicable to the processed input data. Results of the analysis and development of causal forecasting model will increase the level of security and control of a road transport system in the context of determining targeted repressive and preventive measures, in order to reduce RTA rates in urban metropolitan areas and annul their negative consequences, as well as to enable more secure planning of urban transport systems.

Keywords: traffic safety in urban areas, database of road traffic accidents, risk factors, causal models

POJMOVNIK – DEFINICIJE KLJUČNIH POJMOVA I AKRONIMI

Pregledom inozemnih znanstvenih i stručnih studija vidljivo je, a isti je slučaj kompariramo li i nacionalne zakonske propise pojedinih europskih zemalja, da ne postoji zajednički konsenzus oko jednoobraznosti pojmova korištenih u radovima koji obrađuju teme iz područja sigurnosti cestovnoga prometa. U skladu s navedenim, definicije cestovnih prometnih nesreća (dalje u tekstu CPN), kao i njoj komplementarnih pojmova u ovom su radu temeljene na relevantnim međunarodnim standardima i preporukama UN-a, EUROSTAT-a, UNECE-a, ITF-a i ostalih [1,2], te na pozitivnim propisima Republike Hrvatske kao što su *Zakon o sigurnosti prometa na cestama* (NN 67/08, …, 64/15), *Zakon o službenoj statistici* (NN 103/03, …, 12/13) te *Pojmovnik za statistiku prometa*, IV. izdanje, EUROSTAT/UNECE/ITF, prijevod 2010.
Prilikom priprema za ulazak Republike Hrvatske u Europsku uniju primijećeno je kako su se pripadajuće definicije CPN-a sustavno korigirale i usuglašavale s europskom stečevinom i legislativom, posebice kroz izmjene i dopune *Zakona o sigurnosti prometa na cestama* (ponajviše definicija materijalne štete u prometnoj nesreći).

Također, podatci o broju poginulih i ozlijeđenih osoba u prometnim nesrećama obuhvaćaju sve sudionike prometnih nesreća na teritoriju Republike Hrvatske bez obzira na državljanstvo. Ozljede sudionika u prometu podijeljene su u tri kategorije: *poginuli* (smrt je evidentirana na mjestu događaja ili unutar 30 dana nakon nastanka CPN-a), *teško ozlijeđeni* (svaka osoba hospitalizirana dulje od 24 sata) te *lakše ozlijeđeni* (ozlijeđene osobe koje ne pripadaju niti u jednu od gore navedenih kategorija).

Preostali relevantni pojmovi za obradu predmetne teme ovoga znanstvenog rada preuzeti su iz *Biltena o sigurnosti cestovnog prometa* Ministarstva unutarnjih poslova Republike Hrvatske te autoriziranih predavanja i skripti Fakulteta prometnih znanosti Sveučilišta u Zagrebu vezanih uz temu sigurnosti cestovnoga prometa te gradskoga prometa.

Potrebno je napomenuti kako je teže oblike CPN-a, u kojima je rezultat ozljeđivanje ili smrt najmanje jednoga sudionika, u Republici Hrvatskoj zakonska obveza prijaviti ispostavi prometne policije, dok prijava nije nužna ako je riječ samo o lakšim CPN-ovima, tj. manjoj materijalnoj šteti (ako nisu oštećeni nikakvi vitalni dijelovi za upravljanje i zaustavljanje te ako se vozila mogu samostalno kretati cestom). U tim slučajevima sudionici prometne nesreće dužni su popuniti i potpisati *Europsko izvješće o nezgodi* (Prilog 1) ili na drugi način razmijeniti osobne podatke i podatke o vozilima.

AKRONIMI

BDP	Bruto domaći proizvod
CADAS	A common road accident data framework in Europe (engl.)
CARE	Community database on Accidents on the Roads in Europe (engl.)
CCIS	UK Cooperative Crash Injury Study (engl.)
CHILD	Child Injury Led Design (engl.)
CPN	Cestovna prometna nesreća
DZS	Državni zavod za statistiku
EACS	European Accident Causation Survey (engl.)
ECBOS	Enhanced Coach and Bus Occupant Safety (engl.)
ECMT	European Conference of Ministers of Transport (engl.)
EU	Europska unija
EUROSTAT	Statistical administration of the European Commission (engl.)
FAI	Fatal Accident Investigation (engl.)
FARS	Fatal Accident Reporting System (engl.)
FIA	Fédération Internationale de l'Automobile (fr.)
FICA	Swedish Factors Influencing the Causation of Accidents and Incidents Project (engl.)
GIDAS	The German In-Depth Accident Study (engl.)
GIS	Geografski informacijski sustav
GPS	Global Positioning System (engl.)
HŽ	Hrvatske željeznice
IRTAD	International traffic safety data and analysis group (engl.)
ITF	International Transport Forum (engl.)
ITS	Intelligent Transport Systems (engl.)
JGPP	Javni gradski putnički prijevoz

MUP PUZ	Ministarstvo unutarnjih poslova, Policijska uprava zagrebačka
NHTSA	The National Highway Traffic Safety Administration (engl.)
OECD	The Organisation for Economic Co-operation and Development (engl.)
OTS	UK On-the-Spot Project (engl.)
PENDANT	Pan-European Co-ordinated Accident and Injury Database (engl.)
PGDP	Prosječni godišnji dnevni promet
RH	Republika Hrvatska
SAD	Sjedinjene Američke Države
SNACS	SafetyNet Accident Causation System (engl.)
STRADA	Swedish Traffic Accident Data Acquisition (engl.)
TRL	Transport Research Laboratory (engl.)
UN	Ujedinjeni narodi
UNECE	The United Nations Economic Commission for Europe (engl.)
UNICEF	United Nations International Children's Emergency Fund (engl.)
UPN	Upitnik o prometnoj nesreći
WB	The World Bank (engl.)
WHO	World Health Organization (engl.)
ZC	Zagrebački holding d. o. o. – Podružnica Zagrebačke ceste
ZET	Zagrebački holding d. o. o. – Podružnica Zagrebački električni tramvaj

1. UVOD

Unatrag proteklih 20-ak godina u većini zemalja svijeta transportna aktivnost, odnosno broj prometnih entiteta u kontinuiranom je porastu prvenstveno zbog znatnoga društvenog i ekonomskog razvoja urbanih gradskih okruženja te izražene potrebe za što većom mobilnošću građana i robe. Razlog za navedeno jest ubrzana urbanizacija te rast vlasništva nad cestovnim motornim vozilima (više od 500 motornih vozila na 1.000 stanovnika) u kombinaciji s paralelnim razvojem moderne cestovne infrastrukture i prometnih objekata, a što je posebice naglašeno u ekonomski razvijenijim europskim i svjetskim gradovima, primjerice u Sjevernoj Americi, Novom Zelandu i Zapadnoj Europi. U urbanim sredinama[1] navedeno stanje snažno utječe na ukupne eksterne troškove, kao što su vremenski gubitci, troškovi zagađenja, troškovi buka, problemi u protočnosti, lokalni poremećaji na cestovnoj gradskoj mreži te troškovi i gubitci proizašli iz pojave CPN-a (troškovi rizika, gubitka produktivnosti zbog smrti, administrativni troškovi, troškovi medicinske skrbi i dr.). Kao protumjeru navedenoj situaciji države Europske unije i svijeta sve više pokušavaju koordinirati svoje prometne politike, pri čemu se problematika sigurnosti cestovnoga prometa sve više naglašava kao prioritetno područje djelovanja.

S obzirom na uvodne navode, znatno je otežano zadržati postojeće razine stopa CPN-a, odnosno ostvariti njihovo umanjenje.

Na nacionalnom, regionalnom (područnom) i lokalnom planu teži oblici CPN-a – sa smrtnim posljedicama i težim tjelesnim ozljedama – predstavljaju stoga ozbiljan socioekonomski i politički problem.

Sa statističke točke gledišta gotovo je nemoguće iz mnoštva uzročnih čimbenika izdvojiti (izolirati) samo jedan pojedinačni koji utječe na pojavu CPN-a. U najvećoj mjeri ti su čimbenici posljedice interaktivnoga djelovanja skupa različitih rizičnih elemenata i okolnosti u cestovnom prometu koje predstavljaju prometnu opasnost i pokazuju stupanj prometne sigurnosti.

U prilog težini problematike govori zaključak studije što ju je u 182 zemlje provela, a potom rezultate objavila Svjetska zdravstvena organizacija (engl. *World Health Organization* – WHO) [3]. U toj studiji navode se podatci kako na svjetskoj razini oko 1.24 milijuna osoba godišnje pogine u prometnim nesrećama,[2] a između 20 i 50 milijuna osoba zadobiva povrede koje ne dovode do

[1] U Europskoj uniji više od 60% stanovništva živi u urbanim područjima. Izvor: Eurostat.

[2] Oko 2% smrtno stradalih sudionika u prometu odnosi se na razinu EU-a.

smrti, ali su važan uzrok invalidnosti, pri čemu je kod znatnoga broja povrijeđenih utvrđen i precizan stupanj invaliditeta. Drugim riječima, više od 3.000 osoba dnevno pogine na prometnicama zbog CPN-a, dok svake 3 minute na cestama širom svijeta pogine jedno dijete. Globalno promatrajući, CPN je svrstan kao deseti vodeći uzročnik smrtnosti, dok je među populacijom u dobi između 5 i 33 godine svrstan među prva tri.

Projekcije, nažalost, nisu pozitivne te se zaključuje kako je za većinu regija u svijetu takav trend i dalje u porastu. U skladu s time, Svjetska zdravstvena organizacija i Svjetska banka (engl. *The World Bank* – WB) [3] navode kako će do 2030. godine trend CPN-a uznapredovati te biti rangiran kao peti vodeći uzročnik smrtnosti među stanovništvom, pri čemu će se stopa poginulih u odnosu na aktualno vrijeme udvostručiti u slabo i srednje razvijenim zemljama.

Brojne su studije [4, 5, 6] kako na lokalnoj tako i globalnoj razini provedene u svrhu analiziranja podataka o CPN-u. Rezultati o njihovoj učestalosti često variraju ovisno o društveno-ekonomskim uvjetima i cestovnoj infrastrukturi na promatranom lokalitetu. Nadalje, podrobnim statističkim analizama CPN-a na globalnoj razini utvrđeno je kako su stope smrtno stradalih sudionika u CPN-u, promatrane u odnosu na broj registriranih motornih vozila, u zemljama u razvoju znatno veće nego u razvijenim zemljama, gdje je broj poginulih u proteklih dvadeset godina u padu [7].

Potvrđuje to i Fletcherovo istraživanje [8]. Fletcher, naime, tvrdi kako ni distribucija CPN-a nije jednoliko rasprostranjena među svjetskim regijama, pa je potrebno napraviti distinkciju između razvijenih zemalja i onih slabije te srednje ekonomsko razvijenih zemalja. U slabije ekonomski razvijenim zemaljama CPN predstavljaju prijetnju javnomu zdravlju te potencijalnomu nacionalnom razvoju. Promatrajući odnose u takvim zemljama, primijećena je snažna korelacija između stupnja ekonomske razvijenosti zemlje, prvenstveno bruto domaćega proizvoda (BDP) i stopa CPN-a.

Na razini zemalja članica Europske unije (EU) broj poginulih od posljedica CPN-a smanjio se za 36% (EU27) u razdoblju između 2001. i 2009., no unatoč navedenomu, tijekom 2009. godine 35.000 osoba smrtno je stradalo na cestovnim prometnicama, dok je 1.700.000 osoba u policijskih izvješćima zabilježeno kao ozlijeđeno, među kojima 300.000 s teškim tjelesnim ozljedama. Procjene su kako na svaku poginulu osobu na europskim cestama dolaze 4 osobe s ozljedama trajne nepokretnosti (ozljede mozga ili leđne moždine), 10 osoba s teškim ozljedama i 40 osoba s lakšim tipom ozljeda. U 2011. godini u zemljama EU27 smrtno je stradalo oko 30.100 osoba, što je smanjenje od 940 smrtno stradalih zabilježeno u odnosu na prethodnu godinu, pri čemu se novčana vrijednost navedenoga smanjenja procjenjuje na 1.74 milijardi eura [9].

Pregledom dostupnih istraživanja u području analiza i prevencija prometnih nesreća utvrđeno je nekoliko čimbenika koji se smatraju relevantnima za povećan broj CPN-a u zemljama u razvoju, a

oni su porast broja registriranih motornih vozila, niska razina zakonske legislative, nedostatna razina cestovne infrastrukture i prometne opreme, visok udio najrizičnijih sudionika u prometu (biciklista, motorista, djece i starijih osoba) te edukacija sudionika u prometu [10–12].

The World report on child injury prevention, koji su pripremili WHO i UNICEF i predstavili ga 2008. godine, u dijelu koji se odnosi na ozljede nastale kao posljedica prometnih nesreća iznosi podatak kako su glavni uzrok smrti kod mladih u dobnoj granici 10 – 19 godina upravo CPN. Naveden je i podatak kako na godišnjoj razini 260.000 djece premine od posljedica prometnih nesreća, s procjenom da 10 milijuna djece biva ozlijeđeno ili je evidentiran određen stupanj invaliditeta sa snažnim psihičkim i psihološkim traumama [13].

Eksterne troškove CPN-a[3] moguće je iščitati zahvaljujući Povjerenstvu za globalnu cestovnu sigurnost (*Commission for Global Road Safety*), koje koordinira FIA Fondation (*Fédération Internationale de l'Automobile*), koji procjenjuje kako globalni trošak cestovnih prometnih nesreća iznosi više od 500 milijardi američkih dolara godišnje, od čega na razvijene zemlje otpada 100 milijardi [14]. Američka agencija za sigurnost na autocestama (NHTSA, 2008) navodi podatak kako svaka teže ozlijeđena osoba američko gospodarstvo opterećuje s približno 977.000 dolara, dok svaka preminula s 1.100.000.

U skladu s navedenim, možemo ustvrditi kako smrtni slučajevi i ozljede proizašle od posljedica cestovnih prometnih nesreća predstavljaju znatan teret za razvoj gospodarstva i ekonomije te su procjene da se udio kreće od 0,3 do 4% BDP-a, ovisno o stupnju ekonomske razvijenosti pojedine promatrane države te primijenjenoj metodi izračuna [15].

Posljedice nesreća u cestovnom prometu produciraju eksterni trošak od više od 100 milijardi eura (na godišnjoj razini), odnosno više od 1,5% BDP-a zemalja EU-a [16] nepovratno se izgubi zbog negativnih nuspojava odvijanja cestovnoga prometa. Komparacije radi, projekcije na razini RH kreću se 2,5 – 3% BDP-a [17], što je približni ekvivalent ukupnim godišnjim financijskim sredstvima predviđenima za potrebe ulaganja u cestovne prometnice.

Ukupni troškovi zbog nastradalih sudionika u CPN-u (poginule i ozlijeđene osobe) na razini EU-a za 2014. godinu procijenjeni su na 48,5 milijardi eura. Na temelju statističke vrijednosti života, koja je izračunata u studiji HEATCO (Šesti okvirni program za istraživanje i tehnološki razvoj Europske komisije), procijenjeni su troškovi nastali stradavanjem sudionika prometnih nesreća u

[3] Broj nastradalih i nezgode različite težine izražavaju se novčanim vrijednostima, a one su uključene u analizu troškova/koristi. Te vrijednosti uključuju izravne troškove CPN-a, kao što su gubitak produktivnosti zbog smrti, troškovi bolnice, policije i osiguranja, naknada imovine. kao i sporna naknada za prouzročenu bol, žalost i patnju.

RH niži od prosjeka EU-a. Prema navedenomu istraživanju, u RH je materijalni trošak poginule osobe procijenjen na 1.333.000 eura (prosjek EU-a iznosi 1.870.000 eura), teške tjelesne ozljede 173.300 eura (prosjek EU-a iznosi 243.100 eura), a lake tjelesne ozljede 13.300 eura (prosjek EU-a iznosi 18.700 eura) [18].

Na razini grada Zagreba za period tijekom 2010. godine na temelju metodologije proračuna eksternih troškova transporta konzultantske organizacije CE Delft utvrđen je ukupan trošak prometnih nesreća u visini od 63.162.358,00 eura, koji istodobno predstavlja 7,5% proračuna Grada Zagreba, odnosno 70% proračuna namijenjenoga za prometnu infrastrukturu u 2011. godini [19].

U ovom dijelu važno je naglasiti da implementacija strategija i programa sigurnosti cestovnoga prometa u inicijalnoj fazi zahtijeva znatna financijska sredstva, no kasnijim se učincima ostvaruju znatne materijalne uštede, koje unutar nekoliko godina mogu isplatiti sva prethodna ulaganja. Kao izvore financiranja takvih programa posebice valja izdvojiti kazne i takse proizašle iz procesuiranja prometnih prekršitelja, izdvajanje određenoga udjela iz ukupne formirane cijene naftnih energenata te kreiranje posebnih namjenskih fondova vlade, striktno namijenjenih financiranju mjera i aktivnosti koje vode povećanju sigurnosti cestovnoga prometnog sustava.

1.1. Problematika istraživanja

Identifikacija i kvantifikacija uzročnika nastanka CPN-a u svjetskim razmjerima sve se više potencira i iskazuje, korištenjem različitih matematičkih modela i algoritama, kao ključna komponenta u prognoziranju CPN-a.

Iz pregleda dosadašnjih istraživanja vidljivo je kako mnogobrojni autori u ovom području istraživanja kroz svoj stručni i znanstveni doprinos pokušavaju definirati određene opće postulate i zakonitosti. Zajednička problematika njihovih istraživanja može se sublimirati u činjenici da različita geografska područja istraživanja posjeduju individualne problemske specifičnosti i zakonitosti koje u korelaciji s njihovim generalnim stupnjem socioekonomske razvijenosti nije moguće u potpunosti jednoobrazno opisati te aplicirati [20]. U skladu s navedenim, u ekonomski i društveno stabilnijim zemljama izrada modela predviđanja stopa CPN-a mnogo je pouzdanija nego u onima slabijim te u ekonomski nesigurnim državama u kojima su ekonomske aktivnosti oslabljene (etničke i društveno-ekonomske napetosti zbog kojih dolazi do neujednačenoga gospodarskog razvoja, ekonomskoga pada, izbjeglica koje bježe iz zemlje i sl.).

Tradicionalne metode prikupljanja ulaznih podataka za potrebe izrade modela predviđanja stopa CPN-a predstavljale su obrađivanje statistički kategoriziranih informacija (npr. stope CPN-a, broja

poginulih ili ozlijeđenih sudionika u prometu što su ih prikupljale mjerodavne institucije) ili korištenje dobivenih podataka izvođenjem dubinskih analiza individualnih CPN-a nedugo nakon što su se dogodili (najčešće težih oblika prometnih nesreća), a koje je obrađivao multidisciplinarni tim stručnjaka.

Za izradu prognostičkih modela CPN-a za urbana područja nužno je prikupiti i obraditi što više nizova podataka o uzrocima i posljedicama nastanka prometnih nesreća. Tim pristupom u konačnici se dobiva realna statistička podloga uniformirane strukture iz koje je zatim moguće adekvatno iščitati aktualno stanje, trendove i korelacije kretanja sigurnosnih pokazatelja cestovnoga prometnog sustava.

U navedenim modelima posljedice CPN-a (smrtni ishodi, lake i teške tjelesne ozljede, onesposobljavanje, materijalna šteta itd.) neizvjestan je broj-ishod i zavisne su varijable. Vjerojatnost nastanka navedenih klasifikacija CPN-a funkcija je različitih cestovnih, vozačkih, vremenskih i voznih karakteristika te osobina koje se javljaju kao posljedica samoga incidenta i koje se mogu numerički mjeriti.

Važno je naglasiti da, s obzirom na složenost predmetne problematike, odnosno velikoga broja kritičnih parametara (nezavisnih varijabli) potencijalnih incidentnih čimbenika zaslužnih za nastanak cestovnih prometnih nesreća, literatura o prometnim nesrećama još uvijek ne pruža univerzalno prihvaćeni te znanstveno utemeljeni pristup izradi takvih procesa.

Kauzalnost je središnji koncept u znanstvenim disciplinama. Prethodno opisana problematika obrađuje se korištenjem statističkih metoda i stohastičkom terminologijom s obzirom na to da se uzroke nastanka prometnih nesreća nastoji objasniti izučavanjem različitih razina kauzalnosti, poput divergentnosti ljudskih karakteristika (individualno ponašanje), stanja infrastrukture i opreme, stanja vozila, neposrednih prostornih (okolišnih) utjecaja te socijalne strukture na nacionalnom nivou. Pojašnjenje nastanka prometnih nesreća na nacionalnom nivou zaokuplja pozornost prometnih i znanstvenika ostalih profila u posljednja dva desetljeća [21].

1.2. Svrha, ciljevi i znanstvena hipoteza istraživanja

Svrha je znanstvenoga istraživanja omogućiti upravljanje prometnom sigurnošću kroz implementaciju **prognostičkoga modela CPN-a za urbana područja.** Osnovni je cilj predloženoga znanstvenog istraživanja **analiza postojećih modela predviđanja CPN-a te detektiranje najznačajnijih čimbenika sigurnosti CPN-a urbanoga okruženja.** Sublimacijom postojećih prognostičkih modela te detekcijom i klasifikacijom najznačajnijih čimbenika bit će izrađen novi prognostički model CPN-a za urbana područja.

Iz navedene svrhe i cilja istraživanja postavljaju se sljedeće hipoteze:

- Moguće je definirati, strukturirati i rangirati relevantne čimbenike CPN-a urbanih područja.
- Moguće je odrediti funkcijsku vezu među čimbenicima CPN-a za urbana područja.
- Na temelju analize čimbenika moguće je izraditi model predviđanja CPN-a za urbana gradska područja.

Očekuje se da će rezultati znanstvenoga istraživanja potvrditi cilj istraživanja o strukturi i korelaciji relevantnih čimbenika CPN-a za urbana područja. Izradom prognostičkoga modela u inženjerskoj će se praksi omogućiti kvalitetnija prognoza CPN-a. Primjena je rezultata istraživanja višestruka:

- Razvijen model predviđanja CPN-a stvorit će preduvjete za povećanje sigurnosti u cestovnom prometu urbanih područja.
- Primjenom modela na lokalnoj razini urbanih prostora stvorit će se uvjeti za upravljanje sigurnošću u cestovnom prometu, na način da će rezultati modela omogućiti definiranje mjera i aktivnosti za povećanje sigurnosti u cestovnom prometu.
- Na temelju rezultata istraživanja omogućit će se izrada smjernica za praktičnu primjenu povećanja cestovne sigurnosti u urbanim sredinama.

1.3. Metodološki pristup

Znanstvena metodologija može se definirati kao skup različitih postupaka kojima se znanost koristi u znanstvenoistraživačkom radu da bi istražila i izložila rezultate znanstvenoga istraživanja u određenom znanstvenom području ili znanstvenoj disciplini [22].

Za potrebe istraživanja vezanih za obradu i analizu dostupnih podatkovnih baza podataka o CPN-u, kao i za potrebe izrade prognostičkoga modela CPN-a te za provjeru postavljenih hipoteza primijenit će se niz znanstvenih metoda. U skladu s navedenim, planirana je metodologija istraživanja višedisciplinarna, a samo će istraživanje biti provedeno kroz tri sukcesivna dijela.

U prvom dijelu istraživanja analizirat će se relevantne teorijske pretpostavke i istraživanja prognostičkih modela CPN-a.

Navedene aktivnosti planirane su na temelju pregleda i analiza dosadašnjih saznanja i postignuća u stručnoj i znanstvenoj literaturi. Izučavanja relevantnih evaluacijskih studija te ostalih istraživanja vezanih za čimbenike CPN-a i prognostičke modele, a registrirane su uvidom u bazu

podataka referentnih znanstvenih časopisa (*Accident Analysis and Prevention*, *ITE-Journal*, *Journal of Safety Research*, *Traffic Engineering and Control* te *Transportation Research Record*). Također, u radu su korišteni rezultati i statističke komparacije prikazani u objavljenim javnim dokumentima, odnosno biltenima i publikacijama vodećih nacionalnih organizacija zaduženih za praćenje opće razine sigurnosti cestovnoga prometa – OECD/ITF (*The Organisation for Economic Co-operation and Development / International Transport Forum*), kao i istraživačka izvješća i pripadajuća izdanja što su ih objavile specijalizirane agencije i institucije zemalja koje se smatraju vodećima u području upravljanja sigurnosti cestovnoga prometa – Švedske, Velike Britanije, Nizozemske i Australije.

U nastavku će biti analizirane službene baze podataka o CPN-u te relevantne statističke razdiobe/modeli s naznakom područja njihove primjene. Ujedno, dat će se pregled i analiza dosadašnje razine razvijenosti službenog IS-a (Informacijskoga sustava) obrade podataka o CPN-u u RH, bit će prikazana komparativna analiza metodologije prikupljanja i obrađivanja podataka o CPN-u domaćih i inozemnih mjerodavnih institucija te će biti opisane aktualne kooperativne radnje na razini zemalja Europske unije koje se provode u svrhu unapređenja metoda prikupljanja kvantitativnih podataka o prometnim nesrećama (usvajanje zajedničkih metodologija te unifikacija minimalnoga seta statističkih informacija nužnih za kvalitetno opisivanje i analizu CPN-a). U analizi će biti detektirana osnovna ograničenja i nedostatci nacionalne baze podataka o CPN-u u RH.

Primijenjene znanstvene metode:

- *analize i sinteze* – prikupljanje i obrađivanje podataka i informacija te izvođenje zaključaka o razmatranim temama,
- *klasifikacije i deskripcije* – opisivanje čimbenika CPN-a,
- *komparativna metoda* – usporedbom istih činjenica uvidjet će se razlike i ograničenja trenutno dostupnih statističkih modela predviđanja stopa CPN-a u odnosu na predloženi prognostički model.

U drugom dijelu istraživanja analizirat će se čimbenici urbanih CPN-a, rangirati po težini te usporediti sa statističkim podatcima postojećih baza u RH za urbana područja. Za potrebe izrade prognostičkoga modela CPN-a podrobnije će se analizirati dostupni podatci o registriranim CPN-ovima mjerodavnih nacionalnih institucija kako bi se identificirali i kvantificirali ključni čimbenici koji su u neposrednoj vezi s nastankom i posljedicama CPN-a. Područje obuhvata istraživanja za određivanje ulaznih parametara bit će prostor Grada Zagreba i Zagrebačke županije, gdje će se za potrebe istraživanja i izrade prognostičkoga modela CPN-a koristiti podatci iz službenih godišnjih

policijskih statističkih izvještaja, odnosno *Biltena o sigurnosti cestovnog prometa u Republici Hrvatskoj* te podatci o CPN-u kroz UPN (*Upitnik o prometnoj nesreći*) Policijske uprave zagrebačke i Ministarstva unutarnjih poslova Republike Hrvatske.

Postoji opsežna referentna literatura o modelima CPN-a, od kojih većina analizira prometne nesreće koristeći konceptualni prikaz ili statistiku. Stoga je posebna pozornost posvećena sustavnomu pregledu onih statističkih metoda koje imaju evidentiranu raširenu aplikativnu uporabu, kao i prednostima i nedostatcima postojećih statističkih metoda i analitičkih tehnika.

Primijenjene znanstvene metode:

- *induktivna i deduktivna* – proučavanjem nezavisnih varijabli uzroka (rizičnih čimbenika) zaslužnih za pojavu CPN-a izvest ćemo prognostički model za pojedine kategorije CPN-a,
- *povijesna metoda* – komparacija rezultata s drugim autorima,
- *empirijska metoda* – primijenit će se stečena iskustva,
- *metoda dokazivanja i opovrgavanja* – istraživanjem će se dokazati međuzavisnost rizičnih čimbenika zaslužnih za nastanak CPN-a,
- *metoda klasifikacije* – omogućit će podrobniju klasifikaciju i rangiranje cestovnih prometnih nesreća,
- *statistička* – obrada pokazatelja sigurnosti cestovnoga prometa.

U posljednjem dijelu doktorskoga rada izradom i kalibracijom modela predviđanja CPN-a urbanih područja ostvarit će se mogućnost kvalitetnoga kategoriziranja i rangiranja utjecajnih čimbenika, uz prethodno kvantificiranje jačine (povezanosti) njihove međusobne korelacije.

Utjecajni čimbenici bit će izlučeni i definirani na temelju analiza varijance (intervalna ocjena sredine, medijana i varijance, analitički i grafički prikaz raspršenosti), dok će analiza vremenskih nizova uključivati godišnje stope i prosječne godišnje stope njihova rasta ili pada.

Modeliranje kauzalnoga modela ostvarit će se koristeći suvremena dostignuća u statističkoj analizi, kao što su nezavisnosti i parcijalne korelacije te parcijalni korelacijski koeficijent. Za traženje V-struktura i za konstrukcije aciklički usmjerenih grafova koristit će se suvremeni računalni alati *Statistica* [23] i *Tetrad*.

Evaluacija novostvorenoga modela planira se izvesti komparacijom više alternativnih podatkovnih varijabli mjerenja, za koje će se prvotno definirane pretpostavke i odabrani parametri po potrebi korigirati.

Primijenjene znanstvene metode:

- *matematička* – definiranje zavisnih i nezavisnih varijabli predloženoga modela,

- *metoda mjerenja* – utvrđivanje brojčanih vrijednosti varijabli mjerenja uzroka CPN-a,
- *metoda modeliranja* – modeliranje i optimiziranje broja varijabli mjerenja uključenih u izradu predloženoga prognostičkog modela.

1.4. Kompozicija doktorskog rada

Organizacija ovoga znanstvenog rada koncipirana je kroz ukupno devet (9) poglavlja, uz popis literature, popis ilustracija (slika, tablica i grafikona), priloge i životopis.

Kompozicija doktorskog rada podijeljena je kroz sljedeća poglavlja:

1. Uvod
2. Analiza pristupa upravljanju sigurnošću cestovnoga prometa
3. Analiza čimbenika cestovnih prometnih nesreća
4. Baze podataka o cestovnim prometnim nesrećama
5. Dubinska analiza podataka o cestovnim prometnim nesrećama u Gradu Zagrebu
6. Prognostički model cestovnih prometnih nesreća za urbana područja
7. Izrada modela cestovnih prometnih nesreća za urbana područja
8. Rezultati i evaluacija modela
9. Zaključak

U uvodnom dijelu (1.) u skladu s pozitivnim smjernicama prilikom izrada znanstvenih i stručnih radova ukratko će biti opisana problematika istraživanja, ciljevi i radna hipoteza, definicije osnovnih pojmova te sama struktura rada.

U drugom poglavlju (2.) analizirat će se brojne mjere i aktivnosti vezane uz upravljanje sigurnošću cestovnoga prometa koje imaju za cilj smanjiti broj i težinu posljedica CPN-a, dok provođenje odgovarajuće strategije sigurnosti ima izravan utjecaj na njihove krajnje rezultate. U skladu s time, u ovom poglavlju bit će naznačena usporedna analiza strateških dokumenata o sigurnosti cestovnoga prometa te institucionalni okviri, tj. struktura koja je potrebna za njihovu provedbu. Uz navedeno, prikazat će se uređenost lokalnih, nacionalnih i međunarodnih institucionalnih i organizacijskih struktura zaduženih za stvaranje povoljnih uvjeta za sigurno odvijanje prometa.

Treće poglavlje (3.) posvećeno je analizi glavnih čimbenika koji neposredno utječu na sigurnost i mobilnost cestovnoga prometnog sustava. Analiza će se provesti kroz izučavanje *sistemske teorije*, bazirane na trima komponentama: čovjek – cesta – vozilo, zatim relativnih čimbenika sigurnosti cestovnoga prometnog sustava s posebnim naglaskom na analizu CPN-a u urbanim i ruralnim područjima te na temelju kvantitativnih socioekonomskih i prometnih pokazatelja.

U četvrtom poglavlju (4.) bit će prikazana metodologija prikupljanja i obrađivanja podataka o CPN-u inozemnih i domaćih mjerodavnih institucija te aktualne kooperativne radnje i metode na razini zemalja Europske unije kako bi se kod aktualnih baza podataka o CPN-u unaprijedile metode i načini prikupljanja kvantitativnih podataka o prometnim nesrećama (povećanje broja statističkih informacija o CPN-u) te kako bi se detektirala osnovna ograničenja i nedostatci nacionalne baze podataka i predložile aktivnosti za njihovo uklanjanje. U nastavku će biti naznačen pregled dosadašnje razine razvijenosti službenoga Informacijskog sustava obrade podataka o CPN-u u RH te osnovne karakteristike međunarodnih baza podataka o CPN-u.

Detaljna analiza stanja prometnoga sustava za referentnu urbanu sredinu, iskazana kroz trendove kretanja osnovnih sigurnosnih pokazatelja cestovnoga prometnog sustava, bit će prikazana u petom poglavlju (5.). Da bi se omogućila optimalna analiza svih CPN-a, potrebno je raspolagati relevantnim i međusobno povezanim podatcima koji ih karakteriziraju. U skladu s time, u predmetnom poglavlju komparativno će se sagledati apsolutni i relativni retrospektivni zbirni podatci o CPN-u distribuirani po posljedicama, kategoriji sudionika, prostornoj i vremenskoj strukturi, vrsti i uzrocima prometnih nesreća, a u svrhu detektiranja specifičnosti unutar kojih se CPN-i događaju. Obrađeni će biti statistički podatci o prometnim nesrećama koje su se dogodile u periodu od 10 godina, odnosno od 2004. do 2013. godine. Za provedbu prometno-sigurnosne analize korišteni su i statistički podatci o popisu stanovništva iz 2001. i 2011. godine.

U šestom poglavlju (6.) bit će prikazan način odabira ulaznih podataka i rangiranje pojedinih varijabli nužnih za izradu kauzalnoga modela. Analizirat će se kauzalnost čimbenika CPN-a. Budući da on, za razliku od standardnih statističkih modela koji razmatraju nezavisnost i povezanost, pretpostavlja relaciju između slučajne varijable koja je uzrok i slučajne varijable koja je posljedica, izradom modela pokušat će se, na temelju ulaznih analitičkih podataka, odnosno nizova utvrditi razina korelacije uključenih nezavisnih varijabli kako bi se ostvario što zorniji zaključak i predviđanje budućih stopa CPN-a. U skladu s time, u nastavku će biti naznačen sažeti prikaz strategija modeliranja najznačajnijih prethodno primjenjivih statističkih modela, kao i njihova primjena i ograničenja.

U sedmom (7.) poglavlju bit će prikazana strategija modeliranja modela kroz komparaciju različitih varijantnih rješenja. Nakon modeliranja modela i identifikacije utjecajnih čimbenika zaslužnih za pojavu CPN-a bit će objašnjena ocjena i usporedba. U konačnici će za evaluaciju biti

odabran onaj prognostički model koji će se ocijeniti kao realističan i primjenjiv u korelaciji s obrađenom statističkom podlogom.

Rezultati i evaluacija modela naznačeni su u osmom poglavlju (8.). Analizu rezultata predloženih kauzalno-prognostičkih modela promatramo kroz kvalitativnu i kvantitativnu analizu rezultata. Nakon spomenutih analiza provedena je evaluacija pojedinih modela. Evaluacija predloženih modela bit će izvedena s pomoću Kullback–Lieblerove informacije. Kroz evaluacijski proces, prvotno definirane pretpostavke, odnosno odabrani parametri po potrebi će se korigirati ako rezultati predloženoga modela pokažu znatna odstupanja u odnosu na stvarne podatke statističke baze podataka o CPN-u. Tim ćemo pristupom ostvariti mogućnost potvrde funkcionalnosti predloženih prognostičkih modela CPN-a za urbana područja i njihove održivosti u realnom okruženju.

U devetom (9.), zaključnom poglavlju doktorskog rada bit će iznesena ključna opažanja, gdje će biti istaknuti značajni rezultati istraživanja, a dat će se i osvrt na doprinos ovog rada.

2. ANALIZA PRISTUPA UPRAVLJANJU SIGURNOŠĆU CESTOVNOGA PROMETA

Osnovna zadaća subjekata zaduženih za gospodarenje cestovnim prometnicama te sigurnost cestovnoga prometnog sustava jest osiguranje zadovoljavajuće razine sigurnosti i protočnosti prometnih entiteta kako bi se omogućili pomaci u smanjenju težih oblika CPN-a (poginuli i ozlijeđeni), poboljšala kvaliteta života te ostvarila sigurna i održiva mobilnost.

S obzirom na to da tematika sigurnosti u posljednje vrijeme sve više uzima udjela u odnosu na ostale atribute cestovnoga prometnog sustava (protočnost, ekologija i dr.), donošenje učinkovitih rješenja kroz primjenu kvalitetnih alata za povećanje razine cestovne sigurnosti postaje imperativ.

Osobitost je gradskog prijevoza da je integriran s ostalim gradskim oblicima i prostornim strukturama te predstavlja važnu dimenziju mobilnosti, osobito u područjima visoke gustoće naseljenosti. Organizacija i funkcioniranje javnoga gradskog prijevoza razlikuje se u mnogim značajkama od individualnoga prijevoza. Najbitnije značajke javnoga prijevoza putnika u gradovima jesu fiksna trasa, dnevni red polazaka, veliki prijevozni kapacitet te relativno velika točnost prometovanja i stizanja na cilj [24].

Uz poticanje korištenja javnoga gradskog prijevoza, pješačenje je koncept koji je u funkciji održivoga razvoja prometnog sustava gradova. Pješačka populacija, koja predstavlja sve dobne skupine stanovnika gradova, najranjiviji je sudionik prometnoga sustava urbane sredine. Stoga, generalno govoreći, zaštita pješaka gradskim upravama treba biti prioritetni zadatak u rješavanju sigurnoga odvijanja cestovnoga prometa. Iako je pješački promet fundamentalni oblik mobilnosti, a osnovne su mu karakteristike racionalnost i pozitivan učinak na zdravlje i okoliš, lokalne gradske uprave često neodgovarajuće tretiraju taj oblik kretanja prilikom planiranja prometa i definiranja namjena javnih gradskih površina i objekata.

Biciklistički je promet uz javni gradski putnički promet jedan od najvažnijih održivih oblika ostvarivanja prihvatljive razine mobilnosti građana i održivoga razvoja gradova. Usprkos kontinuiranomu porastu individualnoga motornog prometa gradovi bilježe i sve veće učešće biciklističkoga prometa u ostvarenim putovanjima. Za povećan broj korisnika bicikala u gradovima, osim recesijskih prilika, svakako je zaslužan stupanj izgrađenosti i uređenosti biciklističkih površina. Sustavnim proširenjem biciklističke mreže, dogradnjom i prilagodbom novih dionica i spojnica te instaliranjem stalaka za bicikle popularizira se taj vid prometa, ali se nažalost povećava i sigurnosni rizik u biciklističkom prometu.

Kako bi zaštitile rizične skupine sudionika u prometu te im osigurale preduvjete za primjerenu razinu sigurnosti i mobilnosti, mnoge lokalne vlasti identificirale su sigurnost i mobilnost pješaka i biciklista kao imperativ, odnosno definirale najviši prioritet unutar svojih regionalnih i nacionalnih prometnih politika. Preduvjet za navedeno jest provesti prilagodbu postojeće prometne infrastrukture i javnih objekata njihovim potrebama, posebice cestovnih prometnica, raskrižja i čvorova [25, 26, 27]. Iz ranije spomenutih razloga gotovo se kao imperativ nameće potreba promjene postojećih stereotipa u prostornom planiranju i projektiranju te u kreiranju novih pravila ponašanja sudionika u prometu, kojima bi se održala primjerena razina njihove sigurnosti.

S obzirom na znatan intenzitet prometnih sudionika i entiteta u prometu, prostornu saturaciju pojedinih gradskih područja i gustoću cestovne prometne mreže, mogućnost je nastanka CPN-a u urbanim zonama znatno veća nego u ruralnim područjima.

Na lokalnoj razini gradska administracija ima značajan utjecaj u upravljanju sigurnošću prometa – unutar svojih nadležnosti posjeduje alate kojima znatno može utjecati na strateško planiranje gradskoga prometnog sustava kroz pripremu i donošenje kvalitetnih prostorno-prometnih planova te realizaciju odgovarajućih tehničko-regulativnih mjera i rješenja.

Na razinu sigurnosti prometa u kvantitativnom smislu najčešće utječu sljedeći čimbenici koji ujedno čine cestovni prometni sustav: vozači, vozilo ili prometnica te regulative (kroz kontrolu i sankcije), kao i kvaliteta njihove interakcije. Željeni rezultati mogu se ostvariti samo kroz provedbu planiranih, koordiniranih i dugoročnih aktivnosti istodobno usmjerenih na poboljšanje elemenata cestovnoga prometnog sustava te podizanje kvalitete njihovih međusobnih interakcija [28].

Aktualne želje i potrebe za upravljanjem cestovnim prometnim sustavom nadahnute su mnogobrojnim teorijama (sistemski pristup, Haddonova matrica [29] i dr.) primijenjenima u različitim pristupima sistematizaciji glavnih uzročnika nastanka CPN-a. To se ponajprije odnosi na decentralizaciju rada u svrhu poboljšanja razine sigurnosti u cestovnom prometu, odnosno prijenosa obveza i prava s nacionalne na regionalnu (područnu) i lokalnu razinu.

Drugo značajno područje odnosi se na uspostavu kvalitetnoga organizacijskog, zakonodavnog i financijskog okvira za provedbu nužnih intervencija na terenu. U ovom dijelu posebice je naglašena potreba za vođenjem službenih baza podataka o CPN-u kao nezaobilaznoga statističkog i analitičkog alata za kvalitetno praćenje kretanja rizičnih čimbenika u prometu. Posljednje područje očituje se u primjeni inozemnih znanja i iskustava u svrhu pripreme, kreiranja i provedbe preventivnih aktivnosti, i to u ranoj fazi detektiranja pojedinih problemskih područja cestovnoga sustava.

Činjenica je da se inozemna iskustva ne bi trebalo doslovno i nekritički kopirati, nego prilagoditi i primijeniti s obzirom na lokalne specifičnosti svakoga prostora (društveno-ekonomske karakteristike te karakteristike samoga prometnog sustava) na temelju izvršene analize lokalnih uvjeta i analize primjenjivosti na lokalne uvjete [30].

Usvajanjem tih iskustava ostvaruje se brzo razumijevanje problema, što službenicima na nacionalnoj i lokalnoj razini olakšava usvajanje odluka i postavljanje optimalnih ciljeva u skladu sa stranim iskustvima i primjerima dobre prakse iz drugih zemalja.

2.1. Pregled strateških dokumenata najrazvijenijih svjetskih zemalja vezanih uz sigurnost cestovnoga prometa

Brojne mjere i aktivnosti vezane uz sigurnost cestovnoga prometa, proizašle iz provođenja pripadajućih strategija te akcijskih planova, imaju za cilj smanjiti učestalost i težinu posljedica CPN-a.

Analizom stopa poginulih u CPN-u na globalnoj razini potvrđeno je kako se veliki udio CPN-a događa u zemljama u razvoju koje još uvijek nisu implementirale učinkovitu sveobuhvatnu nacionalnu strategiju sigurnosti cestovnoga prometa [31].

S obzirom na to da svaka pojedina zemlja odnosno grad ima specifične situacije vezane uz sigurnosni razvoj vlastitoga prometnog sustava, važno je naglasiti kako prilikom izrade prometnih strategija sigurnosti cestovnoga prometa svaka od njih koristi različite pristupe s drugačijim naglascima na pojedina područja sigurnosti cestovnoga prometa [32]. Upravo iz tih razloga danas je u svijetu prisutan trend kretanja sistematičnoga okvira (platforme) za procjenu najznačajnijih strateških dokumenata sigurnosti cestovnoga prometa, neovisno o stupnju ekonomske razvijenosti pojedine zemlje, već upravo na temelju krajnjih rezultata uspješnosti implementacije tih dokumenata.

Kako bi se anuliralo trenutno stanje, odnosno kontrolirale neželjene posljedice cestovnoga prometnog sustava (apsolutan broj CPN-a, nastradalih te visina materijalne štete), mnogobrojne države kroz svoje relevantne razvojno-planske dokumente vezane uz sigurnost cestovnoga prometa implementiraju svojstvene inicijative, programe i strategije te pripadajuće akcijske planove s različitim razinama uspješnosti. Nakon komparativnoga pregleda dokumentacijske osnove vezane uz sigurnost cestovnoga prometa u razvijenijim europskim i svjetskim državama [33] kao ključno definirana sigurnosna područja djelovanja na cestovni prometni sustav možemo izdvojiti sljedeće:

- izmjena i dopuna zakonske legislative,
- pojačana kontrola sudionika u prometu s većim represivnim mjerama za prijestupnike,
- jačanje edukativnih programa i javnih kampanja o načinu ponašanja i sudjelovanja u prometu, posebice djece i starijih,
- integracija specifičnih ciljeva pojedinih rizičnih skupina sudionika u prometu,
- kontrola ispravnosti cestovnih motornih vozila te modernizacija njihove aktivne i pasivne opreme,
- unapređenje postupka prilikom projektiranja i izvođenja radova na javnim cestovnim površinama i objektima.

Neke od najznačajnijih kontinuiranih i dobro osmišljenih inicijativa u posljednjih dvadesetak godina na području upravljanja sigurnošću cestovnoga prometa jesu upotreba zaštitnih pojaseva i zračnih jastuka, kamera za kontrolu prekoračenja dopuštene brzine prometovanja, pojačana kontrola testiranja na konzumaciju alkohola i opojnih droga s pripadajućim medijskim kampanjama, revizije projektno-tehničke dokumentacije u fazi planiranja i njezine izrade, sigurnosne terenske inspekcije, identifikacije i analize opasnih lokaliteta na cestovnim prometnicama, tzv. „crnih točaka“, odnosno pripadajućih užih zona na kojima je smanjen nivo sigurnosti prometa te implementacija statističkih modela za predviđanje stopa CPN-a, posebice onih težih oblika.

Ako želimo implementirati ili unaprijediti postojeće strategije za povećanje sigurnosti cestovnoga prometa, nameće se potreba za sustavnim komparativnim pregledom strategija (na nacionalnoj i lokalnoj razini) prisutnih u onim zemljama koje ulažu znatna sredstva i resurse u sigurnost cestovnoga prometa i onih u kojima su očiti pomaci na bolje. Tim smo pristupom u mogućnosti kvalitetnije selektirati primjere najboljih inozemnih praksi i iskustava koje su pojedine zemlje akumulirane tijekom vremenskoga okvira planiranja, razvoja i implementacije, a što predstavnicima lokalnih i državnih institucija olakšava rangiranje prioritetnih mjera i aktivnosti usmjerenih k povećanju razine sigurnosti cestovnoga prometa na svojem području.

Međusobno komparirajući strategije sigurnosti cestovnoga prometa u pojedinim najrazvijenijim europskim i svjetskim zemljama u području sigurnosti cestovnoga prometa (Australija, Velika Britanija, Japan, Novi Zeland, Švedska i dr.), može se ponajprije konstatirati da postoje snažni sinergijski partnerski odnosi različitih državnih tijela i organizacija zaduženih za provedbu pojedinih mjera i ciljeva. Nadalje, u primjeru Australije [34] najkvalitetnije je izražena potreba, s jasno definiranim individualnim mjerama i aktivnostima, za pojedina specifična područja djelovanja kao što su ponašanje sudionika u prometu (predstavlja najveći potencijal utjecaja na sigurnost prometa), sigurnost cestovnih prometnica, motorna vozila, jednakost među pojedinim

sudionicima u prometu, medicinske i uslužne usluge, alternativna prijevozna sredstva, istraživanja u svezi sa zakonskim legislativama i programima. Samo tako jasno definiranim mjerama i aktivnostima moguće je točno odrediti viziju koju želimo postići implementacijom strategije, lakše sustavno planirati i odrediti opseg ciljeva i akcijskih planova te alocirati ionako oskudna financijska sredstva.

U posljednjih desetak godina komparacijom nacionalnih vizija, misija i strategija sigurnosti cestovnoga programa u prethodno spomenutim zemljama, a u skladu s preporukama UN-ove rezolucije [35], u području upravljanja sigurnošću cestovnog prometa sve se više primjenjuje pristup uspostave ambiciozno kvantificiranih te vremenski ograničenih ciljeva [36] [37] [38].

Kvantificirani i mjerljivi ciljevi predstavljaju, zapravo, numerički broj ili indeks što ga definiraju nacionalne ili lokalne uprave, ovisno o razini za koju je pripremljen, kako bi se reducirao broj preminulih ili ozlijeđenih osoba u prometu (npr. zadavanje cilja kako do kraja 2020. godine u Republici Hrvatskoj ne bi trebalo biti više od 213 smrtno stradalih osoba).

Za svaki od tako definiranih ciljeva sigurnosti cestovnoga prometa (prethodno potkrijepljenih određenim istraživanjem kako bi ih bilo moguće realno ostvariti) razvijaju se potom specifični programi sigurnosti s ciljanim mjerama i aktivnostima, što je, naposljetku, sastavni dio procesa gotovo svih aktualnih sigurnosnih strategija.

S obzirom na to da je za utvrđivanje učinka implementiranih protumjera u reduciranju stopa CPN-a potrebno određeno vremensko razdoblje, za uspješnu provedbu strategijskih ciljeva potrebno je također predvidjeti i čitav niz drugih čimbenika, kao što su promjenjivi socioekonomski i politički trendovi i sl., koji mogu znatno utjecati na konačan ishod [39].

2.1.1. Osnovne komponente strategija sigurnosti cestovnoga prometa

Osnovne komponente većine učinkovitih strategija sigurnosti cestovnoga prometa moguće je podijeliti u sljedeće skupine: ciljevi, vizija i misija, mjere i aktivnosti te akcijski planovi, pri čemu su ključni čimbenici za uspješnu implementaciju evaluacija i nadzor, istraživanje i razvoj, kvantitativno modeliranje, institucionalni okvir te sredstva za financiranje [40].

Za strateške dokumente osobito je važna evaluacija izvršenih aktivnosti i ostvarenih rezultata tijekom provedenoga vremenskog razdoblja (praćenje napretka ostvarivanja zadanih ciljeva kroz razradu prijelaznih tromjesečnih, reviziju godišnjih te sveobuhvatnih trogodišnjih izvještaja) kako bi dobiveni rezultati za sljedeće izvještajno razdoblje mogli poslužiti kao temelj za

eventualnu korekciju pojedinih zadanih ciljeva te redefiniranje i reorganizaciju određenih nositelja aktivnosti.

U pravilu postoji nekoliko pristupa u mehanizmima procjene učinkovitosti odnosno evaluacije efekata predloženih mjera i aktivnosti te postignuća zadanih ciljeva. Prva je jednostavna komparacija, zatim statistička analiza podataka o CPN-u, procjena ekonomske opravdanosti (*cost-benefit* analiza), *ex-ante* i *ex-poste* analiza (za specifična područja djelovanja kao npr. praćenje i razumijevanje učinkovitosti pojedinih implementiranih mjera za sanaciju takozvanih „crnih točaka“, tj. *BSM – Black Spot Management*), a što se u pravilu provodi u vremenskom razmaku od 12 mjeseci) te analiza trendova na temelju pojedinih ključnih parametara.

Osim na nacionalnoj razini, gdje su u većini slučajeva navedeni ciljevi uvršteni u nacionalne programe/strategije sigurnosti cestovnoga prometa, važna je implementacija i koordinacija kompatibilnih ciljeva i na nižoj razini vlasti, onoj lokalnoj, gdje u većim gradovima/regijama ondašnja gradska uprava igra važnu ulogu u definiranju odgovarajućih mjera i aktivnosti za uspješno provođenje tih ciljeva.

S obzirom na to da inicijative na spomenutim nižim razinama vlasti nisu u Republici Hrvatskoj koordinirane s onim nacionalnim, niti za to postoje odgovarajući popratni dokumenti, nameće se nužna potreba za izradom krovnoga dokumenta o sigurnosti cestovnoga prometa – *Nacionalne strategije sigurnosti cestovnoga prometa u Republici Hrvatskoj*. Nakon njezine izrade potrebno je pristupiti izradi bliskih strateških dokumenata za glavne gradove Republike Hrvatske, s njihovim specifično definiranim prometnim politikama i izazovima na području sigurnosti cestovnoga prometa, ciljevima za smanjenje stopa poginulih i smrtno stradalih, rizičnim čimbenicima, preventivnim i ovršnim mehanizmima, policijskim aktivnostima i dr.

Osim navedenoga, utjecajni političari, državni službenici i organizacijski čelnici koji se bave područjem sigurnosti i mobilnosti cestovnoga prometa na nacionalnoj razini, kao i službenici na lokalnoj/regionalnoj razini, od početka moraju biti involvirani u izradu te kasniju promociju nacionalne strategije sigurnosti cestovnoga prometa. Njihova uloga mora biti u povećanju motivacije, odnosno u naglašavanju prisutne problematike, s obzirom na to da je sam proces planiranja i implementacije sigurnosti cestovnoga prometa vrlo fragmentiran i dugotrajan.

Naposljetku, pri razvoju strateških programa sigurnosti cestovnoga program, koji su osmišljeni da ostvare određene kvantitativne ciljeve kroz implementaciju niza ciljanih mjera i aktivnosti, velika se važnost pridaje predviđanju budućih stopa CPN-a te broja smrtnih slučajeva i ozlijeđenih, stoga bi prognostički modeli CPN-a trebali biti sastavni dio strateških programa.

2.1.2. Akcijski planovi djelovanja

Sveobuhvatan i kvalitetno organiziran akcijski plan bitan je segment strategije upravljanja sigurnošću cestovnoga prometa s obzirom na to da znatno olakšava procjenu, planiranje te provedbu budućih mjera i aktivnosti.

Osnova za izradu svakoga akcijskog plana sigurnosti prometa te kataloško definiranje protumjera za svaki od detektiranih problemskih područja jest temeljita dubinska analitička analiza svih relevantnih i dostupnih statističkih podataka o CPN-u i prometnom sustavu, uz adekvatno opisivanje i praćenje trendova njihova kretanja.

Sadržaj akcijskoga plana mora jasno definirati sve konkretne mjere i aktivnosti za uspješnu provedbu ciljeva naznačenih unutar pripadajuće Strategije – dinamiku i terminski plan za realizaciju pojedinih mjera/aktivnosti (prioritetno rangiranje – status te planirano vrijeme realizacije – kratkoročno, srednjoročno i dugoročno), cilj pojedine mjere/aktivnosti, indikatore njihova praćenja te analizu dionika s jasno naznačenim obvezama i ulogama (definiranje voditelja te skupine institucija i subjekata koji će biti involvirani u provedbu određene aktivnosti) te izvorima i procjenom visine adekvatne financijske podrške – SWOT analiza (razvojne snage, slabosti, mogućnosti, prijetnje).

Predložene mjere moraju također pokrivati i sva relevantna područja djelovanja kroz koja je moguće sustavno djelovati na povećanje razine sigurnosti prometa, kao što su rizično ponašanje sudionika u prometu, provedba i evaluacija, cestovna infrastruktura i vozila te organizacija službi hitne medicinske pomoći unesrećenima.[4]

Neka od najčešćih prioritetnih područja djelovanja koja su uključena u akcijske planove sigurnosti prometa, a za koja se zatim i predlažu specifične mjere i aktivnosti jesu sljedeća: edukacija sudionika u prometu te preventivne medijske kampanje usmjerene k poštivanju prometnih propisa (ograničenje brzine prometovanja, zaštita najranjivijih skupina sudionika u prometu, promjena stavova građana da ne sudjeluju u prometu ako su pod utjecajem alkohola, opojnih sredstava ili zabranjenih medikamenata, upotreba zaštitne opreme, opasnost korištenja mobitela, kao i smanjenje drugih visokorizičnih nepoželjnih ponašanja i radnji vozača u prometu), provedba

[4] Konačni set predloženih mjera i aktivnosti trebalo bi izvesti uvažavajući specifične situacije i zakonitosti prometnoga sustava unutar kojega se planiraju implementirati, u korelaciji s primjerima najbolje prakse iz drugih zemalja proaktivnih u području sigurnosti prometa. To često predstavlja potrebu implementacije nekih novih, specifičnih mjera i aktivnosti sigurnosti prometa, odnosno modifikacije postojećih uvriježenih mjera kako bi se postigli što kvalitetniji željeni efekti.

i evaluacija obuke i licenciranje vozača, edukacija djece i mladih vozača, starijih sudionika u prometu (osobe starije životne dobi te osobe s određenim stupnjem invaliditeta), pješaka, biciklista i motociklista, cestovna infrastruktura, sigurnost cestovnih vozila, zaštita pružnih cestovnih prijelaza i dr.

Gotovo svakim novih strateškim programom sigurnosti cestovnoga prometa sustavno se implementiraju nove specifične mjere i aktivnosti vezane uz postizanje zadovoljavajuće razine sigurnosti odvijanja prometa za sve sudionike u prometu kako bi se povećala opća razina sigurnosti. U skladu s time postignut je znatan napredak.

To se postiže naprednim planiranjem temeljenim na istraživanjima i javnim raspravama između zainteresirane šire javnosti i radnih skupina, za razliku od klasičnih jednogodišnjih planiranja koja dovode do neznatnih unapređenja samo u specifičnim područjima djelovanja.

Takvim pristupom, međusobnim podupiranjem pojedinih mjera i aktivnosti, postiže se veća učinkovitost i sinergija u adresiranju specifičnih ciljeva zadanih kroz određeni vremenski okvir.

S obzirom na složenost poslova, za potrebe uspješnoga provođenja usvojenih akcijskih planova djelovanja često se imenuju koordinator i stručni tim koji kontinuirano rade na realizaciji dogovorenoga.

Važno je također napomenuti da se kontinuirano praćenje inozemnih iskustava iz područja sigurnosti prometa te razmjena najboljih praksa i primjena provjerenih znanja i iskustava ne mogu u potpunosti preslikati na domaće uvjete i uskladiti s našim pravnim i socijalnim okvirom, stoga je potrebno samostalno kreirati i implementirati vlastite mjere i aktivnosti usmjerene k smanjenju djelovanja ključnih čimbenika, naravno uz prethodno kvalitetno organiziran sustav sigurnosti prometa.

2.2. Pregled europskih propisa u području sigurnosti cestovnoga prometa

S obzirom na relativno negativne pokazatelje i prognoze kretanja stopa posljedica CPN-a (u periodu od 1990. do 2000.) [41], na razini Europske unije pokreće se niz programa i izrađuje niz dokumenata u svrhu smanjenja stopa i oblika CPN-a te njihovih negativnih posljedica.

Tijekom 2001. godine Europska komisija objavljuje dokument naziva *European transport policy for 2010: Time to decide* (Bijela knjiga) [42], koji je imao za cilj prepoloviti broj smrtno stradalih

sudionika u prometu za 50% u razdoblju od 2000. do 2010.[5] U tom dokumentu po prvi se put razmatra koncept zajedničke nadležnosti, u kojoj se pojedine aktivnosti, u skladu sa specifičnim situacijama, prioritetima te materijalnim sredstvima, predviđaju realizirati unutar pojedinih zemalja članica, dok je za realizaciju određenih drugih mjera i aktivnosti potrebna suradnja zajednice EU-a u cjelini.

Na tragu toga, u 2003. godini objavljuje se i dokument naziva *European Road Safety Action Programme, Halving the number of road accident victims in the European Union by 2010: A shared responsibility* [43] za period od 2001. do 2010., u kojem su definirane sve relevantne mjere i aktivnosti za postizanje ciljeva navedenih u „Bijeloj knjizi" i *Europskoj povelji o sigurnosti na cestama* (engl. *European Road Safety Charter*),[6] podijeljene u tri glavna programska područja djelovanja:

- područje vezano uz ponašanje sudionika u prometu, odnosno povećanje stupnja poštivanja prometnih propisa i pravila (korištenje zaštitnih pojaseva i kaciga, izbjegavanje prekomjerne brzine i konzumacije alkohola i drugih nedozvoljenih supstanci i dr.) te kontinuirana edukacija i obrazovanje vozača amatera te profesionalnih vozača,
- područje vezano uz poboljšanje sigurnosti motornih vozila (tehnički napredak i harmonizacija obvezne aktivne i pasivne opreme unutar vozila, primjena informacijske i komunikacijske ITS tehnologije – *eSafety*),
- područje vezano uz unapređenje cestovne infrastrukture (analizom primjera najbolje prakse na lokalnoj razini u svrhu uklanjanja detektiranih crnih točki na cestovnoj prometnoj mreži).

Instrumenti za realizaciju navedenih ključnih područja djelovanja odnose se na unapređenje zakonske legislative [44], uključivanje znanstvenih institucija, jačanje financijskih okvira za

[5] Usprkos značajnomu poboljšanju stupnja cestovne sigurnosti, nije u potpunosti ispunjen plan kojim je zacrtano smanjenje broja poginulih za 50% (broj je poginulih smanjen za 40%, što je rezultiralo spašavanjem gotovo 80.000 ljudskih života). Najbolje rezultate ostvarila je Latvija (54% manje poginulih), a slijede ju Španjolska (53%), Estonija (50%) i Portugal (50%). Jedine su dvije zemlje koje su u promatranom periodu zabilježile povećanje broja poginulih Malta (31%) i Rumunjska (14%).

[6] Europska komisija 2004. godine usvojila je *Europsku povelju o sigurnosti u prometu*, koja predstavlja koncept odgovornosti za društvo u cjelini odnosno platformu cestovne sigurnosti civilnoga društva. Potpisalo ju je i konkretne mjere izvršava više od 2.300 udruga, znanstvenih institucija, sveučilišta i škola u suradnji s lokalnom vlašću i trgovačkim društvima.

uspješno planiranje i realizacije aktivnosti, izradu smjernica i primjera najbolje prakse za pojedina problemska područja djelovanja te izradu jedinstvenih baza podataka o CPN-u na razini EU-a, za potrebe kvalitetne komparativne analize te praćenja uspješnosti implementiranih mjera i aktivnosti pojedinih država članica.

U navedenom dokumentu znatna je pozornost posvećena poboljšanju stupnja cestovne sigurnosti najugroženijih kategorija sudionika u prometu te su predložene specifične mjere koje se odnose na poboljšanje stupnja njihove sigurnosti i mobilnosti u prometu. Od navedenih skupina možemo izdvojiti djecu školske i predškolske dobi, mlade ljude i roditelje, slabo i teško pokretne osobe s određenim stupnjem invaliditeta, pješake te bicikliste i motocikliste.

Osim spomenutoga programa EU-a, Europska komisija tijekom 2004. godine usvaja i paket preporuka – *Commission Recommendation 2004/345/EC* [45] u svezi s jačanjem sustava sigurnosti cestovnoga prometa – koji za svoj cilj ima zadano znatno poboljšanje stupnja sigurnosti na prometnicama u Europskoj uniji kroz smanjenje poginulih i stradalih sudionika u prometu. Spomenuti dokument, u svrhu implementacije predloženoga plana na nacionalnoj razini za države članice EU-a prvenstveno se usredotočuje na djelovanje u području ponašanja sudionika u prometu, gdje je za pojedina njihova rizična ponašanja pripremio listu mjera za informiranje javnosti i njegovu provedbu, prethodno temeljenu na primjerima i smjernicama dobre prakse.

Nadalje, 2008. godine unutar Direktive 2008/96/CE [46] navedeni su svi postupci i radnje za uspostavu i provedbu kvalitetnoga upravljanja sigurnošću nad cestovnom infrastrukturom:

- procjena utjecaja na cestovnu sigurnost za sve infrastrukturne projekte (engl. *Road Safety Impact Assessment*),
- revizija u fazi projektiranja infrastrukture (engl. *Road Safety Audit*),
- klasifikacija i upravljanje sigurnošću javne cestovne mreže[7] (engl. *Safety Ranking and Management*),
- sigurnosne provjere (engl. *Road Safety Inspection*),
- upravljanje informacijama o CPN-u (podatci koji moraju biti uključeni u *Upitnik o prometnim nesrećama*) i dr.

Tijekom 2010. godine Europska je komisija usvojila novi, četvrti Akcijski program sigurnosti cestovnog prometa za period 2011. – 2020. Program je nastavak prethodno spomenutoga trećeg akcijskoga programa (period 2001. – 2010.) kojim su postignuti značajni rezultati na planu

[7] Identifikacija cestovnih dionica s velikom koncentracijom CPN-a i identifikacija dionica pogodnih za analizu rangiranja cestovne sigurnosti.

povećanja sigurnosti na cestama EU-a. Aktualni akcijski program definira ukupno sedam temeljnih ciljeva i aktivnosti, koji ujedno predstavljaju i glavne uzročnike smrtnosti kod težih oblika CPN-a :

- brzina i agresivno ponašanje u vožnji,
- konzumacija alkohola i droga, umor, upotreba mobilnih uređaja tijekom vožnje,
- nekorištenje zaštitnih pojaseva te sigurnosnih sustava za djecu,
- nekvalitetno projektiranje i upravljanje cestovnim prometnim objektima i infrastrukturom,
- nedostatak obveznih aktivnih i pasivnih sigurnosnih značajki motornih vozila.

Za svaki od navedenih ciljeva predložen je set interdisciplinarnih mjera u svrhu uspješne redukcije stopa CPN-a, među kojima posebno možemo izdvojiti aktivnosti u svezi s poboljšanjem sustava žurne medicinske pomoći i skrbi o unesrećenima implementacijom sustava E-poziv (engl. *eCall*),[8] uspostavom kvalitetnoga sustava prikupljanja, analize i diseminacije podataka o CPN-u (nastavak razvoja *Europske baze podataka o prometnim nesrećama* – CARE, te širenje njezine dostupnosti) te kvalitetnim planiranjem putovanja koje se integrira s namjenom zemljišta.

Važan set dokumenata (preporuke i rezolucije) vezan uz tematiku sigurnosti cestovnoga prometa proizašao je iz proaktivnoga djelovanja Konferencije europskih ministara prometa (engl. *European Conference of Ministers of Transport*) [47, 48].

Određeni pomaci vidljivi su i u djelovanju Ujedinjenih naroda, gdje se 2004. godine po prvi put na Općoj skupštini raspravljalo o problematici CPN-a te globalnom teretu koji generira.

Kako bi spriječila daljnje negativne trendove i prognoze u cestovnom prometu, odnosno spriječila nastanak CPN-a i smanjila njegove posljedice, Opća skupština UN-a 2010. godine usvaja rezoluciju 64/255 [35], koja proklamira trenutno desetljeće (2011. – 2020.) kao *Desetljeće akcije za sigurnost cestovnog prometa*. Supokrovitelje rezolucije čini ukupno 98 zemalja s ciljem stabilizacije, a kasnije i smanjenja broja smrtnih slučajeva. Rezolucija bi pod pretpostavkom provedbe hitnih institucionalnih reformi te usvajanja najboljih inženjerskih praksi u svrhu poboljšanja sigurnosti

[8] Prvi e-Poziv u stvarnom okruženju u Hrvatskoj ostvaren je u ožujku 2012. godine, a očekuje se da će usluga e-Poziva 2015. godine postati nacionalnom uslugom u zemljama Europske unije. Procjenjuje se kako će sustav, kada postane standardan, spašavati godišnje oko 2.500 ljudskih života u Europi te smanjivati ozbiljnost posljedica nesreća za vozače i putnike u vozilu za 15% jer će omogućiti bržu reakciju hitnih službi, koje će lakše moći doći na mjesto nesreće unutar „zlatnoga sata“.

cestovnoga prometnog sustava mogla prevenirati gubitak oko 5 milijuna ljudskih života te 50 milijuna težih tjelesnih ozljeda sudionika u prometu na globalnoj razini.

Organizacija same rezolucije predlaže poticanje izrade adekvatnih planova i provođenje akcija sigurnosti cestovnoga prometa na nacionalnom, regionalnom i globalnom nivou, a temelji se na ukupno pet zasebnih logičkih cjelina, i to kako slijedi: upravljanje sigurnošću cestovnoga prometa, cestovna infrastruktura, sigurnost i tehnologija vozila, ponašanje sudionika u prometu te liječnička njega nastradalih.

2.3. Institucionalni okviri upravljanja sigurnošću cestovnoga prometa

2.3.1. Analiza dobre prakse i znanja u razvijenim zemljama članicama Europske unije

Posljedice CPN-a često su tjelesne ozljede te znatni materijalni i financijski izdatci nastali zbog šteta na motornim vozilima, uništenja cestovne prometne opreme i signalizacije, intervencije vozila hitnih službi te ostalih troškova održavanja i administracije u periodu nakon nastanka samih CPN-a. Stoga je i imperativ gotovo svih nacionalnih tijela i uprava zaduženih za upravljanje cestovnim prometnim sustavom da rizik tijekom prometovanja svedu na minimum te da reduciraju ukupne troškove CPN-a.

Na tragu toga, znatan je broj članica EU-a tijekom posljednjih 20-ak godina unutar svojih postojećih državnih institucionalnih tijela (najčešće nadležnoga ministarstva) formirao zasebne, neovisne, stručno-savjetodavne agencije ili središnje javne uprave kojima je zadaća upravljanje i razvoj cestovnoga prometnog sustava, odnosno provedba pripadajućih akcijskih planova i programa sigurnosti cestovnoga prometa koji funkcioniraju unutar nadležnosti vlastitih radnih tijela i odbora [49].

U početnim fazama njihova rada problemske su se situacije najčešće očitovale u slabo definiranim pravima i zaduženjima te nedovoljnoj međusobnoj koordinaciji relevantnih subjekata i sektora, što je posebice izraženo na lokalnoj i nacionalnoj razini. Posljedice takvoga rada bile su česte nemogućnosti provedbe određenih standarda ili zakonskih odredbi usvojenih na državnoj razini s operativnim i zakonskim djelovanjem i provedbom putem regionalnih i lokalnih gradskih ureda, službi te komunalnih trgovačkih društava.

U skladu s time, tražeći održive temelje za uspostavljanje efikasnoga sustava sigurnosti cestovnoga prometa na nacionalnoj i lokalnoj razini, preporuke Svjetske zdravstvene organizacije

(engl. *World Health Organization*) i Svjetske banke (engl. *The World Bank*) [50] čine realnu i prihvatljivu osnovu, naznačenu kroz set praktičnih preporuka i smjernica, koje su u nastavku prethodno prilagođene realnim uvjetima i okruženju u nas:

- uspostava vodeće agencije (tijela) na nacionalnoj razini s cjelokupnom odgovornošću za tematiku sigurnosti cestovnoga prometa,
- organiziranje interdisciplinarnih savjetodavnih tijela i organizacija zaduženih za operativno upravljanje sigurnošću cestovnoga prometa na lokalnim i regionalnim razinama (npr. *Savjeti za sigurnosti prometa na cestama na razini županija*),
- definiranje problema, politike sigurnosti u prometu i pripadajućih standarda za sudionike u prometu, mjerljivih aktivnosti, normativnih i institucionalnih organizacijskih okvira te alokacija dostatnih financijskih sredstava i administrativnih kapaciteta koji se odnose na povećanje razine sigurnosti svih sudionika u prometu,
- priprema, usvajanje i praćenje nacionalnih planskih dokumenata (politika, strategija i akcijskih planova) te izravnih i posrednih podzakonskih akata vezanih za sigurnost cestovnoga prometa,
- implementacija realnih ciljanih mjera i aktivnosti u svrhu prevencije CPN-a, minimizacija stopa tjelesnih ozljeda i njihovih posljedica te periodička evaluacija utjecaja njihove primjene, predviđanje dinamike realizacije te definiranje realizacije u skladu s prethodno izrađenom listom prioriteta,
- uspostava procesa transfera znanja i iskustva razvijenijih zemalja i gradova iz EU – podrška razvoju nacionalnih administrativnih kapaciteta te međunarodnih kooperativnih aktivnosti, uspostava trajne međusobne interaktivne suradnje kroz definiranje protokolarnih obveza tijela/organizacija na nacionalnoj razini s upravama i stručnim službama na lokalnoj (regionalnoj) razini.

U pojedinim razvijenim europskim zemljama u navedenu problematiku postupno se uključuju i referentne tehničke i znanstvene institucije kao potpora državnim institucijama zaduženima za sigurnost cestovnoga prometa, koje su svojim istraživačkim radovima putem dodijeljenih znanstvenih projekata i programa znatno pridonijele kvaliteti rada agencija za sigurnost cestovnoga prometa. Riječ je najčešće o samostalnim istraživačkim institutima čiji se opis poslova odnosi isključivo na tematiku sigurnosti cestovnoga prometa, a koji svojim radom donositeljima

odluka pružaju stručne savjete i smjernice izrađene uz pomoć verificiranih znanstvenih metodologija.[9]

Osim agencija i koordinativnih tijela na nacionalnoj razini, mnoge zemlje EU-a unutar svojih institucionalnih okvira sigurnosti prometnoga sustava implementiraju istovjetna tijela i na regionalnoj i lokalnoj razini, ovisno o ukazanim potrebama s terena. Navedena tijela uz snažnu potporu (administrativnu i novčanu) lokalnih i gradskih uprava (ureda i stručnih službi) te ostalih subjekata (prometna policija, zdravstvene i obrazovne ustanove, održavatelji i upravitelji cestovne infrastrukture, predstavnici transportnih tvrtki, nevladine udruge i dr.) pokušavaju implementirati istovjetne vizije i ciljeve zadane na nacionalnoj razini, ali uz prethodno izrađene konkretne akcijske planove i aktivnosti namijenjene uklanjanju specifičnih problemskih situacija unutar njihova administrativnog područja.

Kao predradnja za formiranje takvih tijela, vrlo je važno prethodno izučiti sve relevantne vanjske čimbenike koji bi mogli utjecati na ograničavanje njihova rada kako bi se oni uklonili te kako bi bio omogućen njihov nesmetan rad.

2.3.2. Analiza uređenosti sustava sigurnosti cestovnoga prometa na području Republike Hrvatske

Najznačajniju nacionalnu normativnu podlogu važećega sustava iz područja sigurnosti cestovnoga prometa i cesta čine:

- Zakon o sigurnosti prometa na cestama (NN 67/08, …, 64/15),
- Zakon o cestama (NN 84/11, …, 92/14),
- Zakon o prijevozu u cestovnom prometu (NN 82/13),
- Zakon o prijevozu opasnih tvari (NN 79/07),
- Zakon o inspekciji cestovnog prometa i cesta (NN 22/14),
- Zakon o radnom vremenu, obveznim odmorima mobilnih radnika i uređajima za bilježenje u cestovnom prijevozu (NN 75/13, 36/15).

[9] U njima su prvenstveno zaposleni prometni eksperti s dugotrajnim stažom i iskustvom u području sigurnosti prometa, koji svoje znanje i vještine zatim prenose mlađim djelatnicima. Osim realizacije projekata iz predmetnoga područja (izrada stručnih mišljenja i evaluacija projekata, studija, provedba istraživanja i anketiranja), područje djelovanja može uključivati i obrazovanje i obuku budućih prometnih stručnjaka i inspektora.

U Republici Hrvatskoj pristup rješavanju problema sigurnosti cestovnoga prometa temeljen je na sinergijskom partnerskom odnosu više nacionalnih tijela zaduženih za planiranje i provedbu adekvatnih mjera i aktivnosti.

Unutar posljednjega *Nacionalnog programa sigurnosti cestovnog prometa Republike Hrvatske* nalazi se također i institucionalni okvir unutar kojega je definirana koordinacija između svih relevantnih subjekata s detaljnom listom državnih tijela i nevladinih organizacija koji su unutar vlastitoga djelokruga nadležnosti zaduženi za razvoj sigurnosti cestovnoga prometnog sustava.

Za dijeljenje provedenih aktivnosti i osiguranje bolje međusobne suradnje Vlada je RH, kao i u prethodnim nacionalnim programima, zadužila Ministarstvo unutarnjih poslova, pri čemu za djelotvorniju provedbu Programa ministar unutarnjih poslova na prijedlog ostalih subjekata imenuje Radnu skupinu (stručnu ekipu) unutar koje se nalaze predstavnici MUP-a (odgovorni za predlaganje zakona i njihovo provođenje u prometu te edukaciju vozača i ostalih sudionika u prometu), Ministarstva pomorstva, prometa i infrastrukture (odgovorni za provedbu inspekcijskih nadzora nad cestovnom prometnom infrastrukturom, signalizacijom i opremom na cesti), Ministarstva znanosti, obrazovanja i sporta (odgovorno za pripremu prilagođenih programa obrazovanja u području sigurnosti cestovnoga prometa za djecu školske i predškolske dobi), Ministarstvo zdravstva i socijalne skrbi (odgovorno za organizaciju timova hitne medicinske pomoći, bolničkoga liječenja i rehabilitacijske podrške unesrećenim osobama), Ministarstvo pravosuđa (odgovorno za pripremu novih te usklađenje postojećih zakonskih akata u području sigurnosti cestovnoga prometa), Hrvatski autoklub, Centar za vozila Hrvatske, Hrvatske ceste i Hrvatski ured za osiguranje.

U ovom dijelu važno je navesti kako sve ove institucije predstavljaju samo svojevrsno koordinacijsko tijelo umjesto statutarnoga kakvo bi isključivo bilo zaduženo za nadziranje i provedbu odgovarajućih mjera u ostvarenju zadovoljavajuće razine sigurnosti cestovnoga prometa na području RH. S obzirom na to da svako od navedenih tijela djeluje pod zasebnim organizacijskim i političkim okruženjem, nema previše izravnoga uplitanja međunarodnih institucionalnih struktura.

Također, osim što radna tijela predlažu godišnje planove nabava unutar kojih su navedene sve aktivnosti što ih kroz planirano razdoblje planiraju provesti, poželjno bi bilo i da svako od navedenih tijela radne skupine predlaže zasebne trogodišnje ili petogodišnje planove i programe kako bi se pospješio proces formuliranja liste prioriteta za svako od pojedinih područja djelovanja.

2.3.3. Nacionalni program sigurnosti cestovnoga prometa Republike Hrvatske

Planovi i akcije usmjerene na smanjenje negativnih trendova stradavanja i ugroženosti sudionika u cestovnom prometnom sustavu 90-ih su se godina temeljili ponajprije na individualnim pokušajima i aktivnostima pojedinih državnih i lokalnih tijela, odnosno subjekata kojima je sigurnost cestovnoga prometa djelokrug rada, što je za rezultat imalo parcijalna rješenja te nezadovoljavajuće kratkoročno postignute rezultate.

Sustavan i koordiniran pristup predlaganju skupa preventivnih, edukativnih i represivnih mjera, temeljenih na praćenju svjetskih dostignuća, transferu znanstvenih spoznaja i pozitivnih iskustava zapadnih zemalja EU-a, u RH je implementiran 1994. godine, kada je usvojen i I. Nacionalni program sigurnosti cestovnog prometna RH [51].

Navedeni program već tijekom početnih godina svojega provođenja bilježi određene pozitivne učinke i rezultate, a razlog za njegovu uspješnost leži u činjenici da je pri njegovoj izradi po prvi put radio tim interdisciplinarnih znanstvenih i stručnih autoriteta, okupljenih u sektorskim radnim skupinama iz relevantnih organizacija i radnih tijela.[10]

Navedeni krovni dokument usmjeren je na unapređenje sustava sigurnosti cestovnoga prometa koji kroz svoje programe pokušava sublimirati osnovne prometne pokazatelje cestovnoga prometnog sustava u RH te sustavno definirati najznačajnije elemente i dugoročne vizije i ciljeve na nacionalnoj razini.

Kontinuiranim usvajanjem programa (II. Nacionalni program od 1996. do 2000. [52], III. Nacionalni program od 2001. do 2005. [53] te IV. Nacionalni program od 2006. do 2010. [54]), uz značajna poboljšanja u odnosu na prethodno izdanje u odnosu na koje su inkorporirane gotovo sve preporuke za unapređenje sigurnosti prometa iz razvijenih zemalja) aktualni, V. Nacionalni program sigurnosti cestovnog prometa Republike Hrvatske [55], za razdoblje od 2011. do 2020., utemeljen je na odredbama i smjernicama Moskovske deklaracije iz 2009. godine, Deklaracije Ujedinjenih naroda 62/244 iz ožujka 2010. godine i 4. akcijskoga programa Europske komisije. Nositelj je programa, kao i kod prijašnjih, Ministarstvo unutarnjih poslova. Prema navedenomu

[10] Nacionalni programi sigurnosti cestovnoga prometa Republike Hrvatske predstavljaju nacionalni strateški dokument unutar kojega su naznačeni svi kvantitativni ciljevi i smjernice za ostvarenje planirane razine sigurnosti sudionika u prometu. Trenutni, V. Nacionalni program financiraju tri izvora i to: proračunska sredstva, dio sredstava prikupljen provođenjem tehničkih pregleda vozila i financijska sredstva osiguravajućih društava u visini određenoga postotka uplaćenih obveznih osiguranja vozila.

Programu, na kraju desetogodišnjega razdoblja (u skladu sa zajedničkim ciljevima prihvaćenim na razini EU-a) zadan je cilj o smanjenju broja poginulih u prometnim nesrećama za 50%, odnosno 213 poginulih osoba do 2020. godine.

Promatrajući uspješnost pojedinih nacionalnih programa sigurnosti cestovnoga prometa, V. Nacionalni program možemo prokomentirati kroz Grafikon 2.1., odnosno komparativnom analizom stvarnoga te očekivanoga broja poginulih osoba u CPN-u. Tako možemo konstatirati kako je na državnoj razini evidentno smanjenje broja poginulih osoba kroz znatan period promatranoga vremenskog razdoblja. Komparacijom očekivane i stvarne stope smrtnosti u razdoblju od 2011. do 2013. godine vidljivo je da se stopa nalazi ispod zadanoga praga, što potvrđuje kako su aktualna zakonska legislativa o sigurnosti u prometu i preventivno-represivne policijske aktivnosti u smanjenu broja CPN-a polučile određene pozitivne rezultate.

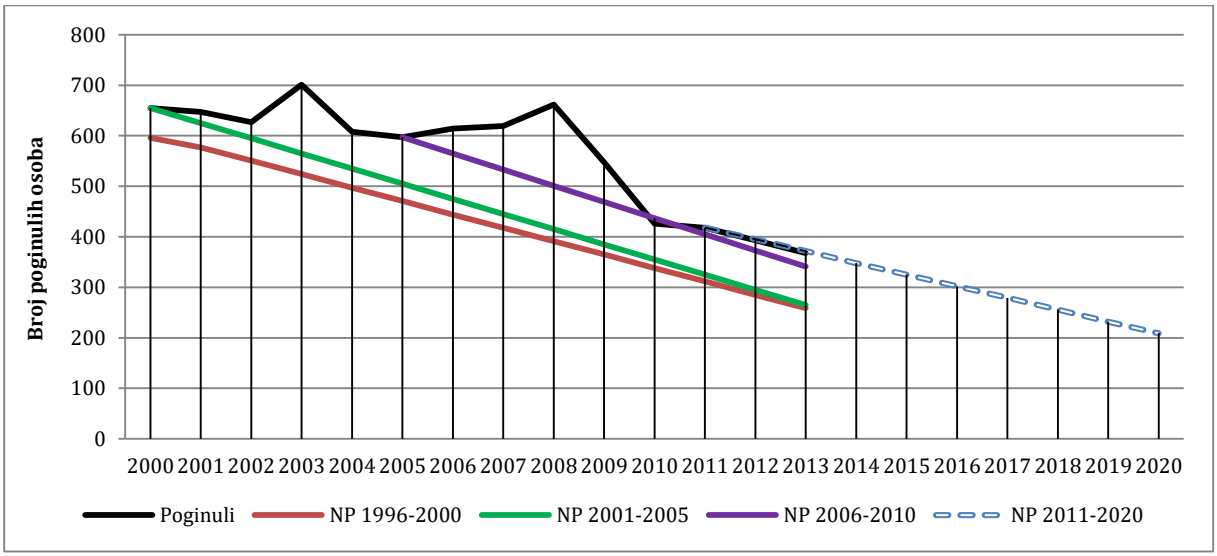

Grafikon 2.1. Pregled odnosa smrtno stradalih sudionika u CPN-u i ciljeva iz Nacionalnih programa sigurnosti cestovnoga prometa Republike Hrvatske za razdoblje 2000. – 2020.

Izvor: Nacionalni programi sigurnosti cestovnog prometa Republike Hrvatske *(od I. do V.), Vlada Republike Hrvatske i* Bilteni o sigurnosti cestovnog prometa *(od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, dopuna i obrada autora.*

Ujedno, za postizanje djelotvornosti i sigurnosti cestovnoga prometnog sustava RH, kao podsustava širega, paneuropskog prometnog sustava, u sklopu navedenoga Programa možemo izdvojiti ukupno pet prioriteta:

- unapređenje prometne kulture sudionika u prometu,
- zaštita najranjivijih skupina sudionika u prometu (pješaci, biciklisti, motociklisti i djeca),
- smanjenje rizika od CPN-a kod mladih vozača,

- unapređenje postojeće zakonske legislative te usklađenje propisa s odgovarajućim međunarodnim standardima,[11]
- **unapređenje metoda prikupljanja i obrade statističkih podataka i informacija o CPN-u kako bi bile kompatibilne na međunarodnoj razini**.

Kako bi se ostvarili zadani prioriteti toga strateškog programa, sustavno se provode, ovisno o financijskim sredstvima, različiti istraživački programi, prvenstveno znanstveno usmjereni u istraživanja kojima su obuhvaćeni sudionici u prometu, tehnologija cestovnih vozila te dizajn infrastrukture. Iako se određeni projekti provode individualno, u većini slučajeva obuhvaćaju interdisciplinarni pristup kakvim su obuhvaćena sva tri (vidi str. 20) prethodno navedena područja djelovanja.

Važno je napomenuti kako se predmetne aktivnosti i istraživanja provode isključivo na nacionalnoj razini i u skladu s organizacijom i provođenjem u MUP-u, dok spomenuti ciljevi i prioriteti nisu ni u kojem dijelu obligatorni regionalnim i gradskim zajednicama, što dovodi u pitanje vjerodostojnost i efikasnost u provođenju predmetnoga nacionalnog strateškog dokumenta. Ujedno, unutar navedenih nacionalnih programa sigurnosti cestovnih prometa možemo konstatirati kako oni ne definiraju zasebno ruralna i urbana područja te u skladu s time pripadajuće statističke analize i podatci nisu dostupni.

Nacionalni program za sigurnost cestovnoga prometa 2011. – 2020. dobra je platforma za rad na sigurnosti cestovnoga prometa. Rezultati i postignuća koje je Republika Hrvatska ostvarila u promatranom periodu znatni su, ali ne i dostatni. Europsko okruženje ima znatno bolje rezultate u području sigurnosti cestovnoga prometa. Stoga bi trebalo implementirati europske smjernice i iskustva te osim nacionalne strategije za veća gradska područja izraditi zasebne programe aktivnosti na povećanju razine sigurnosti prometa (prvenstveno se to odnosi na gradove Zagreb, Split, Rijeka, Osijek i Zadar). Ujedno, unutar postojećega programa nužno je definirati krajnji cilj smanjenja broja nesreća na državnoj razini (Vizija O)[12] te postojeće zakonske propise koji se

[11] Prihvaćanja relevantnih rezolucija, instrumenata i niza priručnika Ujedinjenih naroda o sigurnosti prometa na cestama.

[12] Švedski koncept, predstavljen 1995. godine, nakon usvajanja novoga zakona o sigurnosti cestovnoga prometa. Unutar njega su usvojeni dugoročni ciljevi sigurnosti prometa, pri čemu bi se do 2020. godine broj smrtno stradalih ili ozlijeđenih sudionika u prometu trebao svesti na nulu. Danas je uspješno implementiran u mnogobrojim državama kao što su Švedska, Danska, Norveška, Švicarska i dr. Slični koncepti kreirani su i u drugim državama – Nizozemska je usvojila *Sustainable road safety* 1991. godine, dok je Engleska usvojila *Tomorrow's roads safety* u 2000. godini.

odnose na sigurnost cestovnoga prometa uskladiti između državne i lokalne razine, a što prvenstveno pretpostavlja sustavno unapređenje svih elemenata zakonodavstva.

Analiza organizacijske strukture sigurnosti cestovnoga prometa u Gradu Zagrebu

Na temelju smjernica i preporuka Nacionalnoga programa sigurnosti cestovnoga prometa Republike Hrvatske te programa „Policija u zajednici", Gradska je uprava tijekom 2002. godine usvojila *Zaključak o osnivanju Savjeta za sigurnost prometa na cestama u Gradu Zagrebu* (*SGGZ 4/02*). Stručni, administrativni i tehnički poslovi dodijeljeni su Gradskomu uredu za prostorno uređenje, izgradnju grada, graditeljstvo, komunalne poslove i promet, a glavne su zadaće i aktivnosti Savjeta sljedeće:

- praćenje, promicanje i usklađenje prometno-preventivnih aktivnosti u pogledu sigurnosti u prometu na cestama na području Grada Zagreba,
- provođenje i organiziranje edukacija djece, mladeži i roditelja u predškolskim ustanovama te osnovnim i srednjim školama uz primjenu suvremenih pomagala i uz suradnju prometne policije,
- upozoravanje na nedostatke prometne sigurnosti i uvjete reguliranja prometa kroz praćenje stanja cestovne infrastrukture te prometne opreme i signalizacije,
- predlaganje projekata, studija, elaborata, kampanja, standarda, mjera i akcija iz područja sigurnosti prometa,
- poticanje ostalih aktivnosti od značaja za sigurnost prometa na cestama.

Iako je ideja o osnivanju Savjeta dobro osmišljena i koncipirana, on, nažalost, nikada nije započeo svoje javno djelovanje niti je imao adekvatnu financijsku potporu. Izvješće o svome radu Savjet je trebao dostavljati jedanput godišnje predstavnicima Grada Zagreba, a na nacionalnoj razini predviđena je bila i suradnja te podjela odgovornosti sa stručnim institucijama iz toga područja, posebice s Hrvatskim savjetom za sigurnost cestovnoga prometa.

U skladu s time, na nivou grada Zagreba gradonačelnik je 2009. godine osnovao *Vijeće za prevenciju Grada Zagreba*,[13] sa svrhom koordinacije aktivnosti svih društvenih subjekata na postizanju što većega stupnja sigurnosti, zaštite ljudi i imovine te kvalitete življenja na području

[13] Na temelju članka 56. točke 9. Statuta Grada Zagreba (*Službeni glasnik*, 19/99, 19/01, 20/01 – pročišćeni tekst, 10/04, 18/06, 7/09 i 16/09, 25/09, 10/10, 4/13 i 24/13).

grada Zagreba. Od njegova osnutka uslijedilo je nekoliko promjena u pogledu kadrovske strukture, tako da danas Vijeće u stalnom zasjedanju ima 21 člana, pri čemu je predsjednik Vijeća gradonačelnik grada Zagreba, a njegov zamjenik načelnik Policijske uprave zagrebačke. Od ostalih članova prisutni su predstavnici gradske uprave, gradske skupštine, mjesne samouprave, prometne policije, pravosudna tijela, zdravstvene i civilne udruge te savezi.[14]

2014. godine u Vijeću za prevenciju Grada Zagreba, a na prijedlog Policijske uprave zagrebačke ustrojena je *Radna skupina za sigurnost cestovnog prometa u Gradu Zagrebu*, s glavnim ciljem sveukupnoga poboljšanja stanja sigurnosti u cestovnom prometu, što je preduvjet za kvalitetno uređen institucionalni okvir. Osim MUP-a i PUZ-a članove radne skupine čine predstavnici Sektora za promet te Sektora komunalnog i prometnog redarstva. Radna skupina osnovana je u skladu sa smjernicama aktualnoga Nacionalnog programa sigurnosti cestovnog prometa RH te predstavlja ključno koordinativno tijelo za sigurnost cestovnoga prometa na lokalnoj razini. Osnovne su odrednice njezina rada sljedeće:

- sustavno praćenje i analiza stanja sigurnosti u prometu na cestama Grada Zagreba (povećanje razine sigurnosti sudionika u prometu u zonama škola, dječjih vrtića, semaforiziranih raskrižja i pješačkih prijelaza i sl.),
- predlaganje mjera za poboljšanje sigurnosti u prometu na cestama te predlaganje mjera Vijeću za prevenciju Grada Zagreba. Prijedlozi mjera definirani su radovima vezanim uz izgradnju pješačkih nogostupa, biciklističkih staza i traka, autobusnih stajališta, raskrižja s kružnim tokom i sl. Predmetni se radovi izvode uz koordinaciju s gradskim četvrtima i financiraju putem Plana malih komunalnih akcija te koordinacijom sa Sektorom za ceste. Daljnje su mjere predlaganje radova vezanih uz postavljanje zaštitnih ograda za pješake, semaforizacije raskrižja, izmjene postojeće prometne signalizacije, promjene regulacije prometnica, dionica prometnica i/ili raskrižja i sl.,
- predlaganje mjera usmjereno što učinkovitijemu djelovanju policije i prometnoga redarstva grada Zagreba,
- iniciranje mjera u vezi s nabavom tehničkih uređaja, naprava i ostale infrastrukturne podrške (opremanje prometne policije i drugih tijela nadležnih za poslove sigurnosti cestovnoga prometa),
- suradnja s udrugama građana (biciklističke, auto- i motoudruge, udruga „Roda“ i sl.).

[14] Budući planovi predviđaju da se on aktualizira u okviru djelovanja multidisciplinarnoga radnog tima iz redova znanstvenih, stručnih i javnih djelatnika koji mogu pridonijeti promicanju ciljanih prometno-preventivnih aktivnosti i razvijanju prometne kulture sudionika u prometu Grada Zagreba.

Dosadašnja suradnja Gradske uprave s ostalim predstavnicima iz prethodno spomenute radne skupine može se ocijeniti vrlo kvalitetnom. U dosadašnjem radu provedeno je niz akcija u dijelu tehničkoga reguliranja cestovnoga prometa na širem području grada, pri čemu su svi prijedlozi Policijske uprave zagrebačke uredno realizirani. U pojedinim slučajevima bilo je nepoštivanja zadanih vremenskih rokova zbog obveza iz Zakona o javnoj nabavi, što je prolongiralo prvotno zadane rokove izvođenja.
Terenskim su istraživanjima prethodili radni sastanci svih članova radne skupine, posebice iz MUP PUZ-a, a pri obilasku utvrđenih opasnih lokaliteta izvedeno je skiciranje spornih lokacija te njihovo precizno pozicioniranje, fotografiranje i videosnimanje (stvorena je znatna foto- i videodokumentacija), analizirani su osnovni uzroci nastanka CPN-a i usuglašen je prijedlog mjera za unapređenje stanja sigurnosti prometa.

Uz prethodno navedeno, tijelo bi u svojem daljnjem radu također trebalo biti zaduženo i za izradu Programa rada i preventivnih aktivnosti na povećanju razine sigurnosti prometa na području Grada Zagreba, unutar kojega bi bile definirane sve aktivnosti (organizacijske, legislativne, tehničke, financijske i dr.) Gradske uprave te modusi i nositelji njihova provođenja.

U skladu s planiranim aktivnostima, distribuciju sredstava potrebno je sprovoditi po načelu preciznih zaduženja nositelja pojedinih aktivnosti te ih planirati za svako plansko razdoblje, gdje bi za rad pojedinih tijela unutar Gradske uprave trebalo osigurati adekvatna proračunska sredstva iz gradskoga proračuna.

Osim tijela Gradske uprave, u organizaciji rada na provedbi Programa trebalo bi biti uspostavljeno kvalitetno interaktivno i koordinirano djelovanje, odnosno suradnja s tijelima koja su izvan toga sustava:

- MUP – PUZ – Služba za sigurnost cestovnog prometa,
- MUP – Policijska uprava zagrebačka – I. i II. PPP te PP Sesvete,
- MMPI – Inspekcije cestovnog prometa i cesta,
- Zagrebački holding d. o. o. – Podružnica Zagrebparking,
- Zagrebački holding d. o. o. – Podružnica Zagrebački električni tramvaj (ZET),
- Zagrebački holding d. o. o. – Podružnica Zagrebačke ceste (ZC),
- Hrvatske željeznice – Infrastruktura,
- Hrvatske željeznice – Putnički promet,
- Sveučilište u Zagrebu – Fakultet prometnih znanosti,
- Hrvatski autoklub i tvrtke ovlaštene za izvođenje tehničkih pregleda vozila,
- zdravstvene i obrazovne ustanove (dječji vrtići, škole i autoškole),

- udruženja cestovnih prijevoznika zagrebačkog područja,
- nevladine udruge i udruženja građana (Udruga obitelji osoba stradalih u prometu i dr.),
- lokalni i nacionalni tiskovni i elektronički mediji (za izvještavanje javnosti o akcijama preventivno-propagandnoga i edukativnoga karaktera koje imaju za cilj podizanje prometne kulture i veću sigurnost u prometu).

Tako strukturiranom mrežom suradnika ostvaruje se kvalitetna stručna, medijska, politička, administrativna i tehnička podrška, kao i podrška građana i šire javnosti.

Uz izradu samoga Programa, svako uključeno tijelo i institucija morali bi pripremiti i odgovarajući ***Izvedbeni plan*** svojih aktivnosti vezan za izvođenje radova, mjera ili aktivnosti na provedbi predmetnoga Programa.

U legislativnom dijelu nositelji bi aktivnosti trebali na razini države i grada dosljedno primjenjivati postojeće zakonske propise koji reguliraju područje sigurnosti prometa, kao i predlagati izmjenu propisa ako se za to ukaže potreba.

To se prvenstveno odnosi na nadležnosti MUP PUZ-a u dijelu pojačanoga nadzora i sankcioniranja prekršitelja, prvenstveno na kontrolu brzine kretanja motornih vozila, vožnje pod utjecajem alkohola te poštivanja propisa u dijelu upravljanja mopedima i motociklima bez vozačke dozvole i zaštitnih kaciga (orijentacija na zaštitu mlađih sudionika u prometu).

Od ostalih aktivnosti iz navedenoga područja nužno je naglasiti ulogu Gradskoga ureda za prostorno uređenje, izgradnju grada, graditeljstvo, komunalne poslove i promet prilikom predlaganja izmjene i/ili dopune pojedinih odredbi Zakona o sigurnosti prometa na cestama, kao i praćenje cjelokupnoga postupka prilikom izmjene predmetnoga Zakona s tijelima Ministarstva unutarnjih poslova nadležnima za navedeno područje.

Zbog ispreplitanja državnih i gradskih propisa nužna je koordinacija i kooperacija tijela gradskih i državnih službi kako bi se uskladili propisi i odredile potrebne izmjene zakonskih propisa. Također je potrebno to provesti na razini pravnih službi pojedinih radnih tijela, a uz prethodno mišljenje pojedinih nositelja aktivnosti.

Jedno je od rješenja i donošenje odluka i programa obvezne edukacije o sigurnosti u prometu za sve odgojno-obrazovne ustanove te obrazovanje kadrova i osiguranje financijskih sredstava za rad u tom području, posebice u području formiranja što većega broja prometnih jedinica mladeži i školskih patrola te poboljšanja rada autoškola.

Također, jedna od aktivnosti na prometno-tehničkom području radne skupine trebala bi biti i pojačana kontrola stanja postojeće prometne signalizacije i opreme, što bi kasnije značilo i izradu

prijedloga izmjena i obnove signalizacije te eventualnih postavljanja dodatne opreme na lokacijama koje predstavljaju sigurnosni rizik.

Kako bi se navedene radnje uspješno provele, jedna od prvih zadaća radnih tijela programa za povećanje razine sigurnosti prometa trebala bi biti izrada izvješća o stanju postojeće prometne signalizacije i opreme u Gradu Zagrebu, izvedena s aspekta zadovoljavanja zakonskih propisa te zahtjeva sigurnosti prometa. Na temelju izvješća o kontroli nužno je potom, u što je moguće kraćem vremenskom roku, pristupiti izmjeni i obnovi prometne signalizacije i opreme u skladu s prioritetima određenima u izvješću.

Postavljanje eventualne dodatne signalizacije i opreme trebalo bi izvoditi na temelju dosadašnjih planova i zapažanja gradskih službi nadležnih za sigurnost prometa te na temelju predmetnoga izvješća o kontroli prometne signalizacije.

Neovisno o rezultatima kontrole prometne opreme i signalizacije, nadležne gradske službe moraju izraditi prijedlog jedinstvenoga dodatnog označavanja zona osnovnih škola.

Krajnji cilj predloženih mjera i aktivnosti trebao bi biti podizanje svijesti građana o sigurnosti u cestovnom prometu te o jednakosti svih sudionika u prometu, posebice onih najugroženijih.

Također je nužno učiniti rad tijela zaduženoga za program sigurnosti cestovnoga prometa transparentnim, kako u svojim programima i planovima tako i u financijskom smislu.

2.4. Zaključna razmatranja

Unutar krovnoga zakona o sigurnosti cestovnoga prometa nužno je uspostaviti legislativne i institucionalne okvire za provedbu nužnih mjera i aktivnosti usmjerenih na sigurnost cestovnoga prometa. To se prije svega odnosi na donošenje zakonskih odredaba o potrebi za izradom **Nacionalne strategije sigurnosti prometa na cestama** te na to da je usvoje Sabor ili Vlada RH, kao i odredbe o potrebi za formiranjem nacionalnoga centralnog koordinativnog tijela za sigurnost prometa te Agencije za sigurnost prometa na cestama Republike Hrvatske.

Uspješno ostvarenje zadanih ciljeva unutar programa sigurnosti cestovnoga prometa RH trebalo bi biti adekvatna platforma i smjernica za implementaciju održive *Nacionalne strategije sigurnosti cestovnog prometa u RH*, pri čemu bi njezin sastavni dio trebao biti upravo prethodno spomenuti program zajedno s njegovim izvedbenim planovima.

Nadalje, kako bi se smisleno upravljalo stanjem sigurnosti u skladu s UN-ovom rezolucijom, potrebno je uspostavljati ambiciozne vremenski ograničene kvantificirane ciljeve. Predložena

strategija mora biti u potpunosti usklađena i s općim ciljevima Strategije prometnog razvoja Republike Hrvatske 2014. – 2030., a njezinom bi se realizacijom pridonijelo sljedećim ciljevima:

- osiguranju sigurnosti i zaštite,
- osiguranju učinkovitosti prometnoga sustava.

Osim na legislativu, veliku pozornost treba usmjeriti i na najranjivije skupine sudionika u prometu (pješaci, biciklisti, motociklisti i dr.) – u predloženom strateškom dokumentu za njih je nužno ponuditi zasebna, specifična prometna rješenja i mjere u cilju njihove zaštite.

U skladu s prijedlozima izmjena i dopuna Zakona o sigurnosti prometa na cestama potrebno je stoga na nacionalnom nivou pripremiti i usuglasiti strateške dokumente (strategije i akcijske planove s jasno razrađenim pokazateljima uspješnosti provedbe) sigurnosti cestovnoga prometa s kvalitativno i kvantitativno definiranim ciljevima, vizijom, smjernicama, ključnim područjima djelovanja te vremenskim rokovima predloženim prioritetnim kratkoročnim i dugoročnim mjerama i aktivnostima, a koji se zatim razrađuju na regionalnim i lokalnim razinama.

Kao i za većinu strateških dokumenata (politike, programi, strategije i izvršni planovi), razdoblje koje bi trebalo obuhvatiti trebalo bi biti minimalno 5 godina, s kontinuiranim revizijama i eventualnim dopunama pojedinih aktivnosti.

Osim na nacionalnoj razini, unutar Zakona potrebno je navesti da je dokumente istovjetne Strategiji i planovima sigurnosti prometa obvezno izraditi i na regionalnoj odnosno lokalnoj razini (županije i značajniji gradovi kao što su npr. Zagreb, Rijeka, Split, Osijek, Dubrovnik i dr.), a u skladu sa smjernicama i preporukama pripadajućega krovnog dokumenta na nacionalnoj razini te aktualnim dokumentima Europske unije, Ujedinjenih naroda, Svjetske zdravstvene organizacije (WHO), Europskoga vijeća za sigurnost cestovnoga prometa (ETSC), Međunarodne organizacije za sigurnost prometa (PRI) i drugih relevantnih institucija.

Prilikom usvajanja strategija sigurnosti prometa na državnoj, regionalnoj i lokalnoj razini nije dostatno samo njihovo deklarativno prihvaćanje, već je nužna i njihova dosljedna primjena i kontinuirana evaluacija predloženih odnosno implementiranih protumjera usmjerenih k povećanju razine sigurnosti prometa.

U skladu s time, u Zakon je važno uvrstiti i zasebnu odredbu vezanu uz praćenje i evaluaciju predloženih i implementiranih mjera i aktivnosti za povećanje razine sigurnosti prometa, poželjno u formi periodičnih godišnjih pisanih izvještaja, s obzirom na to da je to jedan od najkvalitetnijih mehanizama kontrole rada svih tijela uključenih u provedbu predložene strategije.

Vezano za jačanje institucionalnih okvira, odnosno formiranje i organizaciju namjenskih koordinativnih radnih tijela na upravljačkoj razini, Nacionalni je program sigurnosti prometa stvorio pretpostavke za osnivanja vijeća za prevenciju općina, gradova i županija, ali iako su u nekim sredinama ta tijela i implementirana, ona nikada nisu preuzela vodeću koordinativnu ulogu s ostalim relevantnim subjektima, niti su pratila i objavljivala relevantne podatke o postojećem stanju sigurnosti prometa i dr.

Razlog za navedeno jest činjenica što zakonski nisu konkretizirana prava i obveze tijela nadležnih za sigurnost prometa na lokalnoj i regionalnoj razini, kao što su: sustav praćenja i izvještavanja u lokalnoj zajednici (najmanje dva puta godišnje pripremiti izvješće o stanju sigurnosti prometa unutar kojega bi se naznačilo postojeće stanje, ali i aktualni problemi u svezi s realizacijom usvojenih strateških dokumenata), definiranje materijalnih preduvjeta za njihov kontinuirani rad (izvori financiranja), nužnosti za vođenje pripadajućih baza podataka, izrada prometno-sigurnosnih analiza, definiranje zakonskih strateških okvira i pripadajućih akcijskih planova (u početnoj fazi svake godine, a kasnije svake dvije) i sl.

No, prije konstituiranja tijela na nižim razinama nužno ga je konstituirati na državnoj, pri čemu ne bi smjelo biti uređeno kao dosada, kao radna skupina pod ingerencijom Ministarstva unutarnjih poslova, već kao zasebno i neovisno tijelo zaduženo za sigurnost prometa, koje je imenovala Vlada RH. U novo, interdisciplinarno radno tijelo poželjno bi bilo imenovati ministre nadležnih ministarstava kao članove radnoga tijela kako bi mu se osigurala politička podrška.

Za potrebe formiranja predložene Agencije u Zakonu o sigurnosti prometa na cestama potrebno je zakonski definirati kako su sva nacionalna tijela i organizacije čija izvorna ili povjerena nadležnost obuhvaća područje upravljanja sigurnošću prometa dužna Agenciji dostaviti kompletnu retrospektivnu zbirnu dokumentaciju iz predmetne tematike te joj u budućnosti kontinuirano prosljeđivati nove ažurirane podatke, i to u unificiranoj formi. Ujedno, financijska se sredstva moraju koristiti namjenski na svim razinama upravljanja, i to u skladu s usvojenim strateškim dokumentima sigurnosti prometa.

U skladu s time, za potrebe financiranja većega broja preventivno-represivnih mjera i aktivnosti u području sigurnosti prometa, posebice kod jedinica lokalne i područne (regionalne) samouprave, potrebno je dopuniti čl. 292. Zakona, prema kojemu se za tu namjenu, prema odluci Vlade Republike Hrvatske, trenutno raspolaže samo prihodima od naplaćenih novčanih kazni alociranih prema državnomu proračunu.

Također, ukupno učešće, odnosno visina sredstava za pojedinu aktivnost što ju predlažu nadležna tijela ili savjeti mora unaprijed biti jasno definirana (npr. sredstva za održavanje cestovne infrastrukture te otklanjanje crnih točaka na cestovnoj mreži) u svrhu izrade kvalitetnih

pripremnih aktivnosti oko definiranja godišnjih planova i programa rada te za projekciju trogodišnjega razdoblja.

U skladu s navedenim, prijedlog je da izvore sredstava za takve aktivnosti, u okviru vlastitih prava i obveza, moraju financijski osigurati lokalne administracije, i to iz djelomičnoga iznosa (maksimalno 30%) koji ostvaruju naplaćivanjem novčanih kazni unutar zakonskih okvira Zakona o sigurnosti cestovnog prometa. U tom je dijelu bitno da se jasno zakonski regulira kako se ta sredstva ne mogu koristiti u druge svrhe osim za povećanje razine sigurnosti cestovnoga prometa (unapređenje cestovne infrastrukture, financiranje preventivnih i represivnih mjera, edukacije građana, javnih kampanja, provođenja znanstvenoistraživačkih aktivnosti i dr.). Također, trebalo bi razmotriti i dodatne izvore financiranja kao što su određene naknade iz poreza, kupnje novih automobila, uvođenje zakonskih promjena u dijelu koji se odnosni na obvezno osiguranje vozila i dr.

Formiranje nacionalne agencije za sigurnost cestovnoga prometa

Agencija bi na temelju javne vlasti, kao djelatnosti od interesa za Republiku Hrvatsku, trebala obavljati sljedeće razvojne, stručne i regulatorne poslove iz područja sigurnosti prometa: analizu i unapređenje sustava sigurnosti cestovnoga prometa, edukativno-stručno usavršavanje vozača i drugih sudionika u prometu, koordinaciju aktivnosti među svim relevantnim subjektima, pripremanje sigurnosne preporuke te pružanje stručne podrške Vladi RH i nadležnim tijelima, upravljanje objedinjenom nacionalnom bazom podataka o CPN-u, dijeljenje podataka iz nacionalne baze podataka s drugim istražnim tijelima uz uvjet očuvanja tajnosti podataka, formuliranje vizije, ciljeva, akcijskih planova i strategije iz područja sigurnosti cestovnoga prometa, kompletiranje i analizu statističkih izvještaja o CPN-u, sudjelovanje na međunarodnim skupovima i seminarima radi usavršavanja osoblja koje se bavi provođenjem istraživanja, promociju teme sigurnosti prometa kroz organizaciju stručnih skupova, provođenje preventivne aktivnosti te medijskih kampanja, osiguranje financijske podrške pri izradi razvojnih studija i istraživanja, predlaganje i evaluaciju upravljačkih mjera implementiranih na terenu, pomaganje lokalnim i regionalnim tijelima u uspostavi organizacijske strukture upravljanja sigurnošću cestovnoga prometa te druge poslove vezane uz sigurnost prometa. Također, nameće se bliska suradnja sa znanstvenim sektorom te vanjskim stručnjacima osposobljenima za obavljanje pojedinih poslova iz nadležnosti toga tijela.

Prilikom uspostave takve vodeće agencije zadužene za sigurnost cestovnoga prometa (poželjno je da ju uspostavi Vlada Republike Hrvatske), nužno je da bude organizirana kao samostalna

statutarna javna ustanova u obavljanju poslova iz svojega djelokruga, odnosno da bude funkcionalno i organizacijski autonomna u odnosu na sva tijela nadležna za cestovni promet, kao i sve pravne i fizičke osoba. Sredstva za rad većim bi dijelom trebala biti osigurana kroz državni proračun Republike Hrvatske,[15] dok bi same rezultate rada trebala dostavljati Vladi Republike Hrvatske, i to periodički izradom odgovarajućih izvještaja (Godišnji izvještaj o radu i poslovanju).

Agencija mora biti osnovana kao pravna osoba s javnim ovlastima na temelju pripadajućega zakona ili odluke o osnivanju kako bi njezin status i nadležnost (uređenje djelatnosti, način upravljanja, sredstva za osnivanje i rad Agencije i druga pitanja važna za njezin rad) bili pravno regulirani u skladu s trenutno važećim nacionalnim i inozemnim zakonskim aktima i propisima, posebice onima vezanim uz usklađenje nacionalnoga zakonodavstva s pravnom stečevinom Europske unije (direktivama, normama i preporukama) te pravnim aktima Vijeća Europe.

Osim toga, poželjno je da uz predloženu Agenciju pri Vladi RH bude uspostavljeno i odgovarajuće koordinativno radno tijelo koje bi na temelju stručnih podloga dobivenih od Agencije moglo kvalitetnije strateški planirati upravljanje (pokretanje mjera i aktivnosti te implementaciju inicijativa) u području sigurnosti prometa.

Formiranjem zasebnoga tijela – Agencije koja bi bila zadužena za sigurnost prometnoga sustava u RH, ostvarili bi se preduvjeti za jasnu hijerarhijsku podjelu zaduženja i odgovornosti među uključenim subjektima, sa snažnim naglaskom na partnerskom odnosu između nacionalne i lokalne (regionalne) uprave.

Samo na taj način moguće je ostvariti zadovoljavajuću razinu reprezentativnosti, nedvosmislenoga vodstva i točno definirane podjele odgovornosti među uključenim subjektima, čime se direktno utječe na zadovoljavajuću podjelu osiguranih resursa, kako onih financijskih i infrastrukturnih tako i onih organizacijskih.

Dostupnost podataka iznimnno je važan problem današnjega sustava evidentiranja podataka o CPN-u jer su trenutno mnogobrojni subjekti zainteresirani za pojedine grupe podataka, a posebice za podatke u vezi s CPN-om, lokacijama crnih točaka na određenom području i sl.

Kako bi stoga u što kraćem roku ispunilo svoju osnovnu ulogu, predloženomu je tijelu, osim potrebne kvalitetne kadrovske ekipiranosti, u početnoj fazi formiranja nužno iz državnih baza podataka podastrijeti kompletnu retrospektivnu zbirnu statističku podlogu, predmete i ostale materijale vezane uz nadležnost dosadašnjih mjerodavnih aktera – Državnoga zavoda za statistiku (DZS), Ministarstva unutarnjih poslova te Ministarstva pomorstva, prometa i infrastrukture. Osim

[15] Agencija može stjecati sredstva i iz drugih izvora (donacije, fondovi i sl.) u skladu s propisima, pod uvjetom da se time ne ugrožava njezina neovisnost u radu.

navedenih subjekata, u kasnijoj fazi Agencija mora formirati i sintetizirati sveobuhvatnu integriranu bazu podataka o ključnim obilježjima nacionalnoga prometnog sustava, što uključuje integraciju baza podataka osiguravajućih kuća, upravitelja cesta, zdravstvenih ustanova, sudstva, ali i predstavnika lokalnih i regionalnih uprava s prethodno uspostavljenom kompatibilnošću s bazama podataka na nacionalnoj i međunarodnoj razini.

Bitni subjekti u procesu uspostave i dogradnje informacijskoga sustava s integriranim podatcima o sigurnosti prometa jesu tijela lokalne i regionalne uprave, s obzirom na to da jedini posjeduju oskudne i teško dostupne relevantne podatke o obilježjima prometnoga sustava. Na temelju obavljenih temeljnih prometnih istraživanja, lokalne su uprave u mogućnosti definirati intenzitet i strukture prometnih tokova, provesti istraživanja o stavovima i ponašanjima sudionika u prometu te o drugim čimbenicima sigurnosti prometa.

Tim pristupom napokon će se pojednostaviti složena procedura dobivanja odgovarajućih kvalitetnih podataka o sigurnosti prometa, pri čemu će zainteresiranim subjektima, u okviru njihovih nadležnosti, biti omogućena jednostavnija distribucija relevantnih podataka nužnih za kvalitetno stručno praćenje i analizu aktualnoga stanja sigurnosti prometa na cestovnoj mreži.

Formiranje središnjega koordinativnog tijela za sigurnost cestovnoga prometa Grada Zagreba

Analizom organizacijske strukture sigurnosti cestovnog prometa u Gradu Zagrebu, u komparaciji sa drugim većim gradovima u Republici Hrvatskoj, , možemo zaključiti kako je u većini tijela jedinica lokalne i područne (regionalne) samouprave RH sustav upravljanja sigurnošću prometa uređen bez jasno razrađenih strategija i ciljanih akcijskih planova. Nadalje, znanstvena istraživanja i aktivnosti vezane uz sigurnost cestovnoga prometnog sustava prvenstveno se provode na razini države, pri čemu jedinice lokalne uprave i područne regionalne samouprave u pravilu na pridaju predmetnoj tematici značaj kakav ona istinski zaslužuje.

Razlozi su za navedeno mnogobrojni. Osim nedostatka financijskih sredstava pojedinih lokalnih administracija, važnu ulogu ima i neusklađen, odnosno nekvalitetno i neadekvatno definiran sustav upravljanja sigurnošću prometa između nacionalne i lokalne razine.

Kako bi detektirani problemi i ograničenja u što kraćem roku bili otklonjeni, nužno je implementirati optimalan model lokalnoga upravljanja sigurnošću cestovnoga prometa, temeljen upravo na jačanju veza i aktivnosti između organizacija na lokalnom i nacionalnom nivou, čime se

ostvaruju preduvjeti za ubrzanje dinamike realizacije zadanih programa i planova sigurnosti prometa [56].

U skladu s time, osim formiranja središnjega nacionalnog koordinativnog tijela koje bi se isključivo bavilo tematikom prometne sigurnosti te Agencije za sigurnost cestovnog prometa kao svojevrsne stručne podrške njegovu radu, na lokalnoj je razini potrebno stabilno i neovisno lokalno koordinativno tijelo za sigurnost cestovnoga prometa, institucionalno organizirano kao savjet ili tematska radna skupina, prioritetno obuhvaćajući područja županija i gradskih naselja unutar kojih su prisutna veća urbana koncentracija stanovništva, cestovne prometne mreže te prometni entiteti. U slučaju grada Zagreba njihovo formiranje, osim na razini grada, obuhvaća i tijela mjesne samouprave, odnosno većina gradskih četvrti ima osnovano i imenovano Vijeće za prevenciju, uz naznačeno iniciranje osnivanja vijeća za prevenciju mjesnih odbora.

Osnovna zadaća tih tijela trebala bi biti da upravljačko-organizacijski i materijalno-financijski strukturalno povežu tijela lokalne samouprave s ostalim subjektima sigurnosti prometa te osiguraju njihov optimalan rad. Na taj način lokalne uprave i tijela postaju aktivnim sudionicima rješavanja problema prometne sigurnosti na svojem području, a što je i prepoznatljivo u normativnoj legislativi, stručnoj literaturi i suvremenoj praksi organizacije sigurnosti prometa u urbanim sredinama.

Za potrebe rada takvoga tijela nužno je uspostaviti organizacijsku strukturu (mrežu partnera) sa što većim brojem uglednih pojedinaca i članova zajednice, ustanova i organizacija (predstavnici nacionalne i lokalne prometne policije, predstavnici lokalnih tijela gradske uprave, odnosno nadležnih sektora i službi zaduženih za održavanje i reguliranje cestovnoga prometa, predstavnici mjesne samouprave gradskih četvrti i mjesnih odbora, obrazovne i zdravstvene ustanove, osiguravajuće kuće, znanstvenoistraživačke institucije, upravitelji cestovne infrastrukture, predstavnici medija, nevladinih udruga i dr.), s jasno definiranim zadatcima, prioritetima, dinamikom te pravima i obvezama svakoga od njih, kako bi krajnja koordinacija te provedene kooperativne aktivnosti bile što produktivnije. Pored jačanja institucionalnih okvira iznimno je važno i individualno jačanje imenovanih članova koordinativnoga tijela, za što je potrebna stručna edukacija i stalno usavršavanje u području sigurnosti prometa.

Važan segment u organizaciji i načinu rada odnosi se na potrebu za formiranjem specijaliziranih radnih grupa unutar Vijeća za prevenciju (radna skupina za sigurnost cestovnoga prometa, prometnu kulturu i obrazovanje, cestovnu infrastrukturu, strateško planiranje i dr.). U skladu s time, potrebno je provesti normativno uređenje takvih tijela te usvojiti tipizirane pravilnike o radu, program raspodjele financijskih sredstava namijenjenih sigurnosti prometa i odluku o praćenju stanja sigurnosti cestovnoga prometa.

Tako strukturiranim sustavom sigurnosti cestovnoga prometa na lokalnoj razini znatno se utječe na poboljšanje razine sustava sigurnosti, s obzirom na to da se na jasno definirane problemske situacije odgovara ciljanim preventivnim i represivnim protumjerama uz kontinuirano praćenje i evoluiranje njihovih efekata primjene.

Takav pristup u potpunosti je u skladu s najboljom praksom najrazvijenijih zemalja, a posebno u skladu s iskustvima Europske unije, pri čemu su osigurani svi relevantni preduvjeti za strateško upravljanje sigurnošću cestovnoga prometa, a tijela lokalnih i regionalnih uprava i samouprava u potpunosti su ukomponirana u kvalitetni sustav sigurnosti prometa.

Kako bi uspješno provodila svoj rad, predložena radna tijela morala bi usvojiti najbolju praksu vezanu uz područje sigurnosti prometa, kao i koristiti suvremene alate – analizu rizičnih lokacija u gradu (tzv. crnih točaka), uvođenje u rad revizora cestovne sigurnosti (predlaganje kvalitetnih građevinsko-tehničkih rješenja), provođenje dubinskih analiza težih oblika CPN-a, represivne prometne politike, agresivne javne kampanje i dr.

Hijerarhija sustava za sigurnost cestovnog prometa

Integralni pristup upravljanju sigurnošću cestovnoga prometa nužan je ako želimo kvalitetno prevenirati mogućnost pojava cestovnih prometnih nesreća te smanjiti broj unesrećenih u urbanim sredinama. Stoga je važan sustavni planerski pristup povezivanja velikoga broja subjekata (institucija – obrazovnih, zdravstvenih i sl.), javnosti, donositelja odluka, lokalnih stručnjaka za sigurnosti cestovnoga prometa, i sl. u kvalitetan holistički tim zadužen za kreiranje mjera i aktivnosti usmjerenih k održivoj prometnoj politici.

Tehnike urbane prometne sigurnosti prvotno zahtijevaju izradu prometno-sigurnosnih analiza za sve sudionike u prometu (posebice one najranjivije), i to na razini pojedinačnih gradskih blokova (kvartova, četvrti) ili cijelih gradova, a u svrhu detektiranja ključnih prometnih problema u urbanim područjima [57]. Potom slijedi formuliranje strateških dokumenata te izrada akcijskih planova i programa unutar kojih su obuhvaćeni radni procesi te setovi koordiniranih mjera i aktivnosti usmjerenih na djelovanje na ciljana problemska područja. Posljednja faza odnosi se na samu implementaciju zadanih radnji, praćenje izvršenja i izrada sigurnosnih procjena u svrhu praćenja napretka prema zadanim ciljevima. U ovom dijelu vrlo je važno uskladiti sigurnosne ciljeve s drugim ciljevima urbane prometne politike, prije svega vodeći računa o namjeni zemljišta, trasiranju linija javnoga gradskog prometa, definiranju cestovnih koridora i sl.

Naposljetku, Vlada Republike Hrvatske, ako joj je stalo do uspješnoga upravljanja sustavom sigurnosti cestovnog prometa, trebala bi ozbiljno razmisliti o formiranju Agencije za sigurnost cestovnog prometa, kao što je to praksa u ostalim zemljama europskoga okruženja koje imaju bolje indikatore stanja sigurnosti u cestovnom prometu [28]. Ministarstvo unutarnjih poslova važan je, ali ne i jedini aktivni sudionik u poboljšanju stanja sigurnosti u cestovnom prometu, odnosno relevantan subjekt nužan za dostizanje usvojenih ciljeva vezanih uz sigurnost cestovnoga prometa. Stoga je potrebno Nacionalni program sigurnosti cestovnoga prometa izmjestiti iz djelokruga MUP-a i formirati agenciju kojoj će jedini zadatak biti proaktivan rad na cestovnoj sigurnosti prometa. Kako bi agencija svoj zadatak ostvarila, potrebno je da, osim s prometnim stručnjacima, surađuje i sa stručnjacima komplementarnih kompetencija (znanstvene, ekonomske, gospodarske, tehničke, matematičke, političke i dr.).

3. ANALIZA ČIMBENIKA CESTOVNIH PROMETNIH NESREĆA

Većina čimbenika koji utječu na sigurnost u prometu identificirani su i evaluirani pregledom literature. Ti su čimbenici obično vezani s karakteristikama prometa (protok vozila, gustoća prometnoga toka, brzina prometnoga toka i zagušenja) i cestovne infrastrukture (geometrija i kvaliteta izvedbe kolničke konstrukcije), vozača (korištenje zaštitnih pojaseva i kaciga, konzumacija alkohola tijekom vožnje, spol i starost vozača i dr.) i drugih sudionika u prometu, vozila te prometne okoline (rasvjeta i vremenski uvjeti).

Također, mnogi su znanstvenici [58,, 59] u svojim objavljenim radovima pokušavali analizirati područje sigurnosti prometa na cestama analizirajući statističke odnose između CPN-a i povezanih čimbenika.

Identifikacija najznačajnijih čimbenika cestovnih prometnih nesreća, posebice onih koje imaju teže posljedice, predstavlja temelj za njihovo kvalitetno i sustavno preveniranje. S obzirom na intenzitet cestovnoga prometa u urbanim sredinama, nužno je istražiti okolnosti (ljudske ili cestovne varijable) koje naviše pridonose nastanku težih tjelesnih ozljeda ili smrtnosti u prometu.

3.1. Sistemska teorija

Sistemska teorija [60], koja se temelji na trima komponentama (čovjek – cesta – vozilo) ujedno je i u korelaciji sa statističkim podatcima baza podataka CPN-a, te najzornije opisuje čimbenike sigurnosti cestovnoga prometa. Komponenta „čovjek“ obuhvaća demografska obilježja sudionika u prometu (dob, spol, obrazovanje, socijalno-ekonomski status), ljudsku percepciju rizika i opće ponašanje ljudi u prometu. Komponenta „cesta“ uključuje prirodne i izgrađene prometne okoline te transportne mreže, dok komponenta vezana za „prijevozna sredstva“ obuhvaća obujam i kvalitetu vozila. Nekontroliran negativan rast svakoga od navedenih čimbenika znatno može utjecati na broj ili težinu pojava CPN-a.

3.1.1. Čovjek kao čimbenik sigurnosti cestovnoga prometa

Čovjek je središnji i ključni akter prometnoga sustava. Nekoliko značajnih studija [61, 62, 63, 64] pokušalo je opisati pojedine čimbenike proizašle iz ponašanja sudionika u prometu koji, prema

službenim statistikama, znatno pridonose pojavi CPN-a, kako na individualnoj razini tako i u kombinaciji s ostalim uzročnicima.

Analizom čimbenika zaslužnih za događanje CPN-a koji su identificirani na temelju istražnih radnji prometne policije u RH (sumirani u *Biltenima o sigurnosti cestovnog prometa*) utvrđeno je da je sličan obrazac identificiran u Sjedinjenim Američkim Državama i u većini drugih država članica EU-a. Ljudski čimbenik, posebice ponašanje sudionika u prometu, predstavlja skupinu čimbenika koji su, prema nekim istraživanjima, zaslužni za pojavu više od 85% svih registriranih CPN-a [65] [66]. Među njima su dva ključna poznata čimbenika, a to su nepropisna i neprilagođena brzina prometovanja i alkoholiziranost pri vožnji, koji zajedno predstavljaju dominantne uzroke prometnih nesreća u cestovnom prometu.

Komponenta *čovjek*, odnosno neprilagođeni ljudski elementi ponašanja u prometu predstavljaju najrizičniju grupaciju čimbenika CPN-a, i to prvenstveno zbog rizičnoga ponašanja vozača (prebrza vožnja, pretjecanje, mimoilaženje, nepoštivanje prvenstva prolaska, nepropisna strana i pravac kretanja, vožnja bez prometne dozvole, neupotreba sigurnosnih pojaseva i kaciga i sl.), bihevioralnih čimbenika (precjenjivanje vlastitih sposobnosti, preuzimanje rizika, akutni psihološki stres te privremena rastresenost), psihofizičkoga stanja (alkoholiziranost, upotreba zabranjenih opojnih sredstava i medikamenata, korištenje mobitela, pospanost i umor, učinci lijekova, bolest i invaliditet), pogrešaka pješaka (nepoštivanje prometne signalizacije te važeće prometne regulacije, prelaženje ceste na nedopuštenom mjestu, nepropisno kretanje i zadržavanje na kolniku) te pogrešaka putnika (prekapacitiranost vozila, nagovaranja vozača na neprilagođenu brzinu prometovanja, neprimjereno sjedenje za vrijeme vožnje, uskakanje i iskakanje putnika u vozilo i sl.).

Također, važan element predstavlja i nedostatno preventivno i represivno djelovanje tijela nadležnih za sigurnost cestovnoga prometa. Studija provedena u Francuskoj i Finskoj [67] pokazuje kako intenziviranje kontrole brzine, u kombinaciji sa strožim represivnim sankcioniranjem vozača, rezultira smanjenjem broja ozlijeđenih i smrtno stradalih sudionika u cestovnom prometu.

Od ostalih čimbenika, možemo izdvojiti: iskustvo, dob, spol, razinu prometne kulture i edukacije sudionika u prometu, dnevne navike, moralne vrijednosti te mnogobrojne druge s tim povezane socioekonomske čimbenike.

S obzirom na iskustvo i dob [68], rizičnu skupinu predstavljaju mladi, neiskusni vozači do 25 godina, skloniji rizičnom ponašanju, te oni starije životne dobi (preko 60 godina) sa smanjenim kognitivnim i motoričkim sposobnostima, kojima je potrebno više vremena da procesuiraju informacije te donesu odluku. Starije su osobe najrizičniji sudionici u prometu. Ustvari, oni

podliježu najvećemu riziku od smrti nakon nesreće, kako u ulozi vozača tako i u ulozi pješaka. Stariji vozači uzrokuju manji broj CPN-a povezanih s konzumacijom alkohola, ali imaju problema s procjenjivanjem udaljenosti između vozila, prestrojavanjima, prometovanjima u složenim cestovnim raskrižjima, smanjenom pozornošću i dr.

Kod određenih mladih vozača evidentirano je recidivno kršenje prometnih propisa i pravila (konzumacija alkohola, korištenje mobilnih uređaja u vožnji [69]). Mladi vozači također su skloniji brzini te se često ne pridržavaju propisanoga razmaka između vozila, što su također bitne činjenice koje se moraju uzeti u obzir [70].

Konstanti napori oko unapređenja edukacije mladih vozača mogu znatno utjecati na smanjenje njihova udjela u cestovnim prometnim nesrećama. Stoga edukacija ima jasnu praktičnu vrijednost koja upozorava na potrebu kvalitetnijega planiranja obrazovnih programa i intervencija namijenjenih mladoj populaciji vozača.

Studije na temu alkohola i zabranjenih opojnih droga [71] [72] potvrđuju da njihova konzumacija tijekom vožnje može znatno narušiti sposobnost vozača da se suoči s konstantnim izazovima u vožnji (smanjena inhibicija i vrijeme donošenja odluke, odnosno reakcije). Vozači koji konzumiraju alkohol i opojne droge osjećaju se samouvjerenima, što rezultira njihovim rizičnim ponašanjem u prometu.

Što se tiče spola, studije potvrđuju kako muškarci imaju veći rizik od sudjelovanja u teškim oblicima CPN-a od žena, dok žene imaju veću vjerojatnost da sudjeluju u CPN-u čije su posljedice materijalna šteta ili lakše tjelesne ozljede [73] [74]. Takva prevaga muškaraca u CPN-u može se pripisati činjenici da su u većem broju izloženi prometu te drugim povezanim čimbenicima.

Iako pospanost i umor igraju važnu ulogu u pojavi CPN-a, njihov utjecaj kroz prethodna istraživanja [75] jako je teško kvantitativno procijeniti.

Način vožnje povezan je ne samo s rizikom od CPN-a, već također i s težinom ozljeda zadobivenih u CPN-u. Prema tomu, brzina predstavlja važan čimbenik koji utječe na pojavu CPN-a kako u pogledu njihova nastanka tako i posljedica. Potvrđuju to istraživanja [76] [77] [78] koja su imala za cilj istražiti odnos između brzine i broja CPN-a, od kojih većina upućuje na to da je povećavanje brzine prometovanja povezano s većim brojem CPN-a i stopama smrtnosti. U svojim radovima autori zaključuju da postoji kauzalna, odnosno uzročno-posljedična veza između promjene u brzini s promjenama u CPN-u, odnosno broj će CPN-a opadati ako se brzina prometovanja smanjuje i obrnuto. Slični zaključci dobiveni su i u studiji [63] koja je izučavala upravo povećava li brzina rizik od pojave prometne nesreće. U navedenom istraživanju autori su utvrdili kako je omjer izgleda za pojavu prometne nesreće pri brzini od 84 km/h gotovo 40 puta veći od omjera ako se prometuje vozilom brzinom ispod 60 km/h. Druga studija [79] izvješćuje da se povećanjem

brzine od 5 km/h iznad ograničenja brzine od 60 km/h u ruralnim područjima udvostručuje rizik od pojave CPN-a.

Nekorištenje sigurnosnoga pojasa i zaštitnih kaciga radnje su često svrstane u grupaciju rizičnoga ponašanja vozača u prometu, pri čemu je korelacija između njihove upotrebe i smrtnosti u CPN-u također izučena i potvrđena kroz studije i istraživanja [80] [81]. Prema njima, zalaganje za korištenje sigurnosnoga pojasa i zaštitnih kaciga osobito bi među mladim vozačima trebalo biti sastavni dio širega sigurnosnog i preventivnog obrazovanja.

Često vozači nisu u potpunosti upoznati s lokalnim prometnim pravilima vožnje te je kod određenoga broja primjetna i niska razina osnovnih vještina nužnih za ostvarenje sigurne vožnje. Ujedno, mnoge studije potvrđuju da vozači recidivisti prometnih prekršaja te oni koji prometuju svojim vozilima suprotno uvriježenim društvenim normama i prometnoj kulturi ujedno predstavljaju i veći rizik u prometu te, dakako, za pojavu CPN-a.

Aktivnosti u području edukacije sudionika u prometu

U ovom dijelu važno je prvenstveno uspostaviti snažne veze između obrazovnoga sektora i drugih subjekata koji su u vezi sa sigurnošću prometa. Edukaciju sudionika u prometu prvenstveno je potrebno sustavno i kvalitetno usmjeriti na djecu školske i predškolske dobi, a u svrhu njihova aktivnoga uključivanja u provedbu pojedinih mjera povezanih uz povećanje razine sigurnosti cestovnoga prometa [12]. U dijelu obrazovanja potrebno je znatno više pozornosti posvetiti stvaranju prometne kulture kako djece tako i odraslih sudionika u prometu, što će rezultirati njihovim usvajanjem ispravnih stavova i sigurnoga ponašanja u prometu. Kada je riječ o djeci, potrebno je kroz sustav osnovnoškolskoga obrazovanja omogućiti bolje upoznavanje djece s prometnim pravilima te ih uključiti u daleko većem broju u organizirane akcije s ciljem povećanja znanja o prometu. Navedene se aktivnosti ogledaju kroz znatno veću satnicu za prometni odgoj, organiziranje raznih natjecanja s temom prometa, kao i kroz obvezno formiranje školskih prometnih jedinica u svim osnovnim školama. S tim je ciljem potrebno osigurati dodatno vrijeme i sredstva za angažiranje nastavnika. Drugi segment u području edukacije sudionika u prometu svakako su javne kampanje za sigurnost cestovnoga prometa [82] [83] [84], putem kojih se na vrlo efikasan način dopire do šire javnosti u vezi s promicanjem sigurnosti u prometu. Njihovom implementacijom sudionici u prometu dobivaju pravovaljane informacije o novim ili dopunjenim zakonskim legislativama u području sigurnosti cestovnoga prometa te mogu znatno doprinijeti smanjenju neprimjerenoga ponašanja promocijom načela sigurne vožnje. Također, preventivnim kampanjama na ciljana područja djelovanja (npr. sprječavanje konzumacije alkohola tijekom

vožnje te veća upotreba sigurnosnih pojaseva ili kaciga) te skupine (djeca, mladi vozači i dr.) krajnjim se korisnicima također povećava svijest o novim znanstvenim saznanjima te utjecaju novih tehnologija i opreme na sigurnost prometa, što pruža pozitivan učinak na smanjenje učestalosti CPN-a i težinu njihovih posljedica.

3.1.2. Cesta kao čimbenik sigurnosti cestovnoga prometa

Čimbenici su koji utječu na sigurnost cestovnoga prometa mnogobrojni. U posljednjih nekoliko desetljeća primjetan je sve veći istraživački interes za učinke prometa i cestovne infrastrukture na stope kretanja CPN-a. Unapređenja u području projektiranja i izvedbe cestovne infrastrukture te inženjerskoga rada predstavljaju stoga važnu ulogu u sigurnosti cestovnoga prometa [85] [86].

Kao osnovni elementi cestovnoga prometnog sustava, tehnička razina izvedbe objekata i uređaja cestovne infrastrukture u kombinaciji s prometnim uvjetima predstavlja bitan čimbenik vezan uz pojavu CPN-a. Nedovoljna opremljenost cestovne prometne mreže, širina kolnika i pješačkih nogostupa, nedostatak prometne opreme i signalizacije te lokalna oštećenja kolnika (ulegnuća, deformacije, udarne rupe i sl.) znatno narušavaju značajke cestovne infrastrukture te one teško dosežu adekvatnu razinu kako bi zadovoljila zahtjeve vozila i sudionika u prometu. Nadalje, ograničenja okolnoga terena često definiraju projektantske smjernice prilikom izvedbe trasiranja, dimenzioniranja i oblikovanja cestovnih koridora, što bitno utječe na razinu prometne sigurnosti.

Promet u urbanim sredinama često je problem za lokalnu upravu s obzirom na to da je obično riječ o cestovnoj mreži koja je zbog prostornih ograničenja često komplicirana i ograničena, prvenstveno nepravilnim položajnim planom prometnica. Cestovna su križanja u glavnini slučajeva dosegla svoje prometne kapacitete unutar kojih, osim individualnih motornih vozila, često prometuju i vozila javnoga gradskog prijevoza, što dodatno potencira problem nedostatne kapacitiranosti cestovne mreže, posebice u vršnim satima.

Kategorija prometnice važan je čimbenik rizika za nesreće u kojima su uključeni pješaci, osobito kada je riječ o lokacijama izvan gradskoga središta, gdje su odvojene staze/trake za pješake, nogostupi i semaforizirani pješački prijelazi rijetki. Uvjeti osvjetljenja čimbenici su zaslužni za vrlo visok rizik od smrti u večernjim satima, noću i zimi, kada je prirodna svjetlost slaba i vidljivost pogoršana kišom i maglom.

Cestovna raskrižja predstavljaju najrizičniju mikrolokaciju za vozače motornih vozila, dok su pješaci i biciklisti najranjiviji na ravnim cestovnim pravcima, prometujući između dvaju rezidencijalnih blokova. Kada govorimo o sigurnosti pješačkoga prometa, potrebno je istaknuti da najrizičniju skupinu čine školska djeca, mladi te građani stariji od 60 godina. Statistički, autoceste

predstavljaju najsigurniju kategoriju cestovnih prometnica, iako kod određenoga broja vozača izazivaju nelagodu zbog povećane brzine prometovanja motornih vozila.

Poboljšanje i modernizacija cestovne infrastrukture predstavlja stoga bitnu ulogu u povećanju razine prometne sigurnosti i protočnosti prometnih entiteta kroz cestovnu mrežu [87].

To se najčešće odnosi na nadogradnju ili rekonstrukciju prometnica odnosno dodavanje novih elementa prometnice (pješački nogostup, biciklistička staza/traka, postavljanje javne rasvjete, uređenje sustava oborinske odvodnje, razdvajanje dvosmjernih kolnika razdjelnim središnjim prometnim pojasom), postavljanje cestovne opreme (delineatori, katadiopteri, taktilne površine za slijepe i slabovidne osobe, zvučni signalizatori, uzdignuti pješački prijelazi, fiksni i elastični prometni stupići, umjetne cestovne izbočine za smirivanje prometa, postavljanje betonskih barijera, klamerica), devijacije i suženja kolnika, izvedba roto križanja, manje građevinske korekcije privoza i radijusa, upuštanje rubnjaka i kolnih ulaza, postavljanje i održavanja prometne signalizacije i sl. Regulacija cestovnih pravaca i raskrižja s pomoću svjetlosne koordinirane prometne regulacije, kao i organizacija prometnih traka namijenjenih isključivo javnomu gradskom prometu (autobus, tramvaj, taksi) također imaju svoje određene sigurnosne implikacije te bi ih trebalo detaljnije izučiti. Navedenim postupcima, uz relativno male financijske izdatke, jednostavnu implementaciju te uglavnom uz potporu pozitivnoga javnog mnijenja znatno se može unaprijediti razina sigurnosti odvijanja motoriziranoga i nemotoriziranoga prometa na određenom lokalitetu, pri čemu se dobiveni rezultati mogu pouzdano potvrditi provedbom prije/poslije analize učinkovitosti.

U grupaciju *cesta* ulazi širok spektar čimbenika vezanih uz prometnu okolinu te stanje cestovne mreže. Tako u navedenu skupinu najčešće ulaze sljedeće problemske prometne situacije, koje rezultiraju pojavom CPN-a: neprikladna ili nepropisno postavljena prometna oprema i signalizacija na cesti (nedostatak zaštitne prometne ograde, prometnih znakova i oznaka na kolniku), nekvalitetno izvedena kolnička konstrukcija (proklizavanje pneumatika, nedostatna kvaliteta i izdržljivost kolničkoga zastora), pogreške u fazi projektiranja (pogrešno izvedena krivulja cestovnoga zavoja, nedostatak pojedinih tehničkih elemenata prometnice – pješačkih nogostupa, javne rasvjete i sl.) te nepovoljni vremenski uvjeti (utjecaj sunčeve svjetlosti, kiša, vjetar, snijeg i sl.). U području prometne okoline valja raščlaniti prirodno okruženje (geološko okruženje, klimatski i prostorni uvjeti, buka i dr.) te prometno okruženje (prometno opterećenje, pravovremeno i kvalitetno informiranje sudionika u prometu i dr.). Važnu grupaciju predstavlja također i obrazac naseljenosti (urbano ili ruralno, oskudno ili visoko konsolidirano područje), stupanj razvijenosti mreže ulica te mreža drugih javnih površina s prepoznatljivom fizičkom strukturom. Unutar toga područja uključena su i bitna obilježja prostorne i građevne strukture

određene topografijom te raznolikost namjena i sadržaja prostora (stambena namjena, javna i društvena namjena, gospodarska namjena i sl.).

Izdvajajući prometnice kao ključne čimbenike CPN-a moguće je modelirati prognostički model. Istraživanja toga tipa u pravilu se provode na cestovnim križanjima i prometnim pravcima s frekventnom pojavom CPN-a. U područje geometrijskih struktura prometnica ubrajaju se varijable cestovne infrastrukture kao što su uzdužni i poprečni nagib kolnika u pravcu i zavoju, broj i širina prometnih traka, proširenje kolnika u zavojima, broj rasvjetnih tijela i dr.

Varijable koje su odnose na prometne uvjete jesu ograničenje brzine prometovanja, udio teškoga teretnog prometa, eventualna lokalna ograničenja proizašla iz karakteristika okolnoga terena, namjena zemljišta, broj uređenih pješačkih prijelaza, autobusnih stajališta, biciklističkih staza/traka i dr.

Važnost analize pojedinih tlocrtnih i vertikalnih elemenata promatrane dionice ceste naglašeno je i u radu Zeggera [88]. U navedenom su istraživanju, kako bi se analizirao međusoban odnos između učestalosti CPN-a i različitih obuhvaćenih ulaznih varijabli mjerenja, promjene u pojedinim elementima ceste (npr. geometrijska struktura) segmentirano analizirane u odnosu na ukupnu dionicu.

Prognostički model CPN-a u ovome se području primarno koristi kako bi se potvrdila korelacija između pojedinih ulaznih varijabli mjerenja i učestalosti CPN-a te za procjenu sigurnosti pojedino analiziranoga cestovnog segmenta (dionice). Dobiveni rezultati mogu se primijeniti na odabir elemenata ceste koje je prioritetno potrebno unaprijediti, odnosno korigirati. Kvalitetni modeli CPN-a, koji se fokusiraju na prometnice kao čimbenike CPN-a, kao ulazne parametre moraju percipirati i informacije koje se odnose na namjenu okolnoga zemljišta te geografske značajke povezane s urbanim područjem.

3.1.3. Vozilo kao čimbenik sigurnosti cestovnoga prometa

Karakteristike vozila i njihovo korištenje često se u literaturi navode kao potencijalno važni čimbenici koji pridonose visokim stopama težih oblika CPN-a.

Tehnologija cestovnih motornih vozila stoga igra bitnu ulogu u povećanju sigurnosti cestovnoga prometa. U području pasivne sigurnosti vozila (zaštitni uređaji u vozilima, kao što su sigurnosni pojasevi, zračni jastuci te sjedalice za djecu) znatna tehnološka poboljšanja dovela su do značajnoga povećanja sigurnosti cestovnoga prometa u posljednjih nekoliko godina, a posebno u dijelu smanjenja broja CPN-a sa smrtnim posljedicama.

Cestovna motorna vozila glavni su alat današnjega modernog prijevoza. Kvaliteta tehničke izvedbe motornih vozila predstavlja vitalnu ulogu u sigurnosti cestovnoga prometa. Problemi kao što su slabe performanse kočionih sustava, mehanički kvarovi i nepravilnosti pojedinih komponenata mogu izravno utjecati na pojavu CPN-a, čime ovaj čimbenik sigurnosti cestovnoga prometa zahtijeva veću pozornost te dodatna istraživanja.

U posljednjoj skupini – *vozila* – najčešće se spominju sljedeći problemski elementi: kvantiteta, starost te nedovoljno održavanje voznoga parka, kao i upotreba nekvalitetnih zamjenskih dijelova, tehnička neispravnost pojedinih elemenata vozila (neispravnost uređaja za kočenje ili upravljanje, neispravnost pneumatika, svjetlosnih uređaja i ostalih uređaja na vozilu potrebnih za ispravno upravljanje vozilom) te nepropisno upravljanje teretom (opterećenost vozila iznad dopuštene nosivosti, nepravilan smještaj i sl.).

U urbanim sredinama poseban značaj ima i sastav, odnosno kompozicija voznoga parka. Izmiješanost velikoga broja različitih oblika prijevoznih sredstava, kao što su osobni automobili, biciklisti, motociklisti, teretna vozila, vozila javnoga gradskog prijevoza i dr., koja prometuju različitim brzinama te prema različitim pravilima, utječe na pojavu incidentnih prometnih situacija kao što su padovi ili sudari između pojedinih kategorija vozila, pri čemu je posebno rizično sudjelovanje u njima nemotoriziranih sudionika u prometu.

Ovisno o stupnju ekonomske razvijenosti države te povećanju prihoda po stanovniku raste i broj kupljenih vozila, što također može rezultirati povećanjem broja CPN-a. Broj prijeđenih kilometara te učestalost inspekcijskih (redovnih i izvanrednih) pregleda vozila također možemo ubrojiti u značajne varijable koje mogu utjecati na apsolutni broj prometnih nesreća [89].

Analizirajući stanje u RH, zbog ekonomskih uvjeta koji prije svega odražavaju negativne socioekonomske pokazatelje zbog recesijskih prilika u državi, za pretpostaviti je i određeno stagniranje u ukupnom broju prijeđenih kilometara motoriziranih vozila, kao i u samom broju registriranih vozila. Tomu u prilog govori podatak o trendu opadanja broja prijavljenih šteta u obveznom osiguranju od automobilske odgovornosti u osiguravajućim društvima, koji također potvrđuje tvrdnje da recesijske prilike znatno utječu na platežnu moć građana.[16]

U periodu od 2004. do 2013. godine ukupan broj registriranih motornih vozila u RH povećao se za 41,23%, a broj novih vozača motornih vozila za 30,43%. U tom dijelu zanimljiv je i statistički podatak koji ukazuje na to kako je tijekom 2011. godine na području RH evidentiran 21.401 novi

[16] Hrvatski ured za osiguranje, *Izvješće o tržištu obveznih osiguranja u prometu s posebnim osvrtom na osiguranje od automobilske odgovornosti 2011.*, ISSN 1848-0918, Zagreb, 2012.

vozač s položenim vozačkim ispitom, dok je istovremeno odjavljeno 20.527 motornih vozila, znatnim dijelom individualnih.

Analizirajući prosječnu starost voznoga parka u RH, koja je bitan element (čimbenik) sigurnosti cestovnoga prometa, prema Centru za vozila Hrvatske, ona je tijekom 2015. godine u RH iznosila oko 13,50 godina. To je potvrđeno iz analize podataka koja ukazuje na to kako od ukupno 1.476.229 osobnih automobila koji su 2015. bili na redovnom tehničkom pregledu, najviše njih, čak 962.173 (65,18%) ima deset i više godina. S udjelom od 21,56% slijedi 318.227 osobnih vozila starih od šest do deset godina, dok je od dvije do šest godina staro njih 156.113, odnosno 10,58%. Također zabrinjava i podatak kako je tijekom 2015. godine od ukupno 1.945.145 motornih vozila (osobni automobili, autobusi, kamioni i ostala motorna vozila) koja su prošla kroz stanice za tehnički pregled, njih 21,94% bilo ocijenjeno neispravnima i vraćeno na uklanjanje uočenih nedostataka. Problemi su dodatni ako se uzme u obzir to da motorna vozila iz prve skupine često nisu opremljena u skladu s novim aktivnim i pasivnim tehnološkim rješenjima sigurnosti vozila (ABS, zračni jastuci itd.).

U skladu s iznesenim, nužno je što ranije poboljšati tehničke karakteristike vozila, unaprijediti razinu detekcije kvarova i održavanja cestovnih vozila te jasno istaći dijelove vozila koje je potrebno unaprijediti jer su slabije tehničke izvedbe.

3.2. Relativni čimbenici rizika cestovnih prometnih nesreća

Prilikom opisivanja stopa i trendova sigurnosti cestovnoga prometa te troškova proizašlih iz pojave CPN-a, a za potrebe kvalitetne usporedbe nivoa sigurnosti pojedinih država, trenutno se u nacionalnim i međunarodnim bazama podataka o prometnim nesrećama koriste mnogobrojni općeprihvaćeni i standardizirani parametri vrednovanja sigurnosti cestovnoga prometa. Na osnovu podataka o CPN-u, njihovim posljedicama i osnovnim socioekonomskim i prometnim karakteristikama gradskoga sustava (broj stanovnika, broj registriranih motornih vozila, površina teritorija, dužina cestovne gradske mreže ovisno o kategorijama prometnica, stupanj motorizacije i sl.) u mogućnosti smo kvalitetno izračunati široko uvriježene relativne indekse sigurnosti odnosno pokazatelje rizika u cestovnom prometu. Pokazatelji koji se obično primjenjuju za mjerenje razine sigurnosti cestovnoga sustava jesu prometni rizik (omjer stradalih sudionika u odnosu na 10.000 vozila, 100.000 ili 1.000.000 vozila), javni rizik (omjer stradalih sudionika u odnosu na 100.000 ili 1.000.000 stanovnika), dinamički prometni rizik (omjer stradalih sudionika u odnosu na 100.000 ili 1.000.000 vozilo/- kilometara) te razni drugi indeksi (u odnosu na

100.000 vozača, broj putničkih kilometara [17] i dr.) koji predstavljaju kvantitativne pokazatelje prometnih nesreća te opisuju nešto realnije stanje sigurnosti. [90] [91]

Iako je u posljednjih nekoliko godina zamjetan stabilan trend smanjenja CPN-a na području RH u usporedbi s ostalim zemljama članicama UNECE-a i Sjeverne Amerike (Grafikon 3.1.), kolacionirajući podatke obrađene u međunarodnoj bazi podataka o prometu te cestovnim nesrećama – „*International road traffic and accident database*" (IRTAD), vidljivo je da stope smrtnih slučajeva u odnosu na 1.000.000 stanovnika, naspram većine drugih zemalja, Hrvatsku svrstavaju u gornji dio ljestvice. U zbirni pregled uvrštene su države UNECE-a, njih ukupno 56, podijeljene u tri kategorije:

- Europska unija i Europska slobodna trgovinska zona (EU + EFTA) – Austrija, Belgija, Bugarska, Hrvatska, Cipar, Češka, Danska, Estonija, Finska, Francuska, Njemačka, Grčka, Mađarska, Island, Irska, Italija, Latvija, Lihtenštajn, Litva, Luksemburg, Malta, Nizozemska, Norveška, Poljska, Portugal, Rumunjska, Slovačka, Slovenija, Španjolska, Švedska, Švicarska i Ujedinjeno Kraljevstvo Velike Britanije i Sjeverne Irske,
- Sjeverna Amerika – Kanada i Sjedinjene Američke Države,
- ostatak UNECE-a – Albanija, Andora, Armenija, Azerbejdžan, Bjelorusija, Bosna i Hercegovina, Gruzija, Izrael, Kazahstan, Kirgistan, Monako, Crna Gora, Republika Moldavija, Ruska Federacija, San Marino, Srbija, Tadžikistan, Bivša Jugoslavenska Republika Makedonija, Turska, Turkmenistan, Ukrajina i Uzbekistan.

U 2013. godini Švedska, Velika Britanija i Nizozemska imale su najmanje stope poginulih osoba po stanovniku, dok su Kirgistan, Ruska Federacija i Kazahstan imali najviše vrijednosti. U UNECE regiji broj poginulih osoba na milijun stanovnika obrnuto je proporcionalan s bruto domaćim proizvodom (BDP) po glavi stanovnika, što je također razlog za velike oscilacije između pojedinih zemalja i regija. UNECE regija kao cjelina u 2013. godini bilježi prosjek od 87 smrtnih slučajeva na milijun stanovnika. U odnosu na njega, države EU + EFTA ostvarile su prosječnu stopu nižu za više od 40%, dok ga je ostatak UNECE-a nadmašio za više od 40%.

S obzirom na to da je u većini navedenih država broj stanovnika, registriranih motornih vozila, tranzitnoga prometa te izgrađenih kilometara cestovne prometne mreže daleko veći nego u RH, to indicira kako su nužni daljnji napori kako bi se smanjile prethodno prikazane vrijednosti, odnosno dostigli ciljevi iz aktualnoga Nacionalnog programa sigurnosti cestovnog prometa.

[17] Zbog nedostatka potrebnih statističkih grupa podataka dinamički prometni rizik (broj poginulih na 100 milijun voz-km) na području RH nije moguće izvesti.

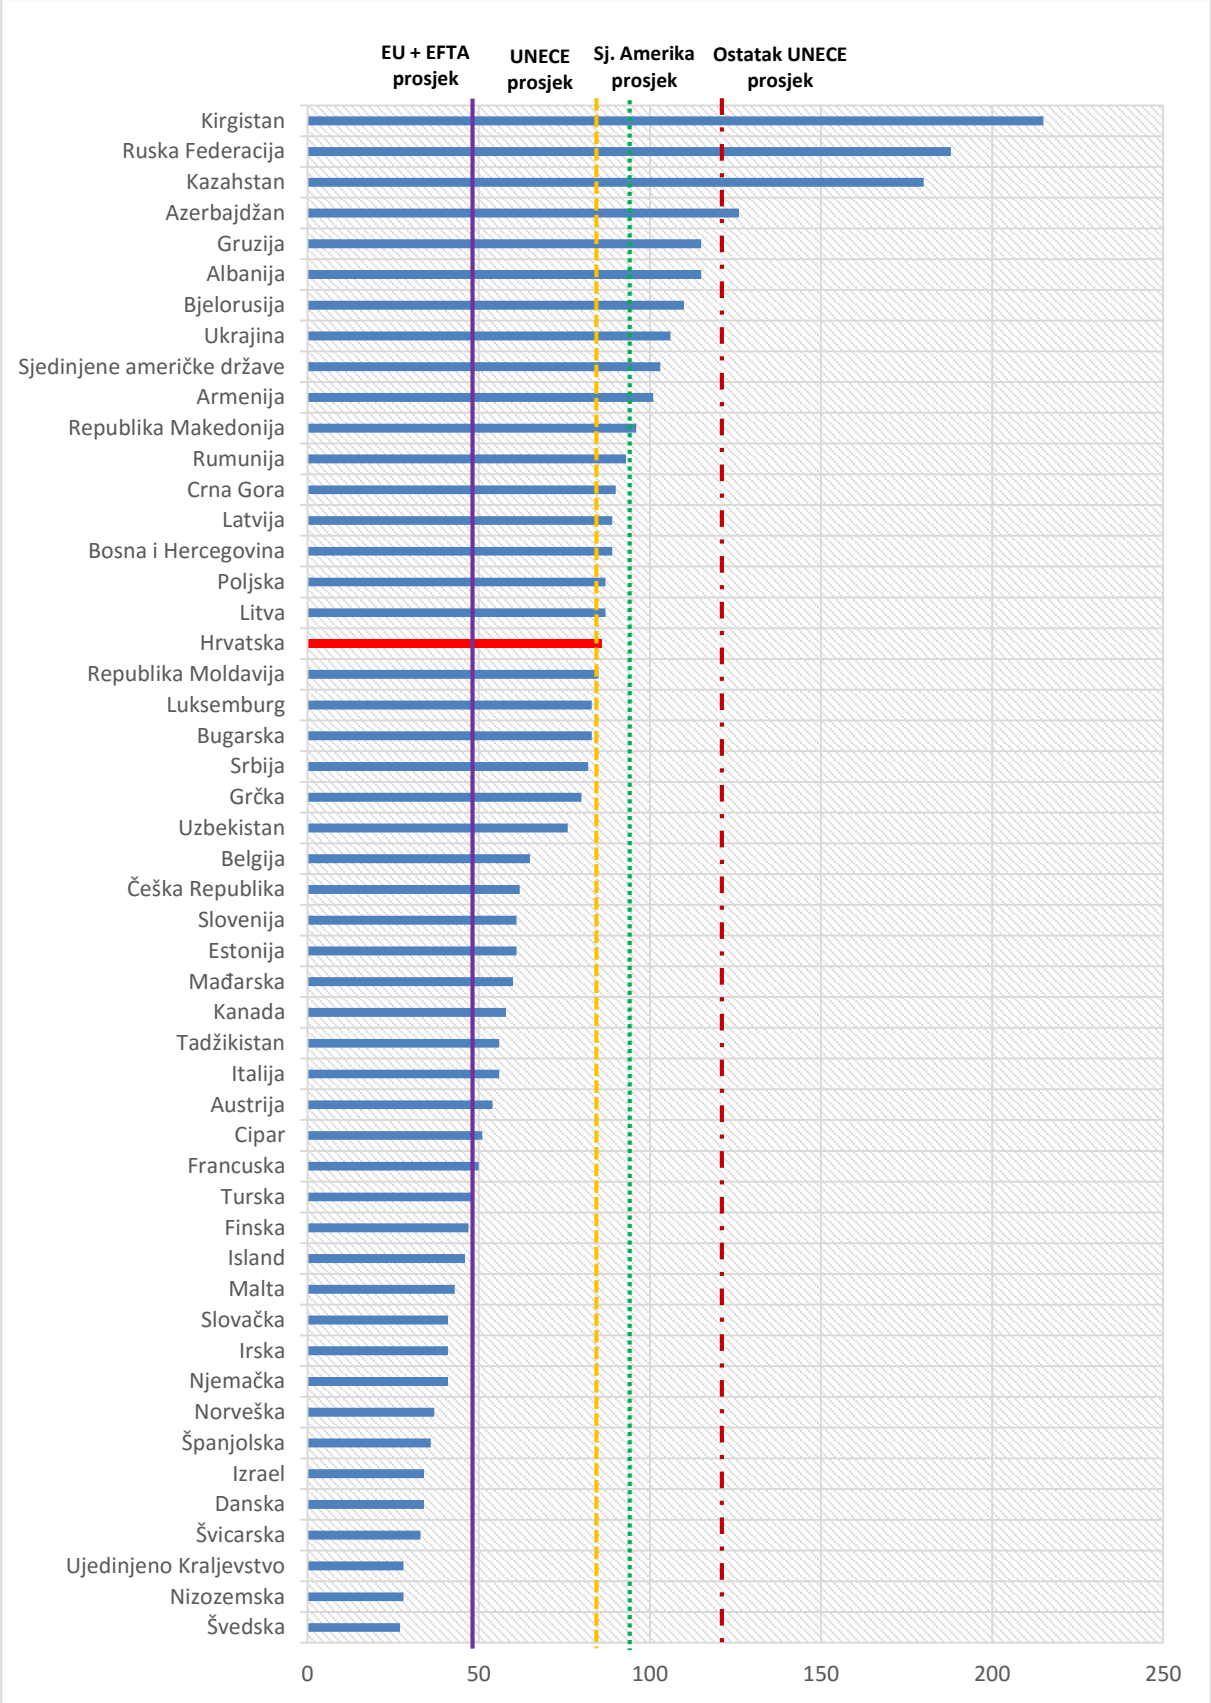

Grafikon 3.1. Broj poginulih osoba na 1.000.000 stanovnika (2013.)

Izvor: OECD/IRTAD i ECMT, obrada autora

Među zemljama članicama EU-a Republika Hrvatska, promatrajući je prema uvriježenomu relativnom sigurnosnom pokazatelju (broj poginulih osoba na 1.000.000 stanovnika), ima iznadprosječnu stopu smrtnih slučajeva od sudjelovanja u CPN-u, te je prema podatcima iz 2013. (Grafikon 3.2.) pozicionirana na visokom četvrtom mjestu, odmah ispod Latvije, Poljske i Rumunjske. Unatoč znatnomu smanjenju stopa smrtnosti od 2008. godine, Hrvatska je jedna od zemalja s najvišim stopama smrtnosti među državama članicama Europske unije.

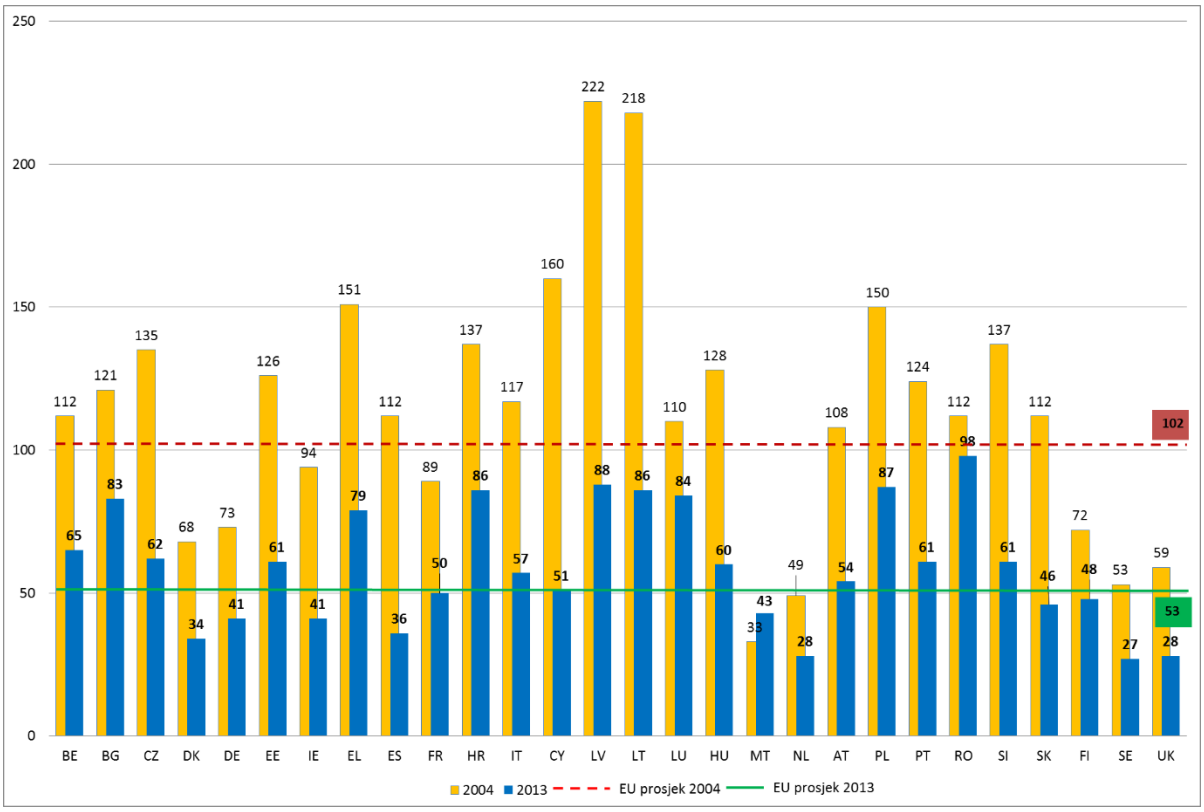

Grafikon 3.2. Broj poginulih osoba na 1.000.000 stanovnika po pojedinim državama članicama Europske unije, komparacijom 2013. s 2004. godinom, Izvor: CARE, Eurostat

Prateći stope kretanja broja poginulih osoba na 1.000.000 stanovnika i komparirajući podatke Republike Hrvatske u odnosu na prosjek Europske unije, kroz srednjoročni vremenski period od 2001. do 2014. godine (Grafikon 3.3.) možemo detektirati međusobnu korelacijsku vezu s tendencijom pada vrijednosti. Republika Hrvatska još je uvijek nisko pozicionirana na ljestvici zemalja EU-a kada je riječ o sigurnosti prometa na cestama. Prema službenim podatcima Eurostata i MUP-a RH broj poginulih osoba na milijun stanovnika iznosio je 2012. godine 57,7 za zemlje EU-a (uključeno 28 zemalja), dok je za Hrvatsku taj broj iznosio 91, što znači da je on 62,5% veći. Iako su vrijednosti Republike Hrvatske kontinuirano iznad prosjeka EU-a, u posljednjoj, 2014. godini, razlika između RH i EU-a bilježi najmanje odstupanje (44,55%), što je svakako ohrabrujući podatak.

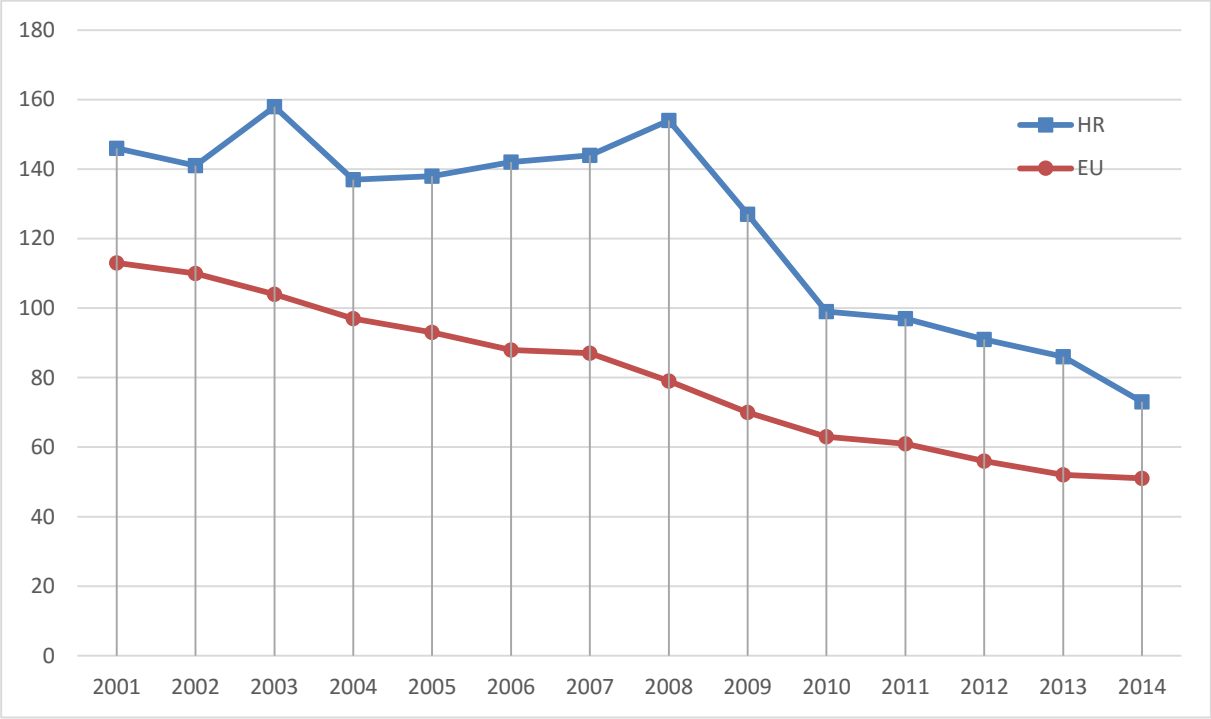

Grafikon 3.3. Broj poginulih osoba na 1.000.000 stanovnika u razdoblju 2001. – 2014. na području Republike Hrvatske i Europske unije, Izvor: CARE, Eurostat

Promatrajući relativne pokazatelje rizika CPN-a na razini Republike Hrvatske (Grafikon 3.4.), vidljiva je konstantna blaga stopa pada svih triju pokazatelja. Relativan broj prometnih nesreća na bazi poginulih osoba na 100.000 vozila smanjen je s 35.3 u 2004. godini na 19.7 u 2013. godini (44,19%), dok broj poginulih osoba na 100.000 vozača pokazuje slične trendove promjena relativnoga broja s 30.2 u 2004. godini na 16.1 u 2013. godini (46,69%). Broj poginulih osoba na 100.000 stanovnika ukazuje na smanjenje od 37,23% u odnosnu na početnu godinu.

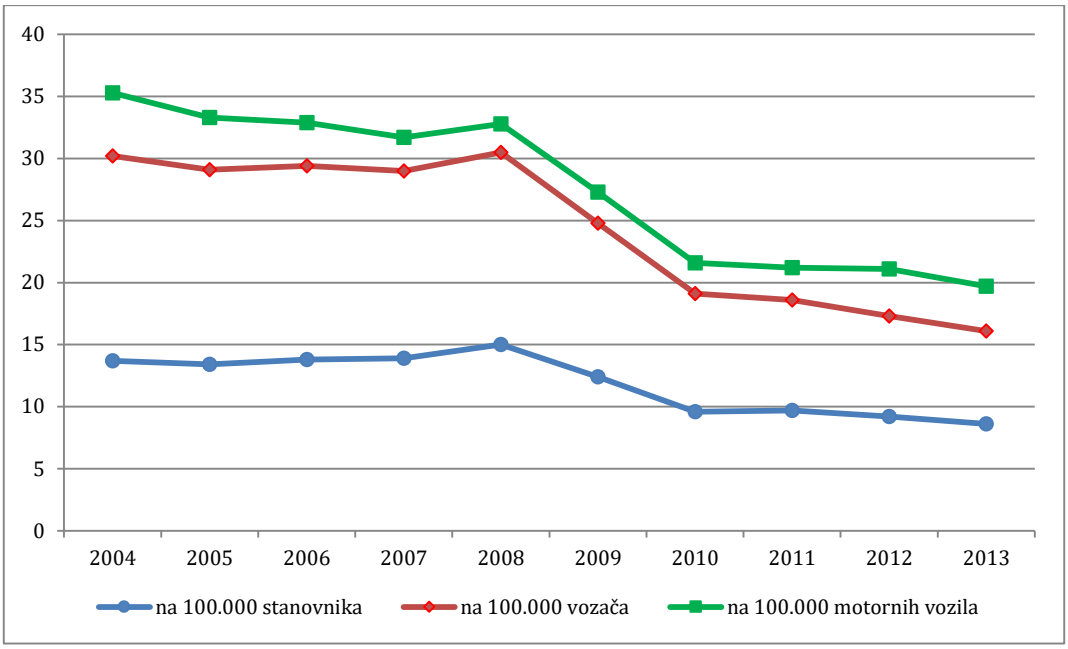

Grafikon 3.4. Broj poginulih osoba na 100.000 stanovnika, vozača, vozila, u razdoblju 2004. – 2013. godine na području Republike Hrvatske

Izvor: Bilteni o sigurnosti cestovnog prometa Republike Hrvatske 2013., RH, Ministarstvo unutarnjih poslova, Zagreb, 2014. Obrada autora.

3.2.1. Analiza cestovnih prometnih nesreća u urbanim/ruralnim područjima

Radi kvalitetnije usporedne analize broja poginulih osoba za urbana/ruralna područja pojedinih država članica Europske unije morala je biti uzeta u obzir odgovarajuća veličina stanovništva (Grafikon 3.5.). Tijekom 2013. godine najveći je broj poginulih osoba na milijun stanovnika u urbanim područjima zabilježen u Rumunjskoj (57,7), koja ujedno ima deset puta veću vrijednost nego Švedska, koja se često koristi kao primjer svjetskoga lidera u području sigurnosti na cestama. Analize broja poginulih osoba u urbanim područjima Republiku Hrvatsku među 28 država članica Europske unije rangiraju na visoko drugo mjesto, s vrijednošću od 50 poginulih osoba u odnosu na milijun stanovnika. Za većinu sjevernih i zapadnih zemalja Europske unije stope poginulih osoba u urbanim područjima nalaze se ispod prosjeka EU-a, koji iznosi 19,6. Od svih zemalja EU-a najniži udio poginulih osoba na cestama u naselju u odnosu na ukupan broj smrtnih slučajeva imaju Belgija, Finska, Estonija i Švedska (ispod 25%).

Vezano na smrtna stradavanja na prometnicama izvan naselja, najvišu stopu smrtnosti na milijun stanovnika imaju Bugarska (75,9), Latvija (61,8) i Estonija (59,8). Navedene su stope više nego dvostruko veće od stope prosjeka EU-a (28,4) te gotovo 5 puta veće od vrijednosti zabilježene u

Nizozemskoj, koja ujedno u odnosu na ostale promatrane zemlje bilježi najmanju stopu od svega 12,1.

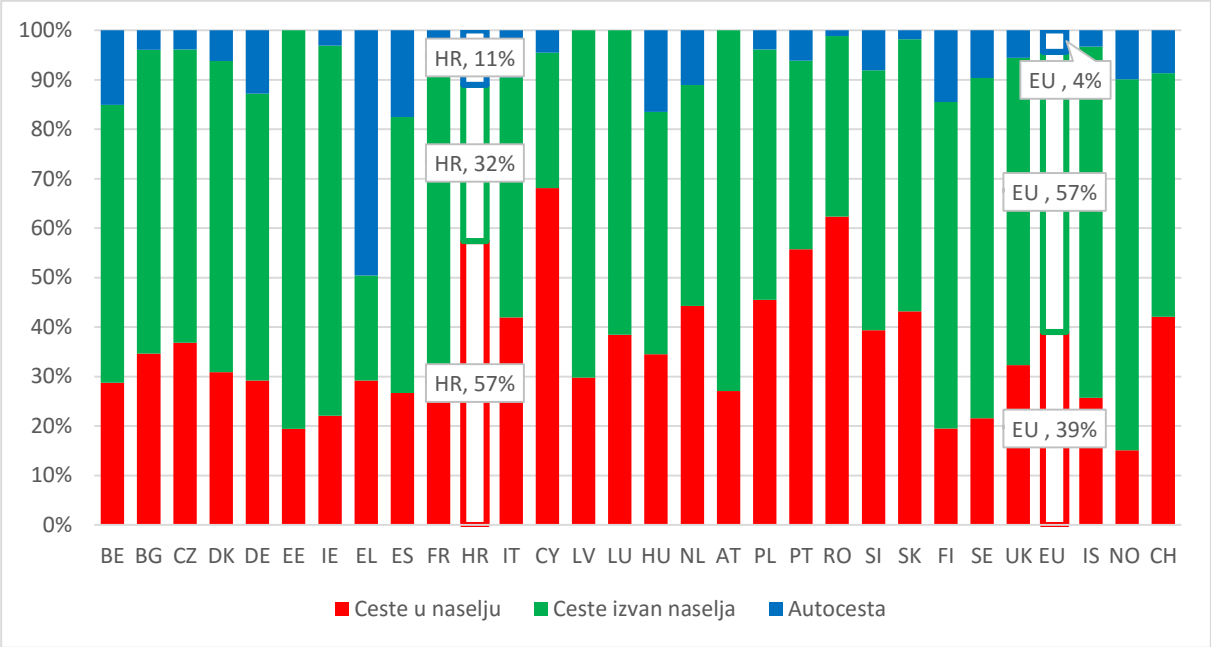

Grafikon 3.5. Broj poginulih osoba u odnosu na milijun stanovnika po državama članicama Europske unije, ovisno o mjestu nastanka CPN-a, 2013. godina. Izvor: CARE Eurostat, obrada autora

Komparirajući podatke o poginulim osobama ovisno o mjestu nastanka CPN-a, tj. prema kategoriji i značajkama cesta (Grafikon 3.6.), vidljivo je kako su vrijednosti vezane za urbana područja s jedne strane i ruralna s druge gotovo dijametralno suprotne u RH i u EU-u. Prema prikupljenim podatcima, udio poginulih osoba u RH tijekom 2014. godine na cestama u naselju u odnosu na ukupan broj poginulih u CPN-u iznosio je 62%, dok je prosjek EU-a 38%, što predstavlja razliku od ukupno 24%. Značajne razlike vidljive su i komparacijom broja osoba poginulih na cestama izvan naselja – njihov udio u broju poginulih osoba u CPN-u u RH iznosi 31%, dok je prosjek EU-a 54%. Podatci vezani za osobe poginule na autocestama te na cestovnim križanjima približno su jednaki za RH i EU, te iznose 7% odnosno 19%. Komparirajući podatke o poginulim osobama u RH između 2007. te 2014. godine, vidljivo je da prosječna godišnja stopa promjene za ceste u naselju iznosi -7%, ceste izvan naselja -12%, autoceste -14% te križanja -6%.

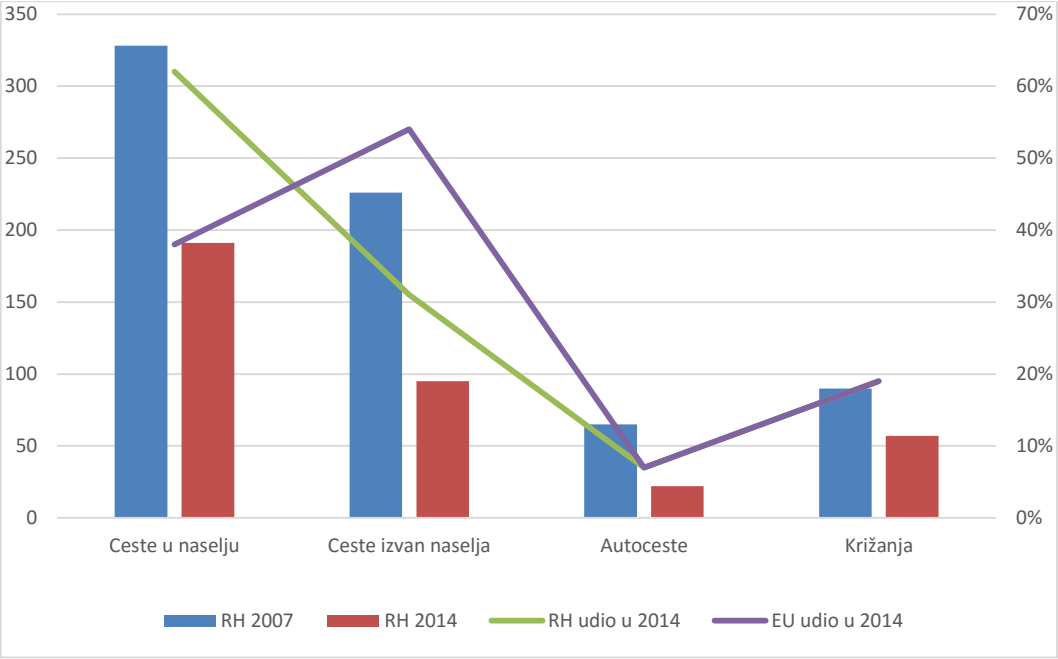

Grafikon 3.6. Prostorna distribucija broja poginulih osoba u CPN-u ovisno o kategorijama i značajkama ceste, komparacija 2014. s 2007. godinom, u Republici Hrvatskoj u odnosu na prosjek Europske unije. Izvor: CARE, Eurostat, obrada autora

Detaljnijom prostornom diferencijacijom za urbana područja, ovisno o značajkama cesta (Grafikon 3.7.) možemo navesti kako unutar gradskih područja Rumunjska ima najniži postotak smrtnih slučajeva (14%) u zonama cestovnih raskrižja, dok se više od polovice urbanih smrtnih slučajeva u Velikoj Britaniji (60%), Nizozemskoj (57%) i Danskoj (53%) dogodilo na cestovnim raskrižjima. Analizirajući podatke za Republiku Hrvatsku, vidljivo je da udio stradavanja na urbanim križanjima iznosi 25%, dok je na lokacijama izvan cestovnih raskrižja 73%. Usporedimo li navedene podatke s prosjekom Europske unije, vidljivo je da su gotovo identični, sa stopom odstupanja od svega 2%.

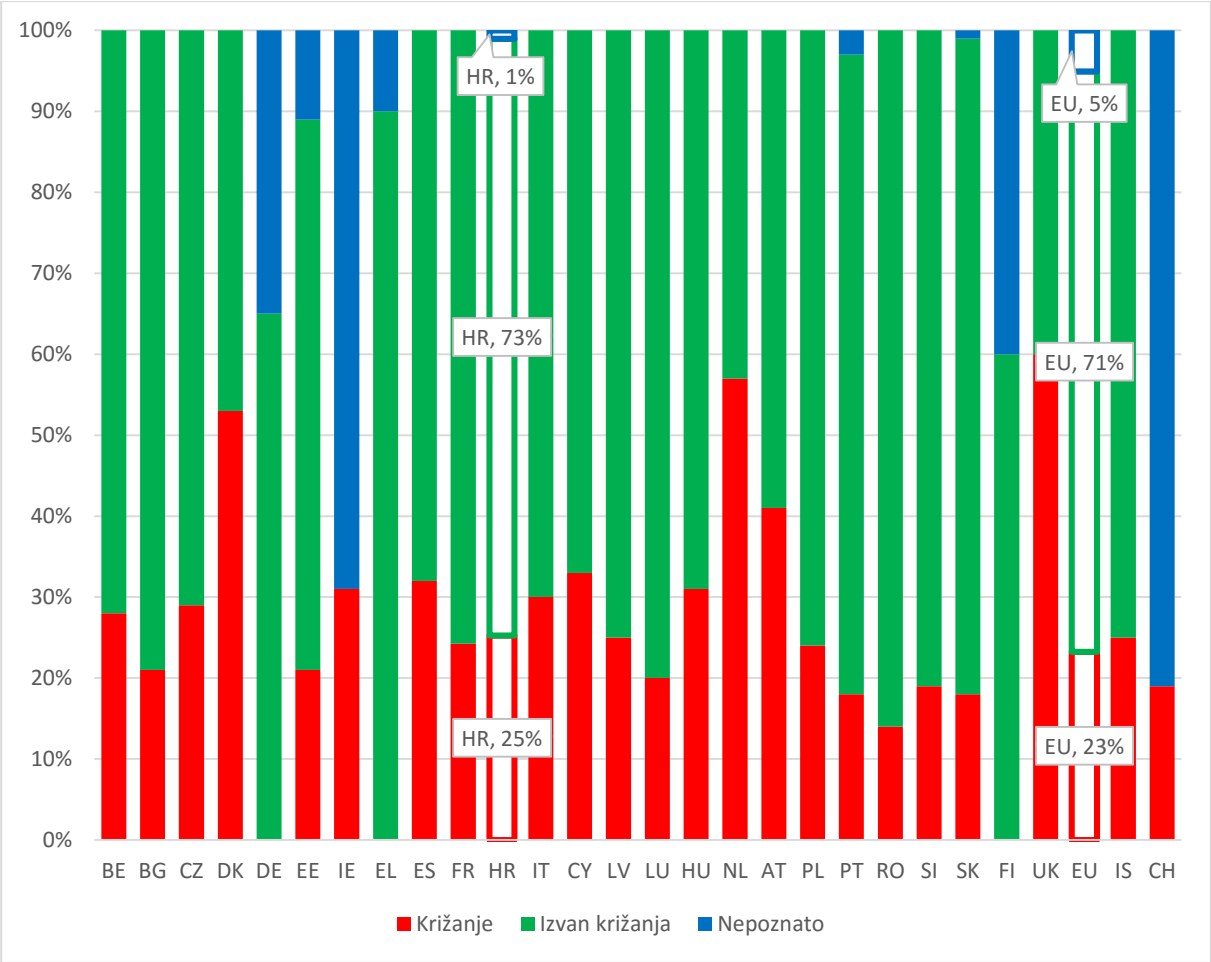

Grafikon 3.7. Prostorna distribucija broja poginulih u CPN-u za urbana područja, ovisno o značajkama ceste, po državama članicama Europske unije, 2013. godina. Izvor: CARE, Eurostat, obrada autora

Usporedimo li navedene podatke s podatcima o smrtnosti na prometnicama izvan naselja, možemo zaključiti kako je udio smrtnih slučajeva na gradskim križanjima dvostruko veći od udjela na cestovnim raskrižjima izvan urbanih područja. Nadalje, više od polovice smrtnih slučajeva koji su se dogodili izvan cestovnih križanja zabilježeni su na cestama izvan urbanih područja. U Republici Hrvatskoj udio osoba poginulih na cestama izvan naselja (ruralno područje) te izvan križanja iznosi visokih 93%, što je svrstava na drugo mjesto među državama članicama EU-a.

Raspodjela smrtnih slučajeva ovisno o kategoriji sudionika u prometu unutar urbanoga područja tijekom 2013. godine prikazana je Grafikonom 3.8. Unutar gradskoga područja, tj. unutar naselja prosjek EU-a ukazuje na to da se 50% registriranih smrtnih slučajeva odnosi na vozače, 39% na pješake te 11% na putnike. Učešća su za Republiku Hrvatsku ponešto drugačija te za vozače iznose 57%, pješake 25% te putnike 18%. Najveće učešće stradalih pješaka u urbanim područjima registrirano je u Latviji, visokih 70%, dok je u Nizozemskoj samo 17%, a na Malti 15%.

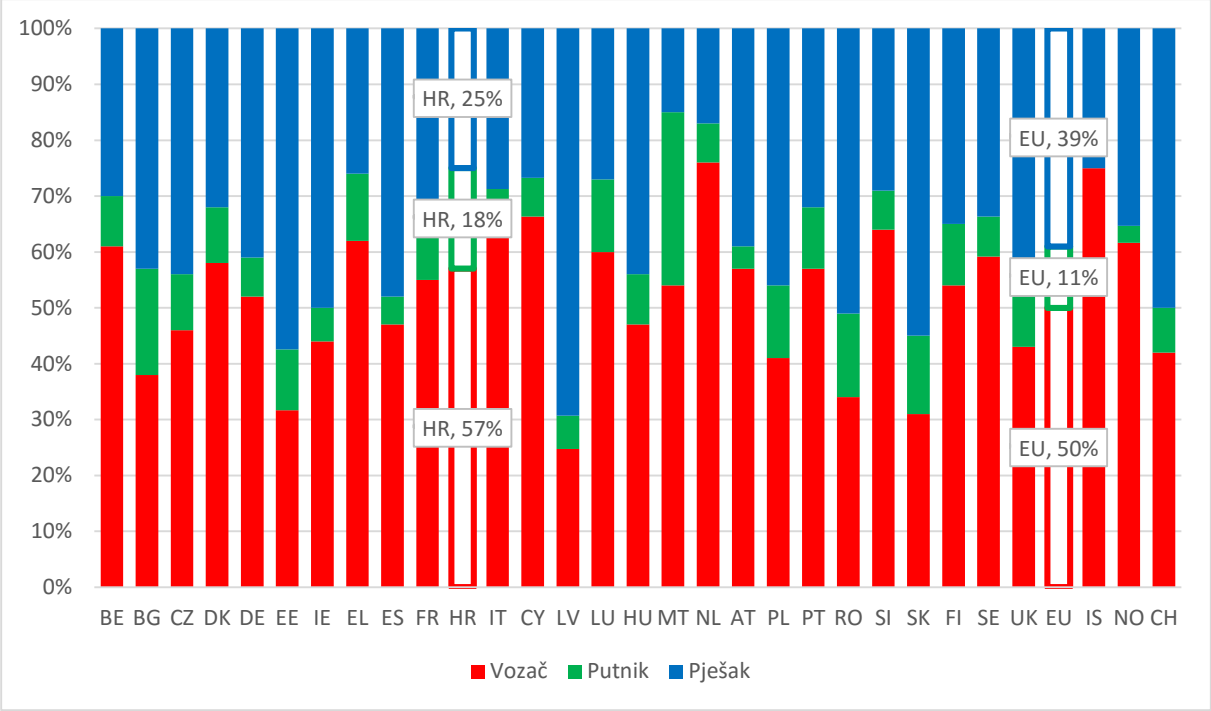

Grafikon 3.8. Prikaz kretanja stopa poginulih sudionika u CPN-u za urbana područja po državama članicama Europske unije, 2013. godina. Izvor: CARE, Eurostat, obrada autora

Za ceste izvan naselja omjeri poginulih sudionika u CPN-u ovisno o kategoriji sudionika u prometu znatno su drugačiji u odnosu na urbana područja te iznose 68% za vozače, 11% za pješake te 21% za putnike. Uspoređujući navedene podatke, najveća je oscilacija u odnosu na ceste izvan naselja upravo kod pješaka (28%), što je posebno indikativno ako uzmemo u obzir da pješaci spadaju u jednu od najugroženijih skupina sudionika u prometu. U ostalim državama članicama Europske unije postotak stradavanja pješaka na prometnicama izvan naselja varira te je najveći u Latviji (26%) te Poljskoj (23%). U Republici Hrvatskoj na prometnicama izvan naselja vozači smrtno stradavaju u postotku od 61%, zatim ih slijede putnici s 30% te pješaci s 10% (15% manje nego u urbanim područjima).

Analiziramo li CPN ovisno o osnovnom stupnju stradavanja sudionika u prometu, možemo zaključiti kako se većina registriranih CPN-a dogodi u urbanim područjima[18], dok se većina onih s teškim tjelesnim ozljedama i pogibeljima registrira na prometnicama u ruralnom području.

Također, CPN-i u urbanim područjima imaju drugačije osobine i karakteristike u odnosu na one nastale u ruralnim područjima i na autocestama. U skladu s time, u urbanim je sredinama znatno

[18] Većina (60%) od registriranih CPN-a koji uključuju lakše/teže tjelesne ozljede nastaju u urbanim gradskim sredinama.

naglašen broj unesrećenih pješaka (37% od ukupnoga broja poginulih u urbanim sredinama) i biciklista (10%). U gradskim područjima također je naglašen udio unesrećenih starijih sudionika u prometu, pri čemu su oko 30% svih smrtno stradalih u CPN-u osobe starije životne dobi, od 65 godina naviše. Glavni razlozi za aktualnu situaciju jesu mnogobrojni nepovoljni socioekonomski (stopa motorizacije, modalna raspodjela, prometno opterećenje, rizično ponašanje u prometu i sl.) i prometni čimbenici (prometna okolina, cestovna infrastruktura) koji dovode sudionike u prometu, posebice one najugroženijih skupina, u nepotrebne rizične (incidentne) situacije u prometu.

3.2.2. Prostorna distribucija cestovnih prometnih nesreća na području Republike Hrvatske

Ako promotrimo statističke podatke CPN-a na razini Republike Hrvatske ovisno o njihovu nastanku, tj. kategorijama i značajkama cesta (Grafikon 3.9.), vidljivo je kako na urbanoj cestovnoj mreži u odnosu na prometnice izvan naselja smrtno stradava u prosjeku 69,07% osoba te 80,48% onih s teškim ili lakim ozljedama u prometu.

Također, s prostornoga gledišta, u ukupnom broju registriranih CPN-a urbana gradska područja značajno prednjače ispred područja izvan naselja, i to s postotnim godišnjim učešćem između 72,5 i 80,2%.

Analizom grafikona može se uočiti nestacionarnost trendova, tj. nepostojanje jasnih trendova navedenih apsolutnih pokazatelja. Ako bi se promatralo samo posljednjih sedam godina, mogao bi se uočiti blagi trend smanjenja učešća poginulih i ozlijeđenih osoba u naseljenim mjestima i izvan njih. Veće stope smanjenja vidljive su na prometnicama izvan naselja – 9,6% manje poginulih te 10,4% manje ozlijeđenih. U urbanim sredinama to smanjenje iznosi 7,2% za poginule te 7,4% za ozlijeđene osobe.

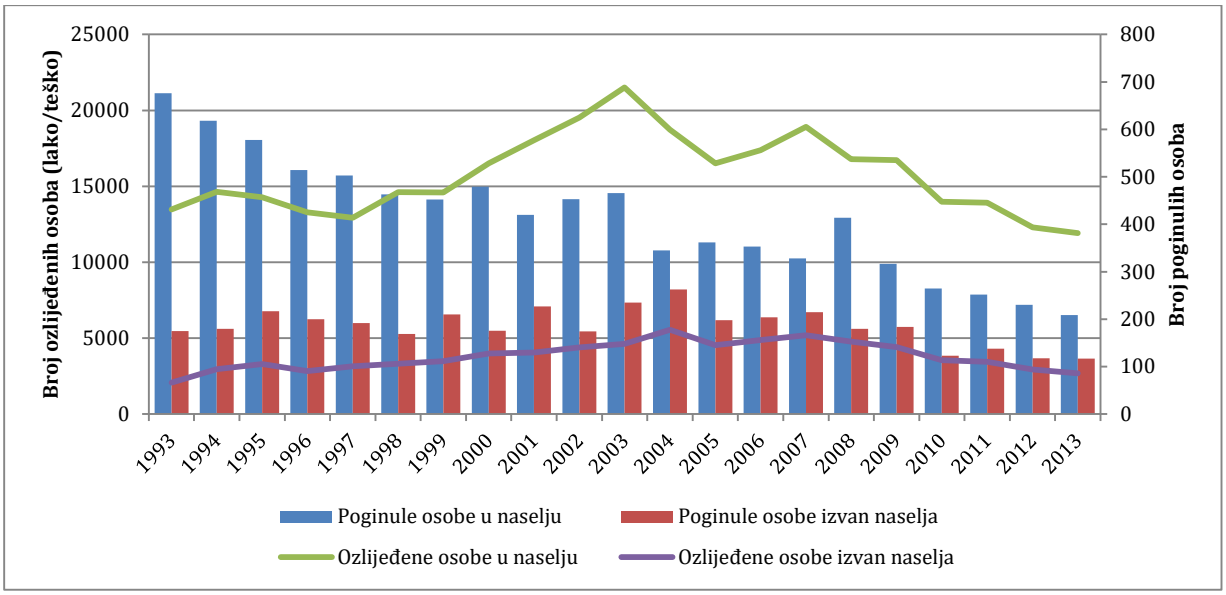

Grafikon 3.9. Prikaz odnosa broja poginulih i ozlijeđenih osoba u CPN-u po mjestu nastanka, u razdoblju 1993. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Promatrajući distribuciju osnovnih kategorija sudionika u prometu ovisno o njihovu svojstvu u trenutku sudjelovanja u prometnoj nesreći (vozači, putnici, pješaci) u urbanom području kroz petogodišnje vremensko razdoblje, mogu se uočiti neka pozitivna kretanja u vezi s razinom sigurnosti, iako su prikazane vrijednosti vrlo visoke u usporedbi s europskim standardima.

Analiza trenda poginulih po svim kategorijama sudionika u prometu pokazuje smanjenje njihova broja. To je vidljivo iz linija linearnih trendova, prikazanih na Grafikonu 3.10. Mali koeficijent determinacije u slučaju broja poginulih vozača upućuje na malu pouzdanost trenda. U slučaju putnika i pješaka poginulih u urbanim sredinama, koeficijent je determinacije veći te nam ukazuje na veću pouzdanost linearnoga trenda.

Kod analize trenda ozlijeđenih sudionika u prometu, za sve promatrane kategorije primjetno je smanjenje njihova broja – 646 ozlijeđenih vozača godišnje manje, 380 ozlijeđenih putnika godišnje manje i 97 ozlijeđenih pješaka godišnje manje. Vrijednosti njihovih koeficijenata determinacije potvrđuju nam pouzdanost procjene trenda.

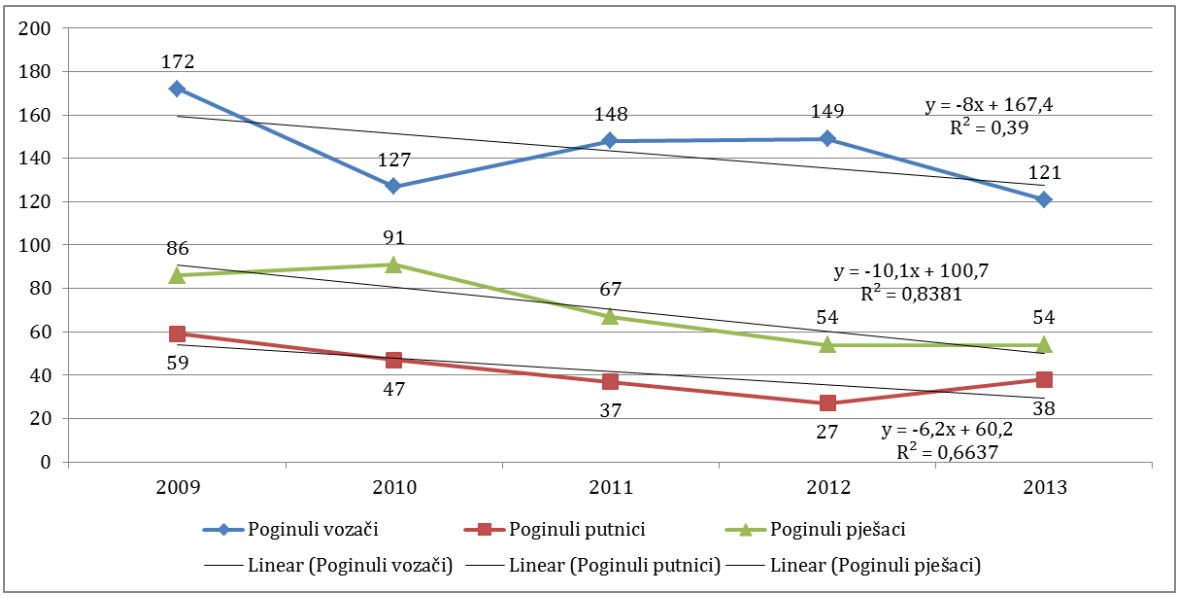

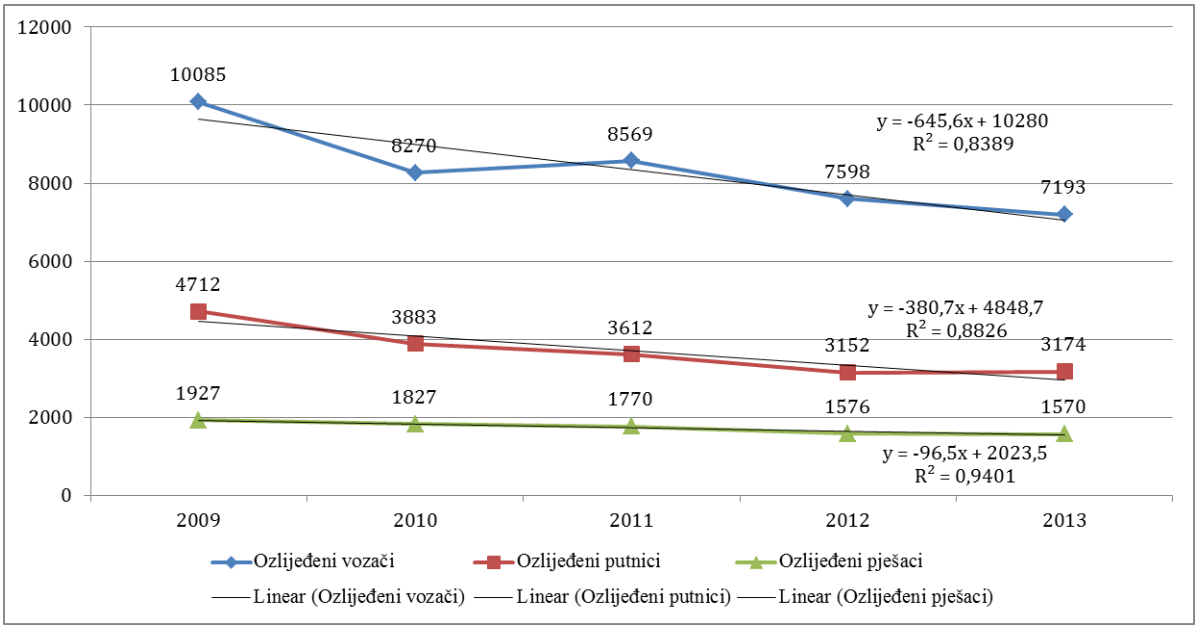

Grafikon 3.10. Prikaz kretanja stopa nastradalih sudionika u CPN-u u urbanom području (u naselju) u razdoblju 2009. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Razlozi su smanjenja stradalih u CPN-u unatoč povećanomu obujmu cestovnoga prometa mnogobrojni. Najviše su zaslužni za smanjenje ukupnoga broja CPN-a te broja stradalih i ozlijeđenih osoba u prometu sljedeći čimbenici: radovi na održavanju i poboljšanju cestovne infrastrukturne mreže (rekonstrukcija postojećih te izgradnja novih, relativno sigurnih cestovnih prometnica), kontinuirano poboljšanje pasivne sigurnosti u motornim vozilima, poboljšanja u zakonodavstvu (u svrhu usklađenja s pravnom stečevinom Europske unije), zabrana konzumacije

alkohola mladim vozačima, pojačana kontrola nošenja zaštitnih kaciga, korištenja sigurnosnih pojaseva i prekoračenja dopuštene brzine, zabrana korištenja mobitela u vožnji, pojačana kontrola u prometu policijskih službenika, poboljšanje kulture sudionika u prometu, efikasnije policijske kontrole i intervencije i dr.

3.3. Kvantitativni socioekonomski i prometni čimbenici

Ubrzan gospodarski i industrijski razvoj u posljednjih nekoliko desetljeća sve više generira porast broja motornih vozila na gradskim prometnicama (*Prilog 2.*), a samim time i broj CPN-a.

Kako bi se kvalitetno upravljalo cestovnim prometnim sustavom te definirale smjernice njegova budućeg razvoja, potrebno je izvesti analizu postojećega stanja te pribaviti sve relevantne informacije. To uključuje pribavljanje podataka o ukupnim troškovima CPN-a, troškovima proizašlim iz pojava prometnih gužvi i zastoja, o osnovnim prometnim pokazateljima kao što su stupanj motorizacije, modalna raspodjela, karakteristike prometnoga toka, te o ostalim relevantnim kvantitativnim socioekonomskim pokazateljima.

U gradovima, ali i u ruralnim područjima CPN se često grupira na određenim kritičnim lokalitetima. Riječ je najčešće o cestovnim raskrižjima, ali isto tako može biti riječ i o zavojima, jednorazinskim željezničko-cestovnim prijelazima, cestovnim pravcima, pješačkim prijelazima, nadvožnjacima, mostovima i sl. Osim pogrešaka vozača, razlog za tako veliku pojavu CPN-a na određenom lokalitetu može biti i loše izvedena cestovna infrastruktura ili okolnost da predstavnici prometne policije nedostatno provode preventivno-represivnu kontrolu.

3.3.1. Stupanj motorizacije

Intenzitet cestovnoga motornog prometa također je jedan od bitnih čimbenika koji može utjecati na učestalost i ozbiljnost pojave CPN-a. Ako usporedimo statističke podatke o CPN-u u odnosu na stupanj motorizacije, odnosno broj registriranih motornih vozila, potvrdit ćemo kako su stope u slabo i srednje razvijenim zemljama svijeta od 10 do 20 puta veće nego u industrijaliziranim zemljama [92]. Porastom stupnja motorizacije takvi će prometno-sigurnosni trendovi i stope postati sve izraženiji.

Izloženost CPN-u osim o stupnju motorizacije ovisi također i o korištenju i namjeni zemljišta te planiranju budućih cestovnih koridora.

Vezano za stupanj motorizacije u razvijenim zemljama svijeta, glavni su elementi koji determiniraju broj CPN-a, osim stupnja motorizacije, svakako i broj stanovništva te udaljenost prometovanja (odnosno prijeđena kilometraža). Drugim riječima, ovisno o porastu broja i trajnosti prometovanja motornih vozila (posebice individualnih motornih vozila) u urbanim, visokokonsolidiranim gradskim područjima raste i broj pojava CPN-a.

Stupanj motorizacije u EU-u, odnosno broj osobnih vozila na 1.000 stanovnika (Grafikon 3.11.) u 2013. godini iznosio je 340 vozila, dok je prosjek EU-a bio 494. To znači da Europska unija ima gotovo jedno vozilo na svaka dva građanina. Prosječni je godišnje prijeđeni put u RH za 2014. godinu iznosio ukupno 14.278,63 km, dok je za kategoriju osobnih automobila iznosio 13.606,89 km.

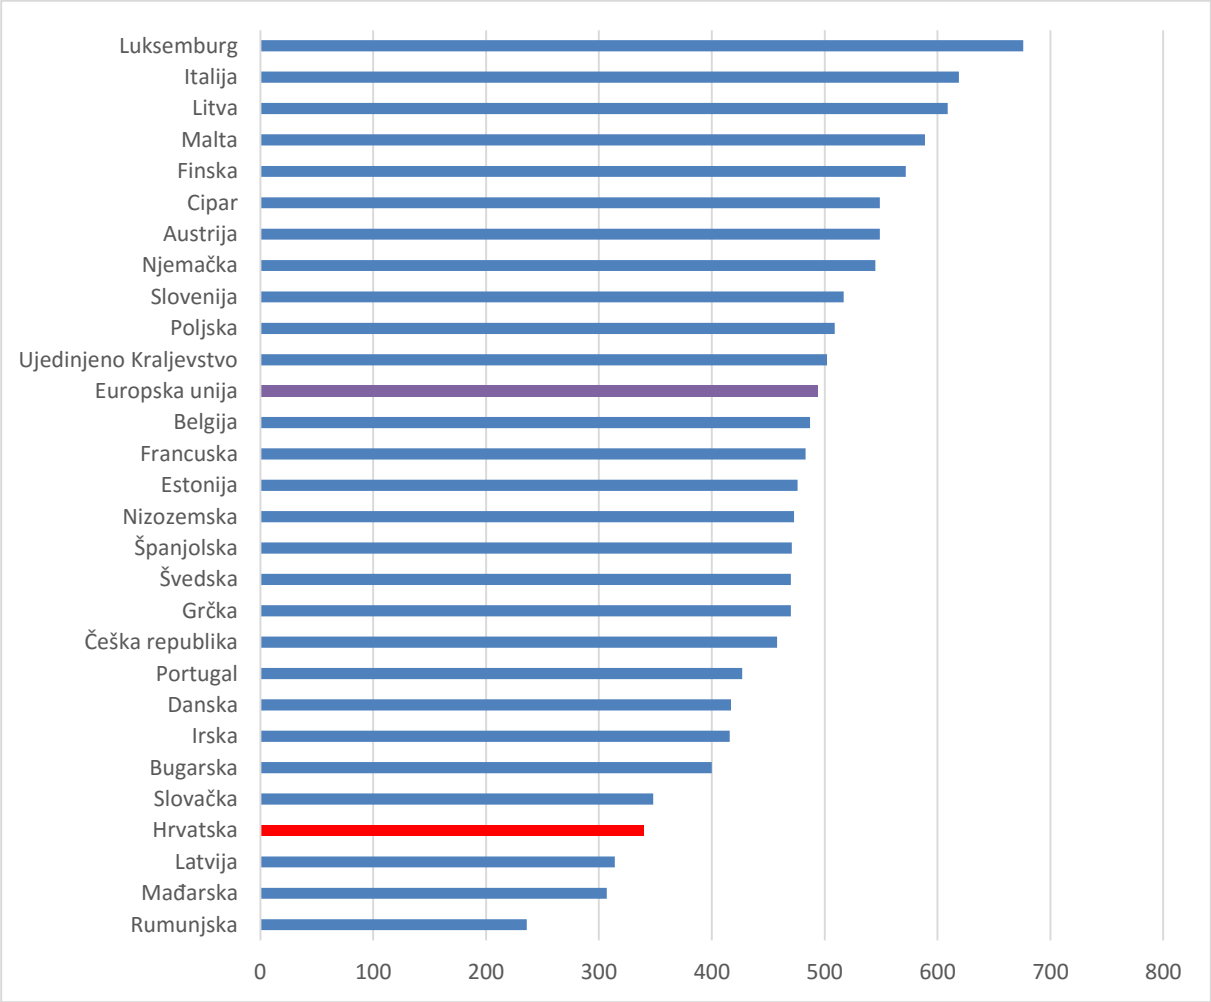

Grafikon 3.11. Stupanj motorizacije u državama članicama Europske unije. Izvor: Eurostat

Grad Zagreb (kao jedinica lokalne samouprave)[19], sa statusom glavnoga i najvećega grada Republike Hrvatske, prostire se na površini od 641,35 km^2 ili 1,13% kopnenoga teritorija Republike Hrvatske. Upravno-teritorijalno podijeljen je na 17 osnovanih gradskih četvrti s ukupno 218 mjesnih odbora te 513 statističkih krugova [93]. Grad ima 6.298 ulica i trgova te 70 naselja, s razvijenom cestovnom mrežom od oko 2,360 km. Proračun Grada Zagreba za 2015. godinu iznosio je 6.850.000.000,00 kuna, a donosi ga Gradska skupština Grada Zagreba u skladu sa Zakonom o proračunu (NN 87/08 … 15/15) te Statutom Grada Zagreba (SGGZ 19/99, 19/01 do 24/13).

Grad je 2001. godine imao 779.145 stanovnika [94], a 2011. unutar administrativnih granica na osnovi broja prijavljenih stanovnika u evidenciji MUP-a obitavalo je 790.017 stanovnika, što čini porast stanovništva od 1,4% (najviše koncentriran u rubnim gradskim četvrtima). (18,44 % ukupnoga stanovništva RH) [95] ili 1.232 st/km^2. Najveća je gustoća naseljenosti u središnjim dijelovima grada – GČ-u Donji grad i Trešnjevka sjever, a najmanja u GČ-u Brezovica.

U Prostornom planu Grada Zagreba [96] prognozirano je da će u 2015. godini grad Zagreb imati oko 340.000 stambenih jedinica te oko 954.000 stalnih stanovnika, odnosno oko 1.000.000 prisutnih (pri prosječnom godišnjem porastu broja stalnih stanovnika od 0,45% u razdoblju 2000. – 2015.), što će izravno utjecati na prometnu situaciju grada.

Usprkos relativno lošemu standardu građana u odnosu na zapadno- i srednjoeuropske gradove, Grad je Zagreb zbog ubrzane urbanizacije i pozitivnoga socioekonomskog statusa njegovih građana zabilježio značajan porast individualnoga motornog prometa[20] sve do unatrag 5-6 godina, kada ga je, kao uostalom i većinu europskih gradova i zemalja, pogodila jaka recesija. Otada je individualni motorni promet u stanovitoj stagnaciji, međutim još uvijek je vrlo intenzivan. Za navedenu problematiku indikativan je i podatak koji ukazuje na to da je u razdoblju od 2000. do

[19] Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi (NN 33/01, …, 19/13) Grad je Zagreb određen kao posebna i jedinstvena teritorijalna i upravna cjelina, kojoj se ustrojstvo uređuje Zakonom o Gradu Zagrebu (Narodne novine 62/01, …, 119/14). Predmetnim zakonom određeno je da Grad Zagreb ima položaj županije, a u okviru svojega samoupravnog djelokruga obavlja poslove iz djelokruga županije i iz djelokruga grada te druge poslove u skladu sa zakonom. U skladu s navedenim, Grad djeluje istovremeno kao jedinica područne (regionalne) i lokalne samouprave.

[20] Posljedice tako nagloga povećanja motorizacije vrlo su nepovoljne po uvjete života u gradu, osobito zbog zagađenja atmosfere, povećanja broja cestovnih prometnih nesreća i višesatnih prometnih zagušenja, devastacije ambijenta, štetnih ispušnih plinova, buke, vibracije, prekomjernoga korištenja naftnih energenata i dr.

2011. godine porast broja motornih cestovnih vozila iznosio znatnih 39%, a porast broja osobnih automobila u promatranom je periodu iznosio 35%.

U skladu s time, iz sljedećega tabličnog prikaza (Tablica 3.1.), o kretanju stope motorizacije na području Grada Zagreba, možemo iščitati kako je do 2009. godine prisutan linearan rast broja registriranih motornih vozila[21] (u razdoblju od 2002. do 2009. broj registriranih motornih vozila linearno raste po prosječnoj stopi od 4,8% godišnje), dok u razdoblju 2009. – 2012. slijedi stagnacija i pad po stopi od 1,5%, što je moguće pripisati recesijskim, odnosno gospodarskim prilikama na nacionalnoj i lokalnoj razini.

Sve to rezultira smanjenim korištenjem osobnih automobila (zbog smanjene platežne moći i rasta cijena naftnih energenata) te rastom nemotoriziranoga i javnoga gradskog prijevoza prilikom ostvarivanja dnevnih putovanja. Ujedno, iz tablice je vidljivo da stopa rasta stanovnika u Gradu Zagrebu stagnira, odnosno da je riječ o neznatnoj stopi rasta stanovništva, koja se na godišnjoj razini kreće ispod 0,4%.

Tablica 3.1. Stupanj motorizacije u Gradu Zagrebu

	2002.	**2003.**	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**
Registrirana motorna vozila	317090	336327	352447	367098	384512	399283	414353	409080	400906	395391	342405
Stanovništvo	779145 (2001)	779945	781632	783455	784211	785866	788095	790298	792860	792875	793057
Stupanj motorizacije (broj stan./reg. moto. vozila.)	2,45	2,31	2,21	2,13	2,04	1,97	1,90	1,93	1,98	2,01	2,32
Stupanj motorizacije (reg. moto. vozila/1.000 stanovnika)	406	431	450	468	490	507	525	516	505	498	432

Izvor: Statistički ljetopisi grada Zagreba (od 2005. do 2014.) i Ministarstvo unutarnjih poslova – Policijska uprava zagrebačka (2013.), obrada autora

[21] Prema podatcima MUP-a Policijske uprave zagrebačke, vidljivo je kako su stanovnici grada prije pojave recesijskih prilika, odnosno do 2009. godine prosječno na godišnjoj razini registrirali oko 15.000 novih osobnih vozila.

Vezano uz stupanj motorizacije, koji se mjeri omjerom broja stanovnika i registriranih motornih vozila, možemo iščitati da na jedno vozilo dolazi 2,32 stanovnika, tj. u prosjeku najmanje svaki drugi stanovnik grada posjeduje motorno vozilo.

Broj vozila registriranih za motorni promet u gradu Zagrebu u 2012. godini iznosio je 342.405[22], što s obzirom na broj stanovnika čini stupanj motorizacije (omjer broja žitelja i broja registriranih motornih vozila) od 432 vozila/1000 stanovnika [93], a koji je izjednačen ili čak i nešto veći od stupnja motorizacije europskih gradova i regija (≈ 1 : 2,5) [97].

Komparirajući navedene pokazatelje s veličinom gradskoga proračuna i visinom bruto domaćega proizvoda (BDP-a) po glavi stanovnika (Grafikon 3.12.)[23] te s relevantnim socioekonomskim pokazateljima razvoja unutarnjih aktivnosti i općih gospodarskih kretanja Grada Zagreba, možemo konstatirati kako je kretanje broja registriranih motornih vozila u korelaciji s pokazateljima općega standarda Grada. Navedena tvrdnja može se potkrijepiti statističkim podatcima koji pokazuju snažan i uravnotežen rast gradskoga proračuna u periodu između 2000. i 2009. po stopi od 7,7% godišnje, dok je u sljedećem vremenskom razdoblju, od 2009. do 2011. godine, vidljiv njegov pad po stopi od 2,6%. Nadalje, iz navedenoga prikaza vidljivo je kako se gradski proračun u 2011. smanjio praktički na razinu proračuna iz 2007. godine, što se neizravno također snažno odrazilo i na sve stavke proračuna koje se odnose na razvoj prometnoga sustava u gradu Zagrebu te na održavanje postojeće te izgradnju nove prometne i komunalne infrastrukture, naznačene u *Programu radova na području prometa i komunalnog gospodarstva u Gradu Zagrebu* Gradskoga ureda za prostorno uređenje, izgradnju grada, graditeljstvo, komunalne poslove i promet.

[22] U ukupnom broju registriranih motornih vozila osobni automobili dominiraju s 82% (podatak iz 2012.), koji ujedno najviše doprinose protočnosti prometnih tokova u Gradu Zagrebu. Nadalje, približno ¾ motornih vozila je u privatnom vlasništvu, a oko ¼ u vlasništvu poslovnih subjekata.

[23] Za 2011. i 2012. godinu ne raspolaže se agregatnim podacima po županijama, ali se očekuje da će stopa rasta za Grad Zagreb i dalje biti pozitivna (sa stopom rasta oko 2%) s obzirom na nešto povoljnija gospodarska kretanja u odnosu na prethodnu godinu.

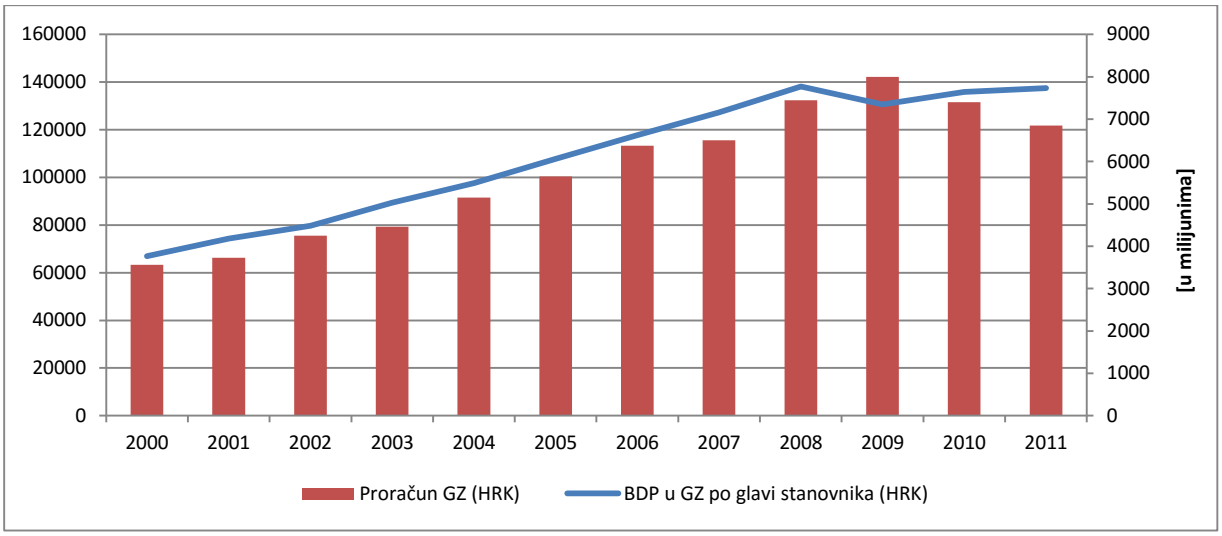

Grafikon 3.12. Kretanje stopa proračuna Grada Zagreba i bruto domaćega proizvoda (BDP-a) po glavi stanovnika u Gradu Zagrebu

Izvor: Statistički ljetopisi Grada Zagreba (od 2005. do 2014.), obrada autora

3.3.2. Modalna raspodjela

Modalna raspodjela putovanja (raspodjela po načinima prijevoza) predstavlja omjer različitih prijevoznih modova u odnosu na ukupan broj putovanja, od ishodišta do odredišta. [98]. Čimbenici su koji utječu na odabir prijevoznoga moda mnogobrojni – dostupnost odnosno vlasništvo vozila, struktura kućanstva, prihodi, rezidencijalna gustoća stanovanja, namjena putovanja, odabir vremena za putovanje, troškovi i mogućnosti parkiranja vozila, pouzdanost, sigurnost i dr. Rizik od pojave CPN-a značajno varira između pojedinih modova, odnosno oblika prijevoza, pri čemu svi oblici individualnoga prijevoza predstavljaju značajno veći rizik od pojave CPN-a u odnosu na javni prijevoz. Rizik od zadobivanja tjelesnih ozljeda posebice je naglašen kod najugroženijih skupina sudionika u prometu – pješaka, biciklista, motociklista. Prema tomu, preraspodjela učešća javnoga gradskog prijevoza u odnosu na individualni, posebice u urbanim sredinama, može značajno doprinijeti smanjenju ukupnoga broja unesrećenih u prometu.

U proteklih 30-ak godina velik je broj studija [99, 100] imao zadatak analizirati povezanost obilježja gradova i njihovih modela mobilnosti. Autori studija svoje su hipoteze potvrđivali uglavnom utvrđujući odnos između namjene zemljišta, određenih socio-ekonomskih uvjeta i mobilnosti primjenom regresijske analize. Namjena i organizacija zemljišta može značajno djelovati na broj CPN-a, pogotovo ako utječe na prometno opterećenje, modalnu raspodjelu putovanja te distribuciju prometa duže cestovne mreže.

U posljednjih desetak i više godina Grad Zagreb i njegovo okruženje bilježe iznimno velik porast motorizacije, što je rezultat povećane prijevozne potražnje i količine prometa.

Dosadašnja snimanja prometnoga opterećenja na mreži cestovnih prometnica nisu provođena kontinuirano i sustavno. Cjelovita brojenja prometa obavljena su u sklopu izrade sveobuhvatnih prometnih projekata odnosno studija, kao što su Generalni prometni plan iz 1978. i Prometna studija Grada Zagreba (SGGZ 7/03) iz 1999. [101], a za što je bila angažirana engleska projektantska konzultantska tvrtka *MVA Consultancy*.

Manja brojenja i prometne analize rađene su u postupku izrade pojedinih prometnih projekata, vezano za izgradnju ili rekonstrukciju određenih cestovnih prometnica ili raskrižja, te u sklopu izrade tehničke dokumentacije za instaliranje semaforskih uređaja i opreme, na temelju čega je dobivena okvirna slika pojedinih karakteristika različitih modova cestovnoga prijevoza.

U vremenskim presjecima između pojedine studije ili pojedinoga prometnoga projekta prometno stanje nije registrirano, niti ga se može pouzdano procjenjivati jer su vremenske distance od jednoga registriranog do sljedećega registriranog stanja prilično velike, nerijetko veće od 10 godina.

U anketi domaćinstava za potrebe navedene prometne studije Grada Zagreba utvrđeno je da se od svih dnevnih putovanja u gradu 25,4% putovanja obavlja pješice, 36,8% javnim prijevozom, 37,1% automobilom i 0,7% biciklom. Ako promatramo modalnu raspodjelu samo s motoriziranim modovima prijevoza, možemo ustvrditi da je udio individualnoga i javnoga prijevoza u gradu Zagrebu gotovo ravnopravan. (Slika 3.1.).

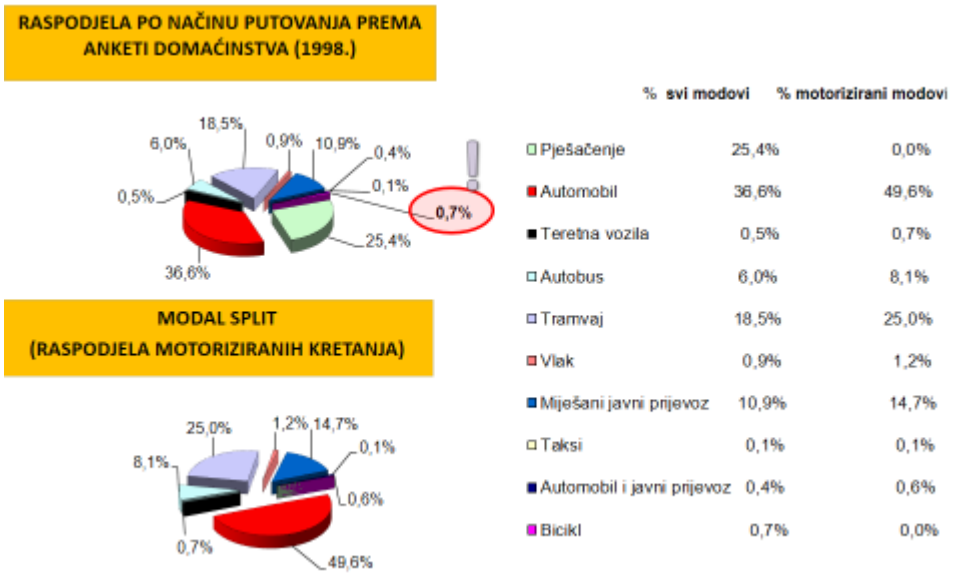

Slika 3.1. Prikaz učešća pojedinih modova u ostvarenim putovanjima

Izvor: Prometna studija grada Zagreba, MVA Traffic Engineering & Planning (1999.), obrada autora

Ako prethodne podatke usporedimo s rezultatima dobivenima u terenskim istraživanjima provedenima u sklopu projekta Civitas ELAN 2009. godine (ispitivanja su ponovljena i tijekom 2012. godine [102] u središnjem dijelu Zagreba na uzorku od 500 ispitanika, prikazanim u Grafikonu 3.13.), možemo uočiti kako u proteklom desetogodišnjem razdoblju javni prijevoz stagnira, što je nepovoljna pojava, dok su individualni motorni i nemotoriziranih transportni modovi u porastu.

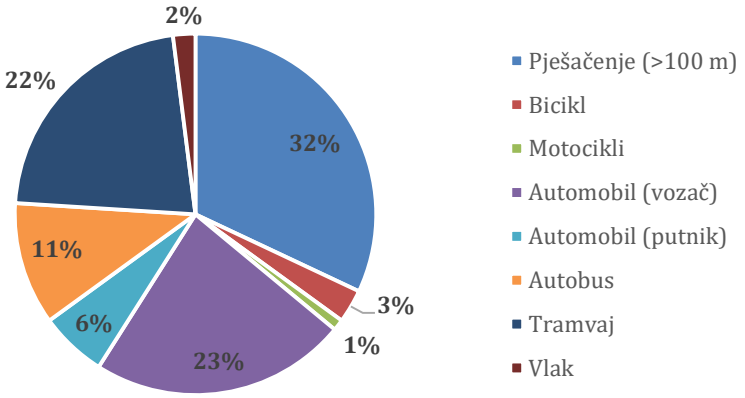

Grafikon 3.13. Modalna razdioba u svim putovanjima

Izvor: Projekt Civitas ELAN (2012.)

Prilikom analize podataka o modalnoj raspodjeli putovanja u gradovima Europske unije (Grafikon 3.14) usporedivim po broju stanovnika i urbanizacijom sa Zagrebom, putnici se mogu podijeliti u četiri kategorije: privatni automobili (vozači i putnici), korisnici javnoga prijevoza, vožnja biciklom i pješačenje. Urbana modalna raspodjela izračunata je za svaki grad kao postotak ukupnoga zbroja putovanja za svaku kategoriju. Za razliku od nekoliko gradova u kojima automobili dominiraju učešćem u odnosu na ukupan broj putovanja, Zagreb po svojim udjelima pojedinih promatranih kategorija predstavlja prosjek, te nema značajnijih odstupanja u odnosu na ostale analizirane gradove.

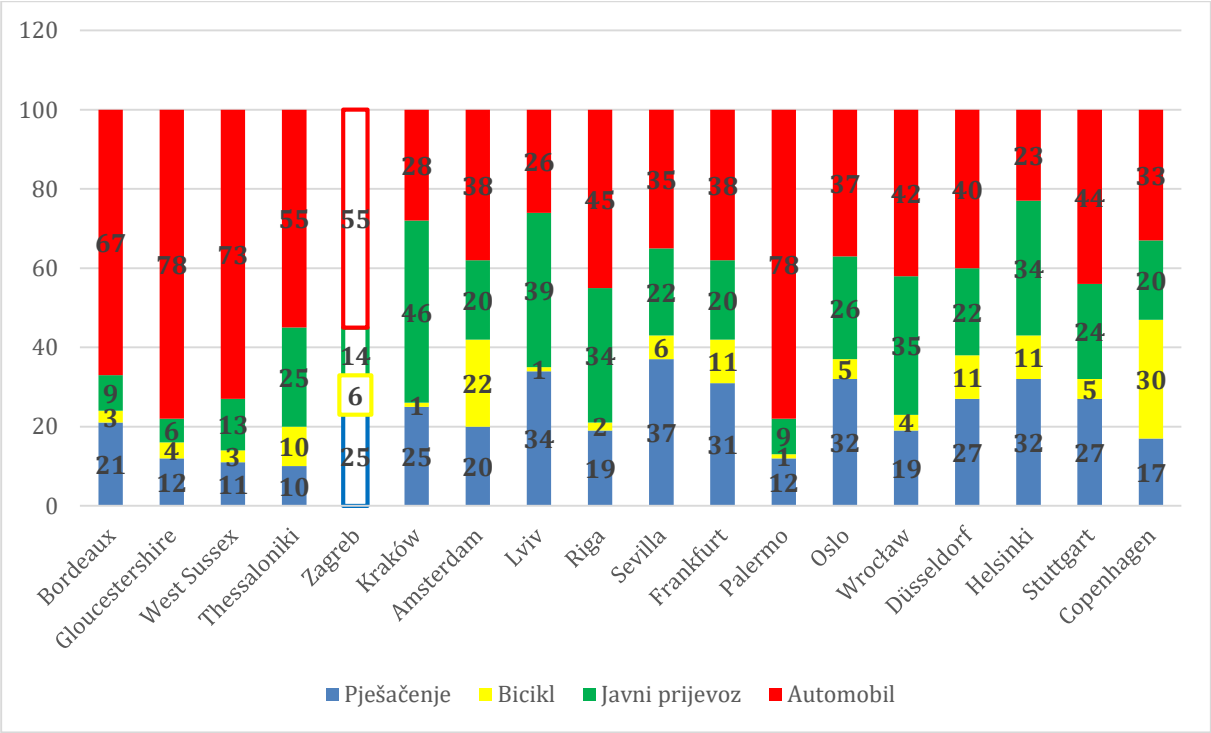

Grafikon 3.14. Komparativni pregled modalne raspodjele putovanja u gradovima Europske unije i Zagreba, Izvor: Projekt EPOMM

U gradovima je odabir modela putovanja na posao, odnosno modalna raspodjela između javnoga i privatnoga prijevoza usko povezan s ponašanjem građana. Osobni automobili vjerojatno će imati veću razinu prioriteta za korištenje prilikom odlaska na posao nego što je to slučaj s ostalim alternativnim, negospodarskim aktivnostima.

Navedene činjenice vitalno utječu na funkcionalnost i sigurnost prometnoga sustava, a time i na svakodnevni život u gradu, koji je karakteriziran nižom razinom uslužnosti te velikim opterećenjem glavnih cestovnih koridora [103].

S obzirom na navedeno, aktualna modalna raspodjela između javnoga i individualnoga prometa u Gradu Zagrebu procjenjuje se na odnos 50 : 50, s obzirom na to da je u međuvremenu došlo do smanjenja cestovnoga motornog prometa i broja registriranih osobnih vozila, čime se ta procjena čini realnom.

Nadalje, tijekom 2016. godine Sektor za promet namjerava provesti i odgovarajuće prometno istraživanje (*Prometni model Grada Zagreba*) kako bi se dobili referentni iznosi (u skladu s jedinstvenom metodologijom prikupljanja i obrade podataka) te osvježilo prethodne podatke. Potrebu uvođenja kontinuiranoga brojenja prometa naglašava vrlo stroga metodologija i kriteriji vezani uz dodjelu financijske potpore strukturnih fondova EU-a, prilikom čega se traže ažurni podatci o prometu, ne stariji od 4 godine. Također je prema zahtjevu Europske komisije obvezno kontinuirano pratiti stanje u prometu zbog procjene stupnja zagađenosti okoliša.

Jedan od najznačajnijih razloga za uvođenje kontinuiranoga praćenja prometnih karakteristika na prometnicama Grada Zagreba jest potreba da se registriraju promjene u prometu koje su posljedica nekih od provedenih regulativnih i organizacijskih mjera ili infrastrukturnih zahvata unutar prometnoga sustava. Na temelju podataka kontinuiranoga brojenja prometa na nekoliko tipičnih presjeka mogla bi se izraditi kvalificirana procjena stanja i promjena na cjelokupnoj mreži u slučaju promjena izazvanih iz okruženja i u području drugih djelatnosti (primjerice u slučaju poskupljenja cijene benzina i dizelskoga goriva, promjene cijena karata u javnom prijevozu i sl.).

3.4. Zaključna razmatranja

Unatoč kontinuiranomu padu broja registriranih CPN-a te stradalih sudionika u prometu unatrag posljednjih desetak godina, prema relativnomu indeksu sigurnosti RH, apsolutni je broj CPN-a i dalje velik, te stoga RH i dalje ima jednu od najviših stopa smrtnosti i ozlijeđenih u prometnim nesrećama u EU-u, posebice komparirajući podatke s onima razvijenijih zemalja Unije. Komparativnim pregledom statističko-vremenskih podataka u vezi s CPN-om te brojnih aktualnih aktivnosti i mjera koje pojedine države poduzimaju u vezi s njihovim anuliranjem utvrđuje se kako još uvijek postoji prostor za unapređenje. Za prikazane razlike u stopama različitih kategorija CPN-a zaslužni su mnogobrojni čimbenici koji utječu na razinu sigurnosti cestovnoga prometa, kao što su opće ekonomske prilike u državama, modalna raspodjela i mobilnost stanovništva (prijeđeni vozilo/km i stupanj motorizacije), gustoća cestovne mreže, tehnološka razina izvođenja i dizajna cestovne infrastrukture, zakonske legislative (posebice u području određivanja granice dopuštene doze konzumiranja alkohola), mjere kontrole neprimjerenih i prevelikih brzina, korištenje sigurnosnih pojaseva te zaštitnih kaciga za motocikliste, organizacija službi hitne

medicinske pomoći te općenito usmjerenje na poboljšanje sigurnosti motornih vozila (starost voznoga parka) i prometnoga sustava u cjelini [104].

Nakon analize čimbenika sigurnosti cestovnoga prometa u cilju njegova unapređenja i implementacije optimalnih mjera i aktivnosti za njegov buduću veću efikasnost koji će u nastavku biti podrobnije naznačeni.

Na temelju službenih prometnih statistika tijekom posljednjih je godina vidljivo da se najvažniji čimbenici za sigurnost cestovnoga prometa mogu podijeliti na sigurnosno ponašanje sudionika u prometu „čovjek“ (u literaturi se navodi da taj čimbenik imaj utjecaj u visini od 60%), sigurnosna stanja vozila te sigurnosno stanje prometnica i njihove okoline (4 do 12%, u kombinaciji sa sudionicima u prometu „čovjek“ preko 30%), a upravo je na području interakcija navedenih podsustava najpotrebnije provesti daljnja istraživanja s obzirom na to da je u praksi vidljivo da više od jednoga navedenog čimbenika pridonosi pojavi CPN-a (Slika 3.2.). Kao što je prikazano na Slici 3.2., tri grupacije čimbenika, kao i međusobne interakcije (područja preklapanja) među njima variraju u jačini njihova doprinosa pojavi CPN-a. Najjači je čimbenik „čovjek“ (93%), a zatim slijede cestovni čimbenici (34%), pri čemu jačina njihove međusobne interakcije iznosi 26%.

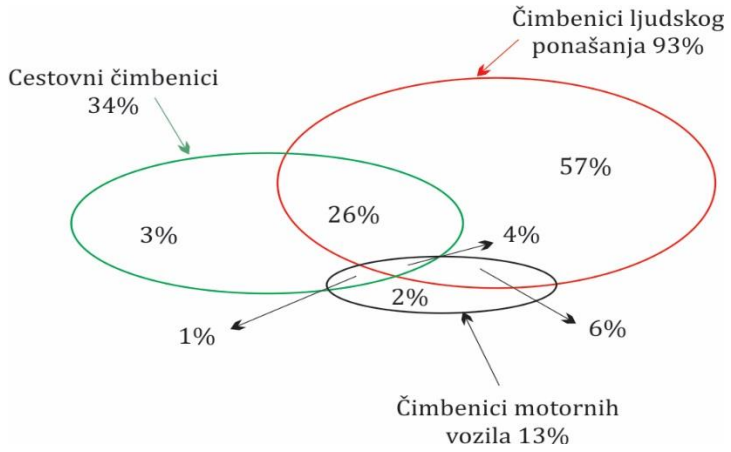

Slika 3.2. Čimbenici pojave cestovnih prometnih nesreća

Izvor: PIARC, Road accident investigation guidelines for road engineers (2007.)

Čimbenik koji se nalazi u grupaciji ljudska ponašanja, a koji znatno doprinosi pojavi većega broja CPN-a svakako je rizično ponašanje vozača, posebice izraženo u urbanim područjima. Za navedeno je ponajviše zaslužna nedovoljna razina prometne kulture pojedinih grupa sudionika u prometu te nepovoljno prometno okruženje. Stoga sudionici u prometu trebaju biti adekvatno educirani i informirani o ključnim elementima sigurnosnoga ponašanja kako bi ih se odvratilo od ponavljanja rizičnih obrazaca ponašanja u budućnosti.

Osim segmenta sudionika u prometu „čovjek“, u današnje vrijeme velika se pažnja posvećuje i stanju cestovne infrastrukture u trenutku nastanka CPN-a, te je stoga nužno povećati razinu usluge na cestovnim prometnicama, prvenstveno unapređenjem postojećih standarda sigurnosti cestovnih prometnica. To je moguće ostvariti pojačanim naporima sudionika koji su zaduženi za gospodarenje cestovnim prometnicama i njihovo održavanje, koji bi u svojim svakodnevnim aktivnostima trebali maksimalno uvažavati sva saznanja o ponašanju cestovnih korisnika kako bi se izbjeglo stvaranje novih potencijalno opasnih lokaliteta na prometnicama te još brže i kvalitetnije sanirala takva postojeća mjesta.

Sigurnosna prednost proizlazi iz poboljšanja prilikom projektiranja cestovne mreže i cestovnih objekata, kvalitete podloge, smanjenja propadanja i deformacija kolnika tijekom nepovoljnih uvjeta [105], kvalitetnije prometne regulacije te manje zbunjujuće prometne signalizacije i opreme. Znatan je napredak postignut i u smjeru poboljšanja sigurnosti i nesmetanosti odvijanja cestovnoga prometa u urbanim sredinama, posebice s naglaskom na mjere i aktivnosti implementiranja u svrhu smanjenja brzine prometovanja motornih vozila, čime se istodobno ostvaruje povoljnije sigurnosno okruženje za sudionike u prometu, posebice one najugroženije. Potrebno je također napomenuti da se, bez obzira na to što u tehnološkoj razini upravljanja prometom zaostajemo za proaktivnim državama Europe, mora konstatirati da je opremljenost naših prometnica signalnom opremom i uređajima na primjerenoj razini i da bi, kada bi to bio presudan ili jedini čimbenik utjecaja, sigurnost sudionika u prometu trebala biti znatno veća.

Aspekti projektiranja i opremljenosti cestovnih prometnica imaju veliki utjecaj na razinu prometne sigurnosti, pogotovo ako se u obzir uzme činjenica da je mogućnost pogrešaka sudionika u prometu izraženija što je sustav cestovne mreže složeniji. Adaptivna cestovna infrastruktura, prilagođena sigurnosnim zahtjevima te limitiranim ljudskim sposobnostima, može značajno smanjiti učestalost i ozbiljnost CPN-a.

Jačanje obrazovnoga sektora i uključivanje šire javnosti nužni su čimbenici u reduciranju problema CPN-a. Provedba edukativnih kampanja te pripadajućih aktivnosti znatno može poboljšati razinu svijesti građana o CPN-u. Osim državnih institucija, koje imaju obvezu provoditi prometnu edukaciju građana, ona bi trebala postati dužnost i pri mnogim privatnim poduzećima i ustanovama te javnim organizacijama. U ovom je dijelu također važno naglasiti da je za kvalitetno vođenje sustava sigurnosti u urbanim sredinama, osim s inženjerima, suradnja potrebna i s ostalim subjektima koji su zaslužni za kreiranje urbanoga okruženja.

Shvativši da je CPN problem preventivne i multidisciplinarne prirode, većina razvijenih zemalja provodi različite politike i mjere za njihovo smanjenje. To uključuje represivnu provedbu, obrazovanje, osposobljavanje i kontinuirana inovativna inženjerska rješenja i poboljšanja.

4. BAZE PODATAKA O CESTOVNIM PROMETNIM NESREĆAMA

U području istraživanja i razvoja sigurnosti cestovnog prometa važan se dio odnosi na analizu i razumijevanje rizičnih čimbenika koji pridonose uzročnosti CPN-a, a čime se kasnije ostvaruje mogućnost za razvoj i vrednovanje ciljanih protumjera i aktivnosti kako bi se broj i oblik CPN-a u budućnosti umanjio te kako bi se ostvarilo kvalitetno praćenje i predviđanje njihovih trendova.

Informacije dobivene kroz registar prometnih nesreća temelje se na standardiziranim pisanim obrascima (Upitnicima) o prometnim nesrećama (Prilog 3. – Primjer Republika Hrvatska). Njih popunjavaju djelatnici prometne policije na mjestu događaja, a ako to nije moguće, neposredno poslije uviđaja (na temelju vođenih zabilješki), te predstavljaju jedan od osnovnih spisa u vezi s uviđajem prometne nesreće, odnosno prikazuju sažetak informacija o njoj. U svim zemljama EU-a prikupljeni se podatci zatim šalju jednoj ili više središnjih ustanova (Statistički zavod, znanstvene ustanove, Ravnateljstvo policije, Upravama za ceste, Nacionalnom vijeću ili Agenciji za sigurnost cestovnog prometa) koje su zadužene za njihovo vođenje i analizu.

Podatci uključuju različite informacije (varijable) koje opisuju mjesto nastanka prometne nesreće te okolnosti koje su joj prethodile (npr. vrijeme nastanka prometne nesreće, tip, lokaciju, broj poginulih/ozlijeđenih osoba, tip sudara, topografiju i stanje kolnika, tip i lokacije cestovne prometnice i sl.).

Unutar obrasca za statističku analizu podataka o CPN-u katkada se nalazi i kratki opis nastanka cestovne prometne nesreće, onako kako ga interpretiraju djelatnici prometne policije. Sadrži akcije koje su joj prethodile, a u nekim su slučajevima iskazane i namjere i ponašanje sudionika u nesreći te očevidaca.

Osim osnovnih stavaka, u izvješću se ovisno o vrsti CPN-a nalazi i čitav niz daljnjih stavaka, koje kasnije pomažu u utvrđivanju činjeničnoga stanja i okolnosti složenih CPN-a. To se prije svega odnosi na GPS koordinate mjesta nesreće, ortofoto dokumentaciju, fotodokumentaciju, dijagram kolizionih točaka, izjave ispitivača te možebitnih očevidaca koji često pružaju značajan izvor informacija.

Na temelju takvih podataka provode se raznovrsne analize i zaključci u svezi s nastankom CPN-a, pri čemu se ovisno o vrsti pretrage ulazni parametri međusobno razlikuju.

S obzirom na to da u posljednje vrijeme traženi uvjeti (zahtjevi) u vezi s analizom CPN-a postaju sve kompleksniji, tako i pripadajući informacijski sustavi i tehnike postaju sve složenije, te pritom moraju biti u mogućnosti podržavati česte nadogradnje i restrukturiranja prikupljenih ulaznih

informacija (opsežna i intenzivna pretraživanja i ažuriranja podataka), kako u području samih baza podataka tako i same korištene aplikacije.

Sam proces prikupljanja navedenih podataka u većini je slučajeva je sljedeći: nakon nastanka prometne nesreće, neovisno o njezinoj vrsti i težini, nužno je prvenstveno osigurati mjesto nesreće kako bi se kvalitetno i sigurno mogli izuzeti svi relevantni tragovi proizašli iz njezina nastanka, a što kasnije bitno pomaže pri rekonstrukciji događanja. Kod težih oblika CPN-a na temelju istražne dokumentacije i sudskih spisa detaljno se analiziraju mjesto i vrijeme nastanka nesreće (karakteristika i stanje cestovne infrastrukture te cestovnih objekata u blizini, stanje i položaj postojeće prometne opreme i signalizacije), zadobivene ozljede unesrećenih sudionika, tragovi i oštećenja na vozilima koja su sudjelovala te drugi relevantni elementi (intenzitet i struktura prometa, ponašanje sudionika u prometu i dr.). Na temelju detaljne i komparativne analize svih raspoloživih materijalnih dokaza utvrđuju se osnovni uzročnici CPN-a, način kretanja sudionika, izvodi se prostorno-vremenska analiza te analiza mogućnosti izbjegavanja nastanka CPN-a. Na temelju navedenoga u konačnici se definiraju najvažniji propusti koji su doprinijeli nastanku, kao i posljedicama CPN-a.

4.1. Metode prikupljanja podataka

4.1.1. Podatkovne podloge o cestovnim prometnim nesrećama

Sa statističkoga gledišta cestovne su prometne nesreće, kao i njihove posljedice slučajni događaji, a s obzirom na ukupan broj prijeđenih kilometara motornih vozila relativno su rijetke pojave.

Iako je jedan događaj gotovo nemoguće prostorno i vremenski predvidjeti, zbir takvih događaja može se ponašati u savršeno predvidljivom smjeru uz prethodno precizno definirane matematičko-statističke odnose [106].

Kako bi prometni stručnjaci i znanstvenici iz područja sigurnosti cestovnoga prometa uspješno proveli svoja istraživanja i potvrdili radne hipoteze, moraju raspolagati s velikim količinama kvantitativnih informacija i pribaviti statistike iz različitih izvora. Njihovom obradom dobivaju informacije ključne za shvaćanje i procjenu socijalnih i ekonomskih troškova proizašlih iz CPN-a, te su u stanju predstaviti i uputiti sigurnosne planove donositeljima odluka na temelju kvalitetno identificiranih čimbenika rizika i prioritetnih problemskih područja, kako bi se pojava CPN-a mogla spriječiti ili barem smanjiti stopa smrtnosti sudionika u njima.

Stoga analiza CPN-a za istraživače prvenstveno uključuje intenzivno pretraživanje i pronalaženje svih relevantnih informacija iz zapisa o prometnim nesrećama i *Upitnika o prometnim nesrećama*.

Unapređenje prometne statistike i analize te implementacija pouzdane statističke baze podataka o CPN-u (koja mora posjedovati takve osobine da je ljudski operateri mogu jednostavno i jednoobrazno prepoznati i interpretirati) predstavljaju nezamjenjiv alat za objektivno istraživanje i procjenu sigurnosti cestovnoga prometa te detektiranje njegovih ključnih problema.

Također, u skladu s nastalim specifičnim problemskim situacijama, zapisi o CPN-u se kontinuirano nadograđuju (proširuju) novim ulaznim podatcima, te se time i sam informatički podsustav koji je u nadležnosti prometne policije sustavno unapređuje i razvija kako bi se dugoročni strateški planovi mogli kvalitetnije strukturirati kroz buduće nacionalne programe sigurnosti.

Jedan od relevantnih načina identificiranja i klasificiranja čimbenika koji najviše doprinose nastanku CPN-a, kao i njihovih karakteristika i posljedica, jest upravo eksploatacija dostupnih retrospektivnih zbirnih podataka i zapisa o CPN-u.[24]

Razlog za njihovo korištenje leži u činjenici što se kumulativni učinci određenih mjera za povećanje razine sigurnosti koje implementiraju kreatori prometne politike tijekom vremena mogu adekvatno mjeriti i testirati.

Reduciranje broja CPN-a traži integrirani pristup u kojem je nužno odgovoriti na pitanja o okolnostima koje su prethodile pojavama incidentnih prometnih situacija, kao i samim njihovim karakteristikama i lokacijama gdje se učestalo događaju.

Iako informacije i izvedene kategorijske varijable o CPN-u koje osiguravaju mjerodavne institucije imaju svoju važnost te predstavljaju kvalitetan temelj za daljnja istraživanja, one su često preopćenite te neadekvatne za kvalitetnu procjenu učinkovitosti protumjera implementiranih u svrhu suzbijanja negativnih stopa CPN-a.

Upravo je u tom smislu za cestovne lokacije ili dionice na kojima je zamjetan znatan broj CPN-a uz teže oblike stradavanja sudionika u prometu nužno provesti dubinske analize prometnih nesreća na individualnoj razini kako bi se podrobnije utvrdile relevantne informacije o udjelu i rangiranju rizičnih čimbenika pojave CPN-a.

Predloženi pristup nažalost iziskuje znatne resurse, što predstavlja ograničavajući faktor za ukupan broj analiziranih slučajeva nesreća primjenom takvoga način djelovanja, te se u skladu s

[24] Sjedinjene Američke Države (SAD) imaju najdulje dostupne statističke vremenske nizove podataka o CPN-u te broju prijeđenih kilometara za motorna vozila, koji se pribavljaju od 1923. godine.

time predlaže da se navedeni pristup primjenjuje samo kod ozbiljnih vrsta CPN-a, kao što su slučajevi smrtno ili teško ozlijeđenih sudionika.

Glavne poteškoće koje sprečavaju kvalitetnu komparaciju zemalja predstavljaju sljedeće činjenice:

- podatci o CPN-u u prošlosti nisu bili adekvatno prikupljani, unificirani i filtrirani kako bi bili relevantni za statističku obradu,
- nemaju sve zemlje (posebice zemlje u razvoju) dostatan kvalitetan niz praćenja statističkih zbirnih podataka,
- značajne razlike u definicijama (CPN-a, stradalih, ozlijeđenih sudionika u prometu).

Rezultat navedenoga bila je međusobna nekompatibilnost, a razlog za to leži u činjenici da su različiti izvori podataka o CPN-u svoje registre temeljili na zasebno usvojenim analitičkim zakonitostima, strukturama i karakteristikama.

Razlika u pojedinim bazama podataka o CPN-u vidljiva je na razini osnovnih informacija o prometnim nesrećama koje se unose u *Upitnik o prometnim nesrećama*. Razlike su stoga vidljive u broju varijabli, vrijednostima i broju stranica koje je potrebno popuniti za potrebe unosa podataka o CPN-u. Također, zbog organizacijskoga ustroja pojedinih tijela na nacionalnoj i lokalnoj razini, osim regularnih, službenih *Upitnika o prometnim nesrećama*, često se znaju voditi i dodatni, specijalizirani upitnici namijenjeni ciljanim interesnim skupinama, kao što su pojedina ministarstva, gradska tijela i agencije za sigurnost cestovnoga prometa (npr. Belgija, Mađarska, Španjolska). Također su u pojedinim zemljama Europske unije u primjeni i specijalizirani upitnici koji se koriste samo kod CPN-a s materijalnom štetom (npr. Slovenija, Poljska, Bugarska, Njemačka, Mađarska).

Nakon detekcije navedene diskrepancije između *Upitnika o prometnim nesrećama* u pojedinim zemljama Europske unije (Tablica 4.1) nužno je što ranije unificirati forme (minimalni set podataka vezan za uvjete, uzroke i posljedice pojedine CPN-a) te protokole prikupljanja i unosa (neovisno o tome vode li se u papirnatom ili digitalnom obliku, unose li se prethodno na terenu u prijenosno računalo ili izravno u informacijski sustav za statističko praćenje), s posebnim naglaskom na uvažavanje specifičnih obilježja i uvjeta pojave prometnih nesreća u urbanim gradskim područjima u odnosu na autoceste. Nadalje, predmetni upitnici moraju biti prilagođeni korisniku (mogućnost jednostavnoga i brzoga popunjavanja) te u potpunosti integrirani s pripadajućim informacijskim sustavom odnosno bazom podataka o CPN-u. Stoga je nužno uz pripadajuće upitnike kreirati i kvalitetne priručnike, koji će nedvosmisleno i iscrpno korisniku za svako polje (varijablu ili vrijednost) definirati opis i značaj.

Tablica 4.1. Osnovni orijentacijski podatci o kvantiteti informacija prikupljenih kroz upitnike o prometnim nesrećama

	DRŽAVA	BROJ VARIJABLI	BROJ VRIJEDNOSTI	BROJ STRANICA
1.	Njemačka	30	149	3
2.	Francuska	68	348	1
3.	Italija	15	197	2
4.	Nizozemska	38	148	2
5.	Belgija	61	239	4
6.	Luksemburg	26	153	2
7.	Velika Britanija	50	255	4
8.	Irska	29	171	1
9.	Danska	45	202	1
10	Grčka	20	168	1
11.	Španjolska	78	277	1
12.	Portugal	22	82	2
13.	**Hrvatska**	**38**	**119**	**2**

Izvor: The DUMAS project – Developing urban management and safety (2000.)

Nadalje, definicije osnovnih pojmova i metodologija koja se primjenjuje za izučavanje podataka o CPN-u također nisu posve unificirane u zemljama Europske unije, što otežava provedbu kvalitetnih komparativnih analiza. Vezano uz usuglašavanje osnovnih pojmova, kao što su prometne nesreće, teško/lako ozlijeđeni te poginuli u prometnim nesrećama, valja navesti da su meritorne definicije tih pojmova one usvojene na *Bečkoj konvenciji o cestovnom prometu*, održanoj 8. studenoga 1968. godine, pri čemu je RH postala stranka predmetne konvencije 8. listopada 1991. godine na temelju notifikacije o sukcesiji. Važnost predmetne konvencije jest u tome što je predmetne definicije u većem dijelu za svoj rad prihvatila i međunarodna baza podataka o prometu i CPN-u – IRTAD, te značajan broj članica OECD-a, kao što su Australija, Belgija, Kanada, Češka Republika, Danska, Finska, Mađarska, Island, Irska, Luksemburg, Nizozemska, Novi Zeland, Norveška, Švedska, Velika Britanija i Sjedinjene Američke Države. Za ostale članice OECD-a, koje nisu uskladile svoje službene evidencije s prethodno usvojenim definicijama (Austrija, Njemačka, Francuska, Grčka, Italija, Japan, Portugal, Španjolska, Švicarska), za potrebe provedbe komparativnih analiza primjenjuju se pojedini korekcijski faktori. [107]

Također, standardizaciju protokola vođenja dubinskih analiza CPN-a, homogenizaciju kriterija vezanih uz definiranje minimalnoga seta podataka za kvalitetnu obradu i analizu podataka o CPN-u, unifikaciju pojmova (definicija) pojedinih kategorija CPN-a i dr. potrebno je, osim na nacionalnoj razini, implementirati i u registrima o CPN-u koji se vode na lokalnoj i regionalnoj razini kako bi se olakšala usporedba obrađenih podataka te osigurala njihova točnost.

U svijetu su se počele stvarati međunarodne baze podataka o CPN-u. U tu svrhu usvojeni su standardi, a primjer je pozitivne prakse uspostava *Rječnika za transportnu statistiku* (*engl. Glossary for Transport Statistics*), koji je usuglašen između UNECE, EUROSTAT-a i ECMT-a. Realizacija takvih međunarodnih baza podataka o CPN-u omogućila je sljedeće:

- komparaciju nacionalnih statistika u području sigurnosti cestovnoga prometa,
- rangiranje zemalja,
- naznake hitnosti potreba međunarodne podrške,
- informacije o razvoju i napretku pojedine države,
- bolju identifikaciju sigurnosnih propusta u prometnom sustavu,
- uočavanje razlika u razini sigurnosti sudionika u prometu i cestovnoj infrastrukturi [108].

Osim objedinjenja i unificiranosti nacionalnih baza podataka o CPN-u, mnogobrojne studije i istraživanja iz područja sigurnosti cestovnoga prometa [109][110] oslanjaju se također i na objedinjavanje podataka različitih lokalnih subjekata zaduženih za njihovo prikupljanje i obradu, što u većini slučajeva predstavlja ustanove iz transportnoga, policijskoga i zdravstvenoga djelokruga.

Također, prethodna istraživanja i iskustva ukazuju na to kako ukupan broj CPN-a koji je evidentirala prometna policije, iako čini značajan postotak, ne prikazuje u potpunosti realnu sliku o ukupnom broj prometnih nesreća, s obzirom na to da ta istraživanja ne objedinjavaju podatke o prometnim nesrećama koje su registrirale pojedinačne osiguravajuće kuće. No ako bi se navedeni podatci i integrirali u službenu bazu podataka CPN-a, dolazi do problema njihove nekompatibilnosti i netransparentnosti, s obzirom na to da podatci koji vode osiguravajuća društva nisu javno dostupni te detaljni u smislu evidentiranja nužnih informacija o mjestu nastanka, uzrocima i posljedicama prometne nesreće [111].

Ostvarenje detaljne i realistične baze podatka o CPN-u i izrada pripadajućih statističkih modela pretpostavlja međusobno povezivanje baza podataka različitih izvora,[25] tako da svaka s drugačijega stajališta prikuplja relevantne informacije o uzrocima i posljedicama nesreća te ih u skladu s time obrađuje i interpretira.

Neki pružatelji izvora podatka o CPN-u u svijetu jesu sljedeći:

[25] Podatke vezane za stanje sigurnosti cestovnoga prometa moraju pribaviti svi relevantni sektori: transportni, zdravstveni, sudbeni i dr., uz preduvjet da su standardizirano klasificirani i kodirani te obrađeni i analizirani primjenom odgovarajućih računalnih baza podataka.

- policijske uprave,
- zdravstvene ustanove,
- osiguravajuće kuće,
- javni i privatni upravitelji cesta te razne transportne tvrtke,
- specijalizirana državna tijela (agencije) za sigurnost cestovnoga prometa,
- specijalizirane interesne grupe (istraživački instituti, udruge stradalih sudionika u prometu, konzultantske tvrtke, specijalizirana odvjetnička društva i dr.) s različitim interesnim područjima djelovanja,
- pravosudne institucije [112].

S obzirom na to da su prikupljanje i obrada statističkih podataka o prometnim nesrećama u nadležnosti ministarstava unutarnjih poslova, odnosno nekolicine njihovih službi, u većini zemalja svijeta pridodaje im se i zadaća organizacije i vođenja nacionalnih službenih baza podataka o CPN-u (Francuska, Italija, Nizozemska, Njemačka, Španjolska i dr.). S obzirom na to da su procedure prikupljanja, upravljanja i eksploatacije obrađenih statističkih podataka o prometnim nesrećama zasebne i nestandardizirane, kvaliteta ulaznih podataka između pojedinih zemalja varira. Nadalje, iako sadrže najdetaljnije setove kategorijskih varijabli o CPN-u, obrađeni podatci policijskih postaja također često znaju biti nepotpuni (zbog nedostatka edukacije kadrova te tehničke opreme i alata) te nedostupni široj stručnoj javnosti na korištenje.

Vezano za izvještaje iz zdravstvenih ustanova, s obzirom na to da postoje različite definicije pojedinih oblika CPN-a, otežana je mogućnost komparativnih analiza između pojedinih zemalja, dok se lakši oblici tjelesnih ozljeda često ni ne evidentiraju u službenim informacijskim sustavima. Nadalje, takav oblik evidentiranja CPN-a često nije povezan sa službenim policijskim izvještajima te jedinstvenim informacijskim sustavom evidentiranja CPN-a, te bi stoga trebalo poduzeti daljnje aktivnosti usmjerene k njegovoj automatizaciji i usuglašavanju s međunarodnim propisima i standardima. Dodatni su problemi u slučajevima kada je zbog medicinske obrade pacijenta potrebno preseliti u drugu zdravstvenu ustanovu, kada je unesrećenik samo prijavljen a ne i hospitaliziran, te kada su za obradu pacijenta na raspolaganju nedostatna sredstva (bolnički kreveti, liječničko osoblje, ambulante i sl.).

Kod evidencija osiguravajućih kuća te javnih i privatnih upravitelja cesta najčešći je problem neusklađena metodologija te otežan pristup informacijama, pri čemu razina prikupljenih podataka često ovisi o planovima i operativnim aktivnostima samih tvrtki. Iako baze podataka osiguravajućih kuća, kao i one zdravstvenih ustanova karakterizira nepovezanost u jedinstveni informacijski sustav CPN-a, one pružaju kvalitetne podatke o lakšim oblicima prometnih nesreća koje su evidentirane prije dolaska policijskih službenika te pokretanja sudskih postupaka.

Osim navedenih izvora, podatci dobiveni od sudbenih tijela te specijaliziranih istraživačkih institucija i udruga također pružaju kvalitetnu podlogu za obradu informacija o uzrocima i uvjetima nastanka CPN-a (posebice u slučajevima teških oblika prometnih nesreća – smrtno stradavanje), s obzirom na to da ona na specifičan pristup obrađuju predmetnu problematiku (sudski sporovi s opsežno pribavljenom pripadajućom dokumentacijom), često pogodnu za detaljnije dubinske analize, tj. rekonstrukcije nastanka CPN-a.

U novije se vrijeme prikupljanje i organizacija podataka o CPN-u u svrhu unapređenja sigurnosne komponente cestovnoga prometnog sustava pridodaje specijaliziranim državnim tijelima (agencijama) s obzirom na to da ona posjeduju odgovarajuću kadrovsku, financijsku i logističku potporu za obavljanje takvih zadataka. Podatci se prikupljaju i analiziraju na temelju više izvora, na lokalnoj i nacionalnoj razini a za potrebe izrade specijaliziranih analitičkih statističkih izvještaja, ekonomskih procjena te predlaganja razvojnih strategija i akcijskih planova.

Iako navedeni pristup (metodologija) ne predstavlja novinu u istraživanju i analizi CPN-a, valja napomenuti kako najznačajniju komponentu za njihovu realizaciju predstavlja objedinjavanje podataka između prometne policije te zdravstvenih ustanova kako bi se ostvarila kauzalnost između okolnosti koje su prethodile incidentnoj situaciji s uzrokom smrti preminulih. Predloženi proces omogućava opsežnu provjeru valjanosti podataka (nedosljednosti i nepodudaranje) između baza pojedinih izvora te njihovu nadopunu relevantnim informacijama.

Povezivanje baza podataka zahtijeva također i suradnju velikoga broja subjekata, od kojih je svaki zaslužan za održavanje vlastitih evidencija koje se odnose na prometne nesreće i stradavanje sudionika u prometu, s usuglašenim metodama i koordinativnim procedurama kako bi se zbirni podatci u procesu povezivanja kvalitetno objedinili [113].

U novije vrijeme napredak u metodama i tehnologiji prikupljanja relevantnih ulaznih podataka o CPN-u predstavlja upotreba radara te videodetekcijskih i kinematičkih senzora, koji omogućavaju znanstvenicima podrobnije informacije koje su se dogodile tijekom prometovanja. Tim smo pristupom u stanju ekstrahirati niz neposrednih informacija (akcija) koje su prethodile nastanku CPN-a, temeljenih na stvarnim vremenima podataka iz prometnoga sustava, a što značajno može pospješiti razumijevanje uzroka nastanka takvih incidentnih situacija. Prikupljanje podataka koje provode nadležne ustanove vezano za sigurnost cestovnoga prometa ne bi stoga trebalo samo ograničiti na prikupljanje podataka o CPN-u, već bi također trebalo uključiti i pozadinske podatke, što se prvenstveno odnosi na one koji obuhvaćaju prometno okruženje.[26]

[26] Neke od razvijenih zemalja svijeta već imaju implementirane učinkovite statističke sustave prikupljanja i praćenja podataka vezanih uz CPN, a koji obuhvaćaju i čitav niz drugih relevantnih informacija vezanih za

U konačnici, potrebno je konstatirati da je, iako su u području prikupljanja i analize podataka o prometnim nesrećama ostvareni značajni napretci, proces i dalje nedovoljno razvijen i krut te su informacije i objašnjenja razloga nastanka prometnih nesreća i dalje šturi, dok su u nekim evidencijama i izostavljeni. Kod predmetnih informatičkih baza podataka problematika se svodi prvenstveno na dosljednost i točnost „rutinski“ prikupljenih podataka o CPN-u, bilo iz policijskih, zdravstvenih ili nekih drugih izvora.

4.1.2. Izvještavanje o cestovnim prometnim nesrećama

Iako razvijene zemlje EU-a službeno vode statistička izvješća o CPN-u, koja su obrađena odgovarajućim alatima i informacijskim sustavom te imaju značajnu aplikativnu vrijednost u svrhu analize i preveniranja CPN-a (ako su u velikom postotku za nastanak CPN-a zaslužni istovjetni uzroci, ciljanim protumjerama moguće ih je u relativno kratkom vremenu otkloniti), kod njih su prisutna i određena ograničenja [114].

Prvenstveni je problem što nisu svi CPN-i evidentirani i pohranjeni u statističkim bazama podataka, što prvenstveno ovisi o njihovu tipu. Razlog tomu leži u činjenici da svaka promatrana zemlja na drugačiji način vrednuje potrebu da se CPN-e, u skladu s tipom i vrstom, registrira u nacionalnu bazu podataka o prometnim nesrećama. U većini slučajeva podatci o prometnim nesrećama preuzimaju se isključivo iz službene statističke baze podataka ministarstva unutarnjih poslova – prometne policije, dok podatci iz ostalih izvora podataka (zdravstvene ustanove, osiguravajuće kuće i sl.) često nisu uključeni u razmatranje, što ukazuje na ozbiljni nedostatak integracije.

Neke države prijavljuju samo one prometne nesreće u kojima je materijalna šteta evidentirana iznad definiranoga novčanog praga, dok u drugima zemljama zakonodavne regule zahtijevaju da stupanj oštećenja motornih vozila koja su sudjelovala u CPN-u bude iznad određene vrijednosne razine (primjer je savezna država Oregon, u kojoj je jedan od kriterija za prijavu CPN-a taj da je šteta na motornom vozilu koje je sudjelovalo u prometnoj nesreće iznad 1,500 američkih dolara).

Hauer et al. [115] i Elvik et al. [116] provodili su studije o nepotpunim izvještavanjima o CPN-u komparirajući i analizirajući podatke iz baza koje ih prikupljaju i distribuiraju, te je utvrđeno značajno odstupanje među različitim izorima podataka, prvenstveno ovisno o težini oblika CPN-

kvalitetnu analizu uzroka i posljedica prometnih nesreća, kao što su prometna situacija u trenutku pojave CPN-a, analiza preglednosti i linije prometnoga pravca, opis oštećenja motornih vozila, izračuni izravnih gubitaka prometne nesreće i sl.

a, ali također i o razini djelovanja subjekata koji su prikupljanje provodili (nacionalni nivo, gradovi, regije i sl.).

Kod tradicionalnih baza podataka o prometnim nesrećama, što su posljedice CPN-a teže, one se podrobnije i detaljnije evidentiraju, tako da su CPN u kojima ima smrtno stradalih obrađene u prosjeku od 85% do 95%, one u kojima su zabilježene teže ozljede 60%, dok one u kojima ima lakše ozlijeđenih sudionika ne prelaze brojku iznad 30%. Također, CPN-i u kojima su sudjelovala cestovna motorna vozila daleko su više obuhvaćeni u službenim statistikama u odnosu na one u kojima ona nisu sudjelovala, a prvenstveno se misli na nemotorizirani promet (pješaci, biciklisti, vozila malih maksimalnih brzina i slično) [117]. Razlozi podizvještavanja također su i situacije u kojima se najčešće zovu samo vozila hitne medicinske pomoći – prometne nesreće biciklista u kojima su samo oni sudjelovali, ozljede djece (roditelji odmah odlaze s njima u bolnicu), vozači motornih vozila pod utjecajem alkohola ne žele zvati predstavnike prometne policije, situacija u kojoj pojedini putnici u vozilima prvotno ne prikazuju znakove traume, a poslije se utvrde komplikacije te su hospitalizirani zbog daljnjega promatranja, te situacije kada na medicinsku obradu dolaze unesrećeni od CPN-a izvan teritorijalnih granica pojedinih lokalnih jedinica.

Značajna ograničenja službenih statistika jesu česta u situacijama kada policijska intervencija nije potrebna niti zakonski obvezatna. Tako postoje slučajevi u kojima u CPN-u u kojem nije bilo teže ozlijeđenih sudionika, nego je riječ samo o manjoj materijalnoj šteti, službenici prometne policije nisu dužni izlaziti na mjesto događaja te obaviti očevid, niti će taj CPN biti zaveden u njihov službeni registar. CPN će se evidentirati samo ako stranka planira podići tužbu u kojoj zahtijeva nadoknadu štete protiv izazivača prometne nesreće u kojoj je sudjelovala. Značajan je problem s navedenim činjenica što su takvi oblici CPN-a vrlo učestali, a zbog njihova neevidentiranja onemogućeno je preventivno djelovanje u smislu uočavanja potencijalnih rizičnih lokacija ili dionica na cestovnoj mreži kako bi se spriječili eventualni teži tjelesni oblici ozljeda sudionika u prometu. Nadalje, izbor uzroka i pogrešaka u nastanku CPN-a lakšega oblika definira se na temelju subjektivnoga mišljenja policijskih službenika, koji često nemaju adekvatnu stručnu opremu za njihovu kvalitetnu analizu i procjenu.

Praksa u većini zemalja EU-a, uključujući i Republiku Hrvatsku, ukazuje na to kako se znatan broj lakših oblika prometnih nesreća i nakon dolaska djelatnika prometne policije ne evidentira, s obzirom na to da se do dolaska policije uspio postići zajednički dogovor između stranaka koje su sudjelovale u nesreći. Sudionici su razmijenili osobne podatke i podatke o vozilima te popunili *Europsko izvješće o nesreći*.

U slučaju da se policijski službenik u RH zatekne na predmetnoj lokaciji, on sastavlja službenu bilješku koja sadržava sve relevantne podatke o CPN-u – o sudionicima nesreće, vozilima, a daje se i kratak opis događaja, vremena i mjesta nastanka prometne nesreće te opis nastalih oštećenja.

Policijski djelatnik pritom nije dužan popuniti statistički list, a događaj se ne evidentira u Informacijskom sustavu Ministarstva unutarnjih poslova.

Izuzetak su situacije kada se jedan od sudionika udaljio s mjesta nesreće, ako u nesreći sudjeluje vozač koji nije stekao pravo na samostalno upravljanje vozilom određene kategorije, kao i kandidat za vozača koji upravlja vozilom za vrijeme osposobljavanja, vozač kojemu je vozačka dozvola istekla, ili mu je oduzeta, vozač kojemu je izrečena mjera prestanka važenja vozačke dozvole, ili mjera opreza privremenoga oduzimanja vozačke dozvole za upravljanje motornim vozilom, ili zaštitna mjera zabrane upravljanja motornim vozilom, zatim vozač za kojega se osnovano sumnja da u organizmu ima droga ili lijekova koji utječu na psihofizičke sposobnosti i na sposobnost upravljanja vozilima, ili da u krvi ima nedopuštenu količinu alkohola, ili ako pokazuje znakove alkoholiziranosti ili utjecaja droga ili lijekova, a odbija se podvrgnuti ispitivanju, ili je u takvom psihofizičkom stanju da nije sposoban sigurno upravljati vozilom. Također, to vrijedi i za vozača koji nema pomagala koja tijekom vožnje mora koristiti, zatim kada se sumnja da je uzrok prometne nesreće tehnička neispravnost vozila, kao i na izričit zahtjev sudionika prometne nesreće [118].

Lakši oblici CPN-a u urbanim sredinama, u kojima je sudjelovao samo jedan sudionik ili je riječ o izlijetanju s kolnika nerazvrstane prometnice, često se ne evidentiraju kako bi počinitelji prometne nesreće izbjegli uključivanje osiguravajućih kuća u sam postupak te spriječili eventualno sankcioniranje policijskih djelatnika i onemogućili pokretanje sudskoga spora prema počiniteljima prometnoga prekršaja.

Također, u mnogim srednje i slabo razvijenim tranzicijskim državama praksa ukazuje na to kako određene informacije o prometnoj nesreći, zbog nedostatne razine stručnosti policijskih službenika (nepohađanje stručnih treninga i odgovarajućih seminara za potrebe kvalitetnoga prikupljanja i obrađivanja podataka o CPN-u) ili nedostatne profesionalnosti njihove službene opreme, mogu u izvještajima biti nepravilno ili polovično unesene (nedostatak GPS lokatora za pozicioniranje mjesta nastanka prometne nesreće i elektronskih uređaja za brz i kvalitetan unos i analizu relevantnih podataka o prometnoj nesreći na samom mjestu nastanka, tj. dlanovnika, prijenosnih računala i sl.). Također, radi proceduralnih pojednostavljenja određeni se broj CPN-a sa znatnijom težinom prikazuje i evidentira kao prometna nesreća z lakšim ishodom (manja materijalna šteta).

Unos što većega broja podataka i informacija o CPN-u te njihovo evidentiranje u službenim statističkim obrascima i registrima jesu nužni kako bi se mogla pratiti sigurnosna analiza svih grupa sudionika u prometu, s obzirom na činjenicu da se možebitnim izbacivanjem određenih grupa neće dobiti realan uvid u postotak njihova učešća u CPN-u, tj. sustavno će se podcjenjivati razina sigurnosti tih kategorija sudionika.

U skladu s gore navedenim, u mnogim tranzicijskim zemljama svijeta u kojima zbog nedovoljnih resursa u broju stručnih ekipa te adekvatne informatičke opreme i operativnoga sustava evidentiranja prometnih nesreća ne postoje konzistentno vođeni registri podataka o CPN-u (integracija sve pribavljene dokumentacijske građe o prometnoj nesreći) mnogi podatci pribavljeni u prošlosti nisu adekvatno obrađeni, te se ne mogu smatrati pouzdanima za provedbu podrobnijih prometno-sigurnosnih te komparativnih analiza.

Problem je evidentiran i u državama EU-a, gdje je za razliku od tranzicijskih zemalja problem u tome što one često koriste informacije dobivene od samo jedne mjerodavne institucije zadužene za prikupljanje i obradu podataka o CPN-u (najčešće Ministarstvo unutarnjih poslova), a što dovodi do situacije da podatci o kvantiteti registriranih prometnih nesreća nisu vjerodostojni i reprezentativni. Problem je vidljiv i u činjenici što postojeći zakonski kriteriji i regule nisu usuglašeni s novim znanstvenim istraživanjima i studijama o prometnim nesrećama, što rezultira nedostatnom razinom informacija prikupljenih o CPN-u koje je potrebno voditi za službenu statistiku. Nedostatak je posebno uočljiv u situacijama kada lokalne i regionalne zakonske regulative i političke odluke definiraju podatke i metodologiju koje je potrebno primijeniti u prikupljanju informacija o CPN-u, što često dovodi do nedosljednosti u obrađenim podatcima te rezultira stvaranjem nepotpunih službenih izvješća, koja su u nesrazmjeru s onima vođenima na nacionalnoj razini.

Jedan od načina za rješavanje uočenih problemskih situacija jest i modernizacija pripadajućega informacijskog sustava prikupljanja i obrade podataka o CPN-u, koji je potrebno nadograditi odgovarajućim filterima za detektiranje i ispravljanje nedostataka. Uz navedeno, potrebno bi bilo pojačati formalnu kontrolu podataka koje su na mjestu nastanka CPN-a prikupili nadređeni ili vanjske specijalizirane ustanove (statističke agencije). Također je poželjno težiti tomu da se informacije o CPN-u usporede s podatcima iz drugih ustanova zaduženih za njihovo prikupljanje i obradu te pojačati suradnju s različitim nacionalnim, regionalnim i lokalnim inicijativama [119].

Vezano za stanje u Republici Hrvatskoj možemo konstatirati kako na njezinu prostoru nije provedena niti jedna studija koja bi obradila navedenu problematiku, te prema tomu trenutno niti ne postoje relevantni službeni podatci o stupnju podizvještavanja o CPN-u.

4.2. Analiza međunarodnih i domaćih baza podataka o cestovnim prometnim nesrećama

4.2.1. Analiza međunarodnih statističkih baza podataka o cestovnim prometnim nesrećama

Standardizacija protokola prikupljanja informacija o CPN-u, kao i samih definicija značajno odstupa unutar zemalja članica EU-a, što onemogućava detaljnu komparaciju podataka o stopama prometnih nesreća. Nadalje, alati koji se koriste za obradu podatka o CPN-u, kao i same hijerarhijske strukture organizacije subjekata koji su zaslužni za prikupljanje i obradu podataka (u većini slučajeva riječ je o policijskoj nadležnosti) razlikuju se između članica EU-a, što dodatno otežava mogućnost komparacije obrađenih podataka.[27]

Rezultat je toga činjenica da je velik broj država preispitao svoje protokole i modele obrada podataka o CPN-u te razvio kooperativnu shemu postavki iz službene baze podataka u suradnji s ostalim relevantnim nacionalnim izvorima podataka. Na taj su se način ostvarili preduvjeti za formiranje internacionalnih standardiziranih izvještaja o CPN-u te sustava njihova praćenja na razini Europske unije.

Europski laboratorij (ERSO) pod ingerencijom Europske komisije organiziran je upravo kako bi se što kvalitetnije mogli prikupiti i analizirati dubinski podatci o CPN-u na prostoru Europske unije. Aktivnosti proizašle iz njegova rada dovele su do usvajanja novih regulativa i harmonizacije procedura u procesu prikupljanja podataka i činjeničnih dokaza o nastanku CPN-a.

Jedno od ključnih područja djelovanja ERSO-a jest i implementacija integrirane baze podataka o CPN-u na razini Europske unije, a sve u svrhu definiranja obilježja njihova nastanka te detektiranja ključnih uzročnih čimbenika.

Formirana statistička baza podataka CPN-a *SafetyNet* (projekt aktivan u periodu 2004. – 2008. godine) prvotno je obuhvaćala dubinske statističke podatke o individualnim CPN-ima za ukupno šest europskih zemalja (Italija, Njemačka, Švedska, Finska, Ujedinjeno Kraljevstvo i Nizozemska). Istražitelji nesreća prikupljene su podatke sistematizirali kroz tri glavne kategorije, koje se

[27] Razni programski izvođači primjenjivali su različita tehnološka rješenja te neujednačen pristup, a tijekom izrade baze podataka o CPN-u dolazilo je do promjena modela podataka, raznih specifičnih zahtjeva i razvoja novih tehnologija, te je potrebno izvršiti standardizaciju, homogenizaciju i migraciju postojećih podataka o CPN-u.

odnose na motorna vozila, sudionike nesreća i cestovnu okolinu, kako bi se postigao sveobuhvatni uvid u proces nastanka prometne nesreće i njezinih krajnjih posljedica. U prosjeku to obuhvaća analizu oko 200 općih i pridonosećih varijabli zaslužnih za pojavu CPN-a, s više od 500 pripadajućih informacija u svakom od analiziranih predmeta.

Za prikupljanje predmetnih podataka i procjenu uzročnih čimbenika svakoga od analiziranih CPN-a u svakoj su od uključenih zemalja bili zaduženi individualni visoko obrazovani stručni timovi (stručnjaci za obavljanje očevida prometnih nesreća, psiholozi i dr.). Navedeni su pojedinci prikupljali ulazne podatke izravno na mjestu nastanka incidentne situacije, po unaprijed izrađenoj i novodefiniranoj metodologiji (*SafetyNet Accident Causation System* – SNACS), koja je omogućavala i kategorizaciju glavnih uzročnih čimbenika zaslužnih za njihov nastanak.

Usvojena metodologija i jedinstveni protokol prikupljanja i analize dubinskih podataka CPN-u definirani su na temelju analize najboljih svjetskih praksa u zemljama koje prednjače u tom području djelovanja, kao što su Švedska, Njemačka, Francuska, Ujedinjeno Kraljevstvo, SAD, Australija i dr.

Jedna od mjera za harmonizaciju sustava prikupljanja podataka o prometnim nesrećama (usuglašavanje definicija varijabli, njihovih raspona vrijednosti, strukture i formata) na nacionalnoj, ali i na razini EU-a jest i implementacija međunarodnoga sustava za prikupljanje podataka o prometnim nesrećama. Primjer je dobre prakse Europska baza podataka o prometnim nesrećama – *CARE*[28] (engl. *Community data bank on road traffic accidents in Europe*), koja je nakon nekoliko svojih nadogradnji u današnjem obliku poznata pod nazivom *CADaS* (engl. *Common Accident Data Set*), a vode je Opća uprava za promet i energetiku (DG TREN) i Europski laboratorij (ERSO) pod ingerencijom Europske komisije.

Rezultat je projekta *CADAS Glossary*, u okviru kojega je definirana objedinjena analitička metodologija s minimalnim setom standardiziranih varijabli koje je potrebno koristiti ako želimo ostvariti nivo informacija o CPN-u na kojemu se mogu komparirati zemlje članice EU-a. Pritom je predloženo da se prilikom analiziranja podataka o CPN-u prethodno prikupi ukupno 88 varijabli te 481 vrijednost. Predložene varijable međusobno su podijeljene ovisno o njihovoj važnosti za analizu, dok su vrijednosti podijeljene ovisno o razini detalja s kojima se predmetni podatci mogu

[28] CARE baza podataka sadrži detaljne informacije o CPN-u koje su prikupile države članice EU-a i ima strukturu koja omogućava maksimalnu fleksibilnost pri analizi podataka. Prema Odluci Vijeća iz 1993. godine, države članice EU-a dužne su prijaviti Europskoj komisiji podatke o svakom registriranom CPN-u koji je rezultirao smrću ili ozljedom sudionika u prometu. Obradu i analizu konačnih setova prikupljenih podataka o CPN-u Komisija kompletira u mjesecu studenom, kada ujedno i distribuira informacije svim državama članicama na daljnju upotrebu.

prikupiti. Daljnja struktura sustava predstavlja podjelu varijabli na 4 osnovne kategorije, a koje se odnose na informacije o samoj prometnoj nesreći, motornim vozilima koja su u njoj sudjelovala, osobama te samoj prometnici na kojoj se incidentna situacija dogodila [120].

Valja naglasiti kako je navedeni projekt još uvijek aktivan te sve više zemalja članica EU-a prilagođava odnosno nadograđuje svoje postojeće nacionalne baze CPN-a prema njegovim praktičnima preporukama i analizama.

Tablica 4.2. Prikaz strukture CADaS varijabli i vrijednosti

Varijable	**Kod**	**Broj varijabli**			**Broj vrijednosti**		
Kategorije		Visoke važnosti (H)	Niske važnosti (L)	UKUPNO	Detaljne varijable	Alternativne varijable	UKUPNO
Prometna nesreća	A	7	5	12	76	15	91
Prometnica	R	16	21	37	151	15	166
Vozila	V	7	10	17	110	7	117
Sudionici	P	15	7	22	96	11	107
Ukupno		**45**	**43**	**88**	**433**	**48**	**481**

Izvor: The CADaS project – Common Accident data set (2011.)

Od ostalih izvora valja navesti WHO [112], koji svoje preporuke za razvoj baza podataka CPN-a usmjeruje upravo na ekonomski slabo i srednje razvijene zemlje koje još uvijek nemaju kvalitetno uspostavljen sustav upravljanja sigurnošću cestovnoga prometa, zbog čega im je predmetna prometna problematika izrazito izražena. Preporuke su podijeljene na ukupno četiri poglavlja, odnosno logičke cjeline i to sa stajališta:

- subjekata uključenih u sustav sigurnosti prometa,
- različitih izvora, sustava i kvalitete prikupljenih podataka,
- potreba krajnjih korisnika podataka,
- analize okruženja.

Vezano za subjekte (organizacije i radna tijela) uključene u sustav sigurnosti prometa, prvenstveno je potrebno identifcirati one stručne kadrove i pojedince koji su trenutno najviše involvirani u područje prikupljanja i uporabe podataka o sigurnosti cestovnoga prometa, kao i one buduće, potencijalne, koji bi mogli pridonijeti da trenutna operativna razina bude još kvalitetnija. Daljnjom analizom potrebno je naznačiti njihove uloge i aktivnosti u prikupljanju sigurnosnih podataka o prometnom sustavu, a kako bi im se mogli doznačiti specijalizirani zadatci za optimalno djelovanje u modernizaciji sustava.

Prvu skupinu kadrova najčešće predstavljaju službeni predstavnici prometne policije (zadužena za provedbu vještačenja CPN-a te ciljanih preventivnih i represivnih mjera i aktivnosti u skladu s pripadajućom zakonskom legislativom), bolničko osoblje (niz specijalista koji su uključeni u obradu pacijenata kojima je zbog sudjelovanja u CPN-u nužna medicinska pomoć odnosno hospitalizacija), kao i čitav niz inženjera (prvenstveno građevinske, strojarske i prometne struke) koji sudjeluju u kreiranju cestovne infrastrukture, prijevoznih sredstava te prometne okoline u cjelini.

U drugu skupinu tzv. potencijalnih subjekata možemo svrstati predstavnike statističkih zavoda, osiguravajućih kuća, nevladinih udruga i organizacija za sigurnost cestovnoga prometa, medije, političare te ostale donositelje odluka koji imaju zadatak pospješiti postojeće informacijske sustave sigurnosti cestovnoga prometa.

Prilikom provođenja analize rada različitih izvora i sustava prikupljanja podataka o razini sigurnosti cestovnoga prometnog sustava prvotno je potrebno identificirati kvalitetu prikupljenih podataka. Osim analize postojećih setova podataka (varijabli i vrijednosti) koji se izuzimaju tijekom izvođenja očevida CPN-a, potrebno je također analizirati formate njihove obrade, a posebice karakteristike informacijskoga sustava koji služe za kasniju obradu i pohranjivanje. Tim smo pristupom u mogućnosti detektirati prednosti i nedostatke (podizvještavanje, različite definicije, nedostatak podataka, pogreške u obradi, neadekvatno kodiranje prikupljenih podataka i sl.) kod svakoga od promatranih subjekata te predložiti listu intervencija za poboljšanje njihova djelovanja.

Za kvalitetno detektiranje nedostataka postojećih sustava prikupljanja i obrade podataka o sigurnosti cestovnoga prometnog sustava svakako je uputno voditi računa i o potrebama krajnjih korisnika, koji će u konačnici navedene podatke i koristiti. Ono se provodi metodama istraživanja, dubinskih intervjua s potencijalnim korisnicima, vođenjem stručnih rasprava kroz djelovanje fokus grupa, praćenjem ponašanja i potreba krajnjih korisnika i sl.

Posljednje područje obuhvaća analizu rada subjekata zaduženih za praćenje sigurnosne razine cestovnoga sustava, posebice s naglaskom na stanje cestovne mreže i infrastrukture. To su prvenstveno upravitelji cestovne infrastrukture te predstavnici pripadajućih ministarstava i agencija. S obzirom na to da je zakonska zadaća upravitelja cestovne infrastrukture obavljanje poslova prikupljanja podataka za formiranje baze podataka o cestama i cestovnih objektima, priprema različitih izvješća o stanju cesta i cestovnih objekata, vođenje i ažuriranje katastra nerazvrstanih cesta i cestovnih objekata, vođenje i ažuriranje pripadajuće tehničke dokumentacije te pripremanje ažurnih obavijesti o njihovim promjenama, navedene aktivnosti predstavljaju kvalitetnu polaznicu u svrhu detektiranja potencijalnih novih setova podataka koje

bi trebalo uvrstiti u službeni nacionalni informacijski sustav prikupljanja i obrada podataka o CPN-u.

Vezano uz rad subjekata zaduženih za praćenje sigurnosti cestovnoga prometa potrebno je navesti kako je u području sigurnosti cestovnoga prometa aktivan čitav niz međunarodnih i nacionalnih strukovnih organizacija i udruženja. Neke su od najznačajnijih organizacija *Europska konferencija ministara za transport – CEMT* (osnovana 1947. godine u Ženevi, objedinjuje znatan broj europskih država, a uključuje Sjedinjene Američke Države, Australiju, Japan i dr. Svojim preporukama, rezolucijama i izvještajima radnih skupina značajno utječe na kreiranje prometnih politika pojedinih zemalja u području sigurnosti prometa), *Europska ekonomska komisija Ujedinjenih naroda – UNECE* (zadužena za pripremu međunarodnih konvencija, rezolucija, sporazuma i sl., pri čemu njezino područje djelovanja i rada obuhvaća i sigurnost prometa. Za područje sprečavanja CPN-a ima organiziranu zasebnu stalnu radnu skupinu), *Organizacija za ekonomsku suradnju i razvoj – OECD* (osnovana 1960. godine, trenutno okuplja 34 države članice te unutar svoje organizacije ima ustrojenu zasebnu komisiju koja obrađuje teme vezane uz promet i njegovu sigurnost).

Od ostalih organizacija valja izdvojiti Vijeće Europe, Međunarodnu organizaciju za standardizaciju – ISO, Međunarodnu organizaciju za preventivu – PRI, Međunarodnu organizaciju za cestovni prijevoz – IRU, Svjetsku zdravstvenu organizaciju – WHO, Međunarodnu automobilističku organizaciju – FIA, Međunarodnu cestovnu federaciju – IRF te dr.

Prema veličini područja koje obuhvaćaju, trenutno u svijetu možemo razlikovati međunarodne, nacionalne, regionalne i lokalne baze podataka o CPN-u.

Neke su od relevantnih međunarodnih baza podataka o prometu i CPN-u sljedeće: IRTAD – baza podataka za zemlje OECD-a (*International Road Traffic and Accident Database*), IRF (*International Road Federation*), UNECE (*United Nations Economic Commission for Europe*); dok su one na razini Europske unije EUROSTAT (*Statistical Office of the European Communities*), CARE (*Community database on Accidents on the Roads in Europe*), CHILD (*Child Injury Led Design*), EACS (*European Accident Causation Survey*), ECBOS (*Enhanced Coach and Bus Occupant Safety*), ECMT (*European Conference of the Ministers of Transport*), PENDANT (*Pan-European Co-ordinated Accident and Injury Database*) te druge.

Na državnoj razini, jedna je od najsuvremenijih baza podataka o CPN-u, koja objedinjuje znatan broj različitih pokazatelja sigurnosti prometa, jest baza podataka Velike Britanije, koju vodi Britanski laboratorij za promet – TRL (*Transport Research Laboratory*). U Švedskoj se za praćenje stanja sigurnosti prometa koristi STRADA (*Swedish Traffic Accident Data Acquisition*), nacionalna

baza podataka o CPN-u a koja objedinjuje informacije o CPN-u prikupljene na terenu sa zdravstvenim podatcima unesrećenih [121]. Sustav prikupljanja podataka uspostavljen je tako da se svi podatci prikupljaju prvotno na lokalnoj razini, odakle se šalju u centralnu jedinicu u kojoj se obrađuju podatci o prometnim nesrećama na nacionalnoj razini. Aktualne smjernice EU-a veliku važnost pridaju razvoju nacionalnih sveobuhvatnih odnosno integriranih baza podataka, koje osim podataka o CPN-u sadržavaju širok spektar relevantnih pokazatelja sigurnosti prometa, koje su pribavili različiti izvori, odnosno mjerodavne institucije.

Također, mnogobrojne zemlje (Švedska, Njemačka, Belgija i dr.) osim državnih imaju i lokalne baze podataka, a kojima je glavni cilj dubinska analiza podataka o CPN-u te poboljšanje razine sigurnosti svih sudionika u lokalnoj urbanoj sredini. Njihovom uspostavom ostvaruje se detaljnija razina prikupljanja i analize relevantnih čimbenika sigurnosti cestovnoga prometa, kao i njihovo klasificiranje i kompariranje, što u konačnici ostvaruje preduvjete za detekciju lokaliteta kritičnih sa stanovišta prometne sigurnosti, kvalitetno upravljanje namjenskim proračunskim sredstvima, efikasniji rad predstavnika gradskih tijela, službi i prometne policije te adekvatno i kontinuirano praćenje stanja sigurnosti u prometu.

S obzirom na to da je krajnji cilj upravljanja sigurnošću cestovnoga prometa smanjenje broja poginulih i teže ozlijeđenih sudionika u prometu, u posljednje vrijeme u primjeni su i specijalizirane baze podataka namijenjene upravo prethodno navedenim kategorijama. To je slučaj FARS-a *(Fatal Accident Reporting System)* u SAD-u, Stats19[29] u Velikoj Britaniji (podatke prikupljaju na mjesečnoj osnovi policijski predstavnici tijekom cijele godine te su dostupni na nacionalnoj, regionalnoj te lokalnoj razini) te FAI *(Fatal Accident Investigation)* baze podataka, kreirane uz podršku Europske komisije. Razina detalja, odnosno prikupljenih informacija o CPN-u u bazi FAI znatno je veća nego što je to trenutno metodološki specificirano u bazama CARE ili CAREPLUS 2. U skladu s time, za svaku pojedinu dubinsku analizu promatranoga CPN-a obično je prikupljeno 100-150 varijabli s više od 500 stavki vrijednosti. Obrađeni podatci mogu se koristiti kao osnova za razvoj protumjera za teže oblike CPN-a unutar EU-a, pri čemu se podatci sustavno prikupljaju prema utvrđenim planovima te su dostupni širemu broju predstavnika država članica.

Potrebno je navesti kako se takve specijalizirane baze podataka ne mogu koristiti za obavljanje analiza i prevenciju težih oblika CPN-a ako nisu povezani s podatcima o CPN-u drugih kategorija. Razlog za to jest činjenica da ako želimo utvrditi koje su značajke specifične za teže oblike CPN-a,

[29] Sveobuhvatni sustav prikupljanja podataka o CPN-u prvotno je implementiran tijekom 1949. godine, značajno moderniziran 1979., dok se podatci o tjelesnim ozljedama sudionika u prometu prikupljaju od 1909. godine.

oni se moraju komparativno usporediti s ostalim oblicima odnosno kategorijama prometnih nesreća.

Iako većina gore spomenutih međunarodnih baza na drugačiji način prikuplja i obrađuje podatke o prometnim nesrećama i ostalim relevantnim socio-ekonomskim informacijama, osnovni je njihov cilj da u jednom kompatibilnom i homogenom formatu objasne pojave CPN-a te smanje nužan trud i vrijeme istraživača i krajnjih korisnika prilikom prikupljanja relevantne statistike. Također, na temelju podataka o CPN-u mnogobrojne lokalne i nacionalne organizacije i agencije objavljuju svoje godišnje biltene i publikacije i to prema već unaprijed definiranim standardiziranim relevantnim pokazateljima (varijablama i čimbenicima).

Bitna značajka navedenih baza podataka, kako onih domaćih tako i onih međunarodnih, jest ta što je velika količina podataka o CPN-u evidentirana i prikazana u formi kategorijskih varijabli različitih klasifikacija i razina važnosti.

Upravo u dijelu primjene različitih alata, tehnika i aplikacija dostupnih za reduciranje kategorijskih varijabli na prometnim stručnjacima stoji odgovornost kako će navedene nizove podataka obraditi i interpretirati kako bi se djelotvorno prepoznali određeni rizični uzroci za svaku kategoriju CPN-a pojedinačno [122].

4.2.2. Analiza domaćih izvora podataka o cestovnim prometnim nesrećama

Jedna od osnovnih pretpostavki odgovornoga sustava upravljanja sigurnošću prometa te kvalitetnoga stručnog obavljanja poslova predmetne tematike svakako je razvoj baza podataka o CPN-u te osnovnim pokazateljima sigurnosti prometa. Dok je baza podataka o CPN-u organizirana unutar djelokruga MUP PUZ-a, baze podataka o osnovnim pokazateljima na državnoj i lokalnoj razini (nužne sa sveobuhvatno praćenje svih relevantnih utjecajnih elemenata sigurnosti prometa) i dalje su međusobno neintegrirane.

Izvore podataka o cestovnim prometnim nesrećama na nacionalnoj razini moguće je dobiti od nekoliko javnih i državnih institucija i organizacija zaduženih za njihovo prikupljanje i obradu, među kojima su najrelevantniji podatci oni dobiveni iz nacionalnih baza podataka Ministarstva unutarnjih poslova Republike Hrvatske te Državnoga zavoda za statistiku Republike Hrvatske (zadužen za dostavu općih podataka kao što su demografski i socio-ekonomski pokazatelji), zatim

određenih zdravstvenih ustanova koje vode internu evidenciju, osiguravajućih društava, uprave cesta te Državne uprave za zaštitu i spašavanje (DUZS).[30]

Na lokalnoj se razini određene baze podataka vode pravni subjekti zaduženi za komunalnu i prometnu djelatnost, a kojima se upravlja zasebno, te tako svaka pojedinačno sadržava i strukturira podatke o prometnim nesrećama. U Gradu Zagrebu, naprimjer, to su prvenstveno interne baze podataka pojedinih podružnica Zagrebačkoga holdinga d. o. o., kao što su Zagrebački električni tramvaj, Zagrebačke ceste, Zrinjevac i dr.

Zakonska obveza pružanja prikupljenih i obrađenih podataka o CPN-u na nacionalnoj razini te razini županija na temelju Zakona o službenoj statistici (NN, br. 103/03 … 12/13) u nadležnosti je Državnoga zavoda za statistiku (podatci se periodički objavljuju i slobodni su za preuzimanje u formi publikacija ili kroz interaktivnu bazu podataka, dostupnu preko interneta) te Ministarstva unutarnjih poslova RH. Nadalje, predmetno ministarstvo, radi stvaranja uvjeta rada policije, u skladu sa Zakonom o policiji (NN 34/11, … 121/16) donosi i provodi planove o izgradnji i korištenju informacijskoga sustava za potrebe policije.

Sustav prikupljanja podataka o CPN-u u Republici Hrvatskoj obuhvaća razradu podataka na mikro- (nužno za procesuiranje individualnih krivaca) i makrorazini (grad, županija, država) [123]. Sadržaj takvih podataka uključuje pojedinosti o svakoj cestovnoj prometnoj nesreći o kojoj

[30] U slučaju prijave CPN-a na državnim, županijskim, lokalnim i nerazvrstanim cestama u primjeni je standardni operativni postupak za postupanje jedinstvenoga operativno-komunikacijskoga centra 112. On je usvojen na temelju članka 37. stavka 4. Zakona o zaštiti i spašavanju („Narodne novine“, broj 174/04, 79/07 i 38/09), uz suglasnost ministra zdravstva i socijalne skrbi, ministra obrane, ministra unutarnjih poslova i ministra mora, prometa i infrastrukture. Unutar navedenoga grafički je razrađen prikaz standardnoga operativnog postupka odnosno komunikacijskoga puta djelovanja u slučaju dojave CPN-a na prethodno kategoriziranim prometnicama, pri čemu ovisno o nadležnostima sudjeluju sljedeći sudionici zaštite i spašavanja u prometnim nesrećama: Ministarstvo zdravstva i socijalne skrbi (putem sanitarne inspekcije), Ministarstvo unutarnjih poslova (putem policijskih uprava i inspekcije zaštite od požara i eksploziva), Ministarstvo zaštite okoliša, prostornog uređenja i graditeljstva (putem inspekcije zaštite okoliša), Ministarstvo regionalnog razvoja, šumarstva i vodnog gospodarstva (putem vodopravne inspekcije), Ministarstvo mora, prometa i infrastrukture (putem inspekcije cestovnoga prometa i cesta), Ministarstvo obrane, Državna uprava za zaštitu i spašavanje, Hrvatske ceste d. o. o. (putem pravne ili fizičke osobe kojoj je ustupljeno izvođenje radova redovitoga održavanja), Županijske uprave za ceste, jedinice lokalne samouprave (putem pravne ili fizičke osobe kojoj je ustupljeno izvođenje radova redovitoga održavanja), hitna medicinska pomoć, vatrogasne postrojbe, Hrvatski autoklub, Hrvatska gorska služba spašavanja. Osim naznačenoga operativnog postupka, DUZS je donio i zasebne standardne operativne postupke u slučaju dojave CPN-a u tunelima te autocestama.

se izvijestilo – broju prometnih nesreća s nastradalim osobama prema vrsti, posljedicama, uzroku, okolnostima njihova nastanka i sudionicima (vozila, vozači, pješaci i putnici) te broju poginulih i ozlijeđenih osoba. Podatke o stupnju ozljeda zadobivenih u CPN-u također prikupljaju predstavnici prometne policije i uvrštavaju u službenu bazu podataka, ali se oni dobivaju od predstavnika zdravstvenih ustanova, odnosno službi hitne medicinske pomoći koje zaprime unesrećene na medicinsku obradu. U takvim slučajevima bolnice su dužne i zakonski kontaktirati predstavnike prometne policije te im pružiti svu relevantnu dokumentaciju, odnosno podatke nužne da se CPN kvalitetno statistički obradi (vrijeme odaziva interventnih timova medicinske pomoći, oblici intervencija unesrećenih osoba, vrijeme zadržavanja unesrećenika u bolnicama, troškovi hospitalizacije i sl.). Tim pristupom, povezivanjem informacija dobivenih od više subjekata zaduženih za prikupljanje i analizu podataka o CPN-u, moguće je kvalitetno pratiti podatke za svakoga unesrećenika u prometu, i to od mjesta nastanka prometne nesreće pa sve do prestanka hospitalizacije.

Osim prethodno navedenih klasifikacija CPN-a, prikazan je i čitav niz ostalih relevantnih informacija i incidentnih čimbenika karakterističnih za pojavu CPN-a, kao što su kategorizacija cestovnih prometnica, stanje površine kolnika i kolničke konstrukcije, meteorološki uvjeti (uvjeti vidljivosti), karakteristike vozača (dob, spol, utjecaj alkohola ili opojnih droga), tehnička ispravnost motornih vozila i dr.

Administrativni izvor podataka prilikom izrade prethodno spomenutih *Biltena o sigurnosti cestovnoga prometa* predstavljaju sumirani podatci dviju baza podataka uspostavljenih u elektronskoj formi, kao elektronički registar, a to su:

- Evidencija i statističko praćenje registracije cestovnih vozila,
- Evidencija i statističko praćenje prometnih nesreća.

Podsustav Informacijskih sustava MUP-a RH bitan za praćenje sigurnosnih pokazatelja cestovnoga prometnog sustava predstavlja statističko-analitičko praćenje prometnih nesreća. Relevantne podatke pribavljaju predstavnici prometne policije, koji na temelju službenih radnji u takvim slučajevima, u postupku vođenja očevida CPN-a, osiguravaju mjesto nesreće te izuzimaju relevantne tragove i informacije koji se kasnije, u što je kraćem roku moguće, kroz odgovarajući obrazac (*Upitnik o prometnoj nesreći*, usuglašen s europskim obrascima) unose u evidenciju i statističko praćenje prometnih nesreća [118].

Njegova je temeljna namjena da se analizom prikupljenih statističkih podatkovnih podloga o CPN-u detektiraju kritični lokaliteti na cestovnoj mreži, tzv. „crne rupe“ te najznačajniji rizični čimbenici CPN-a kako bi se na njih moglo ciljano preventivno djelovati.

Informacije koje su uvrštene u prometnu statistiku i analizu prilikom obrađivanja pojedinoga CPN-a moguće je podijeliti na zapise o sudionicima, vozilima te samoj prometnoj nesreći. Stoga je kroz navedeni podsustav moguće pristupiti statističkomu prikazu podataka o vrstama prometnih nesreća, evidentiranim propustima (greškama) i drugim okolnostima koje su im prethodile, o sudionicima koji su sudjelovali, posljedicama koje su proizvele (tjelesne ozljede, smrtnost, materijalna šteta) te mnogim ostalim statističkim podatcima, a neki su među njima sljedeći: identifikacijski broj oznake prijave (jedinstveni broj u sustavu), informacije o vremenu nastanka CPN-a (datum, dan, sat, dan u tjednu), posljedice i vrste CPN-a, okolnosti koje su prethodile, informacija o tome je li obavljen uviđaj mjesta nesreće, uvjeti vidljivosti, karakteristike ceste, stanje površine kolnika i kolničke konstrukcije, informacija o lokaciji (naznake o aktualnoj prometnoj regulaciji, vertikalnoj i horizontalnoj prometnoj signalizaciji, javnoj rasvjeti, prometnoj i/ili urbanoj gradskoj opremi), okolišni uvjeti i atmosferske prilike, eventualno vrijeme trajanja prekida odvijanja prometa, informacije o vozilima koja su sudjelovala u CPN-u (vrsti, godini proizvodnje, smjeru kretanja vozila i opisu manevra koji je prethodio sudaru, registarskoj tablici, stanju pneumatika), modalnoj podjeli (individualni ili javni prijevoz), osnovne informacije o sudionicima u CPN-u (datum rođenja, spol, svojstvo, državljanstvo, posljedice, stanje), zatim godini polaganja vozačkog ispita, inkriminaciji, korištenju sigurnosnoga pojasa ili kacige, korištenju mobitela, informacije o svim izdanim pisanim odnosno izrečenim (usmenim) upozorenjima sudionika u prometu i dr.

Također, podatke je moguće statistički pretraživati kroz zadavanje određenih vremenskih perioda (godina, mjeseci, dani) te ustrojstvenih jedinica (policijskih uprava te policijskih postaja). Podatke o određenoj prometnoj nesreći moguće je pretraživati i upisom registarske oznake vozila te imena sudionika koji su sudjelovali u nesreći.

Za potrebe izrade određenih prometno-sigurnosnih izvještaja te sigurnosnih procjena, osim pregleda samih statističkih podataka o evidentiranim CPN-ima, Informacijski sustav MUP-a RH omogućava pregled informacija o prometnim nesrećama i za pojedinačne mikrolokacije, odnosno dionice cestovne prometne mreže na kojima je uočena veća akumulacija prometnih nesreća (općine, naselja, cestovne prometnice, kućni brojevi , stacionaže i sl.).

Donedavno je rad prometne policije bio limitiran i neadekavtnom evidencijom stacionaža na kojima su se dogodili CPN-i, što je rezultiralo otežanom selekcijom ulaznih podataka te definiranjem ključnih uzročnika nastanka CPN-a.

U skladu s time, unatrag tri godine prometna policija provodi detekciju visokorizičnih lokaliteta „crnih točaka“ na mreži gradskih prometnica, kao i geografsko pozicioniranje svih cestovnih prometnih nesreća s pomoću sustava za globalno pozicioniranje – GPS uređaja, čime se dodatno pojeftinjuje i pojednostavnjuje metoda lokalizacije mjesta prometne nesreće, što je prethodno

ponekad bilo teško odrediti, posebice ako se CPN dogodio na cestama izvan naselja. Takvim se pristupom ostvaruju preduvjeti za detekciju kritičnih područja djelovanja, pri čemu financijska ulaganja u optimalne mjere sigurnosti prometa ostvaruju svoju maksimalnu ekonomsku učinkovitost (visok stupanj povrata ulaganja) te ujednačuju opću razinu sigurnosti svih pojedinačnih skupina sudionika u prometu.

Na temelju pregleda obrađenih statističkih informacija o pojedinačnim CPN-ima, IS MUP-a RH u mogućnosti je generirati različite oblike statističkih tabličnih izvještaja i grafičkih prikaza koji se kasnije mogu koristiti za daljnja analitička istraživanja u svrhu predlaganja mjera za sanacije opasnih lokaliteta te poboljšanje stupnja sigurnosti.

Valja napomenuti kako javno dostupni podatci o CPN-u koje osigurava MUP ne uključuju geografske atribute, tj. geografske lokacije CPN-a. Stoga, ako zdravstvene i druge institucije, organizacije i tijela koja se bave pitanjima sigurnosti prometa, pravne i fizičke osobe koje obavljaju javni prijevoz i prijevoz za vlastite potrebe te drugi žele koristiti takve statističke podatke u svrhu izučavanja, prethodno moraju službeno ispuniti zahtjev, na temelju čega im MUP izdaje odgovarajuću potvrdu.

Dostavljanje statističkih podataka o CPN-u iz Nacionalne baze podataka u Središnju bazu Europske komisije, a za potrebe njihova prikupljanja i centraliziranja u skladu s preporukama Bijele knjige, RH je regulirala usvajanjem Odluke vijeća od 30. studenoga 1993. o izradi baze podataka Zajednice o nesrećama u cestovnom prometu (93/704/EZ) [1]. Otada Republika Hrvatska aktivno sudjeluje u godišnjem dostavljanju podataka o nesrećama koje za posljedicu imaju smrtni ishod ili ozljedu (teži oblici CPN-a) statističkomu uredu Europske zajednice (*EUROSTAT*). Navedeni se podatci otada koriste u svrhu vođenja Europske baze podataka o prometnim nesrećama – CARE (*engl. Community data bank on road traffic accidents in Europe*).

Nadalje, Republika je Hrvatska dužna dostavljati državama članicama EU-a podatke vezane uz sigurnost prometa na cestama u skladu s potpisanom direktivom [124] Europskoga parlamenta i Vijeća od 2011. godine o olakšavanju prekogranične razmjene informacija o prometnim prekršajima, što je regulirano pripadajućim Pravilnikom [125], a na temelju članka 296. stavka 5. Zakona o sigurnosti prometa na cestama. Tim su zakonom definirani protokolarni postupci koje je potrebno osigurati u svrhu sigurne i zaštićene razmjene podataka te lista prekršaja koje je predviđeno dostavljati nacionalnim kontaktnim točkama država članica EU-a:

- prekoračenje ograničenja brzine,
- vožnja bez korištenja sigurnosnoga pojasa,
- prelazak kroz crveno svjetlo,
- vožnja pod utjecajem alkohola,

- vožnja pod utjecajem droga,
- vožnja bez zaštitne kacige,
- vožnja kolničkom trakom u kojoj je zabranjena vožnja,
- nezakonita uporaba mobilnoga telefona ili drugoga komunikacijskog uređaja u vožnji.

Osim navedenoga, važno je napomenuti kako se unutar IS-a MUP-a, osim podataka o CPN-u i njihovim posljedicama, na temelju Zakona o sigurnosti prometa na cestama vodi kvalitetna baza podataka o vlasnicima ili korisnicima vozila (izrečene zaštitne mjere, negativni prekršajni bodovi, mjere pisanoga upozorenja i dr.) te vrstama i karakteristikama motornih vozila.

Trenutna zakonska obveza obvezuje MUP da podatke o prekršajima i njihovim počiniteljima unutar Informacijskoga sustava pohranjuje kroz period od najmanje 10 godina, dok se podatci o CPN-u i drugim incidentnim događanjima u prometu čuvaju u periodu od najmanje 15 godina.

Ovlašteni korisnici tih podataka prvenstveno su tijela nadležna za obavljanje poslova iz predmetne tematike – pravosudna tijela, tijela ovlaštena za vođenje prekršajnoga postupka i dr.

Podatci o CPN-u i stradalim sudionicima u prometu na području obuhvaćenom RH datiraju još iz 1981. godine. Znatno kvalitetniji i detaljniji nacionalni sustav izvještavanja o CPN-u Vlada je RH uspostavila od 1996. godine kroz odgovarajuće *Biltene o sigurnosti cestovnog prometa*, gdje su sve relevantne informacije o CPN-u sistematizirane i kategorizirane kroz specijaliziranu kompjuteriziranu bazu podataka unutar Informacijskoga sustava MUP-a RH te su većim dijelom kompatibilne s ostalim zemljama članicama EU-a.

S obzirom na to da je Informacijski sustav prikupljanja i obrade podataka o CPN-u u RH prisutan praktički od njezina osnutka, on se u skladu s tehnološkim mogućnostima i obligatornim zakonskim obvezama sustavno nadograđuje i modernizira.

Prema tomu, i sam se broj ulaznih varijabli koje su uključene u statističko-analitičku obradu Informacijskoga sustava MUP-a tijekom godina sustavno ažurira kao svojevrsni odgovor na nove sofisticirane tehnologije. Tijekom 2009. godine u IS-a MUP-a izvršeno je nekoliko nadopuna aplikacija kojima se statistički prate prometne nesreće, prekršaji u prometu te rad autoškola i stanica za tehnički pregled vozila. Izrađen je, umjesto dotadašnjega PN-10, novi obrazac za statističko praćenje prometnih nesreća, UPN (*Upitnik o prometnoj nesreći*), kojim se praćenje prometnih nesreća u statističkom smislu, zbog određenih nadopuna i izmjena, podiglo na višu razinu. Izmijenjeni način prikupljanja i unosa podataka u IS MUP-a na snazi je od 1. siječnja 2010. godine, [126] te obuhvaća ukupno 38 upita.

Za nacionalnu bazu podataka o prometnim nesrećama bitno je da sadrži sve relevantne elemente koji mogu unaprijediti sustav statističke analize CPN-a, za što je preduvjet da bude temeljen na aktualnim znanstvenim metodama, posebice u aktivnostima tijekom prikupljanja, pohranjivanja, analiziranja te dostavljanja određenih prometno-sigurnosnih informacija i stručnih izvještaja.

Ti su elementi u korelaciji s istovjetnim sustavima ostalih zemalja Europske unije kako bi se ostvarili preduvjeti za implementaciju jedinstvenoga sustava praćenja incidentnih situacija i događaja u prometu, a što već duže vrijeme proklamiraju organizacije mjerodavne za predmetnu tematiku u Europskoj uniji.

No, imajući u vidu prethodno navedeno, potrebno je konstatirati da je, iako se informacijski sustav MUP-a kontinuirano nadograđuje s novim bitnim obilježjima i indikatorima kritičnima za praćenje stanja sigurnosti cestovnoga prometa, potrebno što prije implementirati novu, jedinstvenu nacionalnu bazu podataka o praćenju CPN-a i obilježja sigurnosti prometa, usklađenu s objavljenim analizama i preporukama CADAS strukture, odnosno CARE baze podataka koju vodi Europska komisija (Odluka vijeća 93/704/EZ). Za to je potrebno pripremiti i pripadajući provedbeni materijal – *Priručnik*, kako bi se na temelju njega mogli kvalitetno educirati budući certificirani kadrovi. Osnova predloženoga radnog materijala treba biti dokument koji je Europska komisija objavila pod nazivom *Recommendation for a Common Accident Data Set, Reference Guide, Version 3.11* u siječnju 2011. godine, a unutar kojega je naznačen osnovni set podataka o CPN-u koje je potrebno prikupljati u zemljama članicama Europske unije za potrebe europske baze podataka o obilježjima sigurnosti prometa CARE.

4.3. Formiranje integrirane baze podataka o cestovnim prometnim nesrećama za urbana područja

Radna tijela lokalne samouprave također bi trebala uspostaviti sustav prikupljanja statističkih podataka o čimbenicima sigurnosti cestovnoga prometa, odnosno raspolagati kvalitetnom unificiranom statističkom bazom podataka o CPN-a unutar njihova administrativnog područja nadležnosti – analitičkim računalnim programskim rješenjem temeljenim na bazi *web*-sučelja[31] u stvarnom vremenu.

[31] Korisnik pregledava i koristi aplikaciju kroz web preglednik (Chrome, Firefox ili Safari) ili pomoću klasičnih GIS aplikacija (primjerice QGIS), ovisno o načinu korištenja i potrebama korisnika.

Takvu praksu, odnosno suradnju s prometnom policijom na prikupljanju i sistematiziranju relevantnih podataka trebala bi slijediti sva lokalna i regionalna središta u RH, čime bi se ostvarili preduvjeti za formiranje tipiziranih detaljnih statističkih baza podataka o sigurnosti prometa, a koje bi bile u korelaciji sa sustavima koji su implementirani u zemljama Europske unije.

Jedan je od razloga za implementaciju navedenoga i dosadašnja praksa. Naime, ako djelatnici lokalne i područne (regionalne) samouprave zaduženi za područje sigurnosti i tehničke regulacije prometa žele provesti prometno-sigurnosnu analizu nad određenom mikrolokacijom – za potrebe semaforizacije, dodatne prometne signalizacije i opreme te dr., od predstavnika MUP PUZ-a moraju prethodno pisanim putem zatražiti dostavljanje relevantnih podataka za traženu lokaciju, odnosno izvješće o broju i vrsti (strukturi) prometnih nesreća zajedno s dijagramom kolizionih točaka.

S obzirom na to da se takva izvješća tijekom godine traže za više desetaka potencijalno rizičnih lokaliteta (a što predstavlja znatan vremenski angažman predstavnicima MUP, PUZ-a), tim bi se načinom sam proces znatno ubrzao, te bi se predstavnicama Grada omogućilo da samostalno, neovisno o predstavnicima MUP-a provode određene sigurnosne statističke analize stanja, a na raspolaganju bi im za to bio dostatan set parametara (kategorijskih varijabli) za odabir i provođenje optimalnoga prometnog rješenja, odnosno mjere sigurnosti prometa. Implementacijom predložene integrirane baze podataka bile bi otklonjene eventualne dvojbe u samom početku kreiranja određenih aktivnosti, nepotrebna prepiska s predstavnicima MUP PUZ-a i potreba za naknadnim otklanjanjem izvedenih pogrešaka na terenu. Također, ostvario bi se detaljniji odnosno precizniji nivo praćenja (obuhvaćeni svi oblici CPN-a s detaljnijim informacijama o pojedinim rizičnim mikrolokacijama u kombinacijama s relevantnim prometnim podatcima o gradskom sustavu) nužan za kvalitetniju procjenu stanja i aktivnosti na lokalnojrazini.

U skladu s time, u svrhu optimizacije rada te sigurnosne razmjene podataka nužno je uspostaviti izravnu zaštićenu protokolnu kontaktnu povezanost s IS-om MUP-a, s jasno definiranim ovlastima koje svaki korisnik ima na raspolaganju. Administriranje aplikacije moguće je urediti prema vlastitoj viziji sustava, ali ono je u načelu organizirano u dvije osnove grupe – onih koji imaju upravljačke ovlasti spram unosa podataka u sustav (u ovom slučaju djelatnici MUP-a) te onih koji imaju ograničene ovlasti u smislu automatiziranoga pregleda podataka u svrhu provođenja određenih prometno-sigurnosnih analiza (u ovom slučaju korisnici unutar gradskih službi i zavoda). Ujedno, zbog olakšavanja korištenja programske aplikacije nužno je u što većoj mjeri pokušati ostvariti unifikaciju sadržaja (standardizaciju tabličnih prikaza te grafičkoga sučelja) između dvaju programskih rješenja.

S obzirom na to da unosom podataka u IS MUP-a, dobivenih ispunjavanjem UPN-a, dostupnim postaje i velik broj osobnih podataka građana (sudionika CPN-a), potrebno je poštivati njihovu tajnost i povjerljivost te stoga takvi podatci ne smiju biti u paketu koji će biti dostupan krajnjim korisnicima sustava i široj stručnoj javnosti te trebaju biti zaštićeni (cenzurirani) u skladu s naputcima Agencije za zaštitu osobnih podataka.[32]

Osim ulaznih podataka pribavljenih kroz službenu bazu podataka MUP-a, integriranih na temelju prethodno razvijenoga i ažuriranoga Geografsko-informacijskoga sustava (GIS), nužno je da predmetna baza podataka obuhvaća i sve ostale relevantne podatke (prostorne i alfanumeričke) nužne za kvalitetno praćenje i analiziranje stanja sustava sigurnosti prometa[33], kao što su čimbenici sigurnosti cestovnoga prometa (direktni i indirektni – broj stanovnika, starosna struktura stanovništva, populacija i postotak vozača, broj registriranih motornih vozila, geografski položaj, površina teritorija urbanoga područja i sl.), stanje cestovne infrastrukture (struktura i geometrija prometnica, cestovna prometna oprema i signalizacija, lokacije javnih parkirališta, linija i stajališta JGPP-a), referentni prometni podatci (katastar prometne infrastrukture Grada Zagreba, struktura prometnoga toka, podatci o PGDP-u, podatci o broju prijeđenih kilometara vozila na teritoriju lokalne uprave), podatci o osnovnim tipovima ponašanja sudionika u prometu koji dovode do pojave CPN-a (s posebnim naglaskom na starije i mlađe sudionike u prometu), ozlijeđenim sudionicima u prometu (hitni interventni timovi – zdravstvene

[32] Na temelju ustavne odredbe o pravu na zaštitu osobnih podataka (čl. 37. Ustava Republike Hrvatske) donesen je Zakon o zaštiti osobnih podataka (Narodne novine, broj 103/03, 118/06, 41/08, 130/11, 106/12 – pročišćeni tekst), koji je u svim bitnim odredbama u skladu s Direktivom 95/46/EZ o zaštiti pojedinaca u vezi s obradom osobnih podataka i o slobodnom kretanju takvih podataka. Kao podzakonski akti u području zaštite osobnih podataka u RH u primjeni su Uredba o načinu vođenja i obrascu evidencije o zbirkama osobnih podataka (Narodne novine, broj 105/04) i Uredba o načinu pohranjivanja i posebnim mjerama tehničke zaštite posebnih kategorija osobnih podataka (Narodne novine, broj 139/04).

[33] Pri modeliranju predmetnoga informacijskog sustava potrebno je osigurati da se podatci sadržani u jedinstvenoj bazi podataka, koja sadrži i prostornu komponentu, mogu dorađivati, prikazivati i održavati u skladu sa zahtjevima korisnika te standardima u okviru geoinformacija europske i svjetske organizacije za normizaciju. Također, treba biti omogućeno i naknadno proširivanje baze podataka kako po broju nezavisnih cjelina tako i po broju entiteta i vrsti atributnih obilježja. To se ostvaruje modularnom arhitekturom sustava, pri čemu će jedinstvena baza podataka sadržavati različite komponente drugih sustava koji će se modularno nadograđivati.

ustanove, vatrogasci), podatci o motornim vozilima, podatci o provođenju tehničkih pregleda vozila, podatci o registracijama vozila u stanicama za tehnički pregled vozila[34] i dr.

Prilikom modeliranja predmetne baze podataka prethodno je potrebno osigurati uvid u baze podataka navedenih institucija i svih onih s kojima se planira razmjena podataka kako bi programsko rješenje bilo kompatibilno s njihovim postojećim programskim rješenjima (aplikacijama).

Traženi podatci trebaju biti ažurirani na mjesečnoj bazi te strukturirani na razini pojedinih policijskih uprava, županija, općina, gradova, gradskih četvrti i dr., a za potrebe izvođenja detaljnijih analiza i komparacija.

Bitan je segment predložene baze podataka i provedba kontinuiranih izvještavanja o aktualnom stanju i problemima sigurnosti cestovnoga prometa na području Grada Zagreba, i to ovisno o ukazanim potrebama, na mjesečnoj, polugodišnjoj i godišnjoj razini. Predmetna bi izvješća služila kao stručna podloga lokalnim izvršnim tijelima za praćenje kretanja stanja osnovnih parametara sigurnosti prometa – Gradskoj skupštini da minimalno dva puta godišnje, a koordinativnoj radnoj skupini na upravljačkoj razini da na mjesečnoj bazi analizira i stalno ocjenjuje stanja sigurnosti u prometu [127].

S obzirom na to da je takav GIS alat predstavnicima gradske administracije neophodan te s obzirom na veliki broj prethodno navedenih pogodnosti koje bi se mogle ostvariti njegovom implementacijom u području sigurnosti cestovnoga prometa na lokalnoj razini (mogućnost formiranja digitalizirane karte CPN-a s točnim GPS lokacijama, unutar kojih je moguće jasno naznačiti njihovu prostornu koncentraciju), on se može u relativno kratkom roku i uz male financijske izdatke realizirati kao zasebni modul (programski paket) postojećega *Geografskog informacijskog sustava (GIS) Grada Zagreba*[35] ili se može realizirati prilikom uspostave *Katastra prometne infrastrukture Grada Zagreba.*

Implementirana baza podataka smjestila bi se na hardversku jedinicu (server) unutar Gradske uprave, dok bi se kopija baze podataka nalazila kod izvođača radova. Programska aplikacija mora biti vremenski licencirana na neodređeno vrijeme uz mogućnost da je ovlašteni korisnici sustava dopunjuju i izmjenjuju. U skladu s time, za korištenje programske aplikacije potrebno je osigurati

[34] Ministarstvo unutarnjih poslova svojim je rješenjem povjerilo Centru za vozila Hrvatske d. d. i Hrvatskomu autoklubu javnu ovlast za obavljanje navedenih poslova.

[35] Sustav za upravljanje prostornim podacima i osobinama pridruženih njima, razvijen u suradnji sa lokalnim partnerom, tvrtkom APIS-IT d.o.o.

obuku (školovanje) minimalno četiriju ovlaštenih korisnika za rad s cjelovitim sustavom i to kroz primjenu pripadajućih korisničkih priručnika za tehničku pomoć i funkcioniranje aplikacije.

4.4. Zaključna razmatranja

Dosadašnje tradicionalne analize i sigurnosne procjene stanja cestovnoga prometnog sustava u urbanim sredinama uglavnom su se provodile kroz statističke analize službenih zbirnih retrospektivnih podataka o CPN-u, pri čemu su se tražile određene zakonitosti između različitih sigurnosnih čimbenika. To se često provodi uz izostavljanje prostornih atributa nastanka CPN-a, kao i ambijentalnih podataka o njima (zapažanje i tumačenje cestovne okoline, oprema i sučelje vozila, obuka vozača i dr.), što uvelike ograničava kvalitetno praćenje CPN-a. U skladu s vremenskim karakteristikama nastanka određenoga CPN-a, uvjetima na cesti i drugim relevantnim informacijama prikupljenima na terenu, možemo uspješno sumirati njegova obilježja i zakonitosti te utvrditi uzroke nastanka.

Nadalje, postojeći sustav prikupljanja podataka o CPN-u u RH (statističko praćenje uzroka i/ili pogrešaka sudionika u prometnim nesrećama) nije usporediv s onim u najrazvijenijem zemljama Europe (CADAS preporuke Europske komisije). U najvećem broju zemalja Europske unije predstavnici prometne policije educirani su za prikupljanje podataka o tzv. *utjecajnim čimbenicima* (čimbenici koji u većoj ili manjoj mjeri doprinose nastanku CPN-a) u procesu nastanka CPN-a. Prednosti su navedenoga pristupa mnogobrojni, no najvažnija je ta što u odnosu na postojeći način prikupljanja podataka o uzrocima CPN-a – policijski se službenici za svaki CPN opredjeljuju za jedan (prvi izabrani uzrok predstavlja ujedno i primarni uzrok) ili dva (primarni i sekundarni) uzroka – on otklanja mogućnost zanemarivanja svih ostalih čimbenika koji su uključeni u proces nastanka konkretne incidentne prometne situacije. U tom je dijelu poseban naglasak stavljen na prikupljanje novih informacija o CPN-u, što uključuje dodatne podatke o okolnostima nastanka prometnih nesreća – manevrima sudionika, čimbenicima okruženja, uvjetima u prometu i sl., te obuhvaća dopunu i određene korekcije postojećih setova podataka naznačenih u *Upitnicima o prometnim nesrećama*.

Problemske situacije pojedinih lokalnih uprava na razini Europe odnose se i na nepotpuno prijavljivanje i nedostupnost podataka o CPN-u, što značajno narušava provedbu statističkih analiza i procjena u području sigurnosti prometa. Navedene se situacije mogu anulirati dodatnom obukom djelatnika prometne policije te kvalitetnijim praćenjem procesa prikupljanja i unosa podataka s terena.

Iz prethodnih analiza međunarodnih baza podataka o CPN-u indikativno je kako je u svrhu povećanja sigurnosne komponente odvijanja cestovnoga prometnog sustava u urbanim sredinama nužno ustanoviti integriranu i relevantnu nacionalnu bazu (kao i zasebne lokalne i regionalne baze za analizu podataka o CPN-u), uz paralelno poduzimanje daljnjih aktivnosti za unapređenje kvalitete analize i statističkoga praćenja CPN-a. Baza podataka koja uključuje podatke o obilježjima sigurnosti cestovnoga prometa na lokalnoj razini vrlo je značajna za definiranje politika i strategija sigurnosti prometa, kao i pripadajućih akcijskih planova i programa gradova.

To se prije svega planira ostvariti ulaganjem dodatnih financijskih sredstava u razvoj budućega i usavršavanje postojećega službenoga informacijskog sustava za unos i praćenje CPN-a, koji vodi Ministarstvo unutarnjih poslova Republike Hrvatske. To se prije svega odnosi na nužnost povećanja broja ulaznih parametara koje će se prikupljati i analizirati kroz informacijski sustav te njihovu standardizaciju na temelju CADaS protokola kako bi se takve službene baze podataka mogle što bolje iskoristiti (analizirati karakteristike CPN-a i obilježja prometnih prekršaja) i pružiti adekvatnu savjetodavnu funkciju donositeljima odluka. Takav model baze podataka o CPN-u omogućava provedbu značajnoga broja specijaliziranih statističkih analiza značajnih s aspekta sigurnosti cestovnoga prometa kako bi se identificiralo postojeće stanje sigurnosti prometa te, s time u svezi, definirali prijedlozi mjera za unapređenje sigurnosti prometa.

Također je detektiran i nedostatak provedbe dubinskih analiza težih oblika CPN-a na području RH, što predstavlja ustaljenu praksu u visokorazvijenim zemljama Europske unije. Kao podlogu za njihovu implementaciju važno je analizirati procedure i protokole koje su prethodno provedene u sklopu nekoliko međunarodnih projekata, kao što su *Cooperative Crash Injury Study* (*CCIS*) i *On-the-Spot* (*OTS*) u Ujedinjenom Kraljevstvu, *In-Depth Accident Study* (*GIDAS*) u Njemačkoj, *Fatal Accident Reporting System* (*FARS*) u SAD-u te *Factors Influencing the Causation of Accidents and Incidents* (FICA) u Švedskoj.

Nadalje, u skladu s uvriježenom svjetskom praksom, potrebno je ojačati suradnju i koordinaciju predstavnika lokalnih prometnih policija sa strukturama lokalne vlasti u svrhu dijeljenja informacija o sigurnosti prometa te kvalitetnoga kvantificiranja zajedničkih prometno-sigurnosnih projekata. U tom je dijelu posebno važno naglasiti kako je nužno omogućiti pristup takvim informacijama ciljanim korisnicima (znanstvenoj zajednici, specijaliziranim udrugama i sl.) kroz razmjenu datoteka uporabom standardiziranih obrazaca.

Osim poboljšanja postupaka tijekom istražnoga postupka (analiza prometne nesreće, dijagrami kolizije, GPS uređaji, itd.) te provedbe prometne obuke policijskih službenika, prioritetni prijedlog budućih aktivnosti na modernizaciji i reorganizaciji postojećih baza podataka o CPN-u na lokalnoj i nacionalnoj razini zahtijeva uključivanje podataka mjerodavnih baza podataka o cestovnoj

infrastrukturi (katastar prometne signalizacije i karakteristike lokalne cestovne mreže) i motornim vozilima, baze podataka o prometnim obilježjima (prometno opterećenje, stupanj motorizacije, pokazatelji stanja javnih i nerazvrstanih cesta, PGDP pojedinih kategorija vozila i sl.), podataka o štetama i troškovima CPN-a (osiguravajuće kuće) te ostalim relevantnim čimbenicima, prikupljenima kroz:

- Centar za vozila Hrvatske,
- službe za inspekciju cestovnoga prometa i cesta (Ministarstvo pomorstva, prometa i infrastrukture),
- odjel zadužen za upravljanje cestovnom infrastrukturom na području Grada Zagreba,[36]
- bazu podataka o volumenu prometa i uvjetima na cesti (prometni model grada),
- provedbu anketa o ponašanjima sudionika u prometu te stavovima šire javnosti o sigurnosti prometa pojedinih prometnih modova (na temelju evidentiranih prekršaja tijekom nadzora prometa – korištenje sigurnosnih pojaseva, zaštitnih kaciga, prolaza kroz crveno i dr., moguće je kreirati bazu podataka o indirektnim pokazateljima sigurnosti prometa, koji se za potrebe daljnjih stručnih analiza zajedno promatraju s direktnim pokazateljima sigurnosti prometa) [128].

Treća stavka, regulirana Zakonom o cestama (NN 84/11, …, 92/14) i Odlukom o nerazvrstanim cestama (SGGZ 18/13, 16/14), institucionalno spada u nadležnost gradske uprave, točnije novoformiranoga Odjela za katastar prometne signalizacije. Unutar njega se obavljaju poslovi informatizacije sustava nerazvrstanih cesta i cestovnih objekata, odnosno vođenje jedinstvene baze podataka o nerazvrstanim cestama, vođenje i ažuriranje katastra nerazvrstanih cesta, cestovnih objekata, prometne signalizacije i oprema javnih i nerazvrstanih cesta i cestovnih objekata.

Kreiranjem opsežne jedinstvene baze podataka, koja kod nas još uvijek nije ustrojena, pospješila bi se postojeća statističko-dokumentacijska osnova, koja bi djelatnicima na svim razinama i strukturama (lokalna i nacionalna) države i društva omogućila sustavno utvrđivanje i sanaciju najkritičnijih lokacija sa stanovišta sigurnosti prometa na cjelokupnoj cestovnoj mreži te

[36] Za održavanje prometne infrastrukture na području Grada Zagreba u skladu s postojećim zakonima odgovorne su Hrvatske autoceste d. o. o. (HAC), Hrvatske ceste d. o. o. (HC) i Grad Zagreb koji je za te potrebe u sklopu Zagrebačkoga holdinga d. o. o. ustrojio podružnicu Zagrebačke ceste. U skladu sa zakonskom obvezom, navedeni subjekti trebali bi se pridržavati *Programa izgradnje i održavanja javnih cesta za razdoblje 2013. – 2016.* (NN 1/14), koji je usklađen sa *Strategijom prometnog razvitka* i *Strategijom prostornog uređenja Republike Hrvatske*.

omogućila donošenje kvalitetnih zaključaka i potvrđivanje radnih hipoteza u znanstveno-istraživačkim projektima iz toga područja.

Takvom analizom svih relevantnih obilježja cestovnoga prometa, značajnima za praćenje njegove sigurnosti, moguće je ukazati na nedostatke prometnica te njezine okoline, nedostatke u odvijanju prometa te rizičnom ponašanju sudionika u prometu. Na lokalnoj razini obveza je lokalnih vlasti koje su zadužene za nadzor i upravljanje prometom da na temelju podataka o lokacijama teških oblika CPN-a detaljnom analizom čimbenika utvrde uzroke njihova nastanka te po potrebi provedu proceduru gradnje ili rekonstrukcije nedostajućih cestovnih elemenata prometnica i/ili cestovnih objekata, odnosno ugradnje sigurnosne opreme, kao što su oznake na cestama, prometna signalizacija, odbojne pješačke ograde i sl.

S obzirom na obilježje interdisciplinarnosti (podatci se iz različitih izvora uspoređuju i integriraju), tako bi ustrojenu bazu podataka, prije formiranja zasebne središnje *Nacionalne agencije za sigurnost cestovnog prometa Republike Hrvatske*, trebalo povjeriti nadležnomu ministarstvu, odnosno Ministarstvu pomorstva, prometa i infrastrukture, koje već posjeduje kvalitetne stručne kadrove i infrastrukturu za koordinaciju s predloženim subjektima.

Za daljnje obavljanje predstojećih značajnih poslova Ministarstvo bi trebalo oformiti profesionalan tim, odnosno prilagoditi svoju organizaciju te uspostaviti zasebnu ustrojstvenu jedinicu, sektor ili barem odjel, u kojoj bi njezine djelatnike trebalo osloboditi obveza koje imaju prema matičnim upravnim tijelima, uz odgovarajuće vrednovanje složenosti poslova, zadataka i odgovornosti.

Kako je Republika Hrvatska po mnogim svojim gospodarskim i prometnim indikatorima definirana kao zemlja koji se nalazi u svojoj razvojnoj fazi [129], valja naglasiti kako je samim time i prometna situacija značajno drugačija u odnosu na druge razvijene zemlje, posebice u odnosu na nordijske i zemlje zapadne Europe, koje u odnosu na Hrvatsku izdvajaju znatno veća financijska sredstva za tu namjenu te imaju kvalitetnije organizirane investicijske strategije usmjerene na povećanje razine sigurnosti svojih cestovnih prometnih sustava [130].

5. DUBINSKA ANALIZA PODATAKA O CESTOVNIM PROMETNIM NESREĆAMA U GRADU ZAGREBU

Sigurnost cestovnoga prometa predstavlja posebno značajno obilježje cestovnoga prometnog sustava.

Republika Hrvatska, kao i mnoge ostale zemlje svijeta koje pripadaju Organizaciji za ekonomsku suradnju i razvoj (OECD) najvišu stopu smrtnih slučajeva u CPN-u doseže tijekom 70-ih godina. Otada, uz određene fluktuacije u stagnaciji ili porastu broja smrtnih slučajeva, dugoročni trend možemo okarakterizirati kao stabilan s kontinuiranim negativnim predznakom.

Promatrajući stanje sigurnosti u RH u posljednjih nekoliko desetljeća evidentno je kako realizacija nekoliko bitnih mjera prometne sigurnosti, usvojenih kroz dopune i izmjene dvaju krovnih dokumenata sigurnosti cestovnoga prometa – Zakona o sigurnosti cestovnog prometa i Nacionalnoga programa sigurnosti cestovnoga prometa, korespondira sa značajnim smanjenjem broja smrtnih slučajeva. S obzirom na to da u tom periodu nisu vođene evaluacijske studije koje bi potvrdile povezanost između implementiranih mjera i stopa smanjenja poginulih osoba, takva razmatranja ostaju samo pretpostavke (Grafikon 5.1.).

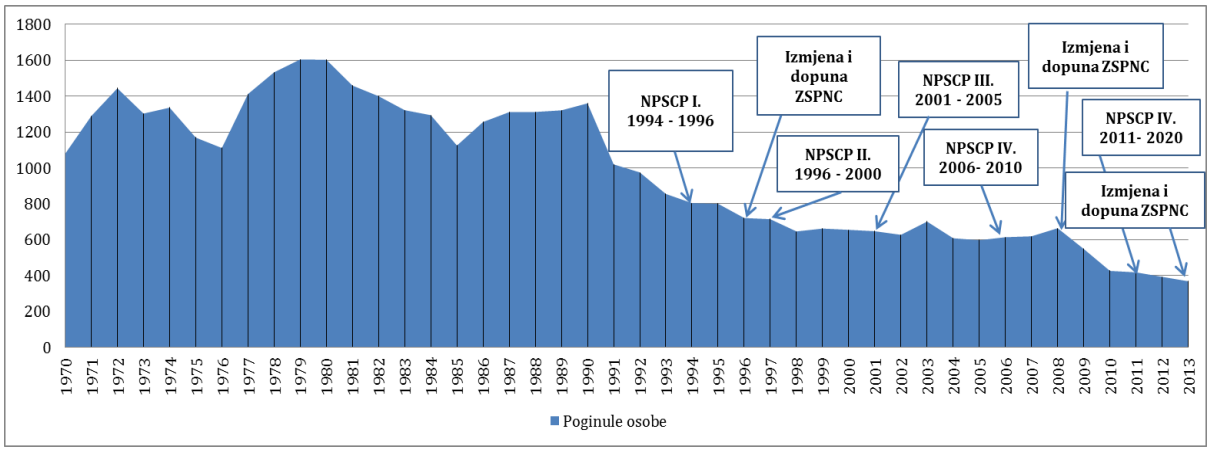

Grafikon 5.1. Dugoročni trend kretanja stopa poginulih osoba u razdoblju 1970. – 2013. u Republici Hrvatskoj s naznakama usvajanja krovnih dokumenata sigurnosti cestovnoga prometa
Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, dopuna i obrada autora

Promatrajući analizu trendova sigurnosti prometa u RH kroz duži vremenski period, mogu se uočiti neka pozitivna kretanja u vezi sa stupnjem sigurnosti, kako na razini gradova tako i na

nacionalnoj razini. Statistički pokazatelji obrađeni u periodu između 1970. i 2010., tj. dugoročni trendovi kretanja broja smrtnih slučajeva u padu su gotovo 70%, dok je alarmantan podatak kako broj ozlijeđenih osoba stagnira, te se kreće u prosjeku oko 18.000 osoba.

Na temelju dubinske analize dugoročnih zbirnih podataka o CPN-u možemo konstatirati dva značajna razdoblja vezana uz sigurnost cestovnoga prometa u RH. Prvo se razdoblje odnosi na period do 2003., pri čemu je prisutan značajan apsolutni broj svih oblika registriranih prometnih nesreća te nastradalih sudionika u prometu, s često oscilirajućim periodima pozitivnih ali i negativnih trendova, s kojima je njihov broj rastao. Takve učestale nestabilnosti (devijacije) u broju promatranih parametara ukazuju na nedjelotvornost odnosno nereguliranost stabilnih procedura upravljanja sustavom sigurnosti cestovnoga prometa.

Brojka smrtno stradalih sudionika na cestama Republike Hrvatske dosegla je svoj vrhunac u 1979. godini, kada je 1.605 ljudi smrtno stradalo na prometnicama. Otada je taj broj u stalnom opadanju (izuzetak nekoliko godina), a od 1992. godine taj je broj kontinuirano ispod 1.000.

Drugo razdoblje odnosi se na srednjoročni vremenski period od 2004. godine do danas, s gotovo kontinuiranim trendom pada svih značajnijih pokazatelja sigurnosti cestovnoga prometa. U razdoblju od posljednjih 10-ak godina na području Republike Hrvatske broj prometnih nesreća kao i osoba nastradalih u tim nesrećama izrazito je varirao na godišnjoj razini – prosječno je godišnje zabilježeno oko 52.000 CPN-a, dok su u njih 29% stradavale osobe (14.905 osoba). Od navedenoga broja nastradalih sudionika, u 2% osobe su poginule, što prosječno godišnje iznosi 526 osoba, dok ih je 20.600 teško ili lako ozlijeđeno.

Valja navesti i činjenicu kako se u razmatranom vremenskom periodu duljina putovanja istodobno mnogostruko povećala, kao i broj prometnih entiteta, što ipak ukazuje na pozitivne korake preventivnih i represivnih radnji nadležnih institucija.

U vezi s posljedicama za sigurnost, srednjoročni trendovi određenih temeljnih sigurnosnih pokazatelja ukazuju na to kako se sigurnost cestovnoga prometa u Republici Hrvatskoj kontinuirano popravlja, te se bilježi smanjenje u svim događanjima.

Prema dostupnim službenim podatcima Ministarstva unutarnjih poslova, (Grafikon 5.2.) prikazano je kretanje broja CPN-a i nastradalih osoba na području Republike Hrvatske za vremenski period od proteklih 15 godina, odnosno od 1999. do 2013. godine. Potrebno je napomenuti da prilikom provedbe istraživanja za potrebe izrade rada polugodišnji podatci za 2014. godinu nisu bili dostupni, dok su podatci u tablici svrstani u rubriku nastradalih osoba podijeljeni prema poginulim i ozlijeđenim osobama (ukupni zbroj evidentiranih teških i lakih tjelesnih ozljeda).

Promatrajući ukupan broj evidentiranih cestovnih prometnih nesreća na prostoru Republike Hrvatske, možemo zaključiti da je nakon porasta broja nesreća od 33,87% (1999. godine u odnosu na 2003.) uslijedilo desetogodišnje gotovo kontinuirano smanjenje broja prometnih nesreća, i to za 63,06% (2003. godine u odnosu na 2013.), a od 2007. je prisutna stabilizacija bez značajnijih oscilacija, s blagim trendom pada.. Takav je trend zamjetan u vezi s brojem poginulih osoba – naime, u 2013. je godini u odnosu na 2003. zabilježeno smanjenje od 47,50%, kao i kod broja ozlijeđenih osoba.

Od ukupnoga broja CPN-a za promatrani vremenski period u prosjeku je poginulo 570 osoba, dok ih je 21.136 teško/lako ozlijeđena. Posebno zabrinjava podatak koji navodi da od ukupnoga broja teško ozlijeđenih osoba njih 5% ostaju trajni stopostotni invalidi (godišnje više od 200 osoba), a 10% trpi određeni oblik trajnih posljedica, pri čemu je najčešće riječ o osobama mlađe životne dobi.[37]

Za promatrani vremenski period najveće postotno smanjenje broja poginulih osoba zabilježeno je 2009. godine u odnosu na 2008., u iznosu od 17,47%, za što je najviše zaslužna primjena novoga Zakona o sigurnosti prometa na cestama (NN 67/08, …, 64/15) odnosno uvećane novčane kazne za izazivanje prometnih nesreća, posebice u dijelu koji se odnosi na vozače recidiviste prometnih prekršaja (oduzimanje motornoga vozila i vozačke dozvole) te učestalije i djelotvornije policijske kontrole i interventno reguliranje prometa.[38]

U vezi s posljedicama za sigurnost, nedavni trendovi spomenutih osnovnih sigurnosnih indikatora također ukazuju na to kako se sigurnost cestovnoga prometa u Republici Hrvatskoj također kontinuirano popravlja. Pregledom apsolutnoga broja CPN-a na prometnicama RH u 2013. godini evidentirano je 34.021 CPN (–8,2% u odnosu na 2012. god.), u kojima je 368 osoba smrtno stradalo (–1,88% u odnosu na 2012. god.), a 15.274 osobe su lakše/teže ozlijeđene (–3,25% manje u odnosu na 2012. god.).

[37] Oobradom podataka Hrvatskoga registra o osobama s invaliditetom i Hrvatskog zavoda za javno zdravstvo (2014.), utvrđeno je da su kod registriranih osoba s invaliditetom (2.913 osoba) prometne nesreće bile uzrok invalidnosti.

[38] Ostale značajnije izmjene i dopune Zakona o sigurnosti prometa na cestama odnose se na njegovo usklađivanje s pravnom stečevinom Europske unije, odnosno sa šest direktiva Europske unije.

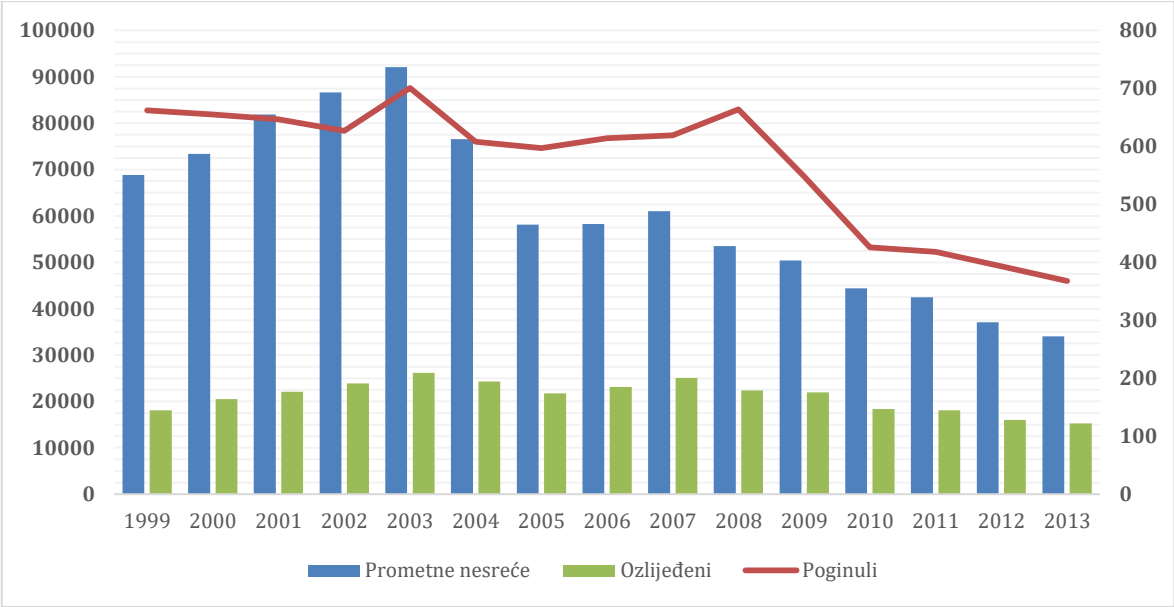

Grafikon 5.2. Kretanje broja CPN-a i stradalih osoba u razdoblju 1999. – 2013. na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb i Statistički ljetopis Republike Hrvatske (od 2005. do 2013), Državni zavod za statistiku RH, Zagreb, obrada autora

Kretanje navedenih pozitivnih trendova vidljivo je i kroz detaljniju analizu osnovnih pokazatelja sigurnosti cestovnoga prometa, odnosno stopa osnovnih kategorija CPN-a (Grafikon 5.3.). Analizirajući predmetni grafikon, možemo konstatirati univerzalnost trendova svih triju kategorija, kao i njihovu vremensku usuglašenost i jačinu promjena trenda.

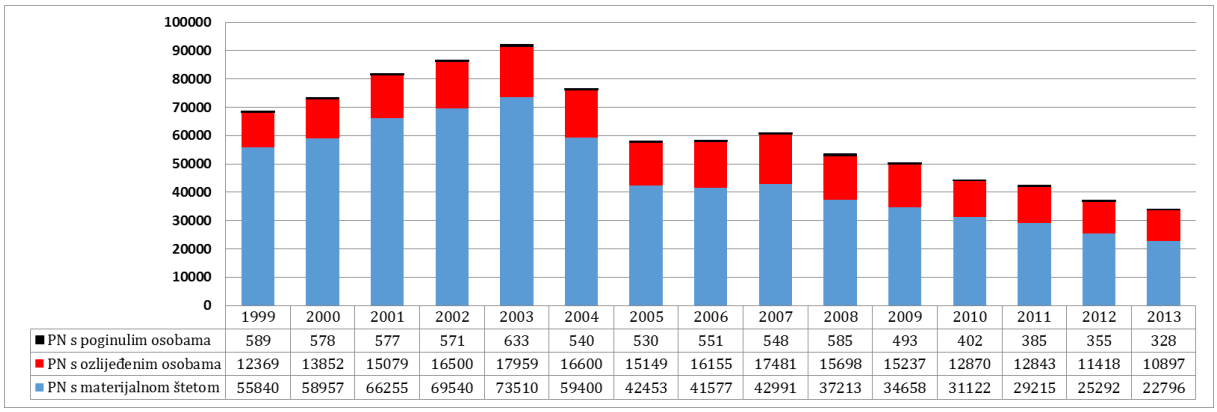

	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013
PN s poginulim osobama	589	578	577	571	633	540	530	551	548	585	493	402	385	355	328
PN s ozlijeđenim osobama	12369	13852	15079	16500	17959	16600	15149	16155	17481	15698	15237	12870	12843	11418	10897
PN s materijalnom štetom	55840	58957	66255	69540	73510	59400	42453	41577	42991	37213	34658	31122	29215	25292	22796

Grafikon 5.3. Stope kretanja osnovnih kategorija CPN-a u prometu u razdoblju 1999. – 2013. na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Tako CPN-i s materijalnom štetom u prosjeku predstavljaju 75,20% ukupnoga broja registriranih prometnih nesreća. Drugo mjesto s 23,96% zauzimaju CPN-i s ozlijeđenim osobama, dok minimalna postotna vrijednosti od 0,83% opada na CPN-e s poginulim osobama.

Analizirajući rezultate prosječne godišnje stope promjene, koja je geometrijska sredina lančanih indeksa, izračunato je prosječno godišnje smanjenje: –6,2% za CPN-e s materijalnom štetom, -4,1% za CPN-e s ozlijeđenim osobama te najmanje smanjenje od –0,9% za CPN-e s poginulim osobama.

Situacija u cestovnom prometu u naznačenom periodu ukazuje na značajan trend pada svih oblika CPN-a. Kontinuirano stabilan trend smanjenja praćenih pokazatelja posebno je zamjetan od 2007. godine do danas. U navedenom vremenskom periodu od 2007. do 2013. godine prosječno godišnje smanjenje iznosi 10,0% za CPN-e s materijalnom štetom, 8,2% za CPN-e s ozlijeđenim osobama, a najmanje je smanjenje od 7,6% za CPN-e s poginulim osobama.

5.1. Analiza trendova sigurnosnih pokazatelja cestovnih prometnih nesreća na području Grada Zagreba

Već duži niz godina ulažu se značajni napori nadležnih gradskih službi i odjela u povećanje razine sigurnosti svih sudionika u prometu.

Lokalne gradske vlasti često si zadaju ciljeve u području upravljanja sigurnošću cestovnoga prometa istovjetne onima što su zadani na nacionalnoj razini, u sklopu nacionalnih programa/strategija cestovnoga prometa te, u skladu s time, statistički prate njihovu realizaciju.

Takvim se pristupom, iako ima određena ograničenja (različita tipologija prostora, zastupljenost kategorija cestovnih prometnica, broja korisnika motornih vozila, obrasci putovanja i sl.), ostvaruje mogućnost međusobne komparacije relativno sličnih gradskih uprava.

Područje Grada Zagreba operativno opserviraju I. i II. postaja prometne policije Zagreb (što ne uključuje dijelove autoceste koji su izvan administrativnoga područja Grada Zagreba) i Policijska postaja Sesvete.

Prema izvješćima Ministarstva unutarnjih poslova Policijske uprave Zagrebačke, u razdoblju 1999. – 2003. (Grafikon 5.4.) sigurnosno stanje s obzirom na broj prometnih nesreća, poginulih te ozlijeđenih osoba na promatranom području nema negativan predznak.

Ujedno, iz grafikona je vidljiv kontinuirani rast broja stanovnika na području Grada Zagreba. Stanovništvo grada Zagreba u posljednjih deset godina raste po prosječnoj godišnjoj stopi od 0,18%.

Broj prometnih nesreća u periodu 1999. – 2013. prikazuje različite trendove. U prvom periodu, od 1999. – 2003. vidljiv je rast broja prometnih nesreća s prosječnom godišnjom stopom od 5,60%.

Tijekom 2003. godine zabilježen je najveći broj prometnih nesreća na području Grada Zagreba (21.011). Otada se taj broj postupno smanjuje te je najmanji 2013. (7.362). U drugom promatranom vremenskom periodu prosječna godišnja stopa smanjenja broja registriranih prometnih nesreća iznosi –9,96%.

Broj poginulih na području Grada Zagreba pokazuje oscilacije uz tendenciju smanjenja. Prosječna godišnja stopa smanjenja u cjelokupnom promatranom periodu iznosi –6,86%.

Broj teško/lako ozlijeđenih sudionika u prometu karakteriziraju tri vremenska perioda. Prvi je periodu 1999. – 2004., drugi 2004. – 2010. i treći 2010. – 2013. U prvom je periodu prisutna visoka razina broja ozlijeđenih osoba. Prosječno je godišnje bila ozlijeđena 561 osoba. U drugom su periodu zamijećene oscilacije uz trend smanjenja od –6,20%. Posljednji, treći period, pokazuje prosječnu godišnju stopu smanjenja od –1,93%

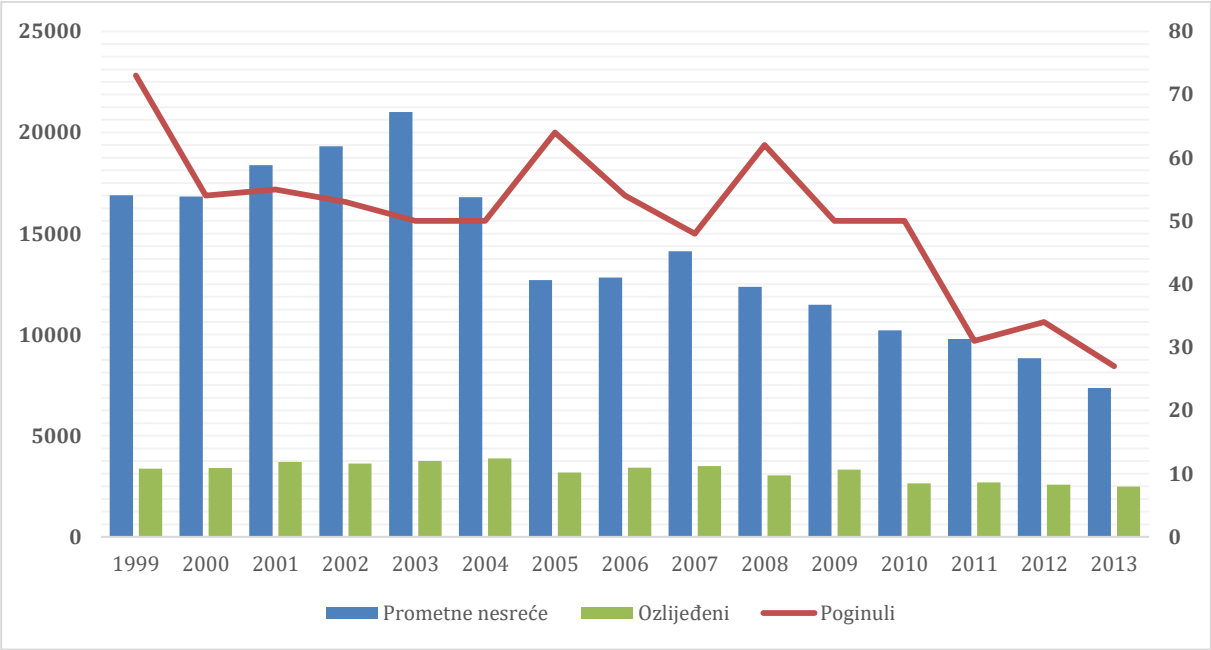

Grafikon 5.4. Kretanje broja CPN-a i stradalih osoba u razdoblju 1999. – 2013. na području Grada Zagreba
Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014. i Statistički ljetopis Grada Zagreba (od 2005. do 2013.), dopuna i obrada autora

Ako analiziramo kretanja stopa CPN-a u odnosu na njihove osnovne kategorije, pri srednjoročno promatranom razdoblju od 10 godina, prikazanom na Grafikonu 5.5., možemo konstatirati njihov spor ali kontinuirano stabilan pad. U prosjeku 78,16% ukupnoga broja CPN-a odnosi se na one u kojima je zabilježena samo materijalna šteta, dok na CPN-e s ozlijeđenim osobama 21,30%. Posljednji, a ujedno i najteži oblik CPN-a odnosi se one u kojima je nastupila smrt sudionika u prometu, a na njih opada svega 0,54% od ukupnoga broja registriranih CPN-a.

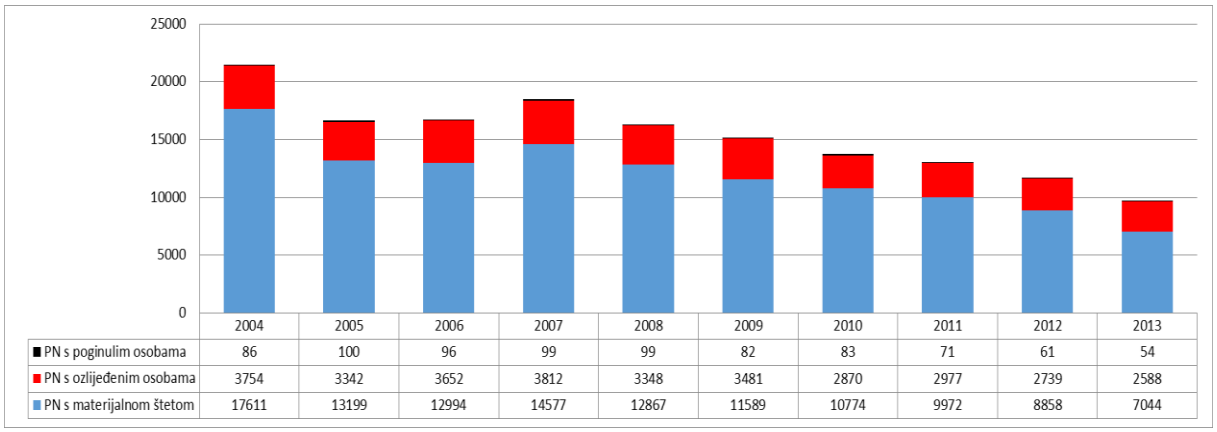

	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013
PN s poginulim osobama	86	100	96	99	99	82	83	71	61	54
PN s ozlijeđenim osobama	3754	3342	3652	3812	3348	3481	2870	2977	2739	2588
PN s materijalnom štetom	17611	13199	12994	14577	12867	11589	10774	9972	8858	7044

Grafikon 5.5. Stope kretanja osnovnih kategorija CPN-a u prometu u razdoblju 2004. – 2013. na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

Prosječna godišnja stopa smanjenja za pojedine navedene kategorije iznosi –9,68% za CPN-e s materijalnom štetom te –4,05% za CPN-e s ozlijeđenim osobama, a najmanje je smanjenje od –5,04% za CPN-e s poginulim osobama.

5.1.1. Svojstva i starosna struktura nastradalih sudionika u cestovnim prometnim nesrećama

Analiza nastradalih sudionika u prometu, prikazana kroz njihovu osnovnu podjelu – poginuli, teško i lako ozlijeđeni (Grafikon 5.6.), pokazala je da na najtežu kategoriju u prosjeku otpada oko 2%., s teškim tjelesnim posljedicama nastrada u prosjeku 14,65%, dok je najveći postotak onih sudionika u CPN-u koji su zadobili laku tjelesnu ozljedu (83,32%). I dok prve dvije kategorije imaju relativno istovjetne stope kretanja, za posljednju možemo konstatirati kako jačina promjene trenda gotovo konstantno oscilira i ne postoji značajna zakonitost promjene trenda.

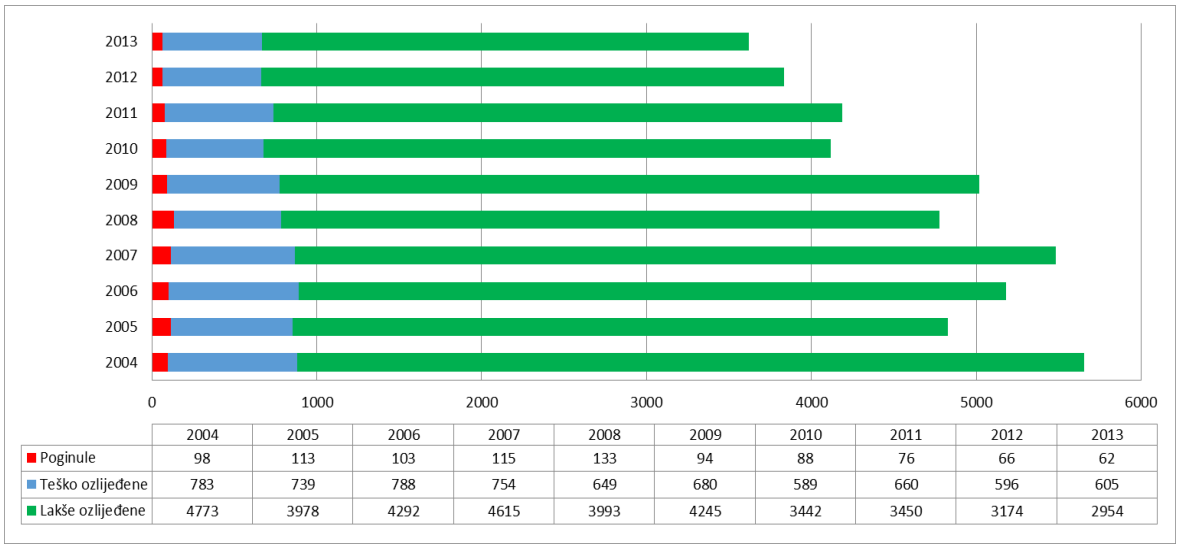

	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013
Poginule	98	113	103	115	133	94	88	76	66	62
Teško ozlijeđene	783	739	788	754	649	680	589	660	596	605
Lakše ozlijeđene	4773	3978	4292	4615	3993	4245	3442	3450	3174	2954

Grafikon 5.6. Stope kretanja osnovnih kategorija nastradalih sudionika u prometu u razdoblju 2004. – 2013. na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

Daljnjom analizom, ako se promatraju nastradali sudionici prema njihovu svojstvu u trenutku nastanka CPN-a, distribuirani prema poginulim i ozlijeđenim osobama (Grafikon 5.7.), može se utvrditi da udio poginulih vozača u odnosu na ostale kategorije iznosi preko 50%, točnije 53,34%. Drugu poziciju zauzima kategorija pješaka s 25,11%, dok su putnici posljednji s udjelom od 21,55%.

Ako se nastradali sudionici promatraju u odnosu na zadobivene ozljede, vozači su opet prvi s udjelom od 55,60%, dok u odnosu na prethodnu analizu drugo mjesto zauzimaju putnici s 31,11%, a treće pješaci sa svega 13,29%.

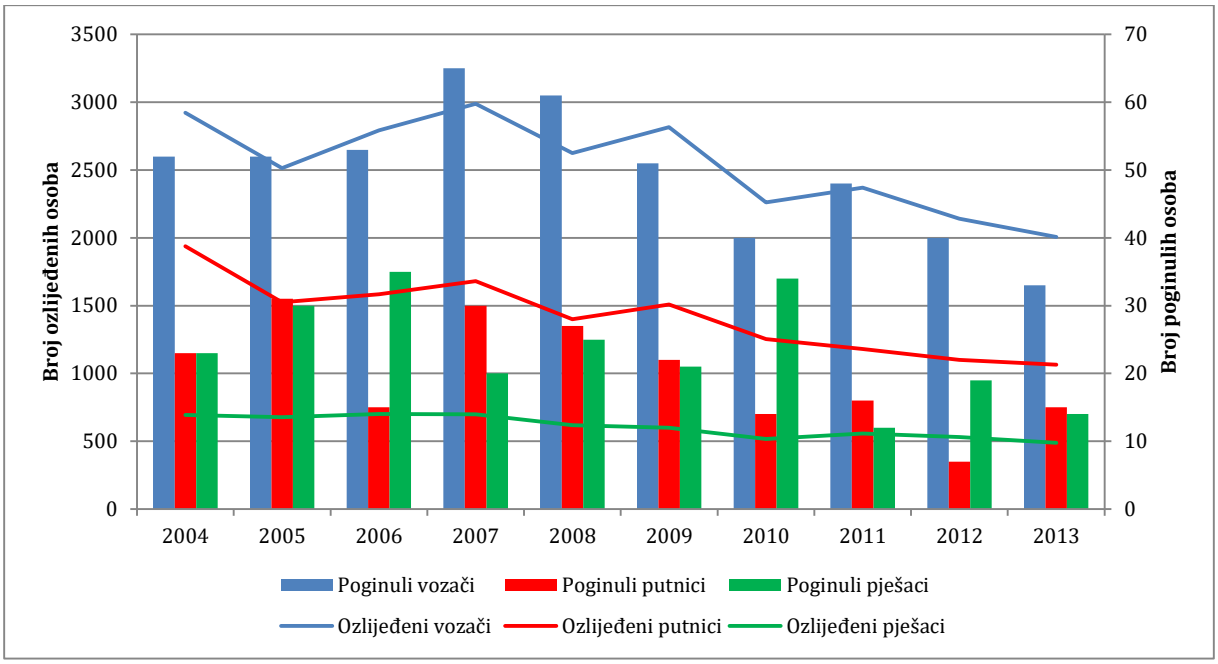

Grafikon 5.7. Stope kretanja nastradalih sudionika u prometu prema njihovu svojstvu u trenutku nastanka CPN-a, u razdoblju 2004. – 2013., na području Ministarstva unutarnjih poslova, Policijske uprave Zagrebačke
Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

Ako se promotre nastradale osobe po njihovoj starosti, što je naznačeno u Grafikonu 5.8., najviše ozlijeđenih sudionika (vozač, putnik i pješak) čine pripadnici srednje životne dobi, starosti od 31 do 50 godina (17,16% ukupnoga broja ozlijeđenih osoba), dok je stopa poginulih najveća kod osoba starije životne dobi od 65 godina na više (19,40% ukupnoga broja poginulih osoba), a koji ujedno i spadaju u jednu od najrizičnijih kategorija sudionika u prometu.

Pozitivan je podatak da učešće djece, starosti 0 – 14 godina, smrtno stradalih u CPN-u iznosi svega 3,34% od ukupnoga broja poginulih sudionika u prometu te 8% od ukupnoga broja ozlijeđenih. Ako se nadovežemo na podatak kako u razvijenim zemljama EU-a, koje već duži niz godina kvalitetno upravljaju sigurnošću cestovnoga prometa, učešće djece poginule u CPN-u iznosi oko 5%, slobodno možemo konstatirati kako je razina sigurnosti djece u prometu na promatranom području zadovoljavajuća.

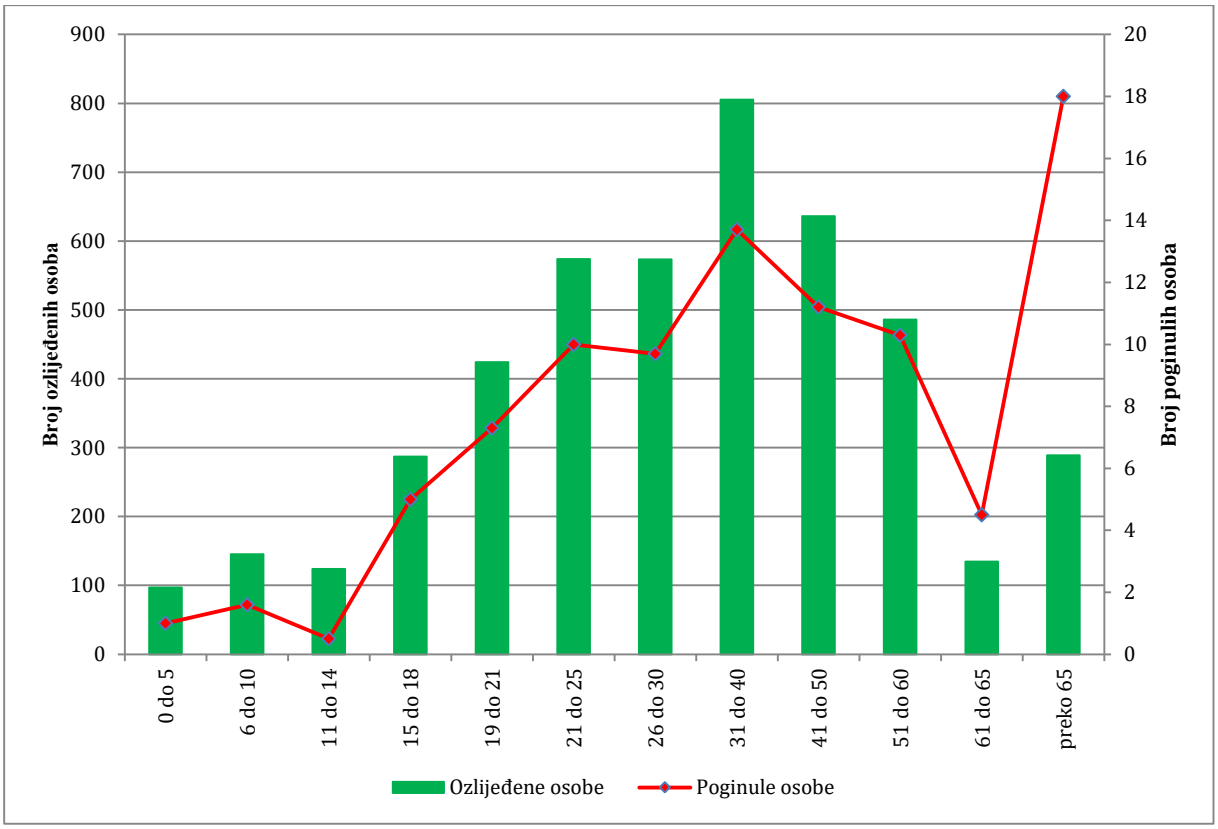

Grafikon 5.8. Prosječne stope nastradalih sudionika u razdoblju 2004. – 2013. po njihovoj starosti, na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

5.1.2. Vremenska distribucija cestovnih prometnih nesreća na području Grada Zagreba

Analizirajući statističke podatke o CPN-u prema vremenskoj distribuciji, na Grafikonu 5.9. prikazan je prosječan dnevni broj registriranih CPN-a te poginulih i ozlijeđenih osoba u periodu 2004. – 2013. Tjedna raspodjela ukazuje na to kako su stope CPN-a najznačajnije u danima početka i kraja radnoga tjedna – ponedjeljkom (2328 ili 15,23%) i petkom (2509 ili 16,41%), dok je broj poginulih (17,1 ili 18,43%) i ozlijeđenih (723,3 ili 15,81%) osoba najviši u periodu vikenda, točnije u subotu. Ujedno, zanimljiv je podatak kako je broj CPN-a najmanji u danima vikenda, a broj ozlijeđenih i poginulih osoba u periodu od utorka do četvrtka.

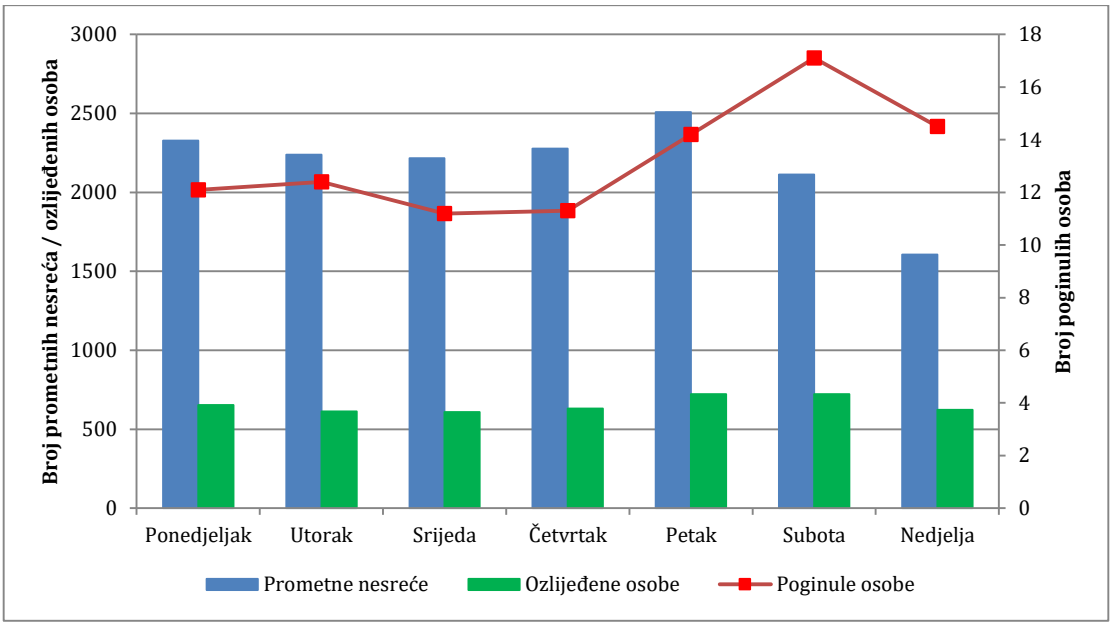

Grafikon 5.9. Prosječna dnevna distribucija broja CPN-a te poginulih i ozlijeđenih osoba u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

Na sljedećem grafikonu (Grafikon 5.10.) prikazana je satna raspodjela prosječnoga broja registriranih CPN-a te poginulih i ozlijeđenih osoba u istovjetnom vremenskom periodu. Iz njega je vidljivo kako je najveći intenzitet CPN-a zabilježen u vremenskom periodu od 14 do 18 sati (25,79% ukupnoga broja CPN-a), u trajanju poslijepodnevnoga vršnog satnoga opterećenja cestovne mreže, i to prvenstveno zbog povećanoga obujma cestovnoga prometa i pješačke aktivnosti zbog migracije radnoga stanovništva svojim domovima. Najveći broj osoba smrtno strada u večernjim satima, od 18 do 22 sata (22,41% ukupnoga broja poginulih osoba), a najviše je ozlijeđenih u poslijepodnevnom intervalu od 16 do 20 sati (25,53% ukupnoga broja ozlijeđenih osoba), za što su najčešći uzročnici pretjerana konzumacija alkohola te smanjena vidljivost.

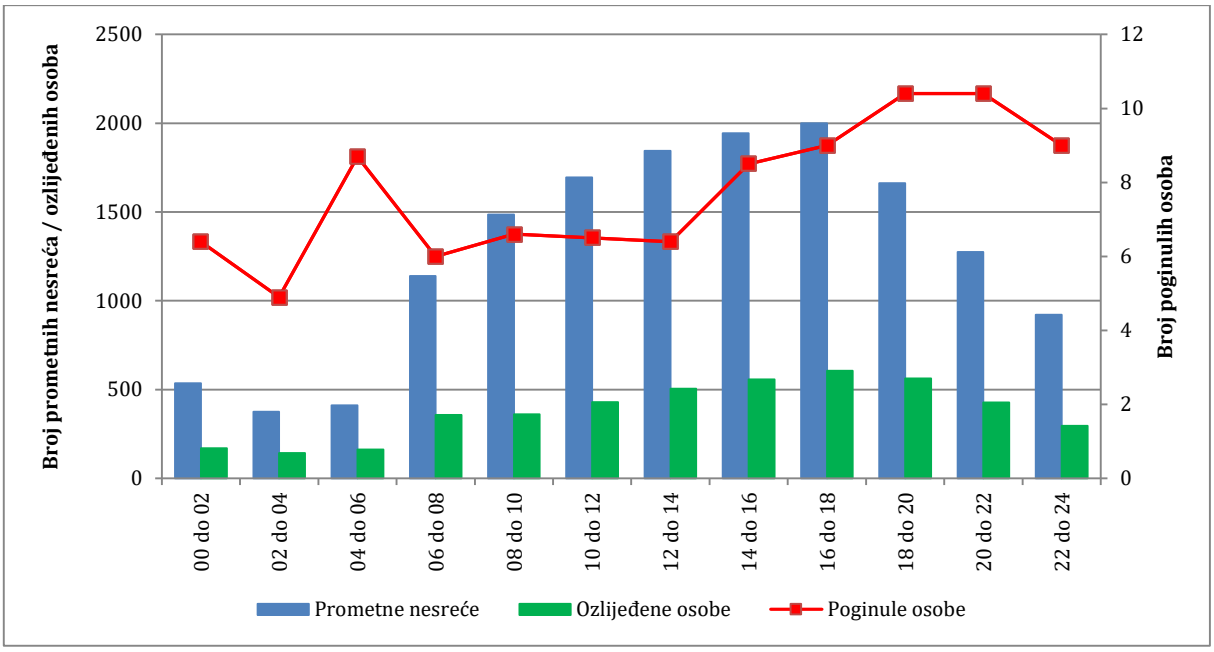

Grafikon 5.10. Prosječna satna distribucija broja CPN-a te poginulih i ozlijeđenih osoba u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

5.1.3. Analiza vrsta cestovnih prometnih nesreća za urbana područja

Prema službenoj strukturi, odnosno podjeli u bazi podataka o CPN-u IS-a MUP-a, trenutno razlikujemo ukupno 15 vrsta prometnih nesreća – sudare vozila (iz suprotnoga smjera, bočnoga smjera, u usporednoj vožnji, u vožnji u slijedu i vožnji unazad), udar vozila u parkirano vozilo, slijetanje vozila s ceste, nalet na bicikl, nalet na motocikl ili moped, sudar s vlakom, udar vozila u objekt (na cesti ili pokraj nje), nalet na životinju i ostalo.

Analizirajući statističke podatke o vodećim vrstama prometnih nesreća, distribuiranim prema prosječnomu broju CPN-a te poginulim i ozlijeđenim osobama u periodu 2004. – 2013. godine (Grafikon 5.11.), dobivamo sljedeće podatke.

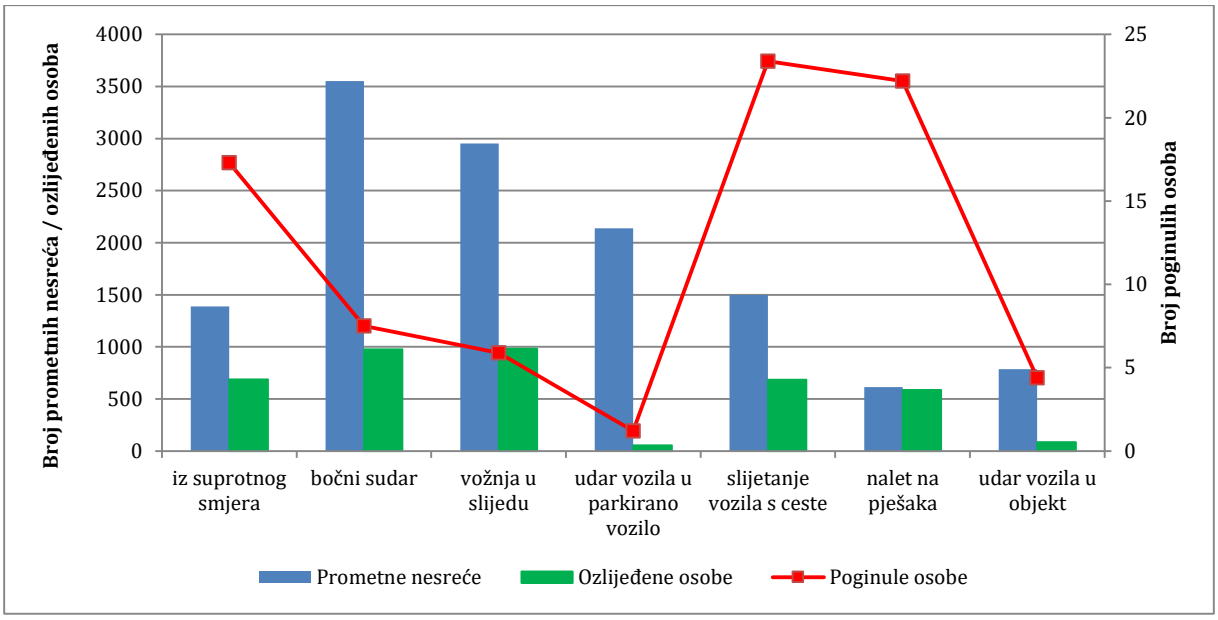

Grafikon 5.11. Prosječna stope CPN-a te poginulih i ozlijeđenih osoba u odnosu na vrste prometnih nesreća u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

Vrste CPN-a kod kojih se najčešće događaju najteži oblici stradavanja sudionika u prometu jesu:

1. slijetanje vozila s ceste (24,87% zastupljenosti)
2. nalet na pješaka (23,59% zastupljenosti)
3. sudari vozila iz suprotnoga smjera (18,38% zastupljenosti)
4. bočni sudar (7,97% zastupljenosti)
5. vožnja u slijedu (6,27% zastupljenosti)

Vrste CPN-a kod kojih se najčešće događa ozljeđivanje (teško ili lako) sudionika u prometu jesu:

1. vožnja u slijedu (21,50% zastupljenosti)
2. bočni sudar (21,31% zastupljenosti)
3. sudari vozila iz suprotnoga smjera(15,04% zastupljenosti)
4. slijetanje vozila s ceste (14,94% zastupljenosti)
5. nalet na pješaka (12,81% zastupljenosti)

U ukupnom broju registriranih CPN-a zastupljene su sljedeće vrste CPN-a:

1. bočni sudar (23,24% zastupljenosti)
2. vožnja u slijedu (19,31% zastupljenosti)

3. udar vozila u parkirano vozilo (14,00% zastupljenosti)
4. slijetanje vozila s ceste (9,81% zastupljenosti)
5. sudari vozila iz suprotnoga smjera (9,08% zastupljenosti)

U navedenoj gradaciji zanimljiv je podatak da se u kategoriji CPN-a i stradalih sudionika u prometu prva dva oblika CPN-a nalaze u zajedničkoj kategoriji, unutar skupine *Sudari vozila u pokretu*.

5.1.4. Analiza uzroka cestovnih prometnih nesreća za urbana područja

Podatci o utjecajnim čimbenicima u procesu nastanka CPN-a prate se i o njima se izvještava kroz kategoriju podataka o pogreškama vozača, pješaka i ostalih uzroka u IS-u MUP-a RH. Na temelju statističke analize onaj utjecajni čimbenik ili zbir čimbenika koji su najviše doprinijeli nastanku CPN-a ujedno se smatra, odnosno tumači kao njezin uzrok.

Prema službenoj statistici, uzroci i pogreške prilikom nastanka CPN-a grupirani su u tri kategorije kako slijedi:

1. pogreške vozača (20 varijabli)
2. pogreške pješaka (4 varijable)
3. ostali uzroci (2 varijable)

Analiza najčešćih okolnosti nastanka CPN-a i najznačajnijih propusta sudionika u prometu, distribuiranih po prethodno naznačenim kategorijama, u periodu 2004. – 2013. godine, prikazana je na Grafikonu 5.12.

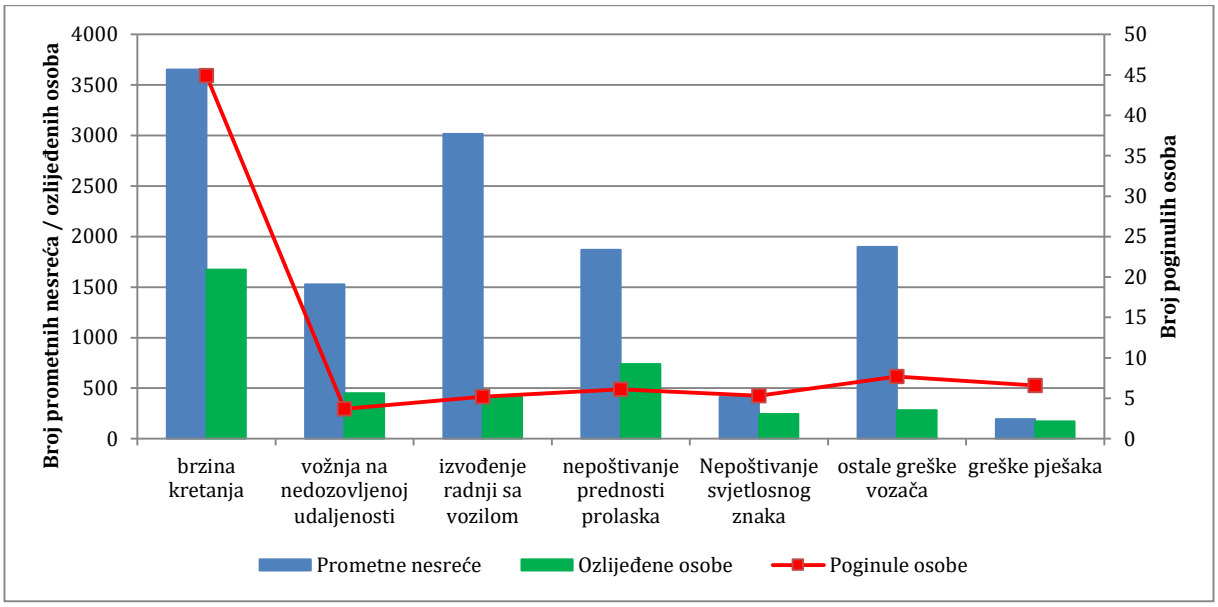

Grafikon 5.12. Prosječne stope najčešćih uzroka prometnih nesreća distribuiranih prema CPN-u te poginulim i ozlijeđenim osobama, u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

Najčešći uzrok svih triju kategorija nalazi se u skupini *Pogreške vozača* i odnosi se na brzinu kretanja motornoga vozila (nepropisna brzina i brzina neprimjerena uvjetima), posebice kod poginulih (55,30% ukupnoga broja poginulih osoba) i ozlijeđenih osoba (41,56% ukupnoga broja ozlijeđenih osoba).

Drugi se po redu uzroci stopa CPN-a za pojedine kategorije međusobno razlikuju to je izvođenje radnji s vozilom (22,94% ukupnoga broja CPN-a), unutar čega se nalaze aktivnosti kao što su nepropisno skretanje, nepropisna vožnja unazad te nepropisno prestrojavanje.

Pri ozljeđivanju sudionika u prometu drugu poziciju zauzima nepoštivanje prednosti prolaska (18,37% ukupnoga broja ozlijeđenih osoba), dok kod smrtnosti sudionika u prometu važnu ulogu igraju skupina ostalih grešaka vozača te greške pješaka (17,61% ukupnoga broja ozlijeđenih osoba).

Važno je napomenuti kako je definiranje uzroka CPN-a i pogrešaka odnosno neprikladnih radnji sudionika isključivo u nadležnosti predstavnika prometne policije, koji nakon očevida i osiguravanja mjesta nesreće unosi prikupljene informacije u bazu podataka o CPN-u. U svrhu otklanjanja određenih nepravilnosti i onemogućavanja subjektivnoga izbora službenika vrlo je važno da službenici budu permanentno kvalitetno educirani i opremljeni odgovarajućim alatima i opremom za obavljanje takvih vrsta poslova.

Osnovu za analizu rizičnoga ponašanja sudionika u prometu moguće je iščitati iz službenih izvještaja MUP-a o evidentiranim prekršajima u prometu, kao i radnjama sudionika u prometu koje su doprinijele pojavi CPN-a.

Tako su pri analizi registriranih prekršaja u prometu (Grafikon 5.13.), koje sačinjava ukupan broj izvješća, naloga te novčanih kazni koje su izdali djelatnici prometne policije, kao najčešći razlozi ispisivanja kazni utvrđeni sankcioniranje vozača zbog nepropisne brzine i parkiranja te ostale vrste prekršaja, a koji zajedno čine više od 39,92% ukupnoga broja prekršaja.

Na temelju takvoga stanja potrebno je izvesti daljnje stručne analize i sigurnosne procjene kojima je konačni cilj implementacija ciljanih mjera i aktivnosti na detektirana problemska rizična ponašanja sudionika u prometu. Njihovim korekcijama znatno se utječe na svijest i stavove rizičnih skupina sudionika u prometu te na njihovu buduću prometnu kulturu.

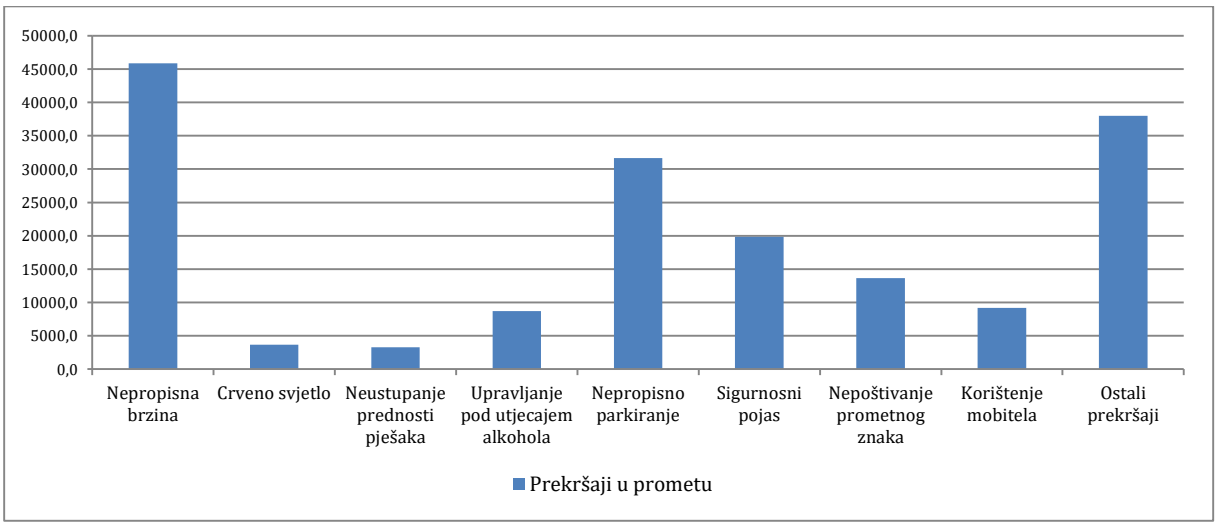

Grafikon 5.13. Prosječan broj evidentiranih prekršaja u prometu u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova

Izvor: Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., obrada autora

5.2. Komparativna analiza i zaključna razmatranja

Komparirajući statističke podatke o ozlijeđenim osobama u CPN-u na razini RH (Prilog 4.) i Grada Zagreba, vidljivo je kako je u razdoblju 1999. – 2013. godine na nacionalnoj razini smrtno stradalo 8.547 osoba, od čega na području Zagreba 584 osobe ili 6,83%, a ozlijeđeno je 317.045 osoba, od čega na području Zagreba 48.619 osobe ili 15,34%, što nedvosmisleno ukazuje na razmjere i društvenu štetu koju trpi lokalna zajednica u gradskom prometnom sustavu.

Usporedimo li podatke iz Grafikona 5.2. i 5.4. za posljednju godinu promatranja (2013.), možemo zaključiti da je udio cestovnih prometnih nesreća na području Grada Zagreba iznosio 21,64% od ukupnoga broja prometnih nesreća na području Republike Hrvatske, uz 7,34% od broja poginulih te 16,33% od broja ozlijeđenih.

Uspoređujući stanje sigurnosti dvaju prometnih sustava, njihova opća ocjena trebala bi se kvalitetno izvesti na temelju relativnih pokazatelja sigurnosti cestovnoga prometa, prikazanih u Tablici 5.1.

Tablica 5.1. Komparativna lista relativnih pokazatelja sigurnosti cestovnoga prometa Republike Hrvatske i Grada Zagreba za 2013. godinu

POKAZATELJI	REPUBLIKA HRVATSKA	GRAD ZAGREB	UČEŠĆE ZG U RH (%)
Broj stanovnika	**4.284.889**	**790.017**	**18,44**
Površina, km^2	**56.542**	**641,32**	**1,13**
Broj CPN-a	**34.021**	**7.362**	**21,64**
Broj CPN-a s poginulim osobama	**328**	**23**	**7,01**
Broj CPN-a s ozlijeđenim osobama	**10.897**	**1.854**	**17,01**
Broj sudionika CPN-a	**71.124**	**14.113**	**19,84**
Broj poginulih	**368**	**27**	**7,34**
Broj teško ozlijeđenih	**2.831**	**420**	**14,84**
Broj lako ozlijeđenih	**12.446**	**2.074**	**16,66**
Broj stradalih	**15.645**	**2.521**	**16,11**
Broj poginulih na 100.000 stanovnika	**7,655**	**3,42**	**44,68**
Broj teško ozlijeđenih na 100.000 stanovnika	**66,069**	**53,16**	**80,46**
Broj lako ozlijeđenih na 100.000 stanovnika	**290,46**	**262,53**	**90,38**
Broj stradalih na 100.000 stanovnika	**365,12**	**319,11**	**87,40**
Broj CPN-a na 100.000 stanovnika	**793,98**	**931,88**	**117,37**
Broj poginulih na 1.000 sudionika	**5,17**	**1,91**	**36,94**
Broj ozlijeđenih na 1.000 sudionika	**214,79**	**176,72**	**82,28**
Broj sudionika CPN-a na 100.000 stanovnika	**1.659,88**	**1.786,42**	**107,62**
Broj CPN-a na 100 km^2	**60,17**	**1.147,94**	**1907,83**
Broj stradalih na 100 km^2	**27,67**	**393,10**	**1420,67**

Izvor: Bilten o sigurnosti cestovnoga prometa (2014.) i Izvješće o stanju i kretanju sigurnosnih pokazatelja u radu Policijske uprave zagrebačke (2013.), Ministarstva unutarnjih poslova, Zagreb i Statistički ljetopis Republike Hrvatske i Grada Zagreba, Zagreb, 2014., obrada autora

Analizirajući podrobnije stanje sigurnosti cestovnoga prometa na lokalnom i nacionalnom nivou naspram relativnoga iznosa (broja cestovnih prometnih nesreća na 100.000 stanovnika), vidljivo je kako su podatci dobiveni za Grad Zagreb (927 CPN/100.000 stanovnika) 16,7% veći od razine RH (794 CPN/100.000 stanovnika).

Razlog je za navedeno znatno izraženiji stupanj motorizacije u Gradu Zagrebu u odnosu na RH, struktura sudionika u prometu (pješaci, biciklisti, teretna i motorna vozila) te kategorizacija prometnica (gradske prometnice – ceste unutar naselja), što značajno doprinosi porastu stope cestovnih prometnih nesreća.

Promatrajući osnovni apsolutni sigurnosni pokazatelj (Grafikon 5.14.), broj poginulih, za potrebe realnijega opisivanja stanja sigurnosti i kvalitetne usporedbe nivoa sigurnosti, kroz standardizirani relativni iznos (pokazatelji rizika) broja poginulih na 100.000 stanovnika, u odnosu na zadane kvantitativne ciljeve iz Nacionalnoga programa sigurnosti cestovnog prometa, vidljivo je kako su rezultati Zagreba znatno niži u odnosu na podatke na razini Republike Hrvatske.

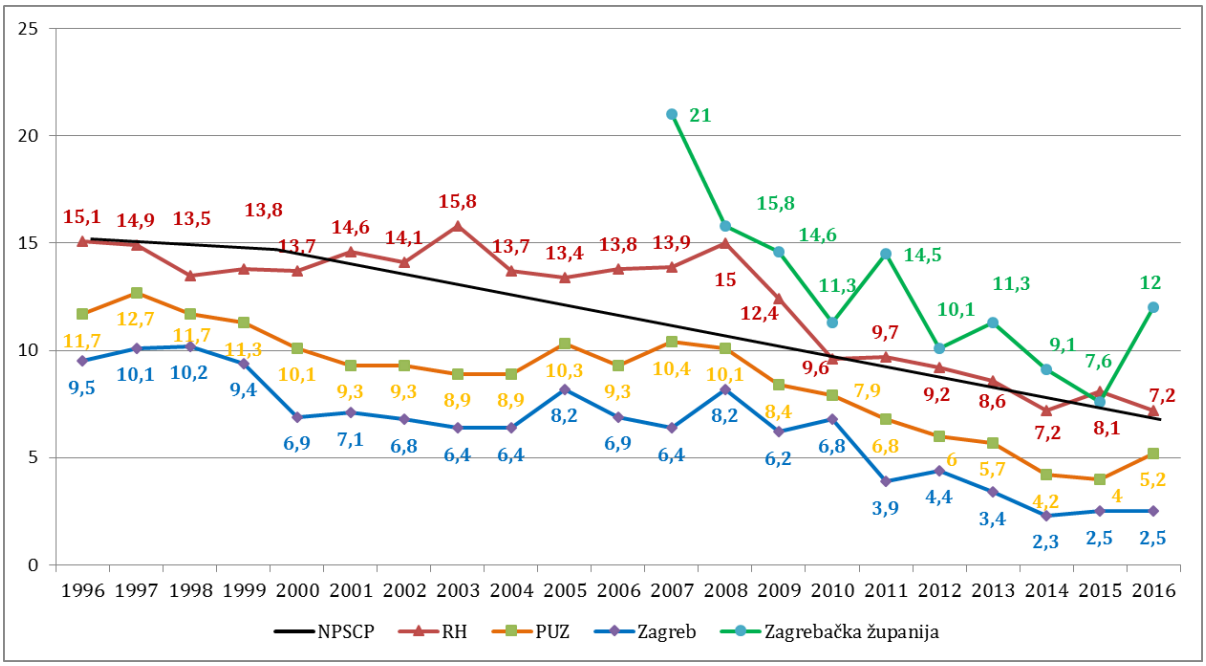

Grafikon 5.14. Komparativni pregled broja poginulih osoba na 100.000 stanovnika u razdoblju 1996. – 2016. za Republiku Hrvatsku, PU zagrebačku, Grad Zagreb i Zagrebačku županiju u odnosu na Nacionalni program sigurnosti cestovnoga prometa Republike Hrvatske

Izvor: *Ministarstvo unutarnjih poslova, Policijska uprava Zagrebačka, Zagreb, 2014., dopuna i obrada autora*

Podatci iz 2013. godine za Grad Zagreb (3,4 poginule osobe na 100.000 stanovnika) znatno su ispod prosjeka na nacionalnom nivou (53% manje), što je vrlo indikativno, pogotovo ako se ima na umu kako administrativne granice Grada Zagreba predstavljaju u potpunosti urbano područje.

Iako Grad Zagreb ima bolje podatke o smrtno stradalima na 100.000 stanovnika u odnosu na nacionalni nivo, važno je naglasiti da europski gradovi imaju još bolje podatke te da pojedini gradovi, poput Berlina i Beča, imaju godišnji prosjek od 1,6 poginulih osoba na 100.000 stanovnika. Stoga Grad Zagreb treba intenzivirati aktivnosti na poboljšanju stanja sigurnosti u cestovnom prometu, iako ima bolje indikatore od nacionalnoga nivoa [131].

U konačnici, komparirajući prethodno analizirane statističke podatke o vrstama i uzorcima CPN-a (greške, propusti i okolnosti) koji dovode ili doprinoste njihovu nastanku, u prethodnim konzultacijama s predstavnicima MUP-a – Služba za sigurnost cestovnog prometa, možemo konstatirati kako nepropisno preticanje (skretanje i prestrojavanje) najčešće dovodi do sudara vozila iz suprotnih smjerova, nepoštivanje prava prednosti (prvenstva) prolaza najčešće dovodi do bočnih sudara, dok nepropisna ili neprilagođena brzina najčešće dovodi do naleta na vozilo koje se kreće u istom smjeru, slijetanje vozila s puta ili rušenje pješaka. Također, pogreške vozača u velikj mjeri definiraju vrstu CPN-e.

Izbor ulaznih nezavisnih varijabli za predloženi prognostički model prvenstveno je usvojen prethodnim pregledom prije spomenutih relevantnih studija i istraživanja te nakon preliminarne analize dostupnih podataka o CPN-u, u skladu s predmetnim policijskim obrascima o broju informacija uključenih u obradu podataka o CPN-u.

Analizom trendova sigurnosnih pokazatelja CPN-a na području Grada Zagreba te službenom strukturom razrade uzroka prometnih nesreća, koju provode predstavnici Ministarstva unutarnjih poslova, možemo utvditi kako je čimbenik „čovjek“ (vozač i pješak) najviše zastupljen uzročnik CPN-a, koji se ujedno prati s najvećim brojem pojedinačnih varijabli. S obzirom na to da su navedeni podatci dostupni i na lokalnoj razini, predstavljali su jedan o ključnih setova podataka koji su primijenjeni kao ulazni parametri za izradu prognostičkoga modela.

Analiza prostorne distribucije broja osoba poginulih u CPN-u, ovisno o mjestu nastanka CPN-a, tj. prema kategorijama i značajkama ceste, također je provedena komparirajući podatke RH s ostalim državama članicama EU-a (vidi Poglavlje 3.), pri čemu je utvrđeno kako su statistički podatci za urbana i ruralna područja između RH i EU-a gotovo dijametralno suprotna. Također je konstatirano kako CPN-i u urbanim područjima imaju značajno drugačije osobine i karakteristike u odnosu na one nastale u ruralnim područjima i na autocestama.

Potrebno je stoga napomenuti kako su svi ulazni parametri koji su se koristili za izradu predloženoga prognostičkog modela CPN-a za urbana područja prethodno selektirani tako da predstavljaju samo kategoriju prometnica (ceste) unutar naselja.

Prometne nesreće prema meteorološkim uvjetima i stanju kolnika, prethodnom analizom apsolutnih podataka nisu predstavljala značajna odstupanja u komparaciji sa statističkim podatcima drugih gradova EU-a te stoga nisu bili uključeni u daljnju razradu modela.

Glavne kategorije CPN-a koje su najčešće strukturirane i analizirane predstavljaju situacije koje su se dogodile između vozila i pješaka, između dvaju vozila te one u kojima je sudjelovalo samo jedno vozilo. Analizirajući dostupne statističke podatke utvrđeno je kako su najčešće vrste CPN-a sudari vozila u pokretu, slijetanje vozila s ceste, nalet na pješaka, udar vozila u parkirano vozilo i dr.

Analizirajući vrste i uzroke CPN-a u urbanim sredinama (ulazni podatci za izradu prognostičkih modela CPN-a za urbana područja), rezultati istraživanja podijeljeni su u tri grupacije – prema broju ukupno registriranih CPN-a, broju ozlijeđenih (teško/lako) te broju poginulih osoba. Glavni uzrok CPN-a, kao što je bilo i očekivano, u svim trima grupacijama predstavlja nepropisna brzina i brzina neprilagođena uvjetima na cesti.

6. PROGNOSTIČKI MODEL CESTOVNIH PROMETNIH NESREĆA ZA URBANA PODRUČJA

6.1. Pregled dosadašnjih istraživanja

U većini europskih metropola poboljšanje sigurnosti u cestovnom prometu urbanih sredina za nadležna gradska tijela i službe predstavlja složen izazov.

Nesreće možemo promatrati kao moguće pojave uzrokovane raznim kauzalnim vezama, koje se sastoje od neovisnih činitelja čiji su doprinosi i međusobna interakcija dijelom determinirani (kauzalni slijed na koji se često može utjecati), a dijelom slučajni [132].

Cestovne prometne nesreće predstavljaju jedan od ključnih problema cestovnoga prometnog sustava. Izradom prognostičkih modela CPN-a uz prethodnu analizu čimbenika relevantnih u nastanku CPN-a, u korelaciji s njihovim posljedicama (vrste i broj prometnih nesreća), u mogućnosti smo kategorizirati te čimbenike po važnosti te utvrditi jačinu (povezanost) njihove međusobne korelacije.

Njihovom se primjenom, uz pretpostavku da se pripadajuće baze podataka o CPN-u kontinuirano unapređuju (ažuriraju), u kombinaciji s dubinskim istraživanjima individualnih CPN-a (prvenstveno onih s težim posljedicama) ostvaruju dodatna saznanja o ključnim čimbenicima koji uzrokuju nastanak CPN-a (vidi Poglavlje 3.). Tim pristupom prometni stručnjaci dobivaju važan analitički alat za sustavnu procjenu stanja sigurnosti svih sudionika u cestovnom prometu.

Nadalje, ostvaruje se kvalitetnija procjena trenutnoga stanja sigurnosti cestovnoga prometa na promatranom području, kao i predviđanje budućega, s obzirom na to da smo primjenom prognostičkih modela CPN-a u mogućnosti simulirati kako bi primjena određenih ciljanih preventivnih mjera mogla imati utjecaj na cjelokupnu razinu sigurnosti [133].

Za potrebe ovoga rada relevantne studije i srodna istraživanja identificirani su pregledom baze podataka u referentnim znanstvenim člancima.

Uočava se kako postoji opsežna literatura o modelima CPN-a, među kojom većina analizira prometne nesreće koristeći konceptualni prikaz ili statistiku. Stoga je posebna pažnja posvećena pregledu onih statističkih metoda koje imaju evidentiranu raširenu aplikativnu uporabu, kao i prednostima i nedostatcima postojećih statističkih metoda i analitičkih tehnika.

Modeli predviđanja CPN-a zasnivaju se na nekoliko setova kritičnih parametara (nezavisnih varijabli) koji se kasnije koriste za analize i zaključke prilikom određivanja prognoza.

Varijable koje se najviše primjenjuju s ciljem opisivanja, objašnjavanja i/ili predviđanja stopa i ishoda CPN-a jesu one iz područja prometnoga sustava te sociodemografski, ekonomski, ekološki i autonomni čimbenici (oni na koje kreatori prometne politike ne mogu utjecati) te vanjski čimbenici (vremenski uvjeti na cestama). Varijable koje možemo izdvojiti jesu sljedeće: broj policijskih kontroli usmjerenih na sprječavanje i sankcioniranje vožnje pod utjecajem alkohola, broj prometnih prekršaja zbog prekoračenja brzine, cijene naftnih energenata, broj vlasnika motornih vozila, tip cestovne mreže, vremenski uvjeti tijekom nastanka CPN-a, broj stanovništva u promatranom području, indikatori stambenoga okruženja, dostupnost zdravstvene usluge, udio nedavnih doseljenika, stopa kriminala te dr. [134]

Osnovu izrade modela za predviđanje težih oblika CPN-a (smrtno ili teže ozlijeđeni sudionici u prometnim nesrećama) predstavlja kvalitetna statistička podloga na kojoj se biraju dostupni i relevantni ulazni parametri. S obzirom na prethodno navedeno, u nastavku je prikazan jedan generalni proces izrade modela, koji su autori [135, 136, 137] više ili manje kronološki implementirali u svojim radovima.

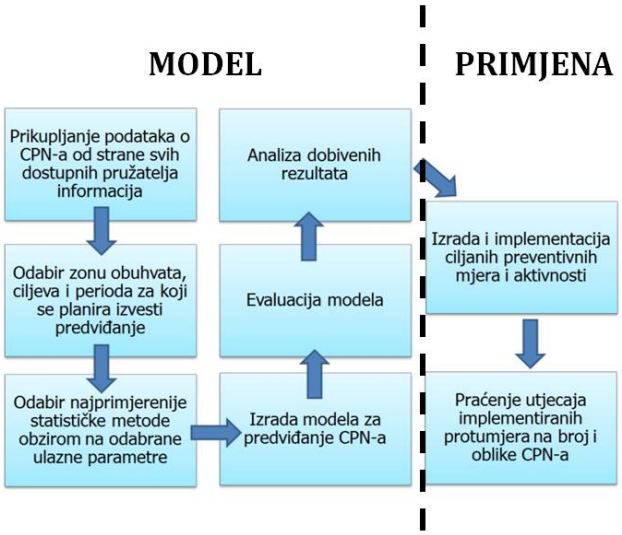

Slika 6.1. Generalni proces izrade modela za predviđanje stopa CPN-a

Prognostički modeli CPN-a najčešće se temelje na službenim bazama podataka o CPN-u. Iz navedenih baza podataka potrebno je definirati činitelje, odnosno ulazne podatke, koji zatim predstavljaju varijable statističkoga modela. Poznati modeli promatraju ulazne podatke kao statistički nezavisne i njihov utjecaj na broj CPN-a. Noviji statistički modeli za prognozu CPN-a koriste složene varijable koje su izvedene iz više njih.

No, također valja napomenuti kako broj CPN-a te njihove posljedice u velikoj mjeri ovise i o količini prometa, odnosno ukupnom broju prometnih entiteta i sudionika u prometu koji su prisutni na cestovnoj prometnoj mreži, kao i o njihovu prevaljenom putu [138, 139, 140]. Nadalje, distribucija putovanja, odnosno izbor rute i moda putovanja na određenom lokalitetu te ekonomske i demografske aktivnosti sudionika u prometu također predstavljaju bitne čimbenike za pojavu i učestalost CPN-a te bi ih se sve više trebalo uključivati prilikom kalibracije i specifikacije modela predviđanja CPN-a.

Problem koji je često prisutan u određivanju ulaznih varijabli i razradi takvih matematičkih modela jest nedostatak podataka u dužem vremenskom periodu, što često iziskuje njihovo izostavljanje iz daljnjih proračuna, pri čemu se smanjuje razina točnosti i pouzdanosti [59].

S obzirom na navedeno, preporuke stručnjaka koji izučavaju CPN jesu da se u svrhu izrade prognoza trendova CPN-a koriste jednostavniji modeli na agregatnoj razini (niz dostupnih podataka koje je moguće pribaviti u duljem vremenskom slijedu). Primjenom navedenih modela kao reprezentativnu bazu možemo koristiti analizu vremenskih sljedova podataka o CPN-u, koje su pribavili subjekti zaduženi za vođenje baze podataka. [141]

Značajno je naglasiti da se tumačenje prethodno spomenutih parametara ne dovodi u uzročnu vezu za objašnjavanje CPN-a, nego predstavlja neizravan utjecaj na razinu sigurnosti cjelokupnoga prometnog sustava. To su posredne ili prividne varijable bez izravnih uzročnih veza, ali koje omogućavaju uspješno predviđanje prometnih nesreća, posebice onih s ozbiljnijim ishodima [142]. Posredne varijable nisu u izravnoj uzročnoj relaciji, pa je na prometnim stručnjacima da adekvatno interpretiraju dobivene rezultate.

Autori iz područja sigurnosti cestovnoga prometa u svojim studijama često primjenjuju matematičke modele CPN-a, a to je motivirano potrebom da se adekvatno opišu promjene u promatranom uzorku prometnih nesreća, kako na nacionalnoj razini (praćenje stopa njihovih kretanja) tako i za potrebe apliciranja ciljanih preventivnih sigurnosnih mjera za njihovo anuliranje. Izradom takvih modela prometnim je stručnjacima omogućeno podrobnije razumijevanje uzroka nastanka CPN-a, što u konačnici dovodi do detekcije kauzaliteta prometnih nesreća te identificiranja kontroliranih nezavisnih varijabli.

S obzirom na složenost trenutno evidentiranih vrsta i broja čimbenika koji potencijalno mogu utjecati na razinu sigurnosti prometnoga sustava, potrebno je odrediti primjerenu metodologiju za provedbu određenih sigurnosnih analiza. Mnogi autori iz područja prometnih, kao i ostalih komplementarnih znanosti tijekom posljednja dva desetljeća sustavno su obrađivali različite metode, tehnike i statističke matematičke modele za potrebe predviđanja CPN-a na mikro- i

makrorazinama, prilikom čega su ulazne podatke i varijable onih prethodnih upotpunjavali različitim brojčanim veličinama uzoraka te vremenskim periodima trajanja samih istraživanja.

Prepoznajući važnost statističkih metoda za povezivanje, klasifikaciju te predviđanje stopa kretanja CPN-a, u nastavku će se prokomentirati prednosti i ograničenja postojećih statističkih metodologija i analitičkih tehnika.

6.1.1. Primijenjena istraživanja

Cestovne prometne nesreće egzistiraju od početaka formiranja cestovnoga prometnog sustava. Tijekom povijesti su se, ovisno o pojedinim državama, koristile različite preventivne mjere i aktivnosti kako bi se umanjili broj i posljedice nesreća.

Jedan od pionira na području istraživanja i analiza cestovnih prometnih nesreća jest britanski statističar i stručnjak za sigurnost prometa, R. J. Smeed, koji je 1949. godine [143] predložio konceptualni okvir za analizu cestovnih prometnih nesreća s ciljem predviđanja broja poginulih osoba u prometnim nesrećama.

Njegov teoretski linearni model čija se prognoza temelji na stupnju motorizacije (broj vozila na 1000 stanovnika ili broj stanovnika na jedno vozilo), koji su kasnije slijedili, ali i osporavali mnogobrojni autori, razmatra odnos između stope smrtnosti u prometnim nesrećama i broja registriranih motornih vozila i stanovnika na uzorku od 20 država različitoga stupnja ekonomske i tehničke razvijenosti, neovisno o njihovoj veličini i standardu prometnoga sustava, tijekom 1938. godine. Predloženi je model svojom jednostavnošću i praktičnošću omogućio detektiranje osnovnih podataka relevantnih za stanje sigurnosti prometa na nacionalnoj razini te ga je vrlo brzo prihvatila većina stručnjaka.

Matematička formula Smeedova modela, poznata i kao Smeedov zakon, izvedena je za stopu smrtnosti u sljedećem obliku:

$$\frac{P}{S} = 0.0003 \cdot \sqrt[3]{\frac{V}{S}} \qquad (6.1.)$$

gdje P, V, S, predstavljaju redom smrtne slučajeve (broj poginulih osoba u zemlji u godini predviđanja), motorna vozila (broj registriranih motornih vozila u godini predviđanja) te populaciju (broj stanovnika u zemlji u godini predviđanja), tako da formula (6.1) mjeri utjecaj nivoa motorizacije na stopu smrtnosti.

U izučavanju modela (6.1.) vrlo je brzo utvrđeno da osnovne predložene modele nije moguće u potpunosti primijeniti i pružiti adekvatnu informaciju o stupnju sigurnosti cestovnoga prometa u zemljama različitoga stupnja razvoja, iako su izvedeni koeficijenti dobiveni na podatcima iz raznih zemalja. Znatne društvene i gospodarske raznolikosti između promatranih zemalja, kao i same metode korištene u prikupljanju podataka o prometnim nesrećama [144] činile su predložene modele pod-parametriranim. Daljnjim studijama i istraživanjima u Europi i SAD-u potvrđeno je kako Smeedova formula nije uspjela precizno predvidjeti stopu smrtnosti u mnogim zemljama, kako onima u razvoju tako i onim razvijenima [145,146]. U skladu s navedenim, nije se ni predlagalo da se Smeedova formula koristi u funkciji predviđanja stope CPN-a.

Primijenjena istraživanja provedena su i publicirana u radu autora Valli [147], koji implementira matematički model za analizu podataka o prometnim nesrećama na razini države te većih gradova u Indiji koristeći koncept Smeedove formule i Andressenove jednadžbe:

$$P = M_0 \cdot (V)^{M_1} \cdot (S)^{M_2} \qquad (6.2.)$$

gdje su M_0, M_1, M_2 parametri koje se razlikuju ovisno o promatranoj zemlji.

Analizirani su podatci o prometnim nesrećama za razdoblje od 25 godina (od 1977. do 2001. godine), dok je sam model korišten za predviđanje broja prometnih nesreća u 7 gradova u razdoblju od 2007. do 2010. godine potkrijepljen statističkim testovima za regresijske jednadžbe. Isti su model implementirali Bener et al. [148] u zemljama u razvoju, a primjerom su bile obuhvaćene pojedine arapske zemlje.

Nadalje, u [149,150,151,152] autori su se u svojim istraživanjima bazirali na proučavanju odgovora na pitanja mogu li primjene različitih modifikacija na cestovnoj prometnoj infrastrukturi (geometrija prometnica) biti u korelaciji s promjenama u stopama smrtnih slučajeva te registriranim prometnim nesrećama. U radovima je, među ostalim, utvrđeno kako povećanjem broja prometnih traka, kao i njihove širine, raste i broj prometnih nesreća te težih oblika stradavanja, dok se proširenjem kolnika u zavoju smanjuje njihov broj.

Fridstrom et al. [106] su izučavali mjesečne podatke o CPN-u na ukupno 18 okruga (regija) u Norveškoj i utvrdili su kako unaprjeđenja i nadogradnje implementirane na državnoj cestovnoj mreži nemaju očekivane efekte u porastu razine sigurnosti cestovnoga prometa, dok Milton i Mannering [153] zaključuju kako povećanje broja prometnih traka na određenom cestovnom segmentu dovodi do veće stope prometnih nesreća. Osim navedenoga, također su ustvrdili da je

na područjima istočnoga Washingtona, gdje su u primjeni uže, „supstandardne“ širine prometnih traka (manje od 3,5 m), primjetan i smanjen broj cestovnih nesreća.

Sljedeće značajno područje istraživanja predmetne problematike utemeljeno je na pretpostavci kako su brojni ekonomski i demografski parametri (nivo zaposlenosti, porast industrijske proizvodnje, osobna primanja, rashodi, potrošnja goriva, proizvodnja vozila, BDP, starost sudionika i dr.) u korelaciji s generalnim stopama CPN-a. Kroz daljnja istraživanja utvrđeno je kako su stope CPN-a usko povezane s ekonomskom ciklusom, tako da stope CPN-a u recesijskom periodu znaju biti ispod prosjeka u odnosu na vremenske periode kada se ekonomski/gospodarski uvjeti u državi poboljšaju. Tim se pristupom ukazuje na postojanost veze između ekonomske aktivnosti pojedine zemlje i broja poginulih osoba u nesrećama, koja se posredno ostvaruje kroz mehanizme samoga putovanja.

Upravo stoga Scuffham i Langley [21], Joksch [154] i Thoresen et al. [155] svoja istraživanja usmjeravaju na izučavanje toga kako određene ekonomske i demografske aktivnosti zemlje utječu na stopu CPN-a, s posebnim osvrtom na trendovske i sezonske varijacije. Kao ulazne varijable radova na tome se području često koriste stopa nezaposlenosti, BDP, konzumacija alkohola, populacijski čimbenici i sl. Iako se prilikom izrade statističkih modela koristilo samo nekoliko socioekonomskih nezavisnih varijabli, nužno je objasniti razloge za takav proces modeliranja. Razlog za njega jest to što se pokazalo kako jednostavni ekonomski modeli zasnovani na najmanjem mogućem broju ekonomskih čimbenika (npr. stopa zaposlenosti, potrošnja kućanstva, BDP) pružaju mnogo kvalitetnije rezultate od onih u koje je uključen veći broj prethodno navedenih relevantnih čimbenika. Isto se u istraživanjima primjenjivalo i zbog pojednostavnjenja izrade samih modela, smanjenja vremena i troškova prikupljanja i obrade te izbjegavanja mogućnosti pogrešaka u obradi velikoga broja podataka, a što bi u konačnici moglo rezultirati smanjenom razinom preciznosti samih statističkih modela predviđanja CPN-a.

Istraživanja koja su proveli Li et al. [156] te Downing et al. [157] dokazuju da je u analizi CPN-a nužno razlikovati one koji su se dogodili u urbanim i one u ruralnim područjima, s obzirom na to da su varijacije u smrtnostima između događanja bile povezane s različitostima u karakteristikama nesreća. U skladu s navedenim, razlike u odnosima CPN-a nisu vidljive samo u uzrocima i posljedicama, već i u sredstvima prevencije koje bi bilo potrebno primijeniti.

S obzirom na to da je većina gore opisanih istraživanja i pripadajućih prognostičkih modela provedena na nacionalnoj razini, razvidno je kako istraživanja u svrhu razvoja prognostičkih modela CPN-a za urbana gradska područja nisu značajno zastupljena, odnosno ne postoji znatan broj znanstvenih radova. Kao referentne autore, koji su djelomično u svojim radovima obuhvatili predmetnu prometnu problematiku, možemo izdvojiti Guevara et al. [158], Lord i Persaud [159], Sayed i Lovegrove [160], Washington et al. [161] i dr.

Zajednička je osobina većine predloženih modela što su namijenjeni za rad na mikrorazini, pri čemu se uglavnom temelje na podatcima prikupljanima unutar pojedinih referentnih prometnih zona, tj. cjelina. Za navedenu skupinu prognostičkih modela predviđena je detaljna razina ulaznih parametara u zoni obuhvata, i to prvenstveno u području:

- geometrijskih i funkcionalnih karakteristika cestovne infrastrukture (dizajna i opremljenosti),
- demografije,
- postojećih urbanističkih uvjeta i namjene zemljišta,
- cestovnoga prometnog opterećenja i strukture ostvarenih putovanja (modalna raspodjela).

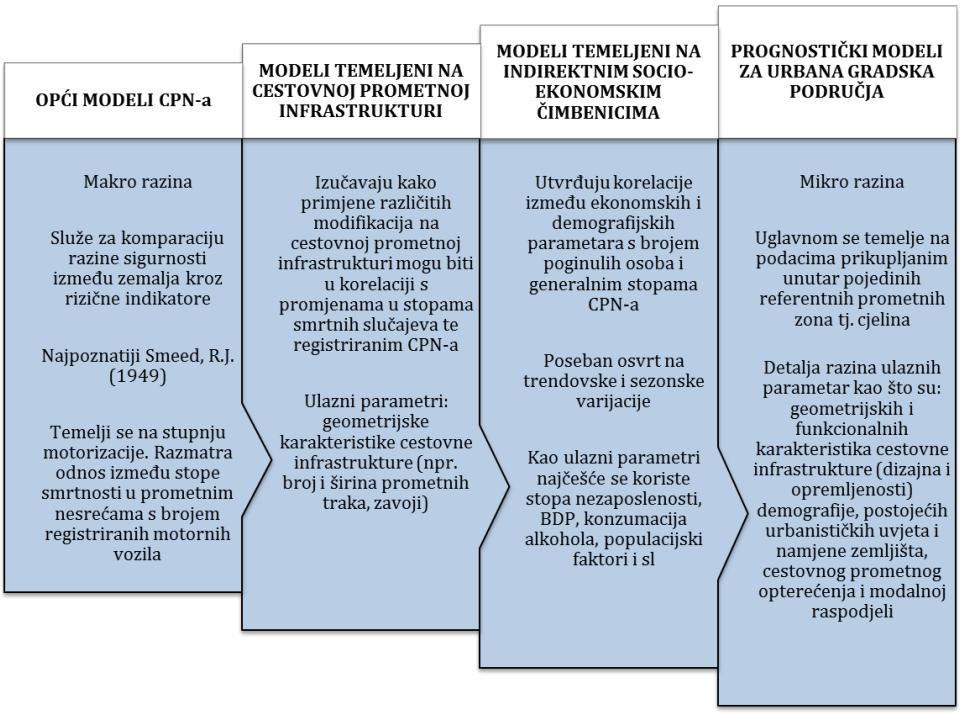

Slika 6.2. Pregled analize prognostičkih modela CPN-a, obrada autora

Osim navedenih područja istraživanja i varijabli koje su se koristile u spomenutim studijama i istraživanjima, kod prognostičkih je modela utvrđena i primjena različitih matematičkih tehnika i metoda koje su se koristile u modeliranju stopa i prognoza CPN-a.

U skladu s time, tijekom posljednjih godina brojna su istraživanja provedena kako bi se istražila učestalost i ozbiljnost CPN-a, koristeći različite statističke metode prognoziranja prometnih nesreća, kao što su Poissonova razdioba, negativna binomna razdioba, model linearne višestruke regresije, logaritamska višestruka regresija, model maksimalne vjerojatnosti, Bayesova metoda,

fuzzy logika, umjetne neuronske mreže i dr. [162,163,164,165]. Predložene su statističke razdiobe i modeli zatim korišteni u različite svrhe izučavanja CPN-a, od kojih su najznačajnije identifikacija opasnih mjesta („crnih točaka“), predviđanja stopa CPN-a te implementacija modificiranih mjera za anuliranje prethodno definiranih rizičnih čimbenika [166].

6.2. Statističke metode predviđanja cestovnih prometnih nesreća

6.2.1. Statističke razdiobe cestovnih prometnih nesreća

Broj prometnih nesreća na promatranoj dionici puta ili cestovnom raskrižju u određenom zadanom vremenskom razdoblju možemo promatrati kao slučajnu varijablu X na skupu elementarnih događaja Ω . Skup vrijednosti slučajne varijable je $X(\Omega)=\{0,1,2,...\}$.

Ako je svakoj vrijednosti slučajne varijable moguće pridružiti vjerojatnost $f(0)=P(X=0)$, $f(1)=P(X=1)$, $f(2)=P(X=2)$, ..., tada je definirana funkcija vjerojatnosti ili diskretna razdioba vjerojatnosti slučajne varijable *X*.

Za funkciju vjerojatnosti nužno vrijedi $\sum_{x\in X(\Omega)} f(x)=1$. Numeričke su karakteristike razdiobe očekivanje razdiobe ili srednja vrijednost $E(X)=\sum_{x\in X(\Omega)} x\cdot f(x)$ i varijanca ili srednje kvadratno odstupanje $V(X)=\sum_{x\in X(\Omega)}(x-E(X))^2\cdot f(x)$ [167].

Poissonova razdioba

Prva statistička razdioba za izučavanje i predviđanje CPN-a korištena pri izradi generalnih modela linearne regresije jest binomna razdioba (engl. *Binomial distribution*) [168]. U području prometa na cestama binomnoj se razdiobi podvrgava protok vozila na presjeku ceste ili raskrižju.

Problem s korištenjem binomne statističke razdiobe uočen je u slučajevima kada u promatranu cestovnu dionicu ili u raskrižje dolazi veliki broj automobila $N\to\infty$, a vjerojatnost je prometne nesreće mala: $p\to 0$. Binomna razdioba se tada aproksimira Poissonovom razdiobom.

Poissonova razdioba (engl. *Poisson distribution*) [167,169] odgovara pojavi rijetkih događaja (u ovom slučaju CPN-a), a dobiva se iz binomne razdiobe. Granični slučajevi pojavljivanja nekoga

određenog događaja u nizu ispitivanja opisivi su Poissonovom razdiobom. Ona ima značajnu prisutnost u području istraživanja cestovnoga prometa te se mnogi autori iz područja sigurnosti cestovnoga prometa u izradi statističkih modela za predviđanje stopa CPN-a opredjeljuju upravo za nju.

Pretpostavke su za tu razdiobu sljedeće: velik broj automobila koji prolazi promatranom cestovnom dionicom ili raskrižjem, a mala vjerojatnost prometne nesreće. Funkcija vjerojatnosti Poissonove razdiobe za λ>0:

$$f(x) = \frac{e^{-\lambda}\lambda^{x}}{x!} \qquad (6.3.)$$

x = *0,1,2,3,...* broj prometnih nesreća

λ – parametar Poissonove razdiobe

e – baza prirodnoga logaritma

Matematičko očekivanje jest $E(X) = \lambda$, a varijanca je $V(X) = \lambda$.

Budući da Poissonova distribucija ima istu sredinu i varijancu, često ne odražava tipične karakteristike razdiobe prometnih nesreća. U brojanju relevantnih podataka za CPN-e često je uočena razlika između varijance i sredine, odnosno vrijednost je varijance veća od sredine (engl. *overdispersion*), što je ujedno i razlog prelaska na prirodnije i fleksibilnije razdiobe od Poissonove.

Negativna binomna razdioba

Negativna se binomna razdioba (engl. *Negative binomial distribution*) [166,168] za razliku od prethodne razdiobe pokazala korisnijim alatom detektiranja međuodnosa između srodnih prijevoznih elemenata (varijabli) i stopa (frekvencija) CPN-a s obzirom na to da uvažava prethodno spomenutu disperziju.

Pretpostavka je negativne binomne razdiobe sljedeća: u nizovima automobila na promatranoj dionici ili raskrižju promatramo broj prometnih nesreća $x = 0,1,2,3,\ldots$, a $r > 0$ je parametar razdiobe. Ako je vjerojatnost prometne nesreće p, tada vjerojatnost $f(x) = P(X = x)$ ima negativnu binomu razdiobu gdje su pripadne vrijednosti određene formulom:

$$NB(r, p): f(x; r, p) = \binom{x + r - 1}{x} p^{x}(1 - p)^{r} \text{ za } x = 0,1,2,\ldots. \qquad (6.4)$$

Ako uvedemo Gamma funkciju $\Gamma(z)=\int_0^\infty t^{z-1}e^{-t}dt$, koja je za prirodne vrijednosti varijable faktorijel, $\Gamma(n)=(n-1)!$, dobivamo negativnu binomnu razdiobu:

$$f(x;r,p)=\frac{\Gamma(x+r)}{x!\Gamma(r)}p^x(1-p)^r \qquad (6.5)$$

Matematičko je očekivanje negativne binomne razdiobe $E(X)=\frac{rp}{1-p}$, a varijanca je

$V(X)=\frac{rp}{(1-p)^2}$.

Ako promatramo očekivanje $\lambda=\frac{rp}{1-p}$, onda je $p=\frac{\lambda}{r+\lambda}$ i vjerojatnost negativne binomne razdiobe jest:

$$f(x;r,p)=\frac{\Gamma(x+r)}{x!\Gamma(r)}\left(\frac{\lambda}{r+\lambda}\right)^x\left(1-\frac{\lambda}{r+\lambda}\right)^r=\frac{\lambda^x}{x!}\cdot\frac{\Gamma(x+r)}{\Gamma(r)}\cdot\frac{(r+\lambda)^{-x}}{\left(1+\frac{\lambda}{r}\right)^r} \qquad (6.6)$$

Za veliki r ili $r\to\infty$ negativna binomna razdioba prelazi u Poissonovu razdiobu $P(\lambda)$.

Problem je toga tipa statističke razdiobe u tome što prilikom brojanja podataka relevantnih za CPN postoji tendencija velikoga broja nula prilikom opažanja, tj. uočen je veliki broj vrijednosti slučajne varijable $x=0$ kod Poissonove razdiobe.

Dvije Poissonove razdiobe

Konveksna kombinacija dviju Poissonovih razdioba (engl. *Zero-inflated Poisson*, *ZIP*) [170,169] primjenjuje se ako je vjerojatnost za vrijednost slučajne varijable X = 0 veća od vrijednosti dobivene standardnom Poissonovom ili negativnom binomom razdiobom.

Kod analize prometnih nesreća na nekoj dionici ili raskrižju u definiranom je vremenskom periodu uočen velik broj vremenskih perioda u kojima nema prometnih nesreća. Na nekim segmentima cestovne prometnice ima CPN-a, ali odgovarajuće su vjerojatnosti preniske da bi se mogle mjeriti tijekom određenoga promatranog vremenskog razdoblja. To stručnjake dovodi u

zabludu, pa se ti segmenti smatraju sigurnim lokalitetima s nultom stopom CPN-a, što ne mora biti slučaj.

To možemo riješiti primjenom konveksne kombinacije dviju Poissonovih razdioba $P(\lambda_1)$ i $P(\lambda_1)$ s funkcijom razdiobe:

$$f(x) = \alpha \frac{e^{-\lambda_1}\lambda_1^x}{x!} + (1-\alpha)\frac{e^{-\lambda_2}\lambda_2^x}{x!}, \qquad \alpha \in [0,1] \tag{6.7}$$

Posebno za $\lambda_1 = 0$ i $\lambda_2 = \lambda$ dobivamo razdiobu koja uvažava velik broj slučajeva bez prometnih nesreća, konveksnu kombinaciju Poissonove razdiobe $P(\lambda)$ zajedno s nul-Poissonovom razdiobom $P(0)$:

$$f_1(x;\lambda) = \begin{cases} \alpha + (1-\alpha)e^{-\lambda} \text{ za } x = 0 \\ (1-\alpha)\dfrac{e^{-\lambda}\lambda^x}{x!} \text{ za } x > 0 \end{cases} \tag{6.8}$$

gdje je α novi parametar razdiobe. Problem je kod toga tipa razdiobe uočen mjerenjem ne samo varijanci većih od očekivanja nego i varijanci manjih od očekivanja.

Zbog prethodno navedene problematike u posljednje se vrijeme prilikom analiza i izrada modela CPN-a koristi se Conway – Maxwell – Poissonova razdioba (engl. *Conway–Maxwell–Poisson*, *CMP* ili *COM– Poisson*) [171], koja uvažava i veću i manju varijancu od očekivanja.

6.2.2. Statistički modeli predviđanja cestovnih prometnih nesreća

Potrebno je procijeniti parametre razdioba koje smo prethodno analizirali. Parametar Poissonove razdiobe jest $\lambda = E(X)$, dok su parametri negativne binomne razdiobe r i p. Parametri se procjenjuju na temelju uzoraka.

Nepristrana je procjena sredine $\bar{x} = \frac{1}{m}\sum_{i=1}^{m} x_i$, a varijance $s^2 = \frac{m}{m-1}\left(\frac{\sum_{i=1}^{m} x^2}{m} - \bar{x}^2\right)$.

U formulama je m veličina uzorka, a vrijednosti izmjerene u uzorku jesu $x_1, x_2, \ldots, x_m$. Problem je u ovom dijelu što u ocjeni parametara nisu uzeti u obzir vanjski čimbenici uvjeta na cesti koji utječu na CPN-e (vozač, cesta i vrijeme).

Model linearne višestruke regresije

Postoje razne tehnike za izradu modela predviđanja CPN-a, pri čemu je jedna od najznačajnijih linearna višestruka regresija [167,172,173]. Dobivena jednadžba omogućava vrlo preciznu stopu predviđanja CPN-a koristeći optimalnu linearnu kombinaciju pojedinih nezavisnih varijabli: spol, dob, prijeđeni kilometri i tomu slično.

Korelacija mjeri stupanj povezanosti statističkoga modela i stvarnih podataka. Jedan je od statističkih modela linearna regresija:

$$y = c_0 + c_1 x_1 + c_2 x_2 + \ldots + c_n x_n \qquad (6.9)$$

$x_1, x_2, \ldots, x_n$ – čimbenici koji utječu na CPN-e,

y – broj CPN-a,

$c_0, c_1, c_2, \ldots, c_n$ – koeficijenti koje treba ocijeniti.

Povezanost se mjeri koeficijentom korelacije R. Ako je koeficijent determinacije $R^2 \approx 1$, govorimo o čvrstoj statističkoj povezanosti, a ako je $R^2 \approx 0$, tada je povezanost slaba.

Najčešći matematički modeli koji su se koristili za statističko analiziranje agregatnih vremenskih nizova podataka, odnosno odabranih varijabli o CPN-u bili su generalizirani modeli linearne regresije. Oni pretpostavljaju normalnu distribuciju pogrešaka zbog čega su često imali pogrešno koncipiranu strukturu.

Kod navedenih modela bitno je sljedeće: ako je R^2 vrijednost određene ulazne varijable znatno visoka (0,9 ili više), varijabla može dovesti do potpuno nekorisnih rezultata [174]. Iz prethodnih iskustava vidljivo je da se linearni modeli ne bi smjeli koristiti u analizi složenijih i agregiranih podataka o CPN-u s obzirom na to da na temelju nekoliko definiranih ulaznih varijabli u modelu nismo u mogućnosti adekvatno ekstrapolirati sve potencijalno relevantne informacije iz tih zapisa. Tako opisana linearna višestruka regresija nije povezana s Poissonovim razdiobama.

Logaritamska višestruka regresija

Logaritamska višestruka regresija izražena je matematičkom formulom:

$$\ln y = c_0 + c_1 x_1 + c_2 x_2 + \ldots + c_n x_n \qquad (6.10)$$

Ako uvedemo početnu varijablu $x_0 = 1$, možemo napisati opći linearni model

$$\ln y = c_0 x_0 + c_1 x_1 + c_2 x_2 + \ldots + c_n x_n = c' x \qquad (6.11)$$

gdje je c' jednoretčana matrica, x matrica reda (n,m), malo n je broj varijabli i malo m broj mjerenja.

Logaritamsku višestruku regresiju za predviđanje CPN-a koristilo je više autora uz različite varijable mjerenja [166,175].

U daljnjim istraživanjima predmetnoga područja uočeno je kako mnoge ulazne varijable uvelike podliježu svojim postojećim temeljnim trendovima kroz određeno promatrano razdoblje, te je zbog toga potrebno prilikom kreiranja takvih modela (mjerenja stupnja korelacije između ulaznih i izlaznih varijabli) posebnu pažnju posvetiti vremenskomu trenutku kada su ti ulazni podatci prikupljani. Primjer su takvoga utjecaja nagle oscilacije u broju CPN-a te promjene broja poginulih osoba u mnogobrojnim zemljama u toku naftne krize 1973. – 1974. godine, pri čemu je u SAD-u tih godina, kada je i brzina kretanja vozila bila ograničena, evidentirano znatno smanjenje broja poginulih osoba u CPN-u, i do 16% u godini.

Elvik [176] napominje da je u izradi određenih matematičko-statističkih modela prilikom analiza prometnih nesreća važno u njih ukomponirati tzv. lažne (engl. *dummy*) varijable s vrijednostima 0 ili 1 s obzirom na to da njihovo zanemarivanje može dovesti do nerealnih izlaznih podataka.

U svojim modelima autori testiraju jesu li uključene varijable koje bi trebale korigirati promjene zbog vremenskoga trenda imale rezultata. To se radi ubacivanjem fiksnoga efekta vremenske (godišnje) lažne (*dummy*) varijable. Ako je koeficijent navedene varijable statistički značajan i negativan, tada neki neimenovani čimbenici reduciraju ukupan broj prometnih nesreća.

Model maksimalne vjerojatnosti

Za određivanje parametara razdiobe na temelju uzorka koristi se model maksimalne vjerojatnosti ili ML (engl. *Maximum likelihood*) [167, 177]. Neka je slučajni uzorak niz mjerenja x_i za $i = 1, \ldots m$

varijable X, s razdiobom vjerojatnosti $f(x) = f(x;\lambda)$ i parametrom λ. Razdioba uzorka zadana je formulom:

$$L(x_1, x_2, ..., x_m; \lambda) = \prod_{i=1}^{m} f(x_i; \lambda) \qquad (6.12)$$

ili

$$\ln L(x_1, x_2, ..., x_m; \lambda) = \sum_{i=1}^{m} \ln f(x_i; \lambda) \qquad (6.13)$$

Parametar λ se određuje traženjem $\max_{\lambda} L(x_1, x_2, ..., x_m; \lambda)$ ili $\max_{\lambda} \ln L(x_1, x_2, ..., x_m; \lambda)$.

Ako je zadana višestruka regresija $y = c'x$, tada se rješava problem $\max_{c'} \ln L(y_1, ... y_m, x_1, ..., x_m; c')$, što ćemo opisati u idućem poglavlju, vidi (6.15).

Poissonov regresijski model

U skladu s prethodno navedenim, javila se potreba da se uz primjenu primjerenijih regresijskih modela u daljnjim istraživanjima [178,179,180] koriste sofisticiranije statističke tehnike poput Poissonove regresije.

Poissonova razdioba $f(y;\lambda) = \frac{e^{-\lambda}\lambda^y}{y!}$ zadana je očekivanjem $E(Y) = \lambda$. Očekivanje se procjenjuje logaritamskom regresijom $\ln E(Y) = c'x$ ili $\lambda = \mathrm{e}^{c'x}$. Uvrštavanje u Poissonovu razdiobu daje

$$f(y; c'x) = \frac{e^{-e^{c'x}} e^{yc'x}}{y!} \qquad (6.14)$$

Na temelju uzorka $y_1, ..., y_m, x_1, ..., x_m$ u koju ulaze m mjerenja zavisne i svih nezavisnih varijabli, a u cilju otkrivanja formule koja bi davala y kao vrijednost funkcije od x_i-ova, dobivamo razdiobu uzorka:

$$L(y_1, ..., y_m, x_1, ..., x_m; c') = \prod_{i=1}^{m} \frac{e^{-e^{c'x_i}} e^{y_i c'x_i}}{y_i!} \qquad (6.15)$$

ili u logaritamskom obliku:

$$\ln L(y_1,\ldots,y_m,x_1,\ldots,x_m;c') = \sum_{i=1}^{m}\left(-e^{c'x_i} + y_i c' x_i - \ln(y_i!)\right) \qquad (6.16)$$

Parametri u c' se određuju rješavanjem

$$\max_{c'} \ln L(y_1,\ldots,y_m,x_1,\ldots,x_m;c') = \max_{c'} \sum_{i=1}^{m}\left(-e^{c'x_i} + y_i c' x_i\right) \qquad (6.17)$$

Poznat je velik broj matematičkih metoda rješavanja navedenoga problema optimizacije, od gradijentne metode do rješavanja sustava jednadžbi nužnog uvjeta ekstrema $\frac{\partial \ln L(y_1,\ldots, y_m, x_1,\ldots, x_m; c')}{\partial c'} = 0$. Budući je $\ln L(y_1,\ldots, y_m, x_1,\ldots, x_m; c')$ konkavna funkcija, postoji maksimum koji određuje c', a time je određena logaritamska višestruka regresija. Uvrštavanjem logaritamske višestruke regresije u Poissonovu razdiobu određena je Poissonova razdioba cestovnih prometnih nesreća. U regresijskom modelu pretpostavljamo da čimbenici koji djeluju na cestovne prometne nesreće nisu kauzalno povezani.

Pristupi modeliranja modela predviđanja stopa CPN-a tijekom godina također su uznapredovali s primjenom sofisticiranih prostorno-vremenskih serijskih modela. U posljednje se vrijeme *fuzzy* logika i umjetne neuronske mreže primjenjuju u modeliranju predviđanja CPN-a. Nedostatci i limitiranosti navedenih metoda jesu u složenosti koja od autora zahtijeva znatan utrošak vremena. Budući da nemaju široku primjenu, dalje se neće podrobnije obrađivati.

6.3. Kauzalno-prognostički model prometnih nesreća za urbana područja

U svrhu planiranja i testiranja adekvatnih protumjera za smanjenje stopa CPN-a važno je u potpunosti razumjeti složeni kauzalni proces uzroka i posljedica CPN-a, s obzirom na to da je riječ o jednom od najkvalitetnijih pristupa za dobivanje vitalnih informacija u svrhu preventivnoga djelovanja.

U skladu s time, izradu prognostičkoga modela CPN-a za urbana područja RH karakterizira složeni postupak koji se, načelno, može podijeliti u pet osnovnih skupina aktivnosti:

- određivanje ciljeva i ograničenja,
- analiza postojećega stanja,
- predviđanje budućega obujma i stopa CPN-a ovisno o njihovoj podjeli,
- vrednovanje modelskih opcija kauzalnoga modela i izbor najboljega varijantnog rješenja u svrhu njegove provedbe.

Nezavisnost i parcijalna korelacija

Skup uzroka CPN-a jest skup varijabli mjerenja $X = (1,2,\ldots,n)$. Uvjetna nezavisnost ili nepovezanost varijabli mjerenja mjeri se koeficijentom parcijalne korelacije [181]. Ako je koeficijent parcijalne korelacije $\rho_{ij|X\setminus\{i,j\}} \approx 0$, [39] varijable mjerenja i i j nezavisne su uz poznavanje ostalih varijabli mjerenja iz skupa $X \setminus \{i, j\}$, a ako $\rho_{ij|X\setminus\{i,j\}} \not\approx 0$, varijable mjerenja i i j su zavisne ili povezane uz poznavanje povezanosti tih varijabli s ostalim varijablama mjerenja.

Prethodno navedena tvrdnja grafički se može prikazati neusmjerenim grafom [182] u kojem su vrhovi varijable mjerenja $1,2,\ldots,n$. Bridovima grafa povezani su zavisni vrhovi. Na Slici 6.3. varijable {1,4}, {1,5}, {2,5} i {3,4} jesu međusobno nepovezane, odnosno nezavisne.

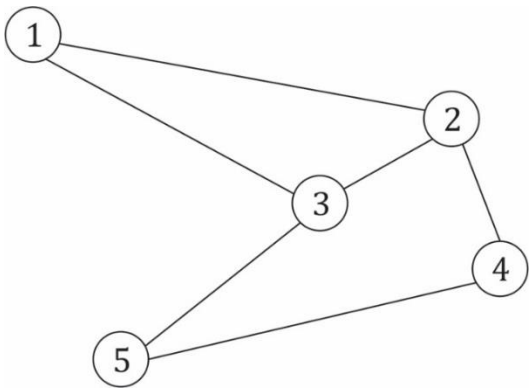

Slika 6.3. Graf zavisnosti varijabli mjerenja

Kauzalnost

Kauzalnost ili povezanost uzroka i posljedice između varijabli X i Y označavamo lukom od uzroka do posljedice $X \rightarrow Y$. U nizu od tri povezane varijable mjerenja X, Y, Z, u oznaci $X - Z - Y$ trebamo odrediti kauzalnu povezanost.

[39] Koeficijent je parcijalne korelacije između varijabli *i* i *j* uz poznavanje ostalih varijabli $\rho_{ij|X\setminus\{i,j\}}$. Taj koeficijent određuje korelaciju između tih varijabli uz pretpostavku poznavanja regresije tih varijabli prema ostalim varijablama ili određuje povezanost tih dviju varijabli uz poznavanje ostalih varijabli.

Ako je $\rho_{XY|Z} > \varepsilon$, gdje je $\varepsilon > 0$, [40] onda varijable X i Y nisu nezavisne uz poznavanje povezanosti s varijablom Z. Kako promatramo povezanost varijabli X i Y, a varijablu Z između njih kao kontrolnu varijablu, ta varijabla ne blokira tok informacija između varijabli X i Y. Tada vrijedi $X \rightarrow Z \leftarrow Y$ i to nazivamo V-strukturom [183].

Ako je $\rho_{XY|Z} \leq \varepsilon$, onda vrijedi $X \rightarrow Z \rightarrow Y$ ili $X \leftarrow Z \leftarrow Y$ ili $X \leftarrow Z \rightarrow Y$ i varijabla Z blokira tok informacija između varijabli X, Y.

Kod kauzalnosti nema zatvorenih putova ili ciklusa između varijabli mjerenja ili, u našem slučaju, nema $X \rightarrow Z \rightarrow Y \rightarrow X$ ili $X \leftarrow Z \leftarrow Y \leftarrow X$. Kauzalna povezanost varijabli mjerenja prikazuje se kauzalnom strukturom.

Kauzalna struktura

Kauzalna je struktura orijentirani graf ili graf povezanosti u kojem su bridovi orijentirani. Brid između varijabli mjerenja $X - Y$ orijentiran kao $X \rightarrow Y$ predstavlja kauzalnu povezanost uzroka X i posljedice Y.

Kod traženja kauzalne strukture pretpostavljamo V-strukturu i acikličnost grafa. Aciklični graf nema zatvorenih puteva ili ciklusa oblika $X \rightarrow Y \rightarrow \ldots \rightarrow X$.

Kod konstrukcije kauzalne strukture nastaju i sve trokutaste strukture $X - Y - Z - X$ uz uvažavanje V-strukture i acikličnosti.

Kauzalni model

Kauzalni je model mreža koja je kauzalni graf s vjerojatnostima prijelaza iz jedne varijable mjerenja u drugu u smjeru kauzalnosti. U kauzalnom modelu svakoj kauzalnosti $X \rightarrow Y$ pridružujemo vjerojatnost prijelaza $p_{XY} = P(Y \mid X)$ ili uvjetnu vjerojatnost. [41]

Vjerojatnost neke varijable ovisi o vjerojatnostima varijabli koje su uzrok i vjerojatnostima prijelaza [183]. Tako je vjerojatnost $P(Z)$ u kauzalnom modelu $X \rightarrow Z \leftarrow Y$ jednaka

---

[40] ε je parametar na temelju kojega modeliramo kauzalni model i određujemo stupanj kauzalne povezanosti.

[41] $P(Y \mid X) = \dfrac{P(Y \cap X)}{P(X)}$

$P(Z) = P(X) \cdot P(Z \mid X) + P(Y) \cdot P(Z \mid Y)$, a u strukturi $X \rightarrow Y \rightarrow Z$ vjerojatnost je $P(Z) = P(Y) \cdot P(Z \mid \mathrm{Y}) = P(X) \cdot P(Y \mid \mathrm{X}) \cdot P(Z \mid \mathrm{Y})$.

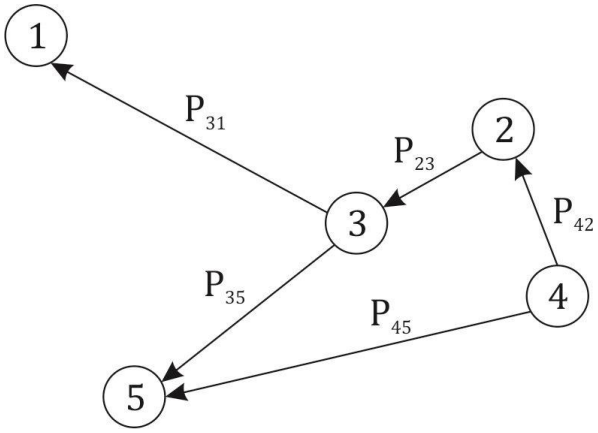

Slika 6.4. Kauzalni model

Vrednovanje kauzalnoga modela

Kauzalni model vrednujemo Kullback–Lieblerovom razlikom između empirijske razdiobe i razdiobe dobivene kauzalnim modelom. Empirijska razdioba $f(x) = f(x_1, x_2, ..., x_n)$, jest razdioba varijabli mjerenja $x_1, x_2, ..., x_n$ cestovnih prometnih nesreća. Kauzalni model cestovnih prometnih nesreća određuje razdiobu $m(x) = m(x_1, x_2, ..., x_n)$, koja je rezultat dobiven modelom.

Razlika tih dviju razdioba mjeri se Kullback–Lieblerovom razlikom $I(f, m)$, koja je razlika ukrštene entropije $H(f, m) = -\sum_x f(x) \cdot \log_2(m(x))$ i entropije

$H(f) = -\sum_x f(x) \cdot \log_2(f(x))$. Ukrštena entropija $H(f, m)$ jest entropija koja sadrži razdiobu $f(x)$ varijabli mjerenja cestovnih prometnih nesreća i razdiobu $m(x)$ dobivenu iz kauzalnoga modela. Entropija $H(f)$ sadrži samo razdiobu $f(x)$ varijabli mjerenja cestovnih prometnih nesreća.

Kullback–Lieblerova razlika jest: [184]

$$I(f, m) = H(f, m) - H(f) = \sum_x f(x) \cdot \log_2\left(\frac{f(x)}{m(x)}\right) \qquad (6.18.)$$

Ta se razlika mjeri u bitima kao jedinicama informacija jer mjeri informaciju koju smo dobili kauzalnim modelom o razdiobi cestovnih prometnih nesreća.

6.4. Linearni kauzalni model

Temelje kauzalnih modela dao je Judea Pearl u svojoj knjizi *Causality: Models, Reasoning, and Inference* (2000) [185]. Prije te knjige Kenneth A. Bollen u svojoj je knjizi *Structural Equations with Latent Variables* (1989) [186] opisao osnovne ideje kauzalnosti i modele strukturnih modela (*Structural Equations Models – SEM*). Na temeljima tih dviju knjiga opisat ćemo linearne metode za ocjenu kauzalnih modela. Na temeljima tih istraživanja i istraživanja autora Richarda Scheinesa, Peter Spirtes, Clark Glymour, Christopher Meek and Thomas Richardson s Department of Philosophy, Carnegie Mellon Universityja pokrenuli su *The TETRAD Project: Constraint Based Aids to Causal Model Specification*. Rezultat je tog projekta besplatan računalni program TETRAD (v.5.2.1-3). Naš je cilj opisati neke teorijske temelje metoda koje se koriste u tom računalnom programu.

Protučinjenični model kauzalnosti

Pretpostavimo da je osoba s imenom *Josip* vozeći osobni automobil velikom brzinom doživjela prometnu nesreću. Josip je imao dvije mogućnosti: voziti dozvoljenom brzinom (x = 0) ili voziti velikom brzinom (x = 1). Označimo posljedicu (y = 1), ako je vožnja završila sa prometnom nesrećom. Ako je vožnja bez prometne nesreće, posljedicu označimo (y = 0). Postavlja se pitanje izračunavanja Josipove vožnje dopuštenom brzinom bez prometne nesreće (x = 0 i y = 0). U Josipovom slučaju imamo samo činjenicu njegove velike brzine (x =1) i njegove prometne nesreće (y = 1). Međutim, posljedica vožnje bez prometne nesreće (y = 0) uz vožnju s dozvoljenom brzinom (x = 0) ne može se ispitati jer to nije činjenica ili je to protučinjenica. U slučaju Josipa to se ne može istraživati. Umjesto jedne osobe možemo promatrati više osoba od kojih neke voze dopuštenom brzinom (x = 0) a druge velikom brzinom (x = 1) s mogućim posljedicama njihove vožnje bez prometne nesreće (y = 0) ili prometnih nesreća sa smrtnim posljedicama (y = 1). U tom slučaju možemo istraživati i protučinjenicu ili ustanoviti vjerojatnost bez prometne nesreće (y = 0) ako je osoba vozila dopuštenom brzinom (x = 0). Rješenje protučinjenice predložio je Judea Pearl kroz kauzalni model. Svaki kauzalni model može se prikazati jednim grafom u kojem su vrhovi grafa varijable koje formiraju model. Naš primjer možemo prikazati grafom na Slici 6.5.

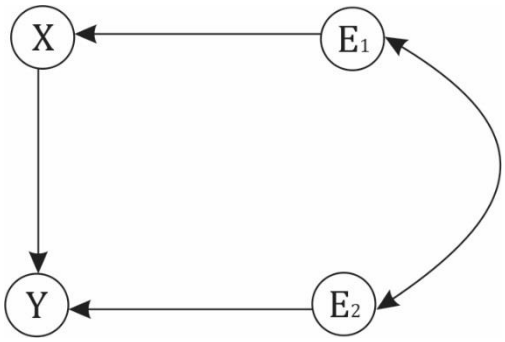

Slika 6.5. Prikaz linearnoga kauzalnog modela

Na grafu su još dvije egzogene varijable E_1 i E_2 . Prva je egzogena varijabla E_1 koja odlučuje o brzini vožnje, druga egzogena varijabla E_2 opisuje uvjete na cesti vidljivost, točnije vidljivost. Tako e_2 = 0 opisuje dobru vidljivost na cesti, a e_2 = 1 opisuje slabu vidljivost na cesti. Linija s dvjema strelicama opisuje međusobnu povezanost egzogenih varijabli ili postojanje latentne varijable L, koja djeluje na obje egzogene varijable i nije opisana u modelu. Graf sa Slike 6.5. možemo opisati strukturnim jednadžbama modela (SEM):

$$\begin{aligned} x &= e_1 \\ y &= e_2(1-x)+(1-e_2)x \end{aligned} \qquad (6.19)$$

Uz jednostavnu pretpostavku vjerojatnosti vožnje dopuštenom i velikom brzinom $P(e_1=0)=0{,}8; P(e_1=1)=0{,}2$ te uvjeta na cesti vidljivosti i slabe vidljivosti uz vjerojatnosti $P(e_2=0)=0{,}6; P(e_2=1)=0{,}4$ i uz uvjet nezavisnosti egzogenih varijabli E_1 i E_1, dolazimo do sljedeće tablice (Tablica 6.1.) vjerojatnosti modela:

Tablica 6.1. Vjerojatnost modela P(x, y, e2)

	x = 0 e2 = 0	x = 1 e2 = 0	x = 0 e2 = 1	x = 1 e2 = 1
y = 0	0,48	0	0	0,08
y = 1	0	0,12	0,32	0

U slučaju prometne nesreće (y = 1) kao posljedica velike brzine (x = 1) vrijednost je egzogenih varijabli (e1 = x = 1) i (e2 = 0). Model nam također daje odgovor na protučinjenicu P(y = 0, x = 0, e2 = 0) / P(y = 0, x = 0) = 0,48 / (0,48 + 0) = 1 ili sigurni smo da onaj koji je nastradao u prometnoj nesreći zbog velike brzine ne bi doživio prometnu nesreću u slučaju vožnje dopuštenom brzinom. Treba naglasiti da je to analiza protučinjenice kauzalnim modelom.

Intervencija i izračunavanje kauzalnoga učinka

Temelj je kauzalnosti intervencija na varijablu uzroka i izračunavanje kauzalnoga učinka na varijablu posljedice. Intervencija na kauzalnom modelu znači promjenu modela brisanjem lukova u grafu koji ulaze u varijablu uzroka i stavljanjem vrijednosti varijabli uzroka. Primjenom intervencije na našem modelu sa Slike 6.5. dolazimo do dvaju modela prikazanih na Slici 6.6.

$$\begin{aligned} x &= e_1 \\ y &= e_2(1-x)+(1-e_2)x \end{aligned} \qquad (6.20)$$

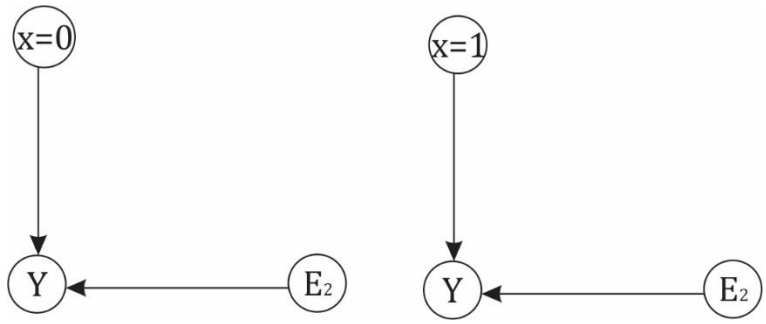

Slika 6.6. Dva kauzalna modela poslije intervencije

Strukturne jednadžbe pridružene intervencijama možemo zapisati jednadžbama:

$$\begin{aligned} x &= 0 \qquad & x &= 1 \\ y &= e_2 \qquad & y &= (1-e_2) \end{aligned} \qquad (6.21)$$

Poslije intervencija na varijablu uzroka *X* promijenile su se razdiobe posljedica *Y*. U našem su to slučaju razdiobe e_2 i $(1-e_2)$. Srednji kauzalni učinak jest razlika očekivanja tih dviju varijabli:

$$E(Y \mid x=0)-E(Y \mid x=1)=(0\cdot 0{,}48+1\cdot 0{,}32)-(0\cdot 0{,}08+1\cdot 0{,}12)=0{,}2$$

To znači da povećanjem brzine kao uzrokom pozitivno djelujemo na prometne nesreće ili vožnjom s nedopuštenom brzinom uzrokujemo prometne nesreće.

Linearni strukturni model kauzalnosti

Linearni strukturni kauzalni model (SEM) nema latentnih varijabli i prikazan je na Slici 6.7.

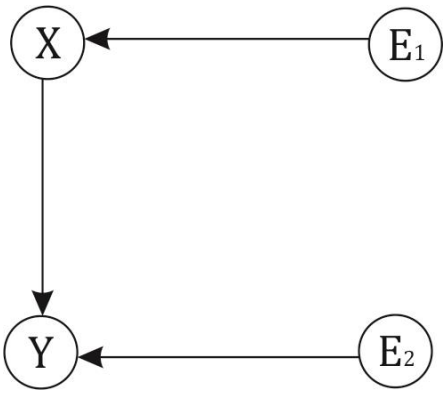

Slika 6.7. Linearni strukturni kauzalni model

Linearnost je u tom modelu prikazana linearnim oblikom strukturnih jednadžbi:

$$\begin{aligned} x &= e_1 \\ y &= a \cdot x + e_2 \end{aligned} \qquad (6.22)$$

Linearni kauzalni modeli koriste kontinuirane varijable. Koeficijent a u modelu jest koeficijent korelacije u regresijskim jednadžbama koje povezuju statističke varijable X i Y. Ako u našem slučaju uzmemo stvarne podatke o ostalim okolnostima i nesrećama zbog brzine neprilagođene uvjetima, dolazimo u slučaju grada Zagreba do koeficijenta $a = 0{,}22$. Strukturne jednadžbe glase:

$$\begin{aligned} x &= e_1 \\ y &= 0{,}22 \cdot x + e_2 \end{aligned} \qquad (6.23)$$

Broj prometnih nesreća zbog brzine neprilagođene uvjetima na cesti u gradu Zagrebu kreće se od 2.000 do 6.000. Ako broj nesreća smanjimo s 6.000 na 2.000, srednji je kauzalni učinak toga linearnoga modela:

$$E(Y \mid x = 6000) - E(Y \mid x = 2000) = E(0{,}22 \cdot 6000 + e_2) - E(0{,}22 \cdot 2000 + e_2) = 0{,}22 \cdot 4000 = 880$$

Smanjenjem broja nesreća zbog brzine neprilagođene uvjetima smanjit će se broj nesreća za 880 zbog ostalih uvjeta, među kojima je i vidljivost na cesti. Ako standardiziramo varijablu X i Y na interval [0, 1], vidimo da je srednji kauzalni učinak jednak 0,22, što pokazuje sličnost kauzalnoga modela opisanoga jednadžbama 6.21 s linearnim kauzalnim modelom opisanim jednadžbama 6.23.

Prikrivene varijable

U modelu su dvije temeljne skupine varijabli. To su endogene ili unutarnje varijable modela i egzogene ili vanjske varijable modela. Svaka od tih varijabli može se mjeriti i zato se zovu varijable mjerenja. Uz varijable mjerenja postoje i varijable u modelu koje su latentne ili prikrivene varijable. Latentne varijable jesu varijable koje ne možemo mjeriti jer nemamo instrumente mjerenja iz realnoga svijeta koji modeliramo. To su ustvari varijable koje su kombinacija nekih varijabli mjerenja i pomažu nam razumjeti kauzalnosti u modelu. U prethodnom primjeru odluka o vožnji velikom brzinom ili dopuštenom brzinom opisana je egzogenom varijablom E_1, a uvjeti vožnje vidljivost ili slaba vidljivost opisani su egzogenom varijablom E_2. U prvom modelu s vrijednostima varijabli 0 i 1 te dvije varijable nisu nezavisne ili postoji latentna varijabla koja se može prikazati kao dodatna latentna egzogena varijabla L. To možemo prikazati novim grafom na Slici 6.8.

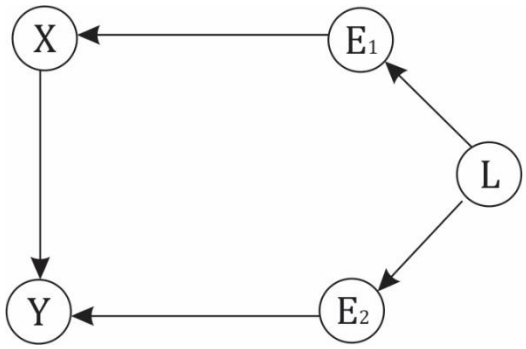

Slika 6.8. Linearni kauzalni model s prikrivenom (latentnom) varijablom

Smisao te latentne varijable izražen je kombinacijom vrijednosti e_1, e_2 i $e_1 \cdot e_2$.

U slučaju drugoga modela s kontinuiranim varijablama egzogena latentna varijabla ne postoji. Najčešće je riječ upravo o takvim linearnim modelima koji nemaju latentne varijable na razini egzogenih varijabli. Latentne su varijable na razini endogenih varijabli i zajedno s linearnim strukturnim jednadžbama objašnjavaju kauzalnu strukturu modela. Najnoviji modeli imaju latentne varijable koje su međusobno nezavisne jer se svaka zavisnost latentnih varijabli može eliminirati kombinacijom nezavisnih egzogenih varijabli.

Budući smjer razvoja kauzalnih modela jest uvođenje nelinearnosti, koju imamo i u prvom modelu.

Novina je u kauzalnim modelima rad s razdiobama koje nisu Gaussove jer u većini praktičnih primjera postoje upravo takve razdiobe.

Nezavisnost varijabli

Pojam nezavisnosti jedan je od najstarijih pojmova u matematici i vezan je za pojam funkcije, gdje je funkcija kao varijabla rezultat djelovanja nezavisnih varijabli. Ovdje nezavisne varijable naglašavaju potpuno nezavisan izbor vrijednosti jedne nezavisne varijable ili nezavisno određivanje vrijednosti nezavisnih varijabli koje određuju vrijednost druge varijable. Koje su varijable nezavisne, a koje zavisne odluka je pojedinca koji određuje na temelju svojega predznanja ili iskustva.

U slučaju statistike dvije su slučajne varijable X i Y s razdiobama $f(x)$ i $f(y)$ nezavisne ako vrijedi $f(x, y) = f(x) \cdot f(y)$. U slučaju nezavisnih slučajnih varijabli X i Y s normalnim razdiobama $f(x)$ i $f(y)$ i razdioba $f(x, y)$ također je normalna. U slučaju normalne razdiobe $f(x, y)$ koeficijent korelacije $r_{xy} = 0$ i obratno, ako je $r_{xy} = 0$, varijable X i Y su nezavisne. Ta je ideja prenesena na podatke mjerenja ili izmjerene vrijednosti varijabli mjerenja. Naprimjer, ako je niz od n izmjerenih vrijednosti $x_1', x_2', \ldots, x_n'$, tada je standardiziran niz vrijednosti tih izmjerenih vrijednosti $x_1 = x_1'/s'$, $x_2 = x_2'/s'$, … , $x_n = x_n'/s'$, gdje je s standardna devijacija uzorka sa srednjom vrijednosti uzorka $\bar{x}'$:

$$s' = \frac{1}{n-1} \sum_{i=1}^{n} \left(x_i' - \bar{x}' \right)^2$$

$$\bar{x}' = \frac{1}{n} \sum_{i=1}^{n} x_i' \qquad (6.24)$$

Izračunate vrijednosti $x_1, x_2, \ldots, x_n$ zovu se standardizirane vrijednosti i njihova je standardna devijacija $s = 1$, srednja je vrijednost $\bar{x} = 0$. Istim postupkom mjerenja za uzorak iz slučajne varijable Y dolazimo do standardiziranih vrijednosti $y_1, y_2, \ldots, y_n$. Tada je određen koeficijent korelacije $r_{xy} = \sum_{i=1}^{n} x_i \cdot y_i$. Ako je koeficijent korelacije jednak 0, tada govorimo o nezavisnosti slučajnih varijabli X i Y na temelju uzorka, iako naše razdiobe u prirodi najčešće nisu Gaussove ili govorimo o ne-Gaussovim razdiobama.

Analiza nezavisnim komponentama

Iz faktorske analize poznata je metoda glavnih komponenti. Glavne su komponente prikrivene varijable koje su međusobno nezavisne i linearne su kombinacije varijabli mjerenja. Ako varijable mjerenja opišemo vrijednostima $X_1, X_2, \ldots, X_n$, a glavne komponente varijablama $Y_1, Y_2, \ldots, Y_n$. Prikaz glavnih komponenti preko varijabli mjerenja je prikazan linearnim kombinacijama (6.25):

$$\begin{aligned} Y_1 &= a_{11}X_1 + a_{12}X_2 + \ldots + a_{1n}X_n \\ Y_2 &= a_{21}X_1 + a_{22}X_2 + \ldots + a_{2n}X_n \\ &\ldots \\ Y_n &= a_{n1}X_1 + a_{n2}X_2 + \ldots + a_{nn}X_n \end{aligned} \qquad (6.25)$$

Koeficijenti u linearnim kombinacijama jesu svojstveni vektori matrice korelacije $R = \lfloor r_{ij} \rfloor$. Varijance faktora svojstvene su vrijednosti iste matrice $\lambda_1 > \lambda_2 > \ldots > \lambda_n$ uz uvjet $\lambda_1 + \lambda_2 + \ldots + \lambda_n = n$. Svojstvene vrijednosti λ_i i svojstveni vektori Y_i jesu rješenja jednadžbi $RY_i = \lambda_i Y_i$.

U linearnim kauzalnim modelima koriste se nezavisne komponente koje se na temelju glavnih komponenti izračunavaju i predstavljaju nezavisne komponente kojima objašnjavamo rezultate mjerenja varijabli mjerenja. Kod traženja nezavisnih komponenti koristi se ne-Gaussova razdioba varijabli mjerenja i drugačiji opis nezavisnosti. Nezavisne komponente ustvari su prikrivene varijable. Varijable mjerenja $X_1, X_2, \ldots, X_n$ se opisuju nezavisnim varijablama $S_1, S_2, \ldots, S_n$:

$$\begin{aligned} X_1 &= c_{11}S_1 + c_{12}S_2 + \ldots + c_{1n}S_n \\ X_2 &= c_{21}S_1 + c_{22}S_2 + \ldots + c_{2n}S_n \\ &\ldots \\ X_n &= c_{n1}S_1 + c_{n2}S_2 + \ldots + c_{nn}S_n \end{aligned} \qquad (6.26)$$

Glavne komponente (6.25) prikažimo matrično $Y = AX$, a prikaz varijabli mjerenja (6.26) kao linearne kombinacije nezavisnih komponenti $X = CS$, supstitucijom druge jednadžbe u prvu dolazimo do jednadžbe $Y = ACS$ ili $Y = W^{-1}S$ ili $S = WY$, a to je rješenje ili skup nezavisnih komponenti. Potrebno je ocijeniti matricu W uz uvjet nezavisnosti ili tražimo maksimum negativnoga prirodnog logaritma funkcije vjerojatnosti (Likelihood):

$$-\log L(W^{-1}) = -\log \prod_{i=1}^{n}\prod_{t=1}^{k} \cosh\left(w_i^T y(t)\right) = -\sum_{i=1}^{n}\sum_{t=1}^{k} \log\cosh\left(w_i^T y(t)\right) \qquad (6.27)$$

U funkciji su vjerojatnosti w_i^T retci matrice *W* koja je inverzna matrica od matrice $W^{-1} = AC$, a $y(t)$ je stupac mjerenja varijabli mjerenja prikazanih glavnim komponentama na temelju jednadžbi (6.25) u trenutku mjerenja *t*. U našoj formuli imamo *k* mjerenja varijabli mjerenja.

LiNGAM

Najpoznatiji je algoritam za rješavanje linearnoga kauzalnog modela s varijablama mjerenja koje imaju ne-Gaussovu razdiobu LiNGAM ili linearni ne-Gaussov aciklički model [187] oblika:

$$x_i = \sum_{j=1;\ j<i}^{n} b_{ij} x_j + e_i \quad ili\ \ X = BX + E \qquad (6.28)$$

Matrica B je donja trokutasta i tako osigurava acikličnost s dijagonalnim elementima 0, dobivano jednadžbu:

$$\begin{aligned} X - BX &= E \\ X &= (I - B)^{-1} E \end{aligned} \qquad (6.29)$$

Ako su E egzogene varijable s karakteristikama nezavisnih varijabli koje su međusobno nezavisne s očekivanjem 0 i standardnim devijacijama σ_i, traženje matrice $(I - B)^{-1}$ je postupak traženja nezavisnih varijabli opisan algoritmom. Kod toga LiNGAM uvažava oblik matrice B u kauzalnim modelima gdje je to moguće optimizacijom funkcije vjerojatnosti oblika:

$$\log L(B) = \sum_{t=1}^{k} \sum_{i=1}^{n} \log p_i \left(\frac{x_i(t) - b_i^T x(t)}{\sigma_i} \right) \qquad (6.30)$$

U funkciji vjerojatnosti $L(B)$ je $p_i = P(e_i / \sigma_i)$ vjerojatnost standardne egzogene varijable ili vjerojatnost vrijednosti mjerenja egzogene varijable ili nezavisne komponente.

U novije vrijeme postoje i proširenja LiNGAM algoritma na kauzalne modele s prikrivenim varijablama, i na cikličke kauzalne modele. Također postoji velik broj ostalih algoritama za rješavanje linearnih i nelinearnih kauzalnih modela.

6.5. Bayesove mreže

Pojam Bayesove mreže temelji se na pojmu Bayesove formule iz vjerojatnosti. Ta formula omogućava određivanje vjerojatnosti uzroka uz poznavanje uvjetne vjerojatnosti posljedica i uzroka i formule potpune vjerojatnosti. Bayesova je mreža usmjereni aciklički graf. Vrhovi su grafa slučajne varijable kao u kauzalnoj strukturi, a lukovi grafa imaju pondere uvjetne vjerojatnosti.

Autor je Bayesove formule Thomas Bayes, engleski prezbiterijanski svećenik, filozof i statističar iz 18. stoljeća. Bayesove mreže poznate su prije kauzalnih mreža i prilagodile su se kauzalnim mrežama uvažavajući intervenciju. Promatrajmo jednostavnu Bayesovu mrežu uzroka CPN-a kroz broj prometnih nesreća uzrokovanih *Brzinom neprimjerenom uvjetima na cesti* (UPBN), *Nepropisnom brzinom* (UPNB) i *Ostalim greškama vozača* (UPOV). Svaka je od navedenih varijabli jedan vrh grafa, a lukovi grafa pokazuju uzročnu povezanost promatranih varijabli. Bayesov graf prikazan je na Slici 6.9.

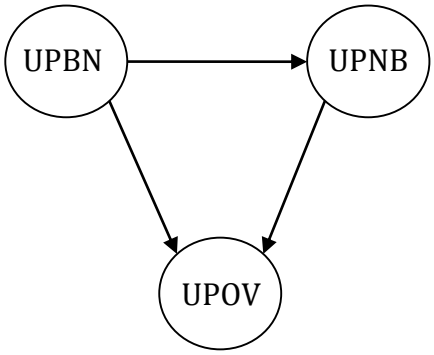

Slika 6.9. Bayesov graf

Svaka slučajna varijabla ima tri vrijednosti 0, 1 i 2. Vrijednost 0 znači najmanji broj nesreća za pojedini uzrok, a vrijednost 2znači najveći broj nesreća uzrokovan pojedinom varijablom. Kroz deset godina dobivena je tablica vrijednosti slučajnih varijabli (Tablica 6.2.).

Tablica 6.2. Vrijednosti varijabli

UPBN	UPNB	UPOV
2	2	2
2	1	0
2	1	1
2	2	2
1	2	2
1	2	2
1	1	1
0	0	1
0	0	0
0	0	0

Iz Tablice 6.2 slijede razdiobe pojedinih varijabli ili funkcije vjerojatnosti prikazane u Tablici 6.3.

Tablica 6.3. Funkcije vjerojatnosti

Varijabla	X	0	1	2
2	2	2		
UPBN	P(x)	0,3	0,3	0,4
UPNB	P(x)	0,3	0,3	0,4
UPOV	P(x)	0,3	0,3	0,4

Funkcije prijelaza ili uvjetne vjerojatnosti koje su pridružene lukovima grafa na temelju Tablice 6.2. prikazane su u Tablici 6.4.

Tablica 6.4. Funkcije prijelaza

	UPNB = 0	UPNB = 1	UPNB = 2
UPBN = 0	1	0	0
UPBN = 1	0	0,33	0,67
UPBN =2	0	0,5	0,5

	UPOV = 0	UPOV = 1	UPOV = 2
UPBN = 0	0,67	0,33	0
UPBN = 1	0	0,33	0,67
UPBN =2	0,25	0,25	0,5

	UPOV = 0	UPOV = 1	UPOV = 2
UPNB = 0	0,67	0,33	0
UPNB = 1	0,33	0,67	0
UPNB =2	0	0	1

	UPOV = 0	UPOV = 1	UPOV = 2
UPBN=0 , UPNB=0	0,67	0,33	0
UPBN=0, UPNB=1*	0,34	0,33	0,33
UPBN=0 , UPNB=2*	0,34	0,33	0,33
UPBN=1, UPNB=0*	0,34	0,33	0,33
UPBN=1, UPNB=1	0	1	0
UPBN=1, UPNB=2	0	0	1
UPBN=2, UPNB=0*	0,34	0,33	0,33
UPBN=2, UPNB=1	0,5	0,5	0
UPBN=2, UPNB=2	0	0	1

* Za ove vrijednosti procijenjena je funkcija prijelaza jer u stvarnim podactima ne postoje ti prijelazi.

Iz navedenih podataka izračunajmo na temelju Bayesova grafa iz Slike 6.9. funkcije vjerojatnosti pojedinih varijabli. Varijabla UPBN jest početna varijabla i ima razdiobu iz Tablice 6.3. prikazanu u Tablici 6.5.

Tablica 6.5. Funkcija vjerojatnosti varijable UPBN

Varijabla	x	0	1	2
UPBN	P(x)	0,3	0,3	0,4

Funkcija vjerojatnosti varijable UPNB ovisi o funkcijama prijelaza od UPBN prema UPNB i funkciji vjerojatnosti UPBN, a marginalna je razdioba zbroj po stupcima tablice i to je funkcija vjerojatnosti UPBN. Sve je prikazano u Tablici 6.6.

Tablica 6.6. Funkcija vjerojatnosti varijable UPNB

	UPNB = 0	UPNB = 1	UPNB = 2
UPBN = 0	1·0,3 = 0,3	0·0,3 = 0	0·0,3 = 0
UPBN = 1	0·0,3 = 0	0,33·0,3 = 0,10	0,67·0,3 = 0,2
UPBN =2	0·0,4 = 0	0,5·0,4 = 0,2	0,5·0,4 = 0,2
P(UPNB)	0,3	0,3	0,4

Funkcija vjerojatnosti varijable UPOV ovisi o funkcijama prijelaza od UPNB-a prema UPNB-u i od UPBN-a prema UPOV-u. To je izračunato u Tablici 6.7.

Tablica 6.7. Funkcija vjerojatnosti varijable UPOV

	UPOV = 0	UPOV = 1	UPOV = 2
UPBN=0 UPNB=0	0,3· 0,3·0,67=0,06	0,3·0,3·0,33=0,03	0,3·0,3·0=0
UPBN=0 UPNB=1	0,3·0,3·0,34=0,03	0,3·0,3·0,33=0,03	0,3·0,3·0,33=0,03
UPBN=0 UPNB=2	0,3·0,4·0,34=0,04	0,3·0,4·0,33=0,04	0,3·0,4·0,33=0,04
UPBN=1 UPNB=0	0,3·0,3·0,34=0,03	0,3·0,3·0,33=0,03	0,3·0,3·0,33=0,03
UPBN=1 UPNB=1	0,3·0,3·0 = 0	0,3·0,3·1 = 0,09	0,3·0,3·0 = 0
UPBN=1 UPNB=2	0,3·0,4·0=0	0,3·0,4·0=0	0,3·0,4·1=0,12
UPBN=2 UPNB=0	0,4·0,3·0,34=0.04	0,4·0,3·0,33=0,04	0,4·0,3·0,33=0,04
UPBN=2 UPNB=1	0,4·0,3·0,5=0,06	0,4·0,3·0,5=0,06	0,4·0,3·0=0
UPBN=2 UPNB=2	0,4·0,4·0=0	0,4·0,4·0=0	0,4·0,4·1=0,16
P(UPOV(m))	0,26	0,32	0,42

Vidimo da naš model ne opisuje stvarnost jer se razlikuje od stvarne razdiobe UPOV. Razliku možemo mjeriti Kullback–Lieblerovom informacijom, koja je razlika ukrštene entropije i entropije varijable iz prirode. Entropija varijable UPOV ili neodređenost varijable iz prirode je H(UPOV):

$$H(UPOV) = -\sum f(x)\cdot \log_2(f(x)) = (0{,}3\log_2(0{,}3) + 0{,}3\log_2(0{,}3) + 0{,}4\log_2(0{,}4)) = 4{,}80\,bita$$

Ukrštena entropija varijable iz prirode UPOV i varijable iz modela UPOV(m):

$$H(UPOV, UPOV(m)) = -\sum f(x)\cdot \log_2(f(x)(m))$$

Razlika ukrštene entropije i entropije je Kullback–Lieblerova informacija, koju smo dobili modelom:

$$I(UPOV, UPOV(m)) = H(UPOV, UPOV(m)) - H(UPOV) = -\sum f(x)\cdot \log_2\left(\frac{f(x)}{f(x)(m)}\right)$$
$$= -\left(0{,}3\log_2\left(\frac{0{,}3}{0{,}26}\right) + 0{,}3\log_2\left(\frac{0{,}3}{0{,}32}\right) + 0{,}4\log_2\left(\frac{0{,}4}{0{,}42}\right)\right) = 0{,}01\,bita$$

Sada pokažimo utjecaj planiranja na ovom jednostavnom modelu. Ako UPBN ili uzroke prometnih nesreća smanjimo na najmanju mjeru ili UPNB = 0, dolazimo do intervencije u modelu koji se može prikazati grafom na sljedećoj slici (Slika 6.10.).

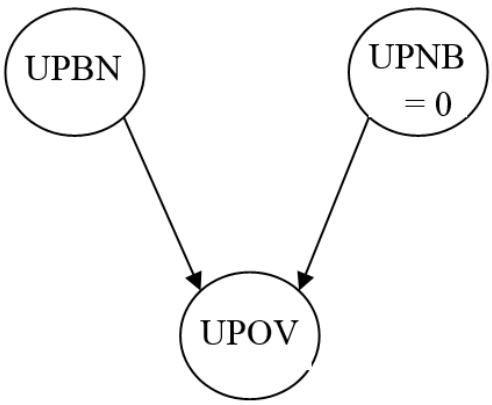

Slika 6.10. Intervencija na Bayesovu grafu

Razdioba UPOV-a prikazana je na sljedećoj tablici (Tablica 6.8.).

Tablica 6.8. Funkcija vjerojatnosti varijable UPOV nakon intervencije UPNB-a

	UPOV = 0	UPOV = 1	UPOV = 2
UPBN=0 UPNB=1	0,3·1·0,34=0,10	0,3·1·0,33=0,10	0,3·1·0,33=0,10
UPBN=1 UPNB=1	0,3·1·0 = 0	0,3·1·1 = 0,30	0,3·1·0 = 0
UPBN=2 UPNB=1	0,4·1·0,5=0,20	0,4·1·0,5=0,20	0,4·1·0=0
P(UPOV(m))	0,30	0,60	0,10

Uz ovu intervenciju možemo izračunati smanjenje broja prometnih nesreća uzrokovanih ostalim greškama vozača. Promjenu broja nesreća računamo iz promjene u razdiobi vrijednost varijable UPOV=1 se promijenila za (0,60 – 0,32), a vrijednost varijable UPOV=2 se promijenila za (0,10 – 0,42). Ukupna je promjena 1 · (0,60 – 0,32) + 2 · (0,10 – 0,42) = – 0,36. To znači smanjenje broja nesreća uzrokovanih ostalim greškama vozača za 36%.

7. IZRADA MODELA CESTOVNIH PROMETNIH NESREĆA ZA URBANA PODRUČJA

U posljednje vrijeme znanstvenici se sve više koriste podatcima u realnom vremenu u izučavanju različitih aspekata sigurnosti cestovnoga prometa, posebice cestovnih prometnih nesreća. U studijama i istraživanjima predlažu se mjere kako bi se broj i težina CPN-a smanjili i prevenirali, pri čemu je bitno da se temelje na znanstvenim i objektivnim istraživanjima o uzrocima i oblicima prometnih nesreća.

Niti jedna mjera kojom se pokušava povećati stupanj sigurnosti na prometnicama ne može spriječiti nastanak nesreće ili smanjiti njezine posljedice ako njezini efekti ne utječu na jedan ili više čimbenika koji sustavno doprinose nastanku nesreća ili ozljeda. Ti su čimbenici (događaji i/ili radnje koje imaju izravan ili neizravan utjecaj na broj i težinu pojava CPN-a) u većini prethodnih studija i istraživanja obilježeni pojmom „rizični čimbenici“ [188]. Složena struktura i umreženost ključnih rizičnih čimbenika koji utječu na sigurnost prometa prometnim stručnjacima znatno otežavaju modeliranje prognostičkoga modela CPN-a.

Rizične čimbenike promatraju interdisciplinarne ekspertne skupine prometnih inženjera, psihologa, liječnika i djelatnika prometne policije u svrhu podrobnije analize pojedinih tipova CPN-a [189].

Analiza utjecajnih čimbenika, metode njihova prikupljanja te analiza onih koji će se primijeniti kao ulazni parametri pri izradi prognostičkih modela CPN-a za urbana područja prethodno su naznačeni u poglavljima 3. i 4.

Predloženim ćemo kauzalnim modelom biti u mogućnosti identificirati odnos između nezavisnih varijabli koje uzrokuju nastanak CPN-a i zavisnih varijabli koje predstavljaju broj ili oblik prometnih nesreća, te će se nastavkom ovih istraživanja pokušati prikazati kako su ti rizični čimbenici kauzalno povezani.

Na području sigurnosti cestovnoga prometna u svijetu se trenutno koriste različite metode i algoritmi analiza podataka u svrhu istraživanja međuodnosa različitih kategorija CPN-a s vozačkim i okolišnim rizičnim čimbenicima evidentiranima u službenim zbirnim registrima o prometnim nesrećama.

Na temelju takvih analiza podataka u vezi s CPN-om u mogućnosti smo dobiti kvalitetne podatke koji mogu pružiti ključne informacije zakonodavnim i izvršnim vlastima za provedbu brojnih mjera i aktivnosti u području politike prevencije smrtnih ishoda i povreda u cestovnom prometu.

Kauzalnost nesreća može se shvatiti i objasniti kroz detaljnu analizu statističkih skupova podataka o prometnim nesrećama, koji mogu pružiti snažne indicije o mnogim čimbenicima nastanka nesreća [170].

Na temelju objedinjenih podataka o prometnim nesrećama iz zbirnih izvješća Ministarstva unutarnjih poslova Republike Hrvatske Policijske uprave zagrebačke izradit će se statistički kauzalni model CPN-a.

U skladu s navedenim prethodno obrađenim ulaznim podatcima, u kauzalni ćemo model uvrstiti one varijable za koje se ispostavi da su zaslužne za uzroke nastanka prometnih nesreća, dok je konačni cilj rangiranje i identifikacija upravo onih najutjecajnijih. Na taj će se način pokušati najvjerodostojnije objasniti uzroci nastanka cestovnih prometnih nesreća na promatranom području, što će rezultirati kvalitetnim prognozama o njihovu budućem broju i vrsti.

Koristeći posljednja dostignuća u kauzalnoj analizi, predloženi će model predstavljati set egzogenih varijabli te set endogenih varijabli u kojem će za svaku endogenu varijablu strukturna jednadžba opisivati kako ta varijabla reagira na promjene u odnosu na druge varijable modela.

7.1. Izbor ulaznih varijabli – čimbenika

U mnogim prometno-sigurnosnim studijama i elaboratima autori se često suočavaju s problemom procjene regresijskih odnosa između podataka o CPN-u i određenih socioekonomskih čimbenika ili drugih karakteristika koje mogu poslužiti kao nezavisne varijable (čimbenici) [174]. Na temelju prethodne analize čimbenika cestovnih prometnih nesreća (Poglavlje 3.) i dubinske analize podataka o sigurnosti cestovnoga prometnog sustava u Gradu Zagrebu (Poglavlje 5.) izabrane su ulazne varijable prognostičkoga modela CPN-a za urbana područja.

Kao varijable za izradu prognostičkoga modela CPN-a za urbana područja RH osim podataka iz državne baze, od MUP PUZ-a su zatražena zbirno obrađena tablična statistička godišnja izvješća („*Stanje sigurnosti u cestovnom prometu na području Policijske uprave zagrebačke*“) te sljedeći statističko-kategorizirani podatci (distribuirani prema prometnim nesrećama i nastradalim osobama) i uzročnici CPN-a povezani s njihovim nastankom, a koji su na nacionalnoj razini već obrađeni u sklopu godišnjih *Biltena o sigurnosti cestovnog prometa*:

- Vrste prometnih nesreća,
- Prometne nesreće prema kategorijama cesta,
- Prometne nesreće po značajkama ceste,
- Prometne nesreće prema meteorološkim uvjetima i stanju kolnika,

- Prometne nesreće prema uvjetima vidljivosti,
- Prometne nesreće prema stanju kolničke konstrukcije,
- Prometne nesreće prema vrsti vozila,
- Uzroci prometnih nesreća.[42]

Kako bi se utvrdila razina kauzalnosti predloženih čimbenika zaslužnih za njihov nastanak te reducirao broj zavisnih varijabli, zavisne varijable u kauzalnom modelu predstavljat će dvije glavne izlazne kategorije CPN-a, koje će biti obrađene i komparirane:

(a) ukupan broj registriranih CPN-a (s materijalnom štetom, ozlijeđenim i poginulim osobama),

(b) broj teško i lako ozlijeđenih sudionika u CPN-u.

U doktorskom radu primarna ograničenost predloženih prognostičkih modela CPN-a za urbana područja jest u karakteristikama njihovih ulaznih varijabli.

Kao što je načelno spomenuto u poglavlju 4., mnoge od ulaznih varijabli koje su korištene za potrebe izrade predloženih prognostičkih modela CPN-a za urbana područja predstavljaju podatke koji su bili dostupni, a ne ujedno i optimalni. Veliki broj istraživanja već je proveden u razumijevanju sigurnosnih aspekata cestovnih prometnih nesreća u urbanim područjima. Međutim, još uvijek postoje čimbenici koje treba dodatno istražiti i uključiti u statističke modele predviđanja stopa CPN-a. Stoga bi se povećanjem broja ulaznih varijabli modela različitih međusobnih karakteristika i grupacija (vozilo i prometna okolina) omogućila podrobnija usporedba, rangiranje i validacija uzročnika cestovnih prometnih nesreća.

U skladu s navedenim, korištenjem se ulaznih podataka koji su značajnije usklađeni s grupacijom rizičnih čimbenika koje predstavlja „čovjek“, a koja je ujedno i najzaslužnija za pojavu CPN-a, pokušala povećati valjanost i preciznost predloženih modela.

Nadalje, limitiranost ulaznih podatka očituje se i u činjenici što su vrijednosti ulaznih varijabli obrađene na godišnjoj, a ne mjesečnoj bazi (kompjuterizirana evidencija statističkih izvješća o gore navedenim ulaznim varijablama – čimbenicima na mjesečnoj bazi, za spomenuto desetogodišnje razdoblje, nije se mogla pribaviti od MUP PUZ-a zbog limitiranosti njihova sustava

[42] S obzirom na to da u IS-u MUP-a nije primjenjivano geoinformacijsko pozicioniranje tokom cijeloga analiziranog vremenskog perioda, točne lokacije nastanaka pojedinoga CPN-a moguće je pribaviti jedino dubinskom analizom svake pojedine prometne nesreće, odnosno pregledom *Upitnika o prometnoj nesreći*.

te dugotrajnosti ekstrahiranja podataka s obzirom na način njihove obrade), čime je ograničena duljina statističkih nizova, kao i praćenje trendova odnosno varijacija unutar predloženih varijabli modela.

Za izradu navedenih modela morala su se uzeti u obzir i određena ograničenja prilikom prikupljanja raspoloživih podatkovnih podloga zbog nedostatka izvora pružatelja detaljnih službenih zbirnih podataka o uzrocima odnosno čimbenicima nastanka prometnih nesreća, kao i nedostatak unificirane baze podataka o cestovnim prometnim nesrećama na razini države, koja bi služila kao platforma za njihovu kontrolu i prevenciju.

Stoga su ulazni podatci za potrebu izrade predloženoga prognostičkog modela prikupljeni samo od jednoga pružatelja podataka. Iako taj (Ministarstvo unutarnjih poslova RH) predstavlja ujedno i najznačajnijega službenog pružatelja takvih statističkih podataka, tim je pristupom ostvareno pojednostavljenje prilikom prikupljanja i kontrole predmetnih podataka, s obzirom na to da su pojedini pružatelji podataka često u međusobnom konfliktu jer su se služili različitim metodologijama i koristili različitim alatima prilikom kreiranja svojih izvještaja.

Kao ograničenje u ovom radu možemo navesti i pojedina neslaganja u bazama podataka IS-a MUP-a Republike Hrvatske i Državnoga zavoda za statistiku, koja se prije svega odnose na broj i strukturu nastradalih osoba. To se očituje u činjenici da se tijekom izvršenja očevida određenoga CPN-a ne znaju konačne posljedice po sudionike te se one naknadno upisuju u službeni registar, pri čemu je posebno problematično razdoblje ono tijekom kraja godine, u mjesecu prosincu.

No osnovno je ograničenje u radu bila nemogućnost kompletiranja prethodno definiranih ulaznih parametara prognostičkoga modela, s obzirom na to da većina podataka koji su traženi od MUP PUZ-a nije zaprimljena, što otežava i usmjerava daljnje aktivnosti. No, i pored prisutnih ograničenja, primijenjen prognostički model predstavlja usustavljen model CPN-a u uvjetima oskudnih raspoloživih podataka za njegovo modeliranje.

Dobiveni podatci u nastavku su obrađeni primjenom osnovnih statističkih metoda – analizom vremenskih nizova, klasifikacijom i komparacijom te deskripcijom uz pomoć računalnih programa *Statistica* tvrtke *StatSoft, Inc.* te programa *Tetrad*, izrađenoga u sklopu *Tetrad Projecta*. Navedeni paket izradili su Spirtes, Glymour i Scheines [190] 2013. godine na Sveučilištu Carnegie Mellon.

Tetrad program dozvoljava korisniku izradu kauzalnih statističkih modela za diskretne vrijednosti podataka ili Bayesove mreže i za kontinuirane vrijednosti podataka koji imaju normalnu razdiobu. Program određuje parametre opisanih modela na temelju varijabli mjerenja. Parametri modela ocjenjuju se na temelju unesenih podataka i tako dobivamo kauzalne statističke modele. Modeli dopuštaju intervenciju za svaki skup varijabli mjerenja i omogućavaju

izračunavanje posljedica intervencija. Nalaženjem različitih modela *Tetrad* program može usporediti njihovu strukturu ili njihove acikličke grafove. U programu su i elementi faktorske analize kojom možemo grupirati varijable mjerenja ili odrediti klase varijabli mjerenja.

Osnovna je struktura *Tetrad* projekta unos podataka i njihova diskretizacija, ako je potrebna za Bayesov tip modela. Podatci se mogu unositi ručno ili iz *Exela*. Velikim brojem algoritama određuje se statistička kauzalna struktura ili aciklički usmjereni graf modela. Odabrana kauzalna struktura u *Teradu* se proširuje parametrima. U idućem koraku *Tetrad* programa iz ulaznih se podataka ocjenjuju parametri modela ili se određuje kauzalna mreža modela ili konačni oblik kauzalnoga modela. Na takvom se modelu mogu raditi razne ciljane intervencije i simulacije stvarnih situacija koje se modeliraju. Prednosti su *Tetrad* programa velik broj poznatih algoritama (PC, JPC, *LiNGAM*, …), brzina izračunavanja i grafički prikazi modela.

U modeliranju kauzalnoga modela statističku bazu predstavljaju podatci o CPN-u iz razdoblja od 10 godina, tj. od 1. siječnja 2004. do 31. prosinca 2013. godine, s obzirom na to da takvo razdoblje predstavlja dobar pokazatelj te dostatan niz praćenja statističkih zbirnih podataka kako bi se predloženo modeliranje moglo kvalitetno provesti, tj. kako bi se trendovi kretanja mogli odvojeno promatrati u odnosu na slučajne oscilacije. Pribavljeni su podatci kritički analizirani i dopunjeni saznanjima teritorijalno nadležne policijske uprave, kao i operativnim iskustvima inspektora za ceste.

Tim se pristupom kroz relativno duži vremenski period mogu utvrditi promjene kretanja promatranih ulaznih parametara modela, čime se može odrediti stupanj njegove uspješnosti te izvesti prognoza budućega stanja, odnosno kretanje prognostičkih trendova.

Nažalost, dostupnu dokumentacijsku podlogu u smislu referentnih prometnih podataka o prometnom sustavu Grada Zagreba, koja nam omogućava uvid u karakteristike prometnoga toka (brzina i gustoća mješovitog prometnog toka, brzina toka vozila javnog gradskog prijevoza i sl.), kao i karakteristike njegovih sudionika (brzina putovanja, način putovanja, struktura putovanja po tipu, vremenska razdioba putovanja tijekom dana i sl.) također nismo mogli iskoristiti kao ulazne podatke prilikom izrade prognostičkoga modela s obzirom na to da oni više nisu aktualni. Naime, posljednja su cjelovita temeljna prometna istraživanja u gradu objavljena prije 13 godina (1998. godine), u okviru izrade *Prometne studije grada Zagreba*.

U skladu s gore navedenim, glavni će cilj u razradi predloženoga kauzalnog modela biti istražiti i analizirati ulazne podatke o uzrocima nastanka CPN-a kako bi se stekao uvid u kauzalnost tih nesreća čimbenicima na kojima se one temelje, tj. utvrditi kauzalnost rizičnih čimbenika ponašanja sudionika u prometu [191] te cestovno-prometne varijable koje najviše utječu na pojavu CPN-a.

Valja napomenuti da će se primjenom kauzalnoga modela očekivano potvrditi hipoteza o kauzalnoj povezanosti rizičnih čimbenika, pri čemu ih više nećemo promatrati međusobno nezavisno.

7.2. Varijable modela

Za potrebe izrade prognostičkoga modela statističku bazu predstavlja 11 varijabli mjerenja koje predstavljaju uzroke CPN-a, odnosno okolnosti koje su prethodile nastanku CPN-a, te 10 varijabli mjerenja koje predstavljaju vrstu CPN-a (Tablica 7.1.). Varijable modela obrađene su u dubinskoj analizi u Poglavlju 5. U nastavku su, iza navedenih varijabli mjerenja naznačene i njihove skraćenice, koje se dalje koriste u izradi modela.

Obilježje je svake varijable u prvom i trećem modelu ukupan broj registriranih CPN-a, a u drugom i četvrtom modelu broj teško/lako ozlijeđenih sudionika u prometu.

Tablica 7.1. Nazivi i skraćenice ulaznih varijabli kauzalnih prognostičkih modela

Red.broj.	Naziv varijable	Skraćenice Modela 1	Skraćenice Modela 2
1.	Nepropisna brzina	UPNB	UONB
2.	Brzina neprimjerena uvjetima	UPBN	UOBN
3.	Vožnja na nedopuštenoj udaljenosti	UPVN	UOVN
4.	Nepropisno skretanje	UPNS	UONS
5.	Nepropisna vožnja unazad	UPNU	UONU
6.	Nepropisno prestrojavanje	UPNP	UONP
7.	Nepoštivanje prednosti prolaza	UPPP	UOPP
8.	Nepoštivanje svjetlosnoga znaka	UPSZ	UOSZ
9.	Ostale greške vozača	UPOV	UOOV
10.	Greške pješaka	UPGP	UOGP
11.	Ostale okolnosti	UPOO	UOOO

Red.broj.	Naziv varijable	Skraćenice Modela 3	Skraćenice Modela 4
1.	Iz suprotnoga smjera	VPSS	VOSS
2.	Bočni sudar	VPBS	VOBS
3.	Vožnja u slijedu	VPVS	VOVS
4.	Udar vozila u parkirano vozilo	VPUP	VOUP
5.	Slijetanje vozila s ceste	VPSC	VOSC
6.	Nalet na bicikle	VPNB	VONB
7.	Nalet na pješaka	VPNP	VONP
8.	Nalet na motocikl ili moped	VPNM	VONM
9.	Ostalo	VPOS	VOOS
10.	Udar vozila u objekt	VPUO	VOUO

Opis svake pojedine ulazne varijable, dobiven u razgovoru s predstavnicima MUP PUZ-a, nije doslovno usvojen, te se sve koriste u skladu s *Upitnikom o CPN-u*, ovisno o interpretaciji samih službenika tijekom obavljanja odgovarajućih radnji na službenoj dužnosti.

7.3. Dijagram toka modela

Kauzalni računalni program *Tetrad* strukturiran je od nekoliko zasebnih modula – *Data Box*, *Data Manipulation Box*, *Search Box*, *Parametric Model Box*, *Instantiated Model Box* te *Updater*. Glavni algoritmi računalnoga programa *Tetrad*, koje smo primijenili prilikom modeliranja predloženoga prognostičkog modela, detaljno su razrađeni u prethodnom poglavlju.

Modul *Data Box* primjenjuje se za unos ulaznih vrijednosti modela. *Data Manipulation Box* digitalizira ulazne podatke za potrebe izrade Bayesova modela. *Search Box* primjenom nekoliko vrsti algoritama (JPC i PC LINGAM) izrađuje optimalnu kauzalnu strukturu. *Parametric Model Box* (Karakteristične vrijednosti modela) koristi se za određivanje parametara modela ili imenovanje prijelaznih vjerojatnosti. *Instantiated Model Box* izračunava vrijednosti parametara modela. Završni modul (Simulacija modela) nam daje konačne razdiobe vrijednosti varijabli na temelju kauzalnoga modela (Slika 7.1.).

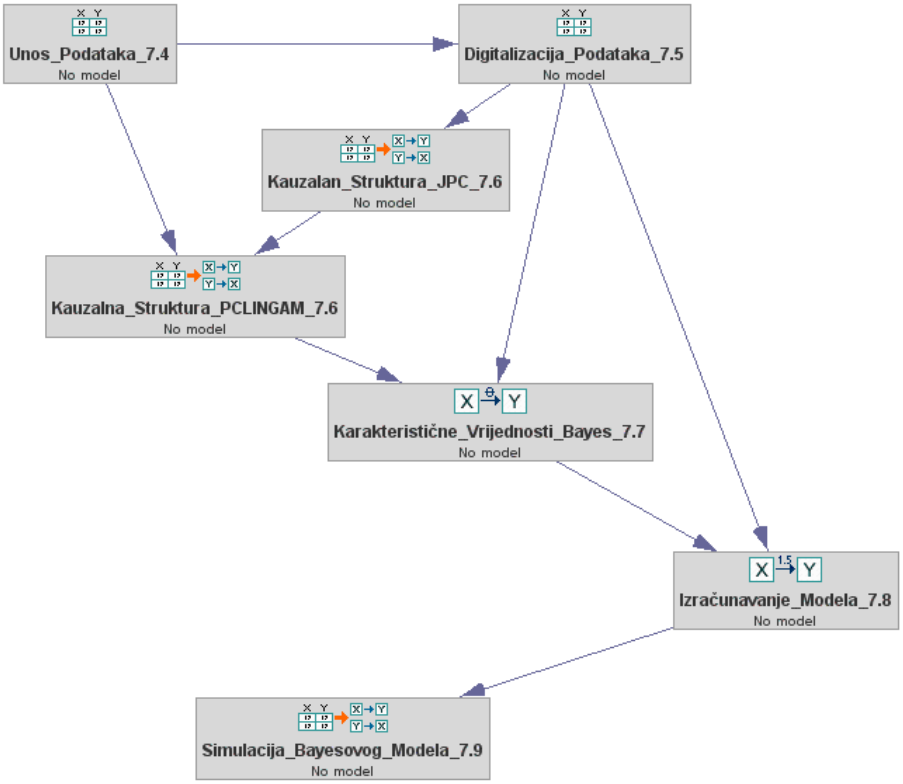

Slika 7.1. Dijagram toka kauzalnoga modela – Primjer Model 1

7.4. Unos podataka u model

Statistički podatci o CPN-u dobiveni od predstavnika MUP PUZ-a prvotno su grupirani i uvršteni u odgovarajuće tablične prikaze korištenjem aplikacijskoga sustava *Excel* računalnoga programa *Office* tvrtke *Microsoft*. Drugi korak bilo je njihovo ekstrahiranje u *Data Box* (Slika 7.2.) računalnoga programa *Tetrad 5.1.0-6*, koji predstavlja svojevrsnu pohranu stvarnih setova podataka na temelju kojih se određuje kauzalna struktura. Kategorijski podatci, naznačeni na predmetnoj slici, nalaze se u *ASCII* formi američkoga standardnog znakovnika za razmjenu informacija, pri čemu stupci predstavljaju vrijednosti svake od ulaznih varijabli predloženih kauzalnih modela.

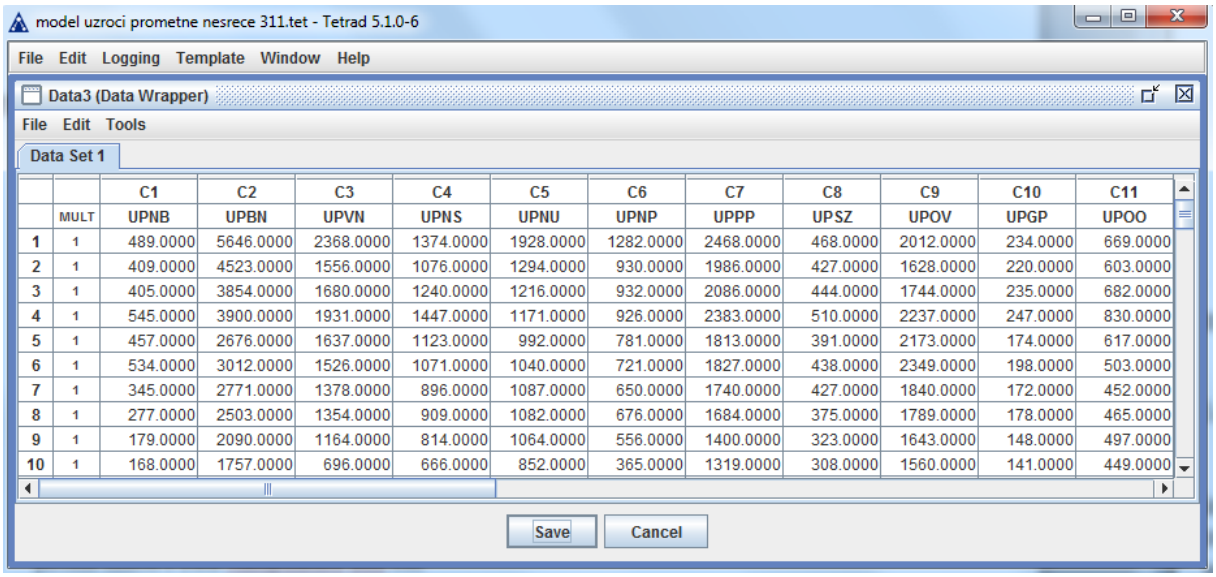

		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
	MULT	UPNB	UPBN	UPVN	UPNS	UPNU	UPNP	UPPP	UPSZ	UPOV	UPGP	UPOO
1	1	489.0000	5646.0000	2368.0000	1374.0000	1928.0000	1282.0000	2468.0000	468.0000	2012.0000	234.0000	669.0000
2	1	409.0000	4523.0000	1556.0000	1076.0000	1294.0000	930.0000	1986.0000	427.0000	1628.0000	220.0000	603.0000
3	1	405.0000	3854.0000	1680.0000	1240.0000	1216.0000	932.0000	2086.0000	444.0000	1744.0000	235.0000	682.0000
4	1	545.0000	3900.0000	1931.0000	1447.0000	1171.0000	926.0000	2383.0000	510.0000	2237.0000	247.0000	830.0000
5	1	457.0000	2676.0000	1637.0000	1123.0000	992.0000	781.0000	1813.0000	391.0000	2173.0000	174.0000	617.0000
6	1	534.0000	3012.0000	1526.0000	1071.0000	1040.0000	721.0000	1827.0000	438.0000	2349.0000	198.0000	503.0000
7	1	345.0000	2771.0000	1378.0000	896.0000	1087.0000	650.0000	1740.0000	427.0000	1840.0000	172.0000	452.0000
8	1	277.0000	2503.0000	1354.0000	909.0000	1082.0000	676.0000	1684.0000	375.0000	1789.0000	178.0000	465.0000
9	1	179.0000	2090.0000	1164.0000	814.0000	1064.0000	556.0000	1400.0000	323.0000	1643.0000	148.0000	497.0000
10	1	168.0000	1757.0000	696.0000	666.0000	852.0000	365.0000	1319.0000	308.0000	1560.0000	141.0000	449.0000

Slika 7.2. Ulazni podatci strukturirani u potprogramu Data Box računalnoga programa Tetrad – Model

7.5. Digitalizacija podataka

Za potrebe Bayesova kauzalnog modela potrebno je podatke digitalizirati ili grupirati. U našim modelima vrijednosti svake su varijable grupirane u tri skupine. Svakoj vrijednosti pridružen je cijeli broj – 0, 1 ili 2. Računalni program *Tetrad* omogućava nam automatsku digitalizaciju, i to prema jednakoj distribuciji intervala ili jednakoj distribuciji vrijednosti. U modelu smo koristili digitalizaciju svih ulaznih varijabli s jednakom distribucijom intervala vrijednosti. U predmetnom računalnom programu to se provodi s pomoću *Data Manipulation Boxa* operacijom digitalizacije podataka *(DataManip – Discretize Dataset)*, vidi Sliku (7.3.). Valja napomenuti da se operacija digitalizacije podataka provodi na način da se prvotni korak, odnosno *Data Box* poveže lukom s *Data Manipulation Boxom*.

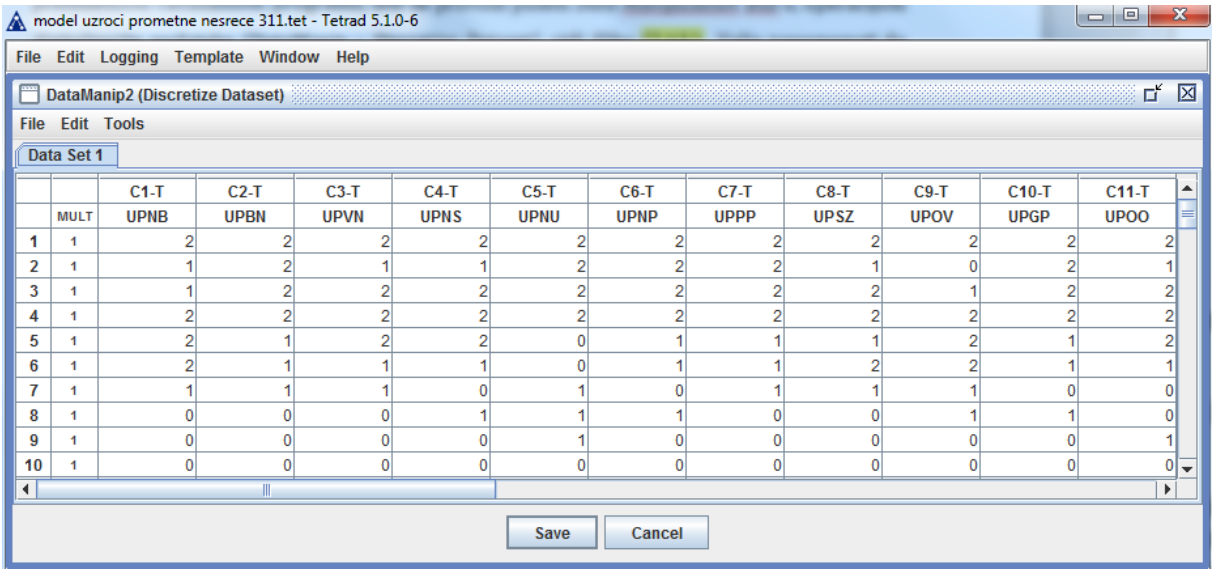

		C1-T	C2-T	C3-T	C4-T	C5-T	C6-T	C7-T	C8-T	C9-T	C10-T	C11-T
	MULT	UPNB	UPBN	UPVN	UPNS	UPNU	UPNP	UPPP	UPSZ	UPOV	UPGP	UPOO
1	1	2	2	2	2	2	2	2	2	2	2	2
2	1	1	2	1	1	2	2	2	1	0	2	1
3	1	1	2	2	2	2	2	2	2	1	2	2
4	1	2	2	2	2	2	2	2	2	2	2	2
5	1	2	1	2	2	0	1	1	1	2	1	2
6	1	2	1	1	1	0	1	1	2	2	1	1
7	1	1	1	1	0	1	0	1	1	1	0	0
8	1	0	0	0	1	1	1	0	0	1	1	0
9	1	0	0	0	0	1	0	0	0	0	0	1
10	1	0	0	0	0	0	0	0	0	0	0	0

Slika 7.3. Digitalizacija ulaznih podataka – Primjer Model 1

7.6. Određivanje kauzalne strukture

Za određivanje kauzalne strukture korišten je *JPC* i *LiNGAM* algoritam. *JPC* algoritam [192] predstavlja jednu od verzija *PC* algoritma, kojim se istražuju ulazni podatci. *PC* algoritam [190] određuje bridove neorijentiranoga grafa i moguće orijentacije bridova ovisno o uvjetnoj nezavisnosti vrhova u širem skupu varijabli.

LiNGAM algoritam određuje konačnu kauzalnu strukturu ulaznih varijabli (vidi str. 153., Poglavlje 6.). *JPC* algoritam definira je kroz *Search Box – JCPC*, a LiNGAM algoritam putem *Search Box – PC LiNGAM*.

Data Box, *Data Manipulation Box* i *Search Box* povezani su lukovima koji određuju redoslijed izvršavanja pojedinih dijelova programa.

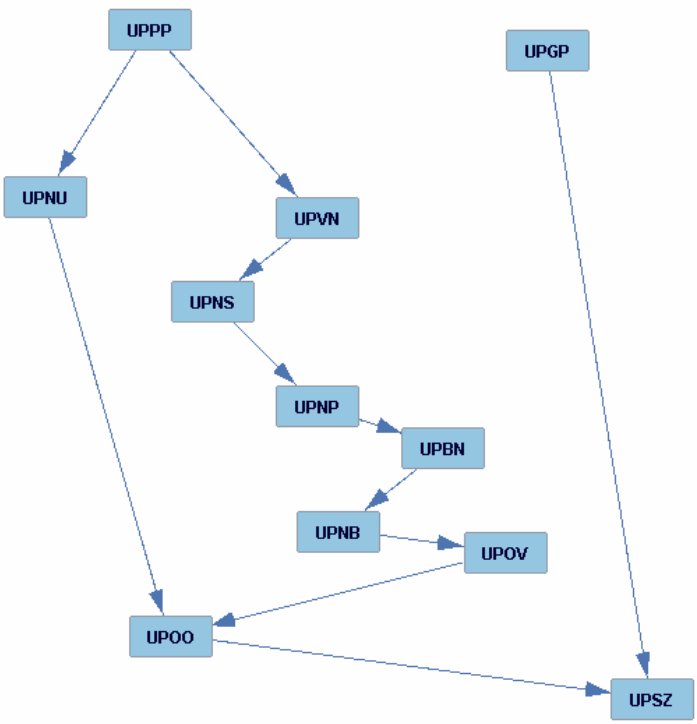

Slika 7.4. Kauzalna struktura – Primjer Model 1

7.7. Karakteristične vrijednosti modela

Na temelju digitalizacije podataka i strukturnoga modela u ovom koraku određujemo karakteristične vrijednosti (parametre) modela. U našem slučaju cilj nam je određivanje Bayesova modela i zato ovdje određujemo Bayesovu strukturu kauzalnoga modela, gdje se svakomu vrhu kauzalne strukture pridružuju vrijednosti 0, 1 ili 2. Računalni program *Tetrad* određuje karakteristične vrijednosti (parametre) modela u dijelu programa koji se zove *Parametric Model Box*, a prilikom njegova pokretanja na raspolaganju nam je više tipova modela koji se mogu generirati, kao što su *Bayes Parametric Models*, *SEM parametric model* te *generalized SEM parametric model*.

Ulazni podatci *Bayes Parametric Modelsa* predstavljaju prethodno izveden usmjereni aciklički graf, dobiven iz prethodnih modula, *Data Manipulation Boxa* i *Search Boxa*. Drugim riječima, svakoj varijabli pridružujemo konačno mnogo vrijednosti. *Bayes Parametric Models* sastoji se od tri komponente – grafičkoga prikaza kauzalne strukture modela, za svaku od navedenih ulaznih varijabli naznačuje broj kategorija koje određena varijabla ima te nazive kategorija povezanih sa svakom od ulaznih varijabli.

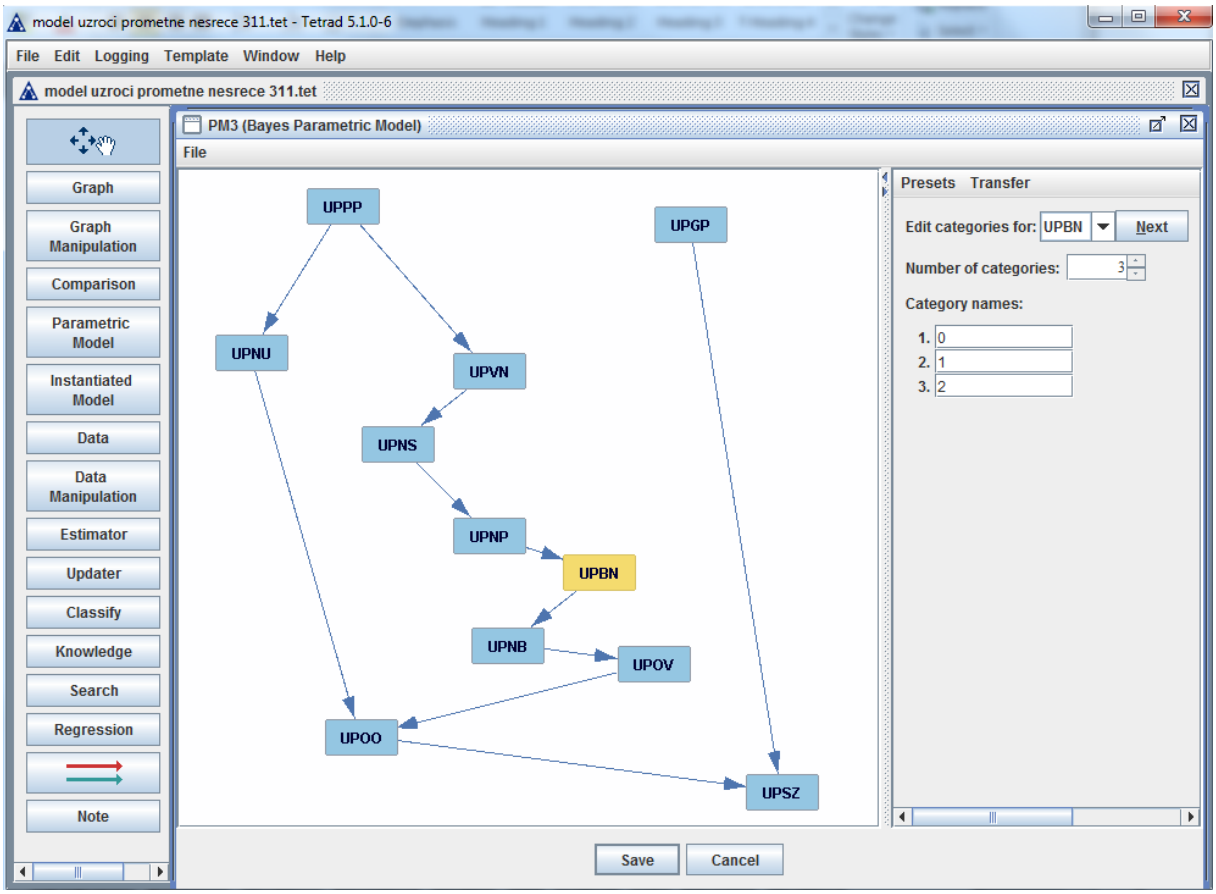

Slika 7.5. Bayesova struktura i parametri modela – Primjer Model 1

7.8. Izračunavanje modela

U *Tetrad* računalnom programu idući je korak određivanje Bayesova kauzalnog modela. *Instantiated Model Box* koristi prethodno parametrizirani model te mu dodjeljuje varijable i njihove vrijednosti.

Izborom *Dirichlet Bayes IM* određujemo vjerojatnosti prijelaza između vrhova kauzalne strukture. Program dozvoljava automatsko ili ručno unošenje vjerojatnosti prijelaza. U našem slučaju, vjerojatnosti prijelaza unesene su ručno, na temelju digitalizacije ulaznih podataka.

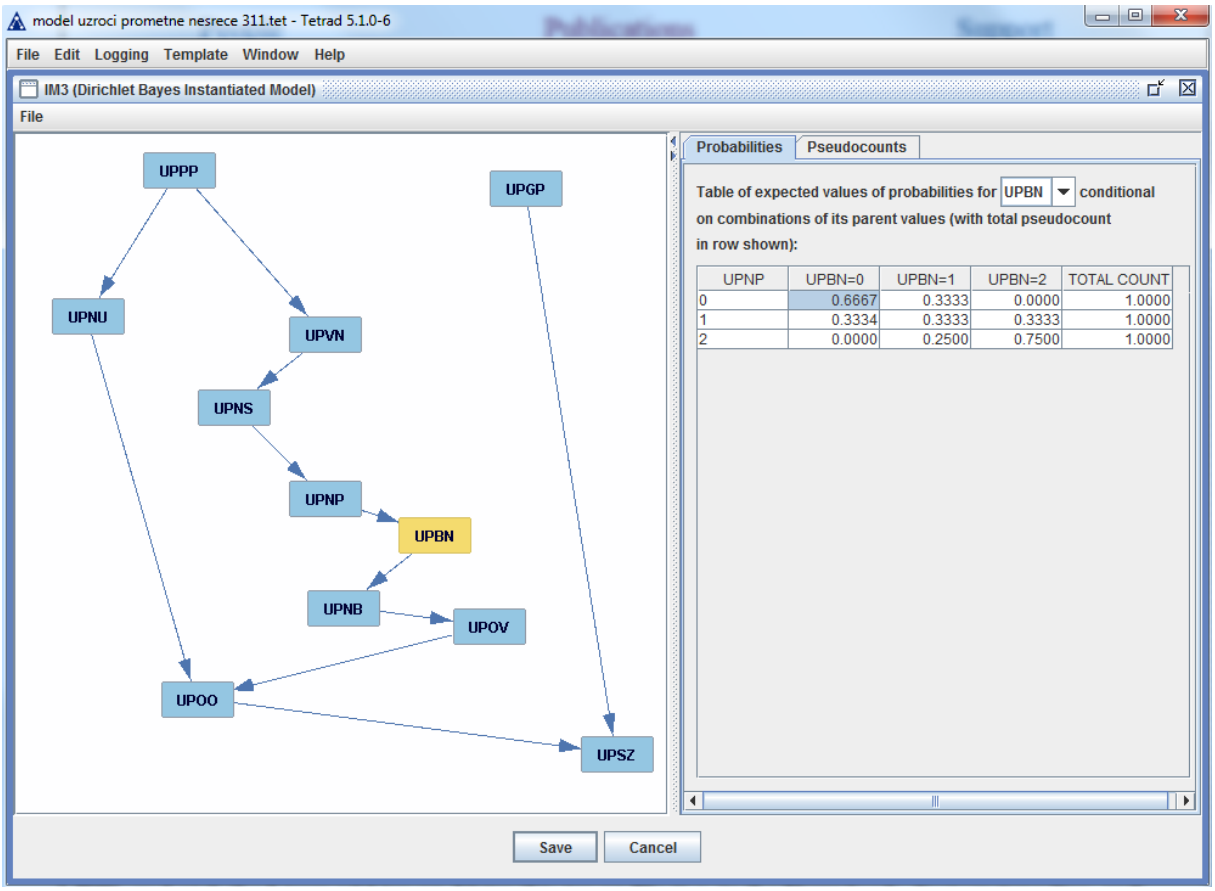

Slika 7.6. Bayesov model djelovanja– Primjer Model 1

7.9. Simulacija Bayesova kauzalnog modela

U ovom koraku određujemo vrijednosti razdioba uzroka CPN-a na temelju Bayesova kauzalnog modela, koji je definiran u prethodnom koraku. *Tetrad* računalni program za to koristi potprogram *Updater*, pri čemu korisnik na raspolaganju ima četiri algoritma – *Approximate updater*, *Row summing exact updater*, *CPT invariant updater* i *SEM updater.* U našem slučaju, za simulaciju predloženih modela korišten je algoritam *Row Summing Exact Updater*, koji je znatno precizniji u odnosu na prvotno navedeni, pri čemu njegova složenost ovisi o broju varijabli i broju kategorija koju svaka od njih posjeduje. Početni izbornik prikazuje kauzalnu strukturu, popis uzroka CPN-a i mogućnost naredbe *Do Update Now*, kojom se određuju početne marginalne razdiobe bez dodatnih uvjeta. Navedeni izbornik možemo koristiti za simulaciju opisanoga modela. U slučaju bez dodatnih uvjeta rezultat su modela jednake razdiobe plavih i crvenih linija koje određuju razdiobu vrijednosti pojedinih uzroka CPN-a na temelju modela. Ako se odlučimo za simulaciju modela, na određene uzroke CPN-a vršimo intervenciju. Intervencija se sastoji od promjene kauzalne strukture i razdiobe varijabli na kojima se provodi intervencija. U slučaju intervencije na određenu varijablu u kauzalnoj strukturi nestaju svi lukovi koji su prethodno u nju

ulazili. Intervencijom na varijablu određuje se samo jedna od mogućih vrijednosti. Ta vrijednost ima vjerojatnost 1. Naredbom *Do Update Now* dobivaju se nove vrijednosti razdiobe uzroka CPN-a, koje su prikazane crvenom linijom. Usporedbom crvene i plave linije može se odrediti posljedica intervencije.

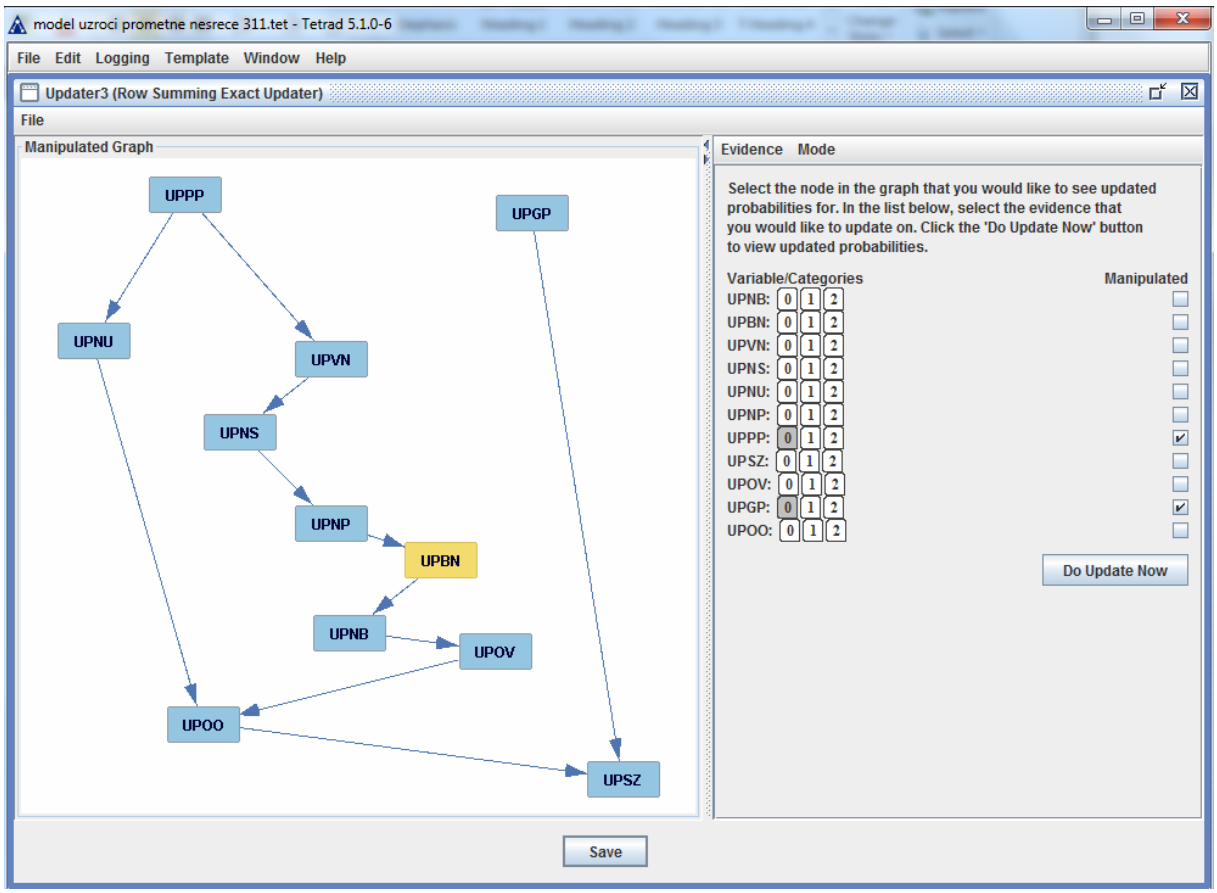

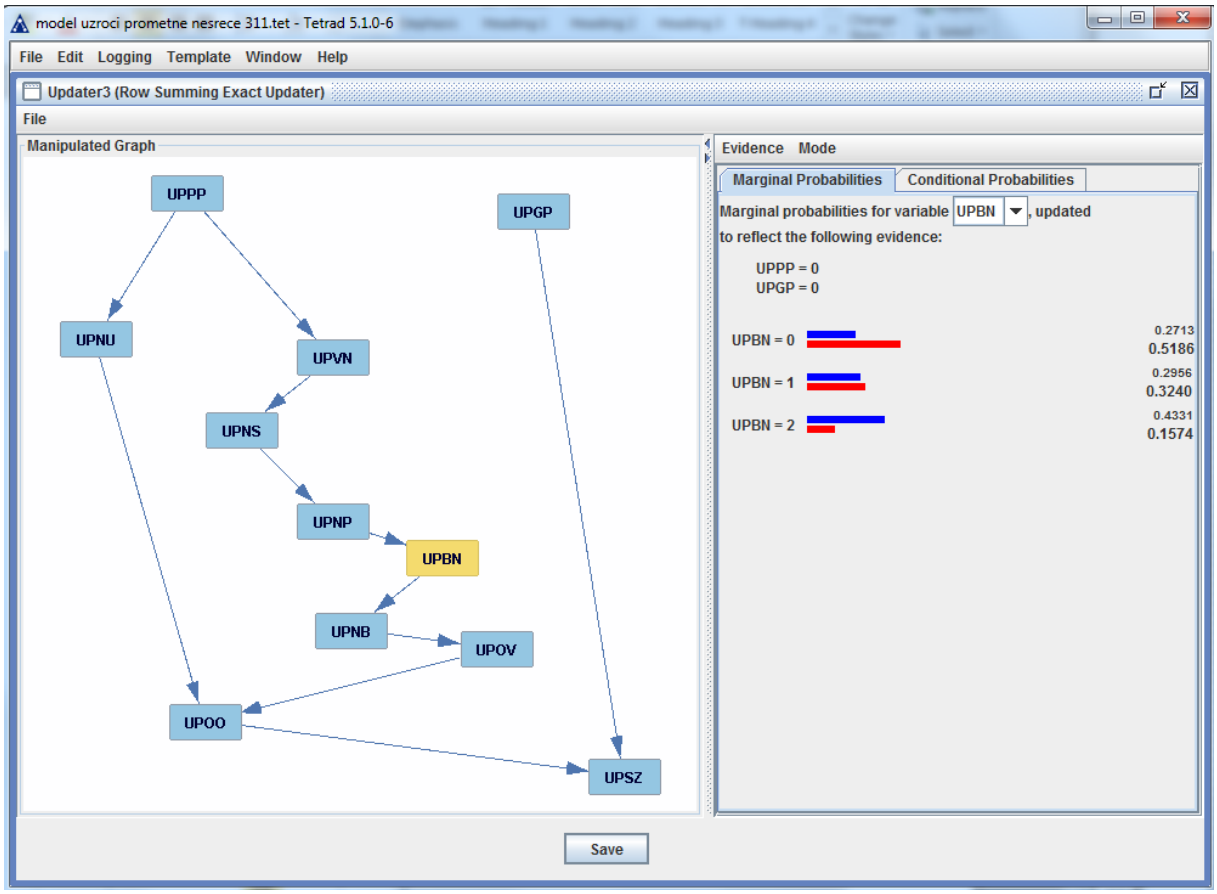

Slika 7.7. Grafički prikazi provedbe simulacije modela – Primjer Model 1

8. REZULTATI I EVALUACIJA MODELA

Analiza rezultata dobivenih kauzalno-prognostičkih modela podijeljena je na dvije skupine modela. Prvu skupinu sačinjavaju dva modela uzroka mjerena brojem nesreća i ozlijeđenih (u nastavku Model 1 i Model 2), dok drugu skupinu predstavljaju modeli vrsta mjereni brojem nesreća i ozlijeđenih (u nastavku Model 3 i Model 4).

Rezultate svake skupine promatramo kroz kvalitativnu i kvantitativnu analizu rezultata. Nakon spomenutih analiza provedena je evaluacija pojedinih modela.

8.1. Kvalitativna analiza rezultata modela uzroka prometnih nesreća

Kod analize uzroka CPN-a obrađene su dvije kategorije – na temelju ukupnoga broja registriranih CPN-a (Model 1) te na temelju ukupnoga broja teško/lako ozlijeđenih sudionika u njima (Model 2). Rezultati Modela 2, prema prethodno opisanomu postupku, navedeni su u Prilogu 5.

Kauzalne strukture Modela 1 i Modela 2, prikazane na Slici 8.1., ukazuju na različite povezanosti varijabli modela.

a)

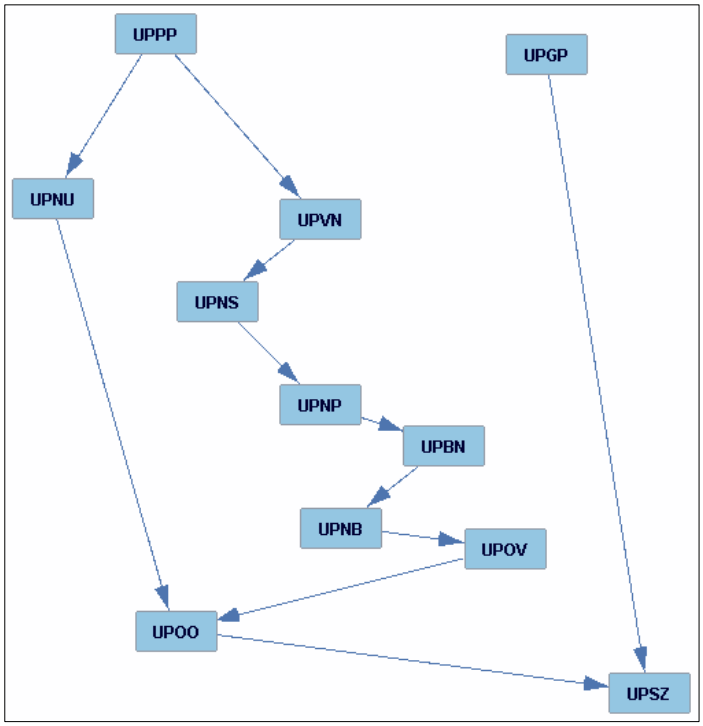

b)

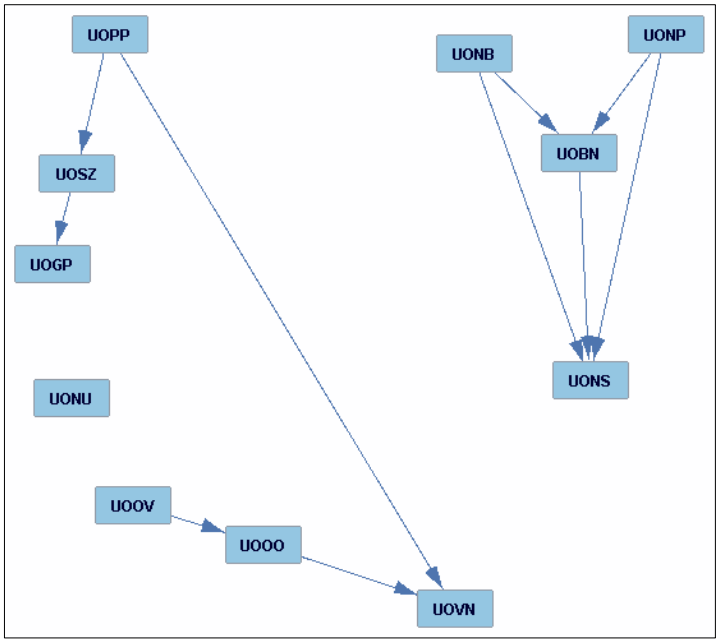

Slika 8.1. Komparativni prikaz kauzalnih struktura modela uzroka CPN-a (Model 1- a) i (Model 2 - b)

U tabličnom prikazu 8.1. prvi stupac predstavlja kauzalnu razinu. Prva kauzalna razina imenuje uzroke koji kauzalno određuju uzroke druge razine. Druga kauzalna razina imenuje uzroke koji određuju treću razinu. Sve ostale kauzalne razine grupirane su u zasebnoj, posljednjoj razini. Uzrok CPN-a koji ne utječe na ostale uzroke vidljiv je u Modelu 2 te je rangiran u nultu razinu.

Tablica 8.1. Prikaz kauzalnih razina prognostičkih modela uzroka CPN-a (Model 1 i Model 2)

Kauzalna razina	Model 1	Model 2
1.	**UPPP**, UPGP	**UOPP**, UOOV, UONB, UONP
2.	UPNU, **UPVN, UPSZ**	**UOSZ**, UOBN, UOOO, **UOVN**, UONS
3.	UPNS, UPOO	UOGP
Ostali	UPNP, UPBN, UPNB, UPOV	-
0.	-	UONU

Iz priložene tablice vidljivi su zajednički uzroci CPN-a na najvišim, dvjema kauzalnim razinama. To su *Nepoštivanje prednosti prolaza* (UPPP i UOPP), *Nepoštivanje svjetlosnoga znaka* (UPSZ i UOSZ) i *Vožnja na nedopuštenoj udaljenosti* (UPVN i UOVN). Svi se navedeni glavni zajednički uzroci, prema službenoj MUP-ovoj statistici, nalaze u skupini GREŠKE VOZAČA.

Razlika u uzrocima registriranih CPN-a i uzrocima ozlijeđenih osoba prve kauzalne razine za Model 1 predstavlja uzrok *Greške pješaka* (UPGP), dok su to kod Modela 2 *Nepropisna brzina* (UONB), *Nepropisno prestrojavanje* (UONP) i *Ostale greške vozača* (UOOV). Valja naglasiti da se u prvoj kauzalnoj razini glavni uzrok, prema službenoj MUP-ovoj statistici, nalazi u skupini *GREŠKE*

PJEŠAKA, a kod uzroka ovisno o broju ozlijeđenih osoba svi su navedeni uzroci uvršteni u kategoriju *GREŠKE VOZAČA*.

Djelovanjem na navedene uzroke prve kauzalne razine možemo utjecati na preostale uzroke ovisno o registriranim CPN-ima te ozlijeđenim osobama.

8.2. Kvantitativna analiza rezultata modela uzroka prometnih nesreća

U Modelu 1 simulacijom smo pretpostavili najmanju vrijednost 0 za uzroke prve kauzalne razine (iskazano podebljano u Tablici 8.2.). Rezultat simulacije potvrdio je smanjenje vrijednosti svih ostalih uzroka CPN-a uključenih u model. Rezultati simulacije svakoga uzroka za Model 1 i Model 2 prikazani su u Tablici 8.2., u stupcu „Rezultat simulacije". Rezultat simulacije izračunavamo kao očekivano smanjenje prosječne razine uzroka CPN-a.

U posljednjem stupcu navedene tablice rezultat simulacije pretvoren je u postotno smanjenje CPN-a za pojedine promatrane uzroke, odnosno ulazne varijable. Postotno smanjenje izračunava se dijeljenjem rezultata simulacije s ukupnim brojem vrijednosti varijable, što u našem slučaju iznosi 3.

Način izračunavanja srednje vrijednosti ranga pojedine ulazne varijable prognostičkoga modela (Grafikon 8.1.) u nastavku je iskazan na primjeru *Nepropisne brzine* pri Modelu 1 (UPNB).

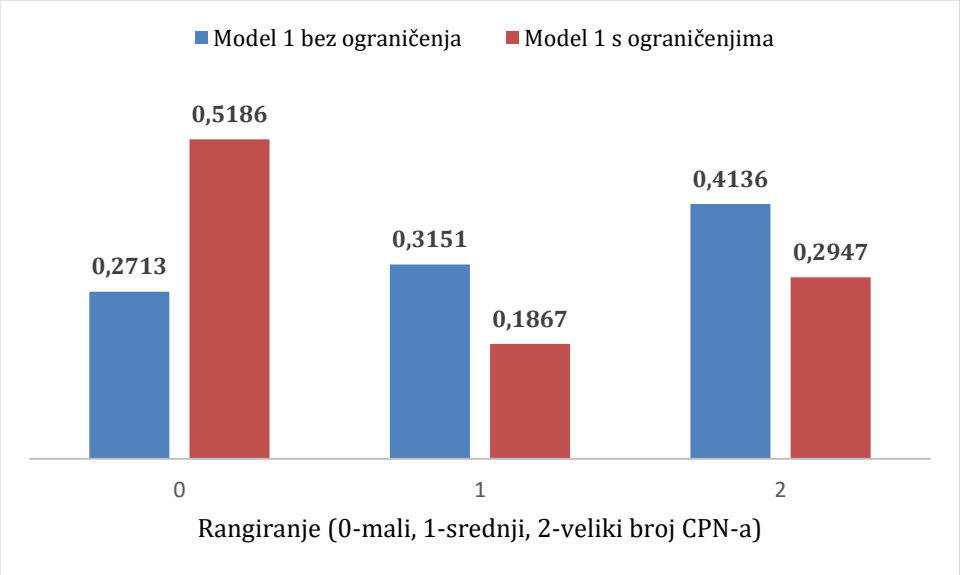

Grafikon 8.1. Primjer izračuna sredine ranga nepropisne brzine kao uzroka broja CPN-a

Na temelju vrijednosti iz grafikona 8.1. srednju vrijednost ranga izračunavamo množenjem vrijednosti ranga (0, 1, 2) s vjerojatnostima pojedinoga ranga (brojevi iznad stupaca). Tako u slučaju Modela 1 bez ograničenja srednja vrijednost ranga $\bar{x} = \sum_{x=0}^{2} f(x) \cdot x$ iznosi:

$$\bar{x}_1 = 0{,}2713 \cdot 0 + 0{,}3151 \cdot 1 + 0{,}4136 \cdot 2 = 1{,}1423$$

U slučaju Modela 1 s ograničenjima srednja vrijednost ranga iznosi:

$$\bar{x}_2 = 0{,}5186 \cdot 0 + 0{,}1867 \cdot 1 + 0{,}2947 \cdot 2 = 0{,}7761$$

Rezultat simulacije ili ograničenja na modelu pokazuje smanjenje srednje vrijednosti ranga, koje iznosi:

$$\bar{x}_2 - \bar{x}_1 = 0{,}7761 - 1{,}1423 = -0{,}3662$$

Prikazano smanjenje odnosi se na tri ranga i prosječno smanjenje broja CPN-a kojemu je uzrok nepropisna brzina te iznosi:

$$(\bar{x}_2 - \bar{x}_1)/3 = -0{,}3662/3 = -0{,}122 = -12{,}2\%$$

Tablica 8.2. Komparativna kvantitativna analiza rezultata prognostičkih modela uzroka CPN-a (Model 1- a) i (Model 2 - b)

a)

MODEL 1	Bez ograničenja na modelu			Ograničenje UPPP=0, UPGP=0			Rezultat simulacije	Smanjenje (%)
	0	1	2	0	1	2		
UPNB	0,2713	0,3151	0,4136	0,5186	0,1867	0,2947	-0,3662	-12,2
UPBN	0,2713	0,2956	0,4331	0,5186	0,324	0,1574	-0,523	-17,4
UPVN	0,3	0,2	0,5	1	0	0	-1,2	-40,0
UPNS	0,2667	0,2333	0,5	0,6667	0,3333	0	-0,9	-30,0
UPNU	0,3	0,4	0,3	0,3333	0,6667	0	-0,3333	-11,1
UPNP	0,2667	0,2806	0,4527	0,6667	0,2222	0,1111	-0,7416	-24,7
UPPP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	**-1,1**	**-36,7**
UPSZ	0,2379	0,5332	0,2289	0,5623	0,4377	0	-0,5533	-18,4
UPOV	0,2859	0,4039	0,3102	0,408	0,371	0,221	-0,2113	-7,0
UPGP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	**-1,1**	**-36,7**
UPOO	0,3669	0,2425	0,3906	0,507	0,3088	0,1842	-0,3465	-11,6

b)

MODEL 2	Bez ograničenja na modelu			Ograničenje UONB, UONP, UOPP, UOOV			Rezultat simulacije	Smanjenje (%)
	0	1	2	0	1	2		
UONB	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
UOBN	0,32	0,28	0,4	1	0	0	-1,08	-36,0
UOVN	0,3352	0,3142	0,3506	0,6667	0,3333	0	-0,6821	-22,7
UONS	0,2934	0,2733	0,4333	1	0	0	-1,1399	-38,0
UONU	0,1958	0,226	0,5782	1	0	0	-1,3824	-46,1
UONP	***0,2***	***0,4***	***0,4***	***1***	***0***	***0***	***-1,2***	***-40,0***
UOPP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
UOSZ	0,3	0,25	0,45	1	0	0	-1,15	-38,3
UOOV	***0,2852***	***0,3644***	***0,3504***	***1***	***0***	***0***	***-1,0652***	***-35,5***
UOGP	0,3	0,1958	0,5042	1	0	0	-1,2042	-40,1
UOOO	0,338	0,2777	0,3843	0,3333	0,6667	0	-0,3796	-12,7

Negativni predznak pokazuje smanjenje vrijednosti. Najveće smanjenje kod promatranih uzroka u Modelu 1 vidljivo je kod uzroka *Vožnja na nedopuštenoj udaljenosti* (UPVN) i iznosi 40%. Taj značajan postotak rezultat je intervencija na uzroke prve razine – 36,7% za *Nepoštivanje prednosti prolaza* (UPPP) te istovjetni postotak za varijablu *Greške pješaka* (UPGP). Iz navedenoga možemo zaključiti da intervencija na varijable prve kauzalne razine od 10% smanjenja uzrokuje smanjenje uzroka UPVN-a od 10,9% smanjenja (40/36,7*10). Na isti smo način u mogućnosti izračunati smanjenje i svih preostalih uzroka CPN-a. U slučaju drugačijih rezultata, ovisno o odabranim preventivnim sigurnosnim mjerama i aktivnostima na uzroke različitih razina, možemo procijeniti kauzalni efekt na preostale uzroke prometnih nesreća. To nam olakšava daljnje planiranje mjera i aktivnosti u području sigurnosti cestovnoga prometa.

U Modelu 2 varijabla naziva *Nepropisno prestrojavanje* (UONP) ima najveći postotak smanjenja (40%), a ona ujedno predstavlja i jednu od varijabli na kojoj je izvršena intervencija.

8.3. Kvalitativna analiza rezultata modela vrsta prometnih nesreća

Kod analize vrsta CPN-a također su obrađene dvije kategorije CPN-a – na temelju ukupnoga broja registriranih CPN-a (Model 3) te na temelju ukupnoga broja ozlijeđenih sudionika u njima (Model 4). Rezultati Modela 3 i Modela 4, prema prethodno opisanom postupku, navedeni su u Prilogu 6. i Prilogu 7. Njihova komparativna kauzalna struktura prikazana je na Slici 8.2.

a)

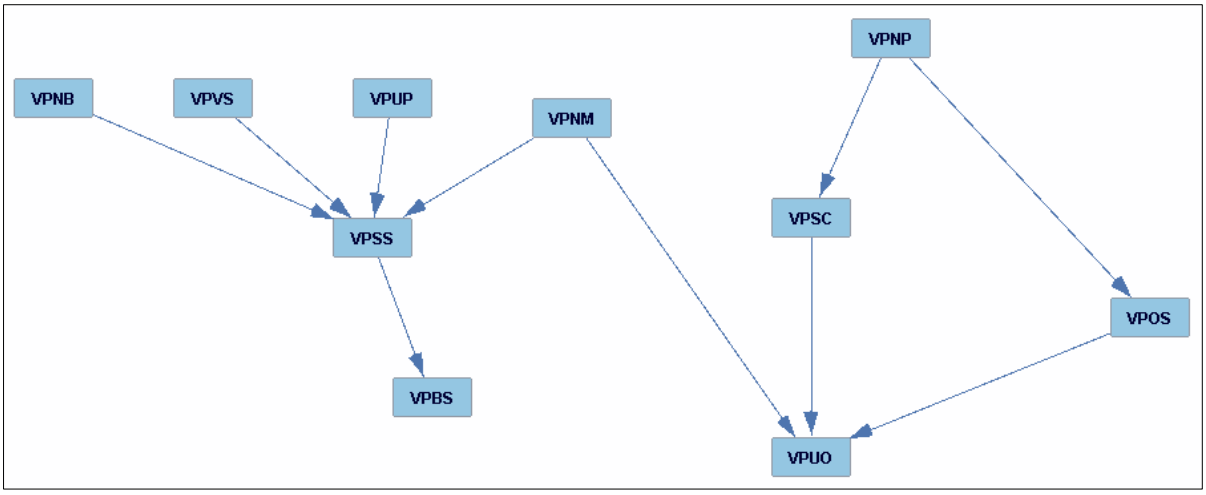

b)

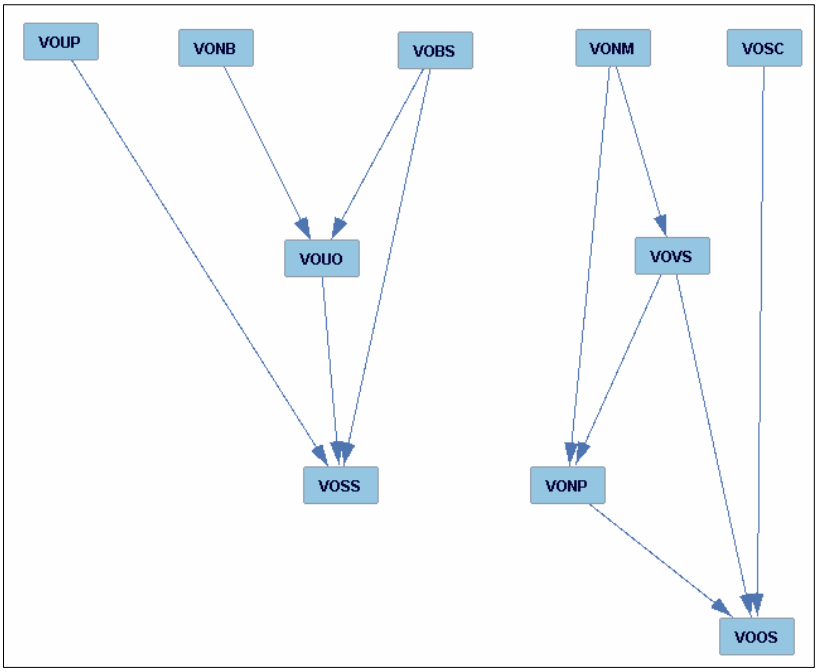

Slika 8.2. Komparativni prikaz kauzalnih struktura prognostičkih modela vrsta CPN-a (Model 3 – a) i (Model 4 - b)

Kao i u prethodna dva modela uzroka CPN-a, i u promatranim modelima vrsta CPN-a postoje određena odstupanja u njihovoj kauzalnoj strukturi. U Modelu 3 imamo ukupno 5 varijabli prve razine, i to kako slijedi: VPNB (*Nalet na bicikle*), VPVS (*Vožnja u slijedu*), VPUP (*Udar vozila u parkirano vozilo*), VPNM (*Nalet na motocikl ili moped*) i VPNP (*Nalet na pješaka*). Kod Modela 4 varijable prve razine čine *Bočni sudar* (VOBS), *Slijetanje vozila s ceste* (VOSC), *Udar vozila u parkirano vozilo* (VOUP), *Nalet na bicikle* (VONB) i *Nalet na motocikl ili moped* (VONM). Ostale kauzalne razine naznačene su u tablici 8.3.

Tablica 8.3. Prikaz kauzalnih razina prognostičkih modela vrsta CPN-a (Model 3 i Model 4)

Kauzalna razina	Model 3	Model 4
1.	VPVS, **VPUP**, **VPNB**, VPNP, **VPNM**	**VOUP**, **VONB**, VOBS, **VONM**, VOSC
2.	**VPSS**, VPSC, **VPUO**, **VPOS**	**VOUO**, VOVS, **VOSS**, VONP, **VOOS**
3.	VPBS	-
Ostali	-	-
0.	-	-

Iz priložene tablice vidljive su zajedničke vrste CPN-a na prvoj kauzalnoj razini – udar vozila u parkirano vozilo (VPUP i VOUP), nalet na bicikle (VPNB i VONB) i nalet na motocikl ili moped (VPNM i VONM). Svi navedeni glavni zajednički uzroci prema službenoj MUP-ovoj statistici ne spadaju u skupinu SUDARI VOZILA U POKRETU. U drugoj kauzalnoj razini zajedničke su varijable sljedeće: *Iz suprotnih smjerova* (VPSS i VOSS), *Udar vozila u objekt* (VPUO i VOUO) i *Ostalo* (VPOS i VOOS). Na kauzalnoj razini vrsta CPN-a *Iz suprotnih smjerova* nalazi se u skupini SUDARI VOZILA U POKRETU.

Razlike prve i druge kauzalne razine čine sve ostale varijable vrsta CPN-a, što ukazuje na veliku sličnost kauzalnih struktura dvaju promatranih modela.

8.4. Kvantitativna analiza rezultata modela vrsta prometnih nesreća

U Modelu 3 i Modelu 4 simulacijom smo također pretpostavili najmanju vrijednost 0 za varijable prve kauzalne razine, a rezultat simulacije potvrdio je smanjenje vrijednosti svih ostalih varijabli. Rezultati simulacije Modela 3 i Modela 4 prikazani su u Tablici 8.4., u stupcu Rezultat simulacije. U posljednjem stupcu prikazanih tablica rezultat simulacije pretvoren je u postotno smanjenje CPN-a za pojedine promatrane vrste.

Tablica 8.4. Komparativna kvantitativna analiza rezultata prognostičkih modela vrsta CPN-a (Model 3 – a) i (Model 4 - b)

a)

MODEL 3	Bez ograničenja na modelu			Ograničenje VPVS, VPUP, VPNB, VPNP, VPNM			Rezultat simulacije	Smanjenje (%)
	0	1	2	0	1	2		
VPSS	0,3104	0,3283	0,3613	0,3334	0,3333	0,3333	-0,051	-1,7
VPBS	0,3104	0,3283	0,3613	0,3334	0,3333	0,3333	-0,051	-1,7
VPVS	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
VPUP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
VPSC	0,3	0,3	0,4	0,6667	0,3333	0	-0,7667	-25,6
VPNB	***0,5***	***0,5***	***0***	***1***	***0***	***0***	***-0,5***	***-25,0***
VPNP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
VPNM	***0,4***	***0,6***	***0***	***1***	***0***	***0***	***-0,6***	***-30,0***
VPOS	0,3	0,3	0,4	0,6667	0,3333	0	-0,7667	-25,6
VPUO	0,2956	0,3322	0,3722	0,2592	0,4816	0,2592	-0,0766	-2,6

b)

MODEL 4	Bez ograničenja na modelu			Ograničenje VOSS, VOSC, VONB, VONP, VONM, VOOS, VOUO			Rezultat simulacije	Smanjenje (%)
	0	1	2	0	1	2		
VOSS	0,255	0,3683	0,3767	1	0	0	-1,1217	-37,4
VOBS	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
VOVS	0,3	0,3	0,4	0,6	0,2	0,2	-0,5	-16,7
VOUP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
VOSC	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***-1,1***	***-36,7***
VONB	***0,5***	***0,5***	***0***	***1***	***0***	***0***	***-0,5***	***-25,0***
VONP	0,3	0,3	0,4	0,6	0,2	0,2	-0,5	-16,7
VONM	***0,5***	***0,5***	***0***	***1***	***0***	***0***	***-0,5***	***-25,0***
VOOS	0,3367	0,3067	0,3566	0,1334	0,5333	0,3333	0,18	6,0
VOUO	0,425	0,2917	0,2833	1	0	0	-0,8583	-28,6

Najveće smanjenje kod promatranih varijabli u Modelu 3 vidljivo je u varijablama nad kojima je izvršena intervencija – *Vožnja u slijedu* (VPVS), *Udar vozila u parkirano vozilo* (VPUP) i *Nalet na pješaka* (VPNP), a koje iznose 36,7%.

Za Model 4 najveće je smanjenje također zamjetno kod varijabli prve kauzalne razine i to za *Bočni sudar* (VOBS), *Udar vozila u parkirano vozila* (VOUP) i *Slijetanje s ceste* (VOSC). Iz posljednje tablice Modela 4 vidljivo je povećanje varijable *Ostalo* (VOOS), što može biti rezultat nedovoljno definirane varijable.

8.5. Evaluacija prognostičkih modela uzroka prometnih nesreća

Evaluaciju modela radimo s pomoću Kullback–Lieblerove informacije [184]. Ta K–L informacija rezultat je razlike ukrštene entropije i entropije stvarnih uzroka CPN-a (vidi str. 145). Uzroci CPN-e mjereni su brojem registriranih CPN-a i brojem teško/lako ozlijeđenih osoba. Ukrštena je entropija neodređenost između broja rezultata simulacije bez intervencije i rezultata simulacije dobivenih intervencijom na varijablama prve kauzalne razine.

Za primjer izračuna evaluacije kao uzroka broja CPN-a analizirana je prva ulazna varijabla prognostičkoga modela, *Nepropisna brzina* pri Modelu 1 (UPNB), te na temelju podataka iz Grafikona 8.1. te formule za Kullback–Lieblerovu informaciju dobivamo sljedeći rezultat:

$$I = 0{,}5186 \cdot \log_2\left(\frac{0{,}5186}{0{,}2713}\right) + 0{,}1867 \cdot \log_2\left(\frac{0{,}1867}{0{,}3151}\right) + 0{,}2947 \cdot \log_2\left(\frac{0{,}2947}{0{,}4136}\right) = 0{,}1997$$

Najmanja vrijednost K–L informacije upućuje na veliku sličnost modela s realnom situacijom.

Tablica 8.5. Komparativni rezultati evaluacije (Model 1 – a) i (Model 2 - b)

a)

MODEL 1	Bez ograničenja na modelu			Ograničenje UPPP=0, UPGP=0			K-L informacija
	0	1	2	0	1	2	
UPNB	0,2713	0,3151	0,4136	0,5186	0,1867	0,2947	0,1997
UPBN	0,2713	0,2956	0,4331	0,5186	0,324	0,1574	0,2978
UPVN	0,3	0,2	0,5	1	0	0	1,7370
UPNS	0,2667	0,2333	0,5	0,6667	0,3333	0	1,0528
UPNU	0,3	0,4	0,3	0,3333	0,6667	0	0,5420
UPNP	0,2667	0,2806	0,4527	0,6667	0,2222	0,1111	0,5813
UPPP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
UPSZ	0,2379	0,5332	0,2289	0,5623	0,4377	0	0,5732
UPOV	0,2859	0,4039	0,3102	0,408	0,371	0,221	0,0557
UPGP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
UPOO	0,3669	0,2425	0,3906	0,507	0,3088	0,1842	0,1445

b)

MODEL 2	Bez ograničenja na modelu			Ograničenje UONB, UONP, UOPP, UOOV			K-L informacija
	0	1	2	0	1	2	
UONB	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
UOBN	0,32	0,28	0,4	1	0	0	1,6439
UOVN	0,3352	0,3142	0,3506	0,6667	0,3333	0	0,6898
UONS	0,2934	0,2733	0,4333	1	0	0	1,7691
UONU	0,1958	0,226	0,5782	1	0	0	2,3525
UONP	***0,2***	***0,4***	***0,4***	***1***	***0***	***0***	***2,3219***
UOPP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
UOSZ	0,3	0,25	0,45	1	0	0	1,7370
UOOV	***0,2852***	***0,3644***	***0,3504***	***1***	***0***	***0***	***1,8100***
UOGP	0,3	0,1958	0,5042	1	0	0	1,7370
UOOO	0,338	0,2777	0,3843	0,3333	0,6667	0	0,8356

Iz navedenih tabličnih prikaza vidljive su vrijednosti najvećih K–L informacija kod većine varijabli kod kojih smo intervenirali. To ukazuje na mogućnost manjih intervencija i manjih K–L informacija. Svi dobiveni rezultati evaluacije nalaze se u granicama prihvatljivosti modela s obzirom na to da su K–L informacije ostalih varijabli prognostičkoga modela manje od varijabli nad kojima je izvedena intervencija ili ograničenje.

Najmanje vrijednosti u modelu mjerenom prema broju registriranih CPN-a (Model 1) jesu varijable treće i više razine – *Ostale greške vozača* (UPOV), *Ostale okolnosti* (UPOO) i *Nepropisna brzina* (UPNB), što ukazuje na pouzdanost modela s obzirom na to da su predmetne varijable rezultat djelovanja viših kauzalnih razina.

Pri Modelu 2 najmanje vrijednosti K–L informacija prisutne su pri kauzalnoj razini drugoga reda, i to za varijable *Vožnja na nedopuštenoj udaljenosti* (UOVN) *i Ostale okolnosti* (UOOO).

8.6. Evaluacija prognostičkih modela vrsta prometnih nesreća

Kullback–Lieblerova informacija rezultat je razlike ukrštene entropije i entropije stvarnih vrsta CPN-a. Vrste CPN-a, ovisno o promatranim kategorijama prometnih nesreća, prikazane su u Modelima 3 i 4. Evaluacija prognostičkih modela vrsta prometnih nesreća prikazana je u tablici 8.6.

Tablica 8.6. Komparativni rezultati evaluacije (Model 3 – a) i (Model 4 - b)

a)

MODEL 3	Bez ograničenja na modelu			Ograničenje VPVS, VPUP, VPNB, VPNP, VPNM			K-L informacija
	0	1	2	0	1	2	
VPSS	0,3104	0,3283	0,3613	0,3334	0,3333	0,3333	0,0029
VPBS	0,3104	0,3283	0,3613	0,3334	0,3333	0,3333	0,0029
VPVS	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
VPUP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
VPSC	0,3	0,3	0,4	0,6667	0,3333	0	0,8187
VPNB	***0,5***	***0,5***	***0***	***1***	***0***	***0***	***1,0000***
VPNP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
VPNM	***0,4***	***0,6***	***0***	***1***	***0***	***0***	***1,3219***
VPOS	0,3	0,3	0,4	0,6667	0,3333	0	0,8187
VPUO	0,2956	0,3322	0,3722	0,2592	0,4816	0,2592	0,0736

b)

MODEL 4	Bez ograničenja na modelu			Ograničenje VOSS, VOSC, VONB, VONP, VONM, VOOS, VOUO			K-L informacija
	0	1	2	0	1	2	
VOSS	0,255	0,3683	0,3767	1	0	0	1,9714
VOBS	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
VOVS	0,3	0,3	0,4	0,6	0,2	0,2	0,2830
VOUP	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
VOSC	***0,3***	***0,3***	***0,4***	***1***	***0***	***0***	***1,7370***
VONB	***0,5***	***0,5***	***0***	***1***	***0***	***0***	***1,0000***
VONP	0,3	0,3	0,4	0,6	0,2	0,2	0,2830
VONM	***0,5***	***0,5***	***0***	***1***	***0***	***0***	***1,0000***
VOOS	0,3367	0,3067	0,3566	0,1334	0,5333	0,3333	0,2150
VOUO	0,425	0,2917	0,2833	1	0	0	1,2345

Kao i kod prethodno analiziranih modela uzroka CPN-a najveće vrijednost K–L informacija prisutne su kod varijabli nad kojima je provedena intervencija. Izuzetak je prisutan u varijabli druge kauzalne razine, *Iz suprotnog smjera* (VOSS), pri vrsti CPN-a ovisno o broju teško/lako ozlijeđenih osoba – Model 4, gdje njezina vrijednosti od 1,9714 nadilazi vrijednosti svih ulaznih varijabli promatranoga modela.

Najmanja vrijednost K–L informacije ili najmanja razlika razdioba prije i poslije intervencije zabilježene su u Modelu 3, pri varijablama *Iz suprotnog smjera* (VPSS), *Bočni sudar* (VPBS) i *Udar vozila u objekt* (VPUO).

U slučaju Modela 4 najmanje su vrijednosti K–L informacije prisutne kod vrsta prometnih nesreća *Vožnja u slijedu* (VOVS), *Nalet na pješaka* (VONP) i *Ostalo* (VOOS).

Najmanja razlika razdioba prije intervencije i poslije nje za pojedinu varijablu mjerenja znači da predloženi model odgovara stvarnomu stanju ili stvarnim vrijednostima varijabli mjerenja.

8.7. Zaključna razmatranja

Za potrebe izrade prognostičkih modela CPN-a na raspolaganju su mnogobrojne metode i algoritmi analize podataka u svrhu istraživanja međuodnosa različitih kategorija CPN-a s vozačkim i okolišnim čimbenicima, evidentiranima u službenim zbirnim registrima o prometnim nesrećama.

U ovome doktorskom radu koristili smo različite algoritme (kauzalne modele) kako bi se poboljšala točnost pojedinih individualnih čimbenika (nezavisnih varijabli) za dvije izlazne kategorije cestovnih prometnih nesreća.

Iz predloženih modela vidljivo je da su čimbenici – varijable modela međusobno uzročno-posljedično povezani. Navedena uzročno-posljedična povezanost razlikuje se ovisno o pojedinom prognostičkom modelu. Čimbenici modela mjereni su prema ukupnomu broju registriranih CPN-a (Modela 1 i 3) te prema broju teško/lako ozlijeđenih osoba (Model 2. i 4.). Također, u modelima su obuhvaćene i dvije skupe čimbenika. Jedno su čimbenici uzroci CPN-a (Model 1 i 2), a drugo su vrste CPN-a (Model 3 i 4). Na temelju uzročno-posljedične povezanosti čimbenika određene su razine utjecaja. U prvu kauzalnu razinu razvrstani su najznačajniji čimbenici na koje je potrebno prioritetno djelovati. Djelovanjem ili intervencijom na te čimbenike dolazi do smanjenja kako broja CPN-a tako i broja ozlijeđenih koji su povezani s ostalim čimbenicima promatranima u modelu.

Primjenom navedenih modela moguće je intervenirati i na ostale čimbenike i promatrati njihov utjecaj na broj CPN-a te broj ozlijeđenih. Prednost navedenih modela leži u njihovoj realnoj primjeni uz aktualno praćenje rizičnih situaciju na cestovnoj mreži gradskih prometnica.

Iznesenim rezultatima i komentarima predloženih kauzalnih modela znatno se može pomoći mjerodavnim ustanovama zaduženima za povećanje sigurnosti prometnoga sustava kako bi njihove planirane restriktivne i preventivne mjere bile što efikasnije te polučile značajne pozitivne rezultate.

9. ZAKLJUČAK

Svrha znanstvenoga istraživanja doktorskog rada *Prognostički modeli cestovnih prometnih nesreća za urbana područja* bila je osigurati upravljanje prometnom sigurnošću kroz implementaciju vjerodostojnoga prognostičkog modela CPN-a za urbana područja. Prepoznajući važnost statističkih metoda za povezivanje, klasifikaciju te predviđanje stopa kretanja CPN-a, kao i činjenicu da takva istraživanja nisu provedena na prostoru nacionalnoga cestovnog prometnog sustava, temeljni cilj predloženoga znanstvenog istraživanja jest analiza postojećih modela predviđanja CPN-a te detektiranje i klasifikacija najznačajnijih čimbenika sigurnosti CPN-a urbanoga okruženja. Sekundarni je cilj ukazati na prednosti i značaj razvijanja i upotrebe modela predikcije CPN-a kao jednoga suvremenog alata za unaprjeđenje sigurnosti prometa.

Posljednjih godina kroz različite istraživačke i znanstvene programe naša su se znanja i razumijevanje u području sigurnosti cestovnoga prometa multiplicirala. Slijedom toga, danas znamo daleko više o veličini, razvoju i pozadini problema vezanih uz sigurnost cestovnoga prometa nego u posljednjih četrdesetak godina.

Znanstveno je istraživanje stoga provedeno kroz tri sukcesivna dijela. U prvom dijelu istraživanja analizirane su međunarodne službene statističke baze podataka o CPN-u, pri čemu su njihovu važnost prvenstveno prepoznali znanstvenici, stručnjaci, nevladine i druge organizacije, institucije, države i mnogi drugi subjekti. Naznačen je sadržaj baze podataka i analiza dosadašnje razine razvijenosti službenoga IS-a obrade podataka o CPN-u u RH, prikazana je komparativna analiza metodologije prikupljanja i obrađivanja podataka o CPN-u koje provode domaći i inozemni službeni pružatelji informacija te su opisane aktualne kooperativne radnje na razini zemalja Europske unije, koje se provode u svrhu unapređenja metoda prikupljanja kvantitativnih podataka o prometnim nesrećama (povećanje broja statističkih informacija o CPN-u). Uvođenjem konzistentnih podataka o CPN-u unutar statističkih metoda spomenutih statističkih razdioba i modela dobivaju se rezultati koji bi trebali pružati stručnu podlogu mjerodavnim stručnim skupinama, nadležnim gradskim upravnim tijelima te predstavnicima Ministarstva unutarnjih poslova, kako bi unutar postojeće gradske prometne politike mogli provoditi ciljane mjere i akcije u svrhu sankcioniranja neprimjerenoga ponašanja vozača motornih vozila te detekcije određenih nedostataka na rizičnim lokacijama, tj. crnim točkama cestovne prometne mreže.

Kroz predmetnu analizu akcentirana su osnovna ograničenja i nedostatci aktualne nacionalne baze podataka o CPN-u u RH, a koji se mogu promatrati u kontekstu prikupljanja i evidentiranja određenih statističkih podataka. Uz navedeno, naznačen je prijedlog mjera za njezin daljnji razvoj,

kao i značaj koji novopredložena integrirana baza podataka (o obilježjima sigurnosti prometa i CPN-a) može imati u smislu unaprjeđenja sigurnosti prometa u urbanim sredinama.

U drugom dijelu istraživanja za potrebe izrade prognostičkoga modela podrobnije su analizirani svi podatci o registriranim CPN-ima koje su dostupnima učinili nacionalni pružatelji informacija kako bi se identificirali i kvantificirali ključni čimbenici CPN-a. Analizirani su glavni čimbenici koji neposredno utječu na sigurnost i mobilnost cestovnoga prometnog sustava, a to se provelo kroz izučavanje *sistemske teorije*, bazirane na trima komponentama (čovjek – cesta – vozilo), relativnih čimbenika sigurnosti cestovnoga prometnog sustava s posebnim naglaskom na analizu CPN-a u urbanim i ruralnim područjima te kroz analizu kvantitativnih socioekonomskih i prometnih pokazatelja. Tim je pristupom u konačnici dobivena realna statistička podloga uniformirane strukture iz koje smo u mogućnosti adekvatno iščitati stanje, trendove i korelacije u kretanju sigurnosnih pokazatelja cestovnoga prometnog sustava. Područje obuhvata istraživanja za određivanje ulaznih parametara bio je prostor Grada Zagreba i Zagrebačke županije, gdje su se za potrebe istraživanja i izrade prognostičkoga modela CPN-a koristili podatci iz službenih godišnjih policijskih statističkih izvještaja, odnosno *Biltena o sigurnosti cestovnog prometa u Republici Hrvatskoj* te podatci o CPN-u koji su pribavljeni kroz UPN (*Upitnik o prometnoj nesreći*), koji je pod ingerencijom Ministarstva unutarnjih poslova, Policijske uprave zagrebačke.

U posljednjem dijelu analizirana su najrecentnija relevantna istraživanja i teoretske pretpostavke na području izrade znanstveno-stručnih analiza i statističkih prognostičkih modela koji služe za izučavanje čimbenika CPN-a. Za potrebe izrade prognostičkoga modela CPN-a prvotno je uspostavljena kauzalna (uzročno-posljedična) veza između različitih kategorija CPN-a te utjecajnih čimbenika. Predstavljanjem i kalibracijom kauzalnoga modela ostvarila se mogućnost kvalitetnoga kategoriziranja i rangiranja utjecajnih čimbenika, uz prethodno kvantificiranje jačine (povezanosti) njihove međusobne korelacije.

Problemi sigurnosti cestovnoga prometa, odnosno CPN-a predstavljaju složeni i višedimenzionalni problem koji je moguće i potrebno sagledati kroz različita područja djelovanja, kako bi se zatim ciljanim mjerama negativne posljedice mogle kontrolirati i umanjiti. Modeli predviđanja CPN-a predstavljaju jedan od najučinkovitijih pristupa u prevenciji posljedica CPN-a. Osnova razvoja tih modela zasniva se na velikoj količini podataka prikupljenih o različitim varijablama i vrijednostima. S obzirom na to da se mnogi podatci trenutno ne obrađuju, potrebno je žurno razviti sustav njihova prikupljanja.

U ovom znanstvenom radu teorijski su opisani, a zatim i izrađeni i evaluirani kauzalni prognostički modeli CPN-a za urbana područja, koji su u stanju detektirati i rangirati najznačajnije čimbenike sigurnosti prometnih nesreća urbanoga okruženja, njihovu međuovisnost i utjecaj na posljedice koje uzrokuju. Navedeni prognostički modeli izvedeni su komparacijom više alternativnih

podatkovnih postavki (varijabli mjerenja) koje su temeljene kako na statističkim podlogama tako i na načelima održivoga razvoja prometa (socioekonomski te prostorni uvjeti).

Prethodno izvedenom dubinskom analizom povijesnih podataka o sigurnosti cestovnoga prometa u Gradu Zagrebu utvrđeno je kako je stanovništvo u kontinuiranom porastu, po prosječnoj godišnjoj stopi od 0,18%. Istovremeno, broj prometnih nesreća u Gradu Zagrebu smanjuje se po prosječnoj godišnjoj stopi od –9,96%, a broj poginulih osoba pokazuje tendenciju smanjenja od –6,86%.

Broj teško/lako ozlijeđenih osoba posljednjih se godina smanjuje po prosječnoj godišnjoj stopi od –1,93%. Odnos broja smrtno stradalih i ozlijeđenih osoba (lako/teško) u gradu iznosi 1 : 50 ili 2%.

Analizirajući strukturu CPN-a u odnosu na njihove osnovne kategorije, možemo konstatirati njihov spor ali kontinuirani pad, sa sljedećim odnosima: 78,16% CPN-a s materijalnom štetom, 21,30% CPN-a s ozlijeđenim te 0,54% CPN-a s poginulim osobama.

Starosna struktura ozlijeđenih i poginulih osoba na područja Grada Zagreba ukazuje na jednaku razdiobu, uz naglasak da su pripadnici srednje životne dobi najugroženiji s obzirom na broj ozlijeđenih osoba u prometu, a osobe starije životne dobi s obzirom na broj poginulih sudionika u prometu.

Nažalost, dostupna dokumentacijska podloga, u smislu referentnih prometnih podataka o prometnom sustavu Grada Zagreba, koja nam omogućava uvid u karakteristike prometnoga toka (brzina i opterećenje mješovitoga prometnog toka, brzina toka vozila javnoga gradskog prijevoza i sl.) kao i karakteristike njegovih sudionika (brzina putovanja, način putovanja, struktura putovanja po tipu, vremenska razdioba putovanja tijekom dana i sl.), također nije mogla biti korištena kao ulazni podatci prilikom izrade prognostičkih modela, s obzirom na to da oni više nisu aktualni. Naime, posljednja su cjelovita temeljna prometna istraživanja u gradu objavljena prije 13 godina (1998. godine), u okviru izrade *Prometne studije grada Zagreba*.

Kvalitetni podatci o trendovima i obilježjima CPN-a nužan su preduvjet za uspješno planiranje preventivnih mjera i aktivnosti te donošenje odluka o potrebnim investicijama. U skladu s time, mnoge razvijene zemlje EU-a i SAD-a imaju razrađen sustav kontinuiranoga prikupljanja takvih podataka na nacionalnoj razini, koji se sustavno upotpunjava novim spoznajama temeljenima na provedenim istraživanjima.

Iako je u Hrvatskoj IS MUP-a, zadužen za prikupljanje i obradu takvih podataka, zbog ulaska u EU već doživio nekoliko nadogradnja posljednjih godina, čime se prvenstveno pokušava doseći

istovjetna metodologija, on još uvijek nije dosegao adekvatnu razinu zemalja članica EU-a koje prednjače u tome, te mu je nužna daljnja modernizacija i informatizacija, koja iziskuje razmjerno mnogo financijskih sredstava te složenu provedbu. Međutim, mnogo veće štete nastaju ako se investicijske odluke donose bez adekvatnih podataka, analiza i prognoza obujma CPN-a, što nije rijedak slučaj u hrvatskim gradovima te gradovima u okruženju.

Nedostatak relevantnih izvora zaduženih za prikupljanje, obradu i distribuciju podataka i informacija o CPN-u predstavlja značajan problem s obzirom na to da navedeni podatci predstavljaju ulazne informacije, a ako nisu konzistentni, bitno utječu na proces modeliranja te preciznost rezultata koje će u budućnosti proizvesti. To je pitanje posebno osjetljivo u manje razvijenim zemljama, kao što je Republika Hrvatska, koje nemaju dovoljno razvijenu osnovnu statističku bazu podataka, a još su manje raspoloživi specifični podatci koji se koriste u tom segmentu prometnoga planiranja. Uz navedeno, određene su se analize temeljile na raspoloživim podatcima iz IS-a MUP-a RH, odnosno na drugim državnim bazama podataka (Državnoga zavoda za statistiku), tako da kvaliteta i dostupnost podataka umnogome određuju i kvalitetu rezultata istraživanja i izrade predloženih prognostičkih modela CPN-a. No unatoč navedenomu, važno je napomenuti da nacionalni registar prometnih nesreća koji vodi Ministarstvo unutarnjih poslova predstavlja jedan od najboljih izvorišta informacija o CPN-u u Republici Hrvatskoj, a koji bitno može pomoći prometnim stručnjacima u njihovim daljnjim istraživanjima.

Također, kako bismo se približili aktualnim europskim dosezima i ciljevima u sigurnosti prometa te time bili usporedivi na međunarodnoj razini, nužno je nastaviti s provedbom kontinuiranoga unapređenja Informacijskoga sustava MUP-a, odnosno metoda i načina prikupljanja kvantitativnih podataka o prometnim nesrećama (povećanje broja statističkih informacija o CPN-u), a posebno je važno omogućiti pristup ciljanim korisnicima (razmjena datoteka uporabom standardiziranih obrazaca, tj. informacija). Unapređenjem Informacijskoga sustava i širenjem baze podataka istraživačima se prilikom obrade prikupljenih informacija o prometnim nesrećama pružaju nove mogućnosti u pogledu metodologije prikupljanja podataka. Ta je činjenica rezultirala mogućnošću dovođenja u vezu različitih varijabli prilikom modeliranja, kao što su izučavanje korelacije prometne infrastrukture, ekonomske, socioekonomske te prostorne varijable.

U izrađenim kauzalno-prognostičkim modelima obuhvaćeni su uzroci i vrste kroz ukupno četiri modela. Prva dva modela odnose se na uzroke mjerene brojem nesreća i uzroke mjerene brojem povrijeđenih. U druga dva modela određena je kauzalna struktura vrsta mjerena brojem nesreća i vrsta mjerenja brojem ozlijeđenih.

Prognostički modeli vrsta i uzroka CPN-a ovisno o broju poginulih osoba u fazi istraživanja također su bili obrađeni, ali s obzirom na njihove male vrijednosti te kratke vremenske nizove, dobiveni rezultati nisu bili pouzdani za analizu i prognoziranje. Tomu u prilog ide i podatak da je broj poginulih osoba manji od 2% od ukupnoga broja nastradalih osoba u prometnim nesrećama u Gradu Zagrebu.

Jedan od kriterija ulaznih parametara prognostičkih modela CPN-a za urbana područja bio je i odabir onih varijabla na koje predstavnici lokalne uprave mogu u najvećoj mjeri intervenirati. Od ukupnoga broja od 26 raspoloživih varijabli mjerenja uzroka prometnih nesreća, u Modelima 1 i 2 promatrano je 11 najznačajnijih uzroka, a od ukupnoga broja od 15 raspoloživih varijabli mjerenja vrsta prometnih nesreća u Model 3 i Model 4 uvršteno je njih 10 najznačajnijih.

Sve varijable mjerenja promatrane su u vremenskom periodu od 1. siječnja 2004. do 31. prosinca 2013. godine.

Svaki predloženi model spada u skupini Bayesovih kauzalnih modela i zato drugi korak njihova modeliranja predstavlja digitalizaciju varijabli mjerenja. Svaka varijabla mjerenja poprimila je vrijednosti 0, 1 ili 2.

Za određivanje kauzalne strukture korišten je *JPC* i *LiNGAM* algoritam, uz računalnu podršku softverskoga paketa *Tetrad*. Dobivena kauzalna struktura parametrizirana je u skladu s prethodno određenom digitalizacijom varijabli mjerenja. U idućem koraku određene su vjerojatnosti prijelaza u skladu s digitalizacijom i parametrizacijom modela. Funkcijske veze između varijabli određene su strukturom i vjerojatnostima prijelaza. Na temelju vjerojatnosti prijelaza izračunate su marginalne vjerojatnosti za pojedine varijable mjerenja. Tim modelskim pristupom dokazali smo hipotezu o kauzalnoj strukturi varijabli mjerenja koje određuju uzroke i vrste prometnih nesreća.

Pretpostavka većine dosadašnjih prognostičkih modela CPN-a bila je nezavisnost između pojedinih uzroka i posljedica prometnih nesreća. Kauzalni modeli prikazuju kauzalne međuzavisnosti i mogu intervencijama na pojedinim varijablama mjerenja izračunavati promjene na ostalim varijablama mjerenja. U našem slučaju, za svaki od razrađenih modela izvedene su intervencije na varijablama koje su primarni uzroci za sve ostale varijable (kauzalna razina 1).

Predloženi modeli potvrdili su radne pretpostavke (hipoteze) o tome kako intervencijom na određene varijable mjerenja ili smanjenjem njihovih digitaliziranih vrijednosti dolazi do smanjenja svih ostalih varijabli mjerenja. Također, kroz navedeni je modelski pristup omogućeno strukturiranje i rangiranje svih relevantnih varijabli mjerenja (uzorka i vrsta CPN-a) prema broju nesreća te broju ozlijeđenih osoba. Na temelju analize i strukturiranja njihovih izvedenih

kauzalnih mreža u mogućnosti smo simulirati rezultate preventivnih mjera i aktivnosti na smanjenju broja i oblika prometnih nesreća u budućnosti.

Modeliranjem i simulacijom u mogućnosti smo odrediti najmanji broj varijabli na koje je potrebno intervenirati. To predstavnicima jedinica lokalne i regionalne uprave i samouprave omogućava kvalitetnije planiranje i raspodjelu novčanih sredstava potrebnih za reguliranje i upravljanje prometnim sustavom. Daljnjim intervencijama na željene kritične varijable dolazi do promjene kauzalne strukture samoga modela i boljih rezultata, ali uz veći opseg poslova i financijsku potrošnju.

U modelu uzroka mjerenim brojem nesreća (Model 1) prva kauzalna razina ili varijable nad kojima je provedena intervencija jesu:

1. *Nepoštivanje prednosti prolaza* (Varijabla UPPP)
2. *Greške pješaka* (Varijabla UPGP).

U modelu uzroka mjerenim brojem ozlijeđenih (Model 2) prva kauzalna razina ili glavni kauzalni uzroci jesu:

1. *Nepoštivanje prednosti prolaza* (Varijabla UOPP)
2. *Nepropisna brzina* (Varijabla UONB)
3. *Nepropisno prestrojavanje* (Varijabla UONP)
4. *Ostale greške vozača* (Varijabla UOOV)

U oba modela uzroka mjerenim brojem nesreća i ozlijeđenih ističe se varijabla *Nepoštivanje prednosti prolaza*. Uz spomenuti zajednički kauzalni uzrok javljaju se preostale relevantne varijable. Za Model 1 to je *Greška pješaka*, a za Model 2 *Nepropisna brzina* i *Nepropisno prestrojavanje*.

U Modelu 1 simulirano je smanjenje varijable prve kauzalne razine za –36,7%. Rezultat navedenoga bilo je smanjenje svih ostalih varijabli modela u rasponu od –7% do –40%. To znači da intervencijom na varijable *Nepoštivanje prednosti prolaska* i *Greške pješaka* ili provođenjem preventivnih mjera za sprječavanje tih uzroka možemo na ekonomičan način utjecati na sve ostale relevantne uzroke nastanka prometnih nesreća.

U Modelu 2 simulirano je smanjenje četiriju varijabli prve kauzalne razine – *Nepoštivanje prednosti prolaza* (UOPP) za –36,7%, *Nepropisna brzina* (UONB) za –36,7%, *Nepropisno prestrojavanje* (UONP) za –40% te *Ostale greške vozača* (UOOV) za –35,5%. Rezultat simulacije također je bilo smanjenje vrijednosti svih ostalih ulaznih parametara u rasponu od –12,7% do –

40,1%. U slučaju uzroka mjerenih brojem ozlijeđenih osoba potrebno je intervenirati na većem broju varijabli mjerenja, unutar kojega je, za razliku od prethodnoga modela, ušla nepropisna brzina i greške vozača.

U modelu vrsta mjerenih brojem nesreća (Model 3) prvu kauzalnu razinu predstavljaju sljedeće varijable s prikazanim smanjenjem nakon intervencije:

1. *Nalet na bicikle* (Varijabla VPNB) –25%
2. *Vožnja u slijedu* (Varijabla VPVS) –36,7%
3. *Udar vozila u parkirano vozilo* (Varijabla VPUP) –36,7%
4. *Nalet na motocikl ili moped* (Varijabla VPNM) –30%
5. *Nalet na pješaka* (Varijabla VPNP) –36,7%

U Modelu 4 intervencija je provedena nad sljedećim varijablama s prikazanim smanjenjem nakon intervencije:

1. *Bočni sudar* (Varijabla VOBS) –36,7%
2. *Udar vozila u parkirano vozilo* (Varijabla VOUP) –36,7%
3. *Slijetanje vozila s ceste* (Varijabla VOSC) –36,7%
4. *Nalet na bicikle* (Varijabla VONB) –25%
5. *Nalet na motocikl ili moped* (Varijabla VONM) –25%

Zajedničke varijable prve kauzalne razine u Modelu 3 i Modelu 4 jesu *Nalet na bicikl*, *Nalet na motocikl ili moped* te *Udar vozila u parkirano vozilo*.

Rezultat intervencije u Modelu 3 jesu smanjenja preostalih varijabli od –1,7% do –25,6%, dok se taj raspon u Modelu 4 kreće od– 16,7% do –37,4%.

Sva četiri modela vrednovani su Kullback–Lieblerovom informacijom, koja prikazuje razliku između razdioba prije intervencije i poslije nje. Rezultati evaluacije modela pokazali su kvalitetno strukturirane kauzalne prognostičke modele CPN-a za urbana područja, čime je dokazana njihova funkcionalnost i održivost. S obzirom na detektirana ograničenja u fazi njihove razrade i modeliranja, u nastavku su naznačena **ključna područja djelovanja te smjernice za daljnja istraživanja**:

- proširenje (dopuna) modela novim ulaznim parametrima s obzirom na to da većinu traženih statističkih podataka nije bilo moguće pribaviti od predstavnika MUP-a, što svakako utječe na njegovu parametrizaciju te kasniju prezentaciju rezultata. Neki su od prijedloga podatci o prometnim nesrećama prema kategorijama cesta, po značajkama

ceste, prema meteorološkim uvjetima i stanju kolnika, prema uvjetima vidljivosti, prema stanju kolničke konstrukcije, prema vrsti vozila, te uključivanje podataka o psihofizičkom stanju sudionika u prometu u trenutku nastanka prometne nesreća (konzumacija alkohola, umor i sl.).

- dodatna sredstva potrebno je investirati u razvoj postojećega informacijskog sustava prikupljanja i obrade podataka o CPN-u kako bi se takve službene baze podataka mogle što bolje iskoristiti i pružiti adekvatnu savjetodavnu funkciju donositeljima odluka (povećanje broja ulaznih parametara, standardizacija varijabli na temelju CADaS smjernica)
- povećanje broja mjerodavnih institucija zaduženih za prikupljanje i obradu podataka o CPN-u te formiranje unificirane nacionalne te posebice lokalnih i regionalnih baza podataka svih obilježja sigurnosti cestovnoga prometa (obuhvaćaju sve relevantne podatke vezane za prometni sustav, čimbenike sigurnosti, obilježja i posljedice CPN-a), a koje bi služile kao platforma za njihovu kontrolu i prevenciju
- provedba temeljitih statističkih analiza podataka nakon finaliziranja prognostičkih modela CPN-a za urbana područja, a koje će biti podvrgnute kontroli kvalitete kroz buduće recenzije
- izrada nacionalne strategije sigurnosti cestovnoga prometa u Republici Hrvatskoj (nakon njezine izrade potrebno je pristupiti izradi bliskih strateških dokumenata za glavne gradove RH)
- analizom učinka predloženih prognostičkih modela CPN-a razmotriti mogućnost prenosivosti primjera dobre prakse u ostale urbane sredine (uz određene prethodne kalibracije modela).

Razni statistički modeli koji se danas koriste pri procjeni stopa CPN-a važni su za percepciju sigurnosti cestovnoga prometa jer su prvi indikatori postojanja problema. Ako krivulja procjene nije u skladu s krivuljom stvarnoga broja poginulih osoba, to znači da određeni čimbenici direktno utječu na odvijanje prometa i uzrokovanje cestovnih prometnih nesreća, pri čemu ih je tada nužno što ranije identificirati i otkloniti.

Predloženi prognostički modeli kretanja stopa CPN-a, izvedeni u sklopu ovoga znanstvenog istraživanja, značajno mogu doprinijeti planiranju budućih aktivnosti i akcija, s obzirom na to da su usmjereni na ciljana kritična područja cestovnoga prometnog sustava te služe kao svojevrsna potpora ostalim komponentama usvojenih nacionalnih strategija sigurnosti cestovnoga prometa.

Znanstveni doprinos doktorskog rada sadržan je u strukturiranju i vrednovanju relevantnih korelacijskih čimbenika CPN-a za urbana područja, izradi prognostičkih modela CPN-a za urbana

područja, vrednovanju, odnosno evaluaciji predloženih prognostičkih modela kroz obradu statističkih podataka na području Grada Zagreba te mogućnosti njihove primjene na ostalim urbanim područjima u RH i svijetu.

Aplikativni doprinos primjene rada mjerljiv je:

- izradom prognostičkoga modela u inženjerskoj će se praksi omogućiti preciznija i kvalitetnija prognoza kretanja stopa CPN-a,
- primjenom modela na lokalnoj razini urbanih prostora stvorit će se uvjeti za upravljanje sigurnošću u cestovnom prometu, na način da će rezultati omogućiti definiranje mjera i aktivnosti za povećanje sigurnosti cestovnoga prometa,
- kroz učinkovitu validaciju i obradu statističkih podataka o CPN-u, u okruženjima gdje su prisutni oskudni pružatelji informacija o njima,
- prilikom izvođenja potrebnih periodičkih prometno-sigurnosnih analiza,
- u svrhu predviđanja stopa i trendova kretanja čimbenika CPN-a na koje je potrebno preventivno djelovati,
- omogućuje donositeljima odluka na lokalnoj, regionalnoj i nacionalnoj razini kvalitetnije planiranje i raspodjelu proračunskih sredstava namijenjenih za reguliranje i upravljanje prometnim sustavom, na temelju provedbe ciljanih preventivnih mjera i aktivnosti,
- na temelju dobivenih rezultata istraživanja moguća je daljnja razrada metodoloških smjernica za njihovu širu primjenu,
- u kreiranju jedinstvenoga sustava praćenja i analiziranja podataka o sigurnosti cestovnoga prometa na lokalnoj, urbanoj razini u Republici Hrvatskoj,
- kroz potporu postojećim procesima i praktičnim znanjima u području sigurnosti prometa,
- kroz njihovu neovisnost o ključnim subjektima i organizacijama u prometu, ako bi se dobiveni podatci za urbana područja koristili za kreiranje gradskih prometnih politika i ocjenu sigurnosnoga sustava na nepristran način.

LITERATURA

[1] Official Journal of the European Union; Council Decision 93/704/EC on the creation of a Community database on road accidents. 1993.

[2] Državni zavod za statistiku; Pojmovnik za statistiku prometa, IV. izdanje. 2011.

[3] World Health Organization; Global status report on road safety. Injury prevention. 2013.

[4] Kopits E, Cropper M.; Traffic fatalities and economic growth. Accid Anal Prev. 2005;37(1):169–78.

[5] Jacobs GD, Sayer I.; Road accidents in developing countries. Accid Anal Prev. 1983;15(5):337–53.

[6] Vasconcellos EA.; Reassessing traffic accidents in developing countries. Transp Policy. 1995;2(4):263–9.

[7] Transport for Health: The Global Burden of Disease from Motorized Road Transport. 2015.

[8] Fletcher J.; Urban Road Safety: A Sourcebook for Policy-makers in Developing Cities. GTZ, Germany; 2010.

[9] Jost G, Richard A, Steriu M.; A Challenging Start towards the EU 2020 Road Safety Target – 6th Road Safety PIN Report. European Transport Safety Council, Brussels; 2012.

[10] Nantulya V, Reich M.; The neglected epidemic: road traffic injuries in developing countries. BMJ Br Med J. 2002;324(7346):1139–41.

[11] Sobngwi-Tambekou J, Bhatti J, Kounga G, Salmi LR, Lagarde E.; Road traffic crashes on the Yaoundé-Douala road section, Cameroon. Accid Anal Prev. 2010;42(2):422–6.

[12] Rui S, Jianming X, Xudong X, Zuo Z.; Education influence in traffic safety: A case study in Vietnam. IATSS Res. 2011;34(2):87–93.

[13] Peden M.; World report on child injury prevention says road crashes are a leading cause of child deaths. Accid Anal Prev. 2009;41(2):357.

[14] Make roads safe: A new priority for sustainable development. London: Commission for Global Road Safety; 2007.

[15] Jacobs G, Aeron-Thomas A, Astrop A.; Estimating global road fatalities. Crowthorne, England: Transport Research Laboratory, TRL Report 445; 2000.

[16] "Towards fair and efficient pricing in transport - policy options for internalising the

external costs of transport in the European Union", Green Paper. COM (95) 691. Brussels, Belgium: Commission: European Commission; 1995.

[17] Doder N.; Predavanje na Fakultetu prometnih znanosti, Zagreb.

[18] Korzhenevych A, Dehnen N, Bröcker J, Holtkamp M, Meier H, Gibson G, et al.; Update of the Handbook on External Costs of Transport. Final Report. 2014.

[19] Brčić D, Slavulj M, Čosić M.; Estimation of externalities of road accidents in local community. In: Road safety in local community / Lipovac, Krsto (ur) - Beograd : Kriminalističko-policijska akademija (ISBN: 978-86-7020-249-8). Srbija, Valjevo; 2013. p. 9–14.

[20] Ameen JRM, Naji JA.; Causal models for road accident fatalities in Yemen. Accid Anal Prev. 2001;33(4):547–61.

[21] Scuffham P a., Langley JD.; A model of traffic crashes in New Zealand. Accid Anal Prev. 2002;34(5):673–87.

[22] Zelenika R.; Metodologija i tehnologija izrade znanstvenog i stručnog djela. Rijeka: Ekonomski fakultet Sveučilišta u Rijeci; 2000.

[23] StaSoft Inc.; StatSoft. Statistica Data analysis software system,version 8. 2013.

[24] Nevistić A.; Prijevoz tereta u urbanim sredinama, Fakultet prometnih znanosti, Seminarski rad, 2014.

[25] Gitelman V, Balasha D, Carmel R, Hendel L, Pesahov F.; Characterization of pedestrian accidents and an examination of infrastructure measures to improve pedestrian safety in Israel. Accid Anal Prev. 2012;44(1):63–73.

[26] Miranda-Moreno LF, Morency P, El-Geneidy AM.; The link between built environment, pedestrian activity and pedestrian-vehicle collision occurrence at signalized intersections. Accid Anal Prev. 2011;43(5):1624–34.

[27] Movahed S, Azad SP, Zakeri H.; A Safe Pedestrian Walkway; Creation a Safe Public Space Based on Pedestrian Safety. Procedia - Soc Behav Sci. 2012;35:572–85.

[28] Brčić D.; Organisational Model of the Traffic Road Safety in the Republic of Croatia. In: IX International Conference Road Safety in Local Community. Zaječar, Republika Srbija: Road Safety in LOcal Community / Lipovac, Krsto ; Nešić, Miladin (ur.). - Zaječar : Academy of Cirminalistic and Police Studies; 2014. p. 33–40.

[29] Haddon W.; Advances in the epidemiology of injuries as a basis for public policy. Public Health Rep. 1980;95(5):411–21.

[30] SUPREME: Best practices in road safety. Handbook for measures at the country level. 2007.

[31] Loo BPY, Wong SC, Hung WT, Lo HK.; A Review of the Road Safety Strategy in Hong Kong. J Adv Transp. 2005;41(1):3–37.

[32] Archer J, Vogle K.; The Traffic Safety Problem in Urban Areas. 2000.

[33] Loo BPY, Hung WT, Lo HK, Wong SC.; Road Safety Strategies: A Comparative Framework and Case Studies. Transp Rev. 2005;25(5):613–39.

[34] Australian Transport Council (ATC): National Road Safety Strategy: 2011-2020. Canberra, Australia; 2011.

[35] United nationals General Assembly: Resolution 64/255 - Improving global road safety. 2010.

[36] Elvik R.; Quantified Road Safety Targets : An Assessment of Evaluation Methodology. Oslo; 2001.

[37] OECD; Safety on Roads: What's the Vision? Paris; 2008.

[38] OECD; Towards Zero. Ambitious Road Safety Targets and the Safe System Approach. Paris; 2008.

[39] Tingvall C, Stigson H, Eriksson L, Johansson R, Krafft M, Lie A.; The properties of Safety Performance Indicators in target setting, projections and safety design of the road transport system. Accid Anal Prev. 2010;42(2):372–6.

[40] Becky PYL, Hung WT, Lo HK, Wong SC.; Review of overseas practices on the formulation of road safety strategy and the effectiveness and the applicability in Hong Kong. Transp Rev. 2005;25:613–39.

[41] Commission E.; Towards a European road safety area: policy orientations on road safety 2011-2020. Framework. 2010;1–15.

[42] European Commission; White Paper - European Transport Policy for 2010: Time to decide - COM(2001). 2001.

[43] Commission of the European Communities; Communication from the Commission - European road safety action programme - Halving the number of road accident victims in the European Union by 2010: a shared responsibility. Vol. 0311 final. 2003.

[44] World Health Organization; Strengthening road safety legislation: a practice and resource manual for countries. 2013.

[45] Official Journal of the European Union; EU recommendation 2004/345/EC – enforcement:

road safety. 2004.

[46] Official Journal of the European Union; EU directive 2008/96/EC of the European Parliament and of the Council. 2008.

[47] Rumar K.; Past, present and future road safety work in ECMT. CEMT/CM (2002)14, ECMT, OECD, Paris. 2002;

[48] Council of Ministers of Transport B. ECMT Key recommendations for road safety.

[49] World Health Organization; European status report on road safety : towards safer roads and healthier transport choices. Copenhagen : WHO Regional Office for Europe; 2009. 161 p.

[50] Peden M, Scurfield R, Sleet D.; World Report on Road Traffic Injury Prevention. Geneva: World Health Organization, Nonserial Publication; 2004.

[51] Hrvatske Vlada; Nacionalni program sigurnosti cestovnog prometa Republike Hrvatske 1994. – 1996. Zagreb, Republika Hrvatska; 1994.

[52] Hrvatske Vlada. Nacionalni program sigurnosti cestovnog prometa Republike Hrvatske 1996. – 2000. Zagreb, Republika Hrvatska; 1997.

[53] Nacionalni program sigurnosti cestovnog prometa Republike Hrvatske 2001. – 2005. Zagreb, NN 30/2001., Republika Hrvatska; 2001.

[54] Nacionalni program sigurnosti cestovnog prometa Republike Hrvatske 2006. – 2010. Zagreb, NN 24/2006., Republika Hrvatska; 2006.

[55] Nacionalni program sigurnosti cestovnog prometa Republike Hrvatske 2011. – 2020. Zagreb, NN 59/2011., Republika Hrvatska; 2011.

[56] Cairney PT.; Community road safety – Organisational and Methodological Challenges. In: Road Safety Research, Policing and Education. Adelaide, SA.; 2001.

[57] Sayed T, Saunier N, Lovegrove G, de Leur P.; Advances in proactive road safety planning. Proc 20th Can Multidiscip Road Saf Conf. 2010;6–9.

[58] Lord D, Mannering F.; The statistical analysis of crash-frequency data: A review and assessment of methodological alternatives. Transp Res Part A Policy Pract. 2010;44(5):291–305.

[59] Savolainen PT, Mannering FL, Lord D, Quddus MA.; The statistical analysis of highway crash-injury severities: A review and assessment of methodological alternatives. Accid Anal Prev. 2011;43(5):1666–76.

[60] Krug EG, Sharma GK, Lozano R.; The global burden of injuries. Am J Public Health. 2000;90(4):523–6.

[61] Evans L.; The dominant role of driver behavior in traffic safety. Am J Public Health. 1996;86(6):784–6.

[62] Guppy A, Adams-Guppy JR.; Behavior and perceptions related to drink-driving among an international sample of company vehicle drivers. J Stud Alcohol. 1995;56(3):348–55.

[63] Moore VM, Dolinis J, Woodward AJ.; Vehicle Speed and Risk of a Severe Crash. Epidemiology. 1995;6(3):258–62.

[64] Shinar D.; Traffic Safety and Human Behavior. Vol. 27, Human Factors. 2007. 776 p.

[65] Graham PB.; Traffic Accidents: Causes and Outcomes. New York: Nova Publishers; 2008. 278 p.

[66] Odero W, Khayesi M, Heda PM.; Road traffic injuries in Kenya: magnitude, causes and status of intervention. Inj Control Saf Promot. 2003;10(1–2):53–61.

[67] Rijkka R, Mikko M.; Effect of Intensified Automatic Speed Control and Decreased Tolerance on Traffic Safety. Nord Road Transp Res J. 2008;41(1).

[68] Petch RO, Henson RR.; Child road safety in the urban environment. J Transp Geogr. 2000;8(3):197–211.

[69] Kidd, David A, Horrey, William J.; Distracted Driving. Profess. 2010;(November):40–6.

[70] Janssen W.; Seat-belt wearing and driving behavior: An instrumented-vehicle study. Accid Anal Prev. 1994;26(2):249–61.

[71] Kennedy BP, Isaac NE, Graham JD.; The role of heavy drinking in the risk of traffic fatalities. Risk Anal. 1996;16:565–9.

[72] Walsh JM, de Gier JJ, Christopherson AS, Verstraete AG.; Drugs and driving. Traffic Inj Prev. 2004;5(3):241–53.

[73] Massie DL, Campbell KL, Williams AF.; Traffic Accident involvement rates by driver age and gender. Accid Anal Prev. 1995;27(1):73–87.

[74] Rivara FP, Barber M.; Demographic analysis of childhood pedestrian injuries. Vol. 76, Pediatrics. 1985. p. 375–81.

[75] Brown ID.; Driver fatigue. Hum Factors. 1994;36(2):298–314.

[76] Nilsson G.; Traffic Safety Dimensions and the Power Model to Describe the Effect of Speed on Safety. Lund Institute of Technology. 2004.

[77] Hauer E.; Speed and Safety. Transp Res Rec J Transp Res Board. 2009;2103(2103):10–7.

[78] Feng C.; Synthesis of Studies on Speed and Safety. Transp Res Rec J Transp Res Board. 2001;1779(1):86–92.

[79] McLean J, Kloeden C.; Alcohol, Traveling Speed and the Risk of Crash Involvement. In: Proceedings of the 16th International Conference on Alcohol, Drugs and Traffic Safety. Montereal; 2002.

[80] Routley V, Ozanne-Smith J, Yu M, Wang J, Wu M, Zhang J, et al.; Focus on seat belt use in China. Traffic Inj Prev. 2010;11(6):578–86.

[81] Mayrose J.; The effects of a mandatory motorcycle helmet law on helmet use and injury patterns among motorcyclist fatalities. J Safety Res. 2008;39(4):429–32.

[82] Hoekstra T, Wegman F.; Improving the effectiveness of road safety campaigns: Current and new practices. IATSS Res. 2011;34(2):80–6.

[83] Phillips RO, Ulleberg P, Vaa T.; Meta-analysis of the effect of road safety campaigns on accidents. Accid Anal Prev. 2011;43(3):1204–18.

[84] Elvik R.; A theoretical perspective on road safety communication campaigns. Accid Anal Prev. 2015;(349):2–7.

[85] Bedard H.; Accidents: Causes, Analysis and Prevention (Safety and Risk in Society). New York: Nova Science Publishers; 2009. 168 p.

[86] Perez I.; Safety impact of engineering treatments on undivided rural roads. Accid Anal Prev. 2006;38(1):192–200.

[87] Sharing Road Safety; Developing an International Framework for Crash Modification Functions. OECD, ITF; 2012. 132 p.

[88] Zegeer CV; Methods for identifying hazardous highway elements. Transportation Research Board, National Research Council; 1986. 80 p.

[89] Jegede FJ.; Spatio-temporal analysis of road traffic accidents in Oyo State, Nigeria. Accid Anal Prev. 1988;20(3):227–43.

[90] Wegman F, Oppe S.; Benchmarking road safety performances of countries. Saf Sci. 2010;48(9):1203–11.

[91] Hermans E, Brijs T, Wets G, Vanhoof K.; Benchmarking road safety: Lessons to learn from a data envelopment analysis. Accid Anal Prev. 2009;41(1):174–82.

[92] Ghee C, Silcock D, Astrop A, Jacobs G.; Socio-economic aspects of road accidents in

developing countries. Transp Res Lab. 1997;(247):29.

[93] Grad Zagreb; Statistički ljetopis Grada Zagreba 2013. 2014.

[94] Državni zavod za statistiku; Popis stanovništva, kućanstava i stanova 2001., Stanovništvo po naseljima. Zagreb; 2002.

[95] Državni zavod za statistiku. Popis stanovništva, kućanstava i stanova 2011., Stanovništvo po naseljima. Zagreb; 2012.

[96] Službeni glasnik Grada Zagreba br. 21/14; Prostorni plan Grada Zagreba (PPGZ) - izmjene i dopune 2014.

[97] Eurostat; EU-27 regions with the highest lowest number of passenger cars per inhabitant. 2010.

[98] Matulin M, Bošnjak I, Šimunovič L.; Different approaches to the modal split calculation in urban areas. In: Conference proceedings of ICTS 2009: Transport, Maritime and Logistics Science. Portorož; 2009.

[99] Litman T, Rowan S.; Land Use Impacts on Transport: How Land Use Factors Affect Travel Behavior. Evaluating Impacts and Problems. 2012.

[100] Ewing R, Cervero R.; Travel and the Built Environment. J Am Plan Assoc. 2010;76(March 2015):265–94.

[101] MVA Traffic Engineering & Planning; Prometna studija Grada Zagreba. Zagreb; 1999.

[102] Mrvelj Š, Matulin M.; Modalna razdioba 2012, CIVITAS ELAN. 2012.

[103] Brčić D, Šimunović L, Tepeš K.; Pedestrian safety in the City of Zagreb. In: IV INTERNATIONAL CONFERENCE "TOWARDS A HUMANE CITY", Transport in cities of Southeastern Europe / Bogdanović, Vuk (ur). Novi Sad, Srbija: Department for traffic engineering - Faculty of technical sciences, University of Novi Sad; 2013. p. 487–94.

[104] Valent F, Schiava F, Savonitto C, Gallo T, Brusaferro S, Barbone F.; Risk factors for fatal road traffic accidents in Udine, Italy. Accid Anal Prev. 2002;34(1):71–84.

[105] Elvik R, Greibe P.; Road safety effects of porous asphalt: A systematic review of evaluation studies. Vol. 37, Accident Analysis and Prevention. 2005. p. 515–22.

[106] Fridstrøm L, Ingebrigtsen S.; An aggregate accident model based on pooled, regional time-series data. Accid Anal Prev. 1991;23(5):363–78.

[107] Lipovac KP.; Bezbednost saobraćaja. Beograd: Javno preduzeće Službeni list SRJ; 2008. 398 p.

[108] World Road Association PIARC Technical Committee; Road accident investigation guidelines for road engineers. 2007.

[109] Kim K, Nitz L, Richardson J, Li L.; Personal and behavioral predictors of automobile crash and injury severity. Accid Anal Prev. 1995;27(4):469–81.

[110] James HF.; Under-reporting of accidents. Traffic Eng Control. 1991;32(12):573–80.

[111] Daniels S, Brijs T, Keunen D.; Official reporting and newspaper coverage of road crashes: A case study. Saf Sci. 2010;48(10):1469–76.

[112] World Health Organization; Data Systems – A road safety manual for decision-makers and practitioners. Geneva; 2011.

[113] Ferrante AM, Rosman DL, Knuiman MW.; The construction of a road injury database. Accid Anal Prev. 1993;25(6):659–65.

[114] Derriks H, Mak P.; IRTAD special report: Underreporting of road traffic casualties. Paris; 2007.

[115] Hauer E, Hakkert, A.; Extent and some implications of incomplete accident reporting. Transp Res Rec. 1988;(1185):1–10.

[116] Elvik R, Myssen A.; Incomplete accident reporting: meta-analysis of studies made in 13 countries. Transp Res Rec. 1999;(1665):133–40.

[117] European Commission; Summary and publication of best Practices in Road safety in the EU Member States. 2007.

[118] Pravilnik o načinu postupanja policijskih službenika u obavljanju poslova nadzora i upravljanja prometom na cestama, Narodne novine 141/11.

[119] Martinez C, Tormo MT, Andreu M, Pace JF, Monleon C.; Urban traffic accident data collection and analysis in Europe: Current state. Survey study. 2007.

[120] ERSO, SafetyNet; CADAS – Common Accident Data Set, Recommendation for a Common Accident Data Set, Reference Guide. Vol. Version 3. 2011.

[121] Howard C, Linder A.; Review of Swedish experiences concerning analysis of people injured in traffic accidents. Linköping, Sweden; 2014.

[122] Sohn SY, Lee SH.; Data fusion, ensemble and clustering to improve the classification accuracy for the severity of road traffic accidents in Korea. Saf Sci. 2003;41(1):1–14.

[123] Šarić Ž.; Model identifikacije opasnih mjesta u cestovnoj prometnoj mreži. Sveučićište u Zagrebu, Fakultet prometnih znanosti; 2014.

[124] Official Journal of the European Union; EU directive 2011/82/EU of the European Parliament and of the Council - facilitating the cross-border exchange of information on road safety related traffic offences. 2011.

[125] Pravilnik o vrsti i načinu dostave podataka državama članicama Europske Unije, u svrhu istražvianja prometnih nesreća, Narodne Novine 131/13.

[126] Vlada Republike Hrvatske; Izvješće o provedbi nacionalnog programa sigurnosti cestovnog prometa RH 2006. – 2010. godine, za 2009. godinu. 2010.

[127] Lipovac K, Vujanović M, Jovanović D.; Značaj i mogućnosti lokalne samouprave u bezbednosti saobraćaja. In: IV stručni seminar Uloga lokalne zajednice u bezbednosti saobraćaja. Kriminalističko-policijska akademija, Zemun; 2009. p. 53–68.

[128] SafetyNet Deliverable D1.12.; Harmonising national road accident data: Development of transformation rules for 15 European countries. 2008.

[129] Hrvatska gospodarska komora; Odabrani ekonomski pokazatelji hrvatskog gospodarstva. 2008.

[130] Bliss T, Breen J.; Implementing the Recommendations of The World Report on Road Traffic Injury Prevention Country guidelines for the conduct of road safety management capacity reviews and the related specification of lead agency reforms, investment strategies and safety pro. Washington: Global Road Safety Facility, World Bank; 2008.

[131] Brčić D, Zovak G, Tepeš K.; Comparison of Analysis of Road Traffic Safety in te City of Zagreb and Republic of Croatia. In: 12th International Symposium Proceedings Road Accident Prevention. 2014. p. 29–37.

[132] OECD; Integrated road safety programmes. Paris, France; 1984.

[133] Elvik R.; Does Use of Formal Tools for Road Safety Management Improve Safety Performance? Transp Res Rec J Transp Res Board. 2012;2318:1–6.

[134] Duponte E, Martensen H.; Multilevel modelling and time series analysis in traffic research – Methodology. Deliverable D7.4 of the EU FP6 project SafetyNet. 2007.

[135] Carson J, Mannering F.; The effect of ice warning signs on ice-accident frequencies and severities. Accid Anal Prev. 2001;33(1):99–109.

[136] Haleem K, Abdel-Aty M, Mackie K.; Using a reliability process to reduce uncertainty in predicting crashes at unsignalized intersections. Accid Anal Prev. 2010;42(2):654–66.

[137] Chang LY.; Analysis of freeway accident frequencies: Negative binomial regression versus artificial neural network. Saf Sci. 2005;43(8):541–57.

[138] Anastasopoulos PC, Mannering FL;. A note on modeling vehicle accident frequencies with random-parameters count models. Accid Anal Prev. 2009;41(1):153–9.

[139] Persaud B, Retting RA, Lyon C.; Guidelines for Identification of Hazardous Highway Curves. Transp Res Rec J Transp Res Board. 2000;1717:14–8.

[140] Martin JL.; Relationship between crash rate and hourly traffic flow on interurban motorways. Accid Anal Prev. 2002;34(5):619–29.

[141] European Commission; COST Action 329: Models for traffic and safety development and interventions, European Communities. Luxembourg; 2004.

[142] Milošević S.; Teorije saobraćajnih nezgoda. Univerzitet u Beogradu, Saobraćajni fakultet; 2008.

[143] Smeed RJ.; Some Statistical Aspects of Road Safety Research. J R Stat Soc. 1949;112(1):1–34.

[144] Amoros E, Martin JL, Laumon B.; Comparison of road crashes incidence and severity between some French counties. Accid Anal Prev. 2003;35(4):537–47.

[145] Adams J.; Smeed's law: Some further thoughts. Traffic Eng Control. 1987;28(2):70–3.

[146] Andreassen DC.; Linking Deaths with vehicles and population. Traffic Eng Control. 1985;26(11):547–9.

[147] Valli PP.; Road Accident Models for Large Metropolitan Cities of India. IATSS Res. 2005;29(1):57–65.

[148] Bener A, Abu-Zidan FM, Bensiali AK, Al-Mulla AA, Jadaan KS.; Strategy to improve road safety in developing countries. Saudi Med J. 2003;24(6):603–8.

[149] Wang Y, Hasselberg M, Wu Z, Laflamme L.; Distribution and characteristics of road traffic crashes in the Chaoyang District of Beijing, China. Accid Anal Prev. 2008;40(1):334–40.

[150] Noland RB.; Traffic fatalities and injuries: The effect of changes in infrastructure and other trends. Accid Anal Prev. 2003;35(4):599–611.

[151] Abdel-Aty MA, Radwan AE.; Modeling traffic accident occurrence and involvement. Accid Anal Prev. 2000;32(5):633–42.

[152] Shankar V, Mannering F, Barfield W.; Effect of roadway geometrics and environmental factors on rural freeway accident frequencies. Accid Anal Prev. 1995;27(3):371–89.

[153] Milton J, Mannering F.; The relationship among highway geometrics, traffic-related elements and motor-vehicle accident frequencies. Transportation (Amst).

1998;25(4):395–413.

[154] Joksch HC.; The relation between motor vehicle accident deaths and economic activitytle. Accid Anal Prev. 1984;16(3):207–10.

[155] Thoresen T, Fry T, Heiman L, Cameron MH.; Linking Economic Activity, Road Safety Countermeasures and other Factorswith the Victorian Road Toll. Report No. 29. Melbourne; 1992.

[156] Li MD, Doong JL, Chang KK, Lu TH, Jeng MC.; Difference in urban and rural accident characteristics and medical service utilization for traffic fatalities in less-motorized societies. J Safety Res. 2008;39(6):623–30.

[157] Downing A, Jacobs G, Aeron-Thomas A, Sharples J, Silcock D, van Lottum C, et al.; Review of Road Safety in Urban Areas. Transport Research Lab, Crowthorne: TRL Limited, 2000. Crowthorne: TRL Limited: Transport Research Laboratory; 2000.

[158] Ladrón de Guevara F, Washington S, Oh J.; Forecasting Crashes at the Planning Level: Simultaneous Negative Binomial Crash Model Applied in Tucson, Arizona. Transp Res Rec. 2004;1897(1):191–9.

[159] Lord D, Persaud BN.; Estimating the safety performance of urban road transportation networks. Accid Anal Prev. 2004;36(4):609–20.

[160] Sayed T, Lovegrove GR.; Macro-level collision prediction models for evaluating neighbourhood traffic safety. Can J Civ Eng. 2006;33(5):609–21.

[161] Washington S, Schalkwyck IV, Mitra S, Meyer M, Dumbach E, Zoll M.; Incorporating Safety into Long-Range Transportation Planning. Washington, DC; 2006.

[162] Abbess C, Jarett D, Wright CC.; Accidents at blackspots: estimating the effectiveness of remedial treatment, with special reference to the "regression-to-mean." Traffic Eng Control. 1981;22(10):535–42.

[163] Kumara SSP, Chin HC.; Modeling accident occurrence at signalized tee intersections with special emphasis on excess zeros. Traffic Inj Prev. 2003;4(1):53–7.

[164] Wood GR.; Generalised linear accident models and goodness of fit testing. Accid Anal Prev. 2002;34(4):417–27.

[165] Kadane JB, Shmueli G, Minka TP, Borle S, Boatwright P.; Conjugate analysis of the Conway-Maxwell-Poisson distribution. Bayesian Anal. 2006;1(2):363–74.

[166] Lord D, Park PYJ.; Investigating the effects of the fixed and varying dispersion parameters of Poisson-gamma models on empirical Bayes estimates. Accid Anal Prev.

2008;40(4):1441–57.

[167] Šošić I.; Primijenjena statistika. Zagreb: Školska knjiga; 2006.

[168] Thailand Accident Research Centar (TARC); Development of Accident Prediction Model, 2009.

[169] Lord D, Washington SP, Ivan JN.; Poisson, poisson-gamma and zero-inflated regression models of motor vehicle crashes: Balancing statistical fit and theory. Accid Anal Prev. 2005;37(1):35–46.

[170] Oh J, Washington SP, Nam D.; Accident prediction model for railway-highway interfaces. Accid Anal Prev. 2006;38(2):346–56.

[171] Lord D, Geedipally SR, Guikema SD.; Extension of the application of conway-maxwell-poisson models: Analyzing traffic crash data exhibiting underdispersion. Risk Anal. 2010;30(8):1268–76.

[172] Weber DC.; A stochastic approach to automobile compensation. Casualty Actuar Soc LVII. 1971;27–63.

[173] Peck RC, McBride RS, Coppin RS.; The distribution and prediction of driver accident frequencies. Accid Anal Prev. 1971;2(4):243–99.

[174] Hautzinger H.; Regression analysis of aggregate accident data: Some methodological considerations and practical experiences. Accid Anal Prev. 1986;18(2):95–102.

[175] Couto A, Ferreira S.; A note on modeling road accident frequency: A flexible elasticity model. Accid Anal Prev. 2011;43(6):2104–11.

[176] Elvik R.; The importance of confounding in observational before-and-after studies of road safety measures. Accid Anal Prev. 2002;34(5):631–5.

[177] Allain E, Brenac T.; The application of generalized linear models of accident frequencies at road sites: The Poisson model and its extensions. Rech - Transp - Secur. 2001;7(72):3–18.

[178] Ayati E, Abbasi E.; Investigation on the role of traffic volume in accidents on urban highways. J Safety Res. 2011;42(3):209–14.

[179] Shankar VN, Ulfarsson GF, Pendyala RM, Nebergall MB.; Modeling crashes involving pedestrians and motorized traffic. Saf Sci. 2003;41(7):627–40.

[180] Lord D, Miranda-Moreno LF.; Effects of low sample mean values and small sample size on the estimation of the fixed dispersion parameter of Poisson-gamma models for modeling motor vehicle crashes: A Bayesian perspective. Saf Sci. 2008;46(5):751–70.

[181] Sarapa N.; Vjerojatnost i statistika II. Dio: Osnove statistike. Slučajne varijable. Zagreb: Školska knjiga; 1996.

[182] Veljan D.; Kombinatorika s teorijom grafova. Zagreb: Školska knjiga; 1989.

[183] Pearl J.; Causality: models, reasoning and inference. Second Edition. Cambridge: Cambridge University Press, United Kingdom; 2009.

[184] Kullback S.; Information Theory and Statistics. Dover Books on Mathematics; 1997.

[185] Pearl J.; Causality: models, reasoning and inference. First Edition. Cambridge: Cambridge University Press, United Kingdom; 2000.

[186] Bollen KA.; Structural Equations with Latent Variables. Wiley-Interscience; 1 edition; 1989.

[187] Hoyes PO, Hyttinen A.; Bayesian discovery of linear acyclic causal models. In: Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence. Canada; 2009.

[188] Elvik R.; Assessing the validity of road safety evaluation studies by analysing causal chains. Accid Anal Prev. 2003;35(5):741–8.

[189] Larsen L.; Methods of multidisciplinary in-depth analyses of road traffic accidents. J Hazard Mater. 2004;111(1–3):115–22.

[190] Spirtes P, Glymour C, Scheines R.; Causation, Prediction, and Search. 1st ed. New York: Springer-Verlag Lecture Notes in Statistics 81; 1993. 530 p.

[191] Petridou E, Moustaki M.; Human factors in the causation of road traffic crashes. Eur J Epidemiol. 2000;16(9):819–26.

[192] Ramsey J.; Bootstrapping the PC and CPC Algorithms to Improve Search Accuracy. Technical report 187. 2010.

PROPISI

1. Zakon o sigurnosti prometa na cestama (NN,[43] 67/08, … 64/15)
2. Zakon o cestama (NN, 84/11, … 92/14),
3. Zakon o prijevozu u cestovnom prometu (NN, 82/13),
4. Zakon o prijevozu opasnih tvari (NN. 79/07),
5. Zakon o inspekciji cestovnog prometa i cesta (NN, 22/14),
6. Zakon o radnom vremenu, obveznim odmorima mobilnih radnika i uređajima za bilježenje u cestovnom prijevozu (NN, 75/13, 36/15).
7. Zakon o službenoj statistici (NN, 103/03, … 12/13)
8. Zakono o proračunu (NN, 87/08, 136/12, 15/15)
9. Zakon o policiji (NN, 34/11, … 121/16)
10. Zakon o zaštiti i spašavanju (NN, 174/04, … 127/10)
11. Zakon o zaštiti osobnih podataka (NN, 103/03, … 106/12 – pročišćeni tekst)
12. Pravilnik o vrsti i načinu dostave podataka državama članicama Europske unije, u svrhu istraživanja prometnih nesreća (NN, 131/13)
13. Pravilnik o načinu postupanja policijskih službenika u obavljanju poslova nadzora i upravljanja prometom na cestama (NN, 141/11)
14. Uredba o načinu vođenja i obrascu evidencije o zbirkama osobnih podataka (NN, 105/04)
15. Uredba o načinu pohranjivanja i posebnim mjerama tehničke zaštite posebnih kategorija osobnih podataka (NN, 139/04).
16. Statut Grada Zagreba (SGGZ 23/16).
17. *Pojmovnik za statistiku prometa*, IV. izdanje, EUROSTAT/UNECE/ITF, 2010.

[43] NN – *Narodne novine*

POPIS ILUSTRACIJA

Popis slika

Slika 3.1. Prikaz učešća pojedinih modova u ostvarenim putovanjima 71
Slika 3.2. Čimbenici pojave cestovnih prometnih nesreća 74
Slika 6.1. Generalni proces izrade modela za predviđanje stopa CPN-a 129
Slika 6.2. Pregled analize prognostičkih modela CPN-a, obrada autora 134
Slika 6.3. Graf zavisnosti varijabli mjerenja 143
Slika 6.4. Kauzalni model 145
Slika 6.5. Prikaz linearnoga kauzalnog modela 147
Slika 6.6. Dva kauzalna modela poslije intervencije 148
Slika 6.7. Linearni strukturni kauzalni model 149
Slika 6.8. Linearni kauzalni model s prikrivenom (latentnom) varijablom 150
Slika 6.9. Bayesov graf 154
Slika 6.10. Intervencija na Bayesovu grafu 157
Slika 7.1. Dijagram toka kauzalnoga modela – Primjer Model 1 166
Slika 7.2. Ulazni podatci strukturirani u potprogramu Data Box računalnoga programa Tetrad – Model 167
Slika 7.3. Digitalizacija ulaznih podataka – Primjer Model 1 168
Slika 7.4. Kauzalna struktura – Primjer Model 1 169
Slika 7.5. Bayesova struktura i parametri modela – Primjer Model 1 170
Slika 7.6. Bayesov model djelovanja– Primjer Model 1 171
Slika 7.7. Grafički prikazi provedbe simulacije modela – Primjer Model 1 173
Slika 8.1. Komparativni prikaz kauzalnih struktura modela uzroka CPN-a (Model 1- a) i (Model 2 - b) 175
Slika 8.2. Komparativni prikaz kauzalnih struktura prognostičkih modela vrsta CPN-a (Model 3 – a) i (Model 4 - b) 179

Popis tablica

Tablica 3.1. Stupanj motorizacije u Gradu Zagrebu 67
Tablica 4.1. Osnovni orijentacijski podatci o kvantiteti informacija prikupljenih kroz upitnike o prometnim nesrećama 80
Tablica 4.2. Prikaz strukture CADaS varijabli i vrijednosti 90
Tablica 5.1. Komparativna lista relativnih pokazatelja sigurnosti cestovnoga prometa Republike Hrvatske i Grada Zagreba za 2013. godinu 124
Tablica 6.1. Vjerojatnost modela P(x, y, e_2) 147
Tablica 6.2. Vrijednosti varijabli 154
Tablica 6.3. Funkcije vjerojatnosti 155
Tablica 6.4. Funkcije prijelaza 155
Tablica 6.5. Funkcija vjerojatnosti varijable UPBN 156
Tablica 6.6. Funkcija vjerojatnosti varijable UPNB 156
Tablica 6.7. Funkcija vjerojatnosti varijable UPOV 156
Tablica 6.8. Funkcija vjerojatnosti varijable UPOV nakon intervencije UPNB-a 158
Tablica 7.1. Nazivi i skraćenice ulaznih varijabli kauzalnih prognostičkih modela 164
Tablica 8.1. Prikaz kauzalnih razina prognostičkih modela uzroka CPN-a (Model 1 i Model 2) 175
Tablica 8.2. Komparativna kvantitativna analiza rezultata prognostičkih modela uzroka CPN-a (Model 1- a) i (Model 2 - b) 177
Tablica 8.3. Prikaz kauzalnih razina prognostičkih modela vrsta CPN-a (Model 3 i Model 4) 180
Tablica 8.4. Komparativna kvantitativna analiza rezultata prognostičkih modela vrsta CPN-a (Model 3 – a) i (Model 4 - b) 181
Tablica 8.5. Komparativni rezultati evaluacije (Model 1 – a) i (Model 2 - b) 182
Tablica 8.6. Komparativni rezultati evaluacije (Model 3 – a) i (Model 4 - b) 184

Popis grafikona

Grafikon 2.1. Pregled odnosa smrtno stradalih sudionika u CPN-u i ciljeva iz Nacionalnih programa sigurnosti cestovnoga prometa Republike Hrvatske za razdoblje 2000. – 2020. 28
Grafikon 3.1. Broj poginulih osoba na 1.000.000 stanovnika (2013.) 53
Grafikon 3.2. Broj poginulih osoba na 1.000.000 stanovnika po pojedinim državama članicama Europske unije, komparacijom 2013. s 2004. godinom, Izvor: CARE, Eurostat 54
Grafikon 3.3. Broj poginulih osoba na 1.000.000 stanovnika u razdoblju 2001. – 2014. na području Republike Hrvatske i Europske unije, Izvor: CARE, Eurostat 55
Grafikon 3.4. Broj poginulih osoba na 100.000 stanovnika, vozača, vozila, u razdoblju 2004. – 2013. godine na području Republike Hrvatske 56
Grafikon 3.5. Broj poginulih osoba u odnosu na milijun stanovnika po državama članicama Europske unije, ovisno o mjestu nastanka CPN-a, 2013. godina. Izvor: CARE Eurostat, obrada autora 57
Grafikon 3.6. Prostorna distribucija broja poginulih osoba u CPN-u ovisno o kategorijama i značajkama ceste, komparacija 2014. s 2007. godinom, u Republici Hrvatskoj u odnosu na prosjek Europske unije. 58
Grafikon 3.7. Prostorna distribucija broja poginulih u CPN-u za urbana područja, ovisno o značajkama ceste, po državama članicama Europske unije, 2013. godina. Izvor: CARE, Eurostat, obrada autora 59
Grafikon 3.8. Prikaz kretanja stopa poginulih sudionika u CPN-u za urbana područja po državama članicama Europske unije, 2013. godina. Izvor: CARE, Eurostat, obrada autora 60
Grafikon 3.9. Prikaz odnosa broja poginulih i ozlijeđenih osoba u CPN-u po mjestu 62
Grafikon 3.10. Prikaz kretanja stopa nastradalih sudionika u CPN-u u urbanom području (u naselju) u razdoblju 2009. – 2013. godine na području Republike Hrvatske 63
Grafikon 3.11. Stupanj motorizacije u državama članicama Europske unije. Izvor: Eurostat 65
Grafikon 3.12. Kretanje stopa proračuna Grada Zagreba i bruto domaćega proizvoda (BDP-a) po glavi stanovnika u Gradu Zagrebu 69
Grafikon 3.13. Modalna razdioba u svim putovanjima 71
Grafikon 3.14. Komparativni pregled modalne raspodjele putovanja u gradovima Europske unije i Zagreba, 72
Grafikon 5.1. Dugoročni trend kretanja stopa poginulih osoba u razdoblju 1970. – 2013. u Republici Hrvatskoj s naznakama usvajanja krovnih dokumenata sigurnosti cestovnoga prometa 108

Grafikon 5.2. Kretanje broja CPN-a i stradalih osoba u razdoblju 1999. – 2013. na području Republike Hrvatske 111
Grafikon 5.3. Stope kretanja osnovnih kategorija CPN-a u prometu u razdoblju 1999. – 2013. na području Republike Hrvatske 111
Grafikon 5.4. Kretanje broja CPN-a i stradalih osoba u razdoblju 1999. – 2013. na području Grada Zagreba 113
Grafikon 5.5. Stope kretanja osnovnih kategorija CPN-a u prometu u razdoblju 2004. – 2013. na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 114
Grafikon 5.6. Stope kretanja osnovnih kategorija nastradalih sudionika u prometu u razdoblju 2004. – 2013. na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 115
Grafikon 5.7. Stope kretanja nastradalih sudionika u prometu prema njihovu svojstvu u trenutku nastanka CPN-a, u razdoblju 2004. – 2013., na području Ministarstva unutarnjih poslova, Policijske uprave Zagrebačke 116
Grafikon 5.8. Prosječne stope nastradalih sudionika u razdoblju 2004. – 2013. po njihovoj starosti, na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 117
Grafikon 5.9. Prosječna dnevna distribucija broja CPN-a te poginulih i ozlijeđenih osoba u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 118
Grafikon 5.10. Prosječna satna distribucija broja CPN-a te poginulih i ozlijeđenih osoba u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 119
Grafikon 5.11. Prosječna stope CPN-a te poginulih i ozlijeđenih osoba u odnosu na vrste prometnih nesreća u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 120
Grafikon 5.12. Prosječne stope najčešćih uzroka prometnih nesreća distribuiranih prema CPN-u te poginulim i ozlijeđenim osobama, u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 122
Grafikon 5.13. Prosječan broj evidentiranih prekršaja u prometu u razdoblju 2004. – 2013., na području Policijske uprave Zagrebačke, Ministarstva unutarnjih poslova 123
Grafikon 5.14. Komparativni pregled broja poginulih osoba na 100.000 stanovnika u razdoblju 1996. – 2016. za Republiku Hrvatsku, PU zagrebačku, Grad Zagreb i Zagrebačku županiju u odnosu na Nacionalni program sigurnosti cestovnoga prometa Republike Hrvatske 125
Grafikon 8.1. Primjer izračuna sredine ranga nepropisne brzine kao uzroka broja CPN-a 176

PRILOZI

PRILOG 1. Europsko izvješće o prometnoj nesreći

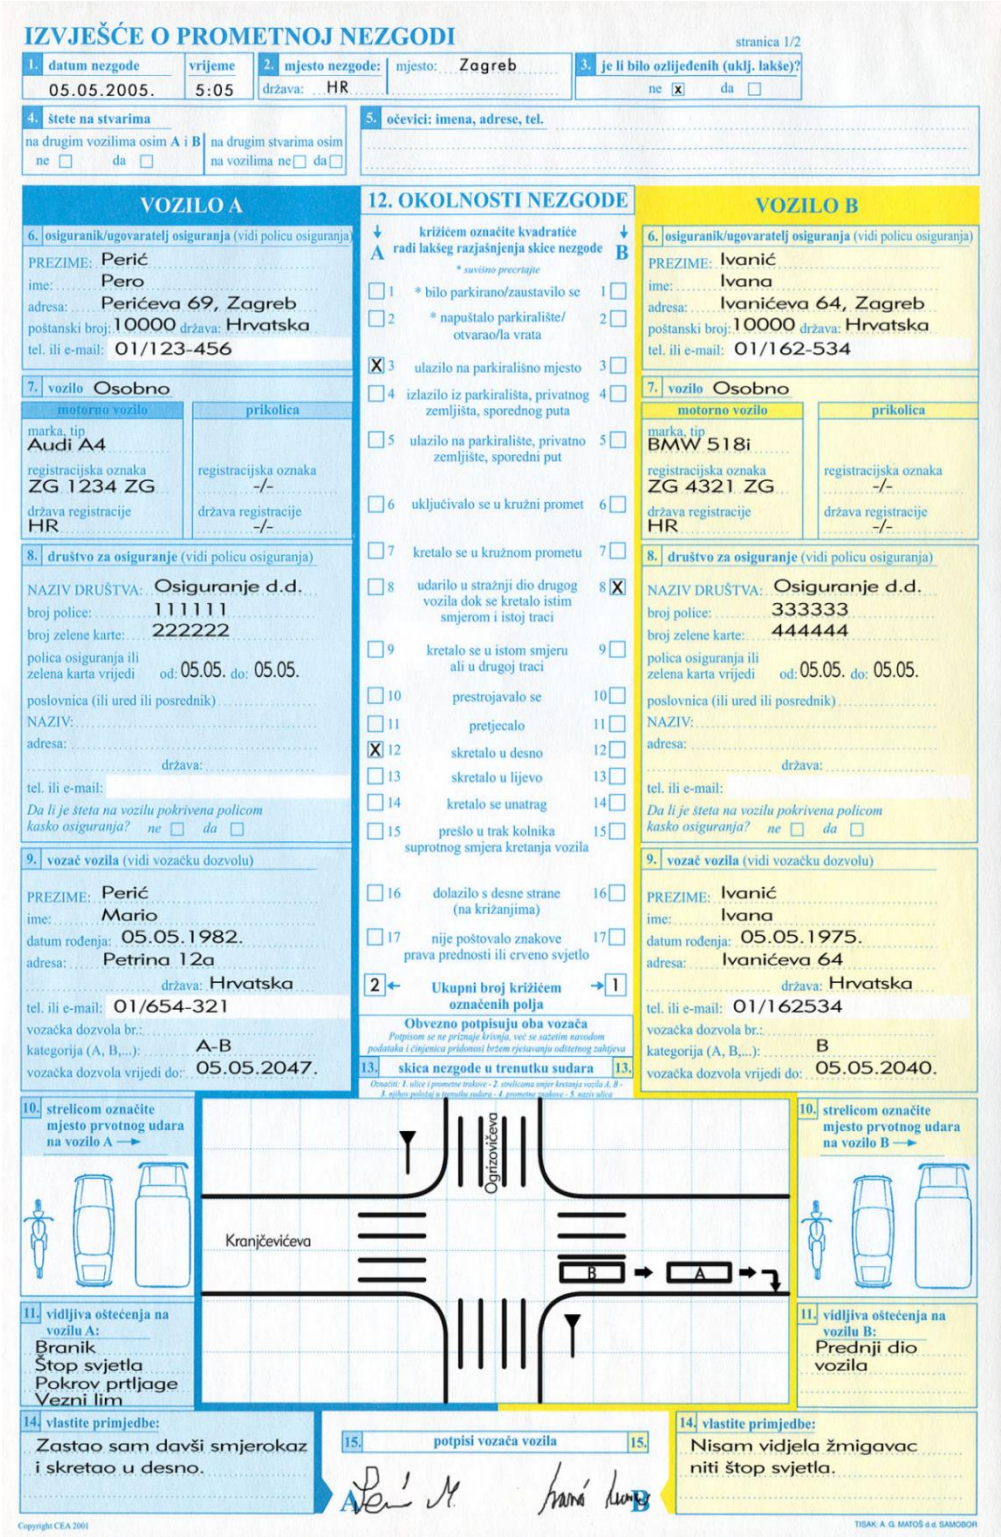

IZVJEŠĆE O PROMETNOJ NEZGODI

stranica 1/2

1. datum nezgode: 05.05.2005. vrijeme: 5:05
2. mjesto nezgode: mjesto: Zagreb; država: HR
3. je li bilo ozlijeđenih (uklj. lakše)? ne [x] da [ ]
4. štete na stvarima: na drugim vozilima osim A i B ne [ ] da [ ]; na drugim stvarima osim na vozilima ne [ ] da [ ]
5. očevici: imena, adrese, tel.

VOZILO A

6. osiguranik/ugovaratelj osiguranja (vidi policu osiguranja)
PREZIME: Perić
ime: Pero
adresa: Perićeva 69, Zagreb
poštanski broj: 10000 država: Hrvatska
tel. ili e-mail: 01/123-456

7. vozilo Osobno
motorno vozilo: marka, tip: Audi A4; registracijska oznaka: ZG 1234 ZG; država registracije: HR
prikolica: registracijska oznaka: -/-; država registracije: -/-

8. društvo za osiguranje (vidi policu osiguranja)
NAZIV DRUŠTVA: Osiguranje d.d.
broj police: 111111
broj zelene karte: 222222
polica osiguranja ili zelena karta vrijedi od: 05.05. do: 05.05.
poslovnica (ili ured ili posrednik)
NAZIV:
adresa:
država:
tel. ili e-mail:
Da li je šteta na vozilu pokrivena policom kasko osiguranja? ne [ ] da [ ]

9. vozač vozila (vidi vozačku dozvolu)
PREZIME: Perić
ime: Mario
datum rođenja: 05.05.1982.
adresa: Petrina 12a
država: Hrvatska
tel. ili e-mail: 01/654-321
vozačka dozvola br.:
kategorija (A, B,...): A-B
vozačka dozvola vrijedi do: 05.05.2047.

12. OKOLNOSTI NEZGODE

križićem označite kvadratiće radi lakšeg razjašnjenja skice nezgode (A / B)
* suvišno precrtajte

[ ] 1	* bilo parkirano/zaustavilo se	1 [ ]
[ ] 2	* napuštalo parkiralište/otvarao/la vrata	2 [ ]
[X] 3	ulazilo na parkirališno mjesto	3 [ ]
[ ] 4	izlazilo iz parkirališta, privatnog zemljišta, sporednog puta	4 [ ]
[ ] 5	ulazilo na parkiralište, privatno zemljište, sporedni put	5 [ ]
[ ] 6	uključivalo se u kružni promet	6 [ ]
[ ] 7	kretalo se u kružnom prometu	7 [ ]
[ ] 8	udarilo u stražnji dio drugog vozila dok se kretalo istim smjerom i istoj traci	8 [X]
[ ] 9	kretalo se u istom smjeru ali u drugoj traci	9 [ ]
[ ] 10	prestrojavalo se	10 [ ]
[ ] 11	pretjecalo	11 [ ]
[X] 12	skretalo u desno	12 [ ]
[ ] 13	skretalo u lijevo	13 [ ]
[ ] 14	kretalo se unatrag	14 [ ]
[ ] 15	prešlo u trak kolnika suprotnog smjera kretanja vozila	15 [ ]
[ ] 16	dolazilo s desne strane (na križanjima)	16 [ ]
[ ] 17	nije poštovalo znakove prava prednosti ili crveno svjetlo	17 [ ]

2 ← Ukupni broj križićem označenih polja → 1

Obvezno potpisuju oba vozača
Potpisom se ne priznaje krivnja, već se sažetim navodom podataka i činjenica pridonosi brzom rješavanju odštetnog zahtjeva

13. skica nezgode u trenutku sudara 13.
Označiti: 1. ulice i prometne trakove - 2. strelicama smjer kretanja vozila A, B - 3. njihov položaj u trenutku sudara - 4. prometne znakove - 5. naziv ulice

VOZILO B

6. osiguranik/ugovaratelj osiguranja (vidi policu osiguranja)
PREZIME: Ivanić
ime: Ivana
adresa: Ivanićeva 64, Zagreb
poštanski broj: 10000 država: Hrvatska
tel. ili e-mail: 01/162-534

7. vozilo Osobno
motorno vozilo: marka, tip: BMW 518i; registracijska oznaka: ZG 4321 ZG; država registracije: HR
prikolica: registracijska oznaka: -/-; država registracije: -/-

8. društvo za osiguranje (vidi policu osiguranja)
NAZIV DRUŠTVA: Osiguranje d.d.
broj police: 333333
broj zelene karte: 444444
polica osiguranja ili zelena karta vrijedi od: 05.05. do: 05.05.
poslovnica (ili ured ili posrednik)
NAZIV:
adresa:
država:
tel. ili e-mail:
Da li je šteta na vozilu pokrivena policom kasko osiguranja? ne [ ] da [ ]

9. vozač vozila (vidi vozačku dozvolu)
PREZIME: Ivanić
ime: Ivana
datum rođenja: 05.05.1975.
adresa: Ivanićeva 64
država: Hrvatska
tel. ili e-mail: 01/162534
vozačka dozvola br.:
kategorija (A, B,...): B
vozačka dozvola vrijedi do: 05.05.2040.

10. strelicom označite mjesto prvotnog udara na vozilo A →

10. strelicom označite mjesto prvotnog udara na vozilo B →

11. vidljiva oštećenja na vozilu A: Branik, Štop svjetla, Pokrov prtljage, Vezni lim

11. vidljiva oštećenja na vozilu B: Prednji dio vozila

14. vlastite primjedbe: Zastao sam davši smjerokaz i skretao u desno.

15. potpisi vozača vozila 15.

14. vlastite primjedbe: Nisam vidjela žmigavac niti štop svjetla.

Copyright CEA 2001

TISAK: A. G. MATOŠ d.d. SAMOBOR

PRILOG 2. Opterećenje prometnica grada Zagreba individualnim motornim prometom, Izvor: Izvješće o stanju okoliša Grada Zagreba, Grad Zagreb, Zagreb, srpanj 2006.

Izmjena opterećenja na frekventnim gradskim prometnicama

Ljubljanska – Slavonska	**80.000 vozila dnevno**
Nova Branimirova (Svetice – Mandlova)	**37.000 vozila dnevno**
Avenija V. Holjevca	**37.000 vozila dnevno**
Heinzelova – Radnička	**35.000 vozila dnevno**
Avenija Dubrovnik	**33.000 vozila dnevno**
Remetinečka cesta	**22.000 vozila dnevno**

Preopterećeni odsječci cestovnih prometnica

- Savska – od Ljubljanske avenije do Vodnikove i od Selske do Ulice Kršnjavoga
- Vlaška – od Draškovićeve do Kvaternikova trga
- Ozaljska – od Selske/Nehajske do Nove ceste
- Ilica – od Vrapčanske do Zagrebačke
- Ljubljanska – od Zagrebačke do Savske
- Slavonska – od Savske do Čulinečke
- Avenija V. Holjevca – od Avenije Dubrovnik do Mosta slobode
- Avenija Hrvatske bratske zajednice – od Mosta slobode do Vukovarske
- Selska – od Jadranskoga mosta do Ilice
- Zagrebačka – od Ljubljanske do Tomislavove
- Av. grada Vukovara – od Savske do Heinzelove
- Heinzelova – od Slavonske do Zvonimirove
- Držićeva – od Slavonske do Branimirove
- „Zeleni valovi“
- Vlaška – od Draškovićeve do Svetica
- Zvonimirova – od Trga žrtava fašizma do Svetica
- Zagrebačka, Bjelovarska i Sesvetska – u istočnom dijelu grada
- Ribnjak, Medveščak, Ksaver, Sv. Duh i dr. sjeverne gradske prometnice

PRILOG 3. UPN obrazac i znakovnik

REPUBLIKA HRVATSKA
MINISTARSTVO UNUTARNJIH POSLOVA

UPITNIK O PROMETNOJ NESREĆI

UPN

BROJ UPN-a _____

PU | PP

BROJ NESREĆE | DATUM NESREĆE | VRIJEME NESREĆE | SEKTOR | OPHODNI RAJON

GEOGRAFSKA ŠIRINA | GEOGRAFSKA DUŽINA | NESREĆA SE DOGODILA U

OPĆINA | NASELJE

ULICA 1 | ULICA 2

KUĆNI BROJ

CESTA | DIONICA | PODIONICA | STACIONAŽA | Km: | Metara:

POSLJEDICA PN | VRSTA PN | Primarno: | Sekundarno: | OKOLNOSTI KOJE SU PREDHODILE | PREKID PROMETA

OČEVID NA MJESTU DOGAĐAJA | SUDJELOVALO VOZILA | SUDJELOVALO OSOBA | UVJETI VIDLJIVOSTI | KARAKTERISTIKE CESTE

STANJE KOLNIČKOG ZASTORA | VRSTA KOLNIČKOG ZASTORA | STANJE POVRŠINE KOLNIKA | REGULACIJA PROMETA | JAVNA RASVJETA

OGRANIČENJE BRZINE | VERTIKALNA SIGNALIZACIJA | HORIZONTALNA SIGNALIZACIJA | OKOLIŠ | ATMOSFERSKE PRILIKE

PODACI O VOZILIMA

VRSTA VOZILA | REGISTRACIJSKA OZNAKA | GODINA PROIZVODNJE | ZEMLJA REGISTRACIJE | SMJER KRETANJA | JAVNI PRIJEVOZ

PRIKOLICA PRIKLJUČENA | OIB | TEHNIČKI PREGLED VRIJEDI | OSIGURANJE VRIJEDI | PROMETNA DOZVOLA VRIJEDI

VRSTA VOZILA | REGISTRACIJSKA OZNAKA | GODINA PROIZVODNJE | ZEMLJA REGISTRACIJE | SMJER KRETANJA | JAVNI PRIJEVOZ

PRIKOLICA PRIKLJUČENA | OIB | TEHNIČKI PREGLED VRIJEDI | OSIGURANJE VRIJEDI | PROMETNA DOZVOLA VRIJEDI

VRSTA VOZILA | REGISTRACIJSKA OZNAKA | GODINA PROIZVODNJE | ZEMLJA REGISTRACIJE | SMJER KRETANJA | JAVNI PRIJEVOZ

PRIKOLICA PRIKLJUČENA | OIB | TEHNIČKI PREGLED VRIJEDI | OSIGURANJE VRIJEDI | PROMETNA DOZVOLA VRIJEDI

ZNAKOVNIK ZA POPUNJAVANJE UPITNIKA O PROMETNOJ NESREĆI (UPN)

PODACI O PROMETNOJ NESREĆI I SUDIONICIMA

ZNAK	POSLJEDICE PROMETNE NESREĆE
1	s poginulim osobama
2	s ozlijeđenim osobama
3	s materijalnom štetom
ZNAK	**VRSTA PROMETNE NESREĆE**
	MEĐUSOBNI SUDAR VOZILA U POKRETU
01	iz suprotnih smjerova
02	bočni sudar
03	usporedna vožnja
04	vožnja u slijedu
05	vožnja unatrag
06	udar vozila u parkirano vozilo
08	slijetanje vozila s ceste
09	nalet na bicikl
10	nalet na pješaka
11	nalet na motocikl ili moped
12	sudar sa željezničkim vozilom
14	ostalo
15	udar vozila u objekt na cesti
16	udar vozila u objekt kraj ceste
	NALET NA ŽIVOTINJU
17	domaća životinja
18	divlja životinja
19	ptica
ZNAK	**OČEVID NA MJESTU DOGAĐAJA**
D	da
N	ne
ZNAK	**UVJETI VIDLJIVOSTI**
1	dan
2	noć
3	sumrak
4	svitanje
ZNAK	**VRSTA KOLNIČKOG ZASTORA**
1	asfalt
2	beton
3	kocka
4	makadam
5	zemlja
ZNAK	**STANJE KOLNIČKOG ZASTORA**
1	dobro
2	manja oštećenja
3	loše
ZNAK	**STANJE POVRŠINE KOLNIKA**
01	suh – čist
02	suh – pijesak, šljunak
03	mokar
04	blato
05	snijeg – razgrnut
06	snijeg – nije razgrnut
07	zaleđen – posut
08	zaleđen – nije posut
09	odron kamenja
10	zemlja suha
11	zemlja mokra
12	ulje i slične tvari
ZNAK	**REGULACIJA PROMETA**
1	prometni znakovi
2	ovlaštena službena osoba
3	pravila prometa
	SEMAFOR
4	uključen u normalan režim rada
5	treptavo žuto svjetlo
6	isključen
ZNAK	**JAVNA RASVJETA**
1	javna rasvjeta u funkciji
2	javna rasvjeta nije u funkciji
3	javne rasvjete nema

ZNAK	OKOLNOSTI KOJE SU PRETHODILE
	GREŠKA – PROPUST VOZAČA
01	nepropisna brzina
02	brzina neprimjerena uvjetima
03	vožnja na nedovoljnoj udaljenosti
04	zakašnjelo uočavanje opasnosti
05	nepropisno pretjecanje
06	nepropisno obilaženje
07	nepropisno mimoilaženje
08	nepropisno uključivanje u promet
09	nepropisno skretanje
10	nepropisno okretanje
11	nepropisna vožnja unatrag
12	nepropisno prestrojavanje
13	nepoštivanje prednosti prolaska
14	nepropisno parkiranje
15	naglo usporavanje – kočenje
16	nepoštivanje svjetlosnog znaka
17	neosiguran teret na vozilu
18	nemarno postupanje s vozilom
19	ostale greške vozača
20	nepropisno kretanje vozila na kolniku
	GREŠKE - PROPUSTI PJEŠAKA
21	nepoštivanje svjetlosnog znaka
22	nekorištenje obilježenog pješačkog prijelaza
23	nekorištenje pothodnika / nathodnika
24	ostale greške pješaka
	OSTALE GREŠKE PROPUSTI
31	neočekivana pojava opasnosti na cesti
33	iznenadni kvar vozila
ZNAK	**KARAKTERISTIKE CESTE**
	RASKRIŽJE
01	T-raskrižje
02	Y-raskrižje
03	četverokrako raskrižje
04	kružni tok
05	ostalo
06	čvor u više razina
	CESTA IZVAN RASKRIŽJA I ČVORA
07	most
08	podvožnjak
09	nadvožnjak
10	tunel
	PRIJELAZ PREKO ŽELJEZNIČKE PRUGE
	fizički zaštićen
11	otvoren
12	zatvoren
	svjetlosna signalizacija
13	ispravna
14	neispravna
	nezaštićen
15	pregledan
16	nepregledan
	CESTA
17	zavoj
18	ravni cestovni potez
19	parkiralište
20	pješački prijelaz
21	nogostup
22	biciklistička staza
23	ostalo
24	pješačka zona
25	zona smirenog prometa
ZNAK	**VERTIKALNA SIGNALIZACIJA**
1	dobra
2	oštećena
3	loša
4	nema je

PRILOG 4. Analiza trendova sigurnosnih pokazatelja prometa u Republici Hrvatskoj

Vremenska distribucija CPN-a na području Republike Hrvatske

U okviru vremenske analize CPN-a ispitivana je dnevna, tjedna i mjesečna neravnomjernost pojave CPN-a. Na vremenski raspored CPN-a utječu mnogobrojni čimbenici, od koji su najznačajniji društvene aktivnosti i dnevne migracije, geografski i klimatski uvjeti, turističke sezone i sl.

Promatrajući distribuciju CPN-a po satima u toku dana u periodu od 2004. do 2013. godine (Grafikon 5.7.), najveće su vrijednosti zabilježene u vremenskom intervalu od 14 do 18 sati, kada se dogodi 24,52% svih registriranih prometnih nesreća. Satna raspodjela istovjetna je i kod broja ozlijeđenih osoba u prometnim nesrećama. Naime, u spomenutom vremenskom periodu 25,56% osoba od ukupnoga broja biva ozlijeđeno.

Maksimalne vrijednosti satnih raspodjela za osobe poginule u prometnim nesrećama nešto je drugačija od prethodnih dviju navedenih kategorija, te je ona najizraženija tokom dana u periodu od 16 do 20 sati, s ukupnim udjelom od 25,48%.

Sa stanovišta sigurnosti cestovnoga prometa najmanje vrijednosti, odnosno period najpogodniji za sudjelovanje u prometu je od 02 do 04 sata, kada se dogodi 2,99% ukupnoga broja CPN-a. U istom periodu nastradalo je 6,11% od ukupnoga broja poginulih osoba te 3,35% od ukupnoga broja ozlijeđenih osoba. Razlog je za navedeno smanjen intenzitet prometnih entiteta na cestovnim prometnicama, čime se ujedno i rizik od nastanka CPN-a te stradavanje sudionika u prometu svodi na minimum.

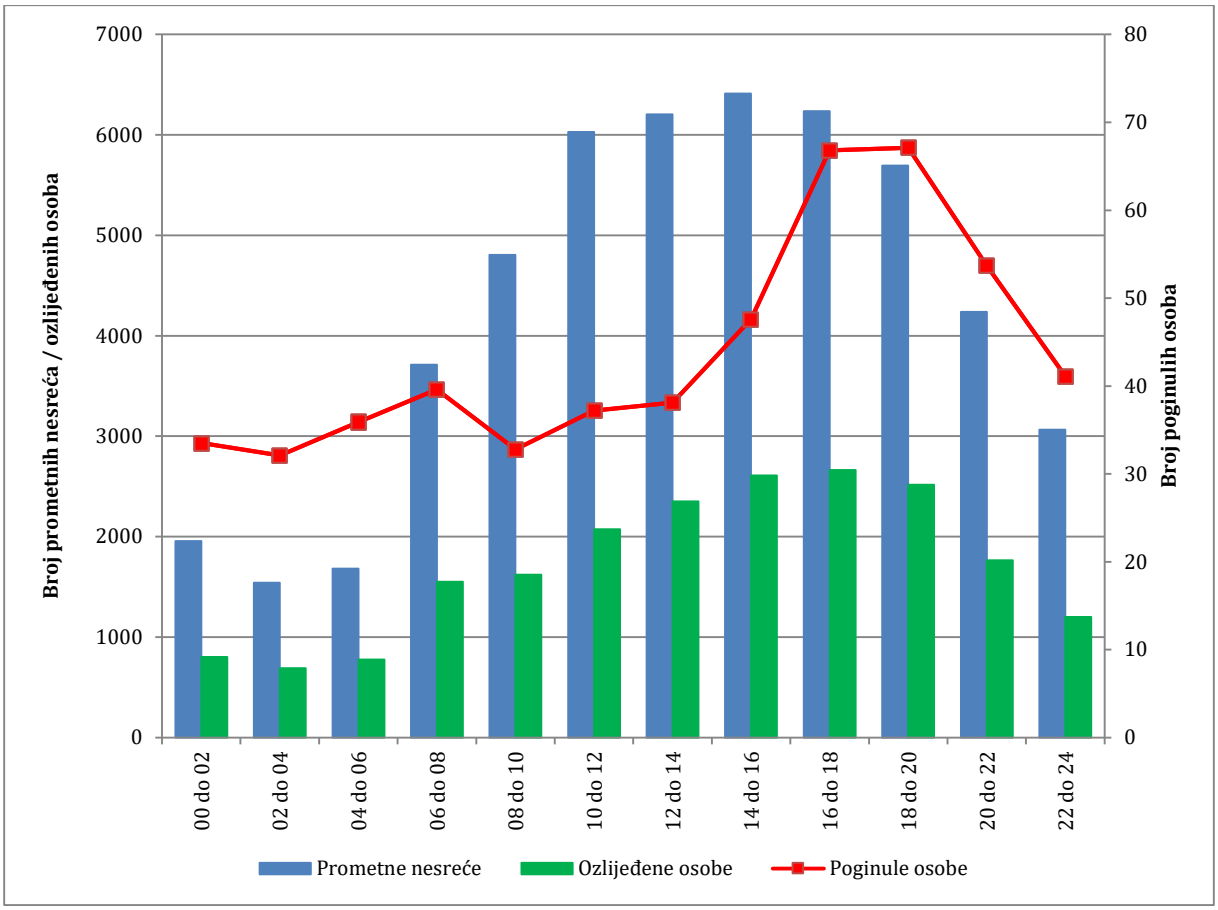

Grafikon 1. Prosječna satna distribucija broja CPN-a, poginulih i ozlijeđenih osoba, u razdoblju 2004. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Analizirajući istovjetne kategorije statističkih podataka, distribuirane po danima u tjednu u kojima su se dogodile (Grafikon 5.8.), možemo konstatirati kako je maksimalna vrijednosti broja prometnih nesreća u danima petka (8.337,9) i subote (7.771,9), a isto vrijedi i za stope ozlijeđenih osoba. Maksimalan broj poginulih osoba najviši je u danima vikenda s učešćem od 36,70% od ukupnog broja poginulih osoba, posebice subotom (99,3). Nadalje, najveće su dnevne stope promjena kod poginulih osoba do 24% (prijelaz s petka na subotu), dok su ta odstupanja u broju ozlijeđenih osoba do 17% (prijelaz s četvrtka na petak).

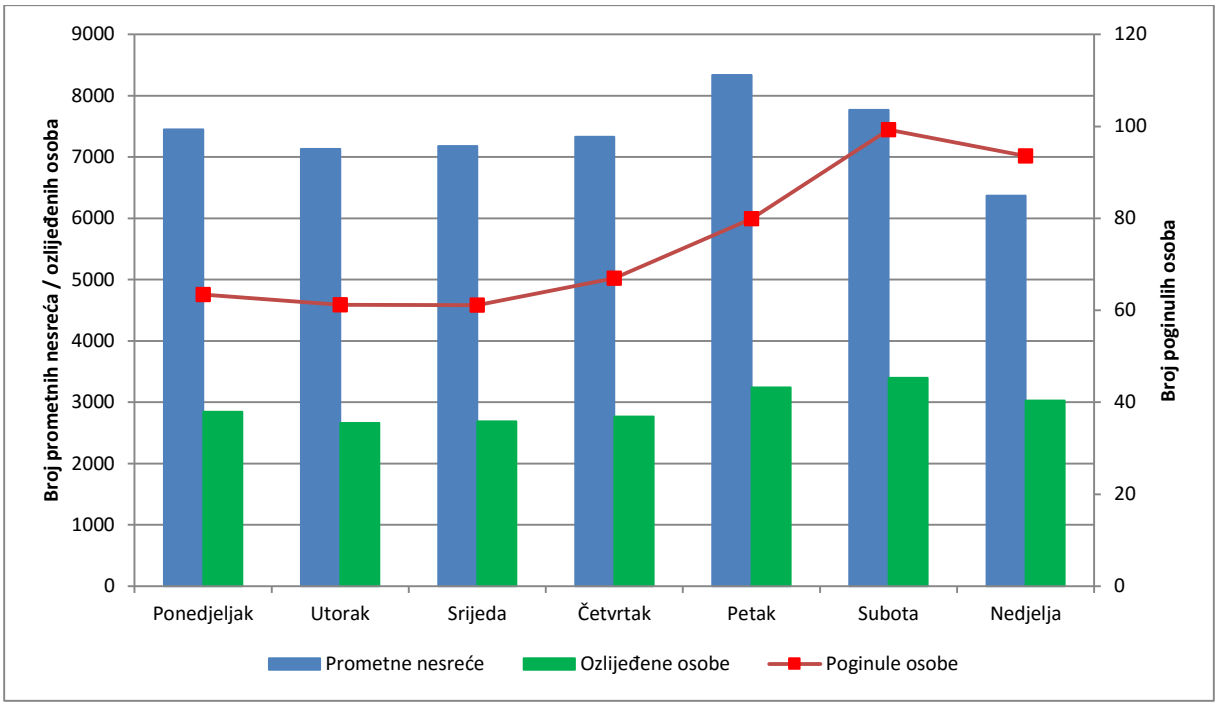

Grafikon 2. Prosječna dnevna distribucija broja CPN-a, poginulih i ozlijeđenih osoba, u razdoblju 2004. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Promatrajući podatke na mjesečnoj razini (Grafikon 3.), možemo navesti kako su maksimalne vrijednosti svih triju kategorija najveće u ljetnim mjesecima, posebice srpnju i kolovozu, za što je zaslužna velika fluktuacija stranih državljana na cestovnoj mreži, u kombinaciji s domicilnim stanovništvo koje koristi svoje godišnje odmore za putovanja. Tako u navedenom periodu pogine 21,08% od ukupnoga broja poginulih osoba, dok njih 8,69% biva ozlijeđeno.

Promatrajući stope poginulih osoba kroz cijelu godinu, vidljiv je postepen rast stopa vrijednosti u periodu od siječnja do srpnja, odnosno pad stopa u periodu od srpnja do studenoga. Izuzetak je mjesec prosinac, kada je stopa promjena za poginule osobe ujedno i najveća, te iznosi 18,93%.

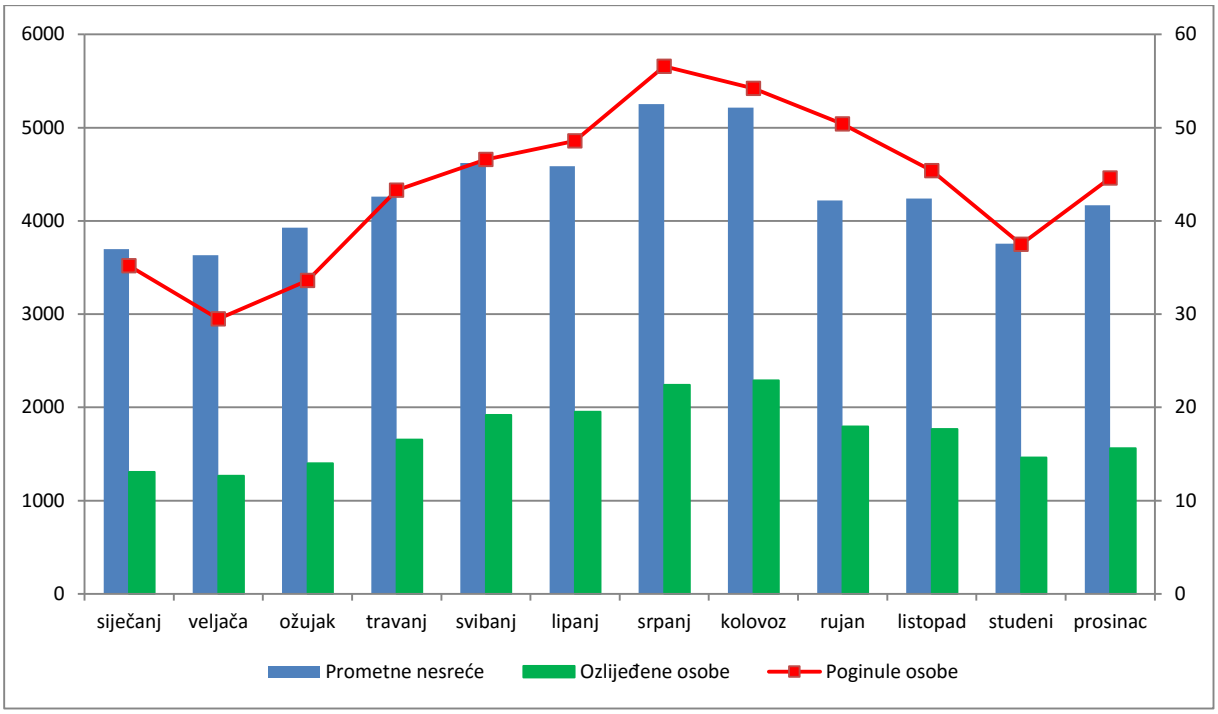

Grafikon 3. Prosječna mjesečna distribucija broja CPN-a, poginulih i ozlijeđenih osoba, u razdoblju 2004. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Svojstva i starosna struktura nastradalih sudionika u CPN-a

Prema svojstvu sudionika nastradalih u CPN-u (Grafikon 5.10.), maksimalne vrijednosti zabilježene su kod vozača, i to u vezi sa smrtnim posljedicama te zadobivanjem određenoga stupnja ozljede (teška/laka ozljeda). Prema istomu, na vozače motornih vozila opada 56,92% ukupnoga postotnog učešća poginulih osoba u cestovnom prometu te 59,04% ozlijeđenih sudionika u prometu. Ukupna postotna zastupljenost kod putnika ima nešto izraženiju razliku između dviju osnovnih skupina osoba nastradalih u CPN-u, te za smrtne slučajeve iznosi 23,62%, dok je za ozlijeđene 30,72%. Najmanje vrijednosti zabilježene su kod stradavanja pješaka, koji sudjeluju s 19,46% u ukupnom broju poginulih osoba, odnosno 10,24% u odnosu na ukupan broj ozlijeđenih sudionika u prometu.

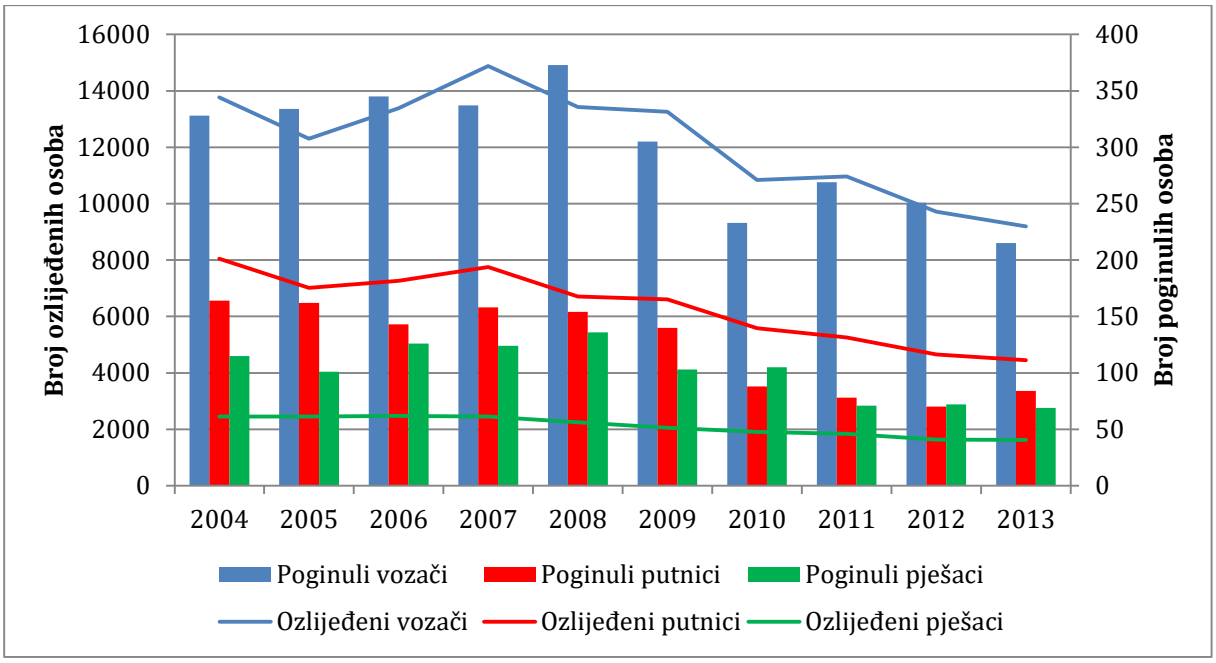

Grafikon 4. Stope kretanja nastradalih sudionika u prometu prema njihovu svojstvu u trenutku nastanka CPN-a, u razdoblju 2004. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Analiza starosne strukture učesnika CPN-a (Grafikon 4.) ukazuje na to kako su osobe srednje starosne dobi, od 18 do 24 godine i od 24 do 34 godine, najugroženija kategorija u smislu zadobivalja određenoga nivoa tjelesnih ozljeda u prometu, s ukupnim postotnim učešćem od 44,66%. Ta je skupina rizična i prilikom analiziranja stopa poginulih osoba u prometu (36,34% od ukupnoga broja), a u velikom joj se postotnom učešću pridružuju sudionici u prometu s više od 65 godina, koji predstavljaju 18,25% od ukupnoga broja poginulih osoba.

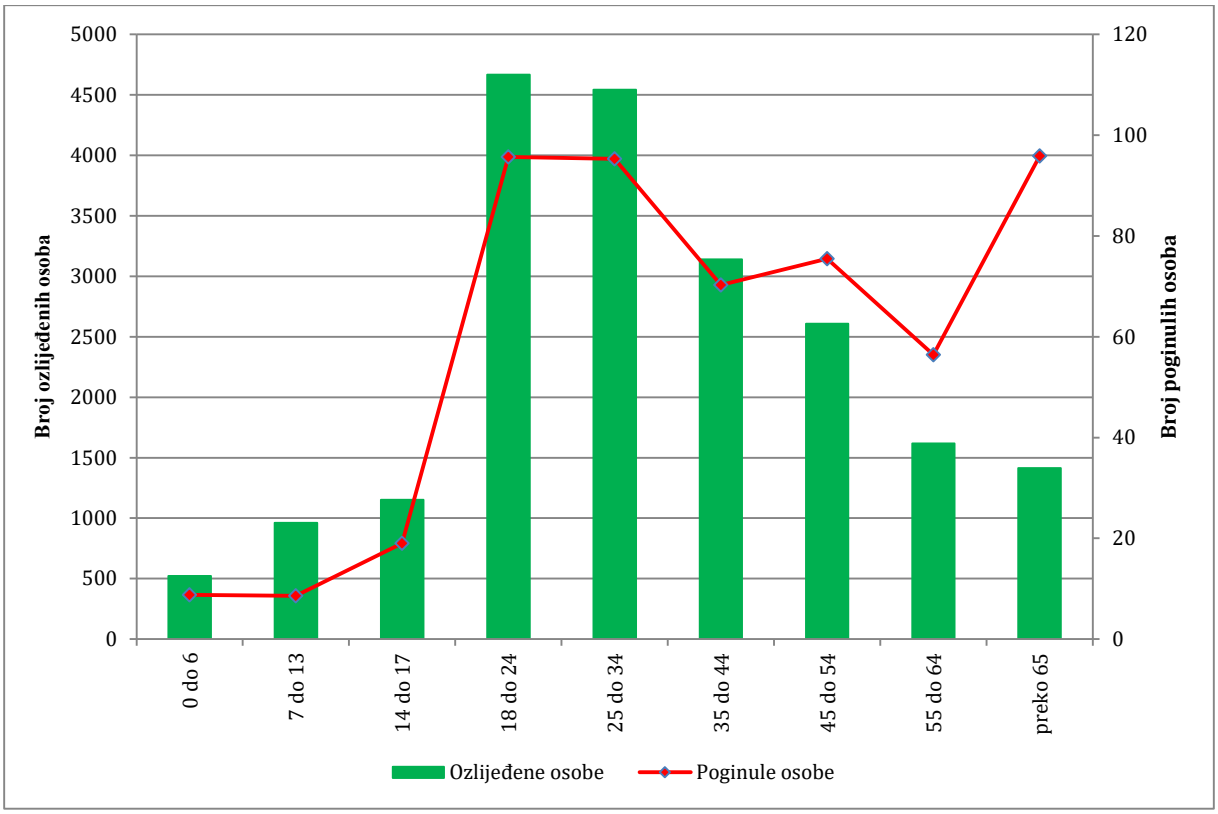

Grafikon 5. Prosječne stope nastradalih sudionika po njihovoj dobnoj starosti, u razdoblju 2004. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Analiza vrsta CPN-a

Prilikom prikupljanja podataka o CPN-u u službenoj bazi podataka, koju vodi Ministarstvo unutarnjih poslova, oni se razvrstavaju u ukupno 15 kategorija, i to kako slijedi: sudari iz suprotnih smjerova, bočni smjer, u usporednoj vožnji, u vožnji u slijedu, u vožnji unazad, udar vozila u drugo zaustavljeno ili parkirano vozilo, slijetanje vozila s ceste, nalet na bicikl, nalet na pješaka, nalet na motocikl ili moped, međusobni sudar cestovnoga vozila i vlaka, udar vozila u objekt na cesti, udar vozila u objekt kraj ceste, nalet vozila te ostale vrste nesreća.

Prosječne vrijednosti 7 ključnih kategorija prikazane su na Grafikonu 6. za period od 10 godina. Možemo konstatirati kako je najveći broj poginulih osoba primjetan za CPN-e pri slijetanju vozila s ceste (31,59%), naletu na pješaka (20,50%) te prometnim nesrećama zbog sudara vozila iz suprotnoga smjera (20,33%). Navedene tri vrste CPN-a čine ukupno 72,42% poginulih osoba u prometu.

Promatrajući vrste prometnih nesreća prema ukupnomu broju evidentiranih, najveća učešća imaju bočni sudar (20%), vožnja u slijedu (15,46%) te slijetanje vozila s ceste (16,31).

Navedene tri vrste prometnih nesreća predstavljaju ukupno 51,77% ukupnoga broja registriranih prometnih nesreća.

Za kategoriju ozlijeđenih sudionika u prometu najveće su vrijednost triju vrsta prometnih nesreća – slijetanje vozila s ceste (23,50%), bočni sudar (18,90%) i vožnja u slijedu (14,97). One predstavljaju ukupni zbroj od 57,37%.

Analitičkom analizom utvrđeno je da slijetanje vozila s ceste predstavlja najznačajniju vrstu prometnih nesreća u svim trima promatranim kategorijama.

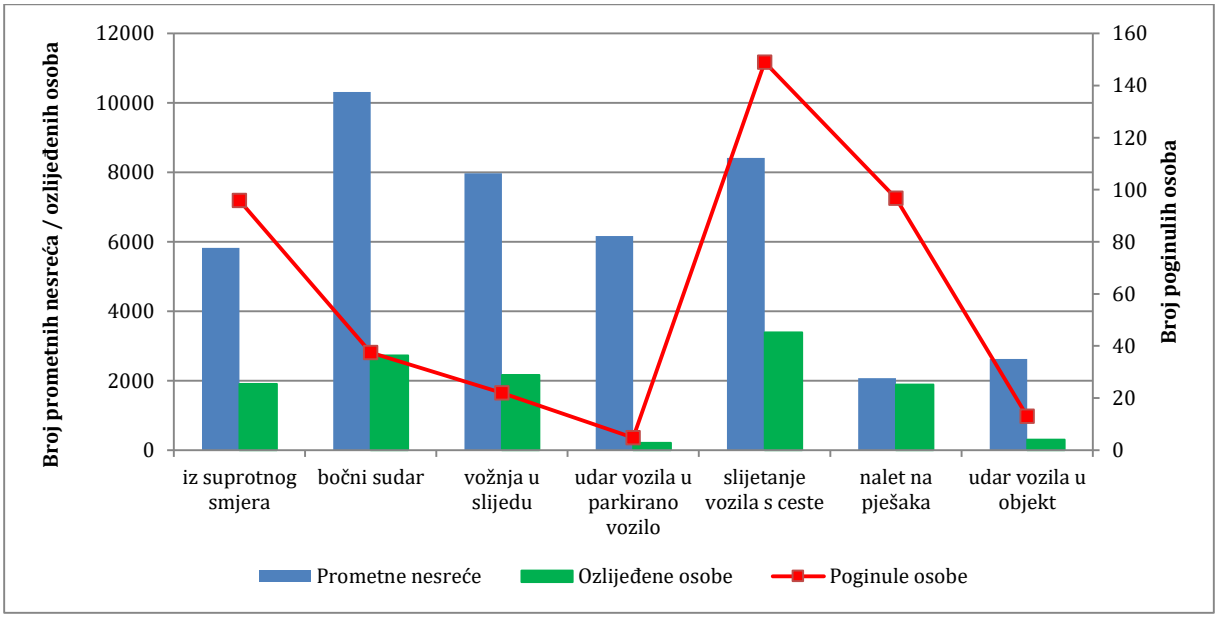

Grafikon 6. Prosječne stope CPN-a, poginulih i ozlijeđenih osoba u odnosu na vrste prometnih nesreća, u razdoblju 2004. – 2013. godine na području Republike Hrvatske

Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

Analiza uzroka CPN-a

Promatrajući nastanak CPN-a te stradavanja sudionika u prometu, ovisno o njihovim uzrocima (Grafikon 7.), brzina kretanja, koja podrazumijeva nepropisnu brzinu te brzinu neprimjerenu uvjetima na cesti, zauzima prvo mjesto u svim trima razmatranim kategorijama. Kod ukupnoga

broja CPN-a brzina kretanja zauzima 49,80% učešća u odnosu na ukupan broj, kod smrtno stradalih 63,38%, a kod ozlijeđenih sudionika u prometu 53,55%.

Drugi najznačajniji uzroci kod promatranih se kategorija nešto razlikuju, tako da je kod CPN-a to izvođenje radnji vozilom, koje podrazumijeva nepropisno skretanje, nepropisnu vožnju unazad te nepropisna prestrojavanja s postotnim učešćem od 17,97%. Kod poginulih i ozlijeđenih osoba drugo mjesto zauzima nepoštivanje prednosti prolaska sa 7,99% promatrajući smrtne slučajeve, a 18,1% ako razmatramo ukupan broj osoba ozlijeđenih u cestovnom prometu.

Važno je napomenuti kako u službenim statističkim izvješćima psihofizičko stanje sudionika CPN-a (umor, alkoholiziranost, uporaba zabranjenih medikamenata i sl.) nije kvantificirana kao jedan od elemenata njihova uzroka, što onemogućava provedbu navedene analize i također se treba uvrstiti kao jedno od ograničenja dolje navedene analize.

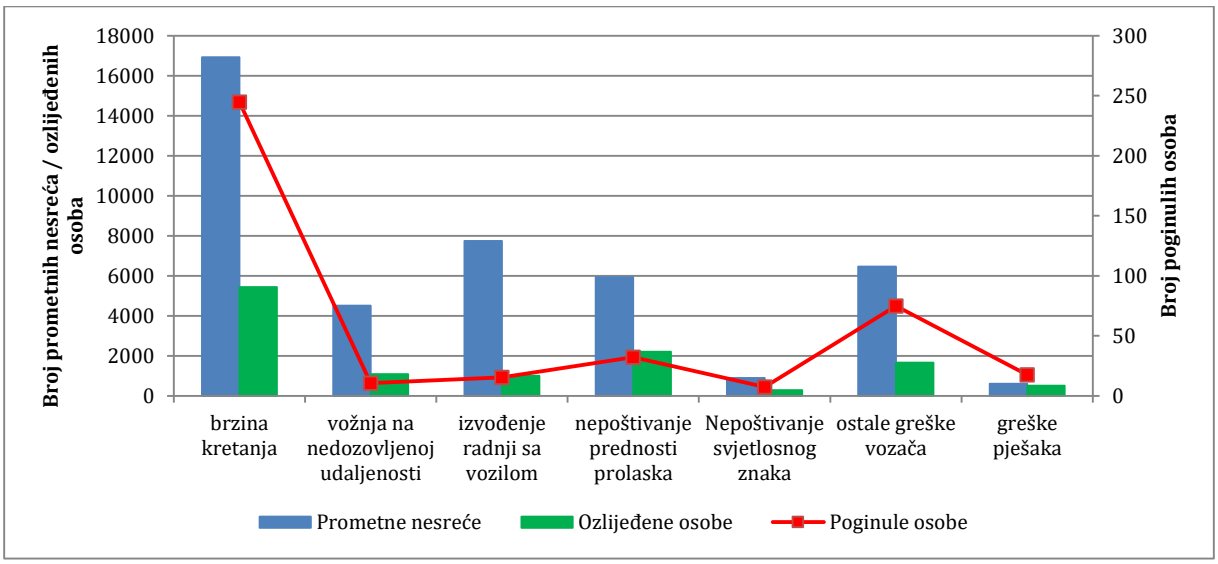

Grafikon 7. Prosječne stope najčešćih uzroka prometnih nesreća distribuirane prema CPN-a, poginulim i ozlijeđenim osobama, u razdoblju 2004. – 2013. godine na području Republike Hrvatske
Izvor: Bilten o sigurnosti cestovnog prometa (od 2005. do 2013.), Ministarstvo unutarnjih poslova, Zagreb, obrada autora

PRILOG 5. Kauzalni model uzroka CPN-a ovisno o broju teško/lako ozlijeđenih sudionika u prometu (Model 2)

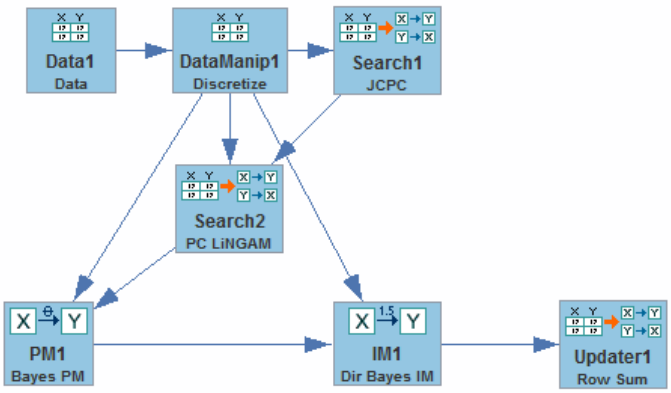

Slika 1. Kauzalni model uzroka CPN-a – Model 2

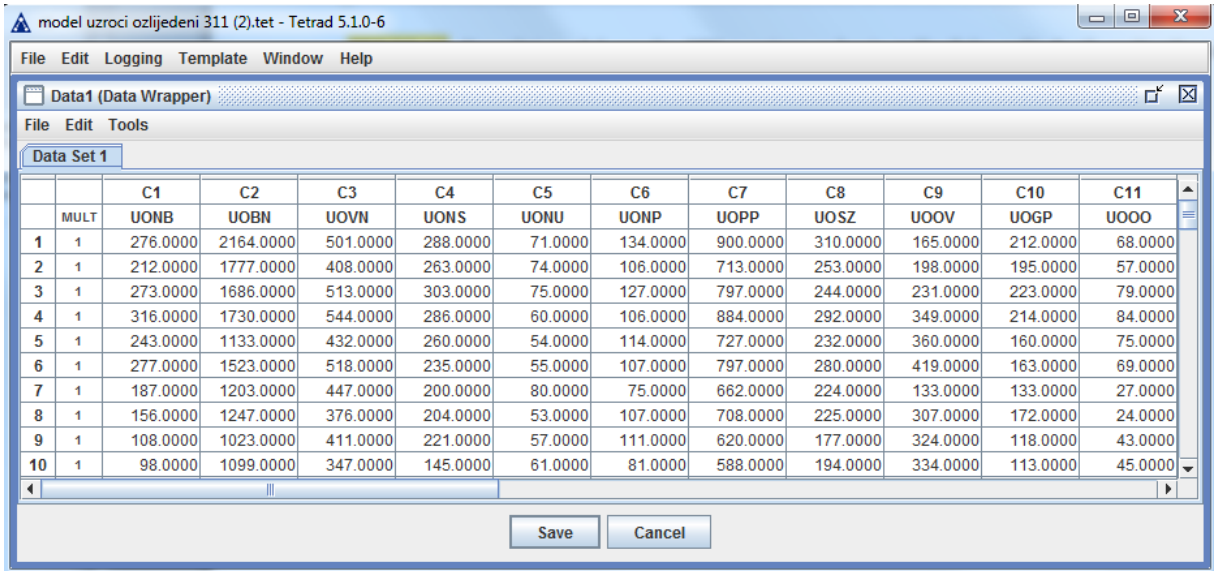

		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
	MULT	UONB	UOBN	UOVN	UONS	UONU	UONP	UOPP	UOSZ	UOOV	UOGP	UOOO
1	1	276.0000	2164.0000	501.0000	288.0000	71.0000	134.0000	900.0000	310.0000	165.0000	212.0000	68.0000
2	1	212.0000	1777.0000	408.0000	263.0000	74.0000	106.0000	713.0000	253.0000	198.0000	195.0000	57.0000
3	1	273.0000	1686.0000	513.0000	303.0000	75.0000	127.0000	797.0000	244.0000	231.0000	223.0000	79.0000
4	1	316.0000	1730.0000	544.0000	286.0000	60.0000	106.0000	884.0000	292.0000	349.0000	214.0000	84.0000
5	1	243.0000	1133.0000	432.0000	260.0000	54.0000	114.0000	727.0000	232.0000	360.0000	160.0000	75.0000
6	1	277.0000	1523.0000	518.0000	235.0000	55.0000	107.0000	797.0000	280.0000	419.0000	163.0000	69.0000
7	1	187.0000	1203.0000	447.0000	200.0000	80.0000	75.0000	662.0000	224.0000	133.0000	133.0000	27.0000
8	1	156.0000	1247.0000	376.0000	204.0000	53.0000	107.0000	708.0000	225.0000	307.0000	172.0000	24.0000
9	1	108.0000	1023.0000	411.0000	221.0000	57.0000	111.0000	620.0000	177.0000	324.0000	118.0000	43.0000
10	1	98.0000	1099.0000	347.0000	145.0000	61.0000	81.0000	588.0000	194.0000	334.0000	113.0000	45.0000

Slika 2. Ulazni podatci strukturirani u potprogramu *Data Box* računalnog programa *Tetrad* – Model 2

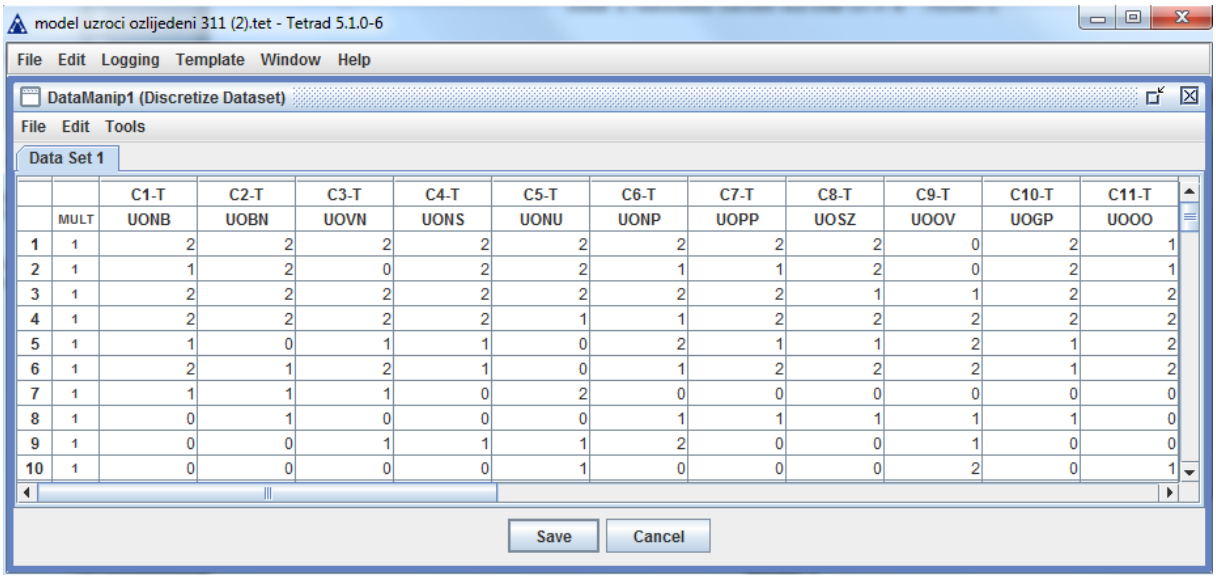

		C1-T	C2-T	C3-T	C4-T	C5-T	C6-T	C7-T	C8-T	C9-T	C10-T	C11-T
	MULT	UONB	UOBN	UOVN	UONS	UONU	UONP	UOPP	UOSZ	UOOV	UOGP	UOOO
1	1	2	2	2	2	2	2	2	2	0	2	1
2	1	1	2	0	2	2	1	1	2	0	2	1
3	1	2	2	2	2	2	2	2	1	1	2	2
4	1	2	2	2	2	1	1	2	2	2	2	2
5	1	1	0	1	1	0	2	1	1	2	1	2
6	1	2	1	2	1	0	1	2	2	2	1	2
7	1	1	1	1	0	2	0	0	0	0	0	0
8	1	0	1	0	0	0	1	1	1	1	1	0
9	1	0	0	1	1	1	2	0	0	1	0	0
10	1	0	0	0	0	1	0	0	0	2	0	1

Slika 3. Digitalizacija ulaznih podataka – Model 2

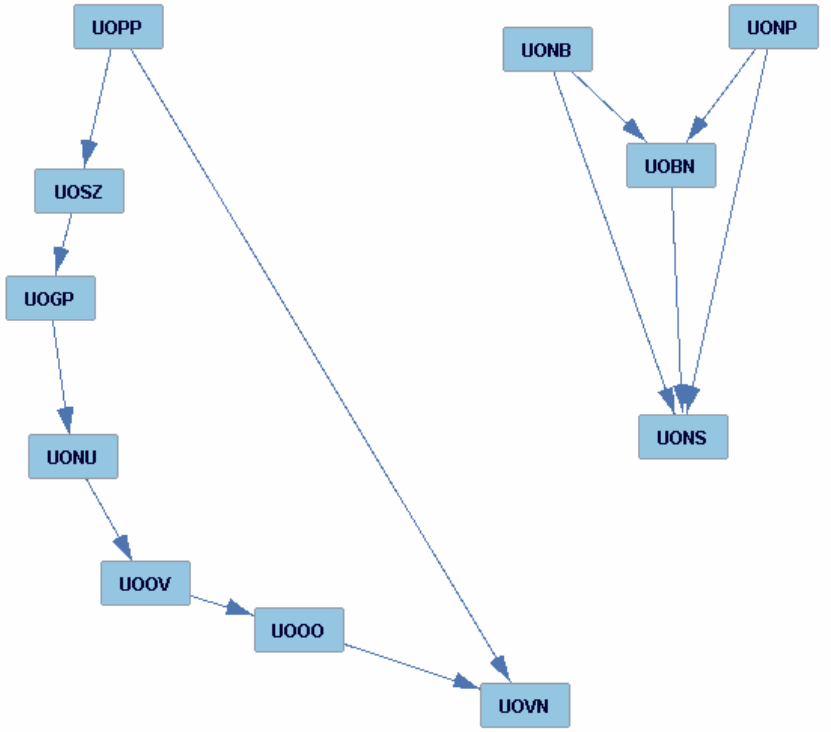

Slika 4. Kauzalna struktura – Model 2

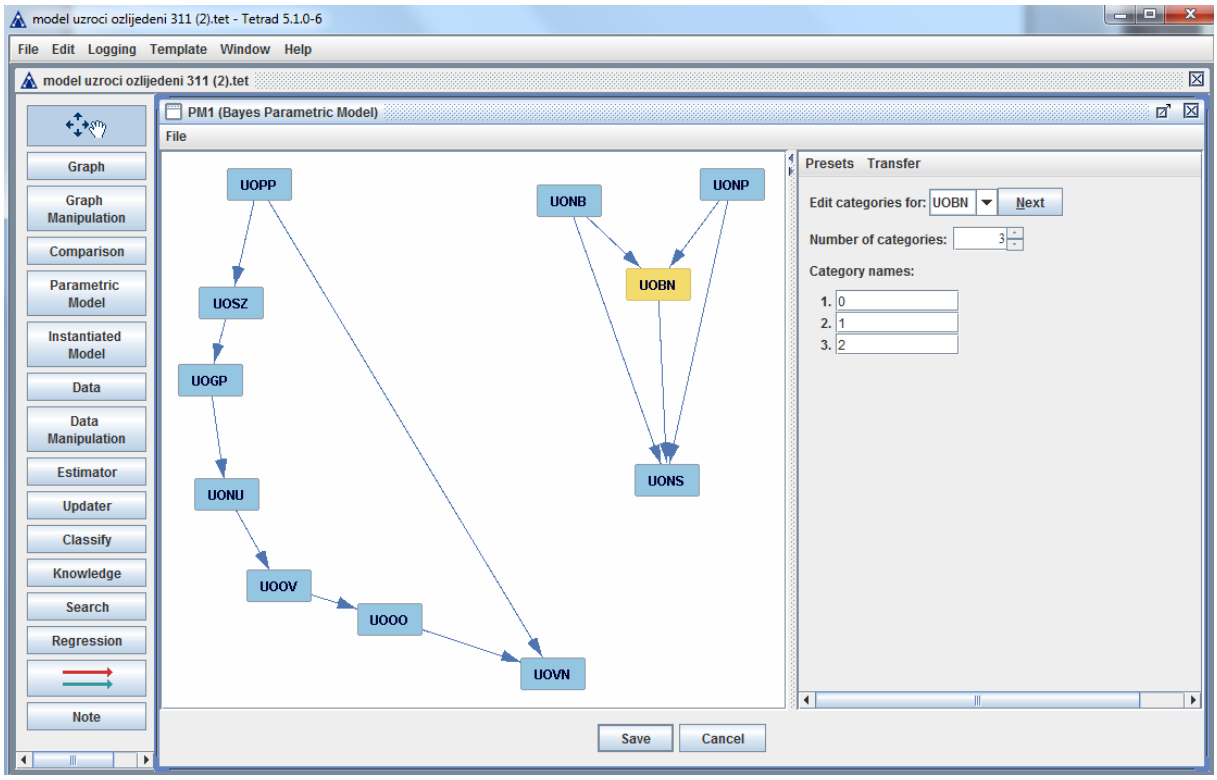

Slika 5. Bayesova struktura i parametri modela – Model 2

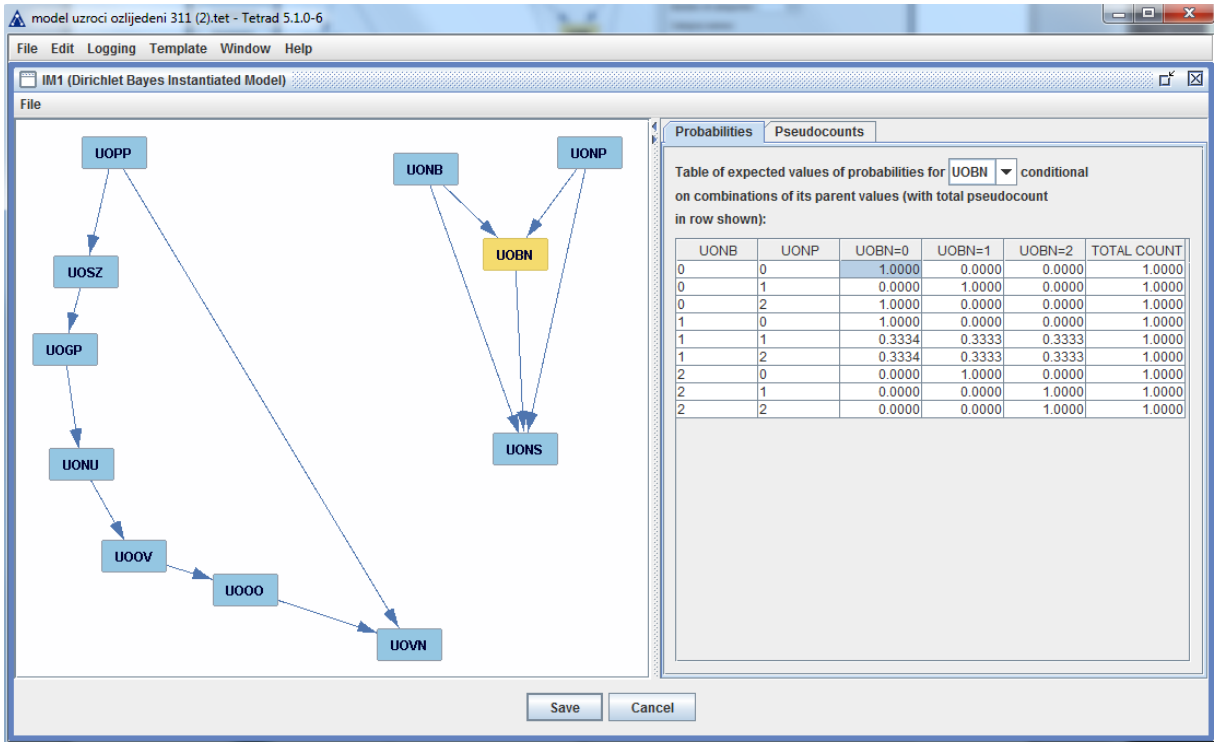

UONB	UONP	UOBN=0	UOBN=1	UOBN=2	TOTAL COUNT
0	0	1.0000	0.0000	0.0000	1.0000
0	1	0.0000	1.0000	0.0000	1.0000
0	2	1.0000	0.0000	0.0000	1.0000
1	0	1.0000	0.0000	0.0000	1.0000
1	1	0.3334	0.3333	0.3333	1.0000
1	2	0.3334	0.3333	0.3333	1.0000
2	0	0.0000	1.0000	0.0000	1.0000
2	1	0.0000	0.0000	1.0000	1.0000
2	2	0.0000	0.0000	1.0000	1.0000

Slika 6. Bayesov model djelovanja – Model 2

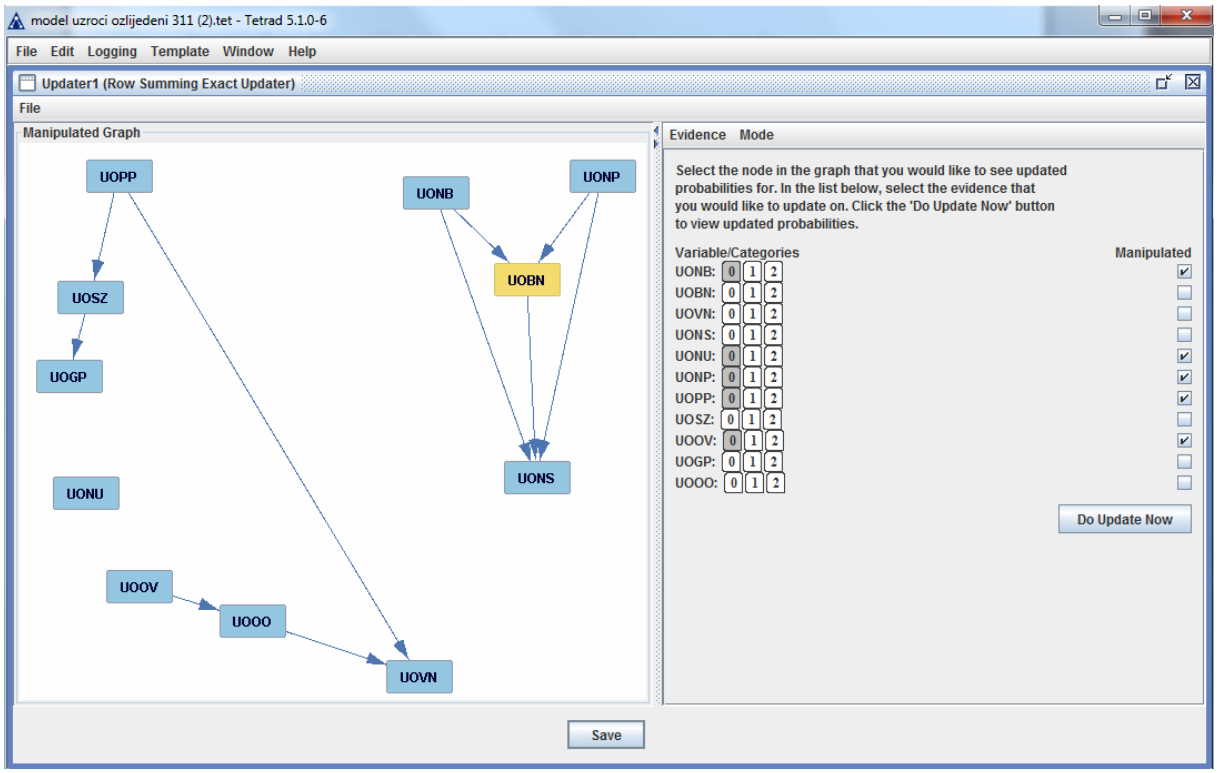

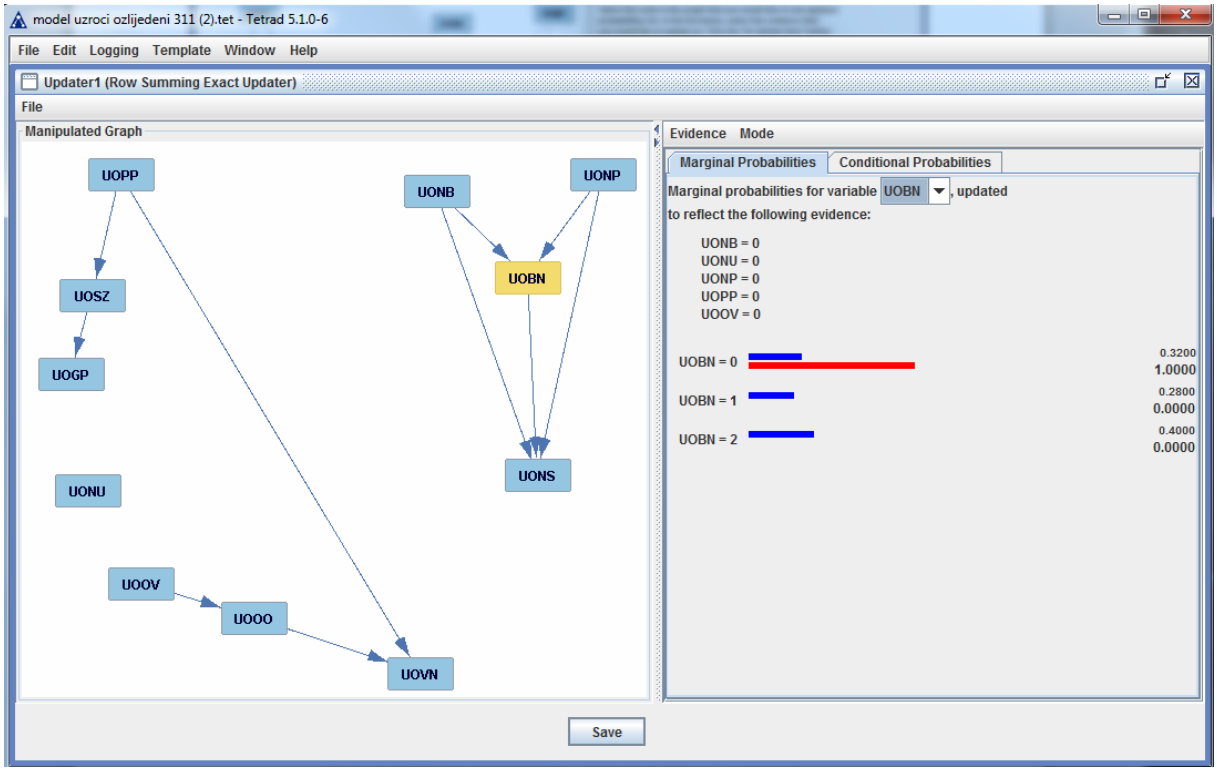

Slika 7. Grafički prikazi provedbe simulacije modela – Model 2

PRILOG 6. Kauzalni model vrsta CPN-a ovisno o broju registriranih CPN-a (Model 3)

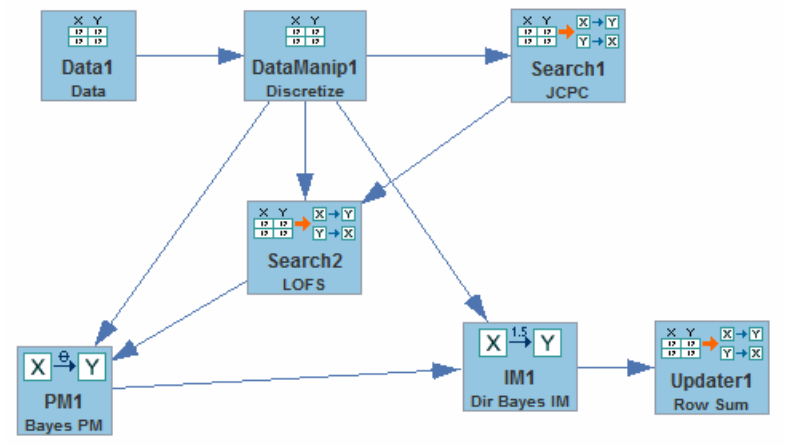

Slika 1. Kauzalni model vrsta CPN-a – Model 3

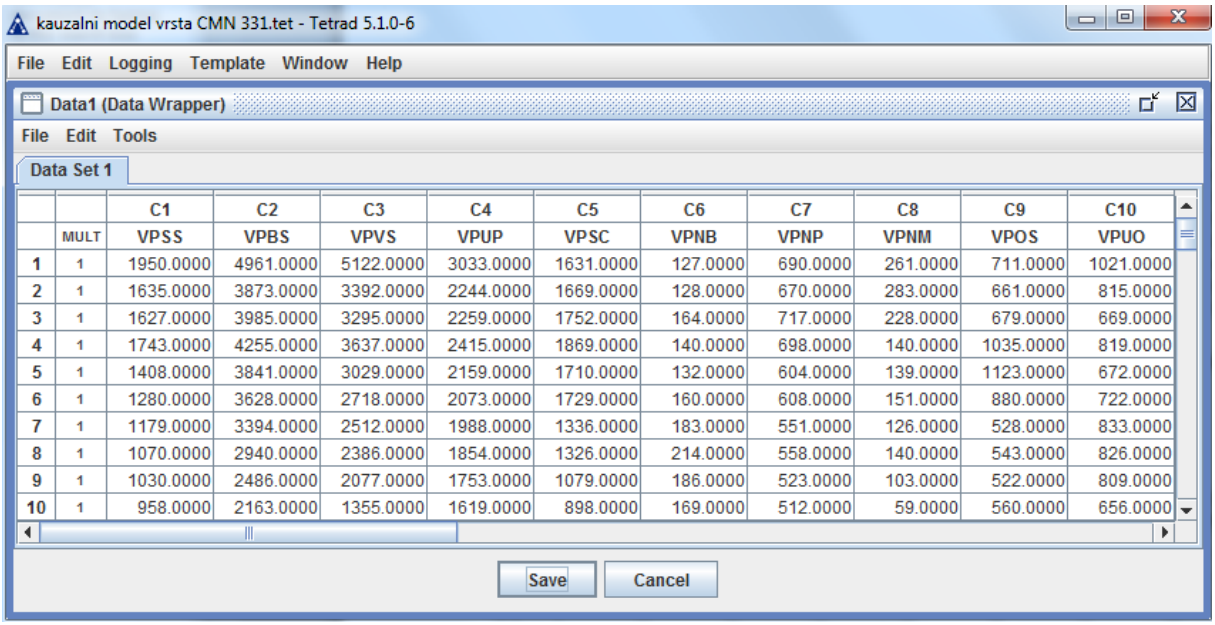

		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
	MULT	VPSS	VPBS	VPVS	VPUP	VPSC	VPNB	VPNP	VPNM	VPOS	VPUO
1	1	1950.0000	4961.0000	5122.0000	3033.0000	1631.0000	127.0000	690.0000	261.0000	711.0000	1021.0000
2	1	1635.0000	3873.0000	3392.0000	2244.0000	1669.0000	128.0000	670.0000	283.0000	661.0000	815.0000
3	1	1627.0000	3985.0000	3295.0000	2259.0000	1752.0000	164.0000	717.0000	228.0000	679.0000	669.0000
4	1	1743.0000	4255.0000	3637.0000	2415.0000	1869.0000	140.0000	698.0000	140.0000	1035.0000	819.0000
5	1	1408.0000	3841.0000	3029.0000	2159.0000	1710.0000	132.0000	604.0000	139.0000	1123.0000	672.0000
6	1	1280.0000	3628.0000	2718.0000	2073.0000	1729.0000	160.0000	608.0000	151.0000	880.0000	722.0000
7	1	1179.0000	3394.0000	2512.0000	1988.0000	1336.0000	183.0000	551.0000	126.0000	528.0000	833.0000
8	1	1070.0000	2940.0000	2386.0000	1854.0000	1326.0000	214.0000	558.0000	140.0000	543.0000	826.0000
9	1	1030.0000	2486.0000	2077.0000	1753.0000	1079.0000	186.0000	523.0000	103.0000	522.0000	809.0000
10	1	958.0000	2163.0000	1355.0000	1619.0000	898.0000	169.0000	512.0000	59.0000	560.0000	656.0000

Slika 2. Ulazni podaci strukturirani u potprogramu *Data Box* računalnog programa *Tetrad* – Model 3

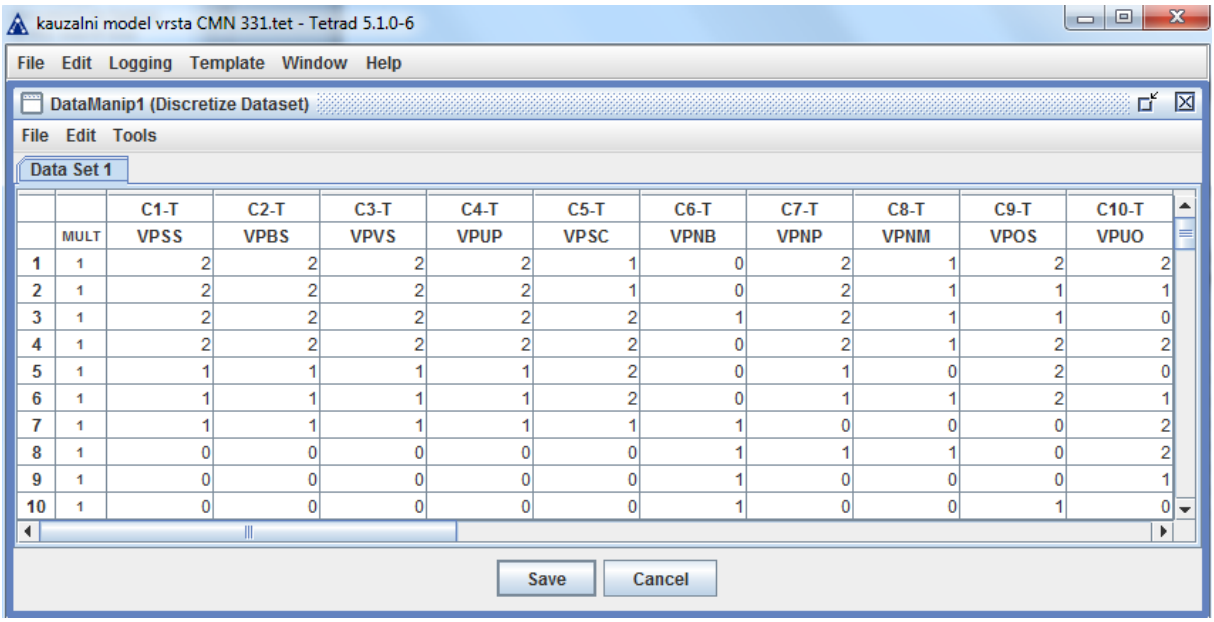

		C1-T	C2-T	C3-T	C4-T	C5-T	C6-T	C7-T	C8-T	C9-T	C10-T
	MULT	VPSS	VPBS	VPVS	VPUP	VPSC	VPNB	VPNP	VPNM	VPOS	VPUO
1	1	2	2	2	2	1	0	2	1	2	2
2	1	2	2	2	2	1	0	2	1	1	1
3	1	2	2	2	2	2	1	2	1	1	0
4	1	2	2	2	2	2	0	2	1	2	2
5	1	1	1	1	1	2	0	1	0	2	0
6	1	1	1	1	1	2	0	1	1	2	1
7	1	1	1	1	1	1	1	0	0	0	2
8	1	0	0	0	0	0	1	1	1	0	2
9	1	0	0	0	0	0	1	0	0	0	1
10	1	0	0	0	0	0	1	0	0	1	0

Slika 3. Digitalizacija ulaznih podataka – Model 3

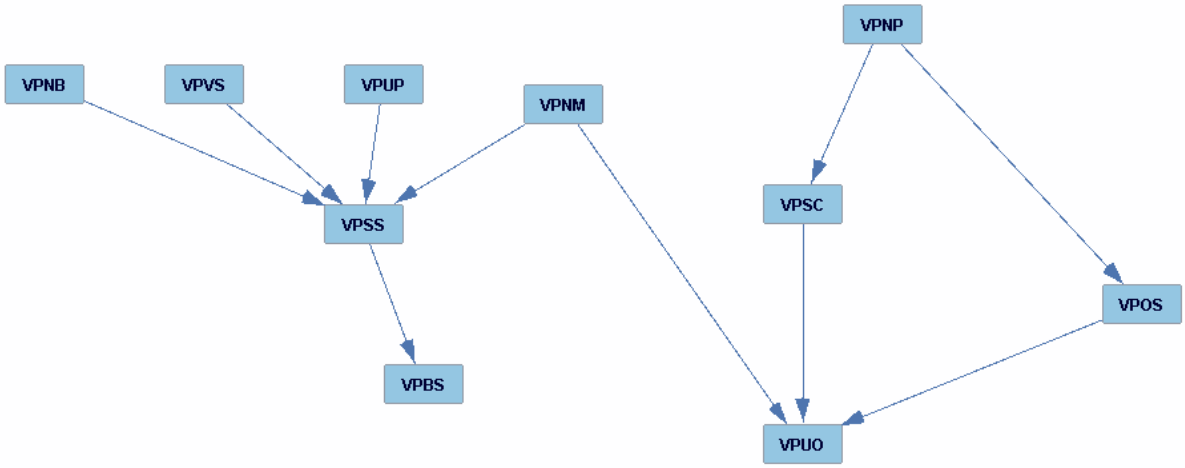

Slika 4. Kauzalna struktura – Model 3

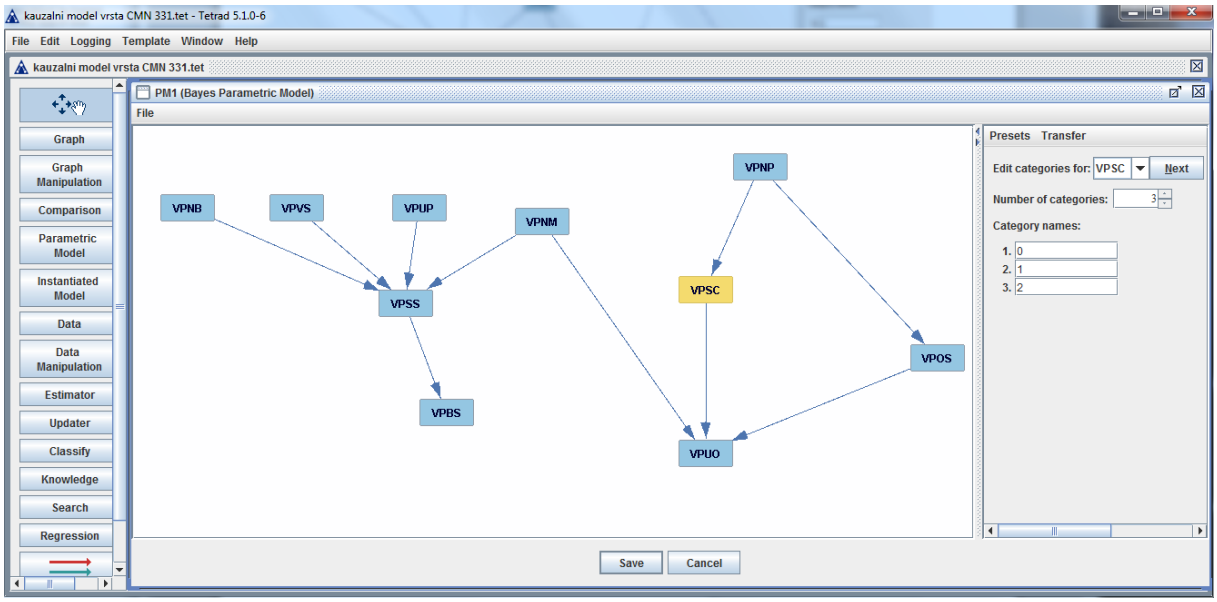

Slika 5. Bayesova struktura i parametri modela – Model 3

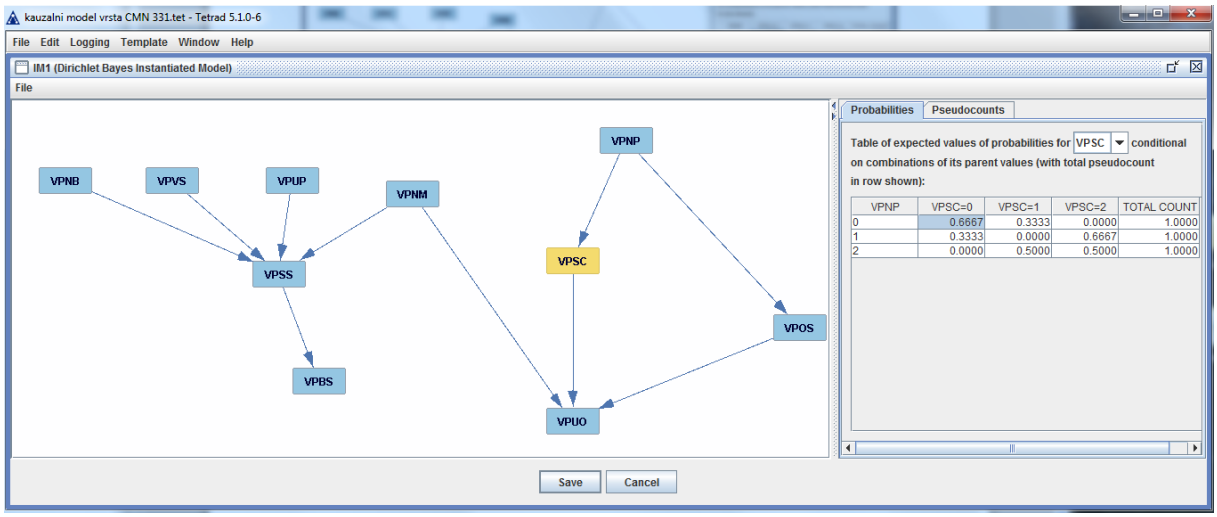

Slika 6. Bayesov model djelovanja – Model 3

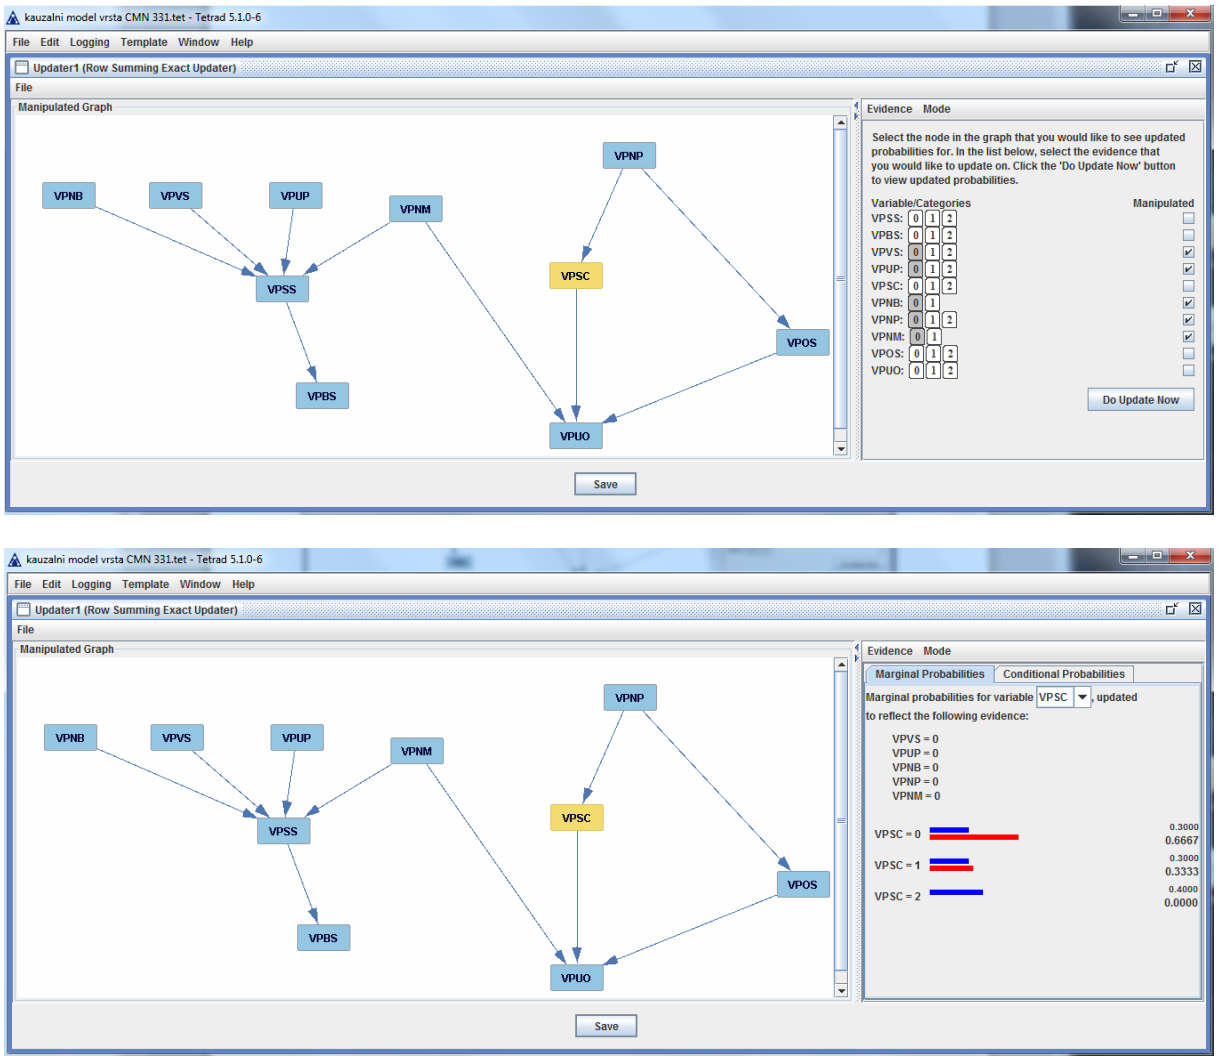

Slika 7. Grafički prikazi provedbe simulacije modela – Model 3

PRILOG 7. Kauzalni model vrsta CPN-a ovisno o broju teško/lako ozlijeđenih sudionika u prometu (Model 4)

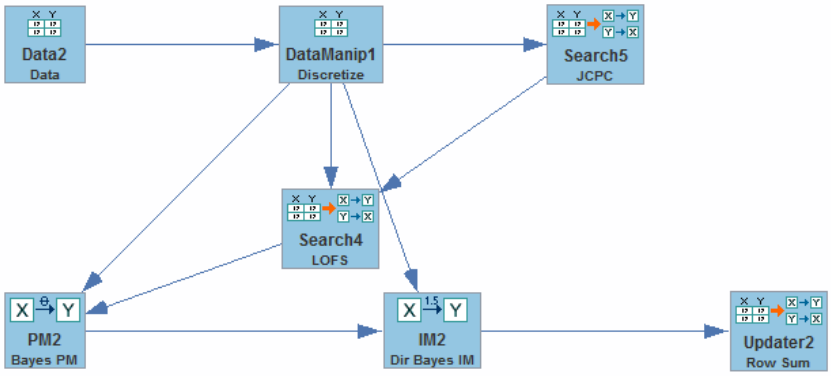

Slika 1. Kauzalni model uzroka CPN-a – Model 4

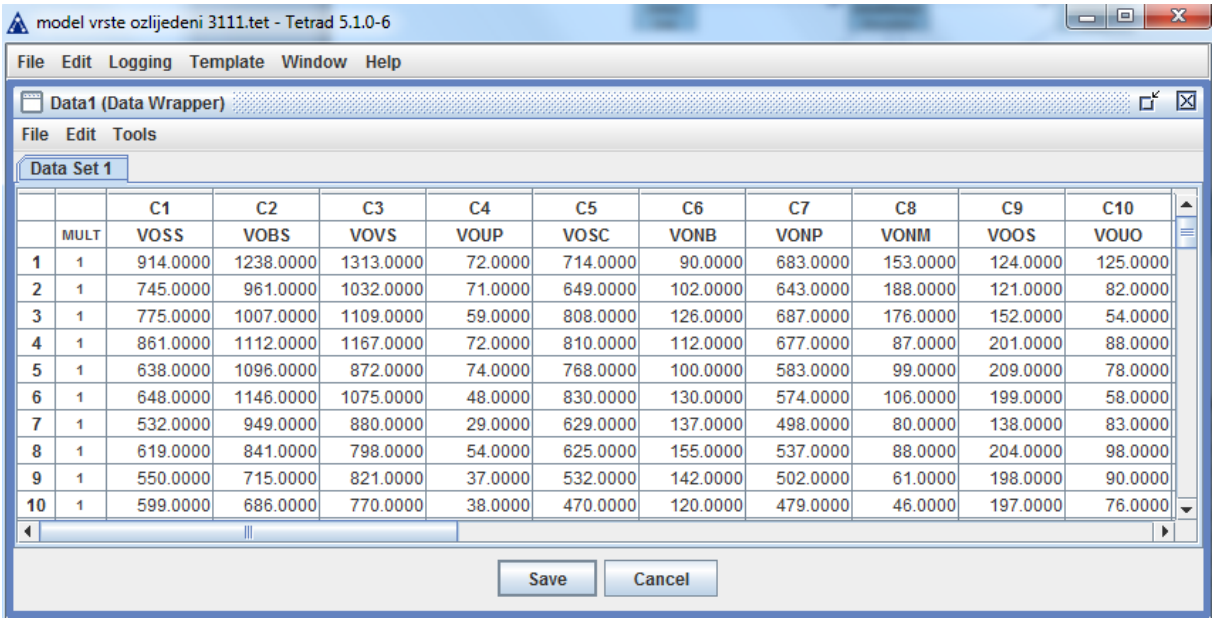

		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
	MULT	VOSS	VOBS	VOVS	VOUP	VOSC	VONB	VONP	VONM	VOOS	VOUO
1	1	914.0000	1238.0000	1313.0000	72.0000	714.0000	90.0000	683.0000	153.0000	124.0000	125.0000
2	1	745.0000	961.0000	1032.0000	71.0000	649.0000	102.0000	643.0000	188.0000	121.0000	82.0000
3	1	775.0000	1007.0000	1109.0000	59.0000	808.0000	126.0000	687.0000	176.0000	152.0000	54.0000
4	1	861.0000	1112.0000	1167.0000	72.0000	810.0000	112.0000	677.0000	87.0000	201.0000	88.0000
5	1	638.0000	1096.0000	872.0000	74.0000	768.0000	100.0000	583.0000	99.0000	209.0000	78.0000
6	1	648.0000	1146.0000	1075.0000	48.0000	830.0000	130.0000	574.0000	106.0000	199.0000	58.0000
7	1	532.0000	949.0000	880.0000	29.0000	629.0000	137.0000	498.0000	80.0000	138.0000	83.0000
8	1	619.0000	841.0000	798.0000	54.0000	625.0000	155.0000	537.0000	88.0000	204.0000	98.0000
9	1	550.0000	715.0000	821.0000	37.0000	532.0000	142.0000	502.0000	61.0000	198.0000	90.0000
10	1	599.0000	686.0000	770.0000	38.0000	470.0000	120.0000	479.0000	46.0000	197.0000	76.0000

Slika 2. Ulazni podatci strukturirani u potprogramu *Data Box* računalnog programa *Tetrad* – Model 4

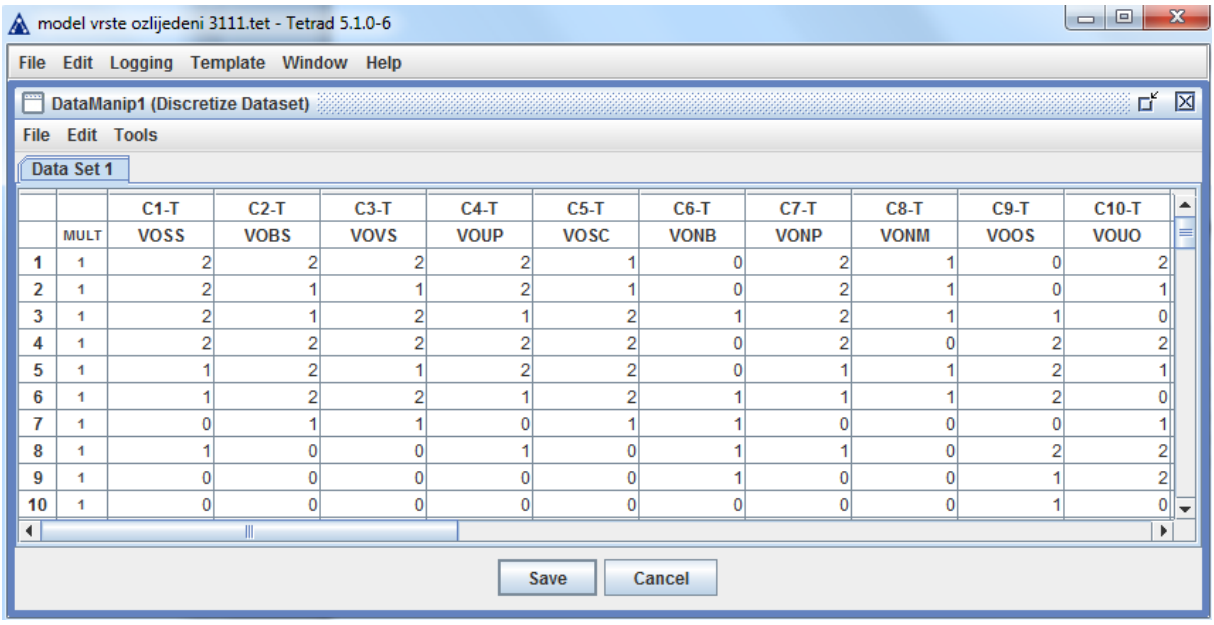

		C1-T	C2-T	C3-T	C4-T	C5-T	C6-T	C7-T	C8-T	C9-T	C10-T
	MULT	VOSS	VOBS	VOVS	VOUP	VOSC	VONB	VONP	VONM	VOOS	VOUO
1	1	2	2	2	2	1	0	2	1	0	2
2	1	2	1	1	2	1	0	2	1	0	1
3	1	2	1	2	1	2	1	2	1	1	0
4	1	2	2	2	2	2	0	2	0	2	2
5	1	1	2	1	2	2	0	1	1	2	1
6	1	1	2	2	1	2	1	1	1	2	0
7	1	0	1	1	0	1	1	0	0	0	1
8	1	1	0	0	1	0	1	1	0	2	2
9	1	0	0	0	0	0	1	0	0	1	2
10	1	0	0	0	0	0	0	0	0	1	0

Slika 3. Digitalizacija ulaznih podataka – Model 4

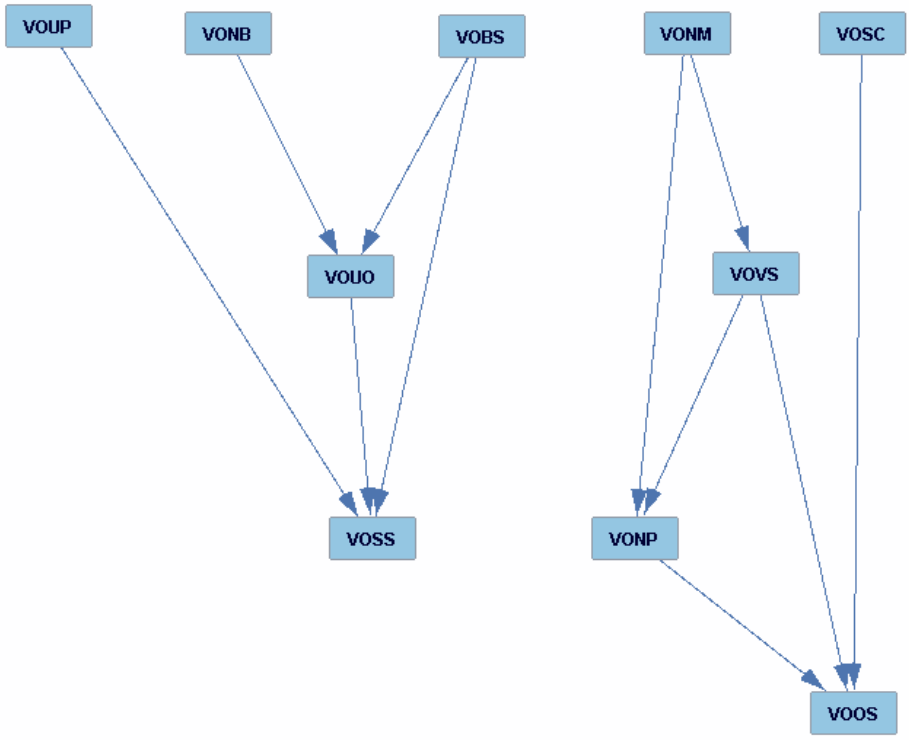

Slika 4. Kauzalna struktura – Model 4

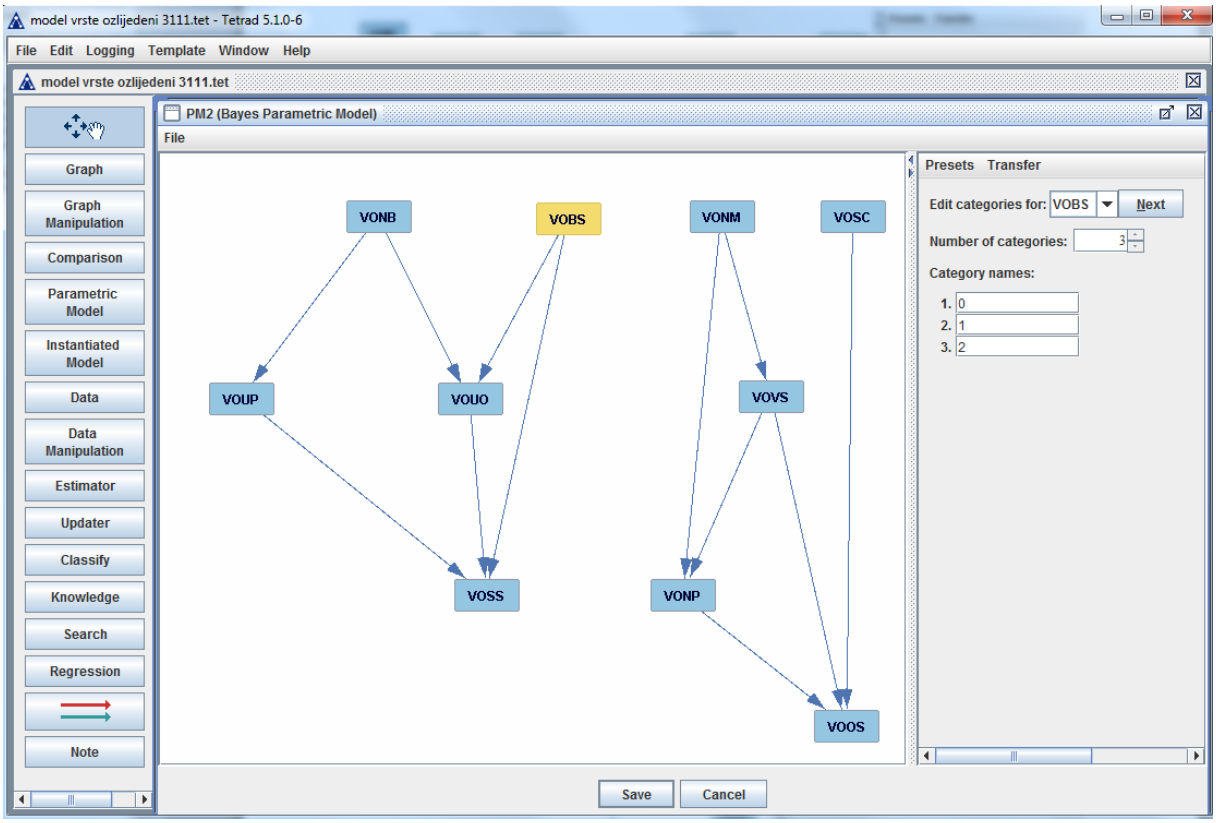

Slika 5. Bayesova struktura i parametri modela – Model 4

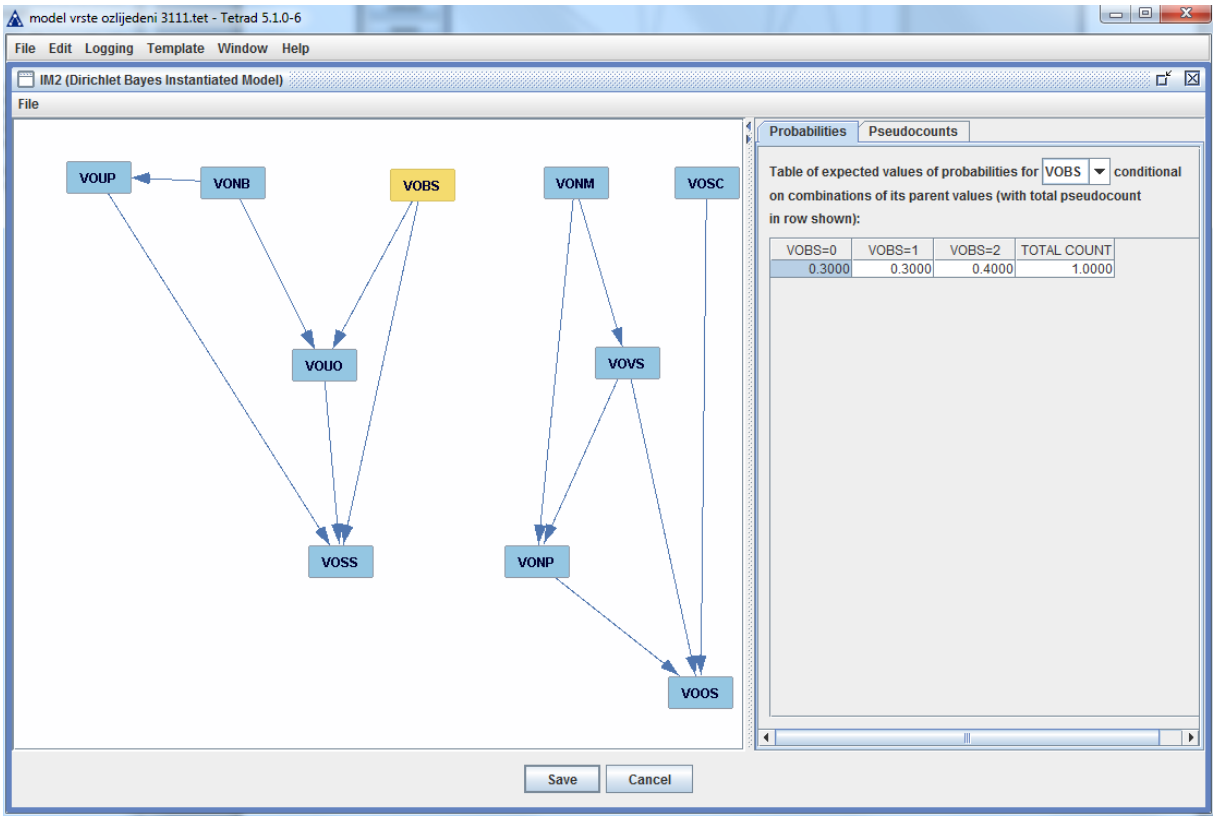

Slika 6. Bayesov model djelovanja – Model 4

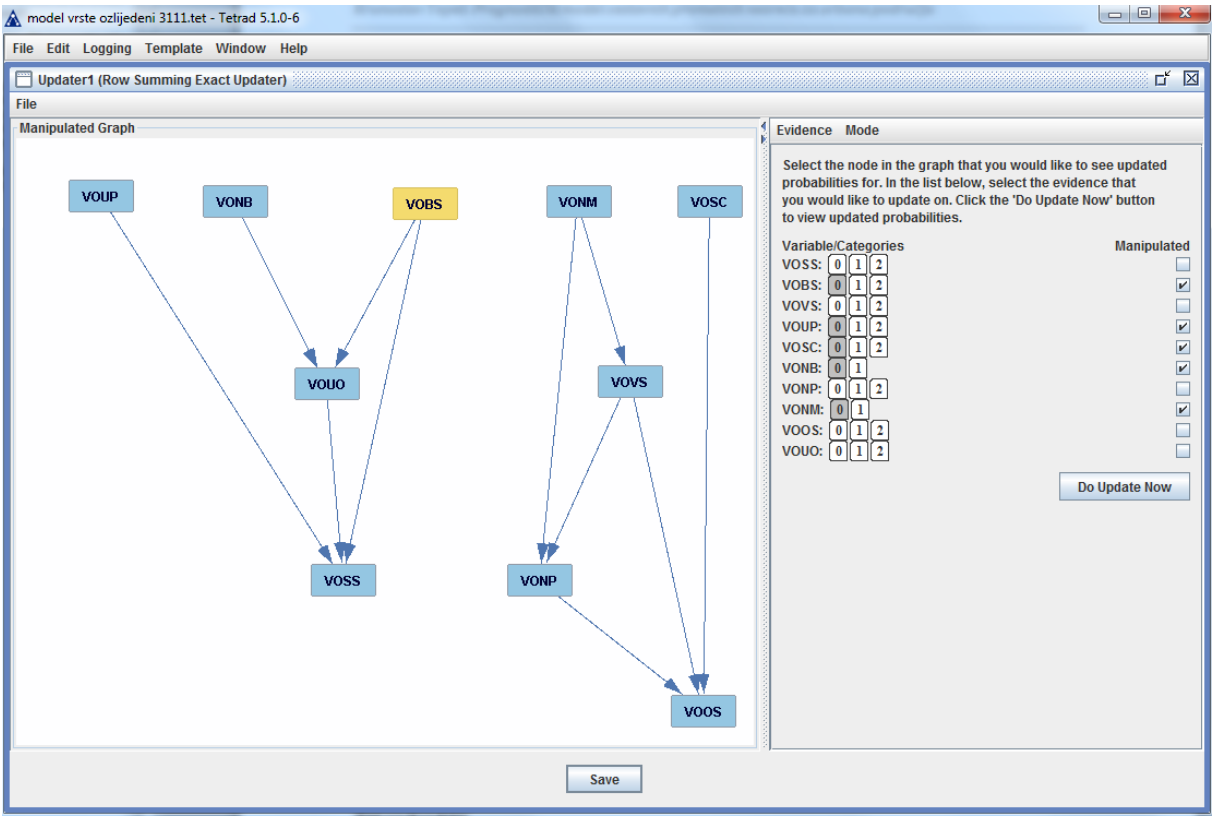

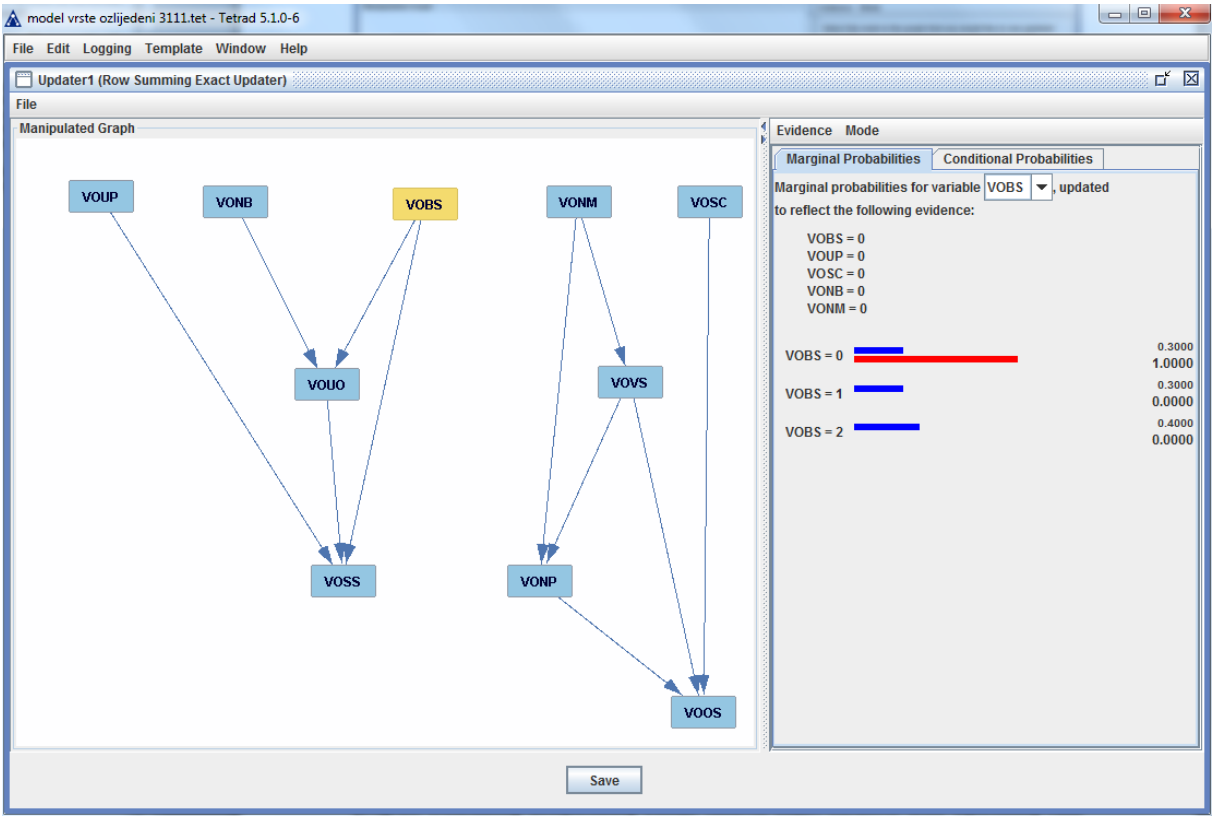

Slika 7. Grafički prikazi provedbe simulacije modela – Model 4

ŽIVOTOPIS

Profesionalni status

Krunoslav Tepeš rođen je 8. veljače 1983. godine u Zagrebu, gdje je završio osnovnu i srednju (X. gimnazija „Ivan Supek“) školu. Godine 2006. na Fakultetu prometnih znanosti završio je program sveučilišnoga dodiplomskog studija, cestovni smjer, obranivši diplomski rad pod nazivom *Elementi vještačenja cestovno-prometnih nesreća*. Godine 2007. na Fakultetu prometnih znanosti upisuje Poslijediplomski doktorski studij "Tehnološki sustavi u prometu i transportu“. Autor je više domaćih i međunarodnih radova vezanih uz gradski promet i sigurnost cestovnoga prometnog sustava te je sudionik znanstvenih i stručnih skupova. Obavio je više revizija prometno-tehnoloških projekata i studija te aktivno sudjelovao u izradi idejnih i izvedbenih projektnih rješenja.

Kretanje u struci

Nakon obavljenoga pripravničkog staža 2009. godine zapošljava se u Gradu Zagrebu, Gradskom uredu za prostorno uređenje, izgradnju grada, graditeljstvo, komunalne poslove i promet, Odjelu za promet. Obnaša dužnost stručnoga suradnika te obavlja više poslova i zadataka vezanih uz tehničku regulaciju i sigurnost cestovnoga prometa, vođenje prometnih tokova, uređenja biciklističkoga prometa te provođenje režima stacionarnoga prometa.

Godine 2012. u Odjelu za planiranje i upravljanje prometom, Odsjeku za semaforizaciju i AUP-om, raspoređen je na mjesto stručnoga savjetnika za pripremu i kontrolu upravljačkih uređaja i programa AUP-a, na kojem obavlja složene poslove nadzora signalnih uređaja i opreme na semaforiziranim raskrižjima. Predlaže rješenja za inoviranje programa semaforskih sustava i njihovo povezivanje, izmjene i dopune opreme semaforskih sustava te druge vidove svjetlosne prometne regulacije radi povećanja sigurnosti prometa.

Unutar Sektora za promet imenovan je za Voditelja odjela za organizacija i upravljanje prometom. Obavlja poslove vezane uz svjetlosnu prometnu signalizaciju, izdavanje odobrenja, suglasnosti i mišljenja te organizaciju javnoga gradskog, cestovnog i autotaksi prometa.

Godine 2015. imenovan je za Pomoćnika pročelnika Sektora za ceste, unutar kojega se obavljaju poslovi vezani za upravljanje i održavanje cesta i cestovnih objekata, izgradnju i rekonstrukciju cesta te poslovi vezani uz prikupljanje podataka za formiranje baze podataka nerazvrstanih cesta i cestovnih objekata, odnosno jedinstvene baze podataka o nerazvrstanim cestama. Njegovo je šire područje interesa planiranje i upravljanje prometom te prometna sigurnost.

Uključen je u kandidiranje i pripremu gradskih prometnih projekata za strukturne i kohezijske fondove Europske unije vezano uz Integrirani putnički prijevoz putnika, Master plan prometnog sustava Grada Zagreba, Zagrebačke županije i Krapinsko-zagorske županije te Uvođenje sustava automatskog upravljanja prometom Grada Zagreba u svrhu povećanja urbane mobilnosti.

Sudjelovanje u projektima

- Prometna analiza i unaprjeđenje sigurnosti i protočnosti oblikovnosti i sigurnosti u raskrižjima s kružnim tokom prometa, Studija – konzultant
- MOBILE 2020 – Projekt Porast biciklizma u malim i srednje velikim gradovima Srednje i Istočne Europe do 2020. godine, član radne skupine
- Sektorska strategija za javnu gradsku prigradsku i regionalnu mobilnost Grada Zagreba, član radne skupine
- Razvoj planova održive urbane mobilnosti, 2013. – 2014., Sveučilište u Zagrebu, Fakultet prometnih znanosti, član projektnog tima
- Dijalog o mobilnosti u Zagrebu – Uspostava suradnje između građana, udruga i Grada Zagreba za osiguravanje boljih prometnih rješenja kao lokalnoga javnog dobra, ref. broj: EuropeAid/135874/ACT/ID/HR – Building Local Partnerships for Open Governance and Fight against Corruption in Responsible Management of Natural Resources, član projektnog tima
- Utjecaj oštećenja betona na koroziju armature – kompjutorske simulacije i ponašanje mostova u uporabi, Program znanstvene suradnje - Potpora "Moja prva suradnja" (1C) Fonda "Jedinstvo uz pomoć znanja" (Unity through Knowledge Fund – UKF) koji djeluje u okviru Hrvatske zaklade za znanost, član projektnog tima

Vještine

Edukacijski seminari vezani uz pripremu gradskih projekata za sufinanciranje iz strukturnih i kohezijskih fondova EU-a te završen specijalistički program izobrazbe u području javne nabave (certifikat).

Aktivno sudjelovao u pripremi i reviziji više idejnih i izvedbenih projektnih prometnih rješenja, studija i planova na području Grada Zagreba.

Popis radova

- ***Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom***

[1.] Pilko, Hrvoje; Brezina, Tadej; Tepeš, Krunoslav. Did Cycling Policy and Programs Advance Cycling in the City of Zagreb? // *Road and Rail Infrastructure IV* / Lakušić, Stjepan (ur.). Zagreb : Department of Transportation, Faculty of civil Engineering, University of Zagreb, 2016. 379-385 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[2.] Tepeš, Božidar; Lešin, Gordana; Hrkač, Ana; Tepeš, Krunoslav. Causal Bayes Model of Mathematical Competence in Kindergarten. // *Journal of systemics, cybernetics and informatics*. 14 (2016) , 3; 14-17 (članak, znanstveni).

[3.] Pilko, Hrvoje; Tepeš, Krunoslav; Brezina, Tadej. Politika i programi razvoja biciklizma u Gradu Zagrebu – kritički osvrt. // *Promet – Traffic & Transportation*. 27 (2015), 5; 405-415 (prethodno priopćenje, znanstveni).

[4.] Tepeš, Božidar; Šimović, Vladimir; Tepeš, Krunoslav. A Note on Modeling of Mathematical Competences // *13th Hawaii International Conference on Education*, January 5-8, 2015, Proceedings Book. Honolulu, USA, 2015. 389-393 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[5.] Brčić, Davor; Tepeš, Krunoslav; Šojat, Dino. Accident Prediction Models in the Scope or Road Safety Improvements // *International Conference "Road safety strategic management"* / Lipovac, Krsto ; Vešović, Vujadin (ur.). Berane : Faculty for Traffic, Communications and Logistics Berane, 2014. 41-53 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[6.] Brčić, Davor; Zovak, Goran; Tepeš, Krunoslav. Comparison of Analysis of Road Traffic Safety in te City of Zagreb and Republic of Croatia // *12th International Symposium Proceedings Road Accident Prevention 2014* / Vujanić, Milan (ur.). Novi Sad : Faculty of Tehnical Sciences Novi Sad, 2014. 29-37 (predavanje,međunarodna recenzija, objavljeni rad, znanstveni).

[7.] Tepeš, Božidar; Šimović, Vladimir; Tepeš, Krunoslav. Causal Model of Mathematical Competences in Kinderegarten // *International Teacher Education Conference*, February 5-7, 2014, Proceedings Book / Ilhan, Ayse Cakir ; Isman, Aytekin ; Birol, Cem ; Eskicumali (ur.). Dubai, UAE, 2014. 102-107 (predavanje,međunarodna recenzija, objavljeni rad, znanstveni).

[8.] Tepeš, Krunoslav; Brčić, Davor; Šojat, Dino. Comparative Analysis of Road Accident Databases For Creating a High-Quality Accident Prediction Model *// Road Safety in Local Community* / Lipovac, Krsto ; Nešić, Miladin (ur.). Zaječar : Academy of Cirminalistic and Police Studies, 2014. 57-64 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[9.] Brčić, Davor; Ćosić, Mario; Tepeš, Krunoslav. An overview of tram safety in the City of Zagreb // *Planning and development of sustainable transport system - ZIRP 2013* / Pavlin, Stanislav ; Šafran, Mario (ur.). Zagreb : Fakultet prometnih znanosti, 2013. 68-76 (međunarodna recenzija, objavljeni rad, znanstveni).

[10.] Brčić, Davor; Šimunović, Ljupko; Tepeš, Krunoslav. Pedestrian safety in the City of Zagreb // IV International Conference "Towards a human City", *Transport in cities of Southeastern Europe* / Bogdanović, Vuk (ur.). Novi Sad, Srbija : Department for traffic engineering - Faculty of technical sciences, University of Novi Sad, 2013. 487-494 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[11.] Matoš, Stipan; Tepeš, Krunoslav. Primjena modela integriranog javnog prijevoza putnika i njegov utjecaj na prilagodbu organizacijsko logističke strukture HŽ-a // *The Second B&H Congress on Railways*. 2013. 329-338 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[12.] Ključarić, Marijan; Tepeš, Krunoslav; Pilko, Hrvoje. Program for Development of Bicycle Traffic in the City of Zagreb // *Proceedings of the 2nd International Conference on Road and Rail Infrastructure - CETRA 2012* / Lakušić, Stjepan (ur.). Zagreb : Department of Transportation, Faculty of Civil Engineering, University of Zagreb, 2012. 899-905 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[13.] Šubić, Nikola; Pilko, Hrvoje; Tepeš, Krunoslav. Application of Crash Prediction Models for Roundabouts in the City of Zagreb // *Conference proceedings Transport, Maritime and Logistics Science*, 15th ICTS 2012 / Zanne, Marina ; Bajec, Patricija (ur.). Portorož : Fakulteta za pomorstvo in promet, 2012. 1-12 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[14.] Tepeš, Krunoslav; Bingula, Zoran; Legac, Goran. Possibilities and benefits of automated garage parking systems regarding fulfillment of parking demands of residential and business facilities // *Under City, Proceedings of the Colloquium on Using Underground Space in Urban Areas in South-East Europe* / Kolić, Davorin (ur.). - Zagreb : Croatian Society for Concrete Engineering and Construction Technology , 2012. 395-405. 2012. 395-405 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[15.] Franc, Tomislav; Šuker, Ivan; Tepeš, Krunoslav. Logistic model of collection bulkey waste in cities // *Logistic and intellignet transport technologies - opportunities for a new economic upturn*. 2009. 86-95 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

[16.] Tepeš, Božidar; Mijić, Ivan; Tepeš, Krunoslav. Two Statistical Models on European and Croatian Information Society // *INFuture2009 Digital Resources and Knowledge Sharing* / H. Stančić, S. Seljan, D. Bawden, J. Lasić-Lazić, A. Slavić (ur.). Zagreb : Department of Information Sciences, Faculty of Humanities and Social Sciences, 2009. 607-613 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

- ***Drugi radovi u zbornicima skupova s recenzijom***

[1.] Brčić, Davor; Tepeš, Krunoslav. Modeli predikcije cestovnih prometnih nesreća te mogućnosti primjene u Republici Hrvatskoj //. *Kongres o cestama 2015* / Šimun, Miroslav (ur.), Zagreb, Hrvatsko društvo za ceste VIA VITA, 2015. 66-66 (predavanje, domaća recenzija, sažetak, znanstveni)

[2.] Legac, Ivan; Ključarić, Marijan; Pilko, Hrvoje; Tepeš, Krunoslav. Sigurnost prometa u kružnim raskrižjima grada Zagreba - preliminarna iskustva // *Ceste 2010*. Zagreb : TIPKO, 2010. 55-65 (predavanje, domaća recenzija, objavljeni rad, znanstveni).

[3.] Tepeš, Božidar; Mijić, Ivan; Tepeš, Krunoslav. Causal Modeling on Croatian Information Society // First Part of the Pre-Conference Proceedings of the Special Focus Symposium on 10th ICESKS: *Information, Communication, and Economic Sciences in the Knowledge Society*. 2010. 231-233 (predavanje, međunarodna recenzija, objavljeni rad).

[4.] Ključarić, Marijan; Tepeš, Krunoslav. Pregled aktivnosti Gradske uprave Grada Zagreba na području sigurnosti prometa // *Sigurnost prometa na cestama Hrvatske, Aktualno stanje i planovi za razdoblje 2010.-2015*. 2009. 71-77 (predavanje, domaća recenzija, objavljeni rad, stručni).

[5.] Legac, Ivan; Pilko, Hrvoje; Tepeš, Krunoslav. Istraživanje oblikovne i sigurnosne komponente kružnih raskrižja u Hrvatskoj // *Zbornik radova Ceste 2009*. TIPKO, Zagreb, 2009. 39-50 (predavanje, domaća recenzija, objavljeni rad, stručni).