

Kontekstualna analiza prometnih nesreća pješaka i biciklista u urbanim sredinama

Ćosić, Mario

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:119:501664>

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

Download date / Datum preuzimanja: **2024-04-20**



Repository / Repozitorij:

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





Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

Mario Ćosić

**KONTEKSTUALNA ANALIZA
PROMETNIH NESREĆA PJEŠAKA I
BICIKLISTA U URBANIM SREDINAMA**

DOKTORSKI RAD

Zagreb, 2017.



Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

Mario Ćosić

**KONTEKSTUALNA ANALIZA
PROMETNIH NESREĆA PJEŠAKA I
BICIKLISTA U URBANIM SREDINAMA**

DOKTORSKI RAD

Mentor:

dr. sc. Ljupko Šimunović, izv. prof.

Zagreb, 2017.



University of Zagreb

FACULTY OF TRANSPORT AND TRAFFIC SCIENCES

Mario Ćosić

**CONTEXT-AWARE ANALYSIS OF ROAD
ACCIDENTS INVOLVING PEDESTRIANS
AND CYCLISTS IN URBAN
ENVIRONMENT**

DOCTORAL THESIS

Supervisor:

Assoc. Prof. Ljupko Šimunović

Zagreb, 2017.

PODATCI I INFORMACIJE O DOKTORANDU

1. **Ime i prezime:** Mario Ćosić, dipl. ing. prom.
2. **Datum, mjesto rođenja:** 10. kolovoza 1980., Banja Luka, Bosna i Hercegovina
3. **Naziv završenoga fakulteta i godina diplomiranja:** Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2006.

INFORMACIJE O DOKTORSKOMU RADU

1. **Naziv doktorskoga studija:** Tehnološki sustavi u prometu i transportu
2. **Naslov doktorskog rada:** Kontekstualna analiza prometnih nesreća pješaka i biciklista u urbanim sredinama
3. **Fakultet na kojem je doktorski rad obranjen:** Fakultet prometnih znanosti Sveučilišta u Zagrebu

POVJERENSTVA, OCJENA I OBRANA DOKTORSKA RADA

1. **Datum prijave teme doktorskoga rada:** 5 veljače 2016.
2. **Mentor:** dr. sc. Ljupko Šimunović, izv. prof., Fakultet prometnih znanosti Sveučilišta u Zagrebu
3. **Povjerenstvo za ocjenu i obranu doktorskoga rada:**
 - dr. sc. Davor Brčić, izv. prof., predsjednik
 - dr. sc. Ljupko Šimunović, izv. prof., član
 - dr. sc. Eduard Missoni, prof., član
 - dr. sc. Goran Zovak, izv. prof., član
 - dr. sc. Damir Medak, prof., vanjski član (Geodetski fakultet Sveučilišta u Zagrebu)
 - dr. sc. Dubravka Hozjan, izv. prof., zamjena.
4. **Lektor:** Ljupka Đurić, prof.
5. **Datum obrane doktorskoga rada:** 8. lipnja 2017.

SAŽETAK

U posljednje se vrijeme aktualizira sustavno istraživanje prometnih nesreća u složenom urbanom okružju zbog sve većega broja stradalih pješaka i biciklista. Prometne su nesreće socijalni, javnozdravstveni i politički izazov svake države. U urbanim je sredinama karakteristično intenzivno prometno opterećenje cestovne mreže na kojoj se stalno izmjenjuju različiti prometni uvjeti koji dovode do međusobnih interakcija motoriziranoga i nemotoriziranoga prometa, što predstavlja potencijalnu opasnost za nastanak prometnih nesreća.

Pristup je rješavanju ovoga problema složen. Iako su prometne nesreće s aspekta prostora i vremena slučajni događaji, detaljnom je analizom uspostavljena korelacija između prometnih nesreća i vanjskih čimbenika (prometni, cestovna infrastruktura, vremenski, namjena zemljišta). Statističkim su analizama i grafoanalitičkim metodama identificirana opasna mjesta (žarišta) na cestovnoj prometnoj mreži te su potom definirani i identificirani utjecajni vanjski čimbenici, koji imaju potencijalni utjecaj na nastanak opasnoga mjesta. Primjenjivanjem binarne logističke regresije identificirani su utjecajni vanjski čimbenici funkcijski povezani u kontekstualni model prometnih nesreća pješaka i biciklista. Modelom je testirana statistička važnost kako pojedini utjecajni čimbenici povećaju vjerojatnost nastanka opasnoga mjesta na urbanoj cestovnoj mreži.

Kako je riječ o velikim količinama relacijskih baza podataka, u radu su korišteni specijalizirani računalni programi s podržanim SQL računalnim jezikom za dohvaćanje, stvaranje i mijenjanje dizajna objekata iz baze podataka, QGIS program za upravljanje i mapiranje radi jednostavnijega uočavanja žarišta prometnih nesreća te SPSS program za statističku analizu podataka i izradu modela binarne logističke regresije.

Rezultati će istraživanja poslužiti projektantima i donositeljima odluka za lakše uočavanje žarišta i učinkovito otklanjanje uzroka prometnih nesreća na postojećoj infrastrukturi (reaktivno djelovanje), za izbjegavanje pogrešaka pri projektiranju novih prometnica (preventivno djelovanje), a pješacima i biciklistima kao upozorenje na opasna mjesta i dionice kojima prolaze od izvora do cilja.

Ključne riječi: prometne nesreće pješaka i biciklista, urbana sredina, kontekstualna analiza, binarna logistička regresija

SUMMARY

Systematic research related to road accidents in complex urban environments is being updated lately due to the increasing number of pedestrian and cyclist casualties. Road accidents pose a challenge to every country in terms of society, healthcare and politics. Urban environments are characterized by an intense traffic volume on the road network, where different conditions constantly alternate, resulting with interactions between motorized and non-motorized traffic and possible conditions for road accidents to occur.

The approach to solving the stated problems is complex. Although road accidents are considered as random events in terms of time and space, an in-depth analysis was used to establish relations between road accidents and external factors (traffic parameters, road infrastructure, time parameters, land use). Statistical analysis, graphical and analytical methods were used to identify accident blackspots on road network, and consecutively, to identify external factors that result with a blackspot. By using binary logistic regression, the identified external factors were correlated into a context-aware road accident model for pedestrians and cyclists. The model was used to test statistical significance, in which particular influence factors increase the probability for an accident blackspot to occur on the road network.

Since the analysis is performed on a large amount of relationship databases, specialized computer software supported by SQL programming language for acquiring, creating and changing the design of database objects, QGIS program for managing and mapping for simple accident blackspot detection, and SPSS program for statistical data analysis and developing binary logistic regression were used in the paper.

The results of the research will serve planners and decision makers to simply detect accident blackspots, efficiently eliminate accident causes (as a corrective action) on the existing infrastructure, avoid mistakes in road design (as a preventive action), and to warn pedestrians and cyclists about dangerous spots and sections on their routes from origin to destination.

Key words: road accidents, pedestrians and cyclists, urban environment, contextual analysis, Binomial Logistic Regression

SADRŽAJ

1. UVOD.....	1
1.1. PROBLEM ISTRAŽIVANJA	1
1.2. SVRHA, CILJEVI I ZNANSTVENI DOPRINOS ISTRAŽIVANJA.....	2
1.3. OSVRT NA DOSADAŠNJA ISTRAŽIVANJA	2
1.4. METODOLOŠKI PRISTUP ISTRAŽIVANJU.....	5
1.5. STRUKTURA DOKTORSKOG RADA	6
2. PREGLED STANJA SIGURNOSTI PJEŠAČKOG I BIKIKLISTIČKOG PROMETA.....	9
2.1. OSOBITOSTI PJEŠAČKOGA I BIKIKLISTIČKOGA PROMETNOGA TOKA	9
2.2. ANALIZA STRATEŠKIH DOKUMENATA SIGURNOSTI CESTOVNOGA PROMETA.....	13
2.3. TEORIJA NASTANKA PROMETNIH NESREĆA.....	16
2.4. POKAZATELJI SIGURNOSTI CESTOVNOG PROMETA U EU.....	20
2.5. STANJE SIGURNOSTI CESTOVNOGA PROMETA U REPUBLICI HRVATSKOJ S OSVRTOM NA PJEŠAKE I BIKIKLISTE.....	26
3. PODRUČJE OBUHVATA, PRIKUPLJANJE I OBRADA PODATAKA	33
3.1. PODRUČJE OBUHVATA ISTRAŽIVANJA	33
3.2. PRIKUPLJANJE PODATAKA	35
3.2.1. PRIKUPLJANJE PODATAKA OD MINISTARSTVA UNUTARNJIH POSLOVA REPUBLIKE HRVATSKE	35
3.2.2. PRIKUPLJANJE I OBRADA PODATAKA IZ BAZA GRADA ZAGREBA	40
3.2.3. PRIKUPLJANJE PODATAKA IZ OPENSTREETMAP PROJEKTA.....	46
3.2.4. DODATNO TERENSKO ISTRAŽIVANJE I PRIKUPLJANJE PODATAKA.....	48
3.2.5. OSTALI IZVORI KORISNIH PODATAKA.....	49
3.3. OBRADA BROJENJA PROMETA.....	49
3.4. RAČUNALNI PROGRAMI ZA OBRADU PODATAKA.....	62
3.5. USPOSTAVLJANJE LOKALNE BAZE PODATAKA ZA POTREBE ISTRAŽIVANJA.....	63
4. STATISTIČKA ANALIZA PROMETNIH NESREĆA NA PODRUČJU GRADA ZAGREBA.....	69
4.1. DESKRIPTIVNA STATISTIČKA ANALIZA PODATAKA O PROMETNIM NESREĆAMA.....	70
4.1.1. ANALIZA OPĆIH PODATAKA O PROMETNIM NESREĆAMA	70
4.1.2. ANALIZA PODATAKA O VREMENU I UVJETIMA PRI DOGAĐANJU PROMETNIH NESREĆA	75

4.1.3. ANALIZA PODATAKA O OKRUŽENJU PRI DOGAĐANJU PROMETNIH NESREĆA	78
4.1.4. ANALIZA PODATAKA O CESTOVNOJ INFRASTRUKTURI PRI DOGAĐANJU PROMETNIH NESREĆA.....	79
4.1.5. ANALIZA PODATAKA O PROMETNIM UVJETIMA PRI DOGAĐANJU PROMETNIH NESREĆA	81
4.2. INFERENCIJALNA STATISTIČKA ANALIZA PODATAKA O PROMETNIM NESREĆAMA	84
4.3. DESKRIPTIVNA STATISTIČKA ANALIZA PODATAKA PO GRADSKIM ČETVRTIMA	95
5. IDENTIFIKACIJA ŽARIŠTA I UTJECAJNIH ČIMBENIKA NASTANKA PROMETNIH NESREĆA	99
5.1. METODOLOGIJA DEFINIRANJA OPASNIH MJESTA (ŽARIŠTA)	99
5.2. ANALIZA OPASNIH MJESTA	103
5.3. METODOLOGIJA ODABIRA UTJECAJNIH ČIMBENIKA	111
5.4. ANALIZA UTJECAJNIH ČIMBENIKA	112
5.4.1. KATEGORIJA PROMETNICE	114
5.4.2. SMJERNOST PROMETNICA	116
5.4.3. TIP RASKRIŽJA	117
5.4.4. REGULACIJA PROMETA NA RASKRIŽJIMA	119
5.4.5. OGRANIČENJE BRZINE	120
5.4.6. INTENZITET PROMETNE POTRAŽNJE	121
5.4.7. NAMJENA POVRŠINE	123
5.4.8. RAZDOBLJE U GODINI	125
5.4.9. BIKIKLISTIČKA INFRASTRUKTURA	126
6. IZRADA MODELA LOGISTIČKE REGRESIJE ŽARIŠTA PROMETNIH NESREĆA	128
6.1. BINARNA LOGISTIČKA REGRESIJA	128
6.2. ANALIZA ULAZNIH PODATAKA	130
6.3. MODEL IDENTIFIKACIJE OPASNIH MJESTA ZA PJEŠAČKI PROMET.....	131
6.4. MODEL IDENTIFIKACIJE OPASNIH MJESTA ZA BIKIKLISTIČKI PROMET	135
7. VALIDACIJA MODELA	138
7.1. METODOLOGIJA VALIDACIJE MODELA.....	138
7.2. REZULTATI VALIDACIJE	141
8. ZAKLJUČAK	143
LITERATURA	148
POPIS SLIKA.....	155
POPIS GRAFIKONA	158
POPIS TABLICA.....	161

POPIS PRILOGA	165
POJMOVNIK.....	168
ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA.....	170

1. UVOD

1.1. Problem istraživanja

Velik udio pješaka i biciklista u urbanom prometu, specifične karakteristike i dinamike kretanja pješaka i upravljanja biciklom, nedovoljna edukacija i obučenost pješaka i biciklista, neuređena prometna infrastruktura, stalni porast udjela stupnja motorizacije i manjkav zakonski okvir doprinose tomu da je prometna sigurnost pješaka i biciklista sve veći problem u urbanim sredinama. Iz navedenoga je vidljiv problem sigurnosti ranjivih sudionika, tj. pješaka i biciklista u urbanim sredinama, stoga su mnoge znanstvene aktivnosti usredotočene na istraživanja navedenoga problema. Učinkovito je rješavanje postojećega problema moguće provesti sustavnom i cjelovitom analizom propusta, uzroka i okolnosti koje dovode do prometnih nesreća (PN-a) pješaka i biciklista te provođenjem odgovarajućih mjera zaštite.

U posljednja dva desetljeća u analizama prometnih nesreća važan napredak predstavlja primjena naprednih tehnoloških sustava poput geografskoga informacijskoga sustava (GIS-a) i inteligentnih transportnih sustava (ITS-a). GIS sustav omogućava istraživačima upravljanje raznim podacima prometnih nesreća na jednostavan i učinkovit način dajući pritom mogućnost prikazivanja raspodjele nesreća u prostoru i vremenu. Stoga je posebna pozornost usmjerena na uspostavu baze podataka iz nejedinstvenih izvora prikupljanja podataka te na provedbu prostorne analize prometnih nesreća pješaka i biciklista u GIS okružju. Važnost analize prostornih podataka leži u atributima i njihovim vezama. S pomoću primjene GIS tehnologije moguće je uočiti veze pojava u prostoru koje su teško razumljive, odnosno teško usporedive s neprostornom bazom podataka. Dosadašnji razvoj GIS alata i tehnologija zasnovanih na globalnom pozicijskom sustavu (engl. *Global Positioning System* – GPS) omogućuje prometnim stručnjacima da uz pomoć dubinskih prostornih analiza dobivaju važne informacije o uzrocima nastanka cestovnih prometnih nesreća. Dubinska analiza pruža brojne informacije o opasnim mjestima na cestovnoj prometnoj mreži i na žarištima cestovnih prometnih nesreća. Takav pristup omogućava bolje razumijevanje uzroka nastanka prometnih nesreća, identifikaciju područja (mjesta) s povećanim rizikom nastanka prometnih nesreća te predlaganje odgovarajućih protumjera kako bi se u konačnici stvorilo sigurno okružje za sve sudionike u prometu te kako bi se povećao i stupanj sigurnosti u cestovnom prometu.

1.2. Svrha, ciljevi i znanstveni doprinos istraživanja

Osnovnim je ciljem istraživanja određivanje korelacije između pojavljivanja prometnih nesreća i vanjskih čimbenika u svrhu jednostavne identifikacije i saniranja opasnih mjesta ili opasnih dionica na cestovnoj prometnoj mreži te mogućnosti prenošenja rješenja na druge gradove.

Hipoteze su istraživanja sljedeće:

- Detaljnom je analizom prometnih nesreća moguće odrediti korelaciju i izraditi model utjecaja vanjskih čimbenika (demografije, namjene zemljišta, parametara prometnoga toka, elemenata i opreme ceste) na prometne nesreće u kojima sudjeluju pješaci i biciklisti.
- Grupiranjem je prometnih nesreća u homogene skupine po vrsti i mjestu nastanka moguće otkriti opasna mjesta (žarišta) i dionice s istim ili sličnim okruženjem u svrhu otklanjanja uzroka prometnih nesreća.

Znanstveni doprinos istraživanja:

- oblikovanje i uspostava postupaka za utvrđivanje žarišta događanja prometnih nesreća s pješacima i biciklistima na temelju kontekstualnoga povezivanja informacija iz nejedinstvenih prostornih baza podataka;
- izrada modela za provedbu kontekstualne analize vanjskih čimbenika i prometnih nesreća s pješacima i biciklistima;
- identifikacija i klasifikacija karakterističnih opasnih mjesta i dionica na pješačkoj i biciklističkoj prometnoj infrastrukturi kao podrška pri donošenju odluka za odabir infrastrukturnih rješenja;
- uspostava kriterija za identifikaciju i vizualizaciju žarišta prometnih nesreća s pješacima i biciklistima.

1.3. Osvrt na dosadašnja istraživanja

Prometne su nesreće velik socijalni i javnozdravstveni problem svake države. One su predmetom analiza mnogih znanstvenih disciplina kao što su medicina, sociologija i prometno-prostorno planiranje. Svaka od ovih disciplina analizira i objašnjava prometne nesreće iz svoje perspektive. [1]

Povezanost društveno-demografskih i društveno-ekonomskih čimbenika te načina života i prometnih nesreća izučavani su u [2]. *Summala* i ostali [3] provode dubinsku analizu pogrešne percepcije vozača automobila. Njihova su istraživanja rezultirala detaljnom analizom kretanja biciklista i vozača te pogreškama u percepciji biciklista i vozača koje su dovele do nesreće. *Noland* i *Quddus* [4] analiziraju utjecaj prometne infrastrukture i demografskih karakteristika prostornih jedinica na prometne nesreće. *LaScala* i ostali [5] proveli su istraživanja na području grada *San Francisca* u vezi s nastankom PN-a pješaka. Rezultati su istraživanja pokazali kako su ozljede pješaka u korelaciji s gustoćom naseljenosti, spolnom i dobnom strukturom lokalnoga stanovništva te sa zaposlenošću i obrazovanjem. *Loo* i *Tsui* [6] istraživali su prostorne analize biciklističkih prometnih nesreća u *Hong Kongu*, pri čemu su utvrdili kako se veći broj PN-a događa u sjevernim rubnim dijelovima grada s većinskim doseljenim stanovništvom koje ima manje prihode.

Raspodjela prometnih nesreća razlikuje se između pojedinih zemalja, ali i okružja u kojem se prometne nesreće događaju. Stopa smrtnosti u prometu u državama Europske unije ukazuje na nižu stopu na sjeveru nego na jugu i nižu na zapadu nego na istoku, što je posljedica različitih prometnih politika u tim zemljama [7]. *Eksler* i *Lassarre* u svom radu [8] prikazuju različite vrijednosti rizika smrtnosti na cestovnim prometnicama unutar pojedine zemlje. Prema statističkim pokazateljima veći se dio prometnih nesreća događa u urbanim sredinama. Neki su od razloga za takvu raspodjelu prometnih nesreća sljedeći: funkcionalne razlike između gradske i izvan gradske mreže, razlike u pogledu dizajna cestovne infrastrukture i obilježja prometa. Gradska je cestovna mreža složenija u odnosu na autoceste i ruralne ceste, gdje uz veću prisutnost pješaka i biciklista postoji veći broj vanjskih utjecajnih čimbenika koji pridonose nastanku prometnih nesreća. Stoga sigurnost prometa u urbanim sredinama treba proučavati u kontekstu okružja. Tako su *Schneider* i ostali [9], *Pulugurtha* i ostali [10] te *Aguero-Valverde* [11] izučavali i identificirali područja s velikim koncentracijama biciklističkih i pješačkih nesreća u urbanom okružju, gdje su analizirali prostorne i fizičke čimbenike koji pridonose nastanku prometnih nesreća. *Inouye* i *Berry* [12] razvijaju prostornu analizu u geografskom informacijskom sustavu (GIS-u), objašnjeno u [13], za procjenu sigurnosti biciklističke mreže. *Siddiqui* i ostali [14] proveli su istraživanje tako da su s pomoću GIS alata usporedili utjecaj korištenja zemljišta i demografskih pokazatelja na prometne nesreće. Istraživanja su pokazala kako urbanizirana i gusto naseljena područja imaju manji broj prometnih nesreća, uz pretpostavku autora kako velika gustoća prometa dovodi do manjih brzina.

Blazquez i *Celis* [15] istražili su identifikaciju žarišta prometnih nesreća u kojima su sudjelovala djeca s pridruženim podacima o okolini. Prostorno-vremenska analiza pokazala je kako se polovica PN-a u kojima sudjeluju djeca događa na raskrižjima u poslijepodnevnim satima pri povratku djece iz škole. *Prasannakumar* i ostali [16] provode slična istraživanja s ciljem identifikacije i analize žarišta prometnih nesreća prouzrokovanih neodgovarajućim razvojem prometne mreže. Rezultati analize prostornih grupiranja prikazuju prostorne i vremenske varijacije žarišta, što potvrđuje da prometne nesreće ovise o vremenskim i prostornim varijablama. Koncentracija prometnih nesreća (žarišta) u istom mjestu može ukazivati na prostorni odnos između prometnih nesreća i okoliša i/ili uvjeta na cesti [17]. Žarišta prometnih nesreća otkrivaju koncentracije istovrsnih nesreća i ukazuju na prostornu ovisnost između individualnih slučajeva koji mogu imati zajedničke uzroke [18]. Identifikacija žarišta istoznačnih prometnih nesreća ukazuje na potrebu za provođenjem analize uzročnih čimbenika, što je bitan korak za odgovarajuću primjenu protumjera, odnosno sigurnosnih poboljšanja [19]. Identifikacija žarišta istoznačnih prometnih nesreća nudi i bolje razumijevanje prostornih uzoraka i grupiranja prometnih nesreća potičući razvoj učinkovitih strategija za poboljšanje sigurnosti prometa [20].

U posljednjih su desetak godina u sve više zemalja svijeta popularizirani sljedeći nazivi: upravljanje opasnim mjestima (engl. *Black Spot Management* – BSM) i upravljanje sigurnošću na cestovnoj mreži (engl. *Network Safety Management* – NSM). Objema je metodologijama svrhom objediniti proces identifikacije i upravljanja opasnim mjestima na cestovnim prometnicama [21]. Unatoč brojnim istraživanjima do danas nisu standardizirana načela i tehnike identifikacije opasnih mjesta, pa se korišteni pristupi razlikuju po zemljama [22]. Međunarodne istraživačke aktivnosti poput programa za ocjenu sigurnosti prometa na cestama iRAP-a (engl. *International Road Assessment Programme*) procjenjuju sigurnost cestovne infrastrukture tako da se pojedinim segmentima ceste dodjeljuju oznake za sigurnost i izrađuju karte koje pokazuju rizik nastanka prometnih nesreća koje uzrokuju smrt i po život opasne ozljede [23], [24]. Osim navedenoga, a u skladu s dosadašnjim istraživanjima, najčešće se pri procjeni razine i mapiranja rizika primjenjuje *Bayesov* prostorni model. Navedeni model analizira višeznačne okolnosti događanja prometnih nesreća te njihove rezultante vrijednosti. *Li* i ostali autori [25] ovaj pristup koriste za prepoznavanje i rangiranje segmenata cesta s potencijalno visokim rizicima prometnih nesreća, tako da se preventivne mjere mogu poduzeti za smanjenje rizika u tim segmentima. Rezultati istraživanja pomoću *Bayesova* modela

omogućuju procjenu relativnoga rizika prometnih nesreća te biranje sigurnijih ruta putovanja u cestovnoj mreži.

Wedagama i ostali [26] razvili su poopćene linearne modele (engl. *generalized linear models*) za istraživanje utjecaja namjene zemljišta, gustoće stanovnika i broja raskrižja na frekvenciju nesreća s pješacima i biciklistima. *Dumbaugh* i *Rae* [27] razvili su regresijski negativni binomijalni model za testiranje utjecaja urbane opreme na koncentraciju prometnih nesreća. Analiza uključuje plan ceste, cestovnu mrežu, stanje nogostupa, ograničenja brzine i njihov utjecaj na pojavnost nesreća. U drugim sličnim istraživanjima koristi se multimodalni logit model za analizu vjerojatnosti nesreća unutar urbanoga okružja [28].

1.4. Metodološki pristup istraživanju

Metodologija rada i plan istraživanja temelje se na postavljenom cilju. Predmetno je istraživanje provedeno u četiri osnovne etape.

U prvoj je etapi izvršeno prikupljanje relevantnih podataka vezanih uz provedbu istraživanja. Nakon prikupljanja i pripreme podataka iz različitih izvora pristupilo se uspostavljanju jedinstvene lokalne baze podataka, pri čemu je korišten geografski informacijski sustav (GIS).

Druga etapa obuhvaća analizu i sintezu podataka. Daljnjom je detaljnijom statističkom analizom podataka s pomoću statističkoga programa uspostavljena korelacija između neposrednih uzroka događanja i posljedica prometnih nesreća sa širim prostornim kontekstom cjelokupnoga događaja prometne nesreće. Za statističku je obradu i analizu podataka korišten SPSS program, a za grafoanalitičke metode proučavanja prometnih nesreća QGIS program.

Treća etapa predstavlja geografsku vizualizaciju rezultata koja omogućuje jednostavnu identifikaciju prometnih nesreća prema vrsti i posljedicama, koja je potrebna za otkrivanje opasnih mjesta, odnosno žarišta prometnih nesreća u urbanom okružju. Vizualna je informacija dostupna kao temeljna sastavnica saznanja o grupiranju prometnih nesreća pješaka i biciklista (žarišta istovrsnih prometnih nesreća). Na temelju statističke analize podataka i grafoanalitičke analize odabrani su mogući utjecajni vanjski čimbenici koji mogu dati najveću važnost pojavnosti opasnih mjesta na cestovnoj prometnoj mreži.

U četvrtoj je etapi izrađen binarni logistički regresijski model identifikacije žarišta prometnih nesreća pješaka i biciklista koji je ovisan o utjecajnim vanjskim čimbenicima nastanka prometnih nesreća. Nakon toga pristupilo se provjeri, tj. validaciji modela na novom skupu podataka.

Za potrebe istraživanja i provjeru hipoteza korištene su karakteristične metode istraživanja koje su sljedeće [29]:

- metoda promatranja – za prikupljanje informacija i podataka o prometnom opterećenju na cestovnoj mreži
- metoda analize i sinteze – za analizu prikupljenih podataka i informacija te za raščlanjivanje složenih pojmova i problema na jednostavnije sastavne dijelove i obrnuto
- metoda klasifikacije i deskripcije – za detaljniju klasifikaciju i opisivanje istovrsnih prometnih nesreća pješaka i biciklista u urbanim sredinama
- komparativna metoda – s pomoću nje izvršena je usporedba istih ili sličnih činjenica te su utvrđene razlike između prometnih nesreća pješaka i biciklista na određenim lokacijama i dionicama cestovne urbane mreže
- induktivna i deduktivna metoda – za analizu pojedinačnih i međusobno povezanih utjecajnih čimbenika prometnih nesreća pješaka i biciklista u urbanim sredinama
- matematičke i statističke metode – za statističku obradu podataka pri čemu je izvršeno modeliranje funkcijske veze između uzroka događanja prometnih nesreća i posljedica u prostornom kontekstu urbanih sredina
- empirijska metoda – daje mogućnost primjene stečenih iskustava na temelju spoznatih rezultata istraživanja.

1.5. Struktura doktorskog rada

Struktura doktorskoga rada sastoji se od osam poglavlja. Na kraju je rada priložen popis korištenih bibliografskih izvora, slika, grafikona, tablica i priloga te pojmovnik karakterističnih definicija.

Poglavlja su doktorskoga rada sljedeća:

1. Uvod
2. Pregled stanja sigurnosti pješačkoga i biciklističkoga prometa
3. Područje obuhvata, prikupljanje i obrada podataka
4. Statistička analiza prometnih nesreća na području Grada Zagreba
5. Identifikacija žarišta i utjecajnih čimbenika nastanka prometnih nesreća
6. Izrada modela logističke regresije žarišta prometnih nesreća
7. Validacija modela
8. Zaključak.

U uvodnom je dijelu opisan problem istraživanja, svrha i ciljevi te su postavljene hipoteze istraživanja. Nadalje su opisana postojeća istraživanja te metodološki pristup izrade doktorskoga rada.

U drugom je poglavlju obrađena zakonska i pravna legislativa u području sigurnosti cestovnoga prometa koja se odnosi na Europsku uniju i na Republiku Hrvatsku. Analizirane su osnovne osobitosti pješačkoga i biciklističkoga prometa uz opis troškova prometnih nesreća. U nastavku je prikazana teorija nastanka prometnih nesreća. U poglavlju su opisani osnovni globalni statistički trendovi kretanja sigurnosnih pokazatelja u cestovnom prometu na području Europske unije, Republike Hrvatske i Grada Zagreba.

U trećem je poglavlju opisano područje istraživanja (Grad Zagreb) te način prikupljanja i obrade podataka iz više nejedinstvenih izvora. Potom su na temelju provedenoga terenskoga istraživanja obrađeni podatci o intenzitetu motoriziranoga i nemotoriziranoga prometa. U nastavku su opisani specijalizirani programski paketi s pomoću kojih je omogućena obrada prikupljenih podataka u svrhu uspostavljanja lokalne baze podataka kao temelja za daljnja istraživanja.

U četvrtom je poglavlju obrađena i prikazana statistička deskriptivna i inferencijalna analiza nad skupom podataka prometnih nesreća pješaka i biciklista u Gradu Zagrebu. Obrada je podataka izvedena nad istovrsnim skupom prometnih nesreća koje su u bazi podataka Ministarstva unutarnjih poslova definirane kao *nalet na pješaka* i *nalet na biciklistu*. Analizirani se podatci prometnih nesreća odnose na razdoblje od 2012. do 2014. godine. Nadalje je u statističkoj analizi obuhvaćena analiza podataka prometnih nesreća prema gradskim četvrtima

Grada Zagreba. Karakteristični su podatci gradskih četvrti dobiveni s pomoću QGIS programa, pri čemu je izvršeno sjedinjenje prostorne i neprostorne baze podataka.

U petom je poglavlju opisan način identifikacije opasnih mjesta te odabir mogućih utjecajnih čimbenika koji dovode do nastanka prometnih nesreća pješaka i biciklista. Nakon identifikacije opasnih mjesta (žarišta) i prikazane vizualizacije žarišta u GIS okružju, u nastavku se određuje važnost utjecaja pojedinih čimbenika na pojavnost prometnih nesreća. Kroz identifikaciju je utjecajnih čimbenika testirana statistička važnost kako pojedini utjecajni čimbenici povećavaju vjerojatnost nastanka opasnoga mjesta. Odabir čimbenika za koje se smatra da imaju potencijalan utjecaj na nastanak opasnoga mjesta temelji se na rezultatima deskriptivne i inferencijalne statistike prikupljenih podataka prikazanih u četvrtom poglavlju.

U šestom je poglavlju opisano stvaranje modela binarne logističke regresije pješačkih i biciklističkih prometnih nesreća u urbanim sredinama. Stvoreni modeli služe za utvrđivanje vjerojatnosti nastanka žarišta prometnih nesreća ovisno o čimbenicima okružja.

U sedmom se poglavlju provodi validacija modela testiranjem modela na novom skupu podataka prometnih nesreća iz 2015. godine, čime se potvrđuje ispravnost i primjenjivost modela.


U zaključnom su poglavlju prikazani najvažniji rezultati istraživanja te je istaknut znanstveni i aplikativni doprinos rada. Na kraju je poglavlja istaknut prijedlog daljnjih istraživanja u području sigurnosti cestovnoga prometa.

2. PREGLED STANJA SIGURNOSTI PJEŠAČKOG I BIKIKLISTIČKOG PROMETA

2.1. Osobitosti pješačkoga i biciklističkoga prometnoga toka


Pješačenje je temeljni, najstariji, najrasprostranjeniji i ekološki najprihvatljiviji oblik kretanja ljudi, odnosno mobilnosti. Svatko je barem u jednom trenutku pješak, uključujući i osobe u invalidskim kolicima i one s drugim pomagalicama. Svako kretanje započinje i završava pješačenjem. Pješačenje je često najbrži način za svladavanje kratkih udaljenosti u gradu. Optimalni polumjer kretanja pješaka iznosi od 400 do 500 metara. Razumna udaljenost pješačenja do koje su ljudi spremni pješachiti iznosi oko 2 km. Pješačenje ima i svojih nedostataka. Glavni su nedostaci mala brzina pješačenja, potrošnja energije, odnosno fizički napor i nemogućnost svladavanja većih udaljenosti pješačenjem. Bicikl je relativno jeftin i neovisan način prijevoza na putovanjima kraćima od 7 km, a pedelec (inačica bicikla s električnim pogonom) je prilagođen za putovanja čak i do 15 km. Bicikl je gotovo idealno rješenje pristupačnosti do određenih aktivnosti, ne zagađuje okoliš i omogućuje primjerenu mobilnost. Nedostaci su korištenja bicikla ovisnost o vremenu, zamor pri dugoj vožnji, ograničena uporaba bicikla zbog nedovoljno izgrađene infrastrukture te neprikladnost za prijevoz tereta veće mase i dimenzija. [30]

Pješaci i biciklisti najslabije su karike prometnoga sustava u pogledu sigurnosti. Iznimno su ugroženi (ranjiviji su od ostalih) i imaju veći rizik od ozljeda u sudaru s vozilom. Nezaštićeni su izvana (oklopom, štitom), nemaju ni pojaseve niti zračne jastuke koji će apsorbirati energiju vozila pri sudaru. Ranjivim sudionicima glavne opasnosti u sudaru predstavljaju veće brzine i mase vozila [30]. Slika 1. prikazuje najčešće tjelesne ozljede pri sudaru s motornim vozilom.




Slika 1. Raspodjela ozljeda pri naletu vozila na pješaka
Izvor: [31]

Utjecaj je ograničenja brzine motornih vozila na gradskim prometnicama jako bitan. Vjerojatnost je smrtnoga stradavanja pješaka pri naletu vozila na njega različita kod mnogih autora. Prema recentnim istraživanjima utjecaja naletne brzine vozila na pješaka u Njemačkoj *Rosén* i *Sander* [32] dokazuju kako je pri brzinama manjima od 30 km/h rizik smrtnoga stradavanja pješaka znatno manji nego u ranije provedenim istraživanjima. *Rosén* i *Sander* pronašli su dvostruko veći rizik smrtnoga stradavanja pješaka pri naletu vozila brzinom od 50 km/h u odnosu na slučaj u kojem je brzina vozila iznosila 40 km/h. Rizik je stradavanja pješaka pri naletu vozila koje se kreće brzinom 50 km/h pet puta veći od rizika pri naletu vozila koje se kreće brzinom 30 km/h (Slika 2. i Slika 3.). [32]



Slika 2. Vjerojatnost smrtnoga stradavanja pješaka pri naletu vozila brzinom od 0 do 120 km/h
Izvor: [32]



Slika 3. Vjerojatnost smrtnoga stradavanja pješaka pri naletu vozila brzinom od 0 do 60 km/h
Izvor: [32]

U statističkim izvješćima većinom se bilježe pješačke nesreće koje su nastale kao rezultat kolizije pješaka i motornih vozila. Prometne nesreće koje se događaju dok pješak hoda, padne i ozlijedi se većinom se ne bilježe i o njima se ne izvještava (problem podizvješćenosti, engl. „under reporting”). Nešto veći udio stradavanja djece i starijih osoba sa smrtnim ishodom imaju nerazvijene zemlje i zemlje u razvoju u odnosu na razvijene zemlje. Djeca zbog fizičkih osobina (niskoga rasta, nedovoljno razvijenoga vida i sl.), mentalnih i kognitivnih sposobnosti (impulzivna su) teško procjenjuju brzinu, udaljenost vozila i prostorne relacije, a starije osobe zbog slabijih refleksa i nemoći. Razdoblje je oporavka od ozljeda za starije osobe puno duže te je visoka vjerojatnost dugoročnoga invaliditeta. Siromašni ljudi s niskim dohotkom više pješače, stoga su time i više izloženi opasnosti od prometnih nesreća. Struktura je prometnoga toka važnim čimbenikom svih nesreća, a u nerazvijenim je zemljama vrlo heterogena. Zbog mješovitoga su toka velike i razlike u brzinama kod prometnih entiteta, što također povećava rizik među samim sudionicima. [30]

U slučaju sudara s motornim vozilom biciklisti su gotovo uvijek žrtve. U mješovitom prometnom okružju autobusa i teretnih vozila njihova manja visina i uska frontalna silueta predstavljaju dodatnu opasnost od ozljeđivanja zbog slabije vidljivosti. Nisko obrazovanje, nedostatak iskustva, obuke i treninga, alkohol, nepozornost, kiša i loše održavan kolnik razlozi su gubitka kontrole nad biciklom i sukoba s pješakom ili s motornim vozilom. Međutim, najveći broj sudara ne uključuje koliziju s motornim vozilima, već je to pad ili kolizija sa stacionarnim objektom ili pješakom u gotovo 65 % do 85 % slučajeva. Jedino je pješak češća žrtva od biciklista u slučaju međusobne kolizije. Biciklisti u prometu ponekad moraju slijediti pravila za vozače, a ponekad za pješake, što im dodatno otežava poziciju u prometu. Neodgovarajuće je ponašanje biciklista i vozača motornih vozila u funkciji dobi i čest je uzrok nesreće u prometu. Djeca se teško nose sa svim prometnim pravilima i propisima koji se pred njih postavljaju. Mladi biciklisti pokazuju što znaju i mogu napraviti s biciklom, češće se voze po kolniku zajedno s automobilima, ne poštuju crveno svjetlo, a sve to povećava rizik od prometne nesreće. Stariji su biciklisti oprezniji, sporije reagiraju, teže održavaju ravnotežu i daju prednost biciklističkim stazama koje su odvojene od kolnika. Djeca i stariji biciklisti pretjerano su zastupljeni u prometnim nesrećama. [30]

Kao i kod pješaćenja biciklisti odabiru najkraći put do cilja. Često se voze jednosmjernim ulicama u krivom smjeru. Ovakva vožnja, posebno kroz raskrižja za vrijeme skretanja, kao i presijecanja kolnih ulaza preko kojih se vozila uključuju na cestu, može biti kobna za bicikliste. Utjecaj alkohola i prevelika brzina dodatno povećavaju rizik od nastanka nesreće. O mnogim se nesrećama u kojima sudjeluju biciklisti (padovi, udarac u ivičnjak i sl.) ne vodi evidencija pa se pravo stanje o njima ne zna. [30]

Kako Republika Hrvatska još nema službeni izračun troška prometne nesreće, brojni domaći autori na temelju međunarodnih iskustava približnom procjenom izračunavaju prometni trošak prometnih nesreća na razini Republike Hrvatske. *Doder* [33] približnom procjenom izračunava prometni trošak prometnih nesreća u Republici Hrvatskoj pod pretpostavkom društvenih gubitaka na državnoj razini od 2,5 do 3 % za 2010. godinu u iznosu oko 10 milijarda kuna. *Brčić i ostali* [34] izračunali su za područje Grada Zagreba za 2010. godinu prosječne društvene troškove prometnih nesreća u iznosu oko 473 milijuna kuna.

Prema metodološkom pristupu izračuna troškova prometnih nesreća iz Priručnika [35] i ekonomskim pokazateljima koji se temelje na tržišnim vrijednostima u 2010. godini, prosječni

trošak poginule osobe u cestovnim prometnim nesrećama u Republici Hrvatskoj iznosi 9 597.600,00 kuna (1.333.000,00 €), teže ozlijeđenoga 1.247.760,00 kuna (173.300,00 €) i lakše ozlijeđenoga 95.760,00 kuna (13.300,00 €). Imajući na umu prethodno navedene troškove prometnih nesreća i podatke da je tijekom 2010. godine u Republici Hrvatskoj zabilježeno 418 poginulih, 3812 teže ozlijeđenih i 15151 lakše ozlijeđenih osoba u cestovnim prometnim nesrećama, definirana je jednadžba (1) za procijenjeni trošak prometnih nesreća:


$$T = Px_1 + Tx_2 + Lx_3 \quad (1)$$

gdje su:

- P – broj poginulih osoba u prometnim nesrećama
- T – broj teže ozlijeđenih osoba u prometnim nesrećama
- L – broj lakše ozlijeđenih osoba u prometnim nesrećama
- x_1 – trošak poginule osobe u prometnim nesrećama
- x_2 – trošak teško ozlijeđene osobe u prometnim nesrećama
- x_3 – trošak lakše ozlijeđene osobe u prometnim nesrećama.

Na temelju izraza (1) ukupni je trošak prometnih nesreća tijekom 2010. godine iznosio oko 10,2 milijarde kuna. Drugim je metodološkim pristupom *Doder* [33] za 2010. godinu dobio slične troškove prometnih nesreća, i to u iznosu od 10 milijarda kuna.

Prema metodologiji izračuna troškova prometnih nesreća iz Priručnika [35], a prema izrazu (1), troškovi prometnih nesreća izraženih u ukupnim društvenim troškovima izračunani su za razdoblje od 2010. godine do 2015. godine (Grafikon 1.). Iz prikazanih je podataka vidljiv trend smanjenja prometnih nesreća tijekom proteklih pet godina, pa je time i trend smanjenja društvenih troškova prometnih nesreća za 2 milijarde kuna.



Grafikon 1. Izračun troškova cestovnih prometnih nesreća u Hrvatskoj 2010. – 2015.

Ako se uzme u obzir da je bruto domaći proizvod Republike Hrvatske 2010. godine iznosio oko 324 milijarda kuna, a 2015. godine oko 330 milijarda kuna [36], udio je troškova prometnih nesreća na razini Republike Hrvatske 2010. godine iznosio oko 3,3 % BDP-a, a 2015. godine oko 2,6 % BDP-a. Na temelju navedenoga može se procijeniti kako su posljednjih godina okvirni društveni troškovi prometnih nesreća u Republici Hrvatskoj od 2,6 % do 3,3 % BDP-a, i prosječno godišnje iznose oko 8,5 milijarda kuna.

2.2. Analiza strateških dokumenata sigurnosti cestovnoga prometa

Na svjetskoj je razini Opća skupština Ujedinjenih naroda 2010. godine donijela rezoluciju 64/225 [37] i objavila *Desetljeće sigurnosti u cestovnom prometu 2011. – 2020.* s ciljem stabilizacije i smanjenja broja žrtava na cestama u svijetu i to smanjenjem broja smrtno stradalih za 50 % do 2020. godine. Ukoliko bi se taj ambiciozni cilj ostvario, to bi spriječilo 5 milijuna smrtno stradalih, 50 milijuna ozlijeđenih osoba te bi se uštedjelo oko 30 bilijuna dolara na globalnoj razini. U tu su se akciju i kampanju uključile međunarodne organizacije, Ujedinjeni narodi, Svjetska zdravstvena organizacija u svojstvu koordinatora aktivnosti, Svjetska automobilistička organizacija, mnoge države, organizacije i udruge [38].

Ujedinjeni narodi u 2011. godini objavili su *Globalni Plan* [39] za desetljeće aktivnosti radi povećanja *Sigurnosti u cestovnom prometu u razdoblju 2011. – 2020. godine*. Navedeni plan potiče države i interesne skupine na primjenu aktivnosti koje će doprinijeti smanjenju predviđene stope smrtno stradalih osoba u cestovnom prometu. Predložene su kategorije aktivnosti sljedeće:

- I. izgradnja kapaciteta za upravljanje sigurnošću cestovnoga prometa
- II. povećanje sigurnosti na cestovnoj infrastrukturi i širim prijevoznim mrežama
- III. daljnje unaprjeđenje sigurnosti u vozilima
- IV. poboljšanje prometne kulture, odnosno ponašanja sudionika u cestovnom prometu
- V. povećanje kvalitete pružanja pomoći unesrećenima nakon prometne nesreće.

Europska je unija prometnu politiku zemalja članica prvi put predstavila javnosti 1992. godine. Osnovnim je ciljem zajedničke politike država Europske unije stvaranje zajedničkoga tržišta prometnih usluga. Taj je cilj, s izuzetkom željezničkoga prometa, gotovo dosegnut u svim granama prometa te su tijekom vremena doneseni novi strateški dokumenti. Konačnim je ciljem uspostavljanje zajedničkoga prometnoga sustava Europe u svim njegovim segmentima.

Pristupanjem Republike Hrvatske Europskoj uniji nastale su obveze ostvarivanja ciljeva iz strateških dokumenata vezanih uz prometni sustav. Službeni su dokumenti EU-a prilično raznoliki. Neki su zakonodavni, odnosno države članice moraju ih uvesti kao obvezu, a neki nisu. Određeni dokumenti Europske unije koji se često spominju u sektoru prometa jesu: Direktive¹, Zelene knjige², Bijele knjige³, Komunikacije⁴ i ostalo.

Europska komisija u Bijeloj knjizi iz 2001. godine [40], naziva *Europska prometna politika za 2010. godinu: vrijeme za donošenje odluka*, predlaže mjere koje su prvi koraci koji se provode u okviru dugoročnije strategije. Prvi se put postavlja cilj da se do 2010. godine prepolovi broj poginulih u cestovnim prometnim nesrećama u EU .

Europska je komisija u lipnju 2003. objavila *Europski akcijski program za sigurnost cestovnoga prometa za razdoblje od 2003. do 2010.* [41]. Ciljem je trećega po redu akcijskoga programa bilo dvostruko smanjenje broja smrtno stradalih na cestama EU-a prije kraja 2010. godine. U konačnici, iako cilj nije postignut u predviđenom roku, ovaj je akcijski program donio pozitivne rezultate u vidu smanjenja broja žrtava u prometnim nesrećama.

U Akcijskom planu urbane mobilnosti iz 2009. [42] Europska komisija nastoji uspostaviti okvir za promicanje politike urbane mobilnosti u kojem se potiče provođenje mjera integrirane dugoročne politike. Ovaj je plan podijeljen u šest tematskih područja urbane mobilnosti opisanih u 20 točaka. U petom tematskom područje *Razmjena iskustava i znanja* potiče se prikupljanje, razmjena i usporedba podataka. Navodi se primjer u području sigurnosti

¹ Direktiva je pravni dokument koji postavlja cilj koji sve zemlje EU-a moraju postići. Međutim, na pojedinim je zemljama da odluče na koji način.

² Zelena je knjiga dokument koji je objavila Europska komisija u svrhu poticanja rasprave o određenim temama na europskoj razini. On poziva odgovarajuće strane (tijela ili pojedince) da sudjeluju u procesu konzultacija i rasprava o temelju iznesenoga prijedloga. Zelena knjiga može dovesti do zakonodavnih zbivanja koja su potom opisana u Bijeloj knjizi.

³ Bijela je knjiga dokument koji sadrži prijedloge za djelovanje Zajednice na određenom području. U nekim slučajevima to slijedi Zelenu knjigu objavljenu za pokretanje procesa konzultacija na europskoj razini. Kad Bijelu knjigu prihvati Vijeće, to može dovesti do akcijskoga programa za Europsku zajednicu u dotičnom području.

⁴ Komunikacija je politički dokument bez obveze za vlasti u zemljama EU-a. Komisija uzima inicijativu objave priopćenja kada želi utvrditi vlastita razmišljanja o nekoj aktualnoj temi. Komunikacija nema pravni učinak.

pješackoga i biciklističkoga prometa, gdje se primjenom najboljih praksa može poboljšati sigurnost najranjivijih sudionika u prometu.

Nakon Akcijskoga programa od 2003. do 2010. godine Europska komisija tijekom 2010. godine donosi novi dokument za poboljšanje sigurnosti cestovnoga prometa na prometnicama zemalja EU-a, pod naslovom *Ususret europskom području sigurnosti na cestama: smjernice za politiku o sigurnosti na cestama za razdoblje od 2011. do 2020.* [43]. U tom dokumentu Europska komisija daje paket inicijativa na europskoj i nacionalnoj razini usmjerenih na poboljšanje sigurnosti vozila, ceste i promjenu ponašanja vozača s glavnim ciljem smanjenja broja poginulih za 50 % u razdoblju od 2011. do 2020. godine. Kako bi se postigao taj cilj, smatra se kako je potrebno postići prosječno godišnje smanjenje od 7 %. U dokumentu se podržava daljnji razvoj tehničkih norma i politika za zaštitu najranjivijih sudionika u cestovnom prometu – starijih osoba, male djece, osoba s invaliditetom i biciklista.

U Bijeloj knjizi iz 2011. godine [44], naziva *Plan za jedinstveni europski prometni prostor – put prema konkurentnom prometnom sustavu unutar kojega se učinkovito gospodari resursima*, predložene su daljnje smjernice za ostvarenje zadanih ciljeva. Jedan je od deset zadanih ciljeva dvostruko smanjiti broj poginulih na cestama do 2020. godine, a do 2050. potpuno iskorijeniti nesreće sa smrtnim ishodom, tj. približiti nuli broj cestovnih nesreća sa smrtnim posljedicama (koncept Vizija nula, engl. *Vision Zero*). U dokumentu se posebno ističu inicijative s fokusom na prometnu sigurnost te se navodi usmjeravanje posebne pozornosti na najranjivije sudionike u prometu kao što su pješaci, biciklisti i motociklisti, među ostalim i kroz sigurniju infrastrukturu i tehnologiju vozila.


Republika Hrvatska već dugi niz godina donosi mjere za povećanje sigurnosti prometa na cestama u obliku nacionalnih programa o sigurnosti cestovnoga prometa. Danas je na snazi peti u nizu *Nacionalni program sigurnosti cestovnoga prometa Republike Hrvatske za razdoblje od 2011. do 2020.* [45], a njegov se okvir temelji na Deklaraciji Ujedinjenih naroda 62/244 iz ožujka 2010. godine. Glavnim je ciljem novoga nacionalnoga programa smanjiti broj poginulih osoba do 2020. godine za pola, s 426 na 213, u odnosu na 2010. godinu. Također je potrebno i spomenuti područja djelovanja *Nacionalnoga programa* koja se odnose na zaštitu ranjivih sudionika u prometu te na povećanje sigurnosti prometa na gradskim prometnicama.

2.3. Teorija nastanka prometnih nesreća

Pojednostavljeni prikaz sigurnosti cestovnog prometa može se promatrati kroz tri osnovna podsustava koji su sljedeći:

- čovjek
- vozilo
- cesta.

Pojedini autori u posljednje vrijeme uvode i četvrti pojam – okolina, jer je za sigurnost prometa posebno značajan prostor u kojem se međusobno isprepliću tri osnovna podsustava. Slika 4. prikazuje utjecaj pojedinih čimbenika na nastanak prometne nesreće, gdje se tri grupe čimbenika i njihove međusobne interakcije mijenjaju u intenzitetu njihova doprinosa nastanku prometne nesreće.





Slika 4. Čimbenici sigurnosti prometa, čovjek – vozilo – cesta (okružje)
Izvor: [46]

Kako sigurnost prometa ovisi o nizu složenih međusobno povezanih čimbenika, ona se može poboljšati primjenom novonastalih znanja dobivenih analizama do sada skrivenih podataka i njihovih mogućih relacija. U iznimno rijetkim slučajevima može se izdvojiti samo jedan uzročnik prometne nesreće. U principu prometnu nesreću prouzrokuje rezultanta nekoliko pojedinačnih uzročnika.

Prema *Hollnagelu* [47] razlikuju se tri osnovna tipa modela nastanka prometnih nesreća (Tablica 1):

- jednostavni linearni model (sekvencijalni ili redni)
- složeni linearni model (epidemiološki)
- sustavni nelinearni model.


Tablica 1. Tipovi modela nastanka prometnih nesreća

	GRAFIČKI PRIKAZ	OSNOVNI PRINCIPI	RAZLOZI ZA ANALIZU	TIPIČNA REAKCIJA
Jednostavni linearni model (SEKVENCIJALA)		Uzročnost (jedan uzorak ili više njih)	Pronađeni specifični uzroci i uzročno-posljedične veze	Eliminiranje veza i uzroka Popravljanje odaziva
Složeni linearni model (EPIDEMIOLOŠKI)		Skrivene ovisnosti	Kombinacija opasnih radnja i latentnih uvjeta	Povećanje sigurnosti i zaštitnih barijera Poboljšanje samoga praćenja (indikatora)
Nelinearni model (SUSTAVNI)		Dinamičke ovisnosti, funkcionalne rezonancije	Složeni međusobni odnosi i zatvoreni spojevi	Monitoring i kontrola performansa Poboljšana predvidljivost

Izvor: [47]

Prvi su znanstveni modeli nastanka prometnih nesreća jednostavni linearni modeli. Ti su modeli nastali u vrijeme industrijalizacije (Slika 5.). Oni pretpostavljaju kako su nesreće kombinacije niza događaja ili okolnosti koje su u međusobnom linearnom slijedu. Pretpostavljalo se kako se nesreće mogu spriječiti eliminiranjem inicijalnoga uzroka u linearnom slijedu. Prvi je razvijen model ove vrste, poznat kao *Domino model*, nastao tijekom 1931. godine od strane *H. W. Heinricha*. Složeni (kompleksni) linearni modeli temelje se na pretpostavci kako je nesreća rezultat kombinacija propusta ili slabosti pojedinih dijelova sustava i latentnih opasnosti u sustavu. Prema *James Reasonovom* [48] modelu švicarskoga sira (engl. *Swiss Cheese Model*) prometna se nesreća događa kad se poklope rupe ili slabosti u svim prometnim čimbenicima tako da kroz njih prolazi zraka svjetlosti. Posljednja su generacija izučavanja prometnih nesreća nelinearni sustavni modeli za čije je izučavanje nužno poznavanje teorije sustava. Prema ovom je modelu prometna nesreća posljedica niza neovisnih čimbenika i njihovih međusobnih interakcija koje se pojavljuju u stvarnom okružju. Iz navedenoga je vidljivo kako kod opisivanja pojma *sigurnosti prometa* problem nije samo nepredvidljivo ponašanje ljudi, nesigurne ceste i vozila, već je on puno složeniji. Tradicionalne metode koriste jednostavne modele utemeljene na jednostavnim odnosima ulaznih i izlaznih parametara, dok suvremene metode koriste

sustavni pristup i analizu velikoga broja parametara i njihovih interakcija, što znači da je njihovo modeliranje prometnih nesreća znatno složenije.



Slika 5. Povijesni razvoj modela nastanka nesreća


Izvor: [47]

Kako prometne nesreće predstavljaju velik društveni trošak, stručnjaci često računaju rizike koji nastaju kao posljedica prometnih nesreća. Matematički se rizik računa kao umnožak učestalosti pojavljivanja neželjenoga događaja i posljedice, koja najčešće nije samo jedna (Slika 6.) Osim prikazanoga dvodimenzionalnoga računanja rizika u novije se vrijeme za izračun uzima i treća dimenzija, izloženost riziku:

$$R = \{ \{ p_i, C_i \} \} \quad (2)$$

gdje su:


- R – rizik
- p_i – vjerojatnost pojavljivanja i-te prometne nesreće
- C_i – konsekvenca ili posljedica i-te prometne nesreće.



Slika 6. Odnos pojavljivanja neželjenoga događaja i posljedice

Za određivanje rizika koriste se kvantitativne metode (npr. engl. *Fault Tree Analyse* – FTA i *Event Tree Analyse* – ETA) i kvalitativne metode izračuna (matrica rizika dobivena kombinacijom alfanumeričkih znakova).

Dubinskom analizom i identifikacijom čimbenika koji povećavaju rizik od prometnih nesreća (rizično ponašanje sudionika u prometu, stanje infrastrukture, stanje vozila, uvjeti na cesti, okruženje) te njihovom klasifikacijom u prostoru i vremenu moguće je otkriti nove spoznaje i dobiti rješenja za smanjenje prometnih nesreća na cestama. Slika 7. prikazuje pojednostavljeni model nastajanja prometnih nesreća uzimajući u obzir njihovu kompleksnost (složenost) te njihovo izučavanje i mjere prevencije [33].



Slika 7. Pogreške u sustavu koji uzrokuje prometne nesreće
Izvor: [33]

Pri dubinskoj analizi prometnih nesreća svaka država, županija i grad ima svoje specifičnosti koje se međusobno razlikuju i o kojima se mora voditi računa pri analizi prometnih nesreća kako se ne bi donijeli krivi zaključci.

2.4. Pokazatelji sigurnosti cestovnog prometa u EU

Pokazatelji sigurnosti prometnih nesreća mogu se predstaviti kao apsolutni i relativni. Apsolutni se pokazatelji prometnih nesreća jednostavno dobivaju neposrednim brojenjem i evidentiranjem prometnih nesreća te njihovih posljedica. Relativni su pokazatelji odnos jednoga od apsolutnoga pokazatelja i neke druge veličine kao što je, primjerice, broj stanovnika, broj vozača, broj vozila, prijeđenih kilometara po vozilu i slično (Tablica 2.).

Tablica 2. Podjela pokazatelja sigurnosti prometa

VRSTE POKAZATELJA	VELIČINE ISKAZIVANJA POKAZATELJA
Apsolutni pokazatelji	• broj prometnih nesreća • broj prometnih nesreća s ozlijeđenima • broj prometnih nesreća s poginulima • broj prometnih nesreća s težim tjelesnim ozljedama • broj prometnih nesreća s lakšim tjelesnim ozljedama • broj prometnih nesreća s materijalnom štetom i ostalo • broj poginulih u prometnim nesrećama • broj teže ozlijeđenih u prometnim nesrećama • broj lakše ozlijeđenih u prometnim nesrećama
Relativni pokazatelji	• broj prometnih nesreća u odnosu na broj stanovnika, • broj prometnih nesreća u odnosu na broj vozila, • broj prometnih nesreća u odnosu na broj vozača • broj prometnih nesreća u odnosu na prijeđenu kilometražu • broj nastradalih/poginulih u odnosu na broj stanovnika, vozila, vozača, prijeđenih kilometara i ostalo.

Tablica 3. prikazuje apsolutne i relativne pokazatelje sigurnosti cestovnoga prometa u Republici Hrvatskoj i u Gradu Zagrebu koji su na međunarodnoj razini usporedivi s drugim gradovima i državama.

Tablica 3. Apsolutni i relativni pokazatelji sigurnosti cestovnoga prometa u Republici Hrvatskoj i u Gradu Zagrebu, 2013. godina

POKAZATELJI	REPUBLIKA HRVATSKA	GRAD ZAGREB
Broj stanovnika	4 284 889	790 017
Površina, km ²	56 542	641,32
Broj PN	34 021	7 362
Broj PN s poginulim osobama	328	23
Broj PN s ozlijeđenim osobama	10 897	1 854
Broj poginulih	368	27
Broj teško ozlijeđenih	2 831	420
Broj lako ozlijeđenih	12 446	2 074
Broj poginulih na 100.000 st.	7,7	3,4
Broj teško ozlijeđenih na 100.000 st.	66,1	53,2
Broj lako ozlijeđenih na 100.000 st.	290,5	262,5
Broj PN na 100.000 st.	794,0	931,9
Broj poginulih na 100 km ²	58,0	421
Broj PN na 100 km ²	60,2	1 147,9


Izvor: [49], [50]

Moguće je pojavljivanje problema kada se ovi pokazatelji međusobno uspoređuju s drugim zemljama svijeta jer trenutačno postoje razlike u vrijednosti i korektnosti evidentiranja prometnih nesreća. Osim toga, ovdje postoji i drugi problem zanemarivanje prometnih nesreća s materijalnom štetom gdje osiguravajuće tvrtke ne izvještavaju nadležne institucije pa značajan dio prometnih nesreća ostaje u tamnoj zoni, odnosno nezabilježen. Stopa izvješćivanja o prometnim nesrećama razlikuje se i između razvijenih zemalja Europe, pri čemu se evidentira oko 35 – 70 % svih prometnih nesreća s pješacima, oko 10 – 40 % s biciklistima i oko 50 – 70 % s automobilima [51]. Prema provedenim istraživanjima najmanje se prijavljuju prometne nesreće s lakše ozlijeđenima i s materijalnom štetom. Prometne nesreće s materijalnom štetom ostaju nezabilježene jer vozači nisu dužni obavijestiti policiju o prometnoj nesreći te takve slučajeve izravno rješavaju s osiguravajućim kućama.

Prometne su nesreće socijalni i javnozdravstveni izazov. Prema procjenama Svjetske zdravstvene organizacije u svijetu na cestovnim prometnicama pogine oko 1,24 milijuna ljudi (oko 3 400 ljudi dnevno) te između 20 i 50 milijuna biva ozlijeđeno. Oko 50 % poginulih na cestama pješaci su, biciklisti i motociklisti, poznati kao najranjivija skupina sudionika na cestama. Cestovne su prometne nesreće danas osmi vodeći uzrok smrtnosti u svijetu i vodeći uzrok smrti mladih ljudi u dobi od 15 do 29 godina. Postojeći trendovi pokazuju kako će cestovne prometne nesreće do 2030. godine postati peti vodeći uzrok smrti ako se ne poduzmu odgovarajuće mjere. [52]

Prema statističkim pokazateljima za 2014. godinu u 28 zemalja članica Europske unije (EU28) oko dvije trećine svih prometnih nesreća događa se u urbanim sredinama, u kojima ukupno smrtno strada oko dvije trećine pješaka i biciklista [7], [53]. Broj poginulih na cestama Europske unije prepolovio se razdoblju između 1992. i 2010. godine sa 70 000 na 31 000. Postavljeni cilj smanjenja broja poginulih na cestama Europske unije za pola u razdoblju od 2011. do 2020. godine ne ispunjava se u potpunosti. Međutim, bitno je napomenuti kako je i dalje prisutan trend smanjenja poginulih na cestama. Stope cestovnih prometnih nesreća razlikuju se među državama članicama, a europske ceste još uvijek nisu u potpunosti sigurne. Promatrajući razdoblje od 2010. do 2014. godine, prosječno smanjenje na razini svih zemalja članica EU-a iznosi 18 % ili 5 700 manje poginulih. U navedenom razdoblju najveće stope smanjenja od preko 30 % ostvarile su Španjolska, Portugal i Grčka, dok je Republika Hrvatska zabilježila smanjenje od 28 %.


Prema raspoloživim izvješćima o stanju sigurnosti u cestovnom prometu na području Europske unije tijekom 2014. godine zabilježeno je oko 25 700 smrtno stradalih ili prosječno oko 51 smrtno stradala osoba na milijun stanovnika [7]. Tijekom 2010. godine prosječan broj smrtno stradalih u cestovnom prometu na milijun stanovnika iznosio je 63, a tijekom 2000. godine oko 80 (Grafikon 2.).



Grafikon 2. Usporedba broja poginulih na 1 milijun stanovnika tijekom 2001. i 2014. godine

Tijekom 2014. godine Švedska, Nizozemska, Velika Britanija i Malta imaju najnižu zabilježenu stopu smrtnosti, i ona iznosi manje od 30 na milijun stanovnika. Najvišu stopu smrtnosti na cestama bilježi Latvija, Rumunjska, Bugarska, Litva i Poljska, preko 80 poginulih osoba na milijun stanovnika, a zatim slijedi Republika Hrvatska sa 73 poginule osobe na milijun stanovnika (Grafikon 2.). Većina je poginulih na cestama EU28 zabilježena izvan naselja (61 %), dok je unutar naselja zabilježeno 39 % svih poginulih, pri čemu Republika Hrvatska bilježi 62 % ukupno nastradalih u naseljima. [54]

U izvješću ETSC-a [55] za razdoblje od 2011. do 2014. godine, promatrajući odnos broja smrtno stradalih na milijardu vozilo-kilometara, vidljivo je kako Republika Hrvatska ima i do četiri puta veći rizik stradavanja na cestovnim prometnicama u odnosu na zemlje Skandinavije ili Velike Britanije (Grafikon 3.).




Grafikon 3. Broj poginulih na milijardu vozilo-kilometara (2011. – 2014.)
Izvor: [55]

Trend je smanjenja stradavanja pješaka i biciklista na području EU-a u manjem padu u odnosu na sveukupni pad smanjenja stradavanja svih sudionika u cestovnom prometu. Najveći je rizik stradavanja pješaka i biciklista u urbanim sredinama. Više od polovine svih teških nesreća događa se u gradskim područjima i one ponajviše uključuju pješake, motocikliste, bicikliste (što obuhvaća i korisnike električnih bicikala) i ostale ranjive sudionike u cestovnom prometu.

Oko 138 000 pješaka i biciklista izgubili su živote na cestama EU-a između 2001. i 2013. godine. Tijekom 2013. godine smrtno ih je stradalo oko 7 600. Prema statističkim pokazateljima za 2014. godinu pješaci i biciklisti čine 29 % svih smrtno stradalih osoba na cestama Europske unije, pješaci 21 %, a biciklisti 8 %. Međutim, velika razlika postoji između zemalja u kojima stradavaju ranjivi sudionici u prometu. Prema statističkim pokazateljima trend smanjenja smrtnosti najranjivijih sudionika u prometu opada sporije u odnosu na ostale smrtno stradale, kao što su vozači i putnici motornih vozila. U posljednjih je deset godina smrtnost pješaka smanjena za 41 %, biciklista za 37 %, motociklista za 34 %, pri čemu je najveće smanjenje smrtnosti ostalih korisnika motornih vozila oko 53 %. [53]


Prema pokazateljima za 2014. godinu u svih 28 zemalja članica Europske unije (EU28) pješaci čine 21 % svih poginulih u prometnim nesrećama. U urbanim sredinama EU-a prosječno smrtno nastrada oko 69 % pješaka, dok u Hrvatskoj nastrada 83 %. U razdoblju od 2011. do 2013. godine Republika Hrvatska ima najveći udio smrtno stradalih pješaka u naseljenim mjestima (Grafikon 4.). Najveći se rizik stradavanja odnosi na osobe starije od 65 godina koje čine 44 % svih poginulih pješaka.



Grafikon 4. Udio poginulih pješaka prema mjestu stradanja u razdoblju od 2011. do 2013. godine
Izvor: [53]


Prema pokazateljima stradanja biciklista na području Europske unije zabilježene su velike razlike među državama članicama. Od svih je poginulih ukupno smrtno stradalo oko 8 % biciklista. Najveći je udio smrtno stradalih biciklista također u urbanim sredinama i iznosi oko 57 %. S obzirom na životnu dob smrtno stradalih biciklista daleko najveći udio (42 %) ima populacija starija od 65 godina. [54]

Prema obrađenim i dostupnim pokazateljima Republika Hrvatska bilježi najveći udio smrtno stradalih biciklista u naseljenim mjestima u odnosu na druge zemlje Europske unije (Grafikon 5.).



Grafikon 5. Udio poginulih biciklista prema mjestu stradanja u razdoblju od 2011. do 2013. godine
Izvor: [53]

Zemlje s apsolutnim najvećim iznosima stradalih biciklista jesu Nizozemska i Danska (Grafikon 6.). Kako ljudi u Nizozemskoj i Danskoj najviše koriste bicikl u odnosu na druge načine prijevoza, vidljiv je povećan broj biciklističkih smrtnih slučajeva. To dovodi do manjega broja smrtnih slučajeva kod drugih modaliteta putovanja, primjerice automobila.



Grafikon 6. Udio smrtno stradalih pješaka, biciklista, motociklista i ostalih sudionika u cestovnom prometu (prosječno od 2011. do 2013. godine)

Izvor: [55]

Iako su svi korisnici ceste u opasnosti u slučaju događanja nesreće, postoje značajne razlike u stopama ozljeda i smrtnosti između različitih skupina korisnika ceste.

Bitno je napomenuti kako apsolutni pokazatelji, posebno ukoliko se nekritički koriste, mogu dovesti do pogrešnih zaključaka. Stoga je puno bolje koristiti relativne pokazatelje koji pružaju dodatnu kvalitetu u analizi prometnih nesreća te se na temelju njih mogu donijeti kvalitetniji zaključci (Tablica 4.).

Tablica 4. Rizik od smrtnoga stradavanja po kilometru i satima za svaki način putovanja

	Način (mod) putovanja	100 mil. osoba-kilometara	100 mil. osoba-sati
Cesta	Motocikl/moped	16,0	500
	Bicikl	6,3	90
	Pješaćenje	7,5	30
	Automobil	0,8	30
	Autobus	0,08	2
	<i>Ukupno</i>	1,1	33
Željeznica		0,04	2
Trajekt		0,33	10,5
Zrakoplov		0,08	36,5

Izvor: [51]

Usporedba rizika smrtno stradalih na cestama EU-a prema načinu putovanja pokazuje kako je rizik putovanja motociklom najveći od svih te je 20 puta veći u odnosu na onaj koji imaju osobe u automobilu. Također, prema pokazateljima iz tablice, biciklisti i pješaci imaju oko 8 do 10 puta veći rizik stradavanja u prometu u odnosu na promet automobilom.

2.5. Stanje sigurnosti cestovnoga prometa u Republici Hrvatskoj s osvrtom na pješake i bicikliste


U Republici Hrvatskoj Ministarstva unutarnjih poslova Republike Hrvatske (MUP) provodi prikupljanje i obradu podataka o cestovnim prometnim nesrećama te ih jedanput godišnje objavljuje u *Biltenu o sigurnosti cestovnoga prometa* [49]. Sadržaj *Biltena* uključuje pojedinosti o svakoj cestovnoj prometnoj nesreći o kojoj se izvijestilo, o broju prometnih nesreća sa stradalim osobama prema vrsti, posljedicama, uzroku, okolnostima i sudionicima (vozila, vozači, pješaci i putnici), o broju poginulih i ozlijeđenih osoba. Važno je napomenuti kako prometne nesreće s manjom materijalnom štetom nisu zabilježene u službenim statistikama. Detaljni podatci za dubinsku analizu prometnih nesreća nisu dostupni u tom obliku.

U posljednjih se deset godina na hrvatskim cestama prosječno dogodilo 47 tisuća prometnih nesreća. U 30 % prometnih nesreća stradavale su osobe. Godišnje je u prometu prosječno stradavalo oko 20 tisuća ljudi. Od toga je broja 80 % prošlo s lakšim tjelesnim ozljedama. Teške je tjelesne ozljede zadobilo 18 % osoba, dok 2 % osoba smrtno strada tijekom godine, što je prosječno godišnje 496 osoba [49]. Karakteristično je za Republiku Hrvatsku to da se u urbanim zonama događa čak 80 % nesreća (postotak za zemlje članice EU-a iznosi 68 %), a u tim nesrećama smrtno strada 59 % sudionika (prosječno smrtno stradalih u urbanim područjima zemalja članica EU-a iznosi 39 %).

Prema statističkim podacima najveći je uzročnik prometnih nesreća vozač, oko 95 %, pješak oko 1 %, dok su ostali čimbenici zanemarivi. Međutim, takvi pokazatelji nisu u potpunosti pouzdani jer nisu utemeljeni na pravomoćnim presudama ili stručnim vještačenjima, već su isključivo opservacije policijskih djelatnika pri očevidu prometnih nesreća.


Grafikon 7. prikazuje stvarni broj poginulih osoba u prometnim nesrećama u odnosu na glavni postavljeni cilj smanjenja broja smrtno stradalih osoba za 50 % do 2020. godine u okviru *Nacionalnoga programa sigurnosti cestovnoga prometa Republike Hrvatske 2011. – 2020. godine* [45]. Dakle, glavni je postavljeni cilj smanjenje broja poginulih u cestovnom prometu s 426 osoba u 2010. godini na 213 osoba do 2020. godine. Tijekom 2014. godine poginule su 33 osobe manje ili 9,7 % manje nego što je predviđeno *Nacionalnim programom sigurnosti cestovnoga prometa*. Međutim, već je 2015. godine zabilježeno povećanje broja smrtno stradalih osoba za 48 u odnosu na prethodnu godinu, ili 28 više nego što je predviđeno *Nacionalnim programom sigurnosti cestovnoga prometa*, a 2016. godine zabilježeno je

ponovno smanjenje na razinu od prije dvije godine. Ovi apsolutni pokazatelji sigurnosti cestovnoga prometa ukazuju na činjenicu da Republika Hrvatska u potpunosti ne upravlja sigurnošću cestovnoga prometa te ju ponovno svrstavaju među zemlje članice EU-a s najlošijim pokazateljima sigurnosti prometa.



Grafikon 7. Prikaz kretanja stvarnoga i očekivanog broja poginulih osoba u cestovnom prometu za razdoblje od 2011. do 2020. godine


Grafikon 8. prikazuje trend smanjenja prometnih nesreća s poginulim i ozlijeđenim osobama u Republici Hrvatskoj od 2010. do 2015. Tijekom posljednjih je godina zamjetan značajniji trend smanjenja broja prometnih nesreća s materijalnom štetom u odnosu na broj ozlijeđenih osoba.



Grafikon 8. Broj prometnih nesreća s poginulim i ozlijeđenim osobama u Republici Hrvatskoj od 2010. do 2015. godine

Iz daljnje je raščlambe ozlijeđenih osoba na poginule, teže i lakše ozlijeđene u prometnim nesrećama vidljiv umjeren trend smanjenja broja teže ozlijeđenih osoba od 12 % u odnosu na

smanjenje broja lakše ozlijeđenih osoba od 20 % u razdoblju od 2010. do 2015. godine (Grafikon 9.).




Grafikon 9. Broj stradalih osoba u Republici Hrvatskoj od 2010. do 2015. godine
Izvor: [49]

Tijekom 2014. godine u urbanim je područjima Republike Hrvatske zabilježeno 62 % stradalih, i oko 80 % ozlijeđenih od ukupnoga broja ozlijeđenih osoba. U zemljama Europske unije u urbanim područjima dogodi se oko 39 % od svih stradalih osoba u cestovnom prometu.


Posljednjih godina broj stradalih pješaka i biciklista na cestama Republike Hrvatske iznosi oko jednu trećinu od ukupno svih stradalih sudionika u prometnim nesrećama. Prema statističkim pokazateljima broj je stradalih pješaka tijekom 2014. iznosio 23,3 % od ukupnoga broja svih stradalih sudionika u prometu, dok je udio stradalih biciklista iznosio 6,2 %.

Prema statističkim pokazateljima tijekom posljednjih je godina zabilježen blagi trend smanjenja broja stradalih pješaka, ali ipak u znatno manjem iznosu u odnosu na ukupan trend smanjenja svih stradalih sudionika na cestovnim prometnicama Republike Hrvatske. Broj je prometnih nesreća s ozlijeđenim pješacima u minimalnom opadanju. Tijekom posljednjih pet godina ovaj trend gotovo da je stabiliziran između 1520 i 1580 prometnih nesreća (Grafikon 10.).




Grafikon 10. Prometne nesreće (sudjelovali pješaci) u Republici Hrvatskoj od 2010. do 2015. godine
Izvor: [49]

Od ukupnoga broja stradalih pješaka u posljednjih je pet godina zabilježeno oko 70 % lakše tjelesno ozlijeđenih (LTO) te 30 % teže tjelesno ozlijeđenih (TTO) (Grafikon 11.).




Grafikon 11. Stradali pješaci u Republici Hrvatskoj od 2010. do 2015. godine
Izvor: [49]

Trenutačni pokazatelji sigurnosti biciklističkoga prometa u Republici Hrvatskoj nisu zadovoljavajući. Iako je u razdoblju od 2011. do 2014. godine zabilježen trend smanjenja broja poginulih biciklista, tijekom 2015. godine došlo je do nagloga povećanja poginulih biciklista na 80 % u odnosu na prethodnu godinu. Iz daljnje je analize rezultata vidljiv trend povećanja broja prometnih nesreća u kojima su sudjelovali biciklisti (Grafikon 12.), što u konačnici rezultira i povećanjem broja ukupno stradalih.



Grafikon 12. Prometne nesreće (sudjelovali biciklisti) u Republici Hrvatskoj od 2010. do 2015. godine
Izvor: [49]


Promatrajući odnos broja stradalih biciklista u prometu, s obzirom na težinu ozljeda, prosječno se 70 % odnosi na lakše ozlijeđene (LTO) te 30 % na teže ozlijeđene (TTO) (Grafikon 13.). Iz podataka je vidljiv zabrinjavajući trend povećanja ozlijeđenih biciklista uz povećanje broja poginulih biciklista tijekom 2015. godine od gotovo 80 % u odnosu na prethodnu 2014. godinu.



Grafikon 13. Stradali biciklisti u Republici Hrvatskoj od 2010. do 2015. godine
Izvor: [49]


Analizirajući općenito stanje pokazatelja sigurnosti prometa na području Grada Zagreba, uočljiv je sličan trend kao i na nacionalnoj razini. Zamjetan je općeniti trend ukupnoga smanjenja svih prometnih nesreća, no on je skoro zanemariv kada se analiziraju prometne nesreće u kojima sudjeluju pješaci i biciklisti.

Grafikon 14. prikazuje ukupan broj prometnih nesreća koje su se dogodile na administrativnom području Grada Zagreba. Iz prikaza je vidljivo kako je prisutan značajan trend smanjenja prometnih nesreća s materijalnom štetom uz manji pad prometnih nesreća sa stradalim osobama. Međutim, trend smanjenja prometnih nesreća s materijalnom štetom možemo objasniti i činjenicom kako je ovo smanjenje samo prividno jer se broj neprijavljenih prometnih nesreća iz baze MUP-a prelio na prometne nesreće kod osiguravajućih društava (Grafikon 18.).



Grafikon 14. Prometne nesreće u Gradu Zagrebu od 2011. do 2015. godine

Grafikon 15. prikazuje ukupan broj poginulih osoba na cestovnoj mreži Grada Zagreba te ukupan broj ozlijeđenih osoba. Iz podataka je razvidan trend smanjena poginulih osoba uz blagi trend smanjenja ozlijeđenih osoba.



Grafikon 15. Stradale osobe u Gradu Zagrebu od 2011. do 2015. godine

Detaljni su statistički pokazatelji sigurnosti pješačkoga i biciklističkoga prometa u Gradu Zagrebu slični pokazateljima na nacionalnoj razini. Tablica 5. prikazuje višegodišnji stalni trend prometnih nesreća prema posljedicama u kojima su sudjelovali pješaci. U njoj je prikazan broj poginulih pješaka te struktura stradalih pješaka prema težini ozljede iz koje je uočljiv ustaljeni trend stradalih pješaka u posljednjem petogodišnjem razdoblju. Udio prometnih nesreća u kojima su sudjelovali pješaci u Gradu Zagrebu iznosi 25 – 30 % od svih prometnih nesreća u kojima su sudjelovali pješaci u Republici Hrvatskoj.

Tablica 5. Prometne nesreće u kojima su sudjelovali pješaci i ukupan broj stradalih pješaka u Gradu Zagrebu od 2011. do 2015. godine

2011. do 2015. godine									
Prometne nesreće (sudjelovali pješaci)					Stradavanje pješaka				
	s poginulim osobama	s ozlijeđenim osobama	s materijalnom štetom	Ukupno nesreća	Poginuli	Ozlijeđeni			Ukupno stradali
						TTO	LTO	Ukupno ozlijeđeni	
2011.	10	460	53	523	11	161	306	467	478
2012.	13	419	61	493	14	128	308	436	450
2013.	6	405	56	467	6	141	273	414	420
2014.	9	441	53	503	9	135	311	446	455
2015.	8	431	55	494	8	128	304	432	440

Tablica 6. prikazuje broj prometnih nesreća u kojima su sudjelovali biciklisti kao i ukupan broj stradalih biciklista na području Grada Zagreba. Pokazatelji su slični kao i kod pješačkoga prometa, gdje je zamjetan ustaljeni broj prometnih nesreća te ukupan broj stradalih biciklista u posljednjem petogodišnjem razdoblju. Udio prometnih nesreća u kojima su sudjelovali biciklisti u Gradu Zagrebu iznosi 20 – 25 % od svih prometnih nesreća u kojima su sudjelovali biciklisti u Republici Hrvatskoj.

Tablica 6. Prometne nesreće u kojima su sudjelovali biciklisti i ukupan broj stradalih biciklista u Gradu Zagrebu od 2011. do 2015. godine


Prometne nesreće (sudjelovali biciklisti)					Stradavanje biciklista				
	s poginulim osobama	s ozlijeđenim osobama	s materijalnom štetom	Ukupno nesreća	Poginuli	Ozlijeđeni			Ukupno stradali
						TTO	LTO	Ukupno ozlijeđeni	
2011.	4	231	98	333	4	59	152	211	215
2012.	1	251	86	338	-	67	161	228	228
2013.	1	252	93	346	1	64	162	226	227
2014.	3	244	83	330	3	82	139	221	224
2015.	1	226	63	290	-	56	144	200	200

3. PODRUČJE OBUHVATA, PRIKUPLJANJE I OBRADA PODATAKA

3.1. Područje obuhvata istraživanja


Odabrano je područje istraživanja Grad Zagreb, koje je ujedno poslovno, trgovačko, administrativno, turističko i sveučilišno središte Republike Hrvatske. Grad Zagreb prostire se na 641 km² te čini oko 1,1 % kopnenoga teritorija Republike Hrvatske. Na području Grada nalazi se oko 6 300 ulica i trgova u 70 naselja s ukupnom površinom pješačke zone oko 800 000 m². Ukupna duljina cestovne mreže iznosi oko 2 400 km. Grad je Zagreb kao jedinica lokalne samouprave teritorijalno podijeljen na 17 gradskih četvrti s ukupno 218 mjesnih odbora. Prema popisu stanovništva iz 2011. godine Grad je Zagreb imao 790 017 stanovnika, što iznosi oko 18 % ukupnoga stanovništva Republike Hrvatske. Ukupan je broj kućanstava iznosio 304 375, uz prosječan broj članova po kućanstvu od 2,6. Prosječna je gustoća naseljenosti iznosila 1 232 st/km², pri čemu je najveća gustoća naseljenosti u središnjem dijelu grada u gradskoj četvrti Donji grad, a najmanja u rubnoj gradskoj četvrti Brezovica. [50]

Na području je Grada Zagreba registrirano 339 749 motornih vozila, od čega su 285 279 osobna vozila [50]. Kao i u drugim gradovima jugoistočne Europe u Gradu je Zagrebu tijekom posljednja dva desetljeća stalan porast stupnja motorizacije uvjetovan pozitivnim socioekonomskim pokazateljima te pojačanom urbanizacijom. Blagi trend smanjenja započinje tijekom 2008. godine, uvjetovan gospodarskom krizom, kada je ujedno i zabilježen najveći stupanj motorizacije od 426 voz/1 000 st. (Grafikon 16.). U razdoblju od 2008. do 2012. godine bilježi se smanjenje stupnja motorizacije. Posljednjih nekoliko godina pokazatelji daju naznake blagoga oporavka te se u predstojećem razdoblju očekuje povećanje stupnja motorizacije u Gradu Zagrebu i u Hrvatskoj do razine drugih zapadnoeuropskih gradova, od oko 450 – 500 vozila na 1 000 stanovnika.



Grafikon 16. Stupanj motorizacije u Republici Hrvatskoj i Gradu Zagrebu
Izvor: [36], [50]

Trenutačno nije poznato koliko u pojedinim hrvatskim gradovima i u Gradu Zagrebu ima bicikala jer se o tome ne vodi službena evidencija niti su rađena sustavna istraživanja na tu tematiku. Međutim, prema posljednjim dostupnim podacima Državnoga zavoda za statistiku (DZS) tijekom 2015. godine uvezeno je 100 tisuća bicikala, pri čemu je ukupan broj uvezenih bicikala na državnoj razini u posljednjem desetljeću iznosio oko 160 tisuća na godinu (Grafikon 17.). Ovi su podatci dobiveni iz baze robne razmjene Republike Hrvatske DZS-a, a uz pomoć već poznate nomenklature carinske tarife koja označava bicikle i ostala slična vozila (uključujući dostavne tricikle) bez motornoga pogona. Kako Republika Hrvatska nema značajniju proizvodnju bicikala, pretpostavlja se da je broj uvezenih bicikala ujedno i broj prodanih novih bicikala. Iz grafičkoga su prikaza tijekom posljednjega desetljeća vidljive oscilacije u broju uvezenih bicikala, vjerojatno uvjetovane ponudom, odnosno potražnjom za biciklom. Najveći je broj prodanih bicikala ostvaren tijekom 2008. godine, vjerojatno jednim dijelom uvjetovan financijskom i gospodarskom krizom u državi, ali i u posljednje vrijeme sve većom popularnošću bicikla kao poželjnoga prijevoznoga sredstva.



Grafikon 17. Broj uvezenih bicikala u Republiku Hrvatsku
Izvor: [36]

3.2. Prikupljanje podataka

S ciljem stvaranja relevantne lokalne baze podataka prikupljeni su podatci prometnih nesreća Ministarstva unutarnjih poslova (MUP-a), Državnoga zavoda za statistiku [36], Geoportala Državne geodetske uprave, Grada Zagreba, društava za održavanje cesta, osiguravajućih društava, meteoroloških služba kao i slobodno dostupnih podataka s *OpenStreetMap* projekta. Značajan je dio podataka prikupljen iz lokalne baze projekata Fakulteta prometnih znanosti, ponajprije podataka vezanih uz istraživanje parametara prometnoga toka na području Grada Zagreba. Dodatnim su terenskim istraživanjem prikupljeni podatci o strukturi prometnoga toka s pomoću kojih je određen intenzitet prometnoga opterećenja na karakterističnim dionicima i lokacijama cestovne mreže.

3.2.1. Prikupljanje podataka od Ministarstva unutarnjih poslova Republike Hrvatske

U Republici Hrvatskoj većinu podataka o prometnim nesrećama prikupljaju djelatnici Ministarstva unutarnjih poslova (MUP-a) na temelju standardiziranoga obrasca, odnosno *Upitnika o prometnoj nesreći* (UPN) (Slika 8. i Slika 9.). Postojeći je UPN obrazac na snazi od 1. siječnja 2010. godine te je u odnosu na stari obrazac PN10 nadopunjen i izmijenjen pa sadrži sveukupno 38 upita o prometnoj nesreći. Upitnik se o prometnoj nesreći popunjava na temelju *Znakovnika za popunjavanje Upitnika o prometnoj nesreći* koji je prilagođen i u primijeni od 1. siječnja 2010. godine (Prilog 1. i Prilog 2.).

Na temelju je tako prikupljenih podataka o prometnim nesrećama i unesenih u središnji informatički sustav MUP-a Republike Hrvatske od 1995. godine dobivena kvalitetna baza podataka o svim registriranim prometnim nesrećama na kojima su policijski službenici izvršili očevid. Bitno je napomenuti kako se od 2010. godine uz svaku prometnu nesreću unose i prostorne koordinate (geografska širina i dužina), pri čemu je stvorena podloga za prikazivanje evidentiranih prometnih nesreća u GIS okružju. Prikupljeni se podatci jednom godišnje objavljuju u *Biltenu o sigurnosti cestovnoga prometa* te se na taj način daju na uvid stručnoj i ostaloj zainteresiranoj javnosti [49].

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: _____	
POSLEDICA 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 _____			
OGRAĐENJE BRZINE _____		VERTIKALNA SIGNALIZACIJA _____		HORIZONTALNA SIGNALIZACIJA _____	
OKOLIŠ _____		ATMOSFERESKE 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 _____			

Slika 8. Upitnik o prometnoj nesreći, stranica 1/2
Izvor: [56]

PODACI O SUDIONICIMA											
PREZIME _____				IME _____				ROĐEN _____		OIB _____	
DRŽAVLJANSTVO _____				REGISTRACIJSKA OZNAKA VOZILA _____				SVOJSTVO SUDIONIKA _____			
KATEGORIJA KOJOM JE UPRAVLJAO _____				GODINA POLAGANJA _____				SPOL SUDIONIKA _____		POSLEDICE _____	
ALKOHOL _____				RAZINA PO ALKOTESTIRANJU _____		ANALIZA KRV I URINA _____		RAZINA PO ANALIZI _____		DROGA _____	
GRUPA DROGE _____				LIJEKOVI _____		UMOR _____		BOLEST _____		SIGURNOSNA SJEDALICA _____	
KACIGA _____		POJAS _____		MOBITEL _____		OZNAKA PRIJAVE _____		INKRIMINACIJA _____		BROJ PRIJAVE _____	
PREZIME _____				IME _____				ROĐEN _____		OIB _____	
DRŽAVLJANSTVO _____				REGISTRACIJSKA OZNAKA VOZILA _____				SVOJSTVO SUDIONIKA _____			
KATEGORIJA KOJOM JE UPRAVLJAO _____				GODINA POLAGANJA _____				SPOL SUDIONIKA _____		POSLEDICE _____	
ALKOHOL _____				RAZINA PO ALKOTESTIRANJU _____		ANALIZA KRV I URINA _____		RAZINA PO ANALIZI _____		DROGA _____	
GRUPA DROGE _____				LIJEKOVI _____		UMOR _____		BOLEST _____		SIGURNOSNA SJEDALICA _____	
KACIGA _____		POJAS _____		MOBITEL _____		OZNAKA PRIJAVE _____		INKRIMINACIJA _____		BROJ PRIJAVE _____	
PREZIME _____				IME _____				ROĐEN _____		OIB _____	
DRŽAVLJANSTVO _____				REGISTRACIJSKA OZNAKA VOZILA _____				SVOJSTVO SUDIONIKA _____			
KATEGORIJA KOJOM JE UPRAVLJAO _____				GODINA POLAGANJA _____				SPOL SUDIONIKA _____		POSLEDICE _____	
ALKOHOL _____				RAZINA PO ALKOTESTIRANJU _____		ANALIZA KRV I URINA _____		RAZINA PO ANALIZI _____		DROGA _____	
GRUPA DROGE _____				LIJEKOVI _____		UMOR _____		BOLEST _____		SIGURNOSNA SJEDALICA _____	
KACIGA _____		POJAS _____		MOBITEL _____		OZNAKA PRIJAVE _____		INKRIMINACIJA _____		BROJ PRIJAVE _____	
POLICIJSKI SLUŽBENIK _____											
OIB POLICIJSKOG SLUŽBENIKA _____											
POTPIS: _____											

Slika 9. Upitnik o prometnoj nesreći, stranica 2/2
Izvor: [56]

Za potrebe izrade ovoga doktorskoga rada, a na temelju sporazuma Fakulteta prometnih znanosti i MUP-a, dobiveni su temeljni podatci o prometnim nesrećama za cijelo područje Republike Hrvatske u razdoblju od 2012. do 2015. godine. Podatci su zaprimljeni u *TXT* formatu za svaku kalendarsku godinu (2012., 2013., 2014. i 2015.), kao i pripadajuće informacije o nazivu i duljini polja zaprimljenih datoteka. U svakoj su kalendarskoj godini dobivene po tri odvojene datoteke podataka o prometnim nesrećama koje su podijeljene na: *Nesreće*, *Vozila* i *Sudionike*.

Inicijalna je obrada preuzetih podataka prometnih nesreća u *TXT* formatu te njihova obrada i spremanje u *CSV* formatu izvršena u tabličnom programu *Microsoft Excel*. *CSV* format najčešće se koristi za razmjenu tabličnih podataka između programa koji koriste međusobno nekompatibilne (često zaštićene i/ili nedokumentirane) formate. Dakle, *CSV* format daje alternativu za uvoz/izvoz podataka između različitih programa, stoga je u radu upravo ovaj format korišten kao veza između različitih programskih rješenja.

Datoteka *Nesreće* čini slog osnovnih podataka o prometnoj nesreći. Redovi u daljnjem tabličnom prikazu označavaju broj pojedine prometne nesreće, ukupan broj redova predstavlja ukupan broj prometnih nesreća za jednu kalendarsku godinu, dok stupci prikazuju attribute o prometnoj nesreći. Tablica 7. prikazuje naziv polja u prvoj datoteci i njegovu duljinu znakova. Iza svakoga se polja nalazi i delimiter ';' koji je dug 1 znak. Tablica 8. prikazuje popis polja vezanih uz informacije o *Vozilima* koja su sudjelovala u prometnoj nesreći. Redovi u ovom slučaju prikazuju broj vozila koja su sudjelovala u prometnim nesrećama. Ukupan broj redova može biti veći od broja prometnih nesreća jer, primjerice, u jednoj prometnoj nesreći može sudjelovati jedno, dva ili više vozila. Tablica 9. prikazuje strukturu sloga o *Sudionicima* prometnih nesreća te kao i kod datoteke *Vozila* ukupan broj redova podataka o sudionicima može iznositi više od ukupnoga broja prometnih nesreća iz prve datoteke *Nesreće*.

Tablica 7. Slog prometnih nesreća

POLJE	DUŽINA
1. BROJ PN	6
2. POLICIJSKA UPRAVA	30
3. POLICIJSKA POSTAJA	30
4. DATUM NEZGODE	8
5. DAN NEZGODE	1
6. VRIJEME PN	4
7. OPĆINA	20
8. MJESTO	30
9. ULICA1	30
10. KUĆNI BROJ	3
11. PODBROJ	2
12. ULICA2	30
13. CESTA	5
14. DIONICA	3
15. PODDIONICA	1
16. STACIONAŽA	6
17. GEOGRAFSKA ŠIRINA	7
18. GEOGRAFSKA DUŽINA	7
19. POSLJEDICA PN	1
20. VRSTA PN	2
21. OKOLNOSTI	2
22. PREKID PROMETA	4
23. UVIĐAJ	1
24. SUDJELOVALO VOZILA	3
25. SUDJELOVALO OSOBA	3
26. KARAKTERISTIKE CESTE	2
27. STANJE KOLNIČKE KONSTRUKCIJE	1
28. STANJE KOLNIČKE POVRŠINE	2
29. REGULACIJA PROMETA	1
30. OGRANIČENJE BRZINE	3
31. VERTIKALNA SIGNALIZACIJA	1
32. HORIZONTALNA SIGNALIZACIJA	1
33. OKOLIŠ	1
34. UVJETI VIDLJIVOSTI	1
35. JAVNA RASVJETA	1
36. ATMOSFERSKE PRILIKE	1
37. KLJUČ PN	8
38. U/VAN NASELJA	1

Tablica 8. Slog vozila


POLJE	DUŽINA
1. REDNI BROJ VOZILA UNUTAR NEZGODE	3
2. BROJ PN	6
3. REGISTARSKO PODRUČJE	2
4. SMJER KRETANJA VOZILA	2
5. VRSTA VOZILA	2
6. DRŽAVA REGISTRACIJE	20
7. PRIKOLICA PRIKLJUČENA	1
8. JAVNI PRIJEVOZ	1
9. GODINA PROIZVODNJE	4
10. TEHNIČKI PREGLED VRIJEDI	1
11. OSIGURANJE VRIJEDI	1
12. PROMETNA DOZVOLA VRIJEDI	1
13. KLJUČ PN	8

Tablica 9. Slog sudionika

POLJE	DUŽINA
1. REDNI BROJ SUDIONIKA UNUTAR NEZGODE	3
2. BROJ PN	6
3. GODINA ROĐENJA	8
4. DRŽAVLJANSTVO	20
5. POSLJEDICE	1
6. POSEBNA STANJA	1
7. SVOJSTVO SUDIONIKA	1
8. KATEGORIJA VOZAČKE DOZVOLE	8
9. GODINA POLAGANJA	4
10. POJAS KORIŠTEN	1
11. KACIGA KORIŠTENA	1
12. MOBILTEL KORIŠTEN	1
13. RADIOSTANICA KORIŠTENA	1
14. OZNAKA PRIJAVE	1
15. INKRIMINACIJA	11
16. ALKOTEST	1
17. RAZINA PO ALKOTESTU	3
18. ANALIZA KRV I URINA	1
19. RAZINA PO ANALIZI	3
20. DROGA	1
21. GRUPA DROGE	1
22. LIJEKOVI	1
23. UMOR	1
24. BOLEST	1
25. ALKOHOL	1
26. RAZINA ALKOHOLA	3
27. SPOL	1
28. KLJUČ PN	8
29. IDENTIFIKATOR VOZILA UNUTAR NESREĆE U KOJEM SE SUDIONIK NALAZIO	3

Važno je napomenuti kako u skladu sa *Zakonom o sigurnosti prometa na cestama* (NN 105/2004) od 20. kolovoza 2004. godine Policija više ne izlazi na očevide prometnih nesreća s manjom materijalnom štetom niti o njima vodi evidenciju. Prema važećem *Pravilniku o načinu postupanja policijskih službenika u obavljanju poslova nadzora i upravljanja prometom na cestama* [57] člankom 30. definirano je postupanje policijskoga službenika u postupku u slučaju prometne nesreće. Ako su posljedice prometne nesreće manje materijalne štete i ako na mjesto

prometne nesreće dođe policijski službenik, prema *Pravilniku* [57] policijski službenik ne radi uviđaj, nego sudionicima prometne nesreće sugerira neka razmijene osobne podatke i podatke o vozilima te popune i potpišu *Europsko izvješće o nesreći*. Policijski službenik ne popunjava statistički list, a događaj se ne evidentira u Informacijskom sustavu Ministarstva unutarnjih poslova. Evidenciju o ovim prometnim nesrećama posjeduju isključivo osiguravajuća društva o autoodgovornosti koja zaprimaju *Europsko izvješće o nesreći* od svojih naručitelja. Prema podacima društva *Croatia osiguranje d.d.* ukupan je udio prometnih nesreća u kojima policija nije obavila očevid u porastu (Grafikon 18.). Iz grafičkoga je prikaza također vidljivo da nema značajnih razlika udjela prijavljenih štetnih događaja od automobilske odgovornosti između područja Grada i Republike Hrvatske. Nažalost, podatci vezani uz udio šteta po kriteriju tipa sudionika (pješač ili biciklist), iz kojih bi se mogao projicirati okvirni udio prometnih nesreća u kojima su sudjelovali pješaci ili biciklisti bez policijskoga izvješća, ne postoje. Navedeno ukazuje na to kako prometne nesreće u znatnom broju nisu u službenoj evidenciji informacijskoga sustava MUP-a te kako su iste dio sive brojke, tj. podizvješćenosti prometnih nesreća (engl. *underreporting road accidents*).



Grafikon 18. Udio prometnih nesreća s policijskim očevidom i bez njega u Republici Hrvatskoj i u Gradu Zagrebu
Izvor: [58]

Prema *Zakonu o policiji* [59] policijske poslove u Ministarstvu unutarnjih poslova obavljaju policijske uprave prema područjima županija (Slika 10.).



Slika 10. Teritorijalni ustroj policijskih uprava u Republici Hrvatskoj
Izvor: [60]

Policijske su uprave podijeljene prema županijama, osim Policijske uprave zagrebačke koja obuhvaća Zagrebačku županiju i Grad Zagreb. Područje je Grada Zagreba operativno podijeljeno na I. i II. postaju Prometne policije Zagreb (ne uključuje dijelove autoceste koji su izvan administrativnoga područja Grada Zagreba) i na Policijsku postaju Sesvete.


3.2.2. Prikupljanje i obrada podataka iz baza Grada Zagreba

Za uspostavljanje lokalne baze podataka, a za potrebu ovoga rada, od raznih su gradskih služba Grada Zagreba prikupljeni digitalni podatci kao što su digitalna cestovna mreža Grada, Generalni urbanistički plan (GUP) Grada Zagreba s namjenom površina te podatci o brojenju motornoga i biciklističkoga prometa na području Grada.


Iz Ureda za katastar i geodetske poslove Grada Zagreba (Katastar) prikupljeni su digitalni podatci u *ESRI shape* formatu. Iz registra prostornih jedinica Grada Zagreba preuzeti su podatci: granice četvrti, granice naselja, granice mjesnih odbora i centralne linije ulica. Slika 11. prikazuje vizualizaciju *ESRI shape* datoteke u QGIS programu u kojoj je vidljiv teritorijalni ustroj Grada Zagreba podijeljen na 17 gradskih četvrti. Slika 12. prikazuje detaljniji prikaz atributnih podataka pojedine duljine centralne projekcije ulice iskazane u metrima. Prikazani su podatci temelj cestovne mreže Grada i njegovih geoprostornih granica omogućavajući daljnju uspostavu, odnosno nadogradnju pouzdane i kvalitetne lokalne baze podataka u GIS

okružju. Ovako utemeljena baza na službenim podacima pruža najbolji korektivni čimbenik unosa ostalih geoprostornih podataka.

Nakon toga je obavljena nadopuna podataka o demografskoj strukturi te urbanim gustoćama za svaku gradsku četvrt. Karakteristični su podatci tablično pridruženi u GIS okružju na temelju informacija iz *Statističkoga ljetopisa Grada Zagreba* [61] i publikacije *Analiza postojećega stanja namjene površina i urbanih gustoća 2011.* [62]




Slika 11. Granice četvrti Grada Zagreba u GIS okružju



Slika 12. Centralne linije ulica s detaljnim prikazom atributa u GIS okružju

Podatci o namjeni površina i prometu iz trenutno važećega Generalnoga urbanističkoga plana (GUP) Grada Zagreba dobiveni su iz Gradskoga ureda za strategijsko planiranje i razvoj Grada Zagreba. Preuzeti su digitalni podatci zapisani u *DWG* formatu. Godina je izrade plana 2011. Početna je obrada podatka izvršena računalnim program AutoCAD u vlasništvu tvrtke *AutoDesk* i danas je jedan od najpoznatijih računalnih programa za crtanje (*Computer Aided Design*) u vektorskom okružju. AutoCAD kao i drugi slični programi podržava niz formata programskih datoteka koje su međusobno kompatibilne s GIS programima. Obradom podatka u AutoCAD programu, poput spajanja i uklanjanja nevažnih slojeva iz originalne datoteke, isti su izvezeni u *DXF* format te integrirani u lokalnu bazu QGIS programa.




Slika 13. Namjena površina Generalnoga urbanističkoga plana Grada Zagreba u *AutoCAD* okružju

Za potrebe je izrade doktorskoga rada korištena skupna namjena površina jer bitno pojednostavljuje analizu obrade podataka. Tablica 10. prikazuje cjelokupan popis atributa s podjelom na šifru, namjenu površina, skupnu namjenu te godinu izrade Plana.

Tablica 10. Tablični prikaz atributa u GIS bazi namjene zemljišta Grada Zagreba

Šifra	Namjena	Skupna namjena	Godina izrade
E	Površina za iskorištavanje mineralnih sirovina	Eksplatacija	2011.
G	Gospodarska namjena	Gospodarska	2011.
I	Proizvodna gospodarska namjena	Gospodarska	2011.
K1	Poslovna gospodarska namjena	Gospodarska	2011.
K2	Trgovački kompleksi – gospodarska namjena	Gospodarska	2011.
T	Ugostiteljski kompleksi	Gospodarska	2011.
TR	Tržnica	Gospodarska	2011.
GR	Groblje	Groblje	2011.
D	Javna i društvena	Javna i društvena	2011.
D1	Upravna – javna i društvena	Javna i društvena	2011.
D2	Socijalna – javna i društvena	Javna i društvena	2011.
D3	Zdravstvena – javna i društvena	Javna i društvena	2011.
D4	Predškolska – javna i društvena	Javna i društvena	2011.
D5	Osnovnoškolska – javna i društvena	Javna i društvena	2011.
D6	Srednjoškolska – javna i društvena	Javna i društvena	2011.
D7	Visoko učilište i znanost - javna i društvena	Javna i društvena	2011.
D8	Kulturna – javna i društvena	Javna i društvena	2011.
D9	Vjerska – javna i društvena	Javna i društvena	2011.
BOT	Botanički vrt	Javne zelene	2011.
JZ	Javne zelene površine	Javne zelene	2011.
ZOO	Zoološki vrt	Javne zelene	2011.
IS	Komunalna infrastruktura	Komunalna	2011.
VC	Vodocrpilište	Komunalna	2011.
O	Poljoprivreda, neuređeno, ostalo	Poljoprivreda, neuređeno, ostalo	2011.
OT	Gospodarenje otpadom	Komunalna	2011.
RA	Rasadnici	Gospodarska	2011.
N	Posebna namjena	Posebna	2011.
AK	Autobusni kolodvor	Promet	2011.
PB	Benzinska postaja	Promet	2011.
P	Parkiralište	Promet	2011.
TE	Terminal	Promet	2011.
TRG	Trgovi	Promet	2011.
Ž	Željeznica	Promet	2011.
-	Prometna površina	Promet	2011.
ZP	Zračni promet	Promet	2011.
R1	Sportsko-rekreacijska namjena s gradnjom	Sport i rekreacija	2011.
R2	Sportsko-rekreacijska namjena bez gradnje	Sport i rekreacija	2011.
RO	Rekreativni odmor	Sport i rekreacija	2011.
M	Mješovita namjena	Stambena i mješovita	2011.
S	Stambena namjena	Stambena i mješovita	2011.
SM	Stambeno-mješovita	Stambena i mješovita	2011.
TT	Transformacija u tijeku	Transformacija	2011.
V1	Vode i vodna dobra – pod vodom	Vode	2011.
V2	Vode i vodna dobra – povremeno pod vodom	Vode	2011.

Kako su preuzeti podaci GUP-a Grada Zagreba u *DWG* formatu bili spremljeni u *Gauss–Krüger* 5 zoni, naknadna je transformacija u novi službeni referentni koordinatni sustav *HTRS96/TM* obavljena u *QGIS* programu. Referentna je podloga za provjeru učitanih podataka digitalna ortofoto karta Republike Hrvatske [63] učitana u *QGIS* program pomoću *WMS* servisa Državne geodetske uprave. Slika 14. prikazuje GUP Grada Zagreba u GIS okružju.



Slika 14. GUP Grada Zagreba, QGIS


Podatci o brojenju biciklističkoga prometa u Gradu Zagrebu preuzeti su od Gradskoga ureda za prostorno uređenje, izgradnju Grada, graditeljstvo, komunalne poslove i promet – Sektor za promet. Na temelju je ovih podataka omogućena izrada prometnoga opterećenja biciklističkoga prometa u gradu Zagrebu te korekcija ručnih brojenja na temelju cjelogodišnjega brojenja biciklističkoga prometa pomoću totema.

U Gradu Zagrebu sve do sredine 2014. godine nije postojalo sustavno brojenje biciklističkoga prometa. Početci se sustavnoga brojenja biciklističkoga prometa temelje na realiziranom projektu *Sustavno brojenje biciklističkoga prometa u gradu Zagrebu* od lipnja 2014. godine. Brojenje se biciklističkoga prometa izvodi s pomoću jednoga fiksnoga brojača (totema) na raskrižju Ulice grada Vukovara i Trga Stjepana Radića, te s pomoću više prenosivih brojača na različitim lokacijama na području grada.




Slika 15. Automatski brojač biciklističkoga prometa u gradu Zagrebu (totem)

Podatci su o parametrima motornoga prometnoga toka dobiveni iz Sektora za komunalno i prometno redarstvo Grada Zagreba. Isključivo je za potrebe izrade ovoga rada omogućen pristup podacima o brojenju prometa. Podatci su prikupljeni s kamera za nadzor prometa s pomoću instaliranoga specijaliziranoga softvera za očitavanje parametara motornoga prometnoga toka (Slika 16. i Slika 17.).




Slika 16. Upravljački dio aplikacije brojenja prometa



Slika 17. Virtualne detektorske petlje na nadzornoj kameri

Grad Zagreb i Odjel prometnoga i komunalnoga redarstva raspolažu s ukupno 354 kamere za nadzor, praćenje i alarmiranje na 118 lokacija. Tijekom predstojećih je dviju godina u planu dodatno proširenje sustava na 50-ak lokacija. Slika 18. prikazuje georeferencirane lokacije nadzornih kamera u središtu grada Zagreba s pripadajućim atributima.



Slika 18. Georeferencirane lokacije nadzornih kamera u središtu grada Zagreba

Kako bi se povećala iskoristivost samoga sustava videonadzora te kako bi se iskoristili svi raspoloživi potencijali, u sklopu proširenja sustava iz 2015 godine započeta je eksperimentalna nadogradnja postojećega sustava sa specijaliziranim programima koji omogućavaju neprekidno i pouzdano brojenje prometa. Tijekom 2016. godine na karakterističnim se lokacijama u gradu provodilo ispitivanje više ponuđenih programa brojenja prometa na terenu, kako bi se testirale njihove mogućnosti u različitim vremenskim uvjetima kao i točnost prikupljenih podataka. U konačnici su dobiveni kvalitetni podatci o parametrima prometnoga toka (brzina, gustoća i protok) s karakterističnih lokacija u gradu na temelju kojih je iskustvenom metodom ekstrapolirano prosječno godišnje opterećenje na druge prometnice u Gradu Zagrebu.

Nažalost, stalno brojenje prometa na cestovnoj mreži Grada Zagreba od strane *Hrvatskih cesta d.o.o.* ne postoji. Stoga modernizacija i nadogradnja sustava nadzornih kamera programima za brojenje prometa predstavlja važan doprinos prometnim planerima i svima onima kojima su podatci potrebni.


3.2.3. Prikupljanje podataka iz OpenStreetMap projekta

OpenStreetMap (OSM) je projekt u kojem trenutačno sudjeluje više od milijun korisnika diljem svijeta s ciljem izrade besplatne i slobodne karte svijeta sa zemljopisnim podatcima. Osnovnim je poticajem razvoja ovoga projekta ponajprije ograničena dostupnost geografskih podataka i njihovo daljnje korištenje. Većina mrežnih karata poput *Google* karata, *Bing* karata i drugih slobodne su za pregledavanje, ali ne i za korištenje njihovih podataka, a koji najčešće podliježu specifičnim autorskim pravima i drugim ograničenjima pri njihovu korištenju.

Specifično za Republiku Hrvatsku postoji domaća *OpenStreetMap* zajednica [64] koja na lokanoj razini omogućava kreiranje podataka i pružanje informacija svim korisnicima *OpenStreetMap* servisa. Za područje Hrvatske na dnevnoj razini mogu se preuzeti recentni podatci u kompresiranom *OSM*, *XML*, i *PBF* formatu s mrežne stranice [65]. Na istoj se mrežnoj stranici također mogu preuzeti i povijesni podatci unatrag posljednjih deset godina.

Uređivanje *OpenStreetMap* podataka obavlja se najčešće pomoću JOSM uređivača (engl. *Java OpenStreetMap Editor*) [66]. Ova aplikacija za uređivanje *OpenStreetMap* podataka također nudi korisniku mogućnost preuzimanja raznih vrsta podataka sa servera. Najčešći je unos podataka s pomoću GPS uređaja korisnika, zatim s pomoću zračnih snimaka, a u posljednje se

vrijeme sve više unose pouzdani podatci iz javnih državnih izvora. Prikaz je osnovne karte podataka vidljiv na mrežnoj stranici <https://www.openstreetmap.org/> (Slika 19.).



Slika 19. *OpenStreetMap* karta
Izvor:[67]

Cestovna je mreža Grada Zagreba, osim preuzetih službenih podataka u ESRI *shape* datoteci iz Ureda za katastar i geodetske poslove, preuzeta i sa servera *OpenStreetMap* zaključno s kolovozom 2016. godine [65]. Preuzimanjem je takve cestovne mreže zadržana postojeća funkcionalna klasifikacija nerazvrstanih cesta na području grada. Za potrebe označavanja cestovne mreže u Republici Hrvatskoj volonteri OSM zajednice koriste Odluku o razvrstavanju cesta [68]. Princip je označenih cesta u OSM-u [69] zadržan i primijenjen u daljnjim istraživanjima (Tablica 11.).


Tablica 11. Klasifikacija cestovne mreže Grada Zagreba prilagođena OSM označavanju

Kategorija prometnice	Napomena
1. Primarne (glavne ili arterijske ceste)	Ceste koje povezuje kvartove unutar grada
2. Sekundarne (sabrne ili distributivne ceste)	Cesta s funkcijom ciljnoga i distributivnoga prometa kvartova
3. Tercijarne (pristupne ceste)	Ceste koje opslužuju razne stambene, poslovne, trgovačke, gospodarske i druge lokalne sadržaje

Slika 19. prikazuje funkcionalnu klasifikaciju cestovnih prometnica pri čemu su žutom bojom označene primarne prometnice te imaju četveroznamenkastu brojčanu oznaku, bijelom su bojom s većom širinom uzorka i peteroznamenkastom brojčanom oznakom definirane sekundarne prometnice, tercijarne prometnice čine sve ostale ceste.

3.2.4. Dodatno terensko istraživanje i prikupljanje podataka

Dodatnim su terenskim istraživanjem ciljanih mjesta i dionica događanja prometnih nesreća u urbanim sredinama prikupljeni ostali podatci (npr. brojenje prometa za procjenu intenziteta prometa na karakterističnim lokacijama) za dokazivanje postavljenih hipoteza. Svrha je terenskih istraživanja pobliže određivanje intenziteta motornoga, biciklističkoga te pješačkoga prometa na široj cestovnoj mreži grada, uz već prethodno prikupljene podatke prometnih tokova od služba Grada Zagreba i internih projekata Fakulteta prometnih znanosti. Brojenje je prometa obavljeno vizualnim prepoznavanjem i bilježenjem na obrazac na najvažnijim pješačkim i biciklističkim lokacijama u Gradu. Točan je odabir karakterističnih lokacija na cestovnoj mreži Grada izvršen uz pomoću QGIS programa na temelju preliminarnih analiza grupiranja prometnih nesreća pješaka i biciklista na određenom prostoru. Brojenje je prometa provedeno dana 13. listopada 2016. (četvrtak) na 44 lokacije pri sunčanom vremenu i temperaturi zraka od 18 °C u 15:00 sati. Slika 20. prikazuje lokacije brojenja prometa podijeljene na četiri skupine, odnosno moda.



Slika 20. Lokacije brojenja prometa u Gradu Zagrebu, listopad, 2016. godina

Plavom su bojom označene lokacije na kojima se istovremeno brojao motorni, pješački i biciklistički promet (11 lokacija), crvenom su bojom označene lokacije na kojima se brojao isključivo pješački promet (8 lokacija), zelenom bojom biciklistički promet (20 lokacija) te su žutom bojom označene lokacije na kojima se brojao pješački i biciklistički promet (5 lokacija).

Kako bi se istovremeno obuhvatile sve ciljane brojačke lokacije, brojenje je prometa izvršeno uz pomoć studenata Fakulteta prometnih znanosti treće godine preddiplomskoga studija. Izvršeno je dnevno brojenja prometa u trajanju od dva sata (od 15:00 do 17:00 sati). Kako bi se točnije odredile karakteristike analiziranih tokova (oscilacije unutar jednoga sata), svaki je sat podijeljen u intervale po 15 minuta. Vozila koja su brojana podijeljena su u pet osnovnih kategorija: osobna vozila, teretna vozila, autobusi, motocikli i bicikli. Brojenje je pješačkoga prometa obavljeno na pješačkim prijelazima i nogostupima.

3.2.5. Ostali izvori korisnih podataka

Karakteristični podatci o brojenju pješačkoga, biciklističkoga i motornoga prometa te parametara prometnoga toka preuzeti su iz interne baze podataka Fakulteta prometnih znanosti Sveučilišta u Zagrebu [70]. Podatci su prikupljeni tijekom dugogodišnje istraživačke djelatnosti djelatnika i studenata Fakulteta, a u kojoj su realizirani neki važniji znanstveno-istraživački projekti, poput *Civitas Elan* (2008. – 2012.) [71] i drugih. Ostali su bitni podatci preuzeti s mrežnih stranica Državnoga hidrometeorološkoga zavoda [72], Hrvatskih cesta d.o.o [73] i drugih izvora.

3.3. Obrada brojenja prometa

Pješački tokovi i pješaćenje predstavljaju temeljni način dolaska do odredišta. Polazeći od činjenice kako je pješaćenje u urbanim sredinama čest oblik kretanja i kako u određenim dijelovima grada dolazi do formiranja intenzivnih pješačkih tokova, ovaj se oblik kretanja mora posebno uzeti u obzir pri izradi prometnih analiza. Pri tom se mora imati na umu i činjenicu kako u grupaciji pješaka postoje i različite starosne grupacije, različite grupacije po razini obrazovanja, različite grupacije po fizičkim značajkama i načinima kretanja, kao i velike individualne razlike pojedinaca prema stavovima i načinu ponašanja u cestovnom prometu. Ovakva raznolikost zahtijeva posebnu pozornost i okretnost u optimalnom rješavanju tokova

pješaka, posebno u situacijama i na mjestima na kojima dolazi do interakcijskih odnosa između pješačkih tokova i tokova vozila.

U središnjem je dijelu grada izgrađena funkcionalna infrastruktura nogostupa, međutim, problem stvaraju parkiranja vozila (propisno i nepropisno parkiranje) pri čemu parkiranje posljedično stvara znatne poteškoće za neometano i sigurno kretanje pješaka, a posebno osoba s invaliditetom, kao i roditelja s dječjim kolicima. Osim toga, parkiranjem vozila neposredno u zoni raskrižja ili pješačkih prijelaza smanjuje se prilazna preglednost za vozače motornih vozila čime se povećava rizik naleta vozila na pješaka ili biciklista. Najčešće je rješenje toga problema postavljanje metalnih ili plastičnih savitljivih stupića, pri čemu se fizički sprječava parkiranje na pješačkim površinama ili se ograničava zauzimanje pješačko-biciklističke površine kod čeonoga parkiranja vozila.

Većina se pješačkih aktivnosti u Gradu Zagrebu odvija u središnjem dijelu grada i oko pješačke zone. Udaljavanjem od središta grada opada intenzitet pješačkoga prometa, osim na određenim lokalnim mjestima i dionicama ulica na kojima su važniji atraktori pješačkoga prometa, primjerice u zoni stajališta javnoga gradskoga prijevoza. Karakteristično je za ta mjesta da uzrokuju kretanje pješaka u valovima, što stvara problem u odvijanju motornoga i nemotoriziranoga prometa. Ostala su važnija mjesta na kojima se javlja značajniji lokalni promet područja oko trgovačkih centara, posebice onih koji se nalaze u zoni stambenoga područja, gradskih tržnica, bolnica, škola i ostalih obrazovnih institucija.

Zemljopisne i infrastrukturne značajke Grada Zagreba omogućavaju uspostavu funkcionalne i sigurne biciklističke mreže kojom se u velikoj mjeri može utjecati na daljnji porast uporabe bicikla kao prijevoznoga sredstva. Jedan je od temeljnih kriterija za vožnju bicikla postojanje i neprekinutost mreže biciklističke infrastrukture [74]. Time se potiče i veća uporaba bicikla. Slika 23. prikazuje postojeću mrežu biciklističkih prometnica na području Grada Zagreba. Daljnjom je analizom biciklističkih prometnica prema vrsti uočljiva dominacija biciklističkih staza u odnosu na biciklističke trakove.

Početkom 2000. godine Grad Zagreb počinje s parcijalnom izgradnjom biciklističke infrastrukture na prometnoj mreži Grada. Prema autorima [75] biciklistička je mreža Grada Zagreba do 2003. godine imala oko 26 km biciklističkih staza. Prema službenom *Izvyješću o biciklističkom podsustavu unutar prometnoga sustava Grada Zagreba* [76] do 2015. godine ukupna je duljina biciklističkih trakova i staza na području grada iznosila oko 250 km, dok je

duljina sportsko–rekreativnih staza na području planine Medvednice oko 289 km. Na području Grada u razdoblju od 2014. godine od 2016. godine na 42 lokacije postavljena su 284 stalka/držača (tzv. klamerice) za parkiranje oko 570 bicikala. Iako je tijekom posljednjih godina zamijećen trend ulaganja u osiguravanje mjesta za parking bicikla, i dalje je potražnja veća od ponude (Slika 21. i Slika 22.).




Slika 21. Biciklističko parkiralište, Vukovarska kod FINE




Slika 22. Biciklističko parkiralište (ograda rampe), Vukovarska kod FINE

Međutim, analizom podataka biciklističkih prometnica iz preuzete baze *OpenStreetMap* projekta na području je Grada Zagreba utvrđeno sveukupno 176,3 km biciklističkih staza i trakova. Struktura je biciklističkih prometnica u Gradu Zagrebu najčešće: biciklistička staza i traka s jedne te iznimno s obje strane ulice. Biciklističke su staze najčešće naknadno izvedene na području pješačke infrastrukture, tj. na nogostupima. Najveću duljinu biciklističke mreže imaju gradske četvrti Trešnjevka – jug i Novi Zagreb – istok. Ove gradske četvrti ujedno imaju i najveći udio biciklističkih staza u odnosu na duljinu ulične mreže (Grafikon 19.). Gradske su četvrti bez označenih biciklističkih staza/traka Brezovica i Medveščak.



Grafikon 19. Duljina biciklističkih staza i trakova po gradskim četvrtima


Nedostatci se postojeće biciklističke infrastrukture ogledaju u činjenici kako ne postoji funkcionalna biciklistička mreža, već samo njezini dijelovi koje treba povezati u jedinstvenu, cjelovitu i funkcionalnu mrežu biciklističkih prometnica (biciklističkih staza i trakova).



Slika 23. Mreža biciklističkih prometnica Grada Zagreba

Izvor: [65]

Osim nepovezanosti biciklističkih prometnica u smislenu mrežu, primjerom je loše prakse nepostojanje biciklističkih prijelaza u zoni raskrižja ili, ako su dizajnirani, neodgovarajuće su pozicionirani unutar raskrižja. Neodgovarajuće pozicioniran biciklistički prijelaz u zoni raskrižja uzrokuje brojne konflikte između pješackoga i biciklističkoga prometnoga toka s jedne strane te biciklističkoga i motornoga s druge strane (Slika 24. i Slika 25.). Prijelaz biciklističke staze ili biciklističkoga traka preko raskrižja u pravilu se označava uz pješački prijelaz na strani bliže središtu raskrižja. Slika 26. prikazuje prekid biciklističke staze u području raskrižja.



Slika 24. Prijelaz biciklističke staze u zoni raskrižja Vukovarska – Miramarska cesta



Slika 25. Konflikt pješačkoga i biciklističkoga prometnoga toka (Vukovarska- Miramarska cesta)



Slika 26. Diskontinuitet biciklističke staze u zoni raskrižja

Jedan je od većih nedostataka postojećih biciklističkih prometnica u Gradu Zagrebu poddimenzioniranost biciklističkih staza označenih na nogostupima, pri čemu se javlja latentan konflikt pješačkoga i biciklističkoga prometnoga toka (Slika 27.). Za očekivati je kako će daljnjim porastom biciklističkoga prometa ovaj problem doći do sve većega izražaja. Stoga postojeća praksa izgradnje mješovitih biciklističkih i pješačkih staza može postojati samo kao prijelazno rješenje u kojem s porastom biciklističkoga prometa mora doći do izdvajanja pješačkoga toka iz biciklističkoga. Daljnji je nedostatak biciklističke prometne infrastrukture nebriga za održavanje postojećih biciklističkih prometnica (Slika 28.). Postojeće se biciklističke prometnice ne održavaju pa se tijekom vremena označeni biciklistički prijelazi u zoni raskrižja izbrišu.



Slika 27. Nedovoljna širina pješačke i biciklističke površine
Izvor: [77]



Slika 28. Neodržavanje postojećih biciklističkih prometnica

Problem biciklističkoga, ali i pješačkoga prometa u središnjem dijelu grada nije riješen jer problemi koje uzrokuje intenzivan motorni promet i zahtjevi za parkiranjem motornih vozila u središnjem dijelu Zagreba u uličnom profilu bitno smanjuju mogućnost izgradnje i uspostave mreže biciklističkih prometnica i udobnijih nogostupa. Osim toga, zamijećeno je kako parkirana vozila i ostali objekti u zoni raskrižja bitno smanjuju prilaznu preglednost raskrižja.

Kao pozitivne primjere razvoja biciklističkih prometnica valja istaknuti kako je GUP-om Grada Zagreba predviđeno da se svugdje gdje se gradi nova ulica ili se vrši rekonstrukcija stare izgradi biciklistička infrastruktura (Slika 29., Slika 30. i Slika 31.), spusti rubnjak u zoni raskrižja, dodaju lanterne za bicikle na raskrižjima sa svjetlosnom signalizacijom, istaknu biciklističke površine crvenom bojom u zonama pojačanoga intenziteta prometa itd.



Slika 29. Novoizgrađena biciklistička prometnica, Marohnićeva ulica




Slika 30. Novoizgrađena biciklistička prometnica, Branimirova ulica



Slika 31. Novoizgrađena biciklistička prometnica, raskrižje na Branimirovoj ulici


Ovisnost je upotrebe bicikla o godišnjem dobu i vremenskim prilikama izrazita kod biciklističkoga prometa. Iz dobivenih je podataka s automatskoga brojača prometa u Gradu Zagrebu vidljivo kako se u zimskim mjesecima intenzitet biciklističkoga prometa smanji za prosječno oko 60 % u odnosu na ljetne mjesece (Grafikon 20.). Najveći je udio korištenja bicikla kao prijevoznoga sredstava zabilježen tijekom svibnja. Nagle promjene vremenskih prilika (kiša, snijeg) koje nisu uvjetovane promjenom godišnjega doba također utječu na upotrebu bicikla kao prijevoznoga sredstava. Udio pješaćenja u ukupnoj raspodjeli putovanja,

ovisno o godišnjem dobu i vremenskim prilikama, ne oscilira u takvom obujmu kao kod biciklista.




Grafikon 20. Mjesečni biciklistički promet s automatskoga brojača prometa (totem) tijekom 2015. godine
Izvor: [78]

Ovisnost je o korištenju bicikla kao o prijevoznom sredstvu u Gradu Zagrebu značajno povezana s meteorološkim prilikama poput oborina u obliku kiše i snijega te dnevne temperature zraka. Uspoređujući brojenja cjelogodišnjega prometa s automatskoga brojača prometa tijekom 2015. godine s podacima Državnoga hidrometeorološkoga zavoda [72] uočene su određene mjesečne nepravilnosti u ukupnom broju zabilježenih biciklista za listopad i studeni. Prema povijesnim podacima Državnoga hidrometeorološkoga zavoda (Grafikon 21. i Grafikon 22.) u listopadu 2015. godine zabilježena je veća količina oborina, gdje je 16 dana u mjesecu padala kiša za razliku od studenoga 2015. godine, s jednim izraženim kišnim danom. Iz navedenoga je vidljivo kako je količina oborina znatno utjecala na smanjenje biciklističkoga prometa u listopadu 2015. godine (24 292 biciklista), odnosno povećanje u studenom 2015. godine (33 818 biciklista).




Grafikon 21. Količina oborina, Zagreb, listopad 2015.
Izvor: [72]




Grafikon 22. Količina oborina, Zagreb, studeni 2015.
Izvor: [72]

Daljnjom je analizom prosječne srednje dnevne temperature zraka u promatranom razdoblju primijećena znatno veća prosječna temperatura zraka u studenom u odnosu na listopad (Grafikon 23.). Osim manje količine oborina tijekom mjeseca studenoga 2015. godine, znatno veće prosječne dnevne temperature zraka za to razdoblje godine dovode do povećanja broja biciklista na prometnicama osjetno više od očekivanoga broja. Slijedom navedenoga, uočljiva je značajna međuovisnost intenziteta biciklističkoga prometa te broja kišnih dana i prosječne dnevne temperature zraka.



Grafikon 23. Srednja dnevna temperatura zraka u Gradu Zagrebu tijekom 2015. godine
Izvor: [72]

Grafikon 24. prikazuje ukupan dnevni promet biciklističkoga prometa s fiksnoga brojača prometa (totema), koji se nalazi na sjevernoj strani prometnice na lokaciji Ulice grada Vukovara i Trga Stjepana Radića. Na grafikonu su prikazani podaci za lipanj 2016. godine, plavi stupac prikazuje ukupan broj biciklista na poprečnom presjeku biciklističke staze. Početni je dan u mjesecu 1. lipnja 2016. srijeda, a završni je 30. lipnja 2016. četvrtak. Zeleni stupac prikazuje broj biciklista koji se kreće u dopuštenom smjeru kretanja biciklističkom stazom, tj. iz smjera istoka prema zapadu, a crveni stupac prikazuje smjer kretanja biciklista u nedopuštenom smjeru, tj. zapad – istok i iznosi oko 40 % biciklista.




Grafikon 24. Dnevni biciklistički promet s automatskoga brojača prometa u lipnju 2016. godine
Izvor: [78]

Analizom su dnevne raspodjele intenziteta biciklističkoga prometa dobiveni očekivani rezultati s obzirom na količinu padalina (kiša) te na prosječnu dnevnu temperaturu zraka. Iz obrađenih je i analiziranih podataka vidljivo kako tijekom radnoga tjedna kiša utječe na smanjenje biciklističkoga prometa 50 – 60 % od uobičajenoga intenziteta biciklističkoga prometa u razdoblju u kojem ne pada kiša.

Osim otežavajućih atmosferskih okolnosti za bicikliste, intenzitet se biciklističkoga prometa značajno mijenja s obzirom na radne dane u tjednu i na vikend. Na temelju analiziranih podataka s automatskoga brojača prometa, pri stabilnim vremenskim uvjetima, vidljivo je kako udio broja biciklista na cestovnim prometnicama tijekom vikenda značajno opada. Subotom intenzitet biciklističkoga prometa iznosi oko 50 %, a nedjeljom oko 25 % prosječnoga dnevnoga prometa radnim danima.

U dnevnim su kretanjima pješaka i biciklista karakteristična vršna opterećenja ujutro između 7 i 8 sati, zatim oko 12 sati te poslijepodnevno opterećenje od 15 do 17 sati. Naravno, svrha putovanja ima bitnu ulogu u ukupnom intenzitetu putovanja, tako je, primjerice, udio pješačkoga prometa znatno veći u jutarnjem i poslijepodnevnom opterećenju u zonama škola ili fakulteta ili u zoni autobusnih i željezničkih kolodvora.



Grafikon 25. Prosječno satno prometno opterećenje biciklističkoga prometa s automatskoga brojača prometa tijekom radnoga dana u srpnju 2015. godine

Slika 32. prikazuje kartu biciklističkoga prometa u Gradu Zagrebu tijekom svibnja 2016. godine. Karta je nastala u okviru europskoga programa *Europski biciklistički izazov* (*The European Cycling Challenge - ECC*), što je najveće urbano ekipno natjecanje građana koje se održava svake godine od 1. do 31. svibnja u brojnim europskim gradovima. Grad Zagreb ovom se programu pridružio 2015. godine te je na temelju podataka od sudionika, koji su sudjelovali u natjecanju, dobivena karta najopterećenijih biciklističkih prometnih koridora u Gradu Zagrebu kao što su Ulica grada Vukovara, Savska cesta, zatim mostovi i pristupne ceste koje povezuju Novi Zagreb sa središtem Grada. Ovako su prikupljeni podatci (na temelju korisničkih zapisa putovanja putem GPS-a) iznimno važni jer mogu planerima i donositeljima odluka poslužiti za donošenje prioriteta pri unaprjeđenju biciklističke infrastrukture na području grada.




Slika 32. Karta biciklističkoga prometa u gradu Zagrebu tijekom svibnja 2016. godine

Izvor: [79]

Na temelju prethodnih spoznaja o biciklističkim prometnim tokovima, prethodnim istraživanjima kao i mjestima na kojima je najveći broj biciklističkih prometnih nesreća određene su lokacije brojenja biciklističkoga prometnoga toka. Provedenim su terenskim istraživanjem tijekom listopada 2016. godine prikupljeni podatci o biciklističkom prometu na 26 lokacija te su uspoređeni s prethodnim istraživanjima [80] iz 2010. i 2012. godine (Grafikon 26.). Iz prikazanih je podataka vidljiv porast biciklističkoga prometa u posljednjih pet godina, uz važnu napomenu kako je brojenje izvršeno tijekom listopada 2016. i kako bi bilo realno za očekivati i veći intenzitet biciklista na prometnicama da je brojenje izvršeno, primjerice, u mjesecu svibnju. Jedini je pad biciklističkoga prometa primijećen na koridoru u Gundulićevoj ulici, što se može tumačiti činjenicom da je brojenje prometa izvršeno u listopadu, a ne u svibnju i da su se, primjerice, biciklistički tokovi preraspodijelili na alternativne paralelne koridore poput Savske i Gajeve ulice na kojoj su tijekom posljednjih pet godina stvorene nove biciklističke staze.


Važna je činjenica koja se može utvrditi stalni porast biciklističkoga prometa u Gradu Zagrebu i više od 100 biciklista tijekom vršnih opterećenja na većini biciklističkih koridora. Prema novom *Pravilniku o biciklističkoj infrastrukturi* [81] samo taj broj biciklista uz minimalan broj pješaka predstavlja kriterij koji zahtijeva segregirane, šire i udobnije biciklističke prometnice. Ako se uzme u obzir činjenica da je većina biciklističkih prometnica izvedena kao biciklističke staze na nogostupima, onda će donositelji odluka morati uložiti znatan napor za usklađivanje postojećega stanja sa zakonskom obvezom.



Grafikon 26. Satni promet bicikla u poslijepodnevnom vršnom opterećenju (2010., 2012. i 2016. godine)


Brojenjem je biciklista obuhvaćena struktura biciklističkoga toka prema spolu. Brojenje je muških i ženskih biciklista izvršeno na trima lokacijama: Savski most, Vukovarska (kod Lisinskoga) i Prilaz baruna Filipovića. Na uzorku je od 668 biciklista utvrđen ukupan udio žena koji upravljaju biciklom, oko 26 %, te muškaraca oko 74 %.

Analizom noćnoga brojenja biciklista, s obzirom na korištenje svjetlosne opreme na biciklu, može se zaključiti kako svaki drugi biciklist uopće ne posjeduje istu pri noćnoj vožnji. Provedenim brojenjem biciklističkoga prometa tijekom 13., 14., i 15. prosinca 2015. godine na uzorku od oko 1 000 biciklista na koridorima u Ulici Hrvatske bratske zajednice, Savskoj cesti, Branimirovoj cesti i Boškovićevoj ulici zabilježeno je oko 39 % biciklista bez svjetala, 10 % samo s prednjim svjetlom, 14 % samo sa stražnjim te 37 % s obama svjetlima na biciklu. Ponovljenim je brojenjem 13. listopada 2016. na uzorku od oko 600 biciklista zamjetan porast broja biciklista koji ne koriste svjetla na biciklu pri noćnoj vožnji (Grafikon 27.). Manji udio biciklista koji nemaju svjetlosnu opremu na svom biciklu, zabilježen tijekom prosinca 2015. godine, može se objasniti činjenicom kako su to vozači koji učestalo koriste bicikl tijekom cijele godine te imaju veću razinu svijesti o važnosti pravilnoga osvjetljenja pri sudjelovanju u prometu.



Grafikon 27. Udio biciklista sa svjetlosnom opremom i bez nje tijekom 2015. i 2016. godine

Na temelju je svih prikupljenih podataka o brojenju prometa motornih vozila kreirana procjena prosječnoga godišnjega dnevnoga prometa na važnijim cestama Grada Zagreba. Dobiveni su podatci o motornom prometu na poprečnim presjecima ulica integrirani u obliku atributnih podataka u lokalnu bazu podataka te su prikazani u QGIS programu (Slika 33.).



Slika 33. Prosječno prometno opterećenje motornoga prometa u Gradu Zagrebu u razdoblju 2012. – 2016. godine

Najopterećenije su gradske prometnice očekivano glavne (primarne) ceste na kojima je prosječni godišnji dnevni promet više od 20 000 vozila. Pojedine sekundarne prometnice također imaju prosječno dnevno opterećenje iznad 20 000 vozila. To se može obrazložiti činjenicom kako se tijekom vremena u zoni tih cesta prenamijenio prostor pri čemu je posljedično došlo do većega prometnoga opterećenja na njima. Primjerom je takve sekundarne prometnice Borongajska cesta u zoni Znanstveno-sveučilišnoga kampusa Borongaj.

3.4. Računalni programi za obradu podataka

Podatci su prometnih nesreća često heterogeni i zbog nepotpunih informacija njihovi međusobni odnosi često ostaju skriveni. Prednost je današnjih istraživanja razvoj naprednih računalnih GIS sustava. Osim toga, uzimajući u obzir podatke koji su donedavno bili nedostupni ili ih je bilo teško prikupiti, omogućeno je vrednovanje postojećih i stvaranje novih modela povećanom razinom sigurnosti u urbanim sredinama.

QGIS (ranije poznat kao i Quantum GIS) je geografski informacijski sustav otvorenoga koda i ujedno je i besplatan za uporabu. Ovaj GIS program omogućuje rad u brojnim operativnim računalnim sustavima kao što su Windows, Mac OS, Android i drugi. Također podržava širok krug vektorskih i rasterskih formata, uključujući ESRI *Shape* datoteke, kao i razne formate baza podataka (PostgreSQL/PostGIS) te omogućuje instalaciju različitih dodataka. QGIS program uvelike se koristi na međunarodnoj razini u akademskim i profesionalnim krugovima te predstavlja alternativni alat za pojedince ili ustanove u odnosu na znatno skuplje slične komercijalne programe u GIS okružju.

QGIS omogućuje pregledavanje, uređivanje i stvaranje raznih vektorskih i rasterskih formata, uključujući ESRI *Shape* datoteke, prostorne podatke u *PostgreSQL/PostGIS* bazama podataka.

ESRI *Shape* format (*SHP*) predstavlja vektorski zapis podataka koji služi za spremanje prostornih podataka. Razvijen je početkom 90-ih godina prošloga stoljeća od strane tvrtke *ESRI* kao otvoreni podatkovni oblik kako bi se omogućila međusobna komunikaciju između *ESRI* programa te drugih GIS programa. *Shape* format sadrži geometrijske podatke nekoga objekta (točka, linija poligon) te atributne podatke koji ga opisuju. *Shape* zapis sastoji se od tri skupa datoteka s različitim ekstenzijama (Tablica 12.).

Tablica 12. Osnovni formati svake ESRI Shape datoteke

Ekstenzija	Opis
SHP	<i>Shape</i> format, služi za spremanje geometrije objekta
SHX	Shape indeks format, indeks koji označava geometriju i omogućava brzo pretraživanje u oba smjera, sprijeda ili straga
DBF	Atributni format, atributi poredani u stupce za svaki objekt

PostgreSQL je sustav za upravljanje objektno-relacijskim bazama podataka. Danas predstavlja jedan od najnaprednijih sustava za upravljanje bazama podataka koji se temelji na slobodnom kodu te se, kao i QGIS, kvalitetom i pouzdanošću može uspoređivati sa sličnim komercijalnim

sustavima [82]. U ovom je radu *PostgreSQL* poslužio kreiranju interne objektno-relacijske baze podataka. Obradeni i spremljeni podatci MUP-a o prometnim nesrećama, s pomoću *Microsoft Excela* u CSV datoteku, uneseni su u *PostgreSQL* bazu podataka u kojoj je omogućeno njihovo povezivanje u međusobne relacije. *PostGIS* je slobodni program koji proširuje *PostgreSQL* sustav za upravljanje bazama podataka, geometrijskim operacijama i tipovima podataka. [83]

Za potrebe je izrade ovoga rada korišten računalni program SPSS (engl. *Statistical Package for the Social Sciences*) za statističku obradu podataka. SPSS je statistički program tvrtke IBM koji u svom programskom paketu sadržava niz statističkih testova i analiza. Osnovni su formati zapisa datoteka u SPSS programu SPV i SAV (Tablica 13.).

Tablica 13. Osnovni formati SPSS datoteke

Ekstenzija	Opis
SPV	format za izlazne datoteke SPSS-a (u starijim verzijama SPSS-a do verzije 15 postojala je ekstenzija .spo)
SAV	služi za spremanje skupa podataka u SPSS programu

U statističkoj je obradi podataka nužno ispravno upisivanje prikupljenih podataka u datoteku, a osnovni su koraci pri početku rada sljedeći:

- kreiranje nove datoteke za upis rezultata
- definiranje varijabla i njihovih karakteristika
- upisivanje prikupljenih podataka.

U radu je izvedena opisna (deskriptivna) statistika koja predstavlja granu statistike koja se bavi predočavanjem i opisivanjem glavnih karakteristika skupljenih podataka pomoću grafikona, dijagrama, tablica i slično. Također, izvedena je i inferencijalna statistička analiza podataka prometnih nesreća s pomoću koje je omogućeno stvaranje zaključaka od pojedinačnih slučajeva do generaliziranih, odnosno općevaljanih.


3.5. Uspostavljanje lokalne baze podataka za potrebe istraživanja

Na temelju preuzetih i prikupljenih podataka o cestovnoj mreži Grada Zagreba, demografskim pokazateljima, GUP-u te brojenju pješackoga, biciklističkoga i motornoga prometa kreirana je jedinstvena lokalna baza podataka integrirana u GIS okružju. Toj je bazi pridružena baza

podataka prometnih nesreća, gdje je u konačnici stvoren temelj za provedbu daljnjih istraživanja.

Postupak pripreme unosa podataka prometnih nesreća u GIS okružje sastoji se od nekoliko koraka. Na temelju prikupljenih podataka od Ministarstva unutarnjih poslova u *TXT* formatu započeta je inicijalna priprema i obrada podataka u *Microsoft Office* paketu programskih aplikacija. Konačnim je ciljem uvesti takve podatke u relacijsku bazu podataka kako bismo podatke mogli prikazati u QGIS programu te kako bismo omogućili obradu u statističkom programu SPSS.


Izvorna je datoteka u tekstualnom *TXT* formatu s pripadajućim podacima prometnih nesreća odvojena s delimiterom između dvaju susjednih podataka, te je svaki unos bio u posebnom redu. Slika 34. prikazuje primjer jedne takve datoteke s osnovnim podacima o vozilima koja su sudjelovala u prometnim nesrećama tijekom 2012. godine.



Slika 34. Zapis datoteke Vozila iz 2012. godine u *TXT* formatu

U svakoj su kalendarskoj godini dobiveni podatci s trima odvojenim datotekama koje nose nazive: *Nesreće*, *Vozila* i *Sudionici*. Podatci su u datotekama složeni u posebnoj strukturi koja je definirana prema preuzetim slogovima (Tablica 7., Tablica 8. i Tablica 9.). Takva je

tekstualna datoteka obrađena u programu *Microsoft Excel* koristeći ugrađene funkcije unutar programa koje učitavaju strukturirane tekstualne datoteke (Slika 35.).



1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
BROJ_PN_god	BROJ_PN	POLICIJSKA UPRAVA	POLICIJSKA POSTAJA	DATUM I VRIJEME	DAN NEZGOD	OPĆINA	MJESTO	ULICA1	KUĆNI BRO																					
2012_26175	26175	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/07 15:40:00.000	5 V. GORICA	V. GORICA	SLAVKA KOLARA																							
2012_26184	26184	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/08 10:40:00.000	6 V. GORICA	RAKITOVEC	RAKITOVEC																							
2012_26195	26195	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/08 20:50:00.000	6 V. GORICA	V. GORICA	UL. 153. BRIG. HRVATSKE VOJSKE																							
2012_26198	26198	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/09 05:49:00.000	7 V. GORICA	V. GORICA	KURILOVEČKA																							
2012_26372	26372	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/10 09:10:00.000	1 V. GORICA	V. GORICA	MATICE HRVATSKE																							
2012_26376	26376	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/10 12:50:00.000	1 V. GORICA	V. GORICA	KNEZA LIUDEVITA POSAVSKOG																							
2012_26385	26385	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/10 23:40:00.000	1 V. GORICA	KOBILIĆ	KOBILIĆ																							
2012_26565	26565	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/11 11:55:00.000	2 V. GORICA	V. GORICA	ZAGREBAČKA																							
2012_26711	26711	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/12 09:32:00.000	3 V. GORICA	RIBNICA	RIBNICA																							
2012_26715	26715	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/12 20:05:00.000	3 ORLE	BUKEVJE	BUKEVJE																							
2012_26768	26768	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 07:50:00.000	4 V. GORICA	V. GORICA	SISAČKA																							
2012_26834	26834	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 09:50:00.000	4 V. GORICA	V. GORICA	ZAGREBAČKA																							
2012_26842	26842	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 09:30:00.000	4 V. GORICA	MIČEVEC	SAVSKA																							
2012_26856	26856	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 14:40:00.000	4 V. GORICA	V. GORICA	KNEZA LIUDEVITA POSAVSKOG																							
2012_26859	26859	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 16:05:00.000	4 V. GORICA	GRADIĆI	GRADIĆI																							
2012_26862	26862	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 21:25:00.000	4 V. GORICA	DONJA LOMNICA	ODRANSKA																							
2012_26864	26864	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 17:58:00.000	4 V. GORICA	V. GORICA	RAKARSKA																							
2012_26868	26868	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 21:25:00.000	4 V. GORICA	PETINA	PETINA																							
2012_26869	26869	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/13 23:30:00.000	4 V. GORICA	V. GORICA	IVANA GORANA KOVAČIĆA																							
2012_26969	26969	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/14 07:00:00.000	5 V. GORICA	VELIKA MLAKA	ZAMLAČKA																							
2012_26977	26977	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/14 07:30:00.000	5 V. GORICA	BUŠEVEC	ZAGREBAČKA																							
2012_27006	27006	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/14 20:50:00.000	5 V. GORICA	V. GORICA	ZAGREBAČKA																							
2012_27019	27019	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/15 10:20:00.000	6 V. GORICA	V. GORICA	ZAGREBAČKA																							
2012_27045	27045	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/16 19:30:00.000	7 V. GORICA	V. GORICA	ŠETALIŠTE FRANJE LUČIĆA																							
2012_27046	27046	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/16 18:35:00.000	7 V. GORICA	V. GORICA	ZAGREBAČKA																							
2012_27049	27049	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/17 00:15:00.000	1 V. GORICA	V. GORICA	KRALJA D. ZVONIMIRA																							
2012_27222	27222	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/17 07:40:00.000	1 V. GORICA	V. GORICA	ZAGREBAČKA																							
2012_27272	27272	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/17 15:30:00.000	1 V. GORICA	V. GORICA	KRALJA PETRA SVAČIĆA																							
2012_27274	27274	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/17 16:00:00.000	1 V. GORICA	V. GORICA	ŠETALIŠTE FRANJE LUČIĆA																							
2012_27452	27452	PP VELIKA GORICA	PP VELIKA GORICA	2012/09/18 20:20:00.000	2 V. GORICA	OBREZINA	OBREZINA																							

Slika 35. Tablica prometnih nesreća nakon povezivanja s jedinstvenim ključem


Podatak u prvom stupcu ove tablice označava broj_PN, tj broj prometne nesreće koji označava prometnu nesreću u pojedinoj godini, svake se godine ponovno započinje od 1. Kako je u jednu tablicu u relacijskoj bazi potrebno unijeti podatke za više godina, potrebno je da podatak o broju prometne nesreće bude jedinstven za svaku godinu kako bismo podatke o vozilu mogli spojiti s podacima o sudionicima i prometnim nesrećama po jedinstvenom ključu (tzv. primarni ključ). U tu je svrhu u tablicu dodano novo polje kojem je spojena godina prometne nesreće i broj prometne nesreće u toj godini, npr. 2012_26175. Ovakvu je prilagodbu bilo potrebno napraviti na svim trima vrstama datoteka (na vozilima, sudionicima i prometnim nesrećama).

Prilagodbu je podataka bilo potrebno napraviti i na datumskim poljima. Primjerice, datum rođenja u datotekama o sudionicima, gdje je zapisana vrijednost 11031939, bilo je potrebno pretvoriti u format 11.03.1939. kako bi takav format mogla pročitati relacijska baza i unijeti u bazu kao datumsko polje. Ovakvu je prilagodbu bilo potrebno napraviti na polju datum nesreće u datoteci o prometnim nesrećama.

Posljednja se izvršena promjena odnosila na polja geometrijska širina i geometrijska dužina. Ova su polja ključna za georeferenciranje lokacija prometnih nesreća na kartama. Podatci su u


izornoj datoteci bili u formatu (4546047;1837053) bez decimalnoga odjeljivanja te je takve podatke trebalo preoblikovati u oblik koji relacijska baza može prepoznati kao lokacijski, kako bismo dobili oblik 45,76797; 18,61814. Svi *Microsoft Excel* dokumenti koji su kreirani spremljeni su u CSV format zbog daljnjega postupka učitavanja u relacijsku bazu.

Nakon obrade podataka u *Microsoft Excelu* koristeći alat *pgAdminIII* kreirane su tri tablice za tri vrste datoteka: Prometna nesreća, Sudionik i Vozilo (Slika 36.). Tablice su kreirane s pomoću opisane strukture izvornih datoteka. Zapisi su iz tablica međusobno povezani preko novostvorenoga zajedničkoga jedinstvenoga polja BrojPN_godina (tzv. primarni ključ).



Slika 36. Kreirane tablice u aplikaciji *pgAdmin III – PostgreSQL*

Nakon što je kreirana baza podataka prometnih nesreća u *pgAdmin III – PostgreSQL* programu, ista je integrirana u QGIS programu s pomoću kojega je omogućena vizualizacija i daljnja obrada podataka. Slika 37. prikazuje lokacije svih prometnih nesreća u Republici Hrvatskoj. Iz prikaza je uočljiva gustoća prometnih nesreća oko većih gradskih središta, ali i raspršenost pojedinih lokacija prometnih nesreća izvan granica Republike Hrvatske. Daljnjom je detaljnom analizom lokacija pojedinih prometnih nesreća uočen već poznati problem točnosti lokacija prometnih nesreća. One su rezultatom netočnih zapisa geografske duljine i širine u UPN obrascu.




Slika 37. Prometne nesreće u Republici Hrvatskoj 2012. – 2014. godine, QGIS

Analizu podataka prometnih nesreća MUP-a u vezi s odstupanjem zabilježenih lokacija prometnih nesreća od njihovih stvarnih geografskih lokacija u Republici Hrvatskoj istraživali su autori u radovima [84] i [85]. Autori [84] su na temelju prikupljenih podataka o prometnim nesrećama na području Republike Hrvatske za 2010. godinu utvrdili značajna odstupanja zabilježenih mjesta nastanka pojedinih prometnih nesreća u odnosu na položaj pojedinih elemenata cestovne mreže. Provjera je promatranih podataka izvršena tako da su informacije o geografskoj duljini i širini uspoređene s ostalim podatcima o mjestu nastanka prometne nesreće koji uključuju naziv ulice, kućni broj te ostale prostorne attribute poput naziva županije, općine ili grada.

U ovom su radu detaljnom analizom podataka prometnih nesreća iz 2012., 2013., 2014. i 2015. godine uočeni prethodno navedeni nedostaci o odstupanju pojedinih lokacija prometnih nesreća uneseni u GIS sustav pomoću geografskih koordinata iz UPN obrasca. Slika 38. prikazuje toplinsku kartu podataka lokacija prometnih nesreća pješaka u Gradu Zagrebu za 2015. godinu. Na prikazu je istaknuto žarište s najvećom koncentracijom prometnih nesreća

pješaka na području I. postaje prometne policije Grada Zagreba u Heinzelovoj ulici. Ovakva su grupiranja prometnih nesreća na području postaja prometne policije uočena analizom i obradom podataka tijekom 2012., 2013. i 2014. godine te je očekivano smanjenje takvih odstupanja tijekom 2015. godine.



Slika 38. Toplinska karta prometnih nesreća pješaka u Gradu Zagrebu tijekom 2015. godine

Na temelju navedenoga, a i s obzirom na relativno mali broj lokacija prometnih nesreća pješaka i biciklista koji su uključeni u istraživanja (1776), pristupilo se provjeri svake lokacije prometne nesreće te je prema potrebi ručno izvršen ispravak lokacije prometnih nesreća. Ispravak je lokacija pojedinih prometnih nesreća izvršen s pomoću unesenih informacija o ulicama i kućnim brojevima koji se nalaze u zapisu svake prometne nesreće. Također, zbog potrebe daljnijeg istraživanja, a u vezi s provedbom identifikacije opasnih mjesta u QGIS programu, ispravljene su lokacije pozicionirane prema središnjoj osi ceste ili prema središtu raskrižja.

4. STATISTIČKA ANALIZA PROMETNIH NESREĆA NA PODRUČJU GRADA ZAGREBA

Za potrebe istraživanja prometnih nesreća pješaka i biciklista u urbanim sredinama u nastavku su statistički obrađene dvije vrste prometnih nesreća:

- nalet na pješaka
- nalet na biciklista.

U ukupnoj su strukturi stradavanja pješaka i biciklista ove dvije vrste prometnih nesreća najbrojnije i uniformne. U Gradu je Zagrebu oko 60 % svih prometnih nesreća u kojima su sudjelovali biciklisti nalet na biciklistu i oko 80 % svih prometnih nesreća u kojima su sudjelovali pješaci nalet na pješaka.

Istraživanjem je prometnih nesreća pješaka i biciklista u Gradu Zagrebu obuhvaćeno 1 776 slučajeva ($N = 1\,776$) koji su zabilježeni u bazi podataka MUP-a za godine 2012., 2013. i 2014. Od navedenoga je broja bilo 1 333 naleta na pješaka i 443 naleta na bicikliste. U te je tri godine zabilježeno ukupno 23 707 prometnih nesreća na području Grada, tako da postotak učešća naleta na pješaka čini **5,6 %** od ukupnoga broja prometnih nesreća, dok postotak učešća naleta na bicikliste čini **1,9 %** od ukupnoga broja prometnih nesreća. Iz baze je podataka MUP-a u svrhu analize izdvojeno dvadesetak varijabla o prometnim nesrećama pješaka i biciklista koje su svrstane u sljedećih pet skupina:

- opći podatci o prometnim nesrećama
- podatci o vremenu i meteorološkim uvjetima prometnih nesreća
- podatci o okruženju
- podatci o cestovnoj infrastrukturi
- podatci o prometnim varijablama.

Deskriptivna je statistička analiza prometnih nesreća predstavljena po tim skupinama podataka. Uzorak je prometnih nesreća selektiran, neslučajan i velik.

Drugu skupinu podataka u ovom istraživanju čine podatci o namjeni zemljišta i urbanim gustoćama. Oni su prikupljeni s pomoću QGIS programa iz lokalne baze podataka za pojedine gradske četvrti ($N_2 = 17$) i bit će posebno analizirani.

Metode su statističke analize koje su ovdje korištene za obje vrste statističkih jedinica (prometne nesreće i gradske četvrti) deskriptivne (relativni brojevi, srednje vrijednosti, mjere disperzije, *Pearsonov* koeficijent korelacije ranga), metode inferencijalne statističke analize (hi-kvadrat test, t-test i F-test razlike između aritmetičkih sredina, kao i t-test razlike između proporcija) te metode multivarijantne statističke analize (klaster analiza, logistička regresijska analiza). Zaključci u vezi s razlikama i povezanosti među varijablama donošeni su na uobičajenoj razini signifikantnosti od 0,05, odnosno uz pouzdanost od 95 %. [86]

Rezultati su analize izneseni i opisani u trima potpoglavljima:

- deskriptivna statistička analiza podataka o prometnim nesrećama
- inferencijalna statistička analiza podataka o prometnim nesrećama
- deskriptivna statistička analiza podataka po gradskim četvrtima.


4.1. Deskriptivna statistička analiza podataka o prometnim nesrećama

4.1.1. Analiza općih podataka o prometnim nesrećama

Rezultati su ove analize predstavljeni u nekoliko tablica i grafikona. Tablice su većinom kombinirane kako bi se u njima prikazala struktura prema nekoj od varijabla i prema vrsti prometne nesreće (nalet na pješaka, nalet na bicikl). Tablica 14. prikazuje podatke o ukupnom broju prometnih nesreća u Gradu Zagrebu i od toga broj naleta na pješaka i naleta na bicikl po godinama. Grafikon 28. prikazuje kretanje udjela naleta na pješaka u ukupnom broju prometnih nesreća kao i udjela naleta na bicikl u ukupnom broju prometnih nesreća u Gradu.

Tablica 14. Ukupan broj prometnih nesreća u Gradu Zagrebu po godinama i broj naleta na pješaka i naleta na bicikl (apsolutno i u postotcima)

Godina	Ukupan broj prometnih nesreća	od toga broj		Ukupno	Postotci od ukupnoga broja prometnih nesreća		Ukupno
		naleta na pješaka	naleta na bicikl		naleta na pješaka	naleta na bicikl	
2012.	9255	437	154	591	4,7	1,7	6,4
2013.	7644	439	135	574	5,7	1,8	7,5
2014.	6 808	457	154	611	6,7	2,3	9,0
Ukupno	23 707	1 333	443	1 776	5,6	1,9	7,5



Grafikon 28. Postotci naleta na pješaka i postotci naleta na bicikl od ukupnoga broja prometnih nesreća u Gradu Zagrebu 2012. – 2014. godine

Ukupan je broj prometnih nesreća u Gradu Zagrebu u promatrane tri godine padao za prosječno 1 224 prometne nesreće godišnje, pa je s 9 255 prometnih nesreća u 2012. godini pao na 6 808 prometnih nesreća u 2014. godini. Prosječan godišnji pad ukupnoga broja prometnih nesreća u tom trogodišnjem razdoblju iznosi 14,2 %.

Broj naleta na pješaka i broj naleta na bicikliste u promatranom razdoblju nema tendenciju ni rasta ni pada, promatrano u apsolutnim brojkama. Međutim, obje te pojave u relativnom iznosu (u postotku od ukupnoga broja prometnih nesreća) imaju jasnu tendenciju rasta. Tako je udio naleta na pješaka u ukupnom broju prometnih nesreća porastao s 4,7 % na 6,7 %. Udio je naleta na bicikl u istom razdoblju porastao s 1,7 % na 2,3 % (Grafikon 28.). Obje su pojave u tom razdoblju zajedno porasle sa 6,4 % na 9,0 %.

U nastavku su analize promatrani broj naleta na pješaka, odnosno broj naleta na bicikliste za sve tri godine zajedno. Tablica 15. prikazuje posljedice naleta na pješaka, odnosno naleta na bicikl za sve tri godine zajedno.

Tablica 15. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema posljedicama (N = 1776)

Posljedica prometne nesreće	Vrsta prometne nesreće		Ukupno
	nalet na pješaka	nalet na bicikl	
s poginulim osobama	27	3	30
s ozlijeđenim osobama	1 201	314	1 515
s materijalnom štetom	105	126	231
Ukupno	1 333	443	1 776

Najteže su posljedice naleta na pješaka, odnosno naleta na bicikl, smrtni ishodi. U Gradu je Zagrebu bilo po devet smrtno stradalih pješaka godišnje, odnosno po jedan poginuli biciklist godišnje. Teže ili lakše ozlijeđenih pješaka bilo je 400 godišnje, odnosno 105 biciklista

godišnje. Može se zaključiti kako svakoga dana u Gradu Zagrebu biva ozlijeđen jedan pješak, odnosno svaka tri dana biva ozlijeđen jedan biciklist.

Tablica 16. prikazuje spolnu struktura stradalih pješaka i biciklista u razdoblju od tri godine.

Tablica 16. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema spolu stradalih pješaka i biciklista (u postotcima)

Spol	Vrsta prometne nesreće	
	nalet na pješaka	nalet na bicikl
muški	58	72
ženski	42	28
Ukupno	100	100

Prema spolnoj strukturi uočava se da u prometnim nesrećama naleta na pješaka, odnosno naleta na bicikl više stradavaju muškarci (58 % muških pješaka i 72 % muških biciklista) nego žene (42 % ženskih pješaka i 28 % ženskih biciklista). Udio je ukupnoga broja pješaka u prometu podjednak po spolu. Na temelju provedenoga brojenja biciklista po spolu omjer muškaraca i žena koji koriste bicikl iznosio je 74/26. Navedeni omjer gotovo u potpunosti odgovara omjeru stradalih biciklista. Ipak, u cjelini (za pješake i za bicikliste zajedno), može se zaključiti kako su muškarci rizičnija skupina.

Tablica 17. prikazuje dobnu strukturu stradalih pješaka i biciklista prema posljedicama u promatranom trogodišnjem razdoblju.

Tablica 17. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu za razdoblje 2012. – 2014. godine prema dobi stradalih pješaka i biciklista i prema posljedicama

Dob	Pješaci prema posljedicama			Biciklisti prema posljedicama		
	poginuli	teže ozlijeđeni	lakše ozlijeđeni	poginuli	teže ozlijeđeni	lakše ozlijeđeni
0 – 6	-	7	31	-	1	2
7 – 13	2	29	101	-	7	22
14 – 17	-	25	82	-	9	25
18 – 24	-	39	129	1	29	74
25 – 34	3	35	113	1	48	121
35 – 44	3	31	72	-	35	74
45 – 54	1	46	95	-	31	62
55 – 64	6	65	118	-	34	48
65 i više	14	127	151	2	19	34
Ukupno	29	404	892	4	213	462

Napomena: Podatci se u ovoj tablici ne podudaraju s onima u drugim tablicama jer obuhvaćaju sve stradale pješake i bicikliste u prometnim nesrećama u Gradu Zagrebu, stoga je broj stradalih i ozlijeđenih nešto veći od samoga broja prometnih nesreća koje su prikazane u svim ostalim tablicama.

Zaključci o najčešćoj dobi poginulih i ozlijeđenih osoba nisu mogući na temelju frekvencija iz tabličnoga prikaza (Tablica 17.) jer one nisu usporedive međusobno, jer se odnose na razrede

različitih veličina. Nakon korekcije frekvencija izračunana je najčešća dob (mod) za svaku od šest skupina sudionika u prometu te su dobiveni sljedeći rezultati:

- 29 poginulih pješaka u dobi je preko 65 godina
- 404 teže ozlijeđenih pješaka u dobi je preko 65 godina
- 892 lakše ozlijeđenih pješaka u dobi je od 17,0 godina
- 4 poginula biciklista, nerealno je izračunavati dob zbog malih frekvencija
- 213 teže ozlijeđenih biciklista u dobi je od 29,9 godina
- 462 lakše ozlijeđenih biciklista u dobi je od 27,5 godina.

Prema tomu, pješaci teže stradavaju u starijoj životnoj dobi, dok su lakše ozlijeđeni pješaci uglavnom mlađe životne dobi (17 godina). Kod biciklista je najčešća dob kod težih ozljeda oko 30 godina, a kod lakših ozljeda nešto manje, 27,5 godina.

Tablica 17. prikazuje broj stradalih, a ne broj prometnih nesreća, stoga je moguće te podatke uspoređivati s vremenom u kojem su se stradavanja događala. Promatrane tri godine imaju 1 096 dana pa se mogu izračunati sljedeća dva relativna broja:

- svakih 10 dana u gradu Zagrebu strada 12 pješaka (biva teže ili lakše ozlijeđeno)
- svakih 10 dana u gradu Zagrebu strada 6 biciklista (biva teže ili lakše ozlijeđeno).

Tablica 18. daje raspodjelu prometnih nesreća pješaka i biciklista prema 11 općina (kvartova) Grada Zagreba. Takav je prikaz isključivo interna podjela područja grada prema klasifikaciji MUP-a te trenutno ne odgovara službenoj podjeli područja grada na 17 gradskih četvrti.

Tablica 18. Broj naleta na pješaka i naleta na bicikl u gradu Zagrebu za razdoblje 2012. – 2014. godine prema bivšim općinama (N = 1776)

Općina (kvart)	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
Zagreb-Centar	149	36	185
Zagreb-Črnomerec	120	24	144
Zagreb-Dubrava	129	35	164
Zagreb-Maksimir	135	27	162
Zagreb-Medveščak	105	24	129
Zagreb-Noví Zagreb	138	56	194
Zagreb-Peščenica	78	44	122
Zagreb-Sesvete	87	27	114
Zagreb-Susedgrad	87	29	116
Zagreb-Trešnjevka	202	82	284
Zagreb-Trnje	103	59	162
Ukupno	1 333	443	1 776

Najviše je naleta na pješaka, kao i naleta na bicikl bilo na području općine Zagreb – Trešnjevka. Podatci po općinama nisu usporedivi s obzirom na različitu gustoću prometne mreže, što će u nastavku biti analizirano na svih 17 gradskih četvrti, a na temelju dobivene obrade podataka prometnih nesreća iz uspostavljene lokalne baze podataka s pomoću QGIS-a.

Tablica 19. prikazuje detaljne podatke o okolnostima nastanka prometne nesreće. Bitno je napomenuti kako ovi upisani podatci predstavljaju subjektivan dojam policijskoga djelatnika koji je obavio očevid prometne nesreće te ne predstavljaju isključivi uzrok nastanka prometne nesreće. Stoga je pokazatelje o okolnostima nastanka prometne nesreće potrebno razmatrati s određenom rezervom. Točne se okolnosti događanja donose u eventualnom sudskom postupku, međutim, takve informacije nisu poznate i u konačnici se može zaključiti da je prisutna još jedna siva brojka u vezi s podizvještavanjem o prometnim nesrećama.

Tablica 19. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu za razdoblje 2012. – 2014. godine prema okolnostima (N = 1776)

Šifra.	Okolnosti prometne nesreće	Vrsta prometne nesreće		
		nalet na pješaka	nalet na bicikl	Ukupno
01	nepropisna brzina	14	2	16
02	brzina neprimjerena uvjetima	283	13	296
03	vožnja na nedovoljnoj udaljenosti	2	2	4
04	zakašnjelo uočavanje opasnosti	20	-	20
05	nepropisno pretjecanje	3	10	13
06	nepropisno obilaženje	25	9	34
07	nepropisno mimoilaženje	2	2	4
08	nepropisno uključivanje u promet	17	211	228
09	nepropisno skretanje	92	31	123
10	nepropisno okretanje	2	1	3
11	nepropisna vožnja unatrag	115	4	119
12	nepropisno prestrojavanje	1	1	2
13	nepoštivanje prednosti prolaska	60	74	134
14	nepropisno parkiranje	1	-	1
16	nepoštivanje svjetlosnoga znaka	35	19	54
18	nemarno postupanje s vozilom	10	6	16
19	ostale pogreške vozača	301	47	348
20	nepropisno kretanje vozila na kolniku	16	10	26
21	pješak nije poštivao svjetlosni znak	75	1	76
22	pješak nije koristio obilježeni pješački prijelaz	126	-	126
23	pješak nije koristio pothodnik/nathodnik	9	-	9
24	ostale pogreške pješaka	124	-	124
	Ukupno	1 333	443	1 776

Tablica 20. prikazuje zbirni poredak okolnosti prometnih nesreća pješaka i biciklista od najučestalijih do manje učestalih.

Tablica 20. Broj naleta na pješaka i naleta na bicikl u gradu Zagrebu za razdoblje 2012. – 2014. godine prema okolnostima (N = 1776) – redoslijedom prvih 10 najučestalijih

Šif.	Okolnosti prometne nesreće	Vrsta prometne nesreće		
		nalet na pješaka	nalet na bicikl	Ukupno
19	ostale pogreške vozača	301	47	348
02	brzina neprimjerena uvjetima	283	13	296
08	nepropisno uključivanje u promet	17	211	228
13	nepoštivanje prednosti prolaska	60	74	134
22	pješak nije koristio obilježeni pješački prijelaz	126	-	126
24	ostale pogreške pješaka	124	-	124
09	nepropisno skretanje	92	31	123
11	nepropisna vožnja unatrag	115	4	119
21	pješak nije poštivao svjetlosni znak	75	1	76
16	nepoštivanje svjetlosnoga znaka	35	19	54
	ostalih 12 okolnosti	105	43	148
	Ukupno	1 333	443	1 776

Najčešćim su uzrokom naleta na pješaka ostale pogreške vozača, kao i brzina neprimjerena uvjetima na cesti. Kod naleta na bicikl najveći je uzrok prometnih nesreća nepropisno uključivanje u promet (kod 48 % prometnih nesreća), dok na sve ostale okolnosti otpada 52 % prometnih nesreća naleta na bicikl.

4.1.2. Analiza podataka o vremenu i uvjetima pri događanju prometnih nesreća

S obzirom na vrijeme prometnih nesreća analizirat će podatci po mjesecima, zatim po danima i konačno po satima u kojima su se dogodili naleti na pješaka ili na bicikl. Tablica 21. prikazuje analizu prometnih nesreća po mjesecima u kojima su se dogodile, Tablica 22. prikazuje prometne nesreće prema danima u tjednu te Tablica 23. prikazuje prometne nesreće prema satima u danu. Od meteoroloških uvjeta postoje podatci prema vidljivosti (Tablica 24.) i prema atmosferskim prilikama (Tablica 25.).

Tablica 21. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema mjesecima (N = 1776)

Mjesec	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
siječanj	105	14	119
veljača	100	13	113
ožujak	117	29	146
travanj	114	41	155
svibanj	112	50	162
lipanj	106	59	165
srpanj	76	69	145
kolovoz	66	37	103
rujan	127	38	165
listopad	147	45	192
studen	126	27	153
prosinac	137	21	158
Ukupno	1 333	443	1 776

Najveći je broj stradavanja pješaka zabilježen u listopadu, a biciklista u srpnju kada je i promet bicikala vjerojatno veći. Zanimljivo je kakoi su upravo ljetni mjeseci (srpanj i kolovoz) razdoblja kada pješaci najmanje stradavaju, najvjerojatnije zbog najmanje gustoće prometa u tim mjesecima.

Tablica 22. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema danima u tjednu (N = 1776)

Dan	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
ponedjeljak	200	72	272
utorak	250	89	339
srijeda	226	59	285
četvrtak	224	64	288
petak	227	65	292
subota	118	55	173
nedjelja	88	39	127
Ukupno	1 333	443	1 776

Najmanje naleta i na pješake i na bicikle bilježi se nedjeljom kada je najmanja gustoća prometa. Najveći je broj stradanja i pješaka i bicikla zabilježen utorkom.

Tablica 23. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema satima u danu (N = 1776)

Sat	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
0 – 1	8	-	8
1 – 2	8	3	11
2 – 3	4	1	5
3 – 4	7	-	7
4 – 5	9	-	9
5 – 6	13	3	16
6 – 7	24	15	39
7 – 8	78	17	95
8 – 9	62	26	88
9 – 10	80	16	96
10 – 11	74	24	98
11 – 12	76	20	96
12 – 13	90	26	116
13 – 14	91	33	124
14 – 15	81	32	113
15 – 16	91	41	132
16 – 17	108	52	160
17 – 18	96	32	128
18 – 19	97	34	131
19 – 20	87	25	112
20 – 21	76	20	96
21 – 22	34	15	49
22 – 23	22	6	28
23 – 24	17	2	19
Ukupno	1 333	443	1 776

Kako raste gustoća prometa od ranih jutarnjih sati, tako i postupno raste broj stradavanja pješaka u naletima na njih. Najveći je broj stradavanja pješaka u prometu između 16 i 17 sati, te to vrijedi i za bicikle. Prema kraju dana, u kasnim noćnim satima, opada gustoća prometa i ugroženost, kako pješaka tako i biciklista.

Tablica 24. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema uvjetima vidljivosti (N = 1776)

Uvjeti	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
svitanje	7	2	9
dan	938	370	1 308
sumrak	32	8	40
noć	356	63	419
Ukupno	1 333	443	1 776

Najveći je broj prometnih nesreća i pješaka i biciklista danju kada je i promet najgušći. Sljedeće je razdoblje po učestalosti prometnih nesreća noćno razdoblje.

Tablica 25. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema atmosferskim prilikama (N = 1776)

Atmosferske prilike	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
vedro	693	298	991
oblačno	443	124	567
kiša	163	17	180
magla	5	1	6
snijeg	28	2	30
slana	-	1	1
ostalo	1	-	1
Ukupno	1 333	443	1 776

Najveći je broj prometnih nesreća i pješaka i biciklista za vedroga vremena jer su takve vremenske prilike i najčešće. Manje ih je za oblačnoga vremena, još manje za kišovitoga vremena, a najmanje kada sniježi. Bolji su atmosferski uvjeti češći, a lošiji rjeđi pa je tom logikom i broj prometnih nesreća veći za dobrog vremena, a manji za lošijega vremena.

4.1.3. Analiza podataka o okruženju pri događanju prometnih nesreća

Tablica 26. prikazuje podatke o broju prometnih nesreća s obzirom na uređenost okoliša u promatranom trogodišnjem razdoblju.

Tablica 26. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema uređenosti okoliša (N = 1776)

Okoliš	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
uređen	1 305	434	1 739
stalno održavan	28	9	37
izraziti nedostaci u okolišu	-	-	-
Ukupno	1 333	443	1 776

Tablica 27. prikazuje podatke o javnoj rasvjeti u promatranom trogodišnjem razdoblju.

Tablica 27. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema funkcioniranju javne rasvjete (N = 1776)

Javna rasvjeta	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
u funkciji	842	238	1 080
nije u funkciji	482	202	684
nema javne rasvjete	9	3	12
Ukupno	1 333	443	1 776

Problem je neuređenosti okoliša malen jer je kod 98 % prometnih nesreća okoliš bio uređen, a tek je kod 2 % prometnih nesreća zabilježen podatak o okolišu kao „stalno održavanom”, dok

nije bilo niti jednoga slučaja s izrazitim nedostacima u okolišu.

Situacija je kod javne rasvjete na prvi pogled lošija jer u 39 % prometnih nesreća javna rasvjeta nije bila u funkciji ili je uopće nije bilo. Međutim, taj podatak treba staviti u odnos s vidljivošću, odnosno noćnim uvjetima u kojima je javna rasvjeta važna. Kod prometnih nesreća naleta na pješaka i naleta na bicikl noću, kod svitanja ili u sumrak postotak nefunkcioniranja ili nepostojanja javne rasvjete iznosi 1,8 %, odnosno kod 32 prometne nesreće nije bilo javne rasvjete.

4.1.4. Analiza podataka o cestovnoj infrastrukturi pri događanju prometnih nesreća

Kod razmatranja stanja u cestovnoj infrastrukturi analizirane su tri varijable: karakteristike ceste, stanje kolničkoga zastora i stanje površine kolnika. U nastavku su prikazani podatci o broju prometnih nesreća s obzirom na karakteristike ceste (Tablica 28.), podatci u sažetijem obliku i poredani prema učestalosti (Tablica 29.), podatci o prometnim nesrećama s obzirom na stanje kolničkoga zastora (Tablica 30.) te podatci o prometnim nesrećama s obzirom na stanje površine kolnika (Tablica 31.).

Tablica 28. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema karakteristikama ceste (N = 1776)

Karakteristike ceste	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
T raskrižje	335	199	534
Y raskrižje	14	6	20
četverokrako raskrižje	339	113	452
kružni tok	20	5	25
ostalo	11	1	12
most	-	1	1
tunel	1	-	1
prijelaz preko željezničke pruge-zaštićen-otvoren	1	-	1
cesta u zavoju	24	6	30
ravni cestovni potez	444	82	526
parkiralište	43	5	48
pješački prijelaz	27	1	28
nogostup	51	18	69
biciklistička staza	4	3	7
ostalo	13	2	15
pješačka zona	6	1	7
Ukupno	1 333	443	1 776

Tablica 29. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema karakteristikama ceste (N = 1776) – poredano prema učestalosti

Karakteristike ceste	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
T raskrižje	335	199	534
ravni cestovni potez	444	82	526
četverokrako raskrižje	339	113	452
nogostup	51	18	69
parkiralište	43	5	48
ostalo	121	26	147
Ukupno	1 333	443	1 776

Najviše prometnih nesreća i kod pješaka i kod biciklista događa se na trima tipovima cesta: na T raskrižju, na ravnom cestovnom potezu i na četverokrakom raskrižju. Broj je prometnih nesreća podjednak na tim trima vrstama cesta, a zajedno se na njima događa 84 % prometnih nesreća naleta na pješaka te 89 % prometnih nesreća naleta na bicikl.

Tablica 30. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema stanju kolničkoga zastora (N = 1776)

Kolnički zastor	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
dobar	1 326	443	1 769
manja oštećenja	-	-	-
loš	7	-	7
Ukupno	1 333	443	1 776

Kolnički je zastor kod velike većine prometnih nesreća bio dobar (kod 99,6 % prometnih nesreća i pješaka i biciklista zajedno). Kolnik je bio loš samo kod 0,5 % prometnih nesreća naleta na pješaka.

Tablica 31. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema stanju površine kolnika (N = 1776)

Kolnik	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
suh-čist	972	395	1 367
suh-pijesak, šljunak	4	-	4
mokar	323	44	367
blato	2	1	3
snijeg razgrnut	11	-	11
snijeg nije razgrnut	11	-	11
zaleđen – nije posut	1	-	1
zemlja suha	8	3	11
zemlja mokra	1	-	1
Ukupno	1 333	443	1 776

Kod 77 % prometnih nesreća i pješaka i biciklista kolnik je bio suh, odnosno čist. Kod 21 % prometnih nesreća nije bio idealan zbog toga jer je bio mokar. Kod preostalih 2 % prometnih nesreća nije bio dobar zbog toga jer je bio posut pijeskom, šljunkom, blatom, snijegom, zemljom ili je bio zaleđen.

4.1.5. Analiza podataka o prometnim uvjetima pri događanju prometnih nesreća

U posljednjoj su skupini podataka o prometnim nesrećama naleta na pješaka i naleta na bicikl razmatrane četiri varijable pa su prometne nesreće iskazane prema:

- ograničenjima brzine (Tablica 32.)
- regulaciji prometa (Tablica 33.)
- vertikalnoj signalizaciji (Tablica 34.)
- horizontalnoj signalizaciji (Tablica 35.).

Tablica 32. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema ograničenjima brzine (N = 1776)

Ograničenje brzine km/sat	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
10	8	2	10
20	45	9	54
30	18	1	19
40	74	19	93
50	1129	385	1 514
60	36	24	60
70	20	3	23
80	3	0	3
Ukupno	1 333	443	1 776

Kako je riječ o prometnim nesrećama u Gradu Zagrebu, većina ih se dogodila u uvjetima ograničenja brzine vozila od 50 km/sat (85 % nesreća). Kod većih ograničenja (na 10, 20, 30 ili 40 km/h) dogodilo se 10 % prometnih nesreća, dok se preostalih 5 % nesreća dogodilo kod ograničenja na 60, 70 ili 80 km/h. Prosječno je ograničenje bilo na 48,8 km/h i vrlo se malo razlikuje kod prometnih nesreća naleta na pješaka (48,6 km/h) i prometnih nesreća naleta na bicikl (49,4 km/h).

Tablica 33. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema regulaciji prometa (N = 1776)

Regulacija prometa	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
prometni znakovi	700	264	964
ovlaštena službena osoba	4	4	8
pravila prometa	343	84	427
semafor uključen u normalan režim rada	280	91	371
semafor sa žutim treptavim svjetlom	6	-	6
Ukupno	1 333	443	1 776

Regulacija je prometa kod većine prometnih nesreća bila s pomoću prometnih znakova (kod 54 % prometnih nesreća). Druga je vrsta regulacije s obzirom na učestalost bila s pomoću pravila prometa (24 %), dok je treća vrsta regulacije s pomoću semafora s normalnim režimom rada (21 %). Na ostala dva načina regulacije prometa (ovlaštena službena osoba ili semafor sa žutim treptavim svjetlom) otpada svega 1 % prometnih nesreća. Navedena se četiri postotka neznatno razlikuju kada se oni računaju samo za prometne nesreće naleta na pješaka u odnosu na postotke koji su računani samo za prometne nesreće naleta na bicikl. Dakle, najsigurnija je regulacija prometa s pomoću semafora postojala kod svake pete prometne nesreće, dok su se preostale četiri prometne nesreće dogodile u okolnostima manje učinkovite regulacije prometa (s pomoću prometnih znakova i na temelju pravila prometa).

Tablica 34. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema kvaliteti vertikalne signalizacije (N = 1776)

Kvaliteta vertikalne signalizacije	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
dobra	1 266	421	1 687
oštećena	1	-	1
loša	2	1	3
nema je	64	21	85
Ukupno	1 333	443	1 776

Kod 95 % prometnih nesreća vertikalna je signalizacija bila dobra, dok je kod 5 % prometnih nesreća ona bila oštećena, loša ili je nije ni bilo.

Tablica 35. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema kvaliteti horizontalne signalizacije (N = 1776)


Kvaliteta horizontalne signalizacije	Vrsta prometne nesreće		
	nalet na pješaka	nalet na bicikl	Ukupno
dobra	1 269	416	1 685
manjkava	5	3	8
loša	1	2	3
nema je	58	22	80
Ukupno	1 333	443	1 776

Kod 93 % prometnih nesreća horizontalna je signalizacija bila dobra, dok je kod 7 % prometnih nesreća ona bila manjkava, loša ili je nije ni bilo. U odnosu na vertikalnu signalizaciju to znači da je bilo nešto lošije stanje kod horizontalne signalizacije.

Na kraju je ovoga poglavlja prikazana analiza pojedinih skupina varijabla koje su utjecale na nastanak prometnih nesreća (Grafikon 28. i Grafikon 29.). Prikazane su prometne nesreće u Gradu Zagrebu za promatrano razdoblje prema postojanju pojedinih od osam vanjskih nepovoljnih okolnosti (iskazano u postocima od N = 1333 kod naleta na pješaka, odnosno od N = 443 kod naleta na bicikl). Iz grafikona se vidi koje su vanjske okolnosti (lošija vidljivost, lošije atmosferske prilike i neodgovarajuća površina kolnika) češće doprinijele prometnim nesrećama, a koje su rjeđe utjecale na njih. Tako su u 48 % prometnih nesreća naleta na pješaka postojale lošije atmosferske prilike. Dakle, od navedenih osam vanjskih čimbenika tri su najznačajnija (s postotcima između 27 i 48 kod pješaka i s postotcima između 11 i 33 kod biciklista), a to su:

- lošija vidljivost (kod 26,4 % svih razmatranih prometnih nesreća)
- lošije atmosferske prilike (kod 44,2 % svih razmatranih prometnih nesreća)
- neodgovarajuća površina kolnika (kod 23,0 % svih razmatranih prometnih nesreća).

Na navedena je tri čimbenika gotovo nemoguće djelovati, ali je na preostalih pet čimbenika moguće djelovati boljom organizacijom prometa, premda su njihovi utjecaji manji (iznose između 1 % i 5 % kod pješaka i između 0 % i 6 % kod biciklista).



Grafikon 29. Postotak lošijih vanjskih okolnosti kod prometnih nesreća naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine

4.2. Inferencijalna statistička analiza podataka o prometnim nesrećama

U ovoj je analizi provjereno nekoliko pretpostavaka o vremenskoj raspodjeli prometnih nesreća, i to uvijek posebno za nalete na pješake i posebno za nalete na bicikle. Prva je pretpostavka kako su naleti na pješaka vremenski jednoliko raspoređeni po mjesecima u godini, tj. kako raspodjela tih prometnih nesreća nalikuje uniformnoj distribuciji. Tablica 21. prikazuje opažene frekvencije, dok bi prema navedenoj pretpostavci teoretske frekvencije bile u svakom mjesecu iste i iznosile bi 111,1 ($1333/12=111,1$). S pomoću hi-kvadrat testa provjerena je istinitost navedene pretpostavke. Rezultati testa ($\chi^2 = 53,392$, $df = 11$, $N = 1333$, $p < 0,001$) pokazuju kako pretpostavka o jednolikoj raspodjeli prometnih nesreća naleta na pješaka po mjesecima u godini nije prihvatljiva. Usporedbom razlika između opaženih i teoretskih frekvencija može se uočiti gdje su razlike najveće. To je u srpnju i kolovozu gdje se opažene frekvencije i očekivane frekvencije najviše razlikuju jer je u tim mjesecima broj naleta na pješaka znatno ispod mjesečnoga prosjeka od 111,1. Također, veće su razlike u listopadu kada je broj naleta znatno iznad mjesečnoga prosjeka od 111,1. Dakle, manji je broj vozila u prometu u ljetnim mjesecima, a veći u listopadu.

Druga je pretpostavka (slična prvoj) kako su prometne nesreće naleta na bicikl vremenski

jednoliko raspoređene po mjesecima u godini, tj. da i ta raspodjela prometnih nesreća nalikuje uniformnoj distribuciji. Tablica 21. prikazuje opažene frekvencije, dok bi prema navedenoj pretpostavci teoretske frekvencije bile u svakom mjesecu 36,9 ($443/12=36,9$). Pomoću hi-kvadrat testa provjerena je istinitost pretpostavke. Rezultati testa ($\chi^2 = 88,928$ $df = 11$ $N = 443$ $p < 0,001$) pokazuju kako pretpostavka o jednolikoj raspodjeli prometnih nesreća naleta na bicikl po mjesecima u godini nije prihvatljiva. Usporedbom razlika između opaženih i teoretskih frekvencija može se uočiti gdje su razlike najveće. To je u lipnju i u srpnju kada se opažene frekvencije i očekivane frekvencije najviše razlikuju jer je u tim mjesecima broj naleta na pješaka znatno iznad mjesečnoga prosjeka od 36,9, jer je u tim mjesecima (vjerojatno) i najveći broj bicikala u prometu. Također, veće su razlike u siječnju i u veljači kada je broj naleta znatno ispod mjesečnoga prosjeka od 36,9 jer su to mjeseci (vjerojatno) s manjim brojem biciklista u prometu.


Treća i četvrta pretpostavka odnose se na prometne nesreće po danima u tjednu. Tako se u trećoj pretpostavci pretpostavlja kako je broj naleta na pješaka podjednako raspoređen po danima u tjednu. Sličnost je s uniformnom raspodjelom provjerena hi-kvadrat testom čiji su rezultati ($\chi^2 = 121,346$ $df = 6$ $N = 1333$ $p < 0,001$) pokazali kako nema sličnosti s jednolikom raspodjelom, odnosno kako navedena pretpostavka nije prihvatljiva. Utorkom je broj naleta na bicikl znatno iznad prosjeka, dok je broj naleta na bicikl nedjeljom znatno ispod prosjeka. Dakle, utorak s najvećim prometom i nedjelja s najmanjim prometom imaju za posljedicu znatno odstupanje broja prometnih nesreća od prosjeka u tim danima.

U četvrtoj pretpostavci pretpostavlja se kako je broj naleta na bicikl podjednako raspoređen po danima u tjednu ($443/7 = 63,3$). Sličnost je s uniformnom raspodjelom provjerena hi-kvadrat testom čiji su rezultati ($\chi^2 = 22,397$ $df = 6$ $N = 443$ $p = 0,001$) pokazali kako nema sličnosti s jednolikom raspodjelom, odnosno kako navedena pretpostavka nije prihvatljiva. Utorkom je broj naleta na bicikl znatno iznad prosjeka, dok je broj naleta na bicikl nedjeljom znatno ispod prosjeka. Dakle, i ovdje kao i kod naleta na pješaka, utorak s najvećim prometom i nedjelja s najmanjim prometom imaju za posljedicu znatno odstupanje broja naleta na bicikl od prosjeka za čitav tjedan.


Za broj prometnih nesreća po satima u danu može se pretpostaviti kako nalikuje normalnoj (*Gaussovoj*) krivulji jer je u ranim jutarnjim satima i kasnim noćnim satima taj broj smanjen, a u dnevnim satima znatno povećan. Provjera je te pretpostavke napravljena jednom za nalete na

pješake, a drugi put za nalete na bicikle (peta i šesta pretpostavka) pomoću *Kolmogorov-Smirnovljeva* testa. Kod naleta na pješaka rezultati testa ($z = 3,231$ $N = 1333$ $p < 0,001$) pokazuju kako pretpostavka o normalnom rasporedu broja naleta na pješaka nije prihvatljiva. Grafikon 30. prikazuje kako izgleda ta distribucija broja naleta na pješaka po satima u danu, prikazana je histogramom, a kako bi izgledala da je normalnoga oblika, prikazana je krivuljom. Bitna je razlika između empirijske distribucije i teoretske (normalne) distribucije u tome što je broj naleta na pješaka u srednjem dijelu distribucije (između 7 i 21 sat) prilično ravnomjeran, dok bi prema normalnoj distribuciji trebao biti u ranijim satima manji, zatim veći te u kasnijim satima opet manji (Grafikon 30.).

Šesta je pretpostavka kako je broj naleta na bicikl sličan normalnoj (*Gaussovoj*) krivulji s obzirom na sate u danu kada su se ti naleti dogodili. Provjera je te pretpostavke napravljena također pomoću *Kolmogorov-Smirnovljeva* testa. Kod naleta na bicikl rezultati testa ($z = 2,171$ $N = 441$ $p < 0,001$) pokazuju kako pretpostavka o normalnom rasporedu broja naleta na bicikl nije prihvatljiva. Grafikon 31. prikazuje kako izgleda ta distribucija broja naleta na bicikl po satima u danu, a kako bi izgledala da je normalnoga oblika. Bitna je razlika između empirijske distribucije i teoretske (normalne) distribucije u tome što je broj naleta na bicikl u prvom dijelu distribucije (između 6 i 9 sati) veći nego što bi bio prema normalnoj distribuciji, dok je u srednjem dijelu distribucije (između 11 i 16 sati) veći, kao što to prikazuje krivulja na grafikonu (Grafikon 31.).



Grafikon 30. Prometne nesreće naleta na pješaka u Gradu Zagrebu 2012. – 2014. godine prema satima u danu ($N = 1333$)



Grafikon 31. Prometne nesreće naleta na bicikl u Gradu Zagrebu 2012. – 2014. godine prema satima u danu (N = 443)

Tablica 36. prikazuje rezultate i zaključke šest provedenih testova.

Tablica 36. Pregled rezultata provjere pretpostavaka o obliku distribucija prometnih nesreća u Gradu Zagrebu 2012. – 2014. godine (za 1 333 naleta na pješaka i 443 naleta na bicikl)

Rb	Analizirana varijabla	Pretpostavljeni oblik distribucije	Korišten test za provjeru	Rezultati testa	Zaključak o pretpostavci
1.	Broj naleta na pješaka po mjesecima	uniformna	hi-kvadrat	$\chi^2 = 88,928$ df = 11 p < 0,001	nije prihvatljiva
2.	Broj naleta na bicikl po mjesecima	uniformna	hi-kvadrat	$\chi^2 = 53,392$ df = 11 p < 0,001	nije prihvatljiva
3.	Broj naleta na pješaka po danima u tjednu	uniformna	hi-kvadrat	$\chi^2 = 22,397$ df = 6 p < 0,001	nije prihvatljiva
4.	Broj naleta na bicikl po danima u tjednu	uniformna	hi-kvadrat	$\chi^2 = 121,346$ df = 6 p = 0,001	nije prihvatljiva
5.	Broj naleta na pješaka po satima u danu	normalna	Kolmogorov-Smirnov	z = 3,231 p < 0,001	nije prihvatljiva
6.	Broj naleta na bicikl po satima u danu	normalna	Kolmogorov-Smirnov	z = 2,171 p < 0,001	nije prihvatljiva

Za potrebe je multivarijantne analize prometnih nesreća formirana nova varijabla pod nazivom broj nepovoljnih vanjskih okolnosti i to na temelju sljedećih osam izvornih varijabla:

- uvjeti vidljivosti
- atmosferske prilike
- uređenost okoliša
- javna rasvjeta
- stanje kolničkoga zastora
- stanje površine kolnika
- stanje vertikalne signalizacije
- stanje horizontalne signalizacije.

Kod svake je od tih varijabla dodijeljeno:

- nula bodova kada su vanjski uvjeti povoljni
- jedan bod kada vanjski uvjeti nisu povoljni.

Primjerice, kod uvjeta vidljivosti postoje četiri oblika te varijable: dan, noć, sumrak i svitanje. Za svaki je oblik toga obilježja označen s „dan” dodijeljeno nula bodova, a za svaki je drugi oblik toga obilježja (noć, sumrak, svitanje), koji znači smanjenu vidljivost, dodijeljen jedan bod. Ovakav je postupak primijenjen za svako od osam navedenih obilježja pa je svaka prometna nesreća dobila nula bodova za normalne vanjske uvjete, dok je svaka prometna nesreća dobila jedan bod za otežane vanjske uvjete odvijanja prometa. Kako se radi o ukupno osam varijabla, svaka je prometna nesreća mogla dobiti minimalno nula bodova, a maksimalno osam bodova. Tablica 37. prikazuje koliko je prometnih nesreća dobilo po nula ili po jedan bod kod svake od osam varijabla.

Tablica 37. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema broju bodova za nepovoljne prometne okolnosti (N = 1776)

Varijabla	Oblik varijable	Broj prometnih nesreća	Postotak prometnih nesreća
Uvjet vidljivosti	dan	1 308	74
	noć, sumrak, svitanje	468	26
Atmosferske prilike	vedro	991	56
	oblačno, kiša, magla, snijeg, slana, ostalo	785	44
Uređenost okoliša	uređen	1 739	98
	slabo održavan, izraziti nedostaci	37	2
Javna rasvjeta	u funkciji	1 744	98
	izvan funkcije, ne postoji	32	2
Stanje koln. zastora	dobro	1 769	100

	manja oštećenja, loše	7	0
Stanje površine koln.	suha i čista	1 367	77
	mokar, blato, snijeg, led, odron, zemlja, ulje	409	23
Stanje vertik. signaliz.	dobra	1 687	95
	oštećena, loša, nema je	89	5
Stanje horiz. signaliz.	dobra	1685	95
	manjkava, loša, nema je	91	5

Nakon ovakve je dodjele bodova izračunan zbroj tih dodijeljenih bodova za svaku prometnu nesreću. Kada su potom prebrojene prometne nesreće prema tom zbroju bodova, odnosno prema broju nepovoljnih vanjskih uvjeta odvijanja prometa, formirana je distribucija frekvencija (Tablica 38.).

Tablica 38. Broj naleta na pješaka i naleta na bicikl u gradu Zagrebu u razdoblju 2012. – 2014. godine prema broju bodova za nepovoljne prometne okolnosti (N = 1776)

Broj bodova za nepovoljne okolnosti	Broj promet. nesreća	% promet. nesreća	Kumulativni % promet. nesreća
0	733	41,3	41,3
1	450	25,3	66,6
2	358	20,2	86,8
3	200	11,2	98,0
4	26	1,5	99,5
5	7	0,4	99,9
6	1	0,1	99,9
7	1	0,1	100,0
8	-	-	-
Ukupno	1 776	100	-

Tablica 38. prikazuje kako kod 41,3 % prometnih nesreća nije bilo niti jedne otežavajuće (nepovoljne) vanjske prometne okolnosti, kako je s jednom nepovoljnom okolnosti bilo 25,3 % prometnih nesreća itd. To onda znači da je kod 58,7 % prometnih nesreća postojala jedna ili više otežavajućih prometnih okolnosti. Nadalje, može se pročitati kako je kod 66,6 % prometnih nesreća (točno 1/3 prometnih nesreća) postojala jedna ili niti jedna nepovoljna okolnost, kako je kod 86,8 % prometnih nesreća postojala jedna, dvije ili nijedna nepovoljna prometna okolnost itd. Kod svih je 1 776 prometnih nesreća zabilježeno ukupno 1 918 nepovoljnih prometnih okolnosti, što daje prosjek od 1,08 nepovoljnih prometnih okolnosti po jednoj prometnoj nesreći. Za distribuciju prometnih nesreća prema broju nepovoljnih prometnih okolnosti izračunani su deskriptivni pokazatelji koji su sljedeći:


- prosječan broj nepovoljnih okolnosti po jednoj prometnoj nesreći od 1,08
- medijan od 1
- mod od 0
- standardna devijacija od 1,135
- koeficijent varijacije od 105 %.

Grafikon 32. prikazuje histogram distribucija prometnih nesreća prema broju nepovoljnih okolnosti. Ta je distribucija prometnih nesreća prema broju nepovoljnih prometnih okolnosti izrazito desno asimetrična (oblika slova L), ima izrazito veliku disperziju (105 %) i nije slična normalnoj distribuciji (prema *Kolmogorov-Smirnovljevom* testu $z = 10,201$ $p < 0,001$).

Ako se osam nepovoljnih prometnih okolnosti sažetije izrazi, tada bi to bilo moguće putem sljedećih dviju grupa okolnosti:

- nepovoljne prometne okolnosti objektivne prirode (uvjet vidljivosti, atmosferske prilike i stanje površine kolnika)
- nepovoljne prometne okolnosti organizacijsko-prometne prirode (uređenost okoliša, javna rasvjeta, stanje kolničkoga zastora, stanje vertikalne signalizacije i stanje horizontalne signalizacije).

Zbroj od ukupno zabilježenih 1 918 nepovoljnih prometnih okolnosti tada bi se mogao raščlaniti u te dvije skupine okolnosti, na one na koje čovjek teško može utjecati i na one koje su nastale zbog loše organizacije prometa. Na prve bi otpalo 1 662 nepovoljne prometne okolnosti (87 %), a na druge 256 nepovoljnih prometnih okolnosti (13 %).



Grafikon 32. Prometne nesreće naleta na pješaka i naleta na bicikl u Gradu Zagrebu 2012. – 2014. godine prema broju nepovoljnih prometnih okolnosti (N = 1776)

Broj nepovoljnih prometnih okolnosti kao izvedena diskontinuirana numerička varijabla odgovarajuća je za testiranje razlika između prometnih nesreća: različitih vrsta prometnih

nesreća (naleta na pješaka, naleta na bicikl), različitih ishoda (posljedica), različitih godina u kojima su se dogodile, različitih mjeseci u kojima su se dogodile, različitih dana u tjednu i različitih sati u danu. Provjera je razlika (slučajnih ili statistički značajnih) između podskupova prometnih nesreća provedena dvjema skupinama metoda:

- parametrijskim metodama (t-test i F-test)
- neparametrijskim metodama (U-test i H-test).

Skup je prometnih nesreća velik ($N = 1776$) i donekle je za očekivati da ne nalikuje normalnoj distribuciji s obzirom na broj nepovoljnih prometnih okolnosti, kako je to utvrđeno *Kolmogorov-Smirnovljev*im testom. Stoga su korištene i neparametrijske metode kao alternativa parametrijskim metodama. Međutim, obje su skupine metoda primijenjene u šest testova dale gotovo istovrsne zaključke, tako da je pitanje izbora parametrijskih ili neparametrijskih metoda analize manje važno. U nastavku su tablično prikazani rezultati šest provedenih parametrijskih testova (Tablica 39.) te rezultati provedenih neparametrijskih testova (Tablica 40). Ispod svake od tih tablica napisani su zaključci na temelju rezultata testiranja.

Tablica 39. Rezultati testiranja važnosti razlika u prosječnom broju nepovoljnih prometnih okolnosti kod prometnih nesreća naleta na pješaka i naleta na bicikl u Gradu Zagrebu 2012. – 2014. godine ($N = 1776$) – t-testovi i F-testovi

R b	Varijabla	Grupa prom. nesreća	N ₁ N ₂	Aritm. sredina	Vrijednost t ili F	p	Stat. znač.
1.	Broj nepovoljnih prometnih okolnosti prema vrsti PN	naleti na pješaka naleti na bicikl	1333 443	1,19 0,75	t = 7,884	<0,001	***
2.	Broj nepovoljnih prometnih okolnosti prema ishodu	s poginulima s ozlijeđenima s mater. štetom	30 1515 231	1,13 1,09 1,00	F = 0,610	0,543	
3.	Broj nepovoljnih prometnih okolnosti prema godini prometne nesreće	2012. g. 2013. g. 2014. g.	591 574 611	1,06 1,19 0,99	F = 4,456	0,012	*
4.	Broj nepovoljnih prometnih okolnosti prema mjesecu prometne nesreće	1. 2. 3. 4. 5. 6. 7. 8. 9. 10. 11. 12.	119 113 146 155 162 165 145 103 165 192 153 158	1,63 1,70 0,98 0,70 0,70 0,57 0,58 0,70 1,01 0,97 1,73 1,90	F = 33,489	<0,001	***
5.	Broj nepovoljnih prometnih okolnosti prema danu u tjednu	ponedjeljak utorak srijeda četvrtak petak	272 339 285 288 292	1,00 1,18 1,08 0,98 1,00			

		subota nedjelja	173 127	1,17 1,27	F = 2,113	0,049	*
6.	Broj nepovoljnih prometnih okolnosti prema satu u danu	0 – 1	8	1,63			
		1 – 2	11	2,00			
		2 – 3	5	2,00			
		3 – 4	7	2,29			
		4 – 5	9	1,22			
		5 – 6	16	2,00			
		6 – 7	39	1,62			
		7 – 8	95	0,89			
		8 – 9	88	0,78			
		9 – 10	96	0,61			
		10 – 11	98	0,61			
		11 – 12	96	0,72			
		12 – 13	116	0,40			
		13 – 14	124	0,70			
		14 – 15	113	0,66			
		15 – 16	132	0,84			
		16 – 17	160	1,11			
		17 – 18	128	1,45			
		18 – 19	131	1,38			
		19 – 20	112	1,60			
		20 – 21	96	1,95			
		21 – 22	49	1,90			
		22 – 23	28	1,89			
		23 – 24	19	1,79	F = 16,554	<0,001	***


Napomena: * statistička važnost do 5 %; ** statistička važnost do 1 %; *** statistička važnost do 0,1 %

Zaključci su na temelju rezultata sljedeći:


1. Prosječan je broj nepovoljnih prometnih okolnosti kod naleta na pješaka (1,19) statistički značajno veći od broja takvih nepovoljnih okolnosti kod naleta na bicikl (0,75). Rezultati t-testa ($t = 7,884 / p < 0,001$) uvjerljivo ukazuju na takav zaključak.
2. Prosječan je broj nepovoljnih prometnih okolnosti (očekivano) najveći kod prometnih nesreća sa smrtnim ishodom (1,13), a najmanji je kod prometnih nesreća s materijalnom štetom (1,00). Međutim, ta je razlika slučajna, odnosno nije statistički značajna kako to pokazuju rezultati F-testa ($F = 0,610 / p = 0,543$).
3. Prosječan broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim promatranim godinama nije isti. Najveći je 2013. godine (1,19), a najmanji 2014. godine (0,99). Iako ta razlika izgleda mala, ona je ipak statistički značajna kako to pokazuju rezultati F-testa ($F = 4,456 / p = 0,012$).
4. Prosječan broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim mjesecima u godini nije isti. Najveći je u zimskim mjesecima (I., II., XI., XII. mj.), a oko dva do tri puta manji u ostalim mjesecima u godini (III. – X. mj.). Ta je razlika

statistički značajna kako to pokazuju rezultati F-testa ($F = 33,489$ $p < 0,001$), a slikovito prikazuje Grafikon 33.


5. Prosječan broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim danima u tjednu nije isti. Najveći je nedjeljom (1,27), a najmanji četvrtkom (0,98). Iako ta razlika izgleda manja, ona je ipak statistički značajna kako to dokazuju rezultati F-testa ($F = 2,113$ / $p = 0,049$), a slikovito prikazuje Grafikon 34.
6. Prosječan broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim satima u danu nije isti. Najveći je u noćnim satima, a dva do tri je puta manji u dnevnim satima. Ta je razlika statistički značajna kako to pokazuju rezultati F-testa ($F = 16,554$ / $p < 0,001$) kao i Grafikon 35.



Grafikon 33. Prosječan broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u različitim mjesecima u godini (N = 1776)



Grafikon 34. Prosječan broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u različitim danima u tjednu (N = 1776)



Grafikon 35. Prosječan broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u različitim satima u danu (N = 1776)

Tablica 40. Rezultati testiranja važnosti razlika u broju nepovoljnih prometnih okolnosti kod prometnih nesreća naleta na pješaka i naleta na bicikl u Gradu Zagrebu 2012. – 2014. godine (N = 1776) pomoću *Mann-Whitneyevoga* U testa (za varijable s dvjema kategorijama) i *Kruskal-Wallisovoga* H testa (za varijable s trima kategorijama i s više njih)

	Varijabla	Broj N	Rezultati U-testa	Rezultati H-testa	p
1.	Broj nepovoljnih prometnih okolnosti prema vrsti prometne nesreće (nalet na pješaka, nalet na bicikl)	1776	U=232033 z = -7,112		<0,001***
2.	Broj nepovoljnih prometnih okolnosti prema ishodu (smrtni slučaj, tjelesna ozljeda, materijalna šteta)	1776		$\chi^2 = 0,530$ df = 2	0,767
3.	Broj nepovoljnih prometnih okolnosti prema godini prometne nesreće (2012., 2013., 2014.)	1776		$\chi^2 = 8,304$ df = 2	0,016*
4.	Broj nepovoljnih prometnih okolnosti prema mjesecu prometne nesreće (1, 2, 3, . . . ,12)	1776		$\chi^2 = 322,392$ df = 11	<0,001***
5.	Broj nepovoljnih prometnih okolnosti prema danu u tjednu (ponedjeljak, utorak, . . . , nedjelja)	1776		$\chi^2 = 10,864$ df = 6	0,093
6.	Broj nepovoljnih prometnih okolnosti prema satu u danu (0-1, 1-2, 2-3, . . . ,23-24)	1776		$\chi^2 = 315,204$ df = 23	<0,001***

Napomena: * statistička važnost do 5 %; ** statistička važnost do 1 %; *** statistička važnost do 0,1 %

Zaključci su na temelju rezultata sljedeći:

1. Broj je nepovoljnih prometnih okolnosti kod naleta na pješaka statistički značajno veći od broja takvih nepovoljnih okolnosti kod naleta na bicikl. Rezultati U-testa ($U = 232033 / z = -7,112 / p < 0,001$) uvjerljivo ukazuju na takav zaključak.
2. Broj je nepovoljnih prometnih okolnosti najveći kod prometnih nesreća sa smrtnim ishodom, a najmanji je kod prometnih nesreća s materijalnom štetom. Međutim, ta je razlika

slučajna, odnosno nije statistički značajna kako to pokazuju rezultati H-testa ($\chi^2 = 0,530 / df = 2 / p = 0,767$).

3. Broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim promatranim godinama nije isti. Ta je razlika ipak statistički značajna kako to pokazuju rezultati H-testa ($\chi^2 = 8,304 / df = 2 / p = 0,016$).
4. Broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim mjesecima u godini nije isti. Najveći je u zimskim mjesecima, a manji u ostalim mjesecima u godini. Ta je razlika statistički značajna kako to pokazuju rezultati H-testa ($\chi^2 = 322,393 / df = 11 / p < 0,001$).
5. Broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim danima u tjednu nije isti. Veći je vikendom, a manji radnim danima. Ta razlika nije statistički značajna kako to dokazuju rezultati H-testa ($\chi^2 = 10,864 / df = 6 / p = 0,093$). Ovaj se zaključak ne podudara sa zaključkom na temelju parametrijskoga F-testa, gdje je bilo $p = 0,049$, tj. postojala je statistički značajna razlika.
6. Broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u pojedinim satima u danu nije isti. Najveći je u noćnim satima, a manji u dnevnim satima. Ta je razlika statistički značajna kako to pokazuju rezultati H-testa ($\chi^2 = 315,204 / df = 23 / p < 0,001$).

4.3. Deskriptivna statistička analiza podataka po gradskim četvrtima

Posebnu skupinu podataka čini desetak varijabla prikupljenih po gradskim četvrtima (GČ) Grada Zagreba. Na uspostavljenoj su lokalnoj bazi podataka uz pomoć QGIS programa izvezeni karakteristični podatci za daljnju statističku analizu. Za svaku od 17 gradskih četvrti poznati su sljedeći podatci:

- površina (u ha)
- broj stanovnika
- broj prometnih nesreća naleta na pješaka
- broj prometnih nesreća naleta na bicikl
- gustoća stanovništva (broj stanovnika po 1 ha ukupne površine gradske četvrti)
- gustoća stanovanja (broj stanovnika po 1 ha površine za stanovanje, tj. površine stambenih i širih stambenih funkcija kao što su zelene površine, škole, vrtići, vjerski objekti, tržnice, trgovci i sl.)
- gustoća ulične mreže (duljina ulične mreže u km na 1 km² površine gradske četvrti)
- gustoća biciklističke mreže (duljina biciklističkih staza u km na 1 km² površine)
- postotak površine gradske četvrti za stambeno-mješovite namjene
- postotak površine javno-društvene namjene

- postotak površine gospodarstvene namjene
- postotak površine prometne namjene.

Tablica 41. prikazuje svih 17 gradskih četvrti, dok je u narednim stupcima njihova površina, broj stanovnika i broj prometnih nesreća naleta na pješaka i naleta na bicikl.

Tablica 41. Osnovni podatci o gradskim četvrtima Grada Zagreba – površina, broj stanovnika i broj prometnih nesreća naleta na pješaka i naleta na bicikl u razdoblju 2012. – 2014.godine (N = 17)

	Naziv gradske četvrti	Površina u ha	Broj stanovn.	Broj naleta		
				na pješaka	na bicikl	svega
1	Brezovica	12 730	12 030	5	1	6
2	Donja Dubrava	1 081	36 363	38	12	50
3	Donji grad	302	37 024	178	39	217
4	Gornja Dubrava	4 025	61 841	98	24	122
5	Gornji grad – Medveščak	1 019	30 962	79	20	99
6	Maksimir	1 497	48 902	122	24	146
7	Novi Zagreb – Istok	1 654	59 055	74	17	91
8	Novi Zagreb – Zapad	6 262	58 103	57	36	93
9	Peščenica – Žitnjak	3 528	56 487	78	43	121
10	Podsused – Vrapče	3 615	45 759	37	15	52
11	Sesvete	16 518	70 009	72	27	99
12	Stenjevec	1 218	51 390	49	19	68
13	Trešnjevka – Jug	983	66 674	95	44	139
14	Trešnjevka – Sjever	581	55 425	109	44	153
15	Trnje	736	42 282	99	55	154
16	Črnomerec	2 423	38 546	114	21	135
17	Podsljeme	5 941	19 165	14	1	15
U k u p n o		64 113	79 0017	442	1 318	1 760

Napomena: Podatci o broju prometnih nesreća neznatno se razlikuju u odnosu na prethodne tablice (za 16 prometnih nesreća)

Iz gore navedene tablice mogu se uočiti dvije atipične gradske četvrti. To su Brezovica i Podsljeme s bitno manje prometnih nesreća od drugih gradskih četvrti.

Za analizu je međusobne povezanosti podataka po gradskim četvrtima korišten *Pearsonov* koeficijent korelacije jer se radi o kontinuiranim i diskontinuiranim numeričkim varijablama, apsolutno ili relativno izraženima. Izračunani su koeficijenti korelacije za najznačajnije parove varijabla s tabličnim rezultatima toga izračuna (Tablica 42.).

Tablica 42. Rezultati korelacijske analize prema gradskim četvrtima


R. b.	Varijable u korelaciji	N	Pearsonov koef. korel.	p	Stat. znač.
1.	Gustoća stanovništva (broj stan. na 1 ha) Broj prom. nesreća naleta na pješaka	17	0,710	0,001	***
2.	Gustoća stanovništva (broj stan. na 1 ha) Broj prom. nesreća naleta na pješ. i na bicikl	17	0,726	0,001	***
3.	Gustoća stanovanja (br. stan. na 1 st. ha) Broj prom. nesreća naleta na pješaka	17	0,654	0,004	**
4.	Gustoća stanovanja (br. stan. na 1 st. ha) Broj prom. nesreća naleta na pješ. i na bicikl	17	0,684	0,002	**

5.	Gustoća ulične mreže (km mreže / km ²) Broj prom. nesreća naleta na pješaka	17	0,691	0,002	**
6.	Gustoća ulične mreže (km mreže / km ²) Broj prom. nesreća naleta na pješ. i na bicikl	17	0,737	0,001	***
7.	Gustoća bicikl.mreže (km mreže / km ²) Broj prom. nesreća naleta na bicikl	17	0,598	0,011	*
8.	% površine GČ stamb. – mješovite namjene Broj prom. nesreća naleta na pješ. i na bicikl	17	0,676	0,003	**
9.	% površine GČ javno-društvene namjene Broj prom. nesreća naleta na pješ. i na bicikl	17	0,746	0,001	***
10.	% površine GČ gospodarske namjene Broj prom. nesreća naleta na pješ. i na bicikl	17	0,197	0,148	
11.	% površine GČ prometne namjene Broj prom. nesreća naleta na pješ. i na bicikl	17	0,695	0,002	**

Napomena: * statistička važnost do 5 %; ** statistička važnost do 1 %; *** statistička važnost do 0,1 %


Za sve rezultate korelacijske analize može se reći kako pokazuju **pozitivnu povezanost** ($0 < r < 1$). To znači da kada nezavisna varijabla poraste (npr. gustoća stanovništva), tada poraste i zavisna varijabla, tj. broj prometnih nesreća. Vrijedi i obrnuto, kada je gustoća stanovništva manja, manji je i broj prometnih nesreća. Svi dobiveni koeficijenti korelacije (osim koeficijenta navedenoga pod rednim brojem 10) pokazuju postojanje povezanosti između varijabla jer su bliže broju 1 nego broju 0. Samo je između postotka površine gradskih četvrti gospodarske namjene i broja prometnih nesreća korelacija slaba ($r = 0,197$). Nadalje treba istaknuti kako su svi koeficijenti korelacije (osim onoga pod rednim brojem 10) statistički važni ($p < 0,05$), tj. može se smatrati da korelacija postoji u čitavom osnovnom skupu prometnih nesreća naleta na pješaka i naleta na bicikl, a ne samo u analiziranom uzorku iz razdoblja 2012. – 2014. godine.

Od 11 razmatranih korelacijskih veza izabrane su dvije (redni broj 2. i 6.) za koje je izrađen dijagram rasipanja (Grafikon 36. i Grafikon 37.) i za njih su izračunane analitičke veličine koje su upisane pored regresijskoga pravca.



Grafikon 36. Grafički prikaz korelacije između gustoće stanovništva (broj stanovnika na 1 ha) (na vodoravnoj osi) i broja prometnih nesreća naleta na pješaka i naleta na bicikl (na okomitoj osi) u Gradu Zagrebu po gradskim četvrtima – za razdoblje 2012. – 2014. godine (N = 17)

Iz gore prikazanoga grafikona uočljiva je dosta jaka i pozitivna korelacija između gustoće stanovništva gradskih četvrti i broja prometnih nesreća. Kada gustoća stanovništva poraste za jedan stanovnik na 1 ha (nezavisna varijabla X), tada broj naleta na pješaka i naleta na bicikl (zavisna varijabla Y) poraste za 1,16. Korelacijom je između gustoće stanovništva i broja prometnih nesreća objašnjeno 52,7 % ukupnih varijacija.



Grafikon 37. Grafički prikaz korelacije između gustoće ulične mreže (dužina mreže u km / površina gradske četvrti u km² – na vodoravnoj osi) i broja prometnih nesreća naleta na pješaka i naleta na bicikl (na okomitoj osi) u Gradu Zagrebu po gradskim četvrtima – za razdoblje 2012. – 2014. godine (N = 17)

Grafikon 37. prikazuje također dosta jaku i pozitivnu korelaciju između gustoće ulične mreže (dužina u km / površina u ha) gradskih četvrti i broja prometnih nesreća. Kada gustoća ulične mreže (nezavisna varijabla X) poraste za 1 km/km², tada broj prometnih nesreća naleta na pješaka i naleta na bicikl (zavisna varijabla Y) poraste za 9,45. Korelacijom je između gustoće ulične mreže i broja prometnih nesreća objašnjeno 54,3 % ukupnih varijacija.

5. IDENTIFIKACIJA ŽARIŠTA I UTJECAJNIH ČIMBENIKA NASTANKA PROMETNIH NESREĆA

Identifikacija opasnih mjesta podrazumijeva postupak određivanja mjesta na cestovnoj prometnoj mreži na kojima se događa iznadprosječan broj prometnih nesreća u odnosu na druga slična mjesta. Identifikacije su opasnih mjesta te odabir potencijalnih utjecajnih čimbenika nastanka prometnih nesreća zasnovane na podacima svake prometne nesreće pješaka i biciklista na području Grada Zagreba tijekom 2012., 2013. i 2014. godine, pri čemu je validacija provedena na skupu podataka iz 2015. godine.

U nastavku je prikazana metodologija:

- određivanja opasnih mjesta prometnih nesreća pješaka i biciklista
- određivanja utjecajnih čimbenika koji djeluju na nastanak prometne nesreće.

5.1. Metodologija definiranja opasnih mjesta (žarišta)

Opasno je mjesto lokacija (mjesto) na cestovnoj prometnoj mreži s velikim brojem gomilanja prometnih nesreća. U radu [21] autori su opisali naziv opasno mjesto na cestovnoj mreži, a koji se koristi za označavanje mjesta na cesti s visokim rizikom za nastanak prometne nesreće. Pod pojmom „visoki rizik” smatra se velika vjerojatnost pojave prometnih nesreća na nekom području u odnosu na druga slična područja na cesti ili prometne nesreće koje se događaju na određenim mjestima rezultiraju teškim posljedicama.

Trenutačno ne postoji univerzalna definicija opasnoga mjesta u cestovnom prometu niti je ista zakonski regulirana. U stručnoj literaturi, kako domaćoj tako i stranoj, ne postoji jednoznačno nazivlje pojma opasno mjesta na cestama, nego se koriste različite izvedenice kao što su *black spot*, *hot spot*, *dangerous accident locations*, *hazardous road location*, *hazardous road sections*, *dangerous roads or problem roads*. U novije su se vrijeme pojavili nazivi kao što su: upravljanje opasnim mjestima (engl. *black spot management* – BSM) te drugi širi pojam koji obuhvaća cjelokupni sustavni tijek identifikacije i upravljanja opasnim mjestima na cestovnoj mreži (engl. *network safety management* – NSM) [87].

U domaćoj su literaturi opasna mjesta poznata i kao „crne točke” ili „crne dionice” na cestovnoj prometnoj mreži. Pojedini su domaći autori definirali opasna mjesta kao dijelove ceste na

kojima se događa veći broj prometnih nesreća, s ljudskim žrtvama i s velikom materijalnom štetom [88]. Autor [89] definira opasna mjesta na cestama u Republici Hrvatskoj na dva načina:

- mjesta gomilanja prometnih nesreća (izrazito opasna mjesta) ili tzv. crne točke. Crnom se točkom smatra lokacija na kojoj se dogodilo dvanaest i više prometnih nesreća s ozlijeđenim i poginulim osobama na udaljenosti 100 [m] od raskrižja ili na odsječku ceste duljine 300 [m] u proteklih pet godina. Ako je duljina dionice između dvaju raskrižja manja od 250 [m], u dionicu se uključuju i raskrižja. Samom raskrižju, kao opasnom mjestu, pripisuju se i one prometne nesreće koje se događaju 20 [m] izvan sjecišta rubova kolnika krajnjih prometnih trakova (uplitanja, isplitanja). Raskrižja se uglavnom ispituju odvojeno od dionice ceste. Velika su denivelirana raskrižja složena i mogu se sastojati od dionica i dijelova raskrižja (ulijevanja i izlijevanja).
- opasna mjesta na kojima se događa natprosječan broj prometnih nesreća, ali manje nego na mjestima gomilanja prometnih nesreća. Takva se opasna mjesta mogu svrstavati na različite načine, odnosno prema različitim kriterijima.

U Republici Hrvatskoj, osim mreže državnih cesta, na državnoj razini ne postoji sustavna jednaka metodologija za istraživanje prometnih nesreća na opasnim cestovnim mjestima te za pronalazak mjera za njihovo otklanjanje. Trenutačno samo Hrvatske ceste d.o.o.⁵ koriste sustavni metodološki pristup identifikaciji i sanaciji opasnih mjesta [90] na dijelu cestovne mreže pod svojom odgovornošću, odnosno na mreži državnih cesta. Nije poznato koriste li i ostala društva za upravljanje javnim cestama, poput Hrvatskih autocesta, pojedinih županijskih uprava za ceste te jedinica lokalne samouprave, navedenu metodologiju.

Prema [90] opasnim se mjestom može nazvati raskrižje ili odsječak ceste duljine do 300 [m], uz uvjet da najmanje jedan od triju kriterija mora biti ispunjen:

- 12 ili više prometnih nesreća s ozlijeđenim osobama u protekle 3 godine

⁵ Hrvatske ceste d.o.o. društvo su s ograničenom odgovornošću za upravljanje, izgradnju i održavanje državnih cesta na području Republike Hrvatske.

- 3 ili više istovrsnih prometnih nesreća s ozlijeđenim osobama u tri (3) godine (ista skupina sudionika, isti pravci kretanja, iste konfliktne točke i dr.)
- 15 ili više prometnih nesreća (ukupan broj nesreća – sve nesreće) u tri (3) godine.

Prema istoj metodologiji opasnom dionicom može se nazvati dio ceste duljine 300 – 1 000 [m] u vremenskom razdoblju 3 – 5 godina, pri čemu se unutar kompaktnih naselja mjesta dionice gomilanja prometnih nesreća u pravilu kreću 500 – 1000 [m].

Za određivanje opasnih mjesta i dionica u brojnim europskim zemljama uobičajeno se koriste sljedeći elementi (Tablica 43. i Tablica 44.):

- broj prometnih nesreća
- dužina cestovne dionice
- vremensko razdoblje promatranja.

Tablica 43. Osnovni elementi za identifikaciju opasnih mjesta na cestama u zemljama Europe i u Hrvatskoj

Zemlja	Definicija crnih točaka
Austrija	- 3 ili više sličnih prometnih nesreća s ozlijeđenim osobama (5 ili više uključivo i one s materijalnom štetom) - dionica ceste do 250 m - vrijeme promatranja: 3 godine (vrijeme promatranja 1 godina)
Njemačka	- 3 do 5 sličnih prometnih nesreća - dionica ceste do 100 m - vrijeme promatranja: 1 godina (sve prometne nesreće), 3 godine (nesreće s ozlijeđenim osobama)
Norveška	- minimum 4 prometne nesreće - dionica ceste do 100 m - vrijeme promatranja: 5 godina
Nizozemska	- minimum 10 prometnih nesreća ili opasnih situacija - minimum 5 prometnih nesreća ili opasnih situacija sličnih karakteristika - uglavnom raskrižja - vrijeme promatranja: 3 – 5 godina
Danska	- minimum 4 prometne nesreće - raskrižje ili dionica ceste (nije definirana duljina) - vrijeme promatranja: 5 godina
Belgija	- 3 i više prometnih nesreća - dionica ceste do 100 m - vrijeme promatranja: 3 godine
Mađarska	- minimum 4 prometne nesreće - dionica ceste do 100 m - vrijeme promatranja: 3 godine
Hrvatska	- 12 prometnih nesreća s ozlijeđenim osobama, - 3 ili više istovrsnih nesreća s ozlijeđenim osobama - 15 ili više prometnih nesreća bez obzira na posljedice i težinu - dionica ceste do 300 m - vrijeme promatranja 3 godine

Izvor: [90], obrada autora

Tablica 44. Osnovni elementi za identifikaciju opasnih dionica na cestama u zemljama Europe i u Hrvatskoj

Zemlja	Definicija opasnih dionica
Njemačka	- 3 različite kategorije prometnih nesreća - dionica ceste 3 – 10 km - vrijeme promatranja: 3 godine
Norveška	- 10 prometnih nesreća - dionica ceste 1 km - vrijeme promatranja: 5 godina
Danska	- minimum 4 različite kategorije prometnih nesreća - dionica ceste 2 – 10 km - vrijeme promatranja: 5 godina
Mađarska	- minimum 4 prometne nesreće - dionica ceste do 1 km - vrijeme promatranja: 3 godine
Hrvatska	- više prometnih nesreća od očekivanoga broja. - dionica ceste 0,3 – 1 km (unutar naselja 0,5 – 1 km) - vrijeme promatranja 3 – 5 godina

Izvor: [90], obrada autora

Pri procesu identifikacije i grupiranja PN-a na urbanoj cestovnoj mreži u GIS okruženju mogu se koristiti različite statističke metode. Jedna je od najviše korištenih statističkih metoda metoda procjene gustoće jezgre (engl. *Kernel Density Estimation* – KDE) prometnih nesreća na nekom području [18]. Pomoću KDE metode dobije se gustoća prometnih nesreća za svaki piksel na izlaznom rasteru, a rezultat su izlazne karte na kojima se uočavaju površine u raznim bojama, odnosno žarišta prometnih nesreća [91]. S pomoću ove metode računa se gustoća prometnih nesreća na određenom području i na taj se način izbjegava točkasti prikaz prometnih nesreća u prostoru koji uzrokuje preklapanje više njih na jednoj lokaciji. Iako KDE tehnički nije metoda analize žarišta već interpolacijska tehnika, analitičari ju često koriste za identificiranje žarišta [92]. U radovima [13] i [14] sugerira se korištenje ove metode identificiranja i grupiranja prometnih nesreća kako bi se utvrdila područja visoke gustoće prometnih nesreća te nastavila daljnja istraživanja istih na mikro razini.

U ovom je doktorskom radu za potrebe identifikacije opasnih mjesta pješaka i biciklista na urbanoj cestovnoj mreži Grada Zagreba primijenjena metodologija pristupa sigurnosti prometa od Hrvatskih cesta d.o.o., gdje je upotrijebljen kriterij triju (3) ili više istovrsnih prometnih nesreća s ozlijeđenim osobama u tri (3) godine (ista skupina sudionika, isti pravci kretanja, iste konfliktne točke i drugo).

Postupak je grupiranja triju ili više istovrsnih prometnih nesreća izvršen na uspostavljenoj lokalnoj bazi podataka prometnih nesreća s pomoću QGIS programa. Posebno su obrađene prometne nesreće pješaka te posebno prometne nesreće biciklista. Postupak se sastojao od nekoliko koraka.

Prvo se pristupilo izradi toplinske karte prometnih nesreća u QGIS programu uz predefinirani dodatak aplikacije za procjenu gustoće jezgre, pri čemu je korišten polumjer od 25 metara. U ovom je postupku kreirana rasterska karta, tzv. toplinska karta koja prikazuje područja s najvećom frekvencijom istovrsnih prometnih nesreća. Nakon izrade toplinske karte grupiranja su prometnih nesreća u rasterskom obliku naknadno definirana žarišta prometnih nesreća s pomoću programskih dodataka QGIS-a, pri čemu je napravljena transformacija rasterskoga oblika u vektorski oblik. Novodefinirani vektorski oblik predstavlja poligone u kojima se nalazi minimalno po tri i više grupiranih lokacija prometnih nesreća.


Nakon toga pregledom je pojedinih lokacija prometnih nesreća ručno napravljena korekcija položaja onih prometnih nesreća koje su ostale izvan kreiranoga vektorskoga poligona. Primjer takvih korekcija bile su prometne nesreće na velikim raskrižjima glavnih prometnica poput Av. V. Holjevca i Av. Dubrovnik. Ručnim je ispravljanjem lokacija prometnih nesreća izvršeno grupiranje prometnih nesreća bliže centru raskrižja ili središnjoj osi prometnice.

Postupak kodiranja sastoji se u tom da se svim prometnim nesrećama koje se nalaze u definiranom poligonu (žarište prometne nesreće) dodijeli oznaka 1, pri čemu se svim ostalim prometnim nesrećama izvan poligona dodjeljuje oznaka 0. Nakon što su podatci prethodno preuzeti iz QGIS programa, postupak je pridruživanja oznake 1, tj. kodiranja žarišta prometnih nesreća, izveden u programu *MS Excel* te je na taj način pripremljena baza podataka za daljnju obradu u statističkom programu *SPSS*. U daljnjem postupku obrade podataka prometnih nesreća kodirane varijable 0 ili 1 predstavljaju zavisnu varijablu.


5.2. Analiza opasnih mjesta

Na temelju lokalne baze podataka te s pomoću QGIS programa u nastavku su vizualizirane karte prometnih nesreća. Za prostorni prikaz raspodjele gustoće prometnih nesreća tematskih karata korištena je metoda *Quadratic Kernel Density* [18][92]. Toplinske karte prikazuju mjesta s povećanom koncentracijom prometnih nesreća pješaka i biciklista iz kojih su vidljive značajne razlike u mjestima događanja prometnih nesreća. Na kartama su različite koncentracije prometnih nesreća prikazane različitim bojama. Svijetle nijanse žute boje ukazuju na manju gustoću prometnih nesreća, pri čemu tamne nijanse crvene boje ukazuju na veću gustoću prometnih nesreća. Tamna nijansa crvene boje ukazuje na središnji dio žarišta, označava područje sa šest i više prometnih nesreća.

Kod pješačkih je prometnih nesreća uočljivo kako je najveća koncentracija u središtu grada te na glavnim (primarnim) cestovnim prometnicama (Slika 39.). Kod biciklističkih je prometnih nesreća najveća gustoća prometnih nesreća na biciklističkim koridorima, koji su ujedno paralelno položeni uz glavne (primarne) prometnice u gradu (Slika 40.).




Slika 39. Toplinska karta opasnih mjesta pješaka na cestovnim prometnicama u Gradu Zagrebu



Slika 40. Toplinska karta opasnih mjesta biciklista na cestovnim prometnicama u Gradu Zagrebu, 2012.-2014.

Detaljnijom analizom prikaza žarišnih lokacija pješak i biciklist vidljiva je značajnija razlika između lokacija događanja prometnih nesreća, tj. žarišta prometnih nesreća pješaka i biciklista (Slika 41). Iz navedenoga je razloga odlučena izvedba dvaju nezavisnih modela kontekstualne analize vanjskih čimbenika, posebno za pješake te posebno za bicikliste.



Slika 41. Žarišna mjesta pješaka i biciklista na cestovnim prometnicama u Gradu Zagrebu, 2012.-2014.

Analizom je opasnih mjesta (žarišta) utvrđeno kako se na žarišnim mjestima dogodi 19 – 24 % svih prometnih nesreća naleta na pješaka. Analizom je gustoće prometnih nesreća po lokaciji utvrđeno kako se na opasnim mjestima u prosjeku dogodi četiri do pet prometnih nesreća, dok se na svim ostalim lokacijama dogodi svega oko 1,2 prometnih nesreća. Isto ukazuje na postojanje određenih zakonitosti kod događanja prometnih nesreća na opasnim mjestima za razliku od nesreća na svim drugim lokacijama.

Detaljnijom je analizom opasnih mjesta (žarišta) utvrđeno kako se na opasnim mjestima dogodi 7 – 9 % svih prometnih nesreća naleta na biciklistu. Analizom je gustoće prometnih nesreća po lokaciji utvrđeno kako se na opasnim mjestima u prosjeku dogodi 4,2 – 5,3 prometnih nesreća, dok se na svim ostalim lokacijama dogodi oko 1,1 prometna nesreća. Isto ukazuje na postojanje određenih zakonitosti kod događanja prometnih nesreća na opasnim mjestima za razliku od nesreća na svim drugim lokacijama.

Daljnijom pojedinačnom analizom opasnih mjesta (žarišta) naleta na pješaka i na biciklistu s najvećim brojem prometnih nesreća dane su zajedničke karakteristike za te slučajeve.

Kod pješačkih su žarišta uočene dvije najučestalije karakteristične situacije:

1. Prometne se nesreće učestalo događaju na pješačkim prijelazima koji nemaju svjetlosnu signalizaciju, i to na jednosmjernim cestama koje imaju dva i više prometnih trakova. Ovdje su karakteristične većinom lokacije na Ilici.

Ulica je s najvećim brojem zabilježenih naleta motornih vozila na pješake uvjerljivo Ilica, zatim Savska cesta, Vukovarska, Avenija Dubrava, Maksimirska cesta itd.

Slika 42. daje prikaz žarišta s najvećim brojem zabilježenih prometnih nesreća (15 prometnih nesreća – nalet vozila na pješaka) u razdoblju od 2012. do 2014. godine. Brojenjem je prometa u vršnom satu od 16 do 17 sati zabilježeno oko 3 100 motornih vozila te 151 pješak koji prelazi pješački prijelaz koji nema svjetlosnu signalizaciju. Međutim, u neposrednoj je udaljenosti zapadno od ovoga pješačkoga prijelaza raskrižje sa svjetlosnom signalizacijom Ilica – Kustošijanska cesta, na kojemu je zabilježen prijelaz 223 pješaka te 1 prometna nesreća s naletom vozila na pješaka (Slika 44).

Slika 43. također prikazuje situaciju u kojoj je na pješačkom prijelazu bez svjetlosne signalizacije zabilježeno devet prometnih nesreća pješaka (nalet vozila na pješaka) s izbrojanih 213 prijelaza pješaka preko pješačkoga prijelaza u vršnom satu, dok je na susjednom prijelazu Ilica – Selska, na kojem postoji svjetlosna signalizacija, zabilježen svega jedan nalet motornoga vozila na pješaka pri 573 zabilježena prijelaza pješaka. Prometno opterećenje motornoga prometa u vršnom satu iznosi oko 2 100 vozila.



Slika 42. Ilica 285 (Kustošijanska)
Izvor: [77]



Slika 43. Ilica – Domobranska
Izvor: [77]



Slika 44. Toplinska karta prometnih nesreća pješaka – pješački prijelaz Ilica (Kustošijanska)



Slika 45. Toplinska karta prometnih nesreća pješaka – zona Ilica – Selska ulica – Domobranska ulica

2. Prometne se nesreće učestalo događaju na pješačkim prijelazima koji nemaju svjetlosnu signalizaciju i koji su neodgovarajućega dizajna (položaja) pješačkoga prijelaza. Ovdje su karakteristične dvije lokacije: Trg žrtava fašizma i Vlaška – Draškovićeve (Slika 46. – Slika 51.)



Slika 46. Trg žrtava fašizma – Račkoga
Izvor: [77]



Slika 47. Trg žrtava fašizma – Račkoga (2D prikaz)
Izvor: [77]




Slika 48. Vlaška – Draškovićeve – Šoštarićeve
Izvor: [77]



Slika 49. Vlaška – Draškovićeve – Šoštarićeve (2D prikaz)
Izvor: [77]



Slika 50. Toplinska karta prometnih nesreća pješaka – zona Trg žrtava fašizma



Slika 51. Toplinska karta prometnih nesreća pješaka – Vlaška – Draškovićeve – Šoštarićeve

Analizom žarišta biciklista s najvećim brojem prometnih nesreća može se izdvojiti jedna najutjecajnija zajednička karakteristika:

Prometne se nesreće učestalo događaju na raskrižjima „T” oblika, na kojima nema svjetlosne signalizacije, gdje dolazi do sudara između motornoga vozila i biciklista. U većini slučajeva motorna se vozila uključuju sa sporedne ceste (desno skretanje) na glavnu cestu, pri čemu se po koridoru glavne ceste odvija intenzivan biciklistički promet (biciklistički koridor).

Ulice su s najvećim brojem zabilježenih naleta motornih vozila na bicikliste sljedeće: Vukovarska, Savska cesta, Zagrebačka avenija, Ilica, Heinzelova itd.

Slika 52. i Slika 53. prikazuju opasno mjesto u Gradu Zagrebu s najvećim brojem zabilježenih biciklističkih prometnih nesreća (7 prometnih nesreća).




Slika 52. Zagrebačka avenija – Nehajska
Izvor: [77]




Slika 53. Toplinska karta prometnih nesreća biciklista u zoni raskrižja Zagrebačka avenija – Nehajska

Ostala slična žarišta prometnih nesreća biciklista na području Grada Zagreba na kojima se dogodilo najviše prometnih nesreća u potpunosti su identična. Dakle, karakterizira ih raskrižje T oblika na kojem se motorna vozila ulijevaju sa sporednoga prilaza na glavni prometni tok (Slika 54. – Slika 59.). Osim toga, ovdje je spoj dviju jednosmjernih ulica u kojima je isključivo dozvoljeno skretanje udesno pa vozači motornih vozila pri uključivanju na glavnu cestu u pravilu promatraju dolazak drugih vozila s lijeve strane, pri čemu zapostavljaju provjeru desne strane raskrižja s koje dolazi biciklist. Osim navedenoga, na većini je žarišnih lokacija zamijećena smanjena prilazna preglednost raskrižja sa sporedne ceste na glavnu.




Slika 54. Savska cesta - spojna cesta
Izvor: [77]



Slika 55. Savska cesta - spojna cesta (2D prikaz)
Izvor: [77]




Slika 56. Vukovarska – Budmanijeva
Izvor: [77]



Slika 57. Vukovarska - Budmanijeva (2D prikaz),
Izvor: [77]



Slika 58. Heinzlova – Podaubskoga



Slika 59. Heinzlova – Podaubskoga (2D prikaz)
Izvor: [77]

5.3. Metodologija odabira utjecajnih čimbenika

Na temelju rezultata statističke analize podataka o cestovnim prometnim nesrećama u Gradu Zagrebu (Poglavlje 4.) te rezultata prostorne baze podataka cestovne prometne mreže Grada Zagreba, pretpostavljeni su ulazni utjecajni čimbenici za kreiranje modela nastanka prometnih nesreća na urbanom području.

Odabrani su oni utjecajni čimbenici koji mogu doprinijeti povećavanju sigurnosti prometa pješaka i biciklista, a na koje se može utjecati pri planiranju i dizajniranju pješačkih i biciklističkih prometnica u urbanom okružju. Pojedini su čimbenici izostavljeni iz kreiranja konačnoga modela, poput vremenskih uvjeta na cestama, zato što se na njima ne može izravno utjecati. Međutim, ovi su čimbenici u međusobnoj korelaciji jer, kako je već prethodno analizirano i obrađeno (Poglavlje 4), kišni dijelovi tijekom dana značajno utječu na intenzitet biciklista u odnosu na uobičajeni suhi i sunčani dan. Naime, konačni rezultati istraživanja moraju poslužiti projektantima i donositeljima odluka za lakše uočavanje žarišta i učinkovito otklanjanje uzroka prometnih nesreća na postojećoj infrastrukturi (reaktivno djelovanje), kao i za izbjegavanje pogrešaka pri projektiranju novih prometnica (preventivno djelovanje). S druge strane, nove spoznaje o utjecajnim čimbenicima nastanka prometnih nesreća daju informaciju pješacima i biciklistima kao upozorenje na opasna mjesta i na dionice kojima prolaze od izvora do cilja.

Na temelju navedenoga, koristeći ulazne podatke koji su značajnije povezani s temeljnim rizičnim čimbenicima u prometu „cestom” i „okružjem”, u nastavku su odabrani sljedeći nezavisni čimbenici:

- kategorija prometnice
- smjernost prometnica (jednosmjerne prometnice s dvama trakovima ili s više njih, dvosmjerne prometnice s četirima trakovima ili s više njih)
- tip raskrižja
- regulacija prometa na raskrižjima
- ograničenje brzine
- intenzitet prometa
- namjena površina
- razdoblje u godini
- biciklistička infrastruktura.

Kodiranje je ili pridruživanje informacija svakoj pojedinoj prometnoj nesreći izvršeno s pomoću QGIS programa i *Microsoft Excela* programa. Pridruživanje je informacija pojedinoj prometnoj nesreći izvršeno u QGIS okružju tako da je, primjerice, oko središnje linije ulica određena tampon zona (engl. *buffer zone*) paralelno 20 metara sa svake strane. Nadalje je na taj način svakoj lokaciji prometne nesreće koja se nalazila u toj zoni dodijeljen novi atribut, primjerice brojučana oznaka 1. Ovaj je postupak korišten za dodjeljivanje novih informacija kod: kategorije prometnice, smjernosti prometnice, intenziteta prometa i biciklističke infrastrukture. Postupak je pridruživanja informacija kod namjene zemljišta izveden također s pomoću tampon zone u QGIS okružju. U ovom je slučaju oko svake prometne nesreće, koju predstavlja točka u GIS sustavu, kreirana radijalna tampon zona u polumjeru od 400 metara. Ovaj je polumjer odabran jer je udaljenost od 400 metara prosječna duljina hoda pješaka te je također ta duljina i prosječna međusobna udaljenost između stajališta u javnom gradskom prijevozu. Naknadnom je obradom u *Microsoft Excel* programu najveći udio namjene površine, koja se nalazi unutar pojedinačne kružnice, pridružen kao temeljna informacija određenoj prometnoj nesreći. Pridružena je informacija o namjeni zemljišta svakoj prometnoj nesreći izvršena na temelju raspodjele naziva atributa skupne namjene GUP-a Grada Zagreba (Tablica 10.). Bitno je napomenuti kako su one prometne nesreće koje su imale najveći udio skupne namjene „Promet” zamijenjene za sljedeću po redu najveću namjenu površina. Ova je preobrazba napravljena jer je analizom utvrđeno kako su to većinom karakteristične situacije na velikim gradskim raskrižjima s najvećim udjelom „Prometnih površina” koje u konačnici pri primjeni rezultata ne bi spoznale stvarne namjene zemljišta oko tih prometnih nesreća.

5.4. Analiza utjecajnih čimbenika


Nakon identifikacije opasnih mjesta provedena je identifikacija relevantnih čimbenika za koje se smatralo kako imaju potencijalan utjecaj na nastanak opasnoga mjesta. Naime, kako je identifikacijom opasnih mjesta utvrđeno koje prometne nesreće pripadaju, odnosno ne pripadaju opasnim mjestima, kroz identifikaciju je utjecajnih čimbenika testirana statistička važnost da pojedini utjecajni čimbenici povećavaju vjerojatnost nastanka opasnoga mjesta.

Za potrebe utvrđivanja utjecajnih čimbenika analizirane su karakteristike prometne infrastrukture, namjena površine te osnovne karakteristike prometnoga toka u zoni svake prometne nesreće. Odabir čimbenika za koje se smatra kako imaju potencijalan utjecaj na nastanak opasnoga mjesta temelji se na rezultatima deskriptivne i inferencijalne statistike,

prikupljenih podataka koji su prikazani u Poglavlju 4. te na rezultatima prostorne baze podataka cestovne prometne mreže Grada Zagreba. Kako je riječ o kategoričkim podacima za potrebe utvrđivanja asocijacije između opserviranih i očekivanih frekvencija, tj. utvrđivanje utjecaja pojedinih čimbenika na nastanak opasnoga mjesta, korišten je Hi-kvadrat test (neparametrijska statistika). Korištena je razina važnosti 0,05. Radi lakše je eksploracije podataka također dan grafički prikaz (engl. *mosaic plot*) te tablični prikaz (kontingencijska tablica) analiziranih podataka.

Analiza je provedena na uzorku od 1 774 prometne nesreće, od čega je 1 333 prometnih nesreća s pješacima te 441 prometna nesreća s biciklistima.

Prije identifikacije utjecajnih čimbenika bilo je potrebno utvrditi postoji li asocijacija između opasnih mjesta za pješake i opasnih mjesta za bicikliste, za što je proveden Hi-kvadrat test. Analizom je rezultata utvrđeno kako postoji asocijacija između opasnih mjesta za pješake i opasnih mjesta za bicikliste ($\chi^2 = 32,224$ / $p = <0,0001$), što ukazuje na mogućnost postojanja različitih utjecajnih čimbenika na nastanak opasnih mjesta na kojima stradavaju pješaci, odnosno biciklisti. Detaljan je prikaz rezultata dan u tabličnom (Tablica 45.) te grafičkom prikazu (Grafikon 38.) iz kojih je uočljivo kako su veći izgledi za nastanak opasnoga mjesta u kojem stradavaju pješaci. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika (engl. *odds ratio*) čija vrijednost iznosi 3,008, što ukazuje na to kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju pješaci tri puta veći u odnosu na izgled za nastanak opasnoga mjesta na kojem stradavaju biciklisti (intervali su pouzdanosti 2,0124 i 4,470).



Grafikon 38. Povezanost vrste PN-a i žarišta PN-a

Tablica 45. Kontingencijska tablica vrste PN-a i žarišta PN-a

	Zariste		
	Count	0	1
	Total %		
	Col %		
	Row %		
Vrsta_PN	bicikli	411 23.17 27.33 93.20	30 1.69 11.11 6.80
	pjesaci	1093 61.61 72.67 82.00	240 13.53 88.89 18.00
		1504 84.78	270 15.22
			1774

Tablica 46. Hi-kvadrat test vrste PN-a i žarišta PN-a

Test	ChiSquare	Prob>ChiSq
Pearson	32.224	<.0001

Uzimajući u obzir kako postoji asocijacija između opasnih mjesta na kojima stradavaju pješaci i opasnih mjesta na kojima stradavaju biciklisti, u nastavku je provedena identifikacija utjecajnih čimbenika na nastanak opasnoga mjesta posebno za pješački promet te posebno za biciklistički promet. Provođenjem je zasebnih analiza utjecajnih čimbenika za pješački i biciklistički promet također moguće vjerodostojnije utvrditi u kojoj mjeri i koji čimbenici utječu na stradavanje pješaka, a koji na stradavanje biciklista.


U nastavku su prikazani rezultati testiranja asocijacije između pojedinih utjecajnih čimbenika i nastanka opasnoga mjesta u kojem stradavaju pješaci, odnosno biciklisti.

5.4.1. Kategorija prometnice


Za potrebe utvrđivanja asocijacije između kategorije prometnice i nastanka opasnoga mjesta prometna je mreža, na temelju prostorne baze podataka cestovne prometne mreže grada Zagreba, podijeljena u sljedeće tri kategorije: primarna, sekundarna i tercijarna.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci te kategorije prometnice utvrđeno kako ista postoji ($\chi^2 = 137,447 / p = <0,0001$) (Tablica 49.). Analizom je rezultata kontingencijske tablice (Tablica 47.) i grafikona (Grafikon 39.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za pješački promet na primarnoj cestovnoj prometnoj mreži, a zatim na sekundarnoj. Najmanji udio opasnih mjesta nalazi se na tercijarnoj prometnoj mreži.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te kategorije prometnice također utvrđeno kako ista postoji ($\chi^2 = 25,516 / p = <0,0001$) (Tablica 50.). Za razliku od pješačkoga prometa, iz analize je rezultata kontingencijske tablice (Tablica 48.) i grafikona (Grafikon 40.) očitó kako se sva opasna mjesta za biciklistički promet nalaze na primarnoj cestovnoj prometnoj mreži.



Grafikon 39. Povezanost kategorije ceste i žarišta PN-a pješaka



Grafikon 40. Povezanost kategorije ceste i žarišta PN-a biciklista

Tablica 47. Kontingencijska tablica kategorije ceste i žarišta PN-a pješaka

Kategorija_ceste	PN_zarista_pjesaci			
	Count	0	1	
	Total %			
	Col %			
	Row %			
1	464	201	665	
	34,81	15,08	49,89	
	42,45	83,75		
	69,77	30,23		
2	367	32	399	
	27,53	2,40	29,93	
	33,58	13,33		
	91,98	8,02		
3	262	7	269	
	19,65	0,53	20,18	
	23,97	2,92		
	97,40	2,60		
	1093	240	1333	
	82,00	18,00		

Tablica 49. Hi-kvadrat test kategorije ceste i žarišta PN-a pješaka

Test	ChiSquare	Prob>ChiSq
Pearson	137,447	<,0001

Tablica 48. Kontingencijska tablica kategorija ceste i žarišta PN-a biciklista

Kategorija_ceste	PN_zarista_bicikli			
	Count	0	1	
	Total %			
	Col %			
	Row %			
1	464	201	665	
	34,81	15,08	49,89	
	42,45	83,75		
	69,77	30,23		
2	367	32	399	
	27,53	2,40	29,93	
	33,58	13,33		
	91,98	8,02		
3	262	7	269	
	19,65	0,53	20,18	
	23,97	2,92		
	97,40	2,60		
	1093	240	1333	
	82,00	18,00		

Tablica 50. Hi-kvadrat test kategorije ceste i žarišta PN-a biciklista


Test	ChiSquare	Prob>ChiSq
Pearson	25,516	<,0001

5.4.2. Smjernost prometnica


Analizom je prostorne baze podataka cestovne prometne mreže grada Zagreba i identificiranih opasnih mjesta zapaženo nastajanje opasnih mjesta na jednosmjernim prometnicama s dvama prometnim trakovima ili s više njih te dvosmjernim prometnicama s četirima prometnim trakovima ili s više njih. Za potrebe utvrđivanja asocijacije između nastanka opasnoga mjesta pješaka, odnosno biciklista i smjernosti prometnice s brojem prometnih trakova svakoj je prometnoj nesreći (opasnom mjestu) na temelju njezine lokacije dodijeljena nova varijabla koja određuje je li se prometna nesreća dogodila na jednosmjernoj prometnici s dvama prometnim trakovima ili s više njih ili na dvosmjernoj prometnici s četirima prometnim trakovima ili s više njih (0 ili 1).

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci te smjernosti prometnice i broja prometnih trakova utvrđeno kako ista postoji ($\chi^2 = 105,840$ / $p = <0,0001$) (Tablica 53.). Analizom je rezultata kontingencijske tablice (Tablica 51.) i grafikona (Grafikon 41.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za pješački promet na jednosmjernim prometnicama s dvama prometnim trakovima ili s više njih te na dvosmjernim prometnicama s četirima prometnim trakovima ili s više njih. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika čija vrijednost iznosi 4,364, što ukazuje na to kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju pješaci četiri puta veći na jednosmjernim i dvosmjernim prometnicama s više prometnih trakova u odnosu na ostalu cestovnu prometnu mrežu (intervali su pouzdanosti 3,251 i 5,858).

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te smjernosti prometnice i broja prometnih trakova utvrđeno kako ista postoji ($\chi^2 = 33,612$ / $p = <0,0001$) (Tablica 54.). Analizom je rezultata kontingencijske tablice (Tablica 52.) i grafikona (Grafikon 42.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za biciklistički promet na jednosmjernim prometnicama s dvama prometnim trakovima te na dvosmjernim prometnicama s četirima prometnim trakovima ili s više njih. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika čija vrijednost iznosi 11,055, što ukazuje kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju biciklisti 11 puta veći na jednosmjernim i dvosmjernim prometnicama s više prometnih trakova u odnosu na ostalu cestovnu prometnu mrežu (intervali su pouzdanosti 3,251 i 5,858). Omjer je rizika za biciklistički promet oko 2,5 puta veći u odnosu na omjer rizika za pješački promet.



Grafikon 41. Povezanost smjernosti prometnica i žarišta PN-a pješaka



Grafikon 42. Povezanost smjernosti prometnica i žarišta PN-a biciklista

Tablica 51. Kontingencijska tablica smjernosti prometnica i žarišta PN-a pješaka

Jednosmjernja_dvosmjerna_broj_traka	PN_zarista_pjesaci			
	Count	0	1	
	Total %			
	Col %			
	Row %			
0	775	86	861	
	58,14	6,45	64,59	
	70,91	35,83		
	90,01	9,99		
1	318	154	472	
	23,86	11,55	35,41	
	29,09	64,17		
	67,37	32,63		
	1093	240	1333	
	82,00	18,00		

Tablica 52. Kontingencijska tablica smjernosti prometnica i žarišta PN-a biciklista

Jednosmjernje_dvosmjernje_broj_traka	PN_zarista_bicikli			
	Count	0	1	
	Total %			
	Col %			
	Row %			
0	283	5	288	
	64,17	1,13	65,31	
	68,86	16,67		
	98,26	1,74		
1	128	25	153	
	29,02	5,67	34,69	
	31,14	83,33		
	83,66	16,34		
	411	30	441	
	93,20	6,80		

Tablica 53. Hi-kvadrat test smjernosti prometnica i žarišta PN-a pješaka

Test	ChiSquare	Prob>ChiSq
Pearson	105,840	<,0001

Tablica 54. Hi-kvadrat test smjernosti prometnica i žarišta PN-a biciklista


Test	ChiSquare	Prob>ChiSq
Pearson	33,612	<,0001

5.4.3. Tip raskrižja


Za potrebe utvrđivanja asocijacije između tipa (vrste) raskrižja i nastanka opasnoga mjesta raskrižja su na temelju analize podataka upitnika o prometnim nesrećama podijeljena u sljedeće četiri osnovne kategorije: trokraka, četverokraka, kružna te ostala.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci te tipa raskrižja utvrđeno kako ista postoji ($\chi^2 = 86,448$ / $p = <0,0001$). Analizom je rezultata kontingencijske tablice (Tablica 55.) i grafikona (Grafikon 43.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za pješački promet na kružnim raskrižjima, a zatim na četverokrakim i trokrakim.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te tipa raskrižja također utvrđeno kako ista postoji ($\chi^2 = 13,598 / p = 0,0035$). Zbog činjenice da više od 20 % ćelija ima očekivanu vrijednost manju od pet za potrebe utvrđivanja asocijacije, korišten je *Fisherov* egzaktni test, a ne Hi-kvadrat test, na temelju kojega je zaključeno kako postoji asocijacija (vrijednost je *Fisherovoga* egzaktnoga testa 17,989 / $p = 0,001$ za dvostrani test). Za razliku od pješačkoga prometa, analizom je rezultata kontingencijske tablice (Tablica 56.) i grafikona (Grafikon 44.) uočljivo kako se najveći udio opasnih mjesta za biciklistički promet nalazi na trokrakim raskrižjima, a zatim na četverokrakim. Opasna mjesta na kružnim raskrižjima te ostalim tipovima nisu zabilježena.



Grafikon 43. Povezanost tipa raskrižja i žarišta PN-a pješaka



Grafikon 44. Povezanost tipa raskrižja i žarišta PN-a biciklista

Tablica 55. Kontingencijska tablica tipa raskrižja i žarišta PN-a pješaka

	PN_zariste_pjesaci			
	Count	0	1	
	Total %			
	Col %			
	Row %			
Tip_raskrizja	1	267 20,03 24,43 79,70	68 5,10 28,33 20,30	335 25,13
	2	235 17,63 21,50 69,32	104 7,80 43,33 30,68	339 25,43
	3	10 0,75 0,91 50,00	10 0,75 4,17 50,00	20 1,50
	4	581 43,59 53,16 90,92	58 4,35 24,17 9,08	639 47,94
		1093 82,00	240 18,00	1333

Tablica 56. Kontingencijska tablica tipa raskrižja i žarišta PN-a bicikala

	PN_zarista_bicikli			
	Count	0	1	
	Total %			
	Col %			
	Row %			
Tip_raskrizja	1	179 40,59 43,55 89,95	20 4,54 66,67 10,05	199 45,12
	2	102 23,13 24,82 91,07	10 2,27 33,33 8,93	112 25,40
	3	5 1,13 1,22 100,00	0 0,00 0,00 0,00	5 1,13
	4	125 28,34 30,41 100,00	0 0,00 0,00 0,00	125 28,34
		411 93,20	30 6,80	441

Tablica 57. Hi-kvadrat test tipa raskrižja i žarišta PN-a pješaka


Test	ChiSquare	Prob>ChiSq
Pearson	86,448	<,0001

5.4.4. Regulacija prometa na raskrižjima


Za potrebe utvrđivanja asocijacije između regulacije prometa na raskrižjima i nastanka opasnoga mjesta, na temelju analize podataka upitnika o prometnim nesrećama i prostorne baze podataka cestovne prometne mreže grada Zagreba, raskrižja su podijeljena u dvije osnovne kategorije: raskrižja upravljana prometnim znakovima i pravilima (0) te raskrižja upravljana prometnim svjetlima (1).

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci te regulacije prometa na raskrižju utvrđeno kako ista postoji ($\chi^2 = 63,763 / p = <0,0001$) (Tablica 60.). Analizom je rezultata kontingencijske tablice (Tablica 58.) i grafikona (Grafikon 45.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za pješački promet na raskrižjima upravljanim prometnim svjetlima. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika čija vrijednost iznosi 3,286, što ukazuje na to kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju pješaci tri puta veći na raskrižjima upravljana prometnim svjetlima u odnosu na ostala (intervali su pouzdanosti 2,430 i 4,445).

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te regulacije prometa na raskrižju utvrđeno kako ista ne postoji ($\chi^2 = 1,362 / p = 0,243$) (Tablica 61.), kontingencijska tablica (Tablica 59.) i grafikon (Grafikon 46.).



Grafikon 45. Povezanost regulacije prometa i žarišta PN-a pješaka



Grafikon 46. Povezanost regulacije prometa i žarišta PN-a biciklista

Tablica 58. Kontingencijska tablica regulacije prometa i žarišta PN-a pješaka

Regulacija_prometa_na_raskrižju	PN_zarista_pjesaci			
	Count	0	1	
	Total %			
	Col %			
	Row %			
0		906	143	1049
		67,97	10,73	78,69
		82,89	59,58	
		86,37	13,63	
1		187	97	284
		14,03	7,28	21,31
		17,11	40,42	
		65,85	34,15	
		1093	240	1333
		82,00	18,00	

Tablica 60. Hi-kvadrat test regulacije prometa i žarišta PN-a pješaka

Test	ChiSquare	Prob>ChiSq
Pearson	63,763	<,0001

Tablica 59. Kontingencijska tablica regulacije prometa i žarišta PN-a biciklista

Regulacija_prometa_na_raskrižju	PN_zarista_bicikli			
	Count	0	1	
	Total %			
	Col %			
	Row %			
0		325	21	346
		73,70	4,76	78,46
		79,08	70,00	
		93,93	6,07	
1		86	9	95
		19,50	2,04	21,54
		20,92	30,00	
		90,53	9,47	
		411	30	441
		93,20	6,80	

Tablica 61. Hi-kvadrat test regulacije prometa i žarišta PN-a biciklista


Test	ChiSquare	Prob>ChiSq
Pearson	1,362	0,2431

5.4.5. Ograničenje brzine


Za potrebe utvrđivanja asocijacije između zakonskoga ograničenja brzine vožnje i nastanka opasnoga mjesta sve su prometne nesreće, na temelju analize podataka upitnika o prometnim nesrećama i prostorne baze podataka cestovne prometne mreže grada Zagreba, podijeljene u dvije osnovne kategorije: nesreće na prometnicama koje imaju zakonsko ograničenje do i uključujući 40 km/h (0) te nesreće na prometnicama koje imaju zakonsko ograničenje jednako i više od 50 km/h (1). S obzirom na to da je na većini prometnica u urbanoj sredini zakonsko ograničenje 50 km/h, ista je vrijednost korištena kao granična za kategorizaciju prometnica drugačijih obilježja, tj. s većim ili manjim zakonskim ograničenjem brzine vožnje, što ujedno i ukazuje na prometne uvjete pojedine prometnice.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci te zakonskoga ograničenja brzine vožnje utvrđeno kako ista postoji ($\chi^2 = 12,175$ / $p = 0,0005$) (Tablica 64.). Analizom je rezultata kontingencijske tablice (Tablica 62.) i grafikona (Grafikon 47.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za pješački promet na prometnicama sa zakonskim ograničenjima brzine vožnje većim od 50 km/h. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika čija vrijednost iznosi 2,934, što ukazuje na to kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju pješaci gotovo tri puta veći na prometnicama sa zakonskim ograničenjima brzine vožnje većim od 50 km/h u odnosu na ostale (intervali su pouzdanosti 1,561 i 5,515).

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te zakonskoga ograničenja brzine vožnje utvrđeno kako ista ne postoji ($\chi^2 = 2,434 / p = 0,119$) (Tablica 65.), kontingencijska tablica (Tablica 63.) i grafikon (Grafikon 48.).



Grafikon 47. Povezanost ograničenja brzine i žarišta PN-a pješaka



Grafikon 48. Povezanost ograničenja brzine i žarišta PN-a biciklista

Tablica 62. Kontingencijska tablica ograničenja brzine i žarišta PN-a pješaka

	PN_zarista_pjesaci		
	Count	0	1
	Total %		
	Col %		
	Row %		
Ogranicenje_brzine	0	135 10,13 12,35 92,47	11 0,83 4,58 7,53
	1	958 71,87 87,65 80,71	229 17,18 95,42 19,29
		1093 82,00	240 18,00
		1333	

Tablica 64. Hi-kvadrat test ograničenja brzine i žarišta PN-a pješaka

Test	ChiSquare	Prob>ChiSq
Pearson	12,175	0,0005*

Tablica 63. Kontingencijska tablica ograničenja brzine i žarišta PN-a biciklista

	PN_zarista_bicikli		
	Count	0	1
	Total %		
	Col %		
	Row %		
Ogranicenje_brzine	0	31 7,03 7,54 100,00	0 0,00 0,00 0,00
	1	380 86,17 92,46 92,68	30 6,80 100,00 7,32
		411 93,20	30 6,80
		441	

Tablica 65. Hi-kvadrat test ograničenja brzine i žarišta PN-a biciklista

Test	ChiSquare	Prob>ChiSq
Pearson	2,434	0,1187


5.4.6. Intenzitet prometne potražnje

Za potrebe utvrđivanja asocijacije između intenziteta prometne potražnje pješačkoga i biciklističkoga prometa i nastanka opasnoga mjesta sve su prometne nesreće, na temelju analize prostorne baze podataka cestovne prometne mreže grada Zagreba, podijeljene u dvije osnovne kategorije: nesreće na prometnicama (lokacijama) koje ne predstavljaju glavne pješačke ili biciklističke koridore (0) te nesreće na prometnicama (lokacijama) koje predstavljaju glavne pješačke ili biciklističke koridore (1). Intenzitet se prometne potražnje temelji na pješačkim i biciklističkim koridorima zbog nedostatka podataka o točnom broju istih za svaku lokaciju


prometne nesreće. Naime, za potrebe bi prikupljanja podataka o intenzitetu prometnih tokova za svaku lokaciju prometne nesreće bilo potrebno provesti brojenje prometa na preko 800 lokacija. Koridori su pretpostavljani na temelju svih dostupnih podatka brojenja prometa za pješake i bicikliste te na temelju provedenih terenskih istraživanja i brojenjima za sva ovim radom identificirana karakteristična opasna mjesta.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci te intenziteta prometne potražnje utvrđeno kako ista postoji ($\chi^2 = 244,163$ / $p = <0,0001$) (Tablica 68.). Analizom je rezultata kontingencijske tablice (Tablica 66.) i grafikona (Grafikon 49.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za pješački promet na prometnicama koje su dio pješačkoga koridora. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika čija vrijednost iznosi 19,438, što ukazuje kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju pješaci 19 puta veći na prometnicama (lokacijama) koje su dio pješačkih koridora (intervali su pouzdanosti 12,099 i 31,228).

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te intenziteta prometne potražnje utvrđeno kako ista postoji ($\chi^2 = 39,145$ / $p = <0,0001$) (Tablica 69). Analizom je rezultata kontingencijske tablice (Tablica 67.) i grafikona (Grafikon 50.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za biciklistički promet na prometnicama koje su dio biciklističkoga koridora. Nije zabilježeno niti jedno opasno mjesto na lokacijama koje nemaju veći intenzitet biciklističkoga prometa.



Grafikon 49. Povezanost intenziteta prometa i žarišta PN-a pješaka



Grafikon 50. Povezanost intenziteta prometa i žarišta PN-a biciklista

Tablica 66. Kontingencijska tablica intenziteta prometa i žarišta PN-a pješaka

Intenzitet_prometne_potraznje	PN_zarista_pjesaci			
	Count	0	1	
	Total %			
	Col %			
	Row %			
0	698	20	718	
	52,36	1,50	53,86	
	63,86	8,33		
	97,21	2,79		
1	395	220	615	
	29,63	16,50	46,14	
	36,14	91,67		
	64,23	35,77		
	1093	240	1333	
	82,00	18,00		

Tablica 67. Kontingencijska tablica intenziteta prometa i žarišta PN-a biciklista

Intenzitet_prometne_potraznje	PN_zarista_bicikli			
	Count	0	1	
	Total %			
	Col %			
	Row %			
0	242	0	242	
	54,88	0,00	54,88	
	58,88	0,00		
	100,00	0,00		
1	169	30	199	
	38,32	6,80	45,12	
	41,12	100,00		
	84,92	15,08		
	411	30	441	
	93,20	6,80		

Tablica 68. Hi-kvadrat test intenziteta prometa i žarišta PN-a pješaka

Test	ChiSquare	Prob>ChiSq
Pearson	244,163	<,0001

Tablica 69. Hi-kvadrat test intenziteta prometa i žarišta PN-a biciklista

Test	ChiSquare	Prob>ChiSq
Pearson	39,145	<,0001

Analizom je biciklističkih i pješačkih koridora utvrđeno kako isti također imaju asocijaciju s kategorijom prometnice, namjenom površine te postojanjem biciklističke infrastrukture, što je potrebno uzeti u obzir pri kreiranju modela. Naime, postojanje više zavisnih varijabla u modelu koje ukazuju na slične činjenice može utjecati na valjanost modela (problem multikolinearnosti).


5.4.7. Namjena površine

Za potrebe je utvrđivanja asocijacije između namjene površine u samoj zoni nastanka prometne nesreće i nastanka opasnoga mjesta lokacije prometnih nesreća, na temelju analize podataka upitnika o prometnim nesrećama i prostorne baze podataka cestovne prometne mreže Grada Zagreba, podijeljena u dvije osnovne kategorije: nesreće koje se nalaze u zoni stambene i mješovite namjene (1), zoni javne i poslovne namjene (2) te nesreće u ostalim zonama (3). Prethodno je definirana raspodjela namjena površina temeljena na analizi prostorne baze podataka cestovne prometne mreže i namjena površina Grada Zagreba iz koje je uočljivo kako se veći broj prometnih nesreća događa upravo u zonama stambene i mješovite namjene te zonama javne i poslovne namjene.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci te namjene površine utvrđeno kako ista postoji ($\chi^2 = 11,719 / p = 0,0029$) (Tablica 72.). Analizom je rezultata kontingencijske tablice (Tablica 70.) i grafikona (Grafikon 51.) uočljivo postojanje veće

vjerojatnosti nastanka opasnoga mjesta za pješački promet u javnim i poslovnim zonama, a zatim stambenim i mješovitim te ostalim.

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te tipa raskrižja također utvrđeno kako ista postoji ($\chi^2 = 7,293 / p = 0,0261$). Zbog činjenice da više od 20 % ćelija ima očekivanu vrijednost manju od pet, za potrebe je utvrđivanja asocijacije korišten *Fisherov* egzaktni test, a ne *Hi-kvadrat* test, na temelju kojega je zaključeno kako postoji asocijacija (vrijednost je *Fisherovoga* egzaktnoga testa 8,204, $p = 0,016$ za dvostrani test). Za razliku od pješačkoga prometa analizom je kontigencijske tablice (Tablica 71.) i grafikona (Grafikon 52.) uočljivo da se najveći udio opasnih mjesta za biciklistički promet nalazi u zonama stambene i mješovite namjene, a zatim u javnim i poslovnim zonama. U ostalim zonama nisu zabilježena opasna mjesta za biciklistički promet.




Grafikon 51. Povezanost namjene površina i žarišta PN-a pješaka

Tablica 70. Kontigencijska tablica namjene površina i žarišta PN-a pješaka

	PN_zarista_pjesaci			
	Count	0	1	
	Total %			
	Col %			
	Row %			
1		848	168	1016
		63,62	12,60	76,22
		77,58	70,00	
		83,46	16,54	
2		150	54	204
		11,25	4,05	15,30
		13,72	22,50	
		73,53	26,47	
3		95	18	113
		7,13	1,35	8,48
		8,69	7,50	
		84,07	15,93	
		1093	240	1333
		82,00	18,00	

Tablica 72. Hi-kvadrat test namjene površina i žarišta PN-a pješaka

Test	ChiSquare	Prob>ChiSq
Pearson	11,719	0,0029



Grafikon 52. Povezanost namjene površina i žarišta PN-a biciklista


Tablica 71. Kontigencijska tablica namjene površina i žarišta PN-a biciklista

	PN_zarista_bicikli			
	Count	0	1	
	Total %			
	Col %			
	Row %			
1		280	27	307
		63,49	6,12	69,61
		68,13	90,00	
		91,21	8,79	
2		67	3	70
		15,19	0,68	15,87
		16,30	10,00	
		95,71	4,29	
3		64	0	64
		14,51	0,00	14,51
		15,57	0,00	
		100,00	0,00	
		411	30	441
		93,20	6,80	

5.4.8. Razdoblje u godini

Uzimajući u obzor kako prometni tokovi značajnije osciliraju tijekom različitih razdoblja u godini (primjerice turistička sezona), za potrebe utvrđivanja asocijacije između razdoblja u godini i nastanka opasnoga mjesta prometne su nesreće s pješacima, na temelju analize podataka upitnika o prometnim nesrećama, podijeljene u 12 kategorija prema mjesecu u kojem su nastale. Prometne su nesreće s biciklistima podijeljene u dvije osnovne kategorije: razdoblje sezone biciklističkoga prometa (1) te razdoblje izvan sezone biciklističkoga prometa. Podjela je pješačkih i biciklističkih prometnih nesreća u prethodno navedene kategorije temeljena na rezultatima deskriptivne i inferencijalne statistike koji ukazuju na određene razlike broja nesreća ovisno o vremenskim uvjetima, tj. razdoblju tijekom godine (Poglavlje 4.). Razdoblje je sezone biciklističkoga prometa te razdoblje izvan sezone biciklističkoga prometa definirano na temelju podataka s cjelogodišnjega automatskoga brojača biciklističkoga prometa. Odabrani su mjeseci od travnja do rujna u jednoj kalendarskoj godini oni s najvećim udjelom biciklističkoga prometa te je taj dio godine nazvan sezonom biciklističkoga prometa, pri čemu je preostali dio mjeseci u godini razdoblje izvan sezone. Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju pješaci i mjeseca u godini utvrđeno kako ista ne postoji ($\chi^2 = 8,394 / p = 0,6776$) (Tablica 73.), (Grafikon 53.).


Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te sezone biciklističkoga prometa utvrđeno kako ista postoji ($\chi^2 = 6,491 / p = 0,0108$) (Tablica 75.). Analizom je rezultata kontingencijske tablice (Tablica 74.) i grafikona (Grafikon 54.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za biciklistički promet tijekom biciklističke sezone, tj. tijekom mjeseci s boljim vremenskim uvjetima. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika čija vrijednost iznosi 3,117, što ukazuje na to kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju biciklisti oko tri puta veći tijekom trajanja biciklističke sezone (intervali su pouzdanosti 1,248 i 7,787).



Grafikon 53. Povezanost mjeseca i žarišta PN-a pješaka

Tablica 73. Hi-kvadrat test mjeseca i žarišta PN-a pješaka

Test	ChiSquare	Prob>ChiSq
Pearson	8,394	0,6776



Grafikon 54. Povezanost mjeseca i žarišta PN-a biciklista

Tablica 74. Kontingencijska tablica mjeseca i žarišta PN-a biciklista

Sezona_biciklistickog_prometa	PN_zarista_bicikli		
	Count	0	1
	Total %		
	Col %		
	Row %		
0	180	6	186
	40,82	1,36	42,18
	43,80	20,00	
	96,77	3,23	
1	231	24	255
	52,38	5,44	57,82
	56,20	80,00	
	90,59	9,41	
	411	30	441
	93,20	6,80	

Tablica 75. Hi-kvadrat test mjeseca i žarišta PN-a biciklista


Test	ChiSquare	Prob>ChiSq
Pearson	6,491	0,0108

5.4.9. Biciklistička infrastruktura

Za potrebe utvrđivanja asocijacije između postojanja biciklističke infrastrukture i nastanka opasnoga mjesta biciklističkoga prometa prometne su nesreće s biciklistima, na temelju analize podataka upitnika o prometnim nesrećama i prostorne baze podataka cestovne prometne mreže Grada Zagreba, podijeljene u dvije osnovne kategorije: nesreće na prometnicama koje nemaju biciklističku infrastrukturu (0) te nesreće na prometnicama koje imaju biciklističku infrastrukturu (1).

Testom je asocijacije između nastanka opasnoga mjesta na kojem stradavaju biciklisti te postojanja biciklističke infrastrukture u zoni istoga utvrđeno kako ista postoji ($\chi^2 = 40,547$, $p = 0,0001$) (Tablica 77.). Analizom je rezultata kontingencijske tablice (Tablica 76.) i grafikona (Grafikon 55.) uočljivo postojanje veće vjerojatnosti nastanka opasnoga mjesta za biciklistički

promet u zonama u kojima postoji biciklistička infrastruktura. Za potrebe je utvrđivanja jakosti asocijacije korišten omjer rizika čija vrijednost iznosi 13,186, što ukazuje na to kako su izgledi za nastanak opasnoga mjesta na kojem stradavaju biciklisti oko 13 puta veći u zonama u kojima postoji biciklistička infrastruktura (intervali su pouzdanosti 4,928 i 35,284).



Grafikon 55. Povezanost biciklističke infrastrukture i žarišta PN-a biciklista

Tablica 76. Kontingencijska tablica biciklističke infrastrukture i žarišta PN-a biciklista

	PN_zarista_bicikli		
	Count	0	1
	Total %		
	Col %		
	Row %		
Biciklistička_infrastrukture	0	298 67,57 72,51 98,35	5 1,13 16,67 1,65
	1	113 25,62 27,49 81,88	25 5,67 83,33 18,12
		411 93,20	30 6,80
		303 68,71	138 31,29

Tablica 77. Hi-kvadrat test biciklističke infrastrukture i žarišta PN-a biciklista

Test	ChiSquare	Prob>ChiSq
Pearson	40,547	<,0001

6. IZRADA MODELA LOGISTIČKE REGRESIJE ŽARIŠTA PROMETNIH NESREĆA

Na temelju rezultata provedenih istraživanja o utjecajnim čimbenicima pristupilo se razvijanju modela za utvrđivanje vjerojatnosti nastanka opasnoga mjesta u kojem stradavaju pješaci i biciklisti. Modelom će biti moguće procijeniti predstavlja li određena lokacija potencijalno opasno mjesto na kojem će se događati prometne nesreće u kojima sudjeluju pješaci i biciklisti.

S obzirom na to da je testom asocijacije utvrđena veza između opasnih mjesta u kojima sudjeluju pješaci te opasnih mjesta u kojima sudjeluju biciklisti, kreirana su dva modela. Naime, utvrđivanjem asocijacije kao i analizom utjecajnih čimbenika moguće je pretpostaviti postojanje različitih utjecajnih čimbenika na nastanak opasnoga mjesta za pješački, odnosno za biciklistički promet.

Analizom je utjecajnih čimbenika te lokacija na kojima se javljaju opasna mjesta utvrđeno kako na nastanak opasnoga mjesta u kojem sudjeluju pješaci i biciklisti utjecaj imaju karakteristike prometne infrastrukture, namjene površine te osnovne karakteristike prometnoga toka.

Kako se modelom procjenjuje vjerojatnost nastanka opasnoga mjesta, tj. zavisna je varijabla dihotomna (ima vrijednost 0 ili 1), za potrebe je kreiranja modela korištena binarna logistička regresija.

6.1. Binarna logistička regresija

Logistička regresija služi za ocjenu koliko dobro skup prediktorskih (nezavisnih) varijabla predviđa ili objašnjava kategorijsku (zavisnu) varijablu. Logistička regresija služi za dobivanje:

- pokazatelja adekvatnosti modela (skup prediktorskih varijabla), tj. za ocjenu kvalitete predviđanja rezultata
- pokazatelja relativne važnosti svake prediktorske varijable.

Kako bi se istražilo je li neko mjesto na cestovnoj mreži s povećanom frekvencijom događanja prometnih nesreća opasno mjesto (žarište) ili nije, primijenit će se binarna logistička regresija. Binarna se logistička regresija koristi u situacijama kada zavisna (kriterijska) varijabla koju želimo objasniti sadrži dvije kategorije, odnosno kada je binarna, tj. dihotomna, pri čemu

nezavisne varijable mogu biti dihotomne, nominalne s više modaliteta, a mogu biti i numeričke. Ukoliko zavisna varijabla sadrži više od dviju kategorija, riječ je o multinomnoj linearnoj regresiji. Bitno je napomenuti kako za razliku od linearne regresijske analize, logistička regresija ne pretpostavlja linearni tip veze između zavisnih varijabla i nezavisnih (kriterijskih) varijabla, niti normalnost distribucije zavisnih varijabla za svaku kombinaciju nezavisnih varijabla, kao niti pogreške predviđanja.

U ovom se doktorskom radu s pomoću binarne logističke regresije ispituje skup utjecajnih nezavisnih varijabla (pješaka i biciklista) na binarnu zavisnu varijablu (žarište prometne nesreće).

Preporučeni je broj uzoraka [94] po kriterijskoj nezavisnoj varijabli najmanje 50, što je u ovom doktorskom radu i ispunjeno. Naime, konačni model za pješački promet sadrži 6 nezavisnih varijabla na skupu podataka od 1 331 prometne nesreće, pri čemu biciklistički model sadrži 4 nezavisne varijable na skupu podataka od 441 prometne nesreće.

Pretpostavke su izrade binarne logističke statističke analize sljedeće:

1. Zavisna varijabla treba biti dihotomna binarna.
2. Nezavisne varijable moraju biti međusobno neovisne.
3. Ne smije postojati multikolinearnost između nezavisnih varijabla, tj. ne smiju imati visoku međusobnu korelaciju.
4. Potrebno je imati dovoljno velik uzorak.
5. Među svim varijablama moraju postojati podatci, tj. podatci u bazi moraju biti potpuno popunjeni.

Konačna jednadžba binarne logističke regresije za procjenu vjerojatnosti događanja jest:

$$Y_{PJ} = \frac{e^{a+bX}}{1+e^{a+bX}}, \quad (3)$$

gdje je:

- Y_{pj} – vjerojatnost događanja nekoga događaja
- a – konstanta
- b – regresijski koeficijenti
- X – nezavisne varijable.

6.2. Analiza ulaznih podataka

Pri kreiranju je modela polazna pretpostavka bila kako na nastanak opasnoga mjesta na kojem stradavaju pješaci i biciklisti utječu karakteristike prometne infrastrukture, namjene površine te osnovne karakteristike prometnoga toka. U skladu s navedenim, za svaku je prometnu nesreću na temelju prostorne baze podataka utvrđena pripadnost opasnom mjestu. Lokacija je opasnih mjesta kao sama metodologija pridruživanja informacije o pripadnosti opasnom mjestu svakoj nesreći detaljno prikazana i opisana u Poglavlju 5.1. Informacije su o karakteristikama prometne infrastrukture određene na temelju podataka iz upitnika o prometnim nesrećama.

Model je opasnih mjesta pješačkoga prometa kreiran na uzorku od 1 333 prometne nesreće, dok je model opasnih mjesta biciklističkoga prometa kreiran na uzorku od 441 prometne nesreće. Detaljnom su analizom pojedine biciklističke prometne nesreće unutar pojedinoga žarišta zamijećene dvije prometne nesreće izrazito važne različnosti u odnosu na druge prometne nesreće unutar žarišta, te su iste isključene iz daljnje obrade. Jedan od mogućih razloga pogrešno su uneseni znakovi u informatički sustav MUP-a.

Analizom rezultata identifikacije utjecajnih čimbenika prikazanih u Poglavlju 5.4. za potrebe kreiranja modela korišteni su sljedeći čimbenici za koje se pretpostavlja kako imaju utjecaj na nastanak opasnoga mjesta:

- karakteristike prometne infrastrukture
 - kategorija prometnice
 - smjernost ulice te broj prometnih trakova
 - tip raskrižja
 - regulacija prometa na raskrižju
 - biciklistička prometnica
- namjena površine
 - namjena površine – prostorno-planska dokumentacija
- karakteristike prometnoga toka
 - intenzitet prometne potražnje
 - brzina – zakonsko ograničenje.

Detaljno je istraživanje, kao i metodologija kategorizacije svakoga pojedinoga čimbenika te asocijacija i jakost veze s nastankom opasnoga mjesta, opisano u Poglavlju 5.

Zbog mogućnosti korištenja modela pri kreiranju idejnih prometnih rješenja nove cestovne infrastrukture, pri kreiranju modela nisu korišteni čimbenici koje nije moguće objektivno predvidjeti. Naime, analizom je podataka također utvrđena i ovisnost vremenskih događanja prometnih nesreća, kao i samih okolnosti prometnih nesreća i sl., na nastanak opasnoga mjesta, stoga je takve informacije moguće imati tek nakon događanja prometne nesreće, tj. nakon početka eksploatacije nove prometne infrastrukture. Primjerice, nije korišten čimbenik okolnosti nastanka prometne nesreće jer je taj kriterij isključivo slobodna procjena policijskoga službenika. Naime, stvarne se okolnosti nastanka prometne nesreće utvrđuju sudskim postupkom, a ti podatci nisu poznati.

Kako je utvrđena statistički važna razlika između žarišta prometnih nesreća u kojima sudjeluju pješaci te žarišta prometnih nesreća u kojima sudjeluju biciklisti, kreirana su dva modela logističke regresijske analize:

- model za prometne nesreće naleta na pješaka
- model za prometne nesreće naleta na bicikl.

Nezavisne varijable koje nisu bile dihotomne, kodirane su kao dihotomne s pomoću *simple* metode [95].

6.3. Model identifikacije opasnih mjesta za pješački promet

Za izradu je modela identifikacije opasnih mjesta za pješački promet korištena binarna logistička regresija sa simultanom metodom (sve su varijable na temelju istraživanja simultano uključene u model te sve ostaju u modelu). Korištena je razina važnosti 0,05 (5%).

Kako su sve nezavisne varijable kategorijske polazne pretpostavke binarne logističke regresije zadovoljene, nije potrebno raditi test linearnosti između logit transformacije zavisne varijable i nezavisnih kontinuiranih varijabla. Isto tako, binarna logistička regresija ne zahtijeva normalnost distribucije niti homogenost varijanci kao što je to slučaj kod linearne regresije.

Kategorijske su varijable koje nisu bili dihotomne s pomoću *simple* metode kodirane kao dihotomne. Kodiranje je ostalih varijabla rađeno prema zaključcima identifikacije utjecajnih čimbenika (Poglavlje 5.4.).

Rezultati su prve iteracije modela identifikacije opasnih mjesta za pješački promet koji uključuje sve nezavisne varijable prikazani tablično u nastavku (Tablica 78.).

Tablica 78. Model identifikacije opasnih mjesta za pješački promet – prva iteracija

<i>Variables in the Equation</i>								
	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
							Lower	Upper
kategorija_cesta_1_2_3			22,447	2	,000			
kategorija_cesta_1_2_3(1)	1,058	,441	5,759	1	,016	2,880	1,214	6,832
kategorija_cesta_1_2_3(2)	,026	,463	,003	1	,954	1,027	,415	2,542
smjernost_cesta	,411	,183	5,057	1	,025	1,508	1,054	2,158
raskrizje_1_4_NOVO			32,251	3	,000			
raskrizje_1_4_NOVO(1)	,769	,224	11,791	1	,001	2,157	1,391	3,346
raskrizje_1_4_NOVO(2)	1,243	,258	23,279	1	,000	3,465	2,092	5,741
raskrizje_1_4_NOVO(3)	2,107	,560	14,151	1	,000	8,226	2,744	24,661
regulacija_prometa_na_raskrižjima	-,146	,226	,419	1	,517	,864	,554	1,346
ogranicenje_brzine	,478	,361	1,751	1	,186	1,612	,795	3,271
intenzitet_prometne_potraznje	2,432	,265	84,377	1	,000	11,382	6,774	19,125
GUP_javna_poslovna	,058	,215	,074	1	,786	1,060	,695	1,617
Constant	-5,162	,528	95,428	1	,000	,006		

Analizom je statističke važnosti cijeloga modela (Tablica 78.) koji uključuje sve utjecajne čimbenike za koje je utvrđena asocijacija s nastankom opasnoga mjesta potvrđena statistička važnost (omnibus test, $\chi^2 = 369,748 / df = 10 / N = 1333 / p = <0,000$). Testiranjem je ponašanja po distribuciji (*goodness of fit*) također utvrđeno kako je model ispravan (Hosmer i Lemeshow test, $\chi^2 = 8,454 / df = 8 / p = 0,390$), iz čega se može zaključiti da model razlikuje nastanak opasnoga mjesta s obzirom na različite utjecajne čimbenike. Logističkim je modelom objašnjeno 0,242 (Cox i Snell R^2) varijacije zavisne varijable, odnosno 0,397 (Nagelkerke R^2). Modelom je točno klasificirano 81,0 % opasnih mjesta u kojima stradavaju pješaci.

Analizom je statističke važnosti nezavisnih varijabla utvrđeno kako četiri varijable statistički nisu značajno prodonijele modelu, tj. za predmetne je varijable $p > 0,05$.

Na temelju rezultata prve iteracije logističkoga modela te detaljne analize svih utjecajnih čimbenika, utjecaja istih na zavisnu varijablu, kao i međusoban utjecaj provedena je druga iteracija modela. Naime, pretpostavka je kako varijable koje nemaju statističku važnost u modelu ne pridonose boljoj predikciji modela.

Rezultati su druge iteracije modela identifikacije opasnih mjesta za pješački promet prikazani tablično u nastavku (Tablica 79.).

Tablica 79. Model identifikacije opasnih mjesta za pješački promet – druga iteracija


		Variables in the Equation						95% C.I. for EXP(B)	
		B	S.E.	Wald	df	Sig.	Exp(B)	Lower	Upper
	kategorija_cesta_1_2_3			94,694	2	,000			
X1	kategorija_cesta_1_2_3(1)	2,618	,396	43,801	1	,000	13,704	6,312	29,752
X2	kategorija_cesta_1_2_3(2)	1,016	,429	5,605	1	,018	2,762	1,191	6,404
	raskrižje_1_4_NOVO			60,647	3	,000			
X3	raskrižje_1_4_NOVO(1)	,940	,203	21,386	1	,000	2,560	1,719	3,814
X4	raskrižje_1_4_NOVO(2)	1,396	,191	53,257	1	,000	4,038	2,776	5,874
X5	raskrižje_1_4_NOVO(3)	2,052	,497	17,055	1	,000	7,783	2,939	20,608
X6	GUP_javna_poslovna	,517	,198	6,815	1	,009	1,677	1,138	2,473
a	Constant	-4,320	,403	114,968	1	,000	,013		

Analizom statističke važnosti cijeloga modela (Tablica 79.) koji uključuje samo važnije utjecajne čimbenike za koje je utvrđena asocijacija s nastankom opasnoga mjesta potvrđena je statistička važnost (omnibus test, $\chi^2 = 227,360 / df = 6 / N = 1333 / p = <0,000$). Testiranje je ponašanja po distribuciji (*goodness of fit*) također utvrdilo kako je model ispravan (Hosmer i Lemeshow test, $\chi^2 = 8,475 / df = 8 / p = 0,389$), iz čega se može zaključiti da model razlikuje nastanak opasnoga mjesta s obzirom na različite utjecajne čimbenike. Logističkim je modelom objašnjeno 0,157 (Cox i Snell R^2) varijacije zavisne varijable, odnosno 0,257 (Nagelkerke R^2). Modelom je točno klasificirano 81,0 % opasnih mjesta u kojima stradavaju pješaci.

Analizom je ponašanja po distribuciji dobiveni model u drugoj iteraciji bolji te su sve nezavisne varijable u modelu statistički važne ($p < 0,05$). Isto tako predmetni model bolje klasificira nesreće koje se nisu dogodile na opasnim mjestima.

Sve su nezavisne varijable u pozitivnoj vezi s nastankom opasnoga mjesta, tj. sve varijable utječu na povećanje vjerojatnosti nastanka opasnoga mjesta. Najjaču vezu ima primarna kategorija prometnice $Exp(B)=13,704$, a zatim raskrižje s kružnim tokom prometa $Exp(B)=7,783$ te četverokrako raskrižje $Exp(B)=4,038$. Najjači je utjecaj kategorije prometnice na nastanak opasnoga mjesta očekivan jer je utvrđena jaka asocijacija između kategorije prometnice i intenziteta prometne potražnje. Iz istoga razloga intenzitet prometne potražnje kao nezavisna varijabla nije uključen u model.

Granična je vrijednost određena na temelju grafikona promatranih i prognoziranih vrijednosti na iznos 0,4 (Grafikon 56.).



Na temelju dobivenih rezultata završni je model za utvrđivanje nastanka opasnoga mjesta prema jednadžbi 3, a u kojem sudjeluju pješaci, sljedeći:

$$Y_{PJ} = \frac{1}{1 + e^{-(4,320 + 2,618X_1 + 1,016X_2 + 0,940X_3 + 1,396X_4 + 2,052X_5 + 0,517X_6)}} \quad (5)$$

- X_1 – primarna prometnica
- X_2 – sekundarna prometnica
- X_3 – trokrako raskrižje
- X_4 – četverokrako raskrižje
- X_5 – raskrižje s kružnim tokom prometa
- X_6 – namjena površine (javna i poslovna)
- a – konstanta.

6.4. Model identifikacije opasnih mjesta za biciklistički promet

Za izradu je modela identifikacije opasnih mjesta za biciklistički promet korištena također binarna logistička regresija sa simultanom metodom (sve su varijable na temelju istraživanja simultano uključene u model te sve ostaju u modelu). Korištena je razina važnosti 0,05 (5 %).

Kako su sve nezavisne varijable kategorijske polazne pretpostavke binarne logističke regresije zadovoljene, nije potrebno raditi test linearnosti između logit transformacije zavisne varijable i nezavisnih kontinuiranih varijabla. Isto tako, binarna logistička regresija ne zahtijeva normalnost distribucije niti homogenost varijanca kao što je to slučaj kod linearne regresije. Kodiranje je varijabla rađeno prema zaključcima identifikacije utjecajnih čimbenika, Poglavlje 5.4.

Rezultati su prve iteracije modela identifikacije opasnih mjesta za biciklistički promet koji uključuje sve nezavisne varijable prikazani u nastavku teksta (Tablica 80.).

Tablica 80. Model identifikacije opasnih mjesta za biciklistički promet – prva iteracija

	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
							Lower	Upper
kategorija_cesta	-16,973	2313,366	,000	1	,994	,000	,000	.
smjernost_cesta	,528	,735	,517	1	,472	1,696	,401	7,167
raskrizje_T	,887	,476	3,476	1	,062	2,427	,956	6,165
ogranicenje_brzine	16,154	5632,972	,000	1	,998	10364503,534	,000	.
intenzitet_prometne_potraznje	17,322	2151,646	,000	1	,994	33324025,172	,000	.
GUP-stambena_i_mješovita	1,649	,683	5,835	1	,016	5,200	1,365	19,815
biciklistička_staza-traka	1,823	,720	6,410	1	,011	6,191	1,509	25,396
Constant	-38,304	6029,921	,000	1	,995	,000		

Analizom je statističke važnosti cijeloga modela (Tablica 80.), koji uključuje sve utjecajne čimbenike za koje je utvrđena asocijacija s nastankom opasnoga mjesta, potvrđena statistička važnost (omnibus test, $\chi^2 = 96,019 / df = 7 / N = 441 / p = <0,000$). Testiranje je ponašanja po distribuciji (*goodness of fit*) također utvrdilo kako je model ispravan (Hosmer i Lemeshow test, $\chi^2 = 5,767 / df = 8 / p = 0,673$), iz čega se može zaključiti da model razlikuje nastanak opasnoga mjesta s obzirom na različite utjecajne čimbenike. Logističkim je modelom objašnjeno 0,196 (Cox i Snell R^2) varijacija zavisne varijable, odnosno 0,500 (Nagelkerke R^2). Modelom je točno klasificirano 93,7 % opasnih mjesta u kojima stradavaju biciklisti.

Analizom je statističke važnosti nezavisnih varijabla utvrđeno kako su samo dvije varijable dale statistički značajan doprinos modelu, tj. za predmetne je varijable $p < 0,05$.

Na temelju rezultata prve iteracije logističkoga modela te detaljne analize svih utjecajnih čimbenika, utjecaja istih na zavisnu varijablu kao i međusoban utjecaj provedena je druga iteracija modela. Naime, pretpostavka je kako varijable koje nemaju statističku važnost u modelu ne pridonose boljoj predikciji modela. Isto tako, izrazito velike vrijednosti Exp(B) ukazuju na moguće atipične vrijednosti.

Rezultati su druge iteracije modela identifikacije opasnih mjesta za biciklistički promet prikazani u nastavku teksta (Tablica 81.).

Tablica 81. Model identifikacije opasnih mjesta za biciklistički promet – druga iteracija
Variables in the Equation


	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
							Lower	Upper
X1 smjernost ceste	1,728	,593	8,481	1	,004	5,631	1,760	18,021
X2 raskrižje_T	,953	,445	4,581	1	,032	2,593	1,084	6,204
X3 GUP-stambena_i_mješovita	2,024	,643	9,898	1	,002	7,570	2,145	26,713
X4 biciklistička_staza-traka	1,883	,588	10,249	1	,001	6,574	2,076	20,824
a Constant	-6,826	,864	62,439	1	,000	,001		

Analizom statističke važnosti cijeloga modela (Tablica 81.), koji uključuje samo važnije utjecajne čimbenike za koje je utvrđena asocijacija s nastankom opasnoga mjesta, potvrđena je statistička važnost (omnibus test, $\chi^2 = 66,394 / df = 4 / N = 441 / p = <0,000$). Testiranje je ponašanja po distribuciji (*goodness of fit*) također utvrdilo kako je model ispravan (Hosmer i Lemeshow test, $\chi^2 = 12,673 / df = 7 / p = 0,080$), iz čega se može zaključiti da model razlikuje nastanak opasnoga mjesta s obzirom na različite utjecajne čimbenike. Logističkim je modelom objašnjeno 0,140 (Cox i Snell R^2) varijacije zavisne varijable, odnosno 0,357 (Nagelkerke R^2). Modelom je točno klasificirano 93,0 % opasnih mjesta u kojima stradavaju biciklisti.

Analizom je ponašanja po distribuciji dobiveni model u drugoj iteraciji bolji te su sve nezavisne varijable u modelu statistički važne ($p < 0,05$).

Sve su nezavisne varijable u pozitivnoj vezi s nastankom opasnoga mjesta, tj. sve varijable utječu na povećanje vjerojatnosti nastanka opasnoga mjesta. Najjaču vezu ima namjena površine ($\text{Exp}(B)=7,570$, a zatim postojanje biciklističke infrastrukture $\text{Exp}(B)=6,574$ te smjernost prometnice i broj trakova $\text{Exp}(B)=5,631$). Najjači je utjecaj namjene površine kao i postojanje biciklističke infrastrukture na nastanak opasnoga mjesta očekivan jer je utvrđena jaka asocijacija između istih i intenziteta prometne potražnje. Iz istoga razloga intenzitet prometne potražnje kao nezavisna varijabla nije uključen u model.

Granična je vrijednost određena na temelju grafikona promatranih i prognoziranih vrijednosti na iznos 0,4 (Grafikon 57.).



Grafikon 57. Promatrane i prognozirane vrijednosti – bicikli

Analizom je vrijednosti *Cookove* udaljenosti utvrđeno kako nema vrijednosti većih od 1 te se prema preporukama može smatrati da nema gotovo sigurnih atipičnih vrijednosti [96]. Na isto upućuju manje vrijednosti omjera rizika.

Na temelju dobivenih rezultata završni je model za utvrđivanje nastanka opasnoga mjesta u kojem sudjeluju biciklisti sljedeći:

$$Y_{PJ} = \frac{e^{-6,826+1,728X_1+0,953X_2+2,024X_3+1,883X_4}}{1 + e^{-6,826+1,728X_1+0,953X_2+2,024X_3+1,883X_4}} \quad (6)$$

$$Y_{PJ} = \frac{1}{1+e^{-(6,826+1,728X_1+0,953X_2+2,024X_3+1,883X_4)}} \quad (7)$$

gdje su:

- X_1 – smjernost ceste – jednosmjerna prometnica s dvama prometnim trakovima ili s više njih, dvosmjerna prometnica s četirima prometnim trakovima ili s više njih
- X_2 – trokrako raskrižje
- X_3 – namjena površine (stambena i mješovita)
- X_4 – postojanje biciklističke infrastrukture (staze i trake)
- a – konstanta.

7. VALIDACIJA MODELA

S ciljem je utvrđivanja primjenjivosti kreiranih modela za pješake i bicikliste u urbanim sredinama provedena validacija istih. Validacija je modela logističke regresije žarišta prometnih nesreća pješaka i biciklista u urbanim sredinama provedena na novom skupu podataka prometnih nesreća iz 2015. godine. Ovi podatci nisu korišteni pri kreiranju baznih modela.


7.1. Metodologija validacije modela

Postupak je validacije modela identifikacije opasnih mjesta pješačkoga i biciklističkoga prometa proveden na temelju baze podataka o prometnim nesrećama u kojima su sudjelovali pješaci i biciklisti na području Grada Zagreba u 2015. godini.

Kako model prognozira nastanak opasnoga mjesta na temelju definiranih ulaznih podataka, prvo je bilo potrebno utvrditi sva opasna mjesta na kojima su stradavali pješaci i biciklisti u 2015. godini. Utvrđivanje je opasnih mjesta provedeno prema metodologiji detaljno opisanoj u Poglavlju 5.1. Kako bi se na temelju korištenoga metodološkoga pristupa identificirala opasna mjesta za podatke iz 2015. godine te kako bi se ispunio uvjet od triju i više istovrsnih prometnih nesreća u tri godine, pridruženi su podatci o prometnim nesrećama iz 2014. i 2013. godine.


Nakon utvrđivanja opasnih mjesta svakoj je prometnoj nesreći (448 pješačkih i 121 biciklistička) u 2015. godini dodijeljena informacija o pripadnosti opasnom mjestu. Također, daljnji je postupak kodiranja, odnosno pridruživanja informacija (vrsta ceste, smjernost ulica, intenzitet prometne potražnje, namjena površina i pripadnost biciklističkoj prometnici) za svaku prometnu nesreću iz 2015. godine izvršen istovjetno prema ranijem metodološkom pristupu izrade modela logističke regresije.

Svi su prethodno navedeni koraci posebno provedeni za prometne nesreće iz 2015. godine u kojima su sudjelovali pješaci i biciklisti. Slika 60. daje prikaz žarišnih mjesta pješačkih i biciklističkih prometnih nesreća u razdoblju od 2013. do 2015. godine.




Slika 60. Žarišna mjesta pješaka i biciklista na cestovnim prometnicama u Gradu Zagrebu, 2013.-2015.

Ukupan je broj prometnih nesreća u kojima su sudjelovali pješaci u 2015. godini na području Grada Zagreba iznosio 448, od čega ih se 85 dogodilo na opasnim mjestima. Analizom je opasnih mjesta za pješački promet u 2015. godini utvrđeno kako se u odnosu na 2014. godinu pojavilo 27 novih opasnih mjesta. Istih je opasnih mjesta ostalo 41, dok je nestalo 18 opasnih mjesta. Ukupan je broj identificiranih opasnih mjesta u 2015. godini za pješački promet na području Grada Zagreba bio 67, što je za osam više u odnosu na 2014. godinu. Analizom je na terenu utvrđeno kako je nestanak opasnih mjesta najčešće vezan uz rekonstrukciju postojećega stanja prometne infrastrukture. Slika 61. daje prikaz opasnih mjesta u 2015. godini u odnosu na 2014. godinu.



Slika 61. Žarišta prometnih nesreća pješaka 2013.-2015. u odnosu na žarišta prometnih nesreća pješaka 2012.-2014.

Ukupan je broj prometnih nesreća u kojima su sudjelovali biciklisti u 2015. godini na području Grada Zagreba iznosio 121, od čega ih se osam dogodilo na opasnim mjestima (žarištima). Analizom je opasnih mjesta u razdoblju 2013. – 2015. godine za biciklistički promet utvrđeno kako su se u odnosu na razdoblje 2012. – 2014. godine pojavila dva nova opasna mjesta (Slika 62). Istih je opasnih mjesta ostalo pet, pri čemu je nestalo samo jedno opasno mjesto. Ukupan je broj identificiranih opasnih mjesta u razdoblju 2013. – 2015. godine za pješački promet na području Grada Zagreba bio sedam, što je za jedan više u odnosu na razdoblje 2012. – 2014. godine. Analizom je na terenu utvrđeno kako je nestanak opasnoga mjesta vezan uz rekonstrukciju postojeće prometne infrastrukture. Slika 62. daje prikaz opasnih mjesta u razdoblju 2013. – 2015. godine u odnosu na razdoblje 2012. – 2014. godine.



Slika 62. Žarišta prometnih nesreća biciklista 2013. – 2015. u odnosu na žarišta prometnih nesreća biciklista 2012. – 2014.

7.2. Rezultati validacije

Analizom je identificiranih opasnih mjesta u kojima stradavaju pješaci prema metodologiji prikazanoj u Poglavlju 5.1. utvrđeno 67 opasnih mjesta. Broj prometnih nesreća pješaka na kojem je izrađena validacija iznosi 448.

Nakon identifikacije opasnih mjesta te pridruživanja informacije svakoj prometnoj nesreći u 2015. godini u kojoj su sudjelovali pješaci, o pripadnosti je opasnom mjestu provedena predikcija na temelju kreiranoga modela. Kako bi se mogla provesti validacija, u sljedećem je koraku na temelju kreiranoga modela izračunana vjerojatnost kako određena prometna nesreća na temelju karakteristike prometne infrastrukture, namjene površine te osnovnih karakteristika prometnog toka pripada, odnosno ne pripada opasnom mjestu.

Usporednom je analizom promatranih te modelom predviđenih vrijednosti utvrđeno odstupanje u 91 prometnoj nesreći (20,31 %). Dobiveno je odstupanje u skladu s karakteristikama modela

koji točno klasificira 81,0 % opasnih mjesta u kojima stradavaju pješaci uz razinu važnosti od 0,05.

Analizom je identificiranih opasnih mjesta u kojima stradavaju biciklisti prema metodologiji prikazanoj u Poglavlju 5.1. utvrđeno sedam opasnih mjesta. Broj prometnih nesreća biciklista na kojem je izrađena validacija iznosi 121.

Nakon identifikacije opasnih mjesta te pridruživanja informacije svakoj prometnoj nesreći u 2015. godini u kojoj su sudjelovali biciklisti, o pripadnosti je opasnom mjestu provedena predikcija na temelju kreiranoga modela. Kako bi se mogla provesti validacija, u sljedećem je koraku na temelju kreiranoga modela izračunana vjerojatnost da određena prometna nesreća na temelju karakteristike prometne infrastrukture, namjene površine te osnovnih karakteristika prometnoga toka pripada, odnosno ne pripada opasnom mjestu.

Usporednom je analizom promatranih te modelom predviđenih vrijednosti utvrđeno odstupanje u 13 prometnih nesreća (10,74 %). Dobiveno je odstupanje u skladu s karakteristikama modela koji točno klasificira 93,0 % opasnih mjesta u kojima stradavaju biciklisti uz razinu važnosti od 0,05.

Usporedbom promatranih te modelima predviđenih vrijednosti utvrđena su odstupanja manja od 5 %, što ukazuje na točnost modela više od 95 %.

8. ZAKLJUČAK

Pogrešna je percepcija da pješaci i biciklisti predstavljaju opasnost za druge sudionike u prometu. Naprotiv, oni su puno češće žrtve i danas su, više nego ikada prije, izloženi opasnostima koje su posljedicom složenoga prometnoga okružja i nepoštivanja prometnih propisa od strane vozača. U koliziji pješaka i biciklista s vozilima koje ima daleko veću masu i brzinu gotovo isključivo stradavaju pješaci i biciklisti. Stoga su neke zemlje u svoju sudsku praksu uvele da je pješak uvijek u pravu pri koliziji s vozilom. Naime, smatra se kako normalna osoba nikada neće svjesno uzrokovati prometnu nesreću u kojoj će ona sama biti žrtva.

U svijetu prosječno godišnje pogine oko 1,2 milijuna ljudi u prometu, a oko 50 milijuna ljudi biva ozlijeđeno (teže i lakše). Zbog „podizviješćenosti” o stradanjima u prometnim nesrećama smatra se da je broj teže i lakše ozlijeđenih u prometu daleko veći, pa taj broj postaje i do 100 puta veći u odnosu na broj smrtnih slučajeva. Prometne nesreće predstavljaju ogroman financijski trošak za cjelokupno društvo. On približno iznosi između 2 i 4 % BDP-a zemlje, što za Republiku Hrvatsku prema nekih izračunima iznosi oko 8,5 milijarda kuna godišnje. Razvijene zemlje ulažu ogromne napore za smanjenje broja prometnih nesreća i u tome su vrlo uspješne. Na taj način smanjuju ukupne troškove i znatno pridonose rastu gospodarstva u svojoj zemlji. Nasuprot tomu, u nerazvijenim zemljama raste broj prometnih nesreća, a time i troškovi, što ih vodi u još veće siromaštvo.

Iako se pristup izučavanju prometnih nesreća od početnoga tradicionalnoga modela preobrazio u sustavni multidisciplinarni pristup, do danas nije pronađen znanstveno utemeljeni cjeloviti model koji bi u potpunosti riješio problem nastanka prometnih nesreća na cestama u urbanom okružju. Kako je u složenoj interakciji glavnih čimbenika (čovjek-vozilo-okružje), koji dovode do prometnih nesreća, najmanje istraženo područje utjecaja okružja na nastanak prometnih nesreća, ovaj je rad usredotočen na analizu prometnih nesreća pješaka i biciklista u kontekstu složenoga urbanoga okružja. U radu su provedena brojna teoretska i terenska istraživanja te statističke analize, nakon čega je utemeljena znanstvena dijagnoza koja je pokazala kako postojeće stanje sigurnosti pješaka i biciklista u Republici Hrvatskoj nije zadovoljavajuće.

Polazna je točka, ali i nužan preduvjet za izradu ovoga rada kvalitetna baza prikupljenih podataka. Ona služi za retrospektivnu analizu nastanka prometnih nesreća i omogućava provedbu daljnjih istraživanja. Kod prikupljanja podataka vodilo se računa da podatci budu: pouzdani (vjerodostojni i nedvojbeni), relevantni (uključene su sve bitne značajke prometne

nesreće) i istovjetni (usporedivi su s relevantnim bazama podataka). Posebna je pozornost posvećena provjeri kvalitete prostornih i neprostornih podataka te otkrivanju i uklanjanju pogrešaka. Učinkovit je sustav za upravljanje prostornom bazom podataka preduvjet za upravljanje velikim heterogenim skupovima podataka u funkcionalnom analitičkom sustavu podrške koji se temelji na GIS-u. Pomoću GIS sustava moguće je mapiranje, upravljanje, analiziranje i vizualizacija prikupljenih podataka o prometnim nesrećama. Daljnje jačanje GIS sustava u području sigurnosti prometa na nacionalnoj razini može stručnjacima omogućiti jednostavnije, učinkovitije i kvalitetnije upravljanje prometnim nesrećama, a s druge strane, s pomoću mrežnih aplikacija moguće je stanovnicima dati informaciju o opasnim mjestima, odnosno žarištima prometnih nesreća.

Učitavanjem lokacija prometnih nesreća u GIS okružje s pomoću zapisa iz UPN obrasca o geografskoj širini i duljini uočen je problem odstupanja pojedinih prometnih nesreća u odnosu na položaj pojedinih elemenata cestovne mreže. Ovaj je problem opažen i u ranijim sličnim istraživanjima te je ovim radom ponovno potvrđen. Kako je skup podataka prometnih nesreća u ovom radu bio relativno mali, u QGIS programu obavljena je ručna korekcija položaja pojedinih prometnih nesreća. Za potrebe istraživanja većega skupa podataka prometnih nesreća te njihovoga georeferenciranja u GIS okružju, u budućnosti je nužno riješiti postojeću problematiku sa stručnim službama MUP-a te informacijskim stručnjacima iz toga područja.

Za potrebe je istraživanja provedena statistička analiza nad skupom podataka prometnih nesreća naleta na pješaka i prometnih nesreća naleta na bicikl. Metode su statističke analize koje su korištene u radu metode deskriptivne i inferencijalne statističke analize. Provedenom detaljnom analizom prometnih nesreća u Gradu Zagrebu u razdoblju od 2012. do 2014. godine može se utvrditi porazna činjenica da je postotak učešća naleta na pješake i bicikliste u porastu u odnosu na ukupan broj prometnih nesreća. Tako je udio naleta na pješaka u ukupnom broju prometnih nesreća porastao sa 4,7 % na 6,7 %, udio naleta na bicikl u istom je razdoblju porastao s 1,7 % na 2,3 %, pri čemu je prosječan godišnji pad ukupnoga broja prometnih nesreća u tom trogodišnjem razdoblju iznosio 14,2 %. Drugim riječima, u Gradu Zagrebu svakoga dana biva ozlijeđen jedan pješak, odnosno svaka tri dana biva ozlijeđen jedan biciklist. Lošem stanju sigurnosti u prometu značajno doprinosi neodgovarajuća biciklističko-pješačka infrastruktura. Naime, funkcionalno izvedena infrastruktura nogostupa, posebice u središtu grada, zauzeta je parkiranjem motornih vozila te naknadno označenim biciklističkim stazama. Provedenim je brojenjem prometa zabilježen stalni porast biciklističkoga prometa tijekom posljednjih godina,

pri čemu je uočljiva potkapacitiranost pješačkih i biciklističkih površina u središtu grada. Prema novom *Pravilniku o biciklističkoj infrastrukturi* povećani broj biciklista na većini koridora predstavlja kriterij koji zahtijeva segregirane šire i udobnije biciklističke prometnice.

Bitno je napomenuti kako donošenje zaključaka samo na temelju statističke obrade podataka prometnih nesreća iz baze podataka MUP-a bez geoprostorne analize istih u GIS okružju (mapiranja, vizualizacije) doista može navesti na krive i nepotpune zaključke. Jedan je od razloga činjenica što je policijski djelatnik pri unosu podataka u UPN obrazac ograničen odabirom samo jednoga znaka iz službenoga *Znakovnika*. Karakterističan je primjer unos znaka u polje „karakteristika ceste”, pri čemu se od 25 ponuđenih znakova mora odabrati samo jedan znak. U praksi je, pri naletu vozila na pješaka na obilježenom pješačkom prijelazu, prema evidenciji MUP-a, zabilježen većinom znak 18, koji prema *Znakovniku* označava *ravni cestovni potez*, dok je manji udio takvih prometnih nesreća označen znakom 20 (*pješački prijelaz*). Ovakve situacije ukazuju na nužne izmjene pri unosu podataka u UPN obrazac kako bi se prema potrebi omogućio dodatan unos potrebnih znakova (atributa) za preciznije definiranje mjesta nesreće i provedbe vjerodostojnije statističke analize.

Postupku izrade modela binarne logističke regresije za procjenu zajedničkoga utjecaja odabranih vanjskih čimbenika na nastanak žarišta prometnih nesreća prethodile su identifikacija žarišta prometnih nesreća i identifikacija utjecajnih čimbenika. Za potrebe je identifikacije opasnih mjesta pješaka i biciklista na urbanoj cestovnoj mreži Grada Zagreba primijenjena metodologija pristupa sigurnosti prometa od Hrvatskih cesta d.o.o., gdje je upotrijebljen kriterij tri (3) ili više istovrsnih prometnih nesreća s ozlijeđenim osobama u tri (3) godine (ista skupina sudionika, isti pravci kretanja, iste konfliktne točke i drugo). Nakon postupka identifikacije opasnih mjesta, a na temelju rezultata deskriptivne i inferencijalne statističke analize podataka o cestovnim prometnim nesrećama, pretpostavljeni su ulazni utjecajni čimbenici. Pojedini su čimbenici izostavljeni iz kreiranja modela, poput vremenskih uvjeta na cestama, zato što se na njih ne može izravno utjecati niti ih se može objektivno predvidjeti.

Analizom rezultata identifikacije utjecajnih čimbenika za potrebe kreiranja konačnoga modela odabrani su sljedeći čimbenici za koje se pretpostavlja kako imaju utjecaj na nastanak opasnoga mjesta:

- karakteristike prometne infrastrukture
 - kategorija prometnice
 - smjernost ulice te broj prometnih trakova
 - tip raskrižja
 - regulacija prometa na raskrižju
 - biciklistička prometnica
- namjena površine
 - namjena površine – prostorno-planska dokumentacija
- karakteristike prometnoga toka
 - intenzitet prometne potražnje
 - brzina – zakonsko ograničenje.

Kako je utvrđena statistički važna razlika između žarišta prometnih nesreća u kojima sudjeluju pješaci te žarišta prometnih nesreća u kojima sudjeluju biciklisti, kreirana su dva modela logističke regresijske analize:

- model za prometne nesreće naleta na pješaka
- model za prometne nesreće naleta na bicikl.

Za izradu je modela identifikacije opasnih mjesta korištena binarna logistička regresija sa simultanom metodom. Izvršene su po dvije iteracije za svaki model, pri čemu su u prvoj iteraciji odabrane sve varijable te su simultano uključene u model. U drugoj iteraciji nakon isključivanja varijabla s razinom važnosti većom od 0,05, prvi je model za prometne nesreće naleta na pješaka točno klasificirao 81,0 % opasnih mjesta, pri čemu je drugi model za prometne nesreće naleta na bicikl točno klasificirao 93,0 % opasnih mjesta. Provedenom validacijom modela na skupu podataka prometnih nesreća iz 2015. godine s pomoću usporedne analize između promatranih i modelom predviđenih vrijednosti, za prvi je model pješaka utvrđeno odstupanje od 20,31 % prometnih nesreća, a za drugi model biciklista od 10,74 %.

Primjenom je modela identifikacije opasnih mjesta moguće utvrditi predstavlja li pojedina lokacija potencijalno opasno mjesto za pješački ili biciklistički promet. Za potrebe modela kao ulazne podatke potrebno je znati osnovne prometno-tehnološke karakteristike lokacije, namjenu površine u zoni lokacije te osnovne karakteristike prometnoga toka. Isto tako, činjenica da se svi ulazni podatci za upotrebu modela znaju već u etapi planiranja i projektiranja prometne infrastrukture dodatno pridonosi važnosti i primjenjivosti istoga u predikciji potencijalno opasnih mjesta. Dosadašnja je praksa utvrđivanja opasnih mjesta uglavnom temeljena na bazama podataka o prometnim nesrećama za određeno razdoblje u kojem se

očekuje da će se dogoditi određeni broj istovrsnih nesreća na istoj lokaciji. Glavnim je nedostatak ovakve metodologije usredotočenost na postojeće podatke o prometnim nesrećama, tj. nesreće se uistinu trebaju dogoditi.

Znanstveni doprinos rada predstavlja izrada modela logističke regresije kojim se dokazuje izravna korelacija žarišta prometnih nesreća s vanjskim čimbenicima. Model je testiran na stvarnim podacima o prometnim nesrećama iz 2015. godine u Gradu Zagrebu. Testiranje je potvrdilo ispravnost modela, pa time i mogućnost njegove primjene za upravljanje prometnim nesrećama u urbanim sredinama. U aplikativnom smislu, rezultati istraživanja mogu poslužiti projektantima i donositeljima odluka za lakše uočavanje žarišta i učinkovito otklanjanje prometnih nesreća na postojećoj infrastrukturi te za izbjegavanje pogrešaka kod dizajniranja novih prometnica. Mapirana se žarišta u GIS okružju mogu iskoristiti za davanje upozorenja o opasnim mjestima i dionicama kojima prolaze pješaci i biciklisti na svom putu od izvorišta do odredišta.

Za podizanje je sigurnosti cestovnoga prometa na veću razinu potreban multidisciplinarni integrirani pristup cijele društvene zajednice, kao i temeljite strukturne promjene u pripremi i provedbi mjera od preventivnih, administrativnih, tehničkih i zakonodavnih sve do edukativnih te je usporedno s njima nužno razvijati i prometnu kulturu.

Sugerira se da se fokus daljnjih istraživanja u dijelu sigurnosti cestovnoga prometa usmjerava, na temelju saznanja iz rada, na aktivnosti vezane uz smisleno upravljanje prometnom sigurnošću urbanih sredina. Daljnja će istraživanja u ovom području sigurnosti cestovnoga prometa biti usredotočena na primjenjivost ove kontekstualne analize prometnih nesreća pješaka i biciklista na manje urbane sredine od Grada Zagreba. Dobiveni će se rezultati i spoznaje u radu koristiti u daljnjoj znanstvenoj i stručnoj evaluaciji te valorizaciji u drugim urbanim sredinama. Osim istraživanja prometnih nesreća s fokusom na pješake i bicikliste u budućnosti, slična se metodologija rada može primijeniti i na druge istovrsne prometne nesreće u kojima su, primjerice, uključeni samo motocikli ili osobna motorna vozila. U nastavku je istraživanja potrebno usmjeriti aktivnosti i na poboljšanje točnosti geografskih zapisa lokacija prometnih nesreća. Na taj bi se način omogućila pouzdana, učinkovita i automatizirana geoprostorna analiza podataka prometnih nesreća.

LITERATURA

- [1] CROW, *Road safety manual*, Record 26. 2009.
- [2] Holz-Rau, C. i Scheiner, J., „Geographical Patterns in Road Safety: Literature Review and a Case Study from Germany“, *EJTIR*, sv. 13, izd. 2, str. 99–122, 2013.
- [3] Summala, H., Pasanen, E., Räsänen, M., i Sievänen, J., „Bicycle accidents and drivers' visual search at left and right turns“, *Accid. Anal. Prev.*, sv. 28, izd. 2, str. 147–153, 1996.
- [4] Noland, R. B. i Quddus, M. A., „A spatially disaggregate analysis of road casualties in England“, *Accid. Anal. Prev.*, sv. 36, izd. 6, str. 973–984, 2004.
- [5] LaScala, E. A., Gerber, D., i Gruenewald, P. J., „Demographic and environmental correlates of pedestrian injury collisions: a spatial analysis“, *Accid. Anal. Prev.*, sv. 32, izd. 5, str. 651–658, 2000.
- [6] Loo, B. P. Y. i Tsui, K. L., „Bicycle crash casualties in a highly motorized city“, *Accid. Anal. Prev.*, sv. 42, izd. 6, str. 1902–1907, 2010.
- [7] European Commission, „Road Safety in the European Union“, 2015. [Na internetu]. Dostupno na: http://ec.europa.eu/transport/road_safety/pdf/vademecum_2015.pdf.
- [8] Eksler, V. i Lassarre, S., „Evolution of road risk disparities at small-scale level: Example of Belgium“, *J. Safety Res.*, sv. 39, izd. 4, str. 417–427, 2008.
- [9] Schneider, R. J., Khattak, A. J., i Zegeer, C. V., „Method of Improving Pedestrian Safety Proactively with Geographic Information Systems: Example from A College Campus“, *Transp. Res. Rec.*, izd. 1773, str. 97–107, 2001.
- [10] Pulugurtha, S. S., Krishnakumar, V. K., i Nambisan, S. S., „New methods to identify and rank high pedestrian crash zones: An illustration“, *Accid. Anal. Prev.*, sv. 39, izd. 4, str. 800–811, 2007.
- [11] Agüero-Valverde, J. i Jovanis, P. P., „Spatial analysis of fatal and injury crashes in Pennsylvania“, *Accid. Anal. Prev.*, sv. 38, izd. 3, str. 618–625, 2006.
- [12] Inouye, D. K. i Berry, K. A., „Assessing Bikeway Networks around Public Schools: A Tool for Transportation Planning in Washoe County, Nevada“, *Plan. Pract. Res.*, sv. 23, izd. 2, str. 229–247, 2008.
- [13] O'Sullivan, D. i Unwin, D., *Geographic information analysis*. John Wiley & Sons, Inc., 2010.
- [14] Siddiqui, C., Abdel-Aty, M., i Choi, K., „Macroscopic spatial analysis of pedestrian and

- bicycle crashes“, *Accid. Anal. Prev.*, sv. 45, str. 382–391, 2012.
- [15] Blazquez, C. A. i Celis, M. S., „A spatial and temporal analysis of child pedestrian crashes in Santiago, Chile“, *Accid. Anal. Prev.*, sv. 50, str. 304–311, 2013.
- [16] Prasannakumar, V., Vijith, H., Charutha, R., i Geetha, N., „Spatio-Temporal Clustering of Road Accidents: GIS Based Analysis and Assessment“, *Procedia - Soc. Behav. Sci.*, sv. 21, str. 317–325, 2011.
- [17] Geurts, K., Thomas, I., i Wets, G., „Understanding spatial concentrations of road accidents using frequent item sets“, *Accid. Anal. Prev.*, sv. 37, izd. 4, str. 787–799, 2005.
- [18] Anderson, T. K., „Kernel density estimation and K-means clustering to profile road accident hotspots“, *Accid. Anal. Prev.*, sv. 41, izd. 3, str. 359–364, 2009.
- [19] Erdogan, S., Yilmaz, I., Baybura, T., i Gullu, M., „Geographical information systems aided traffic accident analysis system case study: city of Afyonkarahisar“, *Accid. Anal. Prev.*, sv. 40, izd. 1, str. 174–181, 2008.
- [20] Steenberghen, T., Dufays, T., Thomas, I., i Flahaut, B., „Intra-urban location and clustering of road accidents using GIS: a Belgian example“, *Int. J. Geogr. Inf. Sci.*, sv. 18, izd. 2, str. 169–181, 2004.
- [21] Šimunović, L., Novačko, L., i Ćosić, M., „Road Network Safety Management in the Republic of Croatia“, *Modern Traffic*, sv. 34, izd. 3–4, str. 240–244, 2014.
- [22] Sørensen, M., *Best Practice Guidelines on Black Spot Management and Safety Analysis of Road Networks*. The Institute of Transport Economics-TOI, 2007.
- [23] „iRAP“. [Na internetu]. Dostupno na: <http://www.irap.net/en/>. [Pristupljeno: 26-ruj-2015].
- [24] „EuroRAP - HAK“. [Na internetu]. Dostupno na: <http://www.hak.hr/sigurnost-u-prometu/projekti/eurorap/>. [Pristupljeno: 11-ruj-2015].
- [25] Li, L., Zhu, L., i Sui, D. Z., „A GIS-based Bayesian approach for analyzing spatial-temporal patterns of intra-city motor vehicle crashes“, *J. Transp. Geogr.*, sv. 15, izd. 4, str. 274–285, 2007.
- [26] Priyantha Wedagama, D. M., Bird, R. N., i Metcalfe, A. V., „The influence of urban land-use on non-motorised transport casualties.“, *Accid. Anal. Prev.*, sv. 38, izd. 6, str. 1049–57, 2006.
- [27] Dumbaugh, E. i Rae, R., „Safe Urban Form: Revisiting the Relationship Between Community Design and Traffic Safety“, *J. Am. Plan. Assoc.*, sv. 75, izd. 3, str. 309–329, lip. 2009.

- [28] Kim, K. i Yamashita, E. Y., „Using a K-Means Clustering Algorithm to Examine Patterns of Pedestrian Involved Crashes in Honolulu, Hawaii“, *J. Adv. Transp.*, sv. 41, izd. 1, str. 69–89, 2007.
- [29] Zelenika, R., *Metodologija i tehnologija izrade znanstvenog i strucnog dijela*, 4. izd. Rijeka: Ekonomski fakultet Sveučilišta u Rijeci, 2000.
- [30] Šimunović, L. i Ćosić, M., *Nemotorizirani promet*. Zagreb: Fakultet prometnih znanosti, 2015.
- [31] Haider, A. H., Crompton, J. G., Oyetunji, T., Risucci, D., DiRusso, S., Basdag, H., Villegas, C. V., Syed, Z. U., Haut, E. R., i Efron, D. T., „Mechanism of injury predicts case fatality and functional outcomes in pediatric trauma patients: the case for its use in trauma outcomes studies“, *J. Pediatr. Surg.*, sv. 46, izd. 8, str. 1557–1563, 2011.
- [32] Rosén, E. i Sander, U., „Pedestrian fatality risk as a function of car impact speed“, *Accid. Anal. Prev.*, sv. 41, izd. 3, str. 536–542, svi. 2009.
- [33] Doder, N., „Stručno – znanstvena prezentacija - Nacionalni programi sigurnosti cestovnog prometa u zemljama Skandinavije“, Fakultet prometnih znanosti, Zagreb, 2011.
- [34] Brčić, D., Slavulj, M., i Ćosić, M., „Estimation of externalities of road accidents in local community“, u *VIII International Conference „Road safety in local community“*, 2013, str. 18–20.
- [35] CE Delft, „Update of the Handbook on External Costs of Transport“, *Final Report*, 2014. [Na internetu]. Dostupno na: http://ec.europa.eu/transport/themes/sustainable/studies/sustainable_en.htm.
- [36] „Republika Hrvatska - Državni zavod za statistiku“. [Na internetu]. Dostupno na: <http://www.dzs.hr/>.
- [37] Resolution of the United Nations General Assembly, „Improving global road safety - 64/225“, 2010. [Na internetu]. Dostupno na: http://www.who.int/entity/violence_injury_prevention/publications/road_traffic/UN_GA_resolution-54-255-en.pdf?ua=1.
- [38] World Health Organization, „About the UN Road Safety Collaboration“. [Na internetu]. Dostupno na: <http://www.who.int/roadsafety/about/en/>. [Pristupljeno: 21-kol-2015].
- [39] United Nations Road Safety Collaboration, „Global plan for the Decade of Action for Road Safety 2011–2020“, *Geneva: WHO*, 2011. [Na internetu]. Dostupno na: http://www.who.int/entity/roadsafety/decade_of_action/plan/plan_english.pdf?ua=1.
- [40] European Commission, „White Paper 2001 - European Transport Policy for 2010: time

- to decide“, izd. COM(2001) 370 final, str. 124, 2001.
- [41] European Commission, „European Road Safety Action Programme: Halving the number of road accident victims in the European Union by 2010: A shared responsibility“, 2003.
 - [42] European Commission, „Action Plan on Urban Mobility“, izd. COM(2009) 490 final, str. 1–12, 2009.
 - [43] European Commission, „Towards a European road safety area: policy orientations on road safety 2011-2020“, *Framework*, izd. COM(2010) 389 final, str. 1–15, 2010.
 - [44] European Commission, „White paper 2011- Roadmap to a Single European Transport Area–Towards a competitive and resource efficient transport system“, izd. COM(2011) 144 final, str. 1–31, 2011.
 - [45] Vlada Republike Hrvatske, „Nacionalni program sigurnosti cestovnog prometa Republike Hrvatske 2011.-2020. godine“, *Narodne novine d.d.*, 2011. [Na internetu]. Dostupno na: http://narodne-novine.nn.hr/clanci/sluzbeni/2011_05_59_1321.html.
 - [46] PIARC, *Road safety manual*. 2004.
 - [47] Hollnagel, E., „Understanding Accidents, or How (Not) to Learn from the Past“, 2011.
 - [48] Reason, J. T., *Managing the Risks of Organizational Accidents*, 1. izd. Ashgate Publishing Company, 1997.
 - [49] Ministarstvo unutarnjih poslova Republike Hrvatske, „Bilteni o sigurnosti cestovnog prometa 2014“. [Na internetu]. Dostupno na: http://www.mup.hr/UserDocsImages/statistika/2015/bilten_za_2014.pdf. [Pristupljeno: 31-kol-2015].
 - [50] Gradski ured za strategijsko planiranje i razvoj grada - Odjel za statistiku, „Statistički ljetopis Grada Zagreba 2014“. [Na internetu]. Dostupno na: <http://www1.zagreb.hr/zgstat/ljetopis2013.html>. [Pristupljeno: 14-kol-2015].
 - [51] European Conference of Ministers of Transport, „Past, Present and Future Road Safety Work in ECMT“, *CEMT/CM(2002)14*, 2002.
 - [52] World Health Organization, „Global Status Report on Road Safety 2013: Supporting a Decade of Action“, 2013.
 - [53] European Transport Safety Council - ETSC, „Making Walking and Cycling on Europe’s Roads Safer“, *PIN Flash* 29. [Na internetu]. Dostupno na: http://etsc.eu/wp-content/uploads/etsc_pin_flash_29_walking_cycling_safer.pdf.
 - [54] European Commission, „Road Safety 2014 - How is your country doing?“, *Reproduction*, 2015.

- [55] The European Transport Safety Council - ETSC, „9 th Road Safety Performance Index Report“. [Na internetu]. Dostupno na: http://etsc.eu/wp-content/uploads/ETSC-9th-PIN-Report_Final.pdf.
- [56] „Naslovnica | Ministarstvo unutarnjih poslova Republike Hrvatske“. [Na internetu]. Dostupno na: <https://www.mup.hr/>.
- [57] Republika Hrvatska-Ministarstvo unutarnjih poslova, „Pravilnik o načinu postupanja policijskih službenika u obavljanju poslova nadzora i upravljanja prometom na cestama“, *Narodne novine* 141/11. [Na internetu]. Dostupno na: http://narodne-novine.nn.hr/clanci/sluzbeni/2011_12_141_2831.html.
- [58] „Croatia osiguranje d.d.“ [Na internetu]. Dostupno na: <http://www.crosig.hr/hr/>. [Pristupljeno: 07-velj-2017].
- [59] Narodne novine d.d., „Zakon o policiji (NN 34/11, 130/12, 89/14, 151/14, 33/15, 121/16)“. [Na internetu]. Dostupno na: http://narodne-novine.nn.hr/clanci/sluzbeni/2011_03_34_762.html. [Pristupljeno: 28-velj-2017].
- [60] „Policijske uprave - mup.hr“. [Na internetu]. Dostupno na: <http://www.policija.hr/MainPu.aspx?id=1255>. [Pristupljeno: 28-velj-2017].
- [61] Gradski ured za strategijsko planiranje i razvoj grada - Odjel za statistiku, „Statistički ljetopis Grad Zagreba“, 2014.
- [62] Gradski ured za strategijsko planiranje i razvoj Grada, „Analiza postojećeg stanja namjene površina i urbanih gustoća 2011.“, 2013.
- [63] „Geoportal DGU“. [Na internetu]. Dostupno na: <http://geoportal.dgu.hr/>.
- [64] „OpenStreetMap Hrvatska“. [Na internetu]. Dostupno na: <http://osm-hr.org/>. [Pristupljeno: 05-lis-2016].
- [65] „Podaci osm-hr“. [Na internetu]. Dostupno na: <http://data.osm-hr.org/croatia/>. [Pristupljeno: 04-ruj-2016].
- [66] „JOSM“. [Na internetu]. Dostupno na: <https://josm.openstreetmap.de/>. [Pristupljeno: 05-lis-2016].
- [67] „OpenStreetMap“, 2014. [Na internetu]. Dostupno na: <https://www.openstreetmap.org/>. [Pristupljeno: 16-ruj-2014].
- [68] Ministarstvo pomorstva prometa i infrastrukture - MPPI, „Odluka o razvrstavanju javnih cesta“, *Nar. novine* 96/2016.
- [69] „WikiProject Croatia“. [Na internetu]. Dostupno na: http://wiki.openstreetmap.org/wiki/WikiProject_Croatia.

- [70] „Univesity of Zagreb“. [Na internetu]. Dostupno na: <http://www.unizg.hr/>. [Pristupljeno: 13-velj-2014].
- [71] „Civitas Initiative“. [Na internetu]. Dostupno na: <http://www.civitas.eu/>.
- [72] „Državni hidrometeorološki zavod - DHMZ“. [Na internetu]. Dostupno na: <http://meteo.hr/>.
- [73] Hrvatske ceste d.o.o., „Sigurnost prometa“. [Na internetu]. Dostupno na: <http://www.hrvatske-cestes.hr/default.aspx?id=60>.
- [74] CROW, *Design manual for bicycle traffic*. CROW, 2007.
- [75] Missoni, E. i Kern, J., „Fatality risk factors for bicyclists in Croatia.“, *Croat. Med. J.*, sv. 44, izd. 5, str. 610–613, 2003.
- [76] Grad Zagreb, „Izvješće o biciklističkom podsustavu unutar prometnog sustava Grada Zagreba“, 2016. [Na internetu]. Dostupno na: <http://www.zagreb.hr/default.aspx?id=96221>. [Pristupljeno: 09-stu-2016].
- [77] „Google maps“, 2017. [Na internetu]. Dostupno na: <https://maps.google.hr/>.
- [78] „Zagreb.hr - Službene stranice Grada Zagreba“. [Na internetu]. Dostupno na: <http://www.zagreb.hr/default.aspx>. [Pristupljeno: 10-kol-2015].
- [79] „Izazov - Cycling Challenge“. [Na internetu]. Dostupno na: <http://www.cyclingchallenge.eu/hr/ecc2016>.
- [80] Gledec, M. i Zajec, N., „Biciklistički promet i njegova sigurnost u RH i Gradu Zagrebu“, Hrvatska komora inženjera tehnologije prometa i transporta, Zagreb, 2012.
- [81] Ministarstvo pomorstva prometa i infrastrukture, „Pravilnik o uvjetima za projektiranje i izgradnju biciklističkih staza i traka-prijedlog“, 2013.
- [82] „PostgreSQL“. [Na internetu]. Dostupno na: <https://www.postgresql.org/>. [Pristupljeno: 15-ruj-2016].
- [83] „PostGIS“. [Na internetu]. Dostupno na: <http://www.postgis.net/>. [Pristupljeno: 17-lis-2016].
- [84] Dadić, I., Horvat, R., Ševrović, M., i Jovanović, B., „Problems and solutions in logging of traffic accidents location data“, u *XI International Symposium „Road Accidents Prevention“*, 2012, str. 67–75.
- [85] Šimunović, T. i Todić, F., „Geostatistička analiza prostorne distribucije prometnih nesreća na području Grada Zagreba u razdoblju od 2010. do 2013. godine“. Geodetski fakultet Sveučilišta u Zagrebu, 2014.

- [86] Petz, B., *Osnovne statističke metode za nematematičare*. Jastrebarsko: Naklada Slap, 2007.
- [87] „RIPCORDEREST - Road Infrastructure Safety Protection - Core Research and Development for Road Safety in Europe“. [Na internetu]. Dostupno na: http://www.transportresearch.info/Upload/Documents/201003/20100318_175819_62902_ripcorder_d06_network_safety_management.pdf.
- [88] Cerovac, V., *Tehnika i sigurnost prometa*. Zagreb: Fakultet prometnih znanosti, 2001.
- [89] Brlek, P., „Metode centralne projekcije prometne signalizacije na cestama“, Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2004.
- [90] Hrvatske ceste d.o.o., „Metodologija pristupa sigurnosti prometa“. Hrvatske ceste d.o.o., Zagreb, 2004.
- [91] Plug, C., Xia, J., i Caulfield, C., „Spatial and temporal visualisation techniques for crash analysis“, *Accid. Anal. Prev.*, sv. 43, izd. 6, str. 1937–1946, 2011.
- [92] Levine, N., „Part IV : Spatial Modeling I Chapter 10: Kernel Density Interpolation“, Washington DC, 2014.
- [93] Flahaut, B., Mouchart, M., Martin, E. S., i Thomas, I., „The local spatial autocorrelation and the kernel method for identifying black zones: A comparative approach“, *Accid. Anal. Prev.*, sv. 35, izd. 6, str. 991–1004, stu. 2003.
- [94] Al-Ghamdi, A. S., „Using logistic regression to estimate the influence of accident factors on accident severity“, *Accid. Anal. Prev.*, sv. 34, izd. 6, str. 729–741, 2002.
- [95] „IBM Knowledge Center - Logistic Regression Define Categorical Variables“. [Na internetu]. Dostupno na: http://www.ibm.com/support/knowledgecenter/SSLVMB_20.0.0/com.ibm.spss.statistics.help/idh_lreg_cat.htm. [Pristupljeno: 26-ožu-2017].
- [96] Cook, R. D. i Weisberg, S., *Residuals and Influence in Regression*. 1982.

POPIS SLIKA

Slika 1. Raspodjela ozljeda pri naletu vozila na pješaka.....	9
Slika 2. Vjerojatnost smrtnoga stradavanja pješaka pri naletu vozila brzinom od 0 do 120 km/h.....	10
Slika 3. Vjerojatnost smrtnoga stradavanja pješaka pri naletu vozila brzinom od 0 do 60 km/h.....	10
Slika 4. Čimbenici sigurnosti prometa, čovjek – vozilo – cesta (okružje).....	16
Slika 5. Povijesni razvoj modela nastanka nesreća	18
Slika 6. Odnos pojavljivanja neželjenoga događaja i posljedice	19
Slika 7. Pogreške u sustavu koji uzrokuje prometne nesreće.....	19
Slika 8. Upitnik o prometnoj nesreći, stranica 1/2	36
Slika 9. Upitnik o prometnoj nesreći, stranica 2/2	36
Slika 10. Teritorijalni ustroj policijskih uprava u Republici Hrvatskoj	40
Slika 11. Granice četvrti Grada Zagreba u GIS okružju	41
Slika 12. Centralne linije ulica s detaljnim prikazom atributa u GIS okružju	41
Slika 13. Namjena površina Generalnoga urbanističkoga plana Grada Zagreba u <i>AutoCAD</i> okružju.....	42
Slika 14. GUP Grada Zagreba, QGIS.....	44
Slika 15. Automatski brojač biciklističkoga prometa u gradu Zagrebu (totem)	44
Slika 16. Upravljački dio aplikacije brojenja prometa	45
Slika 17. Virtualne detektorske petlje na nadzornoj kameri	45
Slika 18. Georeferencirane lokacije nadzornih kamera u središtu grada Zagreba	45
Slika 19. <i>OpenStreetMap</i> karta	47
Slika 20. Lokacije brojenja prometa u Gradu Zagrebu, listopad, 2016. godina.....	48
Slika 21. Biciklističko parkiralište, Vukovarska kod FINE	51
Slika 22. Biciklističko parkiralište (ograda rampe), Vukovarska kod FINE.....	51
Slika 23. Mreža biciklističkih prometnica Grada Zagreba.....	52
Slika 24. Prijelaz biciklističke staze u zoni raskrižja Vukovarska – Miramarska cesta.....	53
Slika 25. Konflikt pješačkoga i biciklističkoga prometnoga toka (Vukovarska- Miramarska cesta).....	53
Slika 26. Diskontinuitet biciklističke staze u zoni raskrižja.....	53
Slika 27. Nedovoljna širina pješačke i biciklističke površine	54
Slika 28. Neodržavanje postojećih biciklističkih prometnica	54
Slika 29. Novoizgrađena biciklistička prometnica, Marohnićeva ulica	54

Slika 30. Novoizgrađena biciklistička prometnica, Branimirova ulica.....	54
Slika 31. Novoizgrađena biciklistička prometnica, raskrižje na Branimirovoj ulici	54
Slika 32. Karta biciklističkoga prometa u gradu Zagrebu tijekom svibnja 2016. godine	58
Slika 33. Prosječno prometno opterećenje motornoga prometa u Gradu Zagrebu u razdoblju 2012. – 2016. godine	61
Slika 34. Zapis datoteke Vozila iz 2012. godine u <i>TXT</i> formatu	64
Slika 35. Tablica prometnih nesreća nakon povezivanja s jedinstvenim ključem	65
Slika 36. Kreirane tablice u aplikaciji <i>pgAdmin III – PostgreSQL</i>	66
Slika 37. Prometne nesreće u Republici Hrvatskoj 2012. – 2014. godine, QGIS	67
Slika 38. Toplinska karta prometnih nesreća pješaka u Gradu Zagrebu tijekom 2015. godine	68
Slika 39. Toplinska karta opasnih mjesta pješaka na cestovnim prometnicama u Gradu Zagrebu.....	104
Slika 40. Toplinska karta opasnih mjesta biciklista na cestovnim prometnicama u Gradu Zagrebu, 2012.-2014.	105
Slika 41. Žarišna mjesta pješaka i biciklista na cestovnim prometnicama u Gradu Zagrebu, 2012.-2014.....	106
Slika 42. Ilica 285 (Kustošijanska)	107
Slika 43. Ilica – Domobranska	107
Slika 44. Toplinska karta prometnih nesreća pješaka – pješački prijelaz Ilica (Kustošijanska).....	108
Slika 45. Toplinska karta prometnih nesreća pješaka – zona Ilica – Selska ulica – Domobranska ulica.....	108
Slika 46. Trg žrtava fašizma – Račkoga.....	108
Slika 47. Trg žrtava fašizma – Račkoga (2D prikaz)	108
Slika 48. Vlaška – Draškovićeve – Šoštarićeve	108
Slika 49. Vlaška – Draškovićeve – Šoštarićeve (2D prikaz).....	108
Slika 50. Toplinska karta prometnih nesreća pješaka – zona Trg žrtava fašizma.....	109
Slika 51. Toplinska karta prometnih nesreća pješaka – Vlaška – Draškovićeve – Šoštarićeve	109
Slika 52. Zagrebačka avenija – Nehajska.....	109
Slika 53. Toplinska karta prometnih nesreća biciklista u zoni raskrižja Zagrebačka avenija – Nehajska	109
Slika 54. Savska cesta - spojna cesta.....	110
Slika 55. Savska cesta - spojna cesta (2D prikaz)	110
Slika 56. Vukovarska – Budmanijeva	110
Slika 57. Vukovarska - Budmanijeva (2D prikaz),	110

Slika 58. Heinzelova – Podaubskoga	110
Slika 59. Heinzelova – Podaubskoga (2D prikaz).....	110
Slika 60. Žarišna mjesta pješaka i biciklista na cestovnim prometnicama u Gradu Zagrebu, 2013.-2015.....	139
Slika 61. Žarišta prometnih nesreća pješaka 2013.-2015. u odnosu na žarišta prometnih nesreća pješaka 2012.-2014.....	140
Slika 62. Žarišta prometnih nesreća biciklista 2013. – 2015. u odnosu na žarišta prometnih nesreća biciklista 2012. – 2014.	141

POPIS GRAFIKONA

Grafikon 1. Izračun troškova cestovnih prometnih nesreća u Hrvatskoj 2010. – 2015.	12
Grafikon 2. Usporedba broja poginulih na 1 milijun stanovnika tijekom 2001. i 2014. godine	22
Grafikon 3. Broj poginulih na milijardu vozilo-km (2011. – 2014.)	23
Grafikon 4. Udio poginulih pješaka prema mjestu stradavanja u razdoblju od 2011. do 2013.	24
Grafikon 5. Udio poginulih biciklista prema mjestu stradavanja u razdoblju od 2011. do 2013.	24
Grafikon 6. Udio smrtno stradalih pješaka, biciklista, motociklista i ostalih sudionika u cestovnom prometu (prosječno od 2011. do 2013. godine)	25
Grafikon 7. Prikaz kretanja stvarnoga i očekivanoga broja poginulih osoba u cestovnom prometu za razdoblje od 2011. do 2020. godine	27
Grafikon 8. Broj prometnih nesreća s poginulim i ozlijeđenim osobama u Republici Hrvatskoj od 2010. do 2015. godine	27
Grafikon 9. Broj stradalih osoba u Republici Hrvatskoj od 2010. do 2015.	28
Grafikon 10. Prometne nesreće (sudjelovali pješaci) u Republici Hrvatskoj od 2010. do 2015.	29
Grafikon 11. Stradali pješaci u Republici Hrvatskoj od 2010. do 2015.	29
Grafikon 12. Prometne nesreće (sudjelovali biciklisti) u Republici Hrvatskoj od 2010. do 2015.	30
Grafikon 13. Stradali biciklisti u Republici Hrvatskoj od 2010. do 2015.	30
Grafikon 14. Prometne nesreće u Gradu Zagrebu od 2011. do 2015.	31
Grafikon 15. Stradale osobe u Gradu Zagrebu od 2011. do 2015.	31
Grafikon 16. Stupanj motorizacije u Republici Hrvatskoj i u Gradu Zagrebu	34
Grafikon 17. Broj uvezenih bicikala u Republiku Hrvatsku	34
Grafikon 18. Udio prometnih nesreća s policijskim očevikom i bez njega u Republici Hrvatskoj i u Gradu Zagrebu	39
Grafikon 19. Duljina biciklističkih staza i trakova po gradskim četvrtima	51
Grafikon 20. Mjesečni biciklistički promet s automatskoga brojača prometa (totem) tijekom 2015. godine	55
Grafikon 21. Količina oborina, Zagreb, listopad 2015.	55
Grafikon 22. Količina oborina, Zagreb, studeni 2015.	55
Grafikon 23. Srednja dnevna temperatura zraka u Gradu Zagrebu tijekom 2015. godine	56
Grafikon 24. Dnevni biciklistički promet s automatskoga brojača prometa u lipnju 2016. godine	57

Grafikon 25. Prosječno satno prometno opterećenje biciklističkoga prometa s automatskoga brojača prometa tijekom radnoga dana u srpnju 2015. godine	58
Grafikon 26. Satni promet bicikla u poslijepodnevnom vršnom opterećenju (2010., 2012. i 2016.)	59
Grafikon 27. Udio biciklista sa svjetlosnom opremom i bez nje tijekom 2015. i 2016. godine	60
Grafikon 28. Postotci naleta na pješaka i postoci naleta na bicikl od ukupnoga broja prometnih nesreća u Gradu Zagrebu 2012. – 2014. godine	71
Grafikon 29. Postotak lošijih vanjskih okolnosti kod prometnih nesreća naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju od 2012. do 2014. godine	84
Grafikon 30. Prometne nesreće naleta na pješaka u Gradu Zagrebu od 2012. do 2014. godine prema satima u danu (N = 1333)	86
Grafikon 31. Prometne nesreće naleta na bicikl u Gradu Zagrebu od 2012. do 2014. godine prema satima u danu (N = 443)	87
Grafikon 32. Prometne nesreće naleta na pješaka i naleta na bicikl u Gradu Zagrebu od 2012. do 2014. godine prema broju nepovoljnih prometnih okolnosti (N = 1776)	90
Grafikon 33. Prosječni broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u različitim mjesecima u godini (N = 1776)	93
Grafikon 34. Prosječni broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u različitim danima u tjednu (N = 1776)	93
Grafikon 35. Prosječni broj nepovoljnih prometnih okolnosti kod prometnih nesreća koje su evidentirane u različitim satima u danu (N = 1776)	94
Grafikon 36. Grafički prikaz korelacije između gustoće stanovništva (broj stanovnika na 1 ha) (na vodoravnoj osi) i broja prometnih nesreća naleta na pješaka i naleta na bicikl (na okomitoj osi) u Gradu Zagrebu po gradskim četvrtima – za razdoblje od 2012. do 2014. godine (N = 17)	97
Grafikon 37. Grafički prikaz korelacije između gustoće ulične mreže (dužina mreže u km / površina gradske četvrti u km ² - na vodoravnoj osi) i broja prometnih nesreća naleta na pješaka i naleta na bicikl (na okomitoj osi) u Gradu Zagrebu po gradskim četvrtima – za razdoblje od 2012. do 2014. godine (N = 17)	98
Grafikon 38. Povezanost vrste PN-a i žarišta PN-a	114
Grafikon 39. Povezanost kategorije ceste i žarišta PN-a pješaka	115
Grafikon 40. Povezanost kategorije ceste i žarišta PN-a biciklista	115
Grafikon 41. Povezanost smjernosti prometnica i žarišta PN-a pješaka	117
Grafikon 42. Povezanost smjernosti prometnica i žarišta PN-a biciklista	117
Grafikon 43. Povezanost tipa raskrižja i žarišta PN-a pješaka	118
Grafikon 44. Povezanost tipa raskrižja i žarišta PN-a biciklista	118
Grafikon 45. Povezanost regulacije prometa i žarišta PN-a pješaka	119
Grafikon 46. Povezanost regulacije prometa i žarišta PN-a biciklista	119
Grafikon 47. Povezanost ograničenja brzine i žarišta PN-a pješaka	121

Grafikon 48. Povezanost ograničenja brzine i žarišta PN-a biciklista	121
Grafikon 49. Povezanost intenziteta prometa i žarišta PN-a pješaka.....	122
Grafikon 50. Povezanost intenziteta prometa i žarišta PN-a biciklista	122
Grafikon 51. Povezanost namjene površina i žarišta PN-a pješaka	124
Grafikon 52. Povezanost namjene površina i žarišta PN-a biciklista	124
Grafikon 53. Povezanost mjeseca i žarišta PN-a pješaka.....	126
Grafikon 54. Povezanost mjeseca i žarišta PN-a biciklista	126
Grafikon 55. Povezanost biciklističke infrastrukture i žarišta PN-a biciklista	127
Grafikon 56. Promatrane i prognozirane vrijednosti – pješaci.....	134
Grafikon 57. Promatrane i prognozirane vrijednosti – bicikli.....	137

POPIS TABLICA

Tablica 1. Tipovi modela nastanka prometnih nesreća	17
Tablica 2. Podjela pokazatelja sigurnosti prometa	20
Tablica 3. Apsolutni i relativni pokazatelji sigurnosti cestovnoga prometa u Republici Hrvatskoj i u Gradu Zagrebu, 2013. godina	20
Tablica 4. Rizik od smrtnoga stradavanja po kilometru i satima za svaki način putovanja....	25
Tablica 5. Prometne nesreće u kojima su sudjelovali pješaci i ukupan broj stradalih pješaka u Gradu Zagrebu od 2011. do 2015. godine	32
Tablica 6. Prometne nesreće u kojima su sudjelovali biciklisti i ukupan broj stradalih biciklista u Gradu Zagrebu od 2011. do 2015. godine	32
Tablica 7. Slog prometnih nesreća	38
Tablica 8. Slog vozila	38
Tablica 9. Slog sudionika	38
Tablica 10. Tablični prikaz atributa u GIS bazi namjene zemljišta Grada Zagreba	43
Tablica 11. Klasifikacija cestovne mreže Grada Zagreba prilagođena OSM označavanju	47
Tablica 12. Osnovni formati svake ESRI Shape datoteke	62
Tablica 13. Osnovni formati SPSS datoteke	63
Tablica 14. Ukupan broj prometnih nesreća u Gradu Zagrebu po godinama i broj naleta na pješaka i naleta na bicikl (apsolutno i u postotcima)	70
Tablica 15. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema posljedicama (N = 1776)	71
Tablica 16. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema spolu stradalih pješaka i biciklista (u postotcima).....	72
Tablica 17. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu za razdoblje 2012. – 2014. godine prema dobi stradalih pješaka i biciklista i prema posljedicama	72
Tablica 18. Broj naleta na pješaka i naleta na bicikl u gradu Zagrebu za razdoblje 2012. – 2014. godine prema bivšim općinama (N = 1776).....	73
Tablica 19. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu za razdoblje 2012. – 2014. godine prema okolnostima (N = 1776)	74
Tablica 20. Broj naleta na pješaka i naleta na bicikl u gradu Zagrebu za razdoblje 2012. – 2014. godine prema okolnostima (N = 1776) – redoslijedom prvih 10 najučestalijih.....	75
Tablica 21. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema mjesecima (N = 1776)	76
Tablica 22. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema danima u tjednu (N = 1776)	76
Tablica 23. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema satima u danu (N = 1776)	77

Tablica 24. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema uvjetima vidljivosti (N = 1776)	77
Tablica 25. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema atmosferskim prilikama (N = 1776)	78
Tablica 26. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema uređenosti okoliša (N = 1776)	78
Tablica 27. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema funkcioniranju javne rasvjete (N = 1776).....	78
Tablica 28. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema karakteristikama ceste (N = 1776).....	79
Tablica 29. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema karakteristikama ceste (N = 1776) – poredano prema učestalosti	80
Tablica 30. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema stanju kolničkoga zastora (N = 1776).....	80
Tablica 31. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema stanju površine kolnika (N = 1776)	80
Tablica 32. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema ograničenjima brzine (N = 1776)	81
Tablica 33. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema regulaciji prometa (N = 1776)	82
Tablica 34. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema kvaliteti vertikalne signalizacije (N = 1776)	82
Tablica 35. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema kvaliteti horizontalne signalizacije (N = 1776)	82
Tablica 36. Pregled rezultata provjere pretpostavaka o obliku distribucija prometnih nesreća u Gradu Zagrebu 2012. – 2014. godine (za 1 333 naleta na pješaka i 443 naleta na bicikl).....	87
Tablica 37. Broj naleta na pješaka i naleta na bicikl u Gradu Zagrebu u razdoblju 2012. – 2014. godine prema	88
Tablica 38. Broj naleta na pješaka i naleta na bicikl u gradu Zagrebu u razdoblju 2012. – 2014. godine prema broju bodova za nepovoljne prometne okolnosti (N = 1776).....	89
Tablica 39. Rezultati testiranja važnosti razlika u prosječnom broju nepovoljnih prometnih okolnosti kod prometnih nesreća naleta na pješaka i naleta na bicikl u Gradu Zagrebu 2012. – 2014. godine (N = 1776) – t-testovi i F-testovi.....	91
Tablica 40. Rezultati testiranja važnosti razlika u broju nepovoljnih prometnih okolnosti kod prometnih nesreća naleta na pješaka i naleta na bicikl u Gradu Zagrebu 2012. – 2014. godine (N = 1776) pomoću <i>Mann-Whitneyevoga</i> U testa (za varijable s dvjema kategorijama) i <i>Kruskal-Wallisovoga</i> H testa (za varijable s trima kategorijama i s više njih)	94
Tablica 41. Osnovni podatci o gradskim četvrtima Grada Zagreba – površina, broj stanovnika i broj prometnih nesreća naleta na pješaka i naleta na bicikl u razdoblju 2012. – 2014.godine (N = 17)	96

Tablica 42. Rezultati korelacijske analize prema gradskim četvrtima	96
Tablica 43. Osnovni elementi za identifikaciju opasnih mjesta na cestama u zemljama Europe i u Hrvatskoj	101
Tablica 44. Osnovni elementi za identifikaciju opasnih dionica na cestama u zemljama Europe i u Hrvatskoj	102
Tablica 45. Kontigencijska tablica vrste PN-a i žarišta PN-a	114
Tablica 46. Hi-kvadrat test vrste PN-a i žarišta PN-a	114
Tablica 47. Kontigencijska tablica kategorije ceste i žarišta PN-a pješaka	115
Tablica 48. Kontigencijska tablica kategorija ceste i žarišta PN-a biciklista.....	115
Tablica 49. Hi-kvadrat test kategorije ceste i žarišta PN-a pješaka	115
Tablica 50. Hi-kvadrat test kategorije ceste i žarišta PN-a biciklista.....	115
Tablica 51. Kontigencijska tablica smjernosti prometnica i žarišta PN-a pješaka.....	117
Tablica 52. Kontigencijska tablica smjernosti prometnica i žarišta PN-a biciklista	117
Tablica 53. Hi-kvadrat test smjernosti prometnica i žarišta PN-a pješaka.....	117
Tablica 54. Hi-kvadrat test smjernosti prometnica i žarišta PN-a biciklista	117
Tablica 55. Kontigencijska tablica tipa raskrižja i žarišta PN-a pješaka.....	118
Tablica 56. Kontigencijska tablica tipa raskrižja i žarišta PN-a bicikala	118
Tablica 57. Hi-kvadrat test tipa raskrižja i žarišta PN-a pješaka.....	118
Tablica 58. Kontigencijska tablica regulacije prometa i žarišta PN-a pješaka	120
Tablica 59. Kontigencijska tablica regulacije prometa i žarišta PN-a biciklista.....	120
Tablica 60. Hi-kvadrat test regulacije prometa i žarišta PN-a pješaka	120
Tablica 61. Hi-kvadrat test regulacije prometa i žarišta PN-a biciklista.....	120
Tablica 62. Kontigencijska tablica ograničenja brzine i žarišta PN-a pješaka.....	121
Tablica 63. Kontigencijska tablica ograničenja brzine i žarišta PN-a biciklista	121
Tablica 64. Hi-kvadrat test ograničenja brzine i žarišta PN-a pješaka.....	121
Tablica 65. Hi-kvadrat test ograničenja brzine i žarišta PN-a biciklista	121
Tablica 66. Kontigencijska tablica intenziteta prometa i žarišta PN-a pješaka.....	123
Tablica 67. Kontigencijska tablica intenziteta prometa i žarišta PN-a biciklista.....	123
Tablica 68. Hi-kvadrat test intenziteta prometa i žarišta PN-a pješaka.....	123
Tablica 69. Hi-kvadrat test intenziteta prometa i žarišta PN-a biciklista.....	123
Tablica 70. Kontigencijska tablica namjene površina i žarišta PN-a pješaka	124
Tablica 71. Kontigencijska tablica namjene površina i žarišta PN-a biciklista	124
Tablica 72. Hi-kvadrat test namjene površina i žarišta PN-a pješaka	124
Tablica 73. Hi-kvadrat test mjeseca i žarišta PN-a pješaka	126
Tablica 74. Kontigencijska tablica mjeseca i žarišta PN-a biciklista.....	126

Tablica 75. Hi-kvadrat test mjeseca i žarišta PN-a biciklista.....	126
Tablica 76. Kontigencijska tablica biciklističke infrastrukture i žarišta PN-a biciklista	127
Tablica 77. Hi-kvadrat test biciklističke infrastrukture i žarišta PN-a biciklista	127
Tablica 78. Model identifikacije opasnih mjesta za pješački promet – prva iteracija.....	132
Tablica 79. Model identifikacije opasnih mjesta za pješački promet – druga iteracija.....	133
Tablica 80. Model identifikacije opasnih mjesta za biciklistički promet – prva iteracija.....	135
Tablica 81. Model identifikacije opasnih mjesta za biciklistički promet – druga iteracija....	136

POPIS PRILOGA

Prilog 1. Znakovnik za popunjavanje Upitnika o prometnoj nesreći, stranica 1.	166
Prilog 2. Znakovnik za popunjavanje Upitnika o prometnoj nesreći, stranica 2.	167

Prilog 1. Znakovnik za popunjavanje Upitnika o prometnoj nesreći, stranica 1.

ZNAKOVNIK ZA POPUNJAVANJE UPITNIKA O PROMETNOJ NESREĆI (UPN)			
PODACI O PROMETNOJ NESREĆI I SUDIONICIMA			
ZNAK	POSLEDJICE PROMETNE NESREĆE	ZNAK	OKOLNOSTI KOJE SU PRETHODILE
1	s poginulim osobama		GREŠKA – PROPUST VOZAČA
2	s ozlijeđenim osobama	01	nepropisna brzina
3	s materijalnom štetom	02	brzina neprimjerena uvjetima
ZNAK	VRSTA PROMETNE NESREĆE	03	vožnja na nedovoljnoj udaljenosti
	MEĐUSOBNI SUDAR VOZILA U POKRETU	04	zakašnjelo uočavanje opasnosti
01	iz suprotnih smjerova	05	nepropisno pretjecanje
02	bočni sudar	06	nepropisno obilaženje
03	usporodna vožnja	07	nepropisno mimoilaženje
04	vožnja u slijedu	08	nepropisno uključivanje u promet
05	vožnja unatrag	09	nepropisno skretanje
06	udar vozila u parkirano vozilo	10	nepropisno okretanje
08	slijetanje vozila s ceste	11	nepropisna vožnja unatrag
09	nalet na bicikl	12	nepropisno prestrojavanje
10	nalet na pješaka	13	nepoštivanje prednosti prolaska
11	nalet na motocikl ili moped	14	nepropisno parkiranje
12	sudar sa željezničkim vozilom	15	naglo usporavanje – kočenje
14	ostalo	16	nepoštivanje svjetlosnog znaka
15	udar vozila u objekt na cesti	17	neosiguran teret na vozilu
16	udar vozila u objekt kraj ceste	18	nemarno postupanje s vozilom
	NALET NA ŽIVOTINJU	19	ostale greške vozača
17	domaća životinja	20	nepropisno kretanje vozila na kolniku
18	divlja životinja		GREŠKE – PROPUSTI PJEŠAKA
19	ptica	21	nepoštivanje svjetlosnog znaka
ZNAK	OČEVID NA MJESTU DOGAĐAJA	22	nekorištenje obilježnog pješačkog prijelaza
D	da	23	nekorištenje pothodnika / nathodnika
N	ne	24	ostale greške pješaka
ZNAK	UVJETI VIDLJIVOSTI		OSTALE GREŠKE PROPUSTI
1	dan	31	neočekivana pojava opasnosti na cesti
2	noć	33	iznenadni kvar vozila
3	sumrak	ZNAK	KARAKTERISTIKE CESTE
4	svitanje		RASKRIŽJE
ZNAK	VRSTA KOLNIČKOG ZASTORA	01	T-raskrižje
1	asfalt	02	Y-raskrižje
2	beton	03	četverokrako raskrižje
3	kocka	04	kružni tok
4	makadam	05	ostalo
5	zemlja	06	čvor u više razina
ZNAK	STANJE KOLNIČKOG ZASTORA		CESTA IZVAN RASKRIŽJA I ČVORA
1	dobro	07	most
2	manja oštećenja	08	podvožnjak
3	loše	09	nadvožnjak
ZNAK	STANJE POVRŠINE KOLNIKA	10	tunel
01	suh – čist		PRIJELAZ PREKO ŽELJEZNIČKE PRUGE
02	suh – pijesak, šljunak		fizički zaštićen
03	mokar	11	otvoren
04	blato	12	zatvoren
05	snijeg – razgrnut		svjetlosna signalizacija
06	snijeg – nije razgrnut	13	ispravna
07	zaleđen – posut	14	neispravna
08	zaleđen – nije posut		nezaštićen
09	odron kamenja	15	pregledan
10	zemlja suha	16	nepregledan
11	zemlja mokra		CESTA
12	ulje i slične tvari	17	zavoj
ZNAK	REGULACIJA PROMETA	18	ravni cestovni potez
1	prometni znakovi	19	parkiralište
2	ovlaštena službena osoba	20	pješački prijelaz
3	pravila prometa	21	nogostup
	SEMAFOR	22	biciklistička staza
4	uključen u normalan režim rada	23	ostalo
5	treptavo žuto svjetlo	24	pješačka zona
6	isključen	25	zona smirenog prometa
ZNAK	JAVNA RASVJETA	ZNAK	VERTIKALNA SIGNALIZACIJA
1	javna rasvjeta u funkciji	1	dobra
2	javna rasvjeta nije u funkciji	2	oštećena
3	javne rasvjete nema	3	loša
		4	nema je

Izvor: [58]

Prilog 2. Znakovnik za popunjavanje Upitnika o prometnoj nesreći, stranica 2.

ZNAK	OKOLIŠ	ZNAK	HORIZONTALNA SIGNALIZACIJA
1	okoliš uređen	1	dobra
2	okoliš slabo održavan	2	manjkava
3	izraziti nedostaci u okolišu	3	loša
ZNAK	ATMOSFERSKE PRILIKE	4	nema je
1	vedro	ZNAK	VRSTA VOZILA
2	oblačno	21	moped
3	kiša	22	moped - tricikl
4	magla	23	motocikl
5	snijeg	24	motocikl s bočnom prikolicom
6	slana	25	motocikl - tricikl
7	ostalo	26	laki četverocikl
ZNAK	SMJER KRETANJA VOZILA	27	četverocikl
	OD - PREMA	28	osobni automobil
01	istok - zapad	30	autobus do 5000 kg i 5000 kg
02	istok - sjever	31	autobus
03	istok - jug	32	teretni automobil do 3500 kg i 3500 kg
04	zapad - istok	33	teretni automobil više od 3500 kg ali manje i = 12000 kg
05	zapad - sjever	34	teretni automobil više od 12000 kg
06	zapad - jug	35	priključno vozilo preko i jednako 750 kg
07	sjever - jug	36	prikolica do 3500 kg i jednako 3500 kg
08	sjever - istok	37	prikolica više od 3500 kg ali manje i jednako 10000 kg
09	sjever - zapad	38	prikolica preko 10000 kg
10	jug - sjever	39	traktor
11	jug - istok	40	radni stroj
12	jug - zapad	51	bicikl
ZNAK	JAVNI PRIJEVOZ	52	tramvaj
D	da	53	zaprežno vozilo
N	ne	54	vlak - željezničko vozilo
ZNAK	PRIKOLICA PRIKLJUČENA	55	laka prikolica
D	da	56	motokultivator
N	ne	61	oklopno vozilo
ZNAK	TEHNIČKI PREGLED VRIJEDI	ZNAK	SPOL SUDIONIKA
D	da	1	muško
N	ne	2	žensko
ZNAK	OSIGURANJE VRIJEDI	ZNAK	DROGA
D	da	D	da - provedeno ispitivanje
N	ne	N	ne - nije provedeno
ZNAK	PROMETNA DOZVOLA VRIJEDI	O	odbijanje ispitivanja na droge
D	da	ZNAK	GRUPA DROGE
N	ne	1	anfetamin
ZNAK	SVOJSTVO SUDIONIKA	2	mdma i derivati
1	vozač	3	benzodiazepini
2	putnik	4	barbiturati
3	pješak	5	kokain
4	jahač	6	opijati
5	gonič stoke	7	tetrahidrokanabiol
ZNAK	POSLEDICE - SUDIONICI	8	metadon
1	smrt - na mjestu događaja	9	ostale droge
2	smrt - pri prijevozu	ZNAK	LIJEKOVI
3	smrt - do 30 dana	D	da
4	ozljede teške	N	ne
5	ozljede lake	O	odbijeno utvrđivanje
6	bez ozljeda	ZNAK	UMOR
ZNAK	ALKOTESTIRANJE	D	da
D	da	N	ne
N	ne	ZNAK	BOLEST
O	odbija	D	da
ZNAK	ALKOHOL	N	ne
D	da	ZNAK	SIGURNOSNA SJEDALICA KORIŠTENA
N	ne	D	da
O	odbija	N	ne
ZNAK	ANALIZA KRV I URINA	ZNAK	KACIGA KORIŠTENA
D	da	D	da
N	ne	N	ne
O	odbija	ZNAK	OZNAKA PRIJAVE
ZNAK	MOBITEL KORIŠTEN	P	prekršajna prijava
D	da	K	kaznena prijava
N	ne	I	izvješće
ZNAK	SIGURNOSNI POJAS KORIŠTEN	N	prekršajni nalog
D	da	S	službena zabilješka
N	ne		

Izvor: [58]

POJMOVNIK

Bicikl	<i>Vozilo koje ima najmanje dva kotača i koje se pokreće isključivo snagom vozača ili koje je opremljeno pedalama i pomoćnim električnim motorom čija najveća trajna snaga nije veća od 0,25 kW i koja se progresivno smanjuje do nule kada brzina dostigne 25 km/h, ili prije ukoliko vozač prestane pokretati pedale.</i>
Biciklistička mreža	<i>Biciklistička infrastruktura primarno namijenjena biciklistima za korištenje na međunarodnoj, nacionalnoj, regionalnoj ili lokalnoj razini.</i>
Biciklistička ruta	<i>Povezan skup putanja koje pokrivaju određeno područje ili grad. Fizički se oblik rute od izvora do cilja može razlikovati. Primjerice, ruta može početi zajedničkim vođenjem bicikla s motornim vozilima na kolniku (zona 30 km/h), zatim prijeći u biciklistički trak, potom kroz biciklistički tunel proći ispod obilaznice te nastaviti kao odvojena biciklistička staza, prečicom presjeći park i na kraju proći kroz pješačku zonu i stići do odredišta.</i>
Biciklistička staza	<i>Izgrađena prometna površina namijenjena prometu bicikala koja je odvojena od kolnika i obilježena propisanim prometnim znakom.</i>
Biciklistički koridor	<i>Gravitacijski dio biciklističke rute u odgovarajućoj širini lateralne udaljenosti od središnje osi rute.</i>
Biciklistički trak	<i>Dio kolnika namijenjen prometu bicikala koji se prostire uzduž kolnika i obilježen je uzdužnom crtom na kolniku i propisanim prometnim znakom.</i>
Lakše ozlijeđena osoba	<i>osoba koja je zadobila ozljede koje su površinska oštećenja tijela (poput površinskih rana ili nagnječenja mekih tkiva, uganuća zglobova i slično), koje se većinom liječe ambulantno i ne ostavljaju trajne posljedice ni funkcionalno ni estetski.</i>
Nemotorizirani promet	<i>Kretanje pješice, biciklom te pomoću koturaljka, romobila, skateboarda, segwaya i sl.</i>
Nogostup	<i>Posebno uređena prometna površina namijenjena kretanju pješaka, koja nije u razini s kolnikom ceste ili je od kolnika odvojena na drugi način.</i>
Ozlijeđena osoba	<i>Osoba koja je u prometnoj nesreći zadobila ozljede za koje treba medicinski tretman.</i>
Pješačenje	<i>Aktivno kretanje tijela naizmjeničnim pokretanjem donjih udova, što dovodi do prenošenja tijela s jednoga mjesta na drugo.</i>
Pješačka staza	<i>Prometnica koja se vodi odvojeno od ulica, a namijenjena je pješacima. Pojam se često rabi za staze u urbanim područjima koje pješacima nude kraće i tiše rute, a također mogu pružati pristup za okolni krajolik ili za parkove.</i>
Pješak	<i>Osoba koja sudjeluje u prometu, a nije vozač niti putnik u vozilu ili na vozilu.</i>
Poginula osoba	<i>Osoba koja je poginula u prometnoj nesreći na mjestu događaja, pri prijevozu ili u roku od 30 dana od posljedica te nesreće.</i>
Prometna nesreća	<i>Događaj na cesti, izazvan kršenjem prometnih propisa, u kojem je sudjelovalo najmanje jedno vozilo u pokretu i u kojem je najmanje jedna osoba ozlijeđena ili poginula ili u roku od 30 dana preminula</i>

	<i>od posljedica te prometne nesreće ili je izazvana materijalna šteta. Nije prometna nesreća kada je radno vozilo, radni stroj, motokultivator, traktor ili zaprežno vozilo krećući se po nerazvrstanoj cesti ili pri obavljanju radova u pokretu sletjelo s nerazvrstane ceste ili se prevrnulo ili udarilo u neku prirodnu prepreku, a pritom ne sudjeluje drugo vozilo ili pješak i kada tim događajem drugoj osobi nije prouzročena šteta.</i>
Prometna nesreća s materijalnom štetom	<i>Prometna nesreća u kojoj je šteta nastala na vozilima koja su sudjelovala u prometnoj nesreći ili na objektima, prometnim znakovima, signalizaciji i opremi na cestama, a nije bilo nastradalih osoba.</i>
Prometna nesreća s nastradalim osobama	<i>Prometna nesreća u kojoj je nastradala jedna ili više osoba (bilo da se radi o poginulim ili ozlijeđenim osobama).</i>
Prometna nesreća s poginulom osobom	<i>Prometna nesreća u kojoj je poginula najmanje jedna osoba na mjestu nesreće, pri prijevozu ili u roku od 30 dana od posljedica te prometne nesreće. Prometna nesreća s ozlijeđenom osobom – prometna nesreća u kojoj je ozlijeđena jedna ili više osoba, a nema poginulih osoba.</i>
Sudionik u prometu na cesti	<i>Osoba koja na bilo koji način sudjeluje u prometu na cesti.</i>
Teško ozlijeđena osoba	<i>Osoba koja je zadobila ozljede zbog kojih je hospitalizirana dulje od 24 sata i koje ostavljaju trajne štetne posljedice. Tu spadaju prijelomi kostiju, otvorena iščašenja zglobova, ozljede mozga i ostalih organa važnih za život, teže opekline te unutarnja i vanjska krvarenja koja ugrožavaju život.</i>
GPS	<i>Globalni pozicijski sustav (engl. Global Positioning System)</i>
OSM	<i>OpenStreetMap</i>
GIS	<i>Geografski informacijski sustav (engl. Geographic Information System)</i>
SHP	<i>Format shape je vektorski zapis podataka koji služi za spremanje prostornih podataka. Razvijen je od strane tvrtke ESRI kao (većinom) otvoreni podatkovni oblik, kako bi omogućio međusobnu komunikaciju između ESRI aplikacija te ostalih GIS programa.</i>
DWG	<i>Izvorni vlasnički format dokumenta za AutoCAD</i>
TXT	<i>Format (TeXT) sadrži tekstualne podatke u obliku teksta i brojeva, prepoznaje veliki broj programa.</i>
CSV	<i>Format (comma-separated values) sadrži tablične podatke u obliku teksta i brojeva te ga prepoznaje velik broj programa.</i>

ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA

Životopis

Profesionalni status

Mario Ćosić rođen je 10. kolovoza 1980. godine u Banja Luci u Bosni i Hercegovina, gdje je završio osnovnu školu. Srednju je tehničku školu završio u Sisku. Diplomirao je 2006. godine na Fakultetu prometnih znanosti te je stekao akademski naziv diplomirani inženjer prometa. Autorom je više domaćih i međunarodnih radova iz polja tehnologije prometa i transporta te sudionikom znanstvenih i stručnih skupova. Sudjelovao je u organizaciji više znanstveno-stručnih radionica i okruglih stolova iz područja gradskoga prometa te sigurnosti cestovnoga prometa.

Kretanje u struci

Godine 2006. za vrijeme studija započinje suradnički odnos na Institutu prometa i veza, gdje je bio zaposlen do lipnja 2011. godine na radnom mjestu stručnoga suradnika. Od srpnja 2011. godine zaposlen je na Fakultetu prometnih znanosti Sveučilišta u Zagrebu, gdje je izabran u naslovno suradničko zvanje asistenta. Na Fakultetu sudjeluje u održavanju nastave iz kolegija Osnove tehnologije prometa, Osnove prometnoga inženjerstva, Inženjerska grafika i dokumentiranje, Nemotorizirani promet, Kolodvori i terminali te Sigurnost cestovnoga i gradskoga prometa. Osim izvođenja nastave aktivno sudjeluje na znanstveno-istraživačkim projektima te poslovima prometnoga planiranja i projektiranja u prometu. Sudjelovao je u izradi preko 40 prometnih studija, projekata i elaborata iz područja prometa.

Vještine

Od tehničkih vještina i kompetencija izvrsno poznaje rad u više specijalističkih i drugih programskih alata kao što su AutoCAD, QGIS te MS Office paket. Posjeduje određeni stupanj znanja i vještina potrebnih za simuliranje i modeliranje prometnih procesa u analitičko-simulacijskim programskim paketima PTV Visum/Vissim.

Popis javno objavljenih radova

Udžbenici i skripta

1. Šimunović, Ljupko; Ćosić, Mario. 2015. *Nemotorizirani promet*. Fakultet prometnih znanosti. Zagreb.

Znanstveni radovi u drugim časopisima

1. Šimunović, Ljupko; Ćosić, Mario; Kordić, Zoran. 2015. *Traffic Calming as a Contribution to Safety of Vulnerable Road Users in Urban Area*. *Suvremeni promet: časopis za pitanja teorije i prakse prometa*. 35 (2015). 3–4. 179–185. (pregledni rad, znanstveni).
2. Šimunović, Ljupko; Novačko, Luka; Ćosić, Mario. 2014. *Road Network Safety Management in the Republic of Croatia*. *Suvremeni promet: časopis za pitanja teorije i prakse prometa*. 34 (2014). 3–4. 240–244. (prethodno priopćenje, znanstveni).
3. Slavulj, Marko; Brčić, Davor; Ćosić, Mario. 2012. *Poticanje javnog gradskog putničkog prijevoza upravljanjem prijevozne potražnje*. *Suvremeni promet: časopis za pitanja teorije i prakse prometa*. Vol. 32 (2012). 5–6. 355–359. (članak, znanstveni).

Objavljena pozvana predavanja na skupovima

1. Ćosić, Mario; Šimunović, Ljupko; Brčić, Davor. 2016. *Mapping and analysing road accidents involving vulnerable road users in the City of Zagreb. Road Safety in Local Community*. Lipovac, Krsto; Nešić, Miladin (ur.). Belgrade: Academy of Criminalistic and Police Studies. 41–50. (pozvano predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
2. Brčić, Davor; Slavulj, Marko; Ćosić, Mario. 2013. *Estimation of externalities of road accidents in local community. Road safety in local community*. Lipovac, Krsto (ur.). Beograd. Kriminalističko-policijska akademija. 9–14. (pozvano predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

1. Mandžuka, Bia; Šimunović, Ljupko; Ćosić, Mario. 2015. *Intelligent Transport Systems for Smart Cities. Book of Conference Proceedings Places and Technologies 2015 – Keeping up with Technologies to Make Healthy Places*. Alenka Fikfak, Eva Vaništa Lazarević, Nataša Fikfak, Milena Vukmirović, Peter Gabrijelčič (ur.). Ljubljana. University of Ljubljana. Faculty of Architecture. 511–517. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
2. Šimunović, Ljupko; Ćosić, Mario; Klešković, Roman. 2015. *Controlled Car Parking Based on Parking Zones in the City of Zagreb – The Present and the Future. 5th International Conference "Towards a Humane City"*. Bogdanović, Vuk (ur.). Novi Sad: University of Novi Sad Faculty of Technical Sciences Department of Traffic Engineering. 317–325. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
3. Šimunović, Ljupko; Ćosić, Mario; Slavulj, Marko. 2014. *Student bicycle sharing system in Zagreb – Studocikl. Road and Rail Infrastructure III, Proceedings of the Conference CETRA 2014*. Lakušić, Stjepan (ur.). Zagreb: Department of Transportation, Faculty of

- Civil Engineering, University of Zagreb. 961-967 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
4. Šimunović, Ljupko; Ćosić, Mario; Vujčić, Tomislav. 2014. *The Impact of Bus Stop Location on Pedestrian Safety. 12th International Symposium Proceedings Road Accident Prevention 2014*. Vujanić, Milan (ur.). Novi Sad: Faculty of Technical Sciences Novi Sad. 127–135. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
 5. Šimunović, Ljupko; Novačko, Luka; Ćosić, Mario. 2014. *Personal rapid transit - A sustainable urban transport system. Proceedings of International Academic Conference on Places and Technologies 2014*. Vaništa Lazarević, E.; Krstić-Furundžić, A.; Đukić, A.; Vukmirović, M. (ur.). Belgrade: University of Belgrade – Faculty of Architecture. 1011–1019. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
 6. Brčić, Davor; Ćosić, Mario; Tepeš, Krunoslav. 2013. *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. 68–76. (međunarodna recenzija, objavljeni rad, znanstveni).
 7. Šimunović, Ljupko; Ćosić, Mario; Lazić, Ivan. 2013. *Safety of Vulnerable Road Traffic Users in Urban Area – Case Study Zagreb // Road Safety in Local Community*. Lipovac, Krsto; Nesic, Miladin (ur.). Belgrade: Academy of Criminalistic and Police Studies, Belgrade, Serbia. 109–114. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
 8. Slavulj, Marko; Ćosić, Mario; Marijanović, Katarina. 2012. *Analysis of the taxi service in the city of zagreb // Development of logistics business and transport system supported by EU funds*. Pavlin, Stanislav; Šafran, Mario (ur.). Zagreb: Fakultet prometnih znanosti. 123–130. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
 9. Slavulj, Marko; Živković, Milan; Ćosić, Mario. 2012. *Electric cars in the service of carsharing. Proceedings of the 7th International Scientific Conference on Ports and Waterways POWA 2012*. Bukljaš Skočibušić, Mihaela; Ćavar, Ivana; Vidan, Pero (ur.). Zagreb: University of Zagreb. Faculty of Transport and Traffic Sciences. (poster, međunarodna recenzija, objavljeni rad, znanstveni).
 10. Slavulj, Marko; Živković, Milan; Ćosić, Mario. 2012. *Effects of transport demand management „push” strategies in the european cities. Proceedings of the 7th International Scientific Conference on Ports and Waterways POWA 2012*. Bukljaš Skočibušić, Mihaela; Ćavar, Ivana; Vidan, Pero (ur.). Zagreb: University of Zagreb. Faculty of Transport and Traffic Sciences. (poster, međunarodna recenzija, objavljeni rad, znanstveni).
 11. Slavulj, Marko; Brčić, Davor; Ševrović, Marko; Ćosić, Mario. 2011. *Model of Traffic Safety Monitoring on the City Crossroads with Application of Conflict Diagram. Proceedings of Automation in Transportation 2011*. Šakić, Željko (ur.). Zagreb: KoREMA. 17–20. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
 12. Vidović, Krešimir; Ćosić, Mario; Županović, Dino. 2010. *Concept of Open Source Traffic Information System. Proceedings ISEP 2010*. Anžek, Mario; Hernavs, Boštjan; Kavran, Zoran; Meše, Pavel; Štern, Andrej (ur.). Ljubljana: Electrotechnical Association of Slovenia. R19-R19. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

13. Budimir, Damir; Dadić, Grgo; Ćosić, Mario. 2009. *Modeling the situation of traffic flow using the method of approximations. Transport, Maritime and Logistics Science: conference proceedings*. Zanne, Marina; Fabjan, Daša; Jenček, Peter (ur.). Portorož: Fakulteta za pomorstvo in promet. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
14. Dadić, Grgo; Budimir, Damir; Ćosić, Mario. 2009. *The impact of the introducing the system for informing drivers about traffic conditions through high technology*. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

Drugi radovi u zbornicima skupova s recenzijom

1. Šimunović, Ljupko; Slavulj, Marko; Ćosić, Mario. 2012. *Koncepcija razvoja biciklističkog prometa u Gradu Zagrebu. Ocjena dosadašnjeg prometnog razvitka Hrvatske i osnovne smjernice daljnjeg razvoja*. Steiner, Sanja; Božičević, Josip; Bukljaš Skočibušić, Mihaela (ur.). Zagreb: Hrvatska akademija znanosti i umjetnosti. 262–269. (predavanje, domaća recenzija, objavljeni rad, znanstveni).
2. Brlek, Predrag; Šoštarić, Marko; Ćosić, Mario. 2007. *Izmjena vozačeve okoline i sigurnost cestovnog prometa. Zbornik radova s 4. hrvatskog kongresa o cestama*. Cavtat-Dubrovnik: Hrvatsko društvo za ceste – VIA VITA. 119.1–119.5. (poster, međunarodna recenzija, objavljeni rad).

Druge vrste radova

1. Brčić, Davor; Šimunović, Ljupko; Slavulj, Marko; Šoštarić, Marko; Ševrović, Marko; Ćosić, Mario; Budimir, Damir; Šojat, Dino. 2016. *Vrednovanje učinaka mjera i strategija održivog transporta u gradovima*. (istraživanje).
2. Brčić, Davor; Šimunović, Ljupko; Slavulj, Marko; Šoštarić, Marko; Pilko, Hrvoje; Ćosić, Mario; Budimir, Damir; Šojat, Dino. 2015. *Vrednovanje učinaka mjera i strategija održivog transporta u gradovima*. (istraživanje).
3. Brčić, Davor; Šimunović, Ljupko; Štefančić, Gordana; Slavulj, Marko; Ćosić, Mario; Rupčić, Diana; Budimir, Damir. 2014. *Analiza funkcije javnog gradskog prijevoza u održivoj urbanoj mobilnosti*. (razvojni projekt).
4. Brčić, Davor; Šimunović, Ljupko; Štefančić, Gordana; Slavulj, Marko; Ćosić, Mario; Rupčić, Diana; Tepeš, Krunoslav. 2014. *Razvoj planova održive urbane mobilnosti*. (razvojni projekt).