



Sveučilište u Zagrebu

Geodetski fakultet

Adam Vinković

**MODELIRANJE SIGURNOSTI
BICIKLISTIČKOG PROMETA NA PODRUČJU
GRADA ZAGREBA UPOTREBOM
VIŠEPARAMETARSKE GEOVIZUALNE
ANALITIKE MNOŠTVENO PRIKUPLJENIH
PROSTORNO-VREMENSKIH PODATAKA**

DOKTORSKI RAD

Zagreb, 2026.



Sveučilište u Zagrebu

Geodetski fakultet

Adam Vinković

**MODELIRANJE SIGURNOSTI
BICIKLISTIČKOG PROMETA NA PODRUČJU
GRADA ZAGREBA UPOTREBOM
VIŠEPARAMETARSKE GEOVIZUALNE
ANALITIKE MNOŠTVENO PRIKUPLJENIH
PROSTORNO-VREMENSKIH PODATAKA**

DOKTORSKI RAD

Mentor:

prof. dr. sc. Robert Župan

Zagreb, 2026.



Sveučilište u Zagrebu

Faculty of Geodesy

Adam Vinković

**MODELING BICYCLE TRAFFIC SAFETY IN
THE CITY OF ZAGREB USING
MULTIPARAMETER GEOVISUAL
ANALYTICS OF CROWDSOURCED
SPATIOTEMPORAL DATA**

DOCTORAL DISSERTATION

Mentor:

prof. dr. sc. Robert Župan

Zagreb, 2026

SVEUČILIŠTE U ZAGREBU
GEODETSKI FAKULTET



Na temelju članka 19. Etičkog kodeksa Sveučilišta u Zagrebu i Odluke br.: 1_349_11 Fakultetskog vijeća Geodetskog fakulteta Sveučilišta u Zagrebu, od 26. 10. 2017. godine (klasa: 643-03/16-07/03), uređena je obaveza davanja „Izjave o izvornosti“ diplomskog / specijalističkog / doktorskog rada koji se vrednuju na diplomskom, specijalističkom studiju i poslijediplomskom doktorskome studiju geodezije i geoinformatike, a u svrhu potvrđivanja da je rad izvorni rezultat rada studenta te da taj rad ne sadržava druge izvore osim onih

IZJAVLJUJEM

Izjavljujem da je moj diplomski / specijalistički/ doktorski rad izvorni rezultat mog rada te da se u izradi tog rada nisam koristila drugim izvorima osim onih koji su u njemu navedeni.

Datum:

Ime i prezime:

I. AUTOR

Ime i prezime:	Adam Vinković
Datum i mjesto rođenja:	6. prosinca 1987., Vinkovci
Sadašnje zaposlenje:	Geodetski fakultet u Zagrebu

II. DOKTORSKI RAD

Naslov:	Modeliranje sigurnosti biciklističkog prometa na području Grada Zagreba upotrebom višeparametarske geovizualne analitike mnoštveno prikupljenih prostorno-vremenskih podataka
Broj stranica:	209
Broj slika:	64
Broj tablica:	30
Broj bibliografskih podataka:	127 + 11 URL-a
Ustanova i mjesto gdje je rad izrađen:	Sveučilište u Zagrebu – Geodetski fakultet
Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Geodezija
Mentor:	Prof. dr. sc. Robert Župan
Oznaka i redni broj:	---

III. OCJENA I OBRANA

Datum prihvatanja teme Odlukom Senata Sveučilišta u Zagrebu:	25. rujna 2024.
Datum sjednice Fakultetskog vijeća na kojem je doktorski rad prihvaćen:	
Sastav povjerenstva koje je ocijenilo doktorski rad:	
Datum obrane doktorskog rada:	
Sastav povjerenstva pred kojim je branjen doktorski rad:	

ZAHVALA

INFORMACIJE O MENTORU

Prof. dr. sc. Robert Župan

Sveučilište u Zagrebu

Geodetski fakultet

Zavod za kartografiju i fotogrametriju

Katedra za kartografiju

Kačićeva 26, 10000 Zagreb

robert.zupan@geof.unizg.hr

SAŽETAK

Kontinuirani rast urbanog biciklizma zahtijeva proaktivno planiranje sigurnosti i preciznu procjenu rizika. Glavni cilj ovog doktorskog istraživanja bio je ispitati mogućnost razvoja sveobuhvatnog modela sigurnosti biciklističkog prometa za Grad Zagreb, usmjerenog na predviđanje, prepoznavanje i vizualizaciju budućih opasnih lokacija, odnosno žarišta prometnih nesreća. Kako bi se prevladao tradicionalni nedostatak pouzdanih podataka o izloženosti, u istraživanju su korišteni mnoštveno prikupljeni podaci biciklističke aktivnosti s platforme Strava. Podaci biciklističke aktivnosti su, uz detaljne podatke infrastrukture, demografije i namjene zemljišta, integrirani sa skupom povijesnih podataka o prometnim nesrećama u kojima su sudjelovali biciklisti između 2018. i 2022. godine. Metodološki okvir prvotno je uspostavljen osnovnim modelom sigurnosti primjenom statističke RQC metode (Rate Quality Control), koja evaluira lokacije na temelju stopa prometnih nesreća i prometne izloženosti. Kako bi se riješila ograničenja tradicionalnih linearnih modela i obuhvatile složene prostorne međuovisnosti, primijenjeni su napredni algoritmi nadziranog strojnog učenja, uključujući slučajne šume (Random Forest), XGBoost (eXtreme Gradient Boosting) i Metodu potpornih vektora (Support Vector Machine), za višeklasnu klasifikaciju razina sigurnosti na mreži od 11374 križanja. Komparativna analiza pokazala je da je algoritam slučajnih šuma ostvario najbolji rezultat u obradi izrazito neuravnoteženih prostornih podataka, bilježeći ukupnu točnost od 88 %, uz najviši odziv (0,694) i F_2 -mjeru (0,698) za kritičnu klasu žarišta. Za interpretaciju algoritama strojnog učenja primijenjena je SHAP (SHapley Additive exPlanations) metoda, temeljena na teoriji kooperativnih igara, kako bi se precizno kvantificirao lokalni i globalni granični doprinos svake varijable. SHAP analiza otkrila je nelinearne pragove čimbenika rizika te empirijski potvrdila fenomen "sigurnosti u brojevima" u Zagrebu. Rezultati su dokazali da izolirani biciklistički promet niskog intenziteta znatno povećava rizik od nastanka žarišta, dok veća biciklistička izloženost djeluje zaštitno i odmiče predikciju modela od klase najvišeg rizika. Zaključno, ovo istraživanje uspješno potvrđuje glavne hipoteze, dokazujući da integracija mnoštveno prikupljenih podataka prostorno-vremenskih podataka i strojnog učenja pruža izrazito pouzdan prediktivni alat. Predloženi proces modeliranja pomiče planiranje urbane prometne sigurnosti s reaktivnog ublažavanja dokumentiranih nesreća prema strategiji proaktivnog predviđanja i prevencije, čime izravno doprinosi donošenju odluka temeljenih na podacima te razvoju sigurnije i održivije biciklističke infrastrukture.

Ključne riječi: sigurnost biciklističkog prometa, MPP, Strava, strojno učenje, Random Forest, SHAP, sigurnost u brojevima, prostorno-vremenska analiza, Grad Zagreb.

ABSTRACT

The continuous growth of urban cycling demands proactive safety planning and accurate risk assessment. The main objective of this doctoral research was to examine the possibility of developing a comprehensive bicycle traffic safety model for the City of Zagreb, aimed at predicting, identifying, and visualizing future hazardous locations or hotspots. To overcome the traditional lack of reliable exposure data, the research utilized crowdsourced bicycle activity data from the Strava platform, integrating it with a dataset of historical crashes data involving cyclists between 2018 and 2022, alongside detailed infrastructure, land-use, and demographic variables. The methodological framework initially established a base safety model using the statistical Rate Quality Control (RQC) method, which evaluates locations based on crash rates and traffic exposure. To address the limitations of traditional linear models and capture complex spatial correlations, advanced supervised machine learning algorithms, including Random Forest (RF), XGBoost, and Support Vector Machine (SVM), were employed for the multi-class classification of safety levels across 11,374 crossings. The comparative evaluation demonstrated that the RF algorithm achieved superior performance in handling highly imbalanced spatial data, recording an overall accuracy of 88%, with the highest recall (0.694) and F2-score (0.698) for the critical hotspot class. To interpret the machine learning "black box," the SHAP (SHapley Additive exPlanations) method, based on cooperative game theory, was applied to exactly quantify the local and global marginal contribution of each variable. The SHAP analysis revealed the non-linear thresholds of risk factors and empirically validated the "Safety in Numbers" (SiN) phenomenon in Zagreb. The results proved that isolated and low-volume bicycle traffic significantly increases the risk of hotspot formation, whereas higher bicycle exposure acts protectively and pulls the model's prediction away from the highest risk class. In conclusion, this research successfully confirms the main hypotheses, demonstrating that the integration of crowdsourced spatiotemporal data with machine learning provides a highly reliable predictive tool. This novel modeling process shifts urban traffic safety planning from a reactive mitigation of documented crashes to a proactive prediction and prevention strategy, thereby directly contributing to data-driven decision-making and the development of safer, more sustainable cycling infrastructure.

Keywords: Bicycle traffic safety, crowdsourced data, Strava, machine learning, Random Forest, SHAP, Safety in Numbers, spatio-temporal analysis, City of Zagreb.

SADRŽAJ

SAŽETAK.....	I
ABSTRACT	III
SADRŽAJ	IV
POPIS TABLICA.....	VI
POPIS SLIKA	IX
1. UVOD	1
2. PREGLED LITERATURE	7
2.1 Podaci biciklističkog prometa.....	7
2.1.1 Mjerenje i procjena volumena biciklističkog prometa	10
2.1.2 Prostorna analiza biciklističke mreže i prometna sigurnost.....	11
2.2 Strava.....	14
2.2.1 Modeliranje volumena biciklističkog prometa.....	16
2.3 Sigurnost biciklističkog prometa	17
2.4 Modeliranje prometnih nesreća	21
2.5 Strojno učenje u kontekstu prostornih podataka prometa	29
2.6 Sinteza literature i pregled istraživačkih prilika	32
3. PODRUČJE ISTRAŽIVANJA, PRIKUPLJANJE I OBRADA PODATAKA	39
3.1 Područje obuhvata i vremenski okvir istraživanja.....	39
3.2 Prikupljanje i obrada podataka biciklističke aktivnosti.....	40
3.2.1 Podaci biciklističke Strava aktivnosti	40
3.2.2 Automatski brojač	45
3.2.3 Kratkotrajno ručno brojanje	47
3.3 Prikupljanje i obrada podataka prometnih nesreća u kojima su sudjelovali biciklisti 48	
3.4 Prikupljanje i obrada ostalih podataka istraživanja.....	54
3.4.1 Administrativne granice	54
3.4.2 Infrastrukturni podaci	54
3.4.3 Demografski podaci	59
3.4.4 Podaci uporabe zemljišta i izgrađenog okoliša.....	59
3.4.5 Meteorološki podaci.....	59

4.	MODELIRANJE VOLUMENA BIKIKLISTIČKOG PROMETA.....	61
4.1	Statistika godišnje i mjesečne Strava aktivnosti.....	61
4.2	Prostorno-vremenska analiza Strava aktivnosti.....	66
4.2.1	Makro-lokacijska prostorna analiza Strava aktivnosti.....	74
4.3	Statistička analiza automatskog brojača i usporedba sa Strava aktivnosti	79
4.4	Analiza kratkotrajnog brojanja.....	85
4.5	Računanje prosječnog godišnjeg dnevnog biciklističkog prometa (PGDBP)	87
5.	MODELIRANJE PROMETNIH NESREĆA	93
5.1	Vremenska analiza prometnih nesreća.....	93
5.2	Prostorna analiza prometnih nesreća.....	97
5.3	Analiza demografskih pokazatelja i posljedica prometnih nesreća	105
5.4	Sigurnost u brojevima	107
6.	IDENTIFIKACIJA ŽARIŠTA PROMETNIH NESREĆA.....	110
6.1	Definiranje i obrada podataka područja statističkog ispitivanja	110
6.2	Izrada baznog modela sigurnosti prilagođenom RQC metodom	113
7.	MODELIRANJE SIGURNOSTI BIKIKLISTIČKOG PROMETA PRIMJENOM METODA STROJNOG UČENJA	119
7.1	Metodologija modeliranja	119
7.2	Priprema prostorne matrice opažanja i selekcija varijabli	120
7.3	Podešavanje hiperparametara i kalibracija modela	126
7.4	Rezultati modeliranja i evaluacija modela	127
7.5	Interpretacija rezultata.....	132
8.	ZAKLJUČAK	142
	LITERATURA	145
	PRILOZI	157
	ŽIVOTOPIS	209

POPIS TABLICA

Tablica 1. Pregled glavnih kategorija i metoda strojnog učenja.....	30
Tablica 2. Pregled najznačajnijih istraživanja iz područja podataka biciklističkog prometa	32
Tablica 3. Pregled najznačajnijih istraživanja u kojima su Strava podaci glavni izvor podataka	33
Tablica 4. Pregled najznačajnijih istraživanja sigurnosti biciklističkog prometa i modeliranja PN-a	36
Tablica 5. Popis lokacija kratkotrajnog brojanja biciklističkog prometa	47
Tablica 6. Biciklistička prometnice na području istraživanja	55
Tablica 7. Cestovna infrastruktura na području istraživanja	58
Tablica 8. Ukupna godišnja Strava aktivnost u razdoblju od 2019. do 2023. godine.	61
Tablica 9. Statistika ukupne Strava aktivnosti po svim segmentima mreže	62
Tablica 10. Statistika ukupne utilitarne i rekreativne Strava aktivnosti po svim segmentima mreže	63
Tablica 11. Broj korisnika Strave po mjesecima u razdoblju od 2019. do 2023.	66
Tablica 12. Ukupan broj prolaza na automatskog brojaču i usporedba sa Strava aktivnosti na segmentu brojača na godišnjoj razini	79
Tablica 13. Koeficijenti korelacije dnevnih podataka automatskog brojača i Strave	84
Tablica 14. Računanje PGDBP-a za 2021.godinu na lokacijama kratkotrajnog brojanja.....	89
Tablica 15. Usporedba izračunatih vrijednosti PGDBP-a i procijenjenih vrijednosti PGDBP-a iz podataka Strave za lokacije kratkotrajnog brojanja	91
Tablica 16. PN-e po PPP-i za pojedinu godinu razdoblja istraživanja	93
Tablica 17. PN-e po mjesecima u godini za pojedinu godinu razdoblja istraživanja	94
Tablica 18. PN-e prema danu u tjednu za pojedinu godinu razdoblja istraživanja	96
Tablica 19. PN-e prema vremenu u danu za pojedini dan u tjednu	96
Tablica 20. PN-e po GC-ima Grada Zagreba za pojedinu godinu	99
Tablica 21. PN-e po jedinici površine GC-i Grada Zagreba za pojedinu godinu.....	101
Tablica 22. PN-e prema starosti sudionika	106
Tablica 23. PN-e prema posljedicama za sudionike (I. Postaja PP-e).....	106
Tablica 24. PN-e prema posljedicama za sudionike (II. Postaja PP-e)	106
Tablica 25. Usporedba SiN efekta na biciklističkoj infrastrukturi, oko nje i na ostatku mreže .	108
Tablica 26. Statistički pokazatelji vrijednosti dobivenih RQC metodom za križanja koja imaju zabilježenu PN-u	116
Tablica 27. Klasifikacijski sustav sigurnosti križanja prema omjeru stope PN-a i kritične razine nastanka PN-e.....	117

Tablica 28. Deskriptivni statistički pokazatelji skupa podataka za sva križanja ($n = 11374$)	123
Tablica 29. Popis svih testiranih hiperparametara u procesu optimizacije.....	126
Tablica 30. Komparativna analiza evaluacije rezultata pojedinog modela na testnom skupu podataka.....	128

POPIS SLIKA

Slika 1. Strava Metro sučelje s mogućnošću pretrage, filtriranja i pregleda podataka na karti ...	42
Slika 2. Stalni automatski brojač biciklističkog prometa u Ulici grada Vukovara	46
Slika 3. Karta lokacija kratkotrajnog ručnog brojanja i automatskog brojača prometa.....	48
Slika 4. Prometne nesreće u kojima su sudjelovali biciklisti za razdoblje 2018.-2022.	53
Slika 5. Tip biciklističke prometnice: a) BP, b) BT, c) CM, d) PB	57
Slika 6. Ukupna godišnja Strava aktivnost u razdoblju od 2019. do 2023.	62
Slika 7. Ukupna Strava aktivnost po mjesecima.....	64
Slika 8. Ukupna utilitarna i rekreativna Strava aktivnost po mjesecima	64
Slika 9. Broj aktivnosti prema vrsti po mjesečnom udjelu i broj korisnika po mjesecima.....	65
Slika 10. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2019.	67
Slika 11. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2020.	68
Slika 12. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2021.....	69
Slika 13. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2022.	70
Slika 14. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2019.	71
Slika 15. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2020.....	71
Slika 16. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2021.	72
Slika 17. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2022.	72
Slika 18. Prosječna godišnja Strava aktivnosti po linijskom segmentu mreže za područje MO-a	75
Slika 19. Prosječna godišnja rekreativna Strava aktivnosti po linijskom segmentu mreže za područje MO-a.....	77
Slika 20. Prosječna godišnja utilitarna Strava aktivnosti po linijskom segmentu mreže za područje MO-a.....	78
Slika 21. Usporedba ukupnog broja prolaza na automatskom brojaču i aktivnosti na Strava segmentu brojača	80
Slika 22. Odnos ukupnog broja prolaza na automatskom brojača i ukupne aktivnosti na Strava segmentu u 2019. prikazan 7-dnevnom trend linijom	81
Slika 23. Odnos ukupnog broja prolaza na automatskom brojača i ukupne aktivnosti na Strava segmentu u 2020. prikazan 7-dnevnom trend linijom	82
Slika 24. Odnos ukupnog broja prolaza na automatskom brojača i ukupne aktivnosti na Strava segmentu u 2021. prikazan 7-dnevnom trend linijom	83
Slika 25. Odnos ukupnog broja prolaza na automatskom brojača i ukupne aktivnosti na Strava segmentu u 2022. prikazan 7-dnevnom trend linijom.....	83

Slika 26. Ukupno biciklista na lokacijama kratkotrajnog brojanja u jutarnjim i popodnevnm vršnim satima	86
Slika 27. Udio muških i ženskih biciklista na lokacijama kratkotrajnog brojanja u jutarnjim i popodnevnm vršnim satima	87
Slika 28. Izračunati PGDBP po linijskom segmentu mreže za cjelokupno područje istraživanja	92
Slika 29. Ukupno PN-a po mjesecima za cjelokupno razdoblje istraživanja	94
Slika 30. Prikaz PN-a po mjesecima u godini i ukupno po mjesecima za sve godine	95
Slika 31. Prikaz PN-a po danima u tjednu po pojednoj godini i ukupno za sve godine	96
Slika 32. Karta PN-a ovisno o radnom danu ili vikendu	98
Slika 33. Karta PN-a po MO-ima Grada Zagreb za cjelokupni period istraživanja	100
Slika 34. Karta PN-a na 10000 stanovnika po MO-ima i GC-ima Grada Zagreb	102
Slika 35. Karta ukupnog broja PN-a izrađena KDE metodom.....	103
Slika 36. Karta PN-a prema količini padalina	104
Slika 37. Proces ekstrakcije križanja iz podataka cestovne infrastrukture.....	112
Slika 38. Model sigurnosti biciklističkog prometa izrađen RQC metodologijom s prikazom lokacija žarišta PN-a.....	118
Slika 39. Matrica korelacije svih varijabli objedinjenog skupa podataka križanja	122
Slika 40. Usporedba matrica konfuzije izračunatih modela	129
Slika 41. PR krivulja za klasu žarišta	130
Slika 42. Karta kontinuiranog indeksa opasnosti za cjelokupno područje istraživanja.....	131
Slika 43. Mjera značajnosti varijabli (Gini impurity).....	132
Slika 44. Sažeti prikaz utjecaja SHAP vrijednosti na klasu žarišta	134
Slika 45. SHAP ovisnost varijable 'DZS_MO_Gust_st-km2' na klasu žarišta	138
Slika 46. SHAP ovisnost varijable 'OSM_road_COUNT' na klasu žarišta	138
Slika 47. SHAP ovisnost varijable 'OSM_road_LENGTH' na klasu žarišta	138
Slika 48. SHAP ovisnost varijable 'OSM_junctionCount_weighted' na klasu žarišta	138
Slika 49. SHAP ovisnost varijable '2019-2022_U-R' na klasu žarišta	138
Slika 50. SHAP ovisnost varijable '2019-2022_tot_trips_sum' na klasu žarišta	138
Slika 51. SHAP ovisnost varijable 'OSM_crossing' na klasu žarišta	139
Slika 52. SHAP ovisnost varijable 'Qj' na klasu žarišta	139
Slika 53. SHAP ovisnost varijable 'bicInfra_COUNT' na klasu žarišta.....	139
Slika 54. SHAP ovisnost varijable 'ZG_uporaba_StamMjes_pc' na klasu žarišta	139
Slika 55. SHAP ovisnost varijable 'ZG_uporaba_PoljVodeSume_pc' na klasu žarišta	139
Slika 56. SHAP ovisnost varijable 'DZS_MO_Ukupno' na klasu žarišta	139

Slika 57. SHAP ovisnost varijable 'ZG_uporaba_JavnDrus_pc' na klasu žarišta.....	140
Slika 58. SHAP ovisnost varijable 'bicInfra_LENGTH' na klasu žarišta	140
Slika 59. SHAP ovisnost varijable 'ZG_uporaba_JavnZeLeSprt_pc' na klasu žarišta	140
Slika 60. SHAP ovisnost varijable 'bic-road_infraRatio' na klasu žarišta	140
Slika 61. SHAP ovisnost varijable 'ZG_uporaba_Gosp_pc' na klasu žarišta	140
Slika 62. SHAP ovisnost varijable 'OSM_trafficSignal' na klasu žarišta	140
Slika 63. SHAP ovisnost varijable 'ZG_tramStajaliste' na klasu žarišta.....	141
Slika 64. SHAP ovisnost varijable 'bicInfra_kategorija_id_num_O' na klasu žarišta	141

1. UVOD

Promicanje aktivnih načina prijevoza (mobilnosti), koji uključuju tjelesnu aktivnost poput hodanja i vožnje bicikla, ključno je za ublažavanje negativnih posljedica urbanizacije, uključujući prometne gužve, degradaciju okoliša i javnozdravstvene krize. Unatoč dokumentiranim prednostima tzv. aktivne mobilnosti, donošenje utemeljenih odluka dosad je bilo otežano zbog nedovoljno opsežnih podataka o obrascima nemotoriziranog prometa. Nemotorizirani promet odnosi se na svaki način prijevoza koji uključuje fizičku aktivnost za dio puta ili cjelokupno putovanje, uključujući hodaње i bicikliranje. Zbog iznimnih prednosti dobiva na sve većoj važnosti, a u odnosu na motorizirani promet je dužinom puta kraći te osjetljiviji na promjene u okolišu (Lee i Sener, 2020). Vožnja bicikla, koju kolokvijalno nazivamo i bicikliranje, aktivnost je koja predstavlja zdravu, ekonomičnu i za okoliš prihvatljivu alternativu motoriziranom prometu. Bicikliranje, kao oblik aktivnog prijevoza, potiče fizičku i mentalnu aktivnost te time može pridonijeti smanjenju kroničnih bolesti koje uzrokuju najveći broj smrti u svijetu. U odnosu na motorizirana prometna sredstva, korištenje bicikla znatno je financijski pristupačnije, omogućuje manju potrošnju fosilnih goriva, smanjuje emisiju stakleničkih plinova, te smanjuje prometne gužve u urbanim sredinama i time poboljšava kvalitetu zraka (National Cooperative Highway Research Program – NCHRP, 2019).

U urbanim sredinama je posljednjih nekoliko godina zabilježen sve veći broj biciklista što je djelomično uzrokovano pandemijom koronavirusa (Büchel i dr., 2022). Svijest o klimatskim promjenama i potrebi za češćom fizičkom aktivnošću uslijed sjedilačkog načina života, također su čimbenici koji utječu na sve veći broj biciklista u prometu, ne samo u Republici Hrvatskoj, već u čitavom svijetu. Može se reći da globalno postoji svijest o potrebi za promjenama u načinu života zbog čega su Ujedinjeni Narodi (UN), u suradnji sa svim članicama, donijeli rezoluciju (United Nations, 2017) koja uključuje 17 strateških ciljeva održivog razvoja (engl. Sustainable Development Goals – SDG) kao osnovu za poboljšanje ljudskog života i očuvanje okoliša. Bicikliranje je povezano s nekoliko UN-ovih ciljeva održivog razvoja, posebno u kontekstu promicanja održivih gradova (SDG 11), zdravijih životnih stilova (SDG 3) i smanjenja emisija stakleničkih plinova (SDG 7 i 13). U želji da se poveća sigurnost prometa, a time i broj biciklista na cestama, mnoge gradske vlasti ulažu značajna sredstva u planiranje i izgradnju infrastrukture za bicikliste.

No, postavlja se pitanje na koji način nadzirati, mjeriti i analizirati biciklistički promet kao i učinak novoizgrađene infrastrukture kojim bi se opravdala financijska ulaganja u biciklističku infrastrukturu. U tu svrhu potrebno je raspolagati podacima o broju biciklista, odnosno broju

vožnji koji se odvija na pojedinom području. Takvi podaci o volumenu prometa neophodni su za provođenje studija sigurnosti (Sanders i dr., 2017) i izvještavanje o korištenju infrastrukture (Hong i dr., 2020). Uz to, informacija o količini biciklističkog prometa, odnosno prometnom toku, na određenom području ključna je za određivanje mjere izloženosti (engl. *exposure*), koju se može definirati kao „*broj prometnih situacija u kojima postoji razuman slijed događaja koji bi mogao dovesti do sudara među sudionicima u prometu*“ (Nordback i dr., 2014). Stoga treba uzeti u obzir da veći broj aktivnih sudionika u biciklističkom prometu, kao i veći broj prometnih nesreća na lokacijama većeg prometnog toka, ne mora uvijek nužno predstavljati i veću opasnost.

Kako bi se premostio nedostatak pouzdanih podataka o izloženosti, suvremena literatura snažno naglašava prijelaz s radno intenzivnih tradicionalnih metoda brojanja na analizu digitalnih tragova kretanja upotrebom mnoštveno prikupljenih podataka (MPP). Zahvaljujući globalnim navigacijskim satelitskim sustavima (GNSS) i širokoj dostupnosti pametnih mobilnih uređaja, pojedinci danas dobrovoljno sudjeluju u prikupljanju ogromnih količina prostornih podataka putem mobilnih aplikacija za praćenje aktivnosti. Ovaj proces oslanja se na izdvajanje zadataka velikoj skupini nepovezanih sudionika, čime se dobiva prostorno-vremenska pokrivenost bez presedana, pri čemu se aplikacija Strava ističe kao jedan od najsnažnijih prediktora volumena biciklističkih vožnji u urbanim sredinama (Dadashova i dr., 2020a). Takvi podaci omogućuju tranziciju u modeliranju prometne sigurnosti s oslanjanja na apsolutne pokazatelje, koji su često pristrani prema visokofrekventnim lokacijama (Wang i dr., 2018), prema relativnim pokazateljima poput gustoće prometnih nesreća koji normaliziraju izloženost i pružaju objektivniju sliku sigurnosnog stanja. Iako MPP-i iz platforme Strava posjeduju izniman potencijal za integraciju s tradicionalnim metodama mjerenja biciklističkog prometa, pitanje njihove reprezentativnosti i dalje predstavlja jedno od ključnih metodoloških ograničenja (Basiri i dr., 2019; Broach i dr., 2023). Unatoč tome, upotreba Strava podataka znatno je unaprijedila preciznost procjene prijevozne potražnje (Lee i Sener, 2021), identifikacije prostorno-vremenskih obrazaca kretanja (Brauer i dr., 2021), evaluacije infrastrukture i određivanja izloženosti biciklističkim nesrećama (Sener i dr., 2021).

Shodno tome, suvremeno upravljanje prometom doživljava transformaciju prelaskom s tradicionalnih, reaktivnih matematičkih metoda koje promatraju nesreće samo kao rijetke i nasumične događaje disperzirane u prostoru, prema proaktivnim prediktivnim modelima temeljenima na metodama strojnog učenja. Znanstveno utemeljenje ovoga rada počiva na spoznaji da se sigurnost prometa ne može cjelovito razumjeti ni unaprijediti bez sagledavanja kompleksnih interakcija između prometne infrastrukture, izgrađenog okoliša i ponašanja sudionika, uz obavezno uzimanje u obzir izloženosti biciklista riziku. Prilikom analize i

predikcije čimbenika koji doprinose učestalosti i težini PN-a, nužno je identificirati skrivene korelacije između događaja na mreži i širokog spektra vanjskih uvjeta. Ti se čimbenici sustavno kategoriziraju u nekoliko ključnih domena, koje obuhvaćaju fizičke karakteristike cestovne infrastrukture, geografske i meteorološke uvjete, intenzitet i dinamiku kretanja prometnog toka, prostorni kontekst uporabe zemljišta i izgrađenog okoliša, sociodemografsku strukturu stanovništva te specifične temporalne obrasce vršnih opterećenja i sezonalnosti. Unatoč tehnološkom napretku, glavni problem u dosadašnjim istraživanjima sigurnosti prometa predstavlja kronični nedostatak podataka koji bi pouzdano kvantificirali upravo navedenu mjeru izloženosti (Vanparijs i dr., 2015). Većina dosadašnjih sigurnosnih studija i operativnih praksi oslanjala se gotovo isključivo na evidenciju povijesnih podataka prometnih nesreća, što onemogućuje preciznu interpretaciju rizika (Ferster i dr., 2021). U nacionalnim i lokalnim okvirima, dodatni izazov predstavlja fenomen nedovoljnog prijavljivanja nezgoda (incidenata) s lakšim posljedicama ili materijalnom štetom. Veći broj studija pokazuje da službene baze nesreća obuhvaćaju tek oko 20 % svih stvarnih incidenata, što znatno ograničava preciznost sigurnosnih procjena (Fischer i dr., 2020). Nadalje, međunarodni pregledi jasno ukazuju na značajan nedostatak konsenzusa u definiranju opasnih mjesta za bicikliste, pri čemu institucije i dalje pretežno primjenjuju isključivo reaktivni kriterij apsolutne učestalosti sudara, potpuno zanemarujući širi urbanistički i infrastrukturni kontekst lokacije (Sajed i dr., 2019).

Iz navedenih ograničenja proizlazi niz iznimno važnih istraživačkih prilika. Za područje Grada Zagreba trenutačno ne postoji cjelovit ni sustavno razvijen model sigurnosti biciklističkog prometa. Podaci o volumenu biciklističkog prometa izrazito su oskudni; na razini cijeloga grada postoji tek jedan stalni automatski brojač biciklističkog prometa, uz oslanjanje na rijetka kratkotrajna ručna brojanja, poput onih provedenih u akademske svrhe. Posljedično, nova se biciklistička infrastruktura nerijetko projektira i gradi bez temeljitih analiza isplativosti te bez provođenja situacijskih analiza stanja sigurnosti i protočnosti prije i poslije implementacije infrastrukturnih rješenja. Nadalje, dosad nije provedena sustavna prostorna ni vremenska analiza nesreća u kojima su sudjelovali biciklisti, a postojeći policijski podaci isporučuju se isključivo u tabličnom obliku te nisu jedinstveni za cijeli grad. U kontekstu identifikacije opasnih mjesta, u struci ne postoji jasno definirana klasifikacija žarišta prilagođena specifičnostima biciklističkog prometa, a dosadašnje metode prostorne analize opasnih mjesta pretežno su bile bazirane isključivo na jednostavnoj učestalosti nesreća (Yiannakoulis i dr., 2012). Takva situacija stvara idealnu istraživačku priliku za primjenu statističke RQC (engl. Rate Quality Control) metode, koja računanjem stope nesreća uzima u obzir prometnu izloženost, čime služi kao visokokvalitetna osnova (bazni model) za usporedbu s prediktivnim metodama. Istovremeno, u praksi prometnog inženjerstva na ovom području dosad nije korišteno strojno

učenje za identifikaciju i klasifikaciju žarišta nesreća, što otvara ogroman potencijal za integraciju geoinformatike, umjetne inteligencije, prometnog inženjerstva i urbanizma.

Cilj rada je ispitati mogućnost dobivanja modela sigurnosti biciklističkog prometa za promatrano razdoblje na području Grada Zagreba na čemu se temelji predikcija za buduću sigurnost u biciklističkom prometu.

Hipoteze istraživanja su:

- 1) Prostorno-vremenskom geovizualnom analizom mnoštveno prikupljenih podataka biciklističkog prometa i podataka prometnih nesreća u kojima su sudjelovali biciklisti moguće je izraditi model sigurnosti biciklističkog prometa.
- 2) Model sigurnosti biciklističkog prometa može se koristiti za identifikaciju, predikciju i vizualizaciju opasnih mjesta za biciklistički promet.

Očekivani znanstveni doprinos predloženog istraživanja očituje se prvenstveno kroz postavljanje novog procesa modeliranja sigurnosti biciklističkog prometa upotrebom i analizom mnoštveno prikupljenih podataka u kombinaciji s podacima prometnih nesreća te ostalim vanjskim čimbenicima koji utječu na promet u cjelini. Samim time, drugi element doprinosa jest izrada potpuno novog modela sigurnosti za dio Grada Zagreba. Takav novi način modeliranja omogućit će ranu predikciju opasnih mjesta, odnosno takozvanih žarišnih točaka. Konačno, izradom predloženog modela značajno će se povećati razumijevanje biciklističke aktivnosti na području Grada Zagreba u cjelini, a posebno u kontekstu čimbenika koji pozitivno ili negativno utječu na sigurnost, što će u konačnici izravno pridonijeti kvalitetnijem donošenju odluka prilikom projektiranja i razvoja sigurnije infrastrukture za bicikliste.

Doktorski rad strukturiran je u osam povezanih cjelina koje logički prate metodološki tijek analize i izrade modela. U uvodnom poglavlju se daje uvod u problematiku teme istraživanja, znanstveno utemeljenje te se obrazlaže opravdanost istraživanja. Drugo poglavlje obuhvaća iscrpan pregled postojeće znanstvene literature, stavljajući fokus na metode prikupljanja podataka, koncept izloženosti te suvremene pristupe analizi i modeliranju sigurnosti biciklističkog prometa. Treće poglavlje detaljno obrazlaže izvore i postupke prikupljanja, obrade te objedinjavanja heterogenih prostornih i atributnih skupova podataka, uključujući Strava aktivnosti, podatke automatskog brojača prometa i podatke prometnih nesreća. U četvrtom poglavlju provodi se prostorno-vremensko modeliranje biciklističke aktivnosti i složeni izračun volumena prometa na cjelokupnoj mreži. Peto poglavlje posvećeno je opsežnoj prostorno-vremenskoj analizi prometnih nesreća, analizi vanjskih čimbenika koji utječu na nastanak prometnih nesreća te empirijskoj provjeri fenomena sigurnosti u brojevima. U šestom poglavlju

primjenjuje se statistička metoda za identifikaciju opasnih mjesta na cestama, čime se formira referentni bazni model. Sedmo poglavlje demonstrira primjenu metoda strojnog učenja za predikciju sigurnosti biciklističkog prometa te uključuje naprednu interpretaciju utjecaja pojedinih okolišnih i infrastrukturnih čimbenika. Rad se zaključuje osmim poglavljem koje donosi sintezu svih rezultata, raspravu o postavljenim hipotezama i završna razmatranja s preporukama za buduća istraživanja.

2. PREGLED LITERATURE

2.1 Podaci biciklističkog prometa

U kontekstu motoriziranog prometa razvijen je značajan broj metoda za prikupljanje i analizu prometnog toka (Nordback i dr., 2013), dok se brojanje biciklističkog prometa uobičajeno izvodi kratkotrajnim ručnim (manualnim) brojanjem za vrijeme vršnih sati, postavljanjem uređaja (npr. induktivne petlje, pneumatske cijevi i pasivni infracrveni senzori) za automatsko (kontinuirano) brojanje prometa na ključnim točkama prometne mreže ili anketama. Takvim tradicionalnim metodama prikupljanja podataka mogu se dobiti iznimno točni i detaljni podaci biciklističkog prometnog toka u svrhu planiranja biciklističkog prometa. U slučaju kratkotrajnog ručnog brojanja mogu se dobiti podaci čak do razine obilježja, primjerice o spolu, nošenju kacige i svjetlosnoj signalizaciji, no izvođenje mjerenja na većem području u pravilu je zahtjevno u pogledu resursa, vremenski dugotrajno i ograničeno te rezultira nedovoljno detaljnim podacima u kontekstu prostora i vremena (Jestico i dr., 2016). Količina biciklista koja se ručno broji ograničena je na nekoliko sati godišnje na određenim lokacijama. Prilikom planiranja ručnog mjerenja važno je pažljivo definirati vrijeme i učestalost brojanja potrebno za dobivanje pouzdane procjene prosječnog godišnjeg dnevnog broja biciklista (PGDB, engl. *Averag Annual Daily Byciclist* – AADB). Masovnim pristupom može se dobiti podatak o volumenu biciklističkog prometa na velikom broju lokacija, no potrebno je odrediti koje dane u tjednu, sate u danu i mjesece u godini treba prikupljati. I dok se u slučaju kratkotrajnog ručnog brojanja dobiva indikacija o ukupnom volumenu biciklističkog prometa, prostorna i vremenska pokrivenost su nedostatne. Za razliku od ručnog brojanja, automatizirani kontinuirani brojači omogućuju dugotrajno i kontinuirano mjerenje kojim se dobiva prometni tok za duže vremensko razdoblje, no prostorna pokrivenost ograničena je lokacijom postavljanja mjerača. Na taj način dobiva se isključivo podatak prometnog toka biciklista na nekoliko nepovezanih lokacija, što nije dovoljno za modeliranje uzorka biciklističkog prometa unutar kompleksne mreže prometnih sudionika.

Trenutno aktualna literatura naglašava hibridni pristup prikupljanju podataka, kojim se nadilaze praznine u podacima i dobiva cjelovitija slika urbane mobilnosti. Prijelaz s radno intenzivnih tradicionalnih metoda brojanja na digitalne tragove kretanja omogućio je "sveobuhvatnost obuhvata" u istraživanju mobilnosti (Alattar i dr., 2021a; Fan i dr., 2021; Kothuri i dr., 2022). Tehnologije za prikupljanje prostornih podataka, poput Globalnog navigacijskog satelitskog sustava (GNSS), omogućuju jednostavno i brzo prikupljanje velikih količina prostornih podataka, a široka dostupnost mobilnih uređaja koji primaju GNSS signal omogućuje

svakom korisniku pozicioniranje i praćenje vlastite lokacije i prikupljanje tragova. Korisnici mobilnih uređaja putem mobilnih aplikacija mogu registrirati lokaciju, navigirati se u prostoru ili bilježiti aktivnost. Na taj način pojedinci dobrovoljno sudjeluju u prikupljanju velike količine prostornih podataka, bilo aktivno kroz svjesno dijeljenje vlastite lokacije, bilo pasivno kroz privolu da njihove podatke koriste vlasnici aplikacija. Tako dobivene podatke nazivamo množtvено prikupljeni podaci (MPP, engl. *crowdsourced data*), a u engleskom jeziku koristi se i izvedenica *crowdsourcing* (engl. *crowd* znači mnoštvo ili gomila, a *source* znači izvor) kojom se označava postupak u kojem se „koristi zajednica (mreža) nepovezanih sudionika u svrhu prikupljanja usluga ili podataka kako bi se riješio specifični problem čije rješavanje bi inače bilo previše radno intenzivno ili neisplativo“ (Misra i dr., 2014). Fan i dr. (2021) analiziraju evoluciju termina množtvено prikupljanje podataka (engl. *crowdsourcing*), referirajući se na rad Howea i Jeffa (2006), koji *crowdsourcing* definiraju kao „čin preuzimanja posla koji tradicionalno obavlja imenovani agent (obično zaposlenik) i njegovo eksternaliziranje (engl. *outsourcing*) nedefiniranoj, općenito velikoj skupini ljudi u obliku otvorenog poziva“. MPP-i omogućuju praćenje aktivne mobilnosti od strane svakog pojedinca koji posjeduje mobilni uređaj te odluči aktivno ili pasivno prikupljati podatke putem mobilnih aplikacija. Pri tome prostorno-vremenska pokrivenost nema ograničenje, a količina prikupljenih podataka direktno je vezana za sudionike nemotoriziranog prometa koji koriste pametne uređaje za praćenje kretanja (McArthur i Hong, 2019). Evidentno je da posljednjih nekoliko godina broj korisnika mobilnih aplikacija za praćenje rekreativnih aktivnosti značajno raste, a to predstavlja izvrsnu priliku za uporabu MPP-a u svrhu istraživanja i razumijevanja biciklističkog prometa (Lin i Fan, 2020). U svom istraživanju Fan i dr. (2021) pokušavaju integrirati MPP-e iz mobilne aplikacije Strava s tradicionalnim brojačima u američkom gradu Charlotte (SAD) upotrebom regresijskih modela. Utvrđeno je da su MPP-i Strave snažan prediktor volumena biciklističkih vožnji, ali zahtijevaju kalibraciju zbog sustavno manje zastupljenosti u usporedbi s referentnim (automatskim kontinuiranim) brojačima.

U području geoznanosti najpoznatiji primjer MPP-a je OpenStreetMap (OSM) koji istovremeno predstavlja kartu svijeta te skup otvorenih i besplatnih prostornih podataka koji stvara i održava zajednica laika kartografa i registriranih volontera, a koji sadrži prostorne i atributne podatke o prirodnom i izgrađenom okolišu uključujući i prometnu infrastrukturu (Nelson i dr., 2021). Zahvaljujući razvoju mobilnih uređaja s ugrađenim GNSS čipovima, geografski informacijski sustavi uz sudjelovanje javnosti (engl. *Public Participation Geographic Information Systems* – PPGIS; u daljnjem tekstu koristit će se engleska kratica) i volonterske geografske informacije (engl. *Volunteered Geographic Information* – VGI) postali su fleksibilne alternative za prikupljanje prostornih podataka izravno od korisnika tih mobilnih uređaja. Geografski informacijski sustavi uz sudjelovanje javnosti (dalje u tekstu koristi se engleska kratica PPGIS) odnose se na „platforme

*i ankete temeljene na GIS-u koje su kreirali stručnjaci - poput urbanista, znanstvenika i vladinih agencija - kako bi prikupili specifična prostorna znanja i doprinose javnosti. Primarni cilj ovog okvira je unaprijediti komunikaciju između dionika i donositelja odluka osnaživanjem građana da doprinesu podacima koji informiraju proces planiranja i istraživanja“ (Alattar i dr., 2021a). Za razliku od PPGIS-a, VGI su podvrsta dobrovoljnog mapiranja gdje prostorne podatke i sadržaj dobrovoljno stvaraju i dijele građani, a ne profesionalci (Alattar i dr., 2021a; Ferster i dr., 2017). Najbolji primjer je gore navedeni OSM. S obzirom da gotovo svaka odrasla osoba na globalnoj razini posjeduje mobilni uređaj moglo bi se reći da građani postaju *senzori* prikupljajući podatke o raznim fenomenima, kao što su npr. opasnosti na cestama ili biciklističke rute. Na taj način količina prikupljenih podataka postaje neizmjerljivo velika. Upravo zbog količine te podatke nazivamo *velikim podacima* (od engleskog izraza *Big data* koji je uvriježen u literaturi). Specifično područje tzv. velikih podataka je područje društvenih mreža za tjelesnu aktivnost (engl. *Social Fitness Networks*), odnosno sportskih društvenih mreža (SDM), gdje mobilna aplikacija Strava jest neprikosnoveni globalni lider.*

Posljednjih desetak godina osjetan je porast istraživanja u području aktivne mobilnosti s naglaskom na pojedine tipove, oblike i aplikacije MPP-a. Alattar i dr. (2021b) ispitivali su učinkovitost PPGIS-a kao dopunu SDM-a u Glasgowu (Škotska). Koristeći metodu online ankete na 816 sudionika, utvrdili su da su korisnici SDM-a (poput Strave) mlađi i orijentirani na rekreaciju, dok PPGIS osigurava širu demografsku reprezentativnost. Prostorno gledano je ruta koju biraju korisnici Strave pokazala slabu korelaciju ($r = 0,22$) s općom biciklističkom populacijom. Garber i dr. (2019) uspoređivali su anketiranjem biciklista u Atlanti (SAD) korisnike aplikacija za praćenje sportske aktivnosti s onima koji ih ne koriste, zaključivši da korisnici aplikacija voze češće i više u slobodno vrijeme, što može dovesti do pristranosti u istraživanjima infrastrukture ukoliko se koriste samo podaci aplikacija. Slično tome, Oksanen i dr. (2015) u Helsinkiju (Finska) su koristili podatke aplikacije Sports Tracker te razvili metodu za generiranje toplinskih karata uz očuvanje privatnosti. Računajući tzv. gustoće putanje aktivnosti korigiranim indeksom raznolikosti korisnika postigli su visoku korelaciju s podacima brojača ($R^2 > 0,7$), čime su dokazali da MPP može obogatiti, ali ne i zamijeniti službene brojače. U domeni VGI-a, Ferster i dr. (2017) analizirali su BikeMaps (BikeMaps, 2026), web-stranicu (platformu) koja građanima služi kao globalni sustav mapiranja lokacija biciklističkih incidenata, u Victoriji (Kanada) kako bi istražili reprezentativnost podataka o sigurnosti. Utvrdili su da mlađi muškarci češće prijavljuju incidente, ali da su žarišta incidenata prostorno konzistentna kroz sve demografske skupine, što potvrđuje vrijednost VGI-a u identifikaciji prioriternih područja za intervenciju.

2.1.1 Mjerenje i procjena volumena biciklističkog prometa

U statističkom modeliranju volumena biciklističkog prometa jedan od ključnih izazova je procjena (izračun) prosječnog godišnjeg dnevnog biciklističkog prometa (PGDBP, engl. *Average Annual Daily Bicycle Traffic* – AADBT) iz uzoraka kratkotrajnih brojanja. Istraživanje grupe autora (Nordback i dr., 2013), na čelu s američkom znanstvenicom Kristom Nordback koja se proteklih desetak godina intenzivno bavila analizom volumena i sigurnosti biciklističkog i pješačkog prometa, koristilo je kontinuirano brojanje bicikala iz Bouldera (Sjedinjene Američke Države – SAD) za procjenu PGDBP-a i analizu pogrešaka koje bi se očekivale iz različitih scenarija brojanja biciklista. Prosječne pogreške u procjeni PGDBP-a varirale su od 15% za četverotjedne uzorke kontinuiranog brojanja do 54% za jednosatno brojanje na godišnjoj razini. Studija je pokazala da je najisplativije trajanje za kratkoročno brojanje bicikala jedan puni tjedan za vrijeme godišnjeg doba s većim volumenom bicikala kada su manje varijacije u broju aktivnosti i stoga točnije procjene. U daljnjoj suradnji Nordback i dr. (2019) istraživali su troškovnu učinkovitost trajanja brojanja biciklističkog prometa u šest američkih gradova, te su zaključili da je tjedan dana optimalno trajanje za procjenu PGDBP-a s prihvatljivom pogreškom. Bopp i dr. (2018) uspostavili su okvir za mjerenje biciklističkog prometa na razini lokalnih zajednica, razlikujući subjektivne metode temeljene na anketama od objektivnih metoda poput kratkotrajnog ručnog brojanja i trajnih automatiziranih brojača. Ističu da su, iako su tradicionalna brojanja zahtjevnija u pogledu resursa, ona „nužna za prepoznavanje dugoročnih vremenskih trendova i sezonskih varijacija“. Nadovezujući se na to, savez sjevernoameričkih gradova i prometnih agencija pružio je smjernice za širenje gradskih programa brojanja biciklista (NACTO, 2022).

El Esawey proveo je seriju istraživanja u Vancouveru (Kanada) sustavno analizirajući točnost faktora prilagodbe na PGDBP. U istraživanju iz 2013. El Esawey i dr. (2013) utvrdili su da su faktori specifični za vremenske uvjete značajno precizniji dok je istraživanje iz 2014. (El Esawey, 2014) pokazalo superiornost mjesečnih faktora nad sezonskim. U istraživanju iz 2016. (El Esawey, 2016) isti autor uspoređivao je tradicionalne faktore s metodom 'dan u godini' (poseban faktor prilagodbe za svaki dan) i utvrdio da potonja ostvaruje najmanju (17,5%) srednju apsolutnu postotnu pogrešku (engl. *Mean Absolute Percentage Error* – MAPE; u daljnjem tekstu koristit će se engleska kratica). Kasniji radovi (El Esawey, 2018b, 2018a) koristili su metodu višestruke imputacije za popunjavanje praznina u podacima uzrokovanih kvarovima senzora, pri čemu je model višestruke imputacije smanjio pogrešku na manje od 3% čak i pri gubicima podataka brojača od četiri mjeseca. Usporedbom povijesnih prosjeka i modela brojanja, utvrdio je da su modeli temeljeni na dubokom učenju superiorniji u točnosti.

Hankey i dr. (2014) koristili su podatke automatiziranih brojača iz Minneapolisa (SAD) za razvoj faktora 'dan u godini' na mješovitoj mreži staza. Potvrdili su da grupiranje lokacija u faktorske skupine značajno poboljšava preciznost modela. Lokacije su pri tom grupirane na rekreacijske, utilitarne i miješane upotrebom dvaju prometnih indeksa: relativni indeks prometa vikend-radni dan i relativni indeks jutarnjeg (7-9 sati) u odnosu na podnevni (11-13 sati) promet. Rezultati su pokazali da ova metoda ima manju pogrešku od tradicionalnih faktora dana u tjednu i mjeseca u godini, posebno za kratkotrajna brojanja. Nosal i dr. (2014) su u Montrealu i Ottawi (Kanada) predložili faktorsku metodu raščlanjivanja koja koristi pojedinačne dnevne sume referentnih mjesta dugotrajnog brojanja, što je omogućilo bolje uračunavanje kratkoročnih varijacija meteoroloških prilika u procjenu PGDBP-a. Fournier i dr. (2017) razvili su sinusoidalni model za procjenu sezonske potražnje, koristeći minimalne podatke za kalibraciju. Model je uspješno replicirao godišnje oscilacije u šest različitih gradova. Figliozzi i dr. (2014) primijenili su funkciju korekcije temeljenu na regresiji koja uključuje vremenske uvjete i specifične aktivnosti (poput praznika) kako bi smanjio pogrešku procjene PGDBP-a na temelju minimalnog broja kratkoročnih brojanja. Beitel i dr. (2017, 2018) razvili su mjeru kvalitete kratkotrajnih brojanja (0-10) koja korelira s relativnom pogreškom procjene, te automatizirani sustav za validaciju i interpolaciju dugotrajnih podataka u Arlingtonu (SAD). Roll i Proulx (2018) razvili su regresijski model sezonske prilagodbe, inovativnu metodu za izračun PGDBP-a za gradove bez mreže stalnih automatiziranih brojača, koristeći varijable vremena i dnevne uvjete za interpolaciju volumena. Validacija modela potvrdila je da se strateškim raspoređivanjem mjerenja kroz različita godišnja doba postižu rezultati visoke točnosti, čime se olakšava planiranje i opravdavanje ulaganja u biciklističku infrastrukturu. Na području Europe, Pogodzinska i dr. (2020) razvili su metodu procjene PGDBP-a koristeći GPS podatke iz sustava javnih bicikala Wavelo u Krakovu (Poljska). Uspoređujući podatke sustava s pet automatskih brojača, analizirali su utjecaj lokacije i dana u tjednu na udio javnih bicikala u ukupnom prometu. Rezultati su pokazali da, iako se taj udio značajno mijenja ovisno o lokaciji, on ostaje postojan tijekom različitih dana u tjednu, što je omogućilo razvoj preciznih statističkih modela s visokom pouzdanosti te je zaključeno da se podaci o kretanju javnih bicikala mogu uspješno koristiti za modeliranje općih prometnih tokova, čime se urbanističko planiranje i sigurnosne analize čine dostupnijima i preciznijima.

2.1.2 Prostorna analiza biciklističke mreže i prometna sigurnost

Utjecaj izgrađenog okoliša, cestovne infrastrukture i topografije na aktivnu mobilnost važan je čimbenik prilikom mrežne analize tokova biciklističkog prometa i određivanja najprometnijih koridora. Cooper (2017) je primijenio prostornu mrežnu analizu u Cardiffu (Wales) koristeći

hibridnu mjeru centralnosti (engl. *betweenness*), kojom se u topološkoj analizi mreže računa koliko se često određena točka ili linija (npr. ulica) nalazi na najkraćim putevima između svih ostalih parova u mreži. Model je integrirao nagib, motorizirani promet i kutnu udaljenost, pokazavši da ovi faktori značajno bolje predviđaju tokove biciklista nego jednostavni algoritmi najkraćeg puta. El Masri i Bigazzi (2019) fokusirali su se na preciznost procjene nagiba cesta u Vancouveru (Kanada). Usporedbom LiDAR podataka, digitalnog modela reljefa (DMR) i satelitskih izvora (SRTM), otkrili su da su standardni DEM-ovi često neprecizni na mostovima i povišenim strukturama, što drastično utječe na modele potrošnje energije biciklista.

Zayed (2016) je razvio indeks „spremnosti grada“ za biciklizam, koristeći metodu analize glavnih komponenti na uzorku od 20 svjetskih gradova prilagođenih biciklistima, utvrdivši da su gustoća naseljenosti i stopa motorizacije odlučujući faktori. Arellana i dr. (2020) razvili su indeks prilagođenosti bicikliranju (engl. *bikeability*, moglo bi se prevesti kao „biciklabilnosti“) koji su primijenila na gradove južne Amerike (Barranquilla, Kolumbija). Rezultati su pokazali da su sigurnost i kvaliteta kolnika kritičniji faktori u ovim regijama nego u gradovima sjeverne Amerike, te naglašavaju da planiranje infrastrukture mora uvažavati percepcije korisnika i socioekonomske karakteristike, razlikujući potrebe onih koji bicikliraju radi rekreacije od onih koji ga koriste kao nužno prijevozno sredstvo do posla. Nelson i dr. (2023) uveli su koncept "biciklističkih uličnih pejzaža" (engl. *bicycle streetscapes*) koristeći klasteriranje metodom k-srednjih vrijednosti (engl. *k-means*), odnosno proveli su klaster-analizu kojom su grupirali neoznačene podatke u 'k' različitih kategorija na temelju njihovih sličnosti. Na temelju 1215 km ulica i staza u Ottawi (Kanada), identificirali su pet kategorija lokacija (npr. biciklističke destinacije, bogatija susjedstva, urbanizirane zone) radi definiranja prioriternih infrastrukturnih ulaganja. Gehrke i Reardon (2021) koristili su model izravne potražnje u Cambridgeu (SAD) za prognozu aktivnosti na planiranoj stazi Grand Junction, identificirajući povezanost susjedstva i gustoću zaposlenosti kao ključne faktore potražnje.

Roy i dr. (2023) primijenili su funkcionalnu analizu podataka (FDA) nad podacima Strave da bi prikazali normalizirani broj biciklističkih aktivnosti po satu i mjesecu u Phoenixu. Koristeći tehniku vremenskog poravnanja korištenjem funkcije kvadratnog korijena brzine (engl. *Square Root Velocity Function* – SRVF) za rješavanje problema vremenske neusklađenosti podataka biciklističke aktivnosti, uspješno su mapirali sezonske i satne promjene u obrascima kretanja nastale zbog infrastrukturnih zahvata. Napredne tehnike fuzije podataka istražili su Kothuri i dr. (2022) kombinirajući podatke aplikacija Strava i StreetLight (StreetLight, 2026) s tradicionalnim brojanjem prometa u šest američkih gradova. Korištenjem metode strojnog učenja pod nazivom slučajne šume (engl. Random Forest – RF; u daljnjem tekstu koristit će se engleska kratica),

pokazali su da fuzija podataka nadmašuje pojedinačne izvore, smanjujući korijen srednje kvadratne pogreške (engl. *Root Mean Square Error* – RMSE; u daljnjem tekstu koristit će se engleska kratica) na 8-9% za lokacije srednjeg volumena.

Aldred i dr. (2016) istraživali su hoće li povećanje volumena biciklizma automatski povećati i demografsku raznolikost biciklista u UK-u. Analizirajući podatke iz popisa stanovništva, autori su otkrili da veći udio biciklističkog prometa ne jamči nužno veću zastupljenost žena i starijih osoba, koji su u britanskom kontekstu tradicionalno podzastupljeni. Rezultati upućuju na to da se u područjima s porastom biciklizma jaz između poslova nije smanjio, dok je sudjelovanje starijih odraslih osoba čak i opalo. Autori zaključuju kako samo povećanje broja korisnika nije dovoljno za stvaranje inkluzivne kulture biciklizma, već je potrebno ciljano ulagati u infrastrukturu i politike prilagođene potrebama ovih specifičnih skupina. Battiston i dr. (2023) koristili su MPP-e Strava aplikacije za područje 61 urbanog središta SAD-a, Ujedinjenog Kraljevstva, Italije i zemalja Beneluksa kako bi analizirali razlike među spolovima u količini rekreativne biciklističke aktivnosti. Otkrili su da žene više preferiraju ulice s nižim ograničenjima brzine i fizički odvojenu infrastrukturu, što su kritični nalazi za postizanje prometne jednakosti među spolovima. Ding i dr. (2020) modelirali su učestalost nesreća u Londonu (UK) koristeći podatke o sustava javnih bicikala, utvrdivši da komercijalna područja nose najveći rizik te da prisutnost biciklističkih autocesta može modificirati rizik ovisno o sezoni. Rupl i dr. (2019) koristili su podatke tradicionalnog ručnog brojanja i suvremenih GPS podataka s pametnih telefona te uveli metriku „ukupne devijacije“ (engl. *total deviation metric*). Na području Bologne (Italija) su kvantificirali dionice cesta koje biciklisti svjesno izbjegavaju, birajući dulje putove radi veće sigurnosti ili udobnosti. Istraživanje potvrđuje da biciklisti preferiraju izdvojene biciklističke staze i rute s manje raskrižja, dok izbjegavaju dionice s gustim motornim prometom i mješovitim zonama s autobusima ili pješacima. Ekološku studiju proveli su Tin Tin i dr. (2012) istraživši kako vremenske prilike i sezonske promjene utječu na učestalost vožnje bicikla u Aucklandu (Novi Zeland). Koristeći podatke automatskih brojača i nacionalne baze klimatskih podataka zaključili su da su temperatura i sunčeva svjetlost ključni čimbenici koji potiču biciklizam, dok padaline i snažni udari vjetra značajno smanjuju broj biciklista na cestama.

U kontekstu značajnih društvenih okolnosti na svjetskoj razini, pandemija COVID-19 pružila je jedinstvenu priliku za promjenu ponašanja u okviru biciklističkog prometa i povećanje tzv. biciklističke kulture unutar gradova. Moglo bi se reći da je pandemija poslužila kao katalizator promjena u aktivnoj mobilnosti. Büchel i dr. (2022) analizirali su promet u Zürichu i Baselu (Švicarska) za vrijeme prvog vala pandemije COVID-19 koristeći podatke dugotrajnih automatiziranih brojača prometa. Utvrdili su da je biciklistička aktivnost radnim danima postala

sličniji vikendima, s jednim vršnim periodom u rano poslijepodne, te da su tzv. *pop-up* staze (improvizirane biciklističke staze nastale prenamjenom cestovne infrastrukture) povećale volumen prometa za 11-48%. Buehler i Pucher (2022) proveli su studije slučaja u 14 gradova Europe i Sjeverne Amerike, ističući da su gradovi s unaprijed pripremljenim planovima (poput Pariza i Vancouvera) najbrže ubrzali razvoj mreže tijekom pandemije uvođenjem *pop-up* staza. Zaključuju da se razina biciklističke aktivnosti općenito povećala od 2019. do 2021., uglavnom zbog porasta rekreativnog biciklizma. Nasuprot tome, dnevna putovanja biciklom na posao i obrazovanje (utilitarne aktivnosti) su se smanjila. Također ističu da je svih 14 gradova u istraživanju izvijestilo je o velikom porastu vladinih potpora biciklizmu u vidu financiranja i izgradnje nove infrastrukture. Xin i dr. (2022) proveli su mrežnu analizu podataka sustava javnih bicikala Citi Bike u New Yorku (SAD) za period od siječnja do travnja 2019. i 2020. Rezultati analize pokazali su da su razvojem pandemije tok vožnje i njegov prostorno-vremenski obrazac distribucije značajno promijenili, što je imalo niz učinaka na korištenje i upravljanje biciklima u gradu. U Australiji su Fuller i dr. (2021) putem anketa utvrdili 'boom' (engl. naziv za nagli i visoki porast) u rekreacijskom biciklizmu tijekom pandemijskog zatvaranja, tzv. *lockdowna* (engleski naziv), ali su upozorili na nedostatak dokaza o trajnom prelasku na biciklizam kao primarni način putovanja na posao. Većina istraživanja biciklističke aktivnosti za vrijeme pandemije COVID-19 razmatra pandemiju kao priliku za održivu tranziciju, naglašavajući da su intervencije taktičkog urbanizma (zatvaranje ulica za aute) imale dugoročne pozitivne učinke (Francke, 2022).

2.2 Strava

Od svih aplikacija za praćenje sportske ili rekreativne aktivnosti uporabom GNSS tehnologije, mnoštveno prikupljeni podaci aplikacije Strava predstavljaju najznačajniji izvor za istraživanje biciklističke aktivnosti jer u odnosu na konkurentne aplikacije imaju globalno najveći broj korisnika i zabilježenih aktivnosti. Do 2023. godine platforma je dosegla preko 100 milijuna korisnika diljem svijeta, pružajući ogroman, kontinuirani skup podataka koji tjedno bilježi milijune aktivnosti, a trenutno Stravu koristi preko 195 milijuna korisnika u više od 185 država svijeta (Strava, 2026). Strava kontinuirano bilježi aktivnosti korisnika od 2009., 2011. je pokrenuta mobilna aplikacija, a od 2014. Strava nudi komercijalnu uslugu Strava Metro kojom pruža uslugu dobivanja anonimiziranih i agregiranih podataka o tzv. aktivnom prijevozu za pješake i bicikliste (Lee i Sener, 2021). Od rujna 2020. Strava Metro podaci dostupni su besplatno (Metro, 2026), no vlasnik podataka, tvrtka Strava Inc. iz SAD-a, odlučuje s kime će surađivati navodeći da „*rade samo s organizacijama koje planiraju, posjeduju ili održavaju infrastrukturu ili teže pozitivno utjecati na procese planiranja*“ prometne infrastrukture. Strava podaci imaju velik

potencijal nadopuniti tradicionalne metode prikupljanja podataka biciklističkog prometa, ali njihova reprezentativnost predstavlja veliki izazov prilikom znanstvenih istraživanja (Basiri i dr., 2019; Broach i dr., 2023). Unatoč nedostacima, upotreba Strava podataka u dosadašnjim biciklističkim istraživanjima značajno je povećala točnost procjene prijevozne potražnje, identifikacije uzorka biciklističkog prijevoza, evaluacije infrastrukture i određivanja izloženosti biciklističkim nesrećama (Lee i Sener, 2021).

Uvođenje Strava Metro podataka revolucioniralo je istraživanje aktivnog prijevoza pružajući visoku prostornu i vremensku rezoluciju (godišnji, mjesečni, dnevni i satni intervali) koji su nedostižni putem tradicionalnih izvora mjerenja poput ručnog brojanja ili anketa o putovanjima (Nelson i dr., 2021). Istraživačima nudi kontinuirani sustav brojanja, ali ne kao kod automatiziranih brojača na pojedinim lokacijama mreže već u cijelim prometnim mrežama (Morrissey, 2018). Na taj način omogućuje robusnu identifikaciju obrazaca putovanja (Boss i dr., 2018), procjenu potražnje (National Cooperative Highway Research Program (NCHRP), 2019), evaluaciju infrastrukture (Hong i dr., 2020) i utjecaja izgrađenog okoliša na biciklističku aktivnost (Shin i dr., 2022). Međutim, podaci predstavljaju značajne izazove u pogledu reprezentativnosti i pristranosti uzorkovanja (Alattar i dr., 2021a; Lee i Sener, 2021; Raturi i dr., 2021; Venter i dr., 2023). Korisnička baza je dosljedno iskrivljena prema tehnološki potkovanim muškarcima srednjih godina koji se rekreativno bave biciklizmom, dok kronično nedovoljno uzorkuje žene, djecu, starije osobe i stanovništvo s niskim prihodima (Brauer i dr., 2021; Kwayu i dr., 2021; Robinson i dr., 2025; Venter i dr., 2023). Iako Strava podaci jesu snažan pokazatelj relativne biciklističke aktivnosti u urbanim jezgrama, obično predstavljaju samo 1-10 % ukupnog volumena biciklističkog prometa, što znači da se moraju kombinirati s podacima brojanja prometa kako bi se dobile apsolutne procjene volumena (Lee i Sener, 2021; Miah i dr., 2021; Robinson i dr., 2025).

Zbog rigoroznih zahtjeva privatnosti i Opće uredbe o zaštiti podataka (GDPR), koja se u EU primjenjuje od svibnja 2018., platforma Strava Metro je u srpnju 2018. implementirala strategiju grupiranja podataka (engl. *binning*) kako bi se zaštitila privatnost korisnika Strave. Kao rezultat metode grupiranja je broj aktivnosti pojedinog segmenta prometne mreže zaokružen na najbliži višekratnik broja 5, a broj aktivnosti segmenta koji broj 3 ili manje aktivnosti je zaokružen na 0. Raturi i dr. (2021) utvrdili su da ova strategija uzrokuje značajan gubitak informacija, s neto pogreškama koje dosežu do 91% za satne agregacije i 50% za dnevne agregacije. Njihovi nalazi otkrili su da korištenje grupiranih podataka može preokrenuti zaključke istraživanja; na primjer, infrastruktura koja je pokazala nasumične promjene broja putnika u izvornim podacima čini se da je imala značajno smanjenje aktivnosti kada je grupirana. Kako bi se ublažili ovi problemi,

autori preporučuju da istraživači izbjegavaju korištenje grupiranih podataka (satnih i dnevnih) za detaljniju vremensku analizu, npr. analizu prometa vršnih sati. Preporuke za korištenje uključuju korištenje mjesečnih ili godišnjih agregacija, gdje veći volumen aktivnosti minimizira pogreške zaokruživanja. Nadalje, autori ističu potrebu za nadopunjavanjem Strava podataka tradicionalnim brojanjem, posebno prilikom analize područja s malim volumenom.

Temeljna pretpostavka za korištenje mnoštveno prikupljenih podataka SDM-a, poput platforme Strava, jest njihova korelacija sa stvarnim stanjem na terenu. Jestico i dr. (2016) istražili su u kojoj mjeri podaci Strave predstavljaju stvarni biciklistički promet u Victoriji (Kanada). Koristeći generalizirane linearne modele (GLM) i usporedbu s ručnim brojanjem, utvrdili su linearnu povezanost (od 0,40 do 0,58) te zaključili da jedan „Strava biciklist“ predstavlja približno 51 stvarnog biciklista u ukupnoj populaciji. Boss i dr. (2018) koristili su MPP-e Strave za praćenje promjena u prostornim obrascima biciklizma nakon ulaganja u infrastrukturu u Ottawi (Kanada). Primjenom lokalnih indikatora prostorne autokorelacije na mreži, otkrili su snažnu korelaciju (0,76 do 0,96) između uzoraka platforme Strava i automatiziranih brojača, što omogućuje detekciju promjena u prometnim tokovima na razini cijelog grada. Conrow i dr. (2018) usporedili su prostorne obrasce MPP-a s konvencionalnim metodama brojanja biciklističkog prometa u Sydneyu (Australija). Rezultati su pokazali da MPP-i bolje predstavljaju bicikliste u gustim urbanim područjima poput središnjih poslovnih četvrti, ali reprezentativnost varira ovisno o socioekonomskim čimbenicima. Jednu od rijetkih istraživanja na području Europe proveli su Venter i dr. (2023), pri čemu su analizirali pouzdanost i pristranost podataka prikupljenih putem aplikacije Strava za praćenje rekreativnih aktivnosti u Oslu (Norveška). Usporedili su ih s terenskim mjerenjima i kontinuiranim statičnim brojačima, kao referentnim podacima rekreativne aktivnosti, te utvrdili visoku preciznost prostorne i vremenske varijacije kretanja ($R^2 = 0,9$), ali i značajnu pristranost prema muškom spolu (15,7 % više od opaženog), populaciji srednje dobi i osobama višeg imovinskog i obrazovnog statusa.

2.2.1 Modeliranje volumena biciklističkog prometa

Napredne statističke metode i algoritmi strojnog učenja ključni su za skaliranje MPP-a na razinu cijele ulične mreže. S obzirom da su podaci Strave često pristrani prema rekreativnim vozačima, Roy i dr. (2019) su razvili statistički model koji koristi geografske varijable, poput blizine zelenih površina, prihoda kućanstva i gustoće naseljenosti, kako bi ispravili te nepravilnosti. Primjenom *Poissonove* regresije i *LASSO* (engl. *Least Absolute Shrinkage and Selection Operator*) metode selekcije varijabli, uspješno su predvidjeli broj biciklista za 86% uličnih segmenata te izradili detaljne karte protoka biciklista na razini ulica u okrugu Maricopa (Arizona, SAD). Prema Anderson i dr. (2006) model izravne potražnje za prometom je pristup predviđanju prometa koji

procjenjuje volumen prometa izravno iz socioekonomskih podataka i podataka o korištenju zemljišta, zaobilazeći višefazne izračune tradicionalnih modela. Dadashova i dr. (2020) razvili su modele izravne potražnje za procjenu PGDBP-a u 12 gradova savezne države Teksas (SAD). Integrirajući podatke Strave s automatiziranim brojačima te karakteristikama cesta i demografijom, postigli su razinu točnosti od 70%, što predstavlja značajno poboljšanje u odnosu na jednostavne metode skaliranja prometne potražnje. Nelson i dr. (2021) razvili su generalizirani model za mapiranje biciklističkog prometa koristeći podatke iz pet sjevernoameričkih gradova te identificirali da su broj korisnika Strave, postotak putovanja na posao, sigurnost u prometu i razina prihoda ključne varijable za precizno mapiranje aktivnosti na razini grada. Iako su se specifični modeli prilagođeni pojedinim gradovima pokazali najtočnijima, istraživanje naglašava da kvaliteta predviđanja najviše ovisi o reprezentativnosti službenih podataka o brojanju biciklista.

2.3 Sigurnost biciklističkog prometa

U kontekstu sigurnosti biciklističkog prometa, literatura se značajno razvila tijekom posljednjeg desetljeća, prelazeći s reaktivnih analiza temeljenih na povijesnim podacima prometnih nesreća (PN) na proaktivne pristupe utemeljene na podacima koji naglašavaju integraciju podataka o izloženosti i napredno statističko modeliranje (Sener i dr., 2021). U okviru analize sigurnosti cestovnog prometa, izloženost se definira kao mjera broja potencijalnih prilika za nastanak PN-e (Turner i dr., 2018). Izloženost predstavlja kvantitativnu mjeru broja potencijalnih prilika ili "prilika za pogrešku" u kojima se PN može dogoditi (Nordback i dr., 2018). Ona predstavlja neizostavan element svake rigorozne znanstvene analize rizika, budući da se rizik matematički izražava kao omjer broja nesreća i mjere izloženosti. Vanparijs i dr. (2015) proveli su opsežan pregled literature, utvrdivši da čak 98% studija o sigurnosti biciklista ne prikuplja podatke o izloženosti, što značajno otežava interpretaciju rizika. Autori zaključuju da se, bez kontrole izloženosti, lokacije s velikim brojem nesreća mogu pogrešno proglasiti nesigurnima. Tako se visokorizičnom može proglasiti lokacija gdje je kalkulirani rizik isključivo rezultat iznimno visokog volumena biciklističkog prometa.

Stoga se može sa sigurnošću reći da je razumijevanje sigurnosti u prometu nemoguće bez adekvatnog mjerenja (računanja) izloženosti. Na temelju pregledanih izvora iz literature, izloženost se može strukturirati i računati na sljedeće načine:

- broj vožnji/aktivnosti: putovanje između dviju točaka u jednom smjeru (podaci se obično prikupljaj anketama o putovanjima i koriste se za procjenu rizika na populacijskoj razini),

- broj biciklista: predstavlja najčešći oblik izravne izloženosti, obično iskazan kao PGDBP (dobiva se ekstrapolacijom kratkotrajnih ručnih ili automatskih brojanja),
- prijeđena udaljenost: iskazuje se kao ukupni prijeđeni kilometri svih vozila (bicikala) na određenom području ili dionici (smatra se najkorisnijom mjerom za usporedbu rizika na dionicama cesta ili u prometnim zonama),
- vrijeme u prometu: trajanje boravka sudionika u prometnom sustavu, npr. sati vožnje bicikla (smatra se najpravednijom mjerom za usporedbu različitih tipova prijevoza koji se kreću različitim brzinama),
- volumen na dionici: intenzitet prometa na specifičnom cestovnom segmentu,
- volumen na raskrižju: specifična mjera za čvorišta koja zbraja sve ulazne aktivnosti (npr. suma PGDBP svih krakova raskrižja),
- MPP-i (Strava): iako predstavljaju manji uzorak opće populacije, služe kao suvremeni surogat izloženosti jer pružaju visoku prostornu i vremensku rezoluciju za cijelu mrežu tamo gdje tradicionalni brojači ne postoje.

Iako su znanstvenici i prometni inženjeri koristili različite metrike za kvantificiranje izloženosti nemotoriziranog prometa poput prijeđene udaljenosti, vremena provedenog u prometu ili broja putovanja (dobiveno anketama), najčešći izvor podataka o izloženosti posljednjih desetak godina nedvojbeno su MPP-i. Iako MPP-i pokazuju visoku korelaciju s terenskim mjerenjima, oni su često pristrani prema mlađim muškarcima i rekreacijskim vožnjama te obično predstavljaju samo mali udio (Chen i dr., 2020; Islam i dr., 2025; Saad i dr., 2019) ukupne populacije. Stoga se preporuča fuzija različitih podataka, odnosno integracija više izvora (ankete, brojači, MPP-i), radi stvaranja robusnijih procjena koje smanjuju nesigurnost pojedinačnih izvora (Sener i dr., 2021). Ferster i dr. (2021) istražili su MPP-e aplikacije Strava u Ottawi (Kanada) za normalizaciju žarišta incidenata. Istraživanje je pokazalo da povijesni podaci o PN-ama otežavaju razlikovanje opasnih dionica od onih koje su jednostavno frekventne. Korištenjem podataka Strave za izračun izloženosti, autori su dokazali da se najveći rizik zapravo ne nalazi na zaštićenim biciklističkim stazama, već na ulicama bez biciklističke infrastrukture.

Transportni konzorcij pacifičkog sjeverozapada (PacTrans) u svom izvješću iz 2016. analizira sigurnost biciklista u Portlandu i Seattleu (SAD) s ciljem razvoja funkcija sigurnosne učinkovitosti (engl. *Safety Performance Functions* – SPF; u daljnjem tekstu koristi se engleska kratica) za raskrižja (Wang i dr., 2016). Upotrebom Strava podataka kao mjere izloženosti, izvješćem je potvrđen nelinearan odnos između volumena prometa i učestalosti nesreća, potvrđujući SiN efekt. Wang i dr. (2018) u svom radu istražuju razvoj alata za bodovanje rizika u prometu, osmišljenog kako bi se unaprijedila sigurnost pješaka i biciklista u Oregonu (SAD).

Autori naglašavaju da su tradicionalne metode, temeljene isključivo na povijesti prijavljenih nesreća, često nepouzdana zbog nedovoljnog broja podataka o manjim incidentima i specifičnim kretanjima nemotoriziranih korisnika. Umjesto toga, koristeći logističku regresiju na podacima o geometriji cesta, intenzitetu prometa (PGDBP iz Strava podataka) i korištenju zemljišta, studija nudi proaktivan pristup koji identificira opasne lokacije na temelju njihove potencijalne izloženosti riziku. Sener i dr. (2019) istražili su sigurnosne izazove aktivnog prijevoza u okrugu Austin (SAD), analizirajući učestalost i težinu PN-a u kojima sudjeluju pješaci i biciklisti. Koristeći Strava podatke kao mjeru izloženosti, ispitali su kako faktori poput gustoće mreže, potražnje za putovanjima i sociodemografskih karakteristika utječu na rizik od sudara s motornim vozilima. Chen i dr. (2020) razvili su okvir za izradu SPF-ova te su, upotrebom podataka Strave u Portlandu i Eugeneu (oboje SAD), utvrdili visoku korelaciju ($p < 0,01$) između aplikacijskih podataka i automatskih brojača, čime su potvrdili Stravu kao validan surogat za izloženost na raskrižjima. Autori zaključuju da veći broj biciklista na sporednim cestama smanjuje vjerojatnost nesreća, dok prisutnost klasičnih biciklističkih staza uz rub kolnika na raskrižjima neočekivano korelira s povećanim brojem incidenata. Slično tome, Saad i dr. (2019) istraživali su nedostatak podataka o biciklističkoj aktivnosti i razvili metodu prilagodbe Strava podataka u okrugu Orange na Floridi (SAD) primjenom faktora populacijske reprezentacije i terenskih promatranja kako bi prevladali pristranost aplikacije prema mlađim muškarcima. S prilagođenim Strava podacima potvrdili su da čimbenici poput postojanja biciklističkih staza, širine nogostupa i sustava prometne signalizacije značajno smanjuju učestalost nesreća, te dodatno potvrdili SiN koncept. Islam i dr. (2025) koristili su desetogodišnje podatke o nesrećama u Utahu i podatke Strave kako bi analizirali frekvenciju i ozbiljnost nesreća na signaliziranim raskrižjima, potvrđujući efekt SiN (10% povećanja volumena biciklista korelira sa samo 2% povećanja nesreća).

U području prometne sigurnosti faktori modifikacija PN-a (FMPN, engl. *Crash Modification Factors* – CMF) koriste se za procjenu očekivane promjene u broju PN-a nakon što se na određenoj lokaciji primijeni neka sigurnosna mjera ili promijeni geometrija ceste (DiGioia i dr., 2017). Raihan i dr. (2019) su koristili podatke o aktivnostima iz Strave za ekstrakciju podataka o izloženosti, kategorizirajući ih u razine (niska, srednja, visoka) unutar cenzusnih blokova urbanih sredina na Floridi (SAD). Za procjenu FMPN-a koriste model negativne binomne raspodjele s viškom nula (engl. *Zero-Inflated Negative Binomial* – ZINB) te zaključuju da širina prometnog traka i ograničenje brzine pozitivno utječu na sigurnost, dok prisutnost pločnika bez barijera neočekivano može povećati rizik. Mulvaney i dr. (2015) predstavili su sustavni pregled literature kojim su ispitali utjecaj različitih oblika biciklističke infrastrukture na učestalost PN-a i ozljeda među biciklistima. Analizirajući 21 studiju, autori su istražili učinkovitost mjera poput

označenih staza, posebnih raskrižja i ograničenja brzine od 30 km/h u urbanim sredinama. Središnji zaključak ukazuje na to da trenutačno nedostaju visokokvalitetni dokazi koji bi potvrdili da specifična infrastruktura izravno smanjuje broj PN-a. Sustavni pregled postojeće literature o utjecaju različitih vrsta biciklističke infrastrukture na sigurnost prometa dali su i DiGioia i dr. (2017). U svom radu sustavno analiziraju 22 različita infrastrukturna tretmana, te zaključuju da, iako određena rješenja smanjuju rizike (npr. biciklističke staze i uklanjanje uličnog parkiranja), nedostatak standardiziranih podataka o izloženosti biciklista otežava donošenje definitivnih statističkih zaključaka.

Pojam „*sigurnost u brojevima*“ (engl. *Safety in Numbers* – SiN; u daljnjem tekstu koristit će se engleska kratica), koji bi se još mogao i prevesti kao '*sigurnost u brojnosti*', u kontekstu prometa označava fenomen gdje povećanje broja pješaka ili biciklista na cestama dovodi do apsolutnog smanjenja rizika od PN-a po pojedincu, odnosno broj nesreća povećava se sporije od rasta volumena prometa. Tradicionalni prometni modeli dugo su pretpostavljali da linearni rast broja biciklista donosi i linearan rast PN-a. Međutim, istraživanja su pokazala suprotno (Elvik i Goel, 2019; Islam, 2021; Jacobsen, 2003; Strauss i dr., 2013). Kada se broj ljudi koji pješače ili bicikliraju udvostruči, broj nesreća s njihovim sudjelovanjem raste znatno sporije, što znači da rizik za svakog pojedinačnog sudionika opada. Pretpostavlja se da je glavni razlog zbog kojeg dolazi do SiN efekta promjena ponašanja vozača motornih vozila, koji zbog povećanog broj biciklista na cestama počinju biti svjesniji njihove prisutnosti te shodno tome smanjuju brzinu, postaju oprezniji i prihvaćaju bicikliste kao ravnopravne i očekivane sudionike prometa. Nadovezujući se na sistematski pregled literature koji su 2015. napravili Vanparijs i dr. (2015), Elvik i Goel (2019) su u svojoj meta-analizi pregledali dosadašnja istraživanja koja procjenjuju SiN efekt i zaključili da je izraženiji kod pješaka nego kod biciklista te da je snažnije uočljiv na makro-razini (poput cijelih gradova) nego na pojedinačnim raskrižjima. Autori sugeriraju da uzrok veće sigurnosti vjerojatno nije kvaliteta same infrastrukture, već promjena u ponašanju vozača motornih vozila. Aldred i dr. (2018) proveli su studiju slučaja kojom su istražili čimbenike koji utječu na rizik od ozljeda biciklista u Londonu. Uspoređujući mjesta nesreća s kontrolnim lokacijama temeljenim na stvarnom protoku prometa, autori su potvrdili fenomen '*sigurnosti u brojnosti*', dokazujući da se vjerojatnost ozljede smanjuje kako raste broj biciklista na određenoj dionici, dok veći volumen motornog prometa izravno povećava rizik. Ključni nalazi ukazuju na to da su stambene ulice (koje imaju nižu ograničenja brzine) i ograničenja brzine od 20 milja/h (~32 km/h) znatno sigurnije opcije od složenih raskrižja (koja predstavljaju najopasnije točke u mreži) i prometnica s ograničenjem brzine od 30 milja/h (~48 km/h).

2.4 Modeliranje prometnih nesreća

Kada se govori o generalnoj sigurnosti cestovnog prometa, tada se pokazatelje sigurnosti može podijeliti na apsolutne i relativne. Apsolutni pokazatelji sigurnosti cestovnog prometa dobivaju se neposrednim brojanjem i evidentiranjem PN-a te njihovih posljedica (Ćosić, 2017). Oni predstavljaju jednostavne (ukupne) brojčane vrijednosti koje iskazuju razmjere stradanja na cestama. Primjeri apsolutnih pokazatelja uključuju:

- ukupan broj PN-a (sa smrtnim ishodom, s ozlijeđenima ili s materijalnom štetom),
- broj poginulih osoba u PN-ama,
- broj teže ili lakše ozlijeđenih osoba.

Relativni pokazatelji predstavljaju odnos (omjer) između nekog apsolutnog pokazatelja i druge veličine koja služi kao mjera izloženosti riziku ili demografski kontekst. Ovi pokazatelji omogućuju usporedbu sigurnosti između različitih područja, vremenskih perioda ili skupina sudionika (Ćosić, 2017). Primjeri relativnih pokazatelja obuhvaćaju:

- stopu PN-a: broj nesreća u odnosu na prijedenu kilometražu (npr. na milijun vozila po km-u dionice),
- gustoću PN-a: broj nesreća po kilometru duljine ceste (ili po raskrižju),
- socijalne pokazatelje: broj smrti ili PN-a na 100000 stanovnika ili 100 km²,
- motorizaciju: broj PN-a u odnosu na broj registriranih vozila ili vozača.

Apsolutni pokazatelji ne uzimaju u obzir prometno opterećenje te stoga mogu, ako se koriste nekritički, biti pristrani prema lokacijama s većim prometom zbog čega mogu dovesti do pogrešnih zaključaka (Ćosić, 2017). Relativni pokazatelji pružaju dodatnu kvalitetu jer normaliziraju izloženost riziku, čime omogućuju objektivniji uvid u razinu sigurnosti (Ferster i dr., 2021). Stoga se smatraju pouzdanijim u znanstvenim istraživanjima jer odvajaju mjesta koja su opasna zbog velikog volumena prometa od onih koja su inherentno opasna zbog infrastrukturnih nedostataka (Fakultet prometnih znanosti, 2016). Ćosić (2017) u svom radu daje primjer Grada Zagreba, koji ima visok apsolutni broj nesreća, no gledajući relativne pokazatelje, poput broja smrtnih slučajeva na 100000 stanovnika (3,4), ima značajno bolji prosjek od nacionalnog (7,7), što ukazuje na važnost razlikovanja ovih mjera pri donošenju strateških odluka.

Modeliranje PN-a je znanstvena i inženjerska disciplina, primarno razvijena za motorizirani promet, koja koristi matematičke i statističke metode kako bi se razumjeli uzroci PN-a, predvidio njihov broj na određenim lokacijama i procijenila učinkovitost sigurnosnih mjera. Prostorno

gledano provodi se na makro-razini (države, regije, gradovi, cenzusne jedinice poput četvrti ili prometne analitičke zone) (Wei i Lovegrove, 2013) ili na mikro-razini (specifične lokacije prometne mreže: pojedinačni zavoji, dionice cesta ili raskrižja) (Fan i dr., 2021). U suvremenom upravljanju prometom, ovaj proces je doživio veliku transformaciju prelaskom s tradicionalnih reaktivnih metoda na proaktivne i prediktivne modele, kao što su modeli temeljeni na strojnom učenju. Tradicionalni matematički pristup analizi sigurnosti temelji se na modeliranju podataka o broju nesreća. Pristup se vremenom mijenjao zbog specifične prirode podataka: nesreće su rijetki, diskretni i često nasumični događaji, koji su karakterizirani prekomjernom disperzijom i velikim brojem nula unutar prometne mreže (Nordback i dr., 2014). Ciljevi modeliranja PN-a u znanstvenoj literaturi mogu biti različiti te često ovise o dostupnim podacima. Sistematizirano prema ciljnoj varijabli predviđanja, modeliranje PN-a se može podijeliti na:

- modeliranje učestalosti (frekvencije) PN-a (engl. *crash frequency*),
- modeliranje težine (stupnja ozljede) PN-e (engl. *crash severity*),
- modeliranje čimbenika (faktora) koji utječu na pojavu PN-a,
- modeliranje rizika od ozljede ili pojave PN-e (engl. *injury risk*),
- modeliranje stope PN-a (engl. *crash rate*),
- identifikaciju žarišta (crnih točaka/opasnih mjesta, engl. *hotspot*) PN-a.

Najveći broj radova fokusiran je analizu, vizualizaciju i modeliranje učestalosti PN-a. Učestalost ili frekvencija PN-a često se koristi u kalkulaciji rizika od pojave PN-a i kalkulaciji stope PN-a, te za prikaz i identifikaciju žarišnih točaka promete mreže. (Abdulhafedh, 2016) je istražio učinkovitost različitih statističkih metoda u predviđanju učestalosti PN-a na autocestama, koristeći petogodišnje podatke s ceste I-90 u Minnesoti. S obzirom da se radi o motoriziranom prometu, autor je raspolagao velikom količinom podataka o PN-a, zbog čega je mogao usporediti tradicionalne pristupe (Poissonovu i negativnu binomnu (NB) regresiju) s naprednijim modelom umjetnih neuronskih mreža (engl. *Artificial Neural Networks* – ANNs) te potvrditi njihovu izrazito bolju točnost predviđanja. UNN-e uspješnije obrađuju složene, nelinearne odnose među čimbenicima rizika bez potrebe za unaprijed definiranim funkcijama. Ključni doprinos rada je identifikacija geometrije ceste i gustoće prometa kao najutjecajnijih varijabli koje pridonose nastanku nezgoda. Wei i Lovegrove (2013) analizirali su podatke iz 500 prometnih analitičkih zona (engl. *Traffic Analysis Zone* – TAZ) u Kanadi, te na makro-razini, upotrebom NB regresije, identificirali ukupno vožene kilometre motoriziranih vozila i bicikala kao ključne prediktore učestalosti sudara. U istraživanju učestalosti PN-a s biciklistima na Floridi (SAD), Saha i dr. (2018) su na razini popisnih blokova utvrdili da su ključni čimbenici rizika demografske karakteristike populacije, Strava podaci (kao mjerilo aktivnosti biciklista) te

količina motoriziranog prometa. Wang i dr. (2024) su istražili primjenu metode geografski ponderiranih RF-a (engl. *Geographically Weighted Random Forest* – GW-RF) kako bi se preciznije predvidjeli učestalost PN-a u SAD-u. Autori su analizirali kako različiti čimbenici, poput cestovne mreže, socioekonomskih uvjeta i uporabe zemljišta, različito utječu na sigurnost prometa ovisno o specifičnoj geografskoj lokaciji. Ključni doprinos istraživanja je dokazivanje postojanja prostorne heterogenosti, što znači da isti čimbenik (npr. gustoća raskrižja) može imati snažan utjecaj na broj nesreća u jednoj regiji, dok je u drugoj njegov značaj zanemariv. Islam i dr. (2025) su u svom radu analizirali sigurnost biciklista na semaforiziranim raskrižjima u Utah-i (SAD) koristeći desetogodišnje podatke o nesrećama i inovativne i podatke Strave kao mjeru izloženosti biciklista. Autori su analizirali učestalost i ozbiljnost PN-a, otkrivajući da su nesreće češće na raskrižjima s četiri kraka, duljim pješačkim prijelazima i u socioekonomski ugroženijim četvrtima, dok čimbenici poput lijevog skretanja vozila i nedostatka ulične rasvjete značajno povećavaju rizik od težih ozljeda.

Kod modeliranja težina PN-a autori se najčešće bave analizom ishoda PN-e, koji se većinom kategorizira na razini od materijalne štete do fatalnih ozljeda. Ammar i dr. (2023) su analizirali nacionalne podatke o prometnim nesrećama u SAD-u kako bi identificirali ključne čimbenike koji utječu na razinu težine ozljeda biciklista u sudarima s motornim vozilima. Primjenjujući statističko modeliranje (multinominalu logističku regresiju), autori su dokazali da se uzroci ozljeda značajno razlikuju ovisno o tome događa li se nesreća na prometnim trakama ili na mjestima poput biciklističkih staza i pješačkih prijelaza. Studija ističe da čimbenici poput brzine kretanja vozila, dobi vozača i biciklista, te vrste vozila presudno određuju hoće li ishod biti lakša ili teška ozljeda. Tejashwini i dr. (2024) su analizirali opsežne setove podataka iz gusto naseljenih urbanih područja u Indiji, uključujući čimbenike poput dobi vozača, brzine i tipa vozila i vremenskih uvjeta. U istraživanju se RF algoritam pokazao najuspješnijim u predviđanju težina PN-a, a rezultat je web-aplikacija koja kategorizira rizik od nezgoda na tri razine te korisnicima nudi proaktivne savjete i alternativne rute kako bi se smanjila smrtnost na cestama. U svom radu Ejikeme (2025) je istražila integraciju GIS-a i strojnog učenja kako bi se identificirali prostorni, vremenski i infrastrukturni čimbenici koji utječu na težinu biciklističkih nesreća u tri američke savezne države. U radu koristi stabla odlučivanja (engl. *decision trees*), točnije napredni algoritam strojnog učenja *eXtreme Gradient Boosting* (XGBoost) kako bi riješila problem neuravnoteženosti podataka, budući da su teške nesreće statistički rijetke, ali društveno najznačajnije. Istraživanje je pokazalo da su uvjeti osvijetljenja, tip ceste i doba dana ključni prediktori ozbiljnosti ozljeda, dok sama blizina biciklističkih staza ima iznenađujuće malen utjecaj na ishod nesreće.

Prilikom analize i predikcije čimbenika koji doprinose učestalosti i težini PN-a fokus je na identifikaciji korelacije između nesreća i vanjskih uvjeta. U istraživanjima analiziran je širok spektar čimbenika koji se mogu sistematizirati u nekoliko ključnih kategorija:

- a) cestovna infrastruktura (obuhvaća fizičke karakteristike prometnica i njihovu opremu):
 - geometrija i karakteristike ceste: oblik dionice, broj i širina prometnih traka, nagib ceste, kategorija prometnice,
 - karakteristike raskrižja: tip (prema broju krakova), gustoća raskrižja, prisutnost i duljina pješačkih prijelaza,
 - prometna signalizacija i oprema: vrsta regulacije (prometni znakovi, semafori, pravila prometa), kvaliteta horizontalne i vertikalne signalizacije, prisutnost javne rasvjete, zaštitne ograde,
 - mikrolokacijski elementi: prisutnost, tip i duljina biciklističke infrastrukture, dostupnost nogostupa, prisutnost stajališta javnog prijevoza.
- b) Geografski i meteorološki uvjeti (utjecaj na vidljivost i uvjete na kolniku):
 - vremenske prilike: padaline, magla, vjetar,
 - stanje kolnika: stanje površine (suh, mokar, zaleđen, snijeg, blato), kvaliteta kolničkog zastora (oštećenja, pukotine), koeficijent trenja,
 - uvjeti vidljivosti: doba dana (dan, noć, sumrak, svitanje), prisutnost i funkcionalnost ulične rasvjete,
 - ostali geografski utjecaji: nadmorska visina (elevacija), prisutnost prepreka vidljivosti (drveće, zgrade), topografija terena (nagib).
- c) Karakteristike prometnog toka (intenzitet i dinamika kretanja sudionika):
 - volumen prometa: PGDP (PGDBP kod biciklističkog prometa), prijeđena udaljenost svih vozila na dionici u kilometrima ili miljama (engl. *Vehicle Kilometers/Miles Traveled* – VKT/VMT), te specifične mjere izloženosti (prilagođene za pješake i bicikliste),
 - brzina: zakonska ograničenja brzine, prosječna brzina prometnog toka i varijacija brzina,
 - struktura toka: udio teških vozila (kamioni, autobusi), udio tranzitnog prometa, mješovitost prometa.
- d) Uporaba zemljišta i izgrađeni okoliš (prostorni kontekst u kojem se promet odvija):
 - vrsta namjene (uporabe): omjeri ili postotci stambenih, gospodarskih, javno-društvenih, zelenih i sportsko-rekreacijskih površina,

- atraktori prometa: blizina obrazovnih ustanova, bolnica, trgovačkih centara, vjerskih objekata, parkinga,
 - urbana struktura: gustoća ulične mreže, entropija namjene zemljišta (raznolikost mješovite gradnje), razina urbanog razvoja.
- e) Sociodemografski čimbenici (karakteristike populacije na promatranom području ili sudionika u PN-i):
- demografija: gustoća naseljenosti, dobna struktura, spol, rasna/etnička pripadnost,
 - socioekonomski status: razina obrazovanja, stopa nezaposlenosti, medijan prihoda kućanstva,
 - vlasništvo i kretanje: broj vozila po kućanstvu (osobito kućanstva bez vozila), veličina kućanstva, udio putovanja na posao različitim modovima (hodanje, bicikl, javni prijevoz).
- f) Temporalni čimbenici (utjecaji vezani uz vrijeme događanja):
- vremenski okviri: sat u danu (vršna opterećenja), dan u tjednu (vikend/radni dan), mjesec u godini, godišnje doba (npr. sezona bicikliranja), kvartal godine.

Alkaabi (2023) je istražila uzroke PN-a motoriziranog prometa u Abu Dhabiju (Ujedinjeni Arapski Emirati – UAE) koristeći kombinaciju statističke analize anketa vozača o ponašanju i povijesnih podataka policije o PN-ama (vrijeme, lokacija, tip sudara). Autorica je identificirala nepažljivu vožnju, a posebice nedržanje sigurnosnog razmaka, kao primarni čimbenik rizika, dok demografska analiza pokazuje da su sredovječni i iskusniji vozači skloniji nezgodama zbog pretjeranog samopouzdanja. Malaghan i dr. (2025) su u svom radu koristili nestrukturirane tekstualne opise nesreća iz baza MPP-a u Irskoj, koje su analizirali metodom obrade prirodnog jezika (engl. *Natural Language Processing* – NLP) kako bi nadoknadili nedostatak podataka u službenim policijskim evidencijama, koje često zanemaruju blaže incidente i situacije u kojima je sudar zamalo izbjegnut. Koristeći klasterizaciju metodom k-srednjih vrijednosti i Getis-Ord Gi* statistiku, studija je identificirala deset ključnih bihevioralnih čimbenika, poput interakcije s tramvajskim tračnicama, te locirala žarišta PN-a u Dublinu (Irska).

Modeliranje rizika od ozljede s fokusom na vjerojatnost ozljede uzimajući u obzir izloženost, proveli su (Strauss i dr., 2013; Yiannakoulis i dr., 2012) Inovativnu metodu za prostorno mapiranje rizika od sudara biciklista i motornih vozila u urbanim sredinama, koristeći podatke statističkih krugova o putovanju na posao u gradu Hamilton (Kanada), predstavili su Yiannakoulis i dr. (2012). Pri tome su kritizirali tradicionalne prikaze sigurnosti koji se temelje isključivo na broju nesreća, naglašavajući da se pravi uvid dobiva tek uvođenjem

koncepta izloženosti, koji oni dobivaju izračunom rizika prema prijedenoj udaljenosti. Strauss i dr. (2013b) su koristili Bayesovu metodu, kojom se parametri procjenjuju tretirajući ih kao slučajne varijable s definiranim apriornim raspodjelama, kako bi istovremeno istražili učestalost ozljeda biciklista i intenzitet biciklističkog prometa na signaliziranim raskrižjima u Montrealu. Istraživanje je naglasilo da veći broj biciklista povećava ukupan broj nesreća, ali paradoksalno smanjuje individualni rizik, što podupire SiN hipotezu.

Stopa PN-a izražava se kao broj nesreća normaliziran mjerom aktivnosti. U literaturi stopa PN-a ili stopa incidencije (engl. *incidence rate*) definira se kao omjer između apsolutnog broja PN-a i određene mjere izloženosti, što omogućuje objektivniju usporedbu rizika na različitim lokacijama od same učestalosti PN-a. Vanparijs i dr. (2015) u svom pregledu literature ističu da je stopa incidencije temeljni alat za interpretaciju rizika i definiraju ju kao omjer incidenata (sudara ili konflikata) i jedinice izloženosti, koja se može mjeriti kroz udaljenost, vrijeme ili broj prolazaka/aktivnosti. Nordback i dr. (2014) koriste stopu PN-a izraženu kao broj sudara biciklista i motornih vozila na milijun biciklista kako bi definirali zone visokog i umjerenog rizika u Boulderu (SAD). I ova studija je potvrdila SiN efekt i dokazala nelinearnu vezu između volumena prometa i učestalosti PN-a, a rezultati su pokazali da su raskrižja s manje od 200 biciklista dnevno kritične zone visokog rizika, dok veća prisutnost bicikala potiče sigurnije okruženje. Sanders i dr. (2017) su razvili metodu za procjenu izloženosti pješaka i biciklista u prometu, koristeći Seattle (SAD) kao studiju slučaja za gradove s ograničenim resursima. Istraživači su razvili pojednostavljene modele temeljene na dostupnim podacima, poput namjene zemljišta i socioekonomskih faktora, kako bi izbjegli skupe i dugotrajne sveobuhvatne programe brojanja. Ključni doprinos studije je integracija MPP-a, točnije Strava podataka, koji su značajno povećali preciznost modela za bicikliste i pojednostavili proces analize. Svrha ovog pristupa je omogućiti lokalnim vlastima da kroz analizu rizika i nesreća učinkovitije planiraju sigurnosne mjere. Autori zaključuju kako su ovi aproksimativni modeli dovoljno robusni za prioritarno rješavanje infrastrukturnih problema i povećanje sigurnosti ranjivih skupina sudionika u prometu. Pillionnet i dr. (2024) su u svom radu koristili podatke PN-a i godišnje upitnike o kretanju biciklista kako bi izračunali stopu incidencije sudara u odnosu na broj prijeđenih kilometara. Upotrebom generaliziranog linearnog modela (engl. *Generalized Linear Model* – GLM) dobili su granulirane stope incidencije za različite tipove biciklističke infrastrukture, pružajući uvid u relativnu sigurnost staza u odnosu na vožnju cestom. U kontekstu motoriziranog prometa, Berhanu i dr. (2024) su stopu PN-a izračunavali iz povijesnih podataka PN-a i brojanja prometa na dionicama cesta u Adis Abebi (Etiopija). Upotrebom RF prediktivnog modela identificirali su dionice ceste sklone nesrećama te razvili sustav za identifikaciju sigurnih ruta, koji vozače usmjerava dalje od područja sklonih sudarima i zagušenjima.

U suvremenom inženjerstvu cestovnog prometa ne postoji jedinstvena, univerzalno prihvaćena definicija žarišta PN-a, odnosno opasnog mjesta. Teorijski gledano moglo bi se definirati žarište PN-a kao lokaciju prometne mreže koja ima veći očekivani broj nesreća od sličnih lokacija, što je rezultat lokalnih čimbenika rizika. Temeljna filozofija upravljanja opasnim mjestima (engl. *Black Spot Management* – BSM) i sigurnosne analize mreže (engl. *Network Safety Management* – NSM) počiva na korištenju povijesti PN-a za identifikaciju mjesta gdje specifični, često nevidljivi infrastrukturni nedostaci pridonose riziku (Aziz i Ram, 2022).

Metode identifikacije žarišta PN-a dijele se na reaktivne i proaktivne. Reaktivne se oslanjaju na povijesne podatke o nesrećama i mogu biti (Fakultet prometnih znanosti, 2016a):

- numeričke: temeljene isključivo na fiksnom kriteriju broja PN-a u određenom vremenu (npr. 4 ili više nesreća u 5 godina),
- statističke: uspoređuju zabilježeni broj s normalnim brojem (kritičnom razinom) za slične lokacije,
- temeljene na modelima (engl. model based): koriste napredne matematičke modele (poput Empirijske Bayesove metode ili metoda strojnog učenja) za procjenu očekivanog broja PN-a na temelju karakteristika lokacije.

Pri tome se metode temeljene na modelima smatraju najboljima s teorijskog stajališta jer kontroliraju slučajne varijacije i sustavne čimbenike rizika (Sørensen, 2007). Proaktivne metode identifikacije nisu temeljene na nesrećama, već služe za identifikaciju lokacija s visokim potencijalom za PN-e prije nego što se one dogode. One se temelje na analizi različitih vanjskih čimbenika poput geometrije ceste, vidljivosti, trenja površine, gustoće naseljenosti, ponašanja sudionika i sl. Mahmoud i dr. (2021) su u svom istraživanju identificirali žarišta PN-a ranjivih sudionika na cestama s više traka, pri čemu su primijenili RF metodu za procjenu izloženosti te kontekst ceste za klasifikaciju PN-a.

Najčešće korištena metoda za vizualizaciju gustoće i identifikaciju klastera PN-a u GIS okruženju je *Kernel Density Estimation* (KDE), što bi prevedeno na hrvatski bilo procjena gustoće jezgre. KDE je metoda prostorne analize kojom se procjenjuje intenzitet događaja (u ovom slučaju PN-a) na području istraživanja stvaranjem zaglađene površine gustoće (Moridpour i dr., 2023). Kranji rezultat je toplinska karta (engl. *heat map*) koja prikazuje rizik ili grupiranje PN-a. Prednosti ove metode su što precizno locira zone visoke koncentracije PN-a bez obzira na administrativne granice, pretvara raštrkane točke u neprekidnu površinu (toplinsku kartu) koju donositelji odluka lako razumiju, te smanjuje utjecaj manjih prostornih pogrešaka u koordinatama pojedinačnih PN-a. Nedostatak je što metoda neparametarska te joj nedostaje kvantitativna

statistička procjena (Harirforoush i Bellalite, 2019). Naglašava učestalost nekog fenomena u prostoru zanemarujući vanjske čimbenike koji mogu na njega utjecati. Također, rezultat prikaza značajno ovisi o odabiru širine pojasa (engl. *bandwidth*) i veličini prostorne ćelije (Ejikeme, 2025). Preveliki pojas previše zaglađuje podatke (gube se detalji), dok premali pojas stvara rascjepkane "otoke". Ćosić (2017) je u svojem istraživanju izradio toplinsku kartu PN-a KDE metodom s polumjerom od 25m da bi identificirao žarišta (klastere od 3 ili više istovrsnih PN-a). Potom ih je pretvorio u poligone koje je koristio za definiranje i identifikaciju značajnih vanjski čimbenika koji imaju potencijalni utjecaj na nastanak opasnoga mjesta primjenom binarne logističke regresije. Moridpour i dr. (2023) su generirali površinu gustoća sudara KDE metodom kako bi identificirali žarišta za pješake i bicikliste na cestovnoj mreži Teritorija australskog glavnog grada. Za rangiranje lokacija primijenjena je metoda ekvivalentne štete na imovini (engl. *Equivalent Property Damage Only* – EPDO), koja ponderira lokacije prema težini ozljeda i društvenim troškovima.

Za razliku od KDE metode, koja mjeri intenzitet na temelju prostorne gustoće, metode prostorne statistike (engl. *spatial statistics*) matematički dokazuju jesu li ta prostorna grupiranja rezultat slučajnosti ili statistički značajnog uzorka. Najznačajnije su *Local Moran's I* (koji se još naziva i *Anselin Local Moran's I*) i *Getis-Ord Gi**. Prva identificira prostorne anomalije i tipove grupiranja, te detektira u podacima četiri vrste odnosa: Visoko-Visoko (žarišta), Nisko-Nisko (hladne točke), ali i prostorne izuzetke poput Visoko-Nisko (visok broj PN-a okružen mirnim zonama) i Nisko-Visoko. *Getis-Ord Gi** metoda analizira svaku lokaciju u kontekstu njezinih susjeda i procjenjuje postoji li prostorno grupiranje visokih ili niskih vrijednosti za određeni atribut (Songchitruksai i Zeng, 2010). Ako lokacija ima visoku vrijednost (npr. puno PN-a) i njezini susjedi također imaju visoke vrijednosti, ona postaje statistički značajno žarište. Prema Songchitruksai i Zengu (2010) se smatra pogodnijom za identifikaciju opasnih mjesta od Moranovog indeksa jer može jasno razlikovati obrasce u kojima dominiraju visoke vrijednosti (žarišta) od onih u kojima dominiraju niske vrijednosti.

Važna činjenica je da se praksa identifikacije žarišta PN-a značajno razlikuje po zemljama, te je često ovisna o zakonskoj regulativi, društvenom kontekstu, prometnoj infrastrukturi i dostupnosti podataka. Aziz i Ram (2022) su u svojem sustavnom pregledu literature proveli tzv. meta-analizu metodologija koje se koriste za prepoznavanje žarišnih točaka na području 34 države svijeta i otkrili značajan nedostatak međunarodnog konsenzusa u definiranju opasnih mjesta, pri čemu su istaknuli kako velika većina država i dalje primjenjuje isključivo kriterij učestalosti sudara bez razmatranja šireg konteksta poput namjene zemljišta ili hijerarhije cesta. Na državnoj razini, u Republici Hrvatskoj sustavnu identifikaciju i rangiranje potencijalno

opasnih mjesta na mreži državnih cesta te pregled, analizu i sanaciju lokacija opasnih mjesta provode prvenstveno Hrvatske ceste d.o.o. (Hrvatske Ceste). Pri tome je trenutno aktualna *Metodologija za identifikaciju opasnih mjesta u cestovnoj prometnoj mreži* (Fakultet prometnih znanosti, 2016), izrađena 2016. od strane grupe autora s Fakulteta prometnih znanosti, Sveučilišta u Zagrebu. Predložena metodologija bazirana je na statističkom ispitivanju svake lokacije na kojoj se dogodila PN-a. Za svaku lokaciju se, na temelju prosječne stope PN-a, provodi usporedba stope PN-a s kritičnom razinom nastanka PN-a, te se identificirana potencijalna opasna mjesta rangiraju prema omjeru stope i kritične razine nastanka PN-e. Navedena metodologija još je poznata pod nazivom *Rate Quality Control* (RQC), a njeno korištenje omogućuje dinamičko postavljanje kriterija ovisno o prometnom opterećenju i tehničkim karakteristikama ceste. Prednost ove metode je njezina znanstvena utemeljenost i prilagodljivost, dok je nedostatak ovisnost o preciznim podacima PGDP-a. S obzirom da međunarodno ne postoji jedinstvena metodologija identifikacije žarišta PN-a za cestovni (motorizirani) promet, očekivano ne postoji niti jedinstvena metodologija za biciklistički promet. To pruža priliku za donošenje prijedloga i implementacije vlastite metodologije kojom bi se omogućila identifikacija žarišta PN-a u kojima sudjeluju biciklisti, s ciljem povećanja sigurnosti prometa u kojem su biciklisti, uz pješake, najranjivija skupina sudionika.

2.5 Strojno učenje u kontekstu prostornih podataka prometa

U kontekstu prometnog inženjerstva i analize prostornih podataka, strojnom učenju prethodio je niz statističkih i matematičkih metoda koje su se desetljećima koristile u svrhu rješavanja različitih istraživačkih problema (Rahman, 2022; Nam i dr., 2024; Senkondo i dr., 2025; Ejikeme, 2025):

- klasifikacija faktora rizika i analize ishoda PN-a: logistička regresija, Ordered Logit i Ordered Probit modeli,
- predviđanje učestalosti PN-a: linearna, Poissonova, NB i ZINB regresija,
- prostorna analiza: geografski ponderirana regresija (engl. *Geographically Weighted Regression* – GWR), uvjetni autoregresivni model (engl. *Conditional Autoregressive* – CAR), KDE, Moran's I, Getis-Ord Gi*,
- procjena volumena prometa: Kalmanov filter, Dijkstra algoritam.

Strojno učenje predstavlja granu umjetne inteligencije koja koristi računalne algoritme za automatsko učenje obrazaca iz podataka, s ciljem obavljanja zadataka poput klasifikacije, predikcije i prepoznavanja uzorak (Nikparvar i Thill, 2021). U kontekstu prometnog inženjerstva i sigurnosti, ove metode postaju neizostavne zbog svoje sposobnosti modeliranja nelinearnih i

kompleksnih odnosa između ulaznih varijabli i izlaznih rezultata (poput vjerojatnosti ili težine PN-a) (Berhanu i dr., 2024). U znanstvenoj literaturi strojno učenje se primarno dijeli prema prirodi procesa učenja i vrsti povratne informacije koju algoritam dobiva tijekom rada na (Shakya, 2023):

- nadzirano učenje (engl. *supervised learning*): algoritam uči iz prethodno obilježenih podataka. Cilj je razviti model koji može mapirati ulazne značajke na ispravan izlaz (klasu ili vrijednost) kako bi predvidio ishode na novim, neviđenim podacima. Glavne podskupine su klasifikacija (predviđanje diskretnih kategorija) i regresija (predviđanje kontinuiranih numeričkih vrijednosti).
- Nenadzirano učenje (engl. *unsupervised learning*): algoritam grupira podatke bez definiranih oznaka (labela). Fokus je na otkrivanju skrivenih struktura ili obrazaca unutar podataka, pri čemu su najčešće primjene grupiranje (klasteriranje) i redukcija dimenzionalnosti.
- Učenje potkrepljivanjem (engl. *reinforcement learning*): temelji se na interakciji agenta s okolinom, gdje on uči donositi odluke na temelju sustava nagrada i kazni kako bi maksimizirao kumulativnu korist.

Prema Nikparvar i Thill (2021) poseban izazov u strojnom učenju predstavljaju prostorni podaci zbog svojih specifičnih svojstava kao što su prostorna zavisnost (autokorelacija) i prostorna heterogenost, što zahtijeva prilagodbu standardnih algoritama ili specifičnu pripremu prostorne matrice opažanja.

Tablica 1. Pregled glavnih kategorija i metoda strojnog učenja (prilagođeno prema Berhanu i dr., 2024; Khan i Hussain, 2024; Nikparvar i Thill, 2021)

Kategorija	Podtip	Ključni algoritmi	Primjena u prometu
Nadzirano učenje	Klasifikacija	RF, SVM, XGBoost, stabla odlučivanja, k-NN	Predviđanje posljedica PN-a i identifikacija žarišta
	Regresija	Linearna regresija, SVR, ANN, GWR	Procjena PGDBP-a
Nenadzirano učenje	Grupiranje	K-means, SOM (engl. Self-Organizing Maps), DBSCAN	Identifikacija obrazaca kretanja i klasteriranje PN-a
	Redukcija dimenzionalnosti	PCA (engl. <i>Principal Component Analysis</i>), GWPCA, PPCA	Sažimanje kompleksnih prostornih varijabli
Duboko učenje	Specijalizirane mreže	CNN (za slike), RNN/LSTM (za sekvence), GNN (za grafove)	Analiza prometnih tokova i prostorno-vremenskih predikcija

U kontekstu ovog istraživanja bit će korištene metode klasifikacije. Metode klasifikacije koriste se za dodjeljivanje opažanja određenim diskretnim klasama, što je u sigurnosti prometa ključno za predviđanje vjerojatnosti PN-a ili njihovo rangiranje po opasnosti. OD klasifikacijski metoda najčešće korišteni algoritmi u domeni prometnog inženjerstva su RF, SVM i XGBoost. RF je ansambl metoda temeljena na stablima odlučivanja koja koristi tehniku *bagginga* (engl. *bootstrap aggregation*), odnosno smanjenje varijance modela. Algoritam gradi mnoštvo nekoreliranih stabala na različitim podskupovima podataka, a konačno predviđanje donosi se većinskim glasovanjem. Ključne prednosti RF-a su visoka otpornost na prekomjerno prilagođavanje (engl. *overfitting*) i robusnost prema šumu u podacima. U prometnim istraživanjima RF se pokazao iznimno učinkovitim u identifikaciji varijabli koje najviše pridonose nastanku PN-a (Berhanu i dr., 2024; Khan i Hussain, 2024; Miah i dr., 2023). SVM je metoda koja mapira ulazni prostor u prostor više dimenzionalnosti pomoću tzv. *kernel* funkcija, gdje traži optimalnu *hiperravninu* koja najbolje razdvaja klase uz maksimiziranje margine (Nikparvar i Thill, 2021). Iako je SVM izuzetno moćan u prostorima visokih dimenzija, on je računalno zahtjevniji za velike skupove podataka i osjetljiviji na buku i ekstremne vrijednosti (engl. *outliere*) u usporedbi s ansambl metodama. U prometu se često koristi za klasifikaciju ozbiljnosti ozljeda u nesrećama (Khan i Hussain, 2024). XGBoost pripada obitelji metoda pojačavanja (engl. *boosting*) i predstavlja visokoučinkovitu implementaciju gradijentno pojačanih stabala odlučivanja. Za razliku od RF-a koji gradi stabla paralelno, XGBoost ih gradi sekvencijalno, gdje svako novo stablo pokušava ispraviti pogreške prethodnog ansambla minimiziranjem funkcije gubitka (Nikparvar i Thill, 2021). Smatra se jednom od najmoćnijih metoda za strukturirane (tabularne) podatke i često postiže najviše rezultate u točnosti predviđanja na kompleksnim prometnim mrežama (Khan i Hussain, 2024).

Trenutna istraživanja ukazuju na značajan pomak od tradicionalnih statističkih modela prema metodama strojnog učenja. Tradicionalni pristupi često nisu mogli adekvatno obuhvatiti nelinearne odnose i kompleksne prostorno-vremenske zavisnosti PN-a, dok modeli strojnog učenja, poput Random Foresta i XGBoosta, pokazuju superiornu moć predviđanja u kompleksnim urbanim sredinama (Berhanu i dr., 2024). Primjena strojnog učenja mogla bi u sklopu istraživanja o sigurnosti biciklističkog prometa omogućiti integraciju heterogenih izvora podataka (većina istraživanja i dalje se oslanja isključivo na povijesne podatke o PN-ama, dok biciklistički promet zahtijeva integraciju MPP-a i specifičnih infrastrukturnih parametara). Osim toga, trenutni sigurnosni modeli često podcjenjuju rizik na lokacijama gdje nema izgrađene infrastrukture, a gdje se biciklisti svejedno kreću (National Association of City Transportation Officials, 2022). Trenutno ne području sigurnosti biciklističkog prometa ne postoje istraživanja koja identificiraju žarišta PN-a, integriraju strojno učenje i GIS analizu te korisnicima

vizualiziraju objektivno najopasnije dionice prometne mreže. Stoga izrada modela sigurnosti biciklističkog prometa, koji koristi strojno učenje za analizu faktora koji doprinose riziku i za preciznu predikciju žarišta PN-a, te GIS za njihovu vizualizaciju, predstavlja logičan i nužan korak prema proaktivnom upravljanju sigurnošću u urbanim sredinama.

2.6 Sinteza literature i pregled istraživačkih prilika

Prvi dio pregleda literature istražuje evoluciju metoda prikupljanja podataka o biciklističkoj aktivnosti, krećući se od tradicionalnih pristupa (ručno brojanje, automatski brojači, ankete) prema suvremenim izvorima temeljenim na digitalnim tragovima kretanja, poznatima kao MPP. Unatoč metodološkim izazovima i nedostatku reprezentativnosti, temeljni zadatak prikupljanja i obrade podataka biciklističkog prometa jest procjena PGDBP-a. PGDBP je ključna varijabla za razumijevanje tokova biciklističkog prometa i za izračun izloženosti biciklista riziku. Aktualna literatura jasno naglašava trend uporabe MPP-a u modeliranju volumena biciklističkog prometa. Kombinacija preciznosti tradicionalnih metoda brojanja sa širokim prostornim i vremenskim obuhvatom MPP-a, među kojima su podaci aplikacije Strava najzastupljeniji, daje najbolje rezultate u pregledanim istraživanjima. U nastavku je prikazan popis (Tablica 2) najznačajnijih znanstvenih članaka iz područja biciklističkog prometa i aktivnosti s fokusom na ciljanu varijablu istraživanja, metode modeliranje volumena (PGDBP) i uporabu MPP-a.

Tablica 2. Pregled najznačajnijih istraživanja iz područja podataka biciklističkog prometa

Autori (godina)	Područje istraživanja	Ciljana varijabla istraživanja	Upotreba MPP-a	Metoda izračuna volumena prometa (PGDBP)
Alattar i dr. (2021a)	Glasgow (UK)	Prostorna heterogenost	Strava	Modeliranje prostorne pogreške
El Esawey (2014)	Vancouver (Kanada)	Procjena PGDBP-a	Ne (brojači)	Mjesečni i sezonski faktori prilagodbe
Fan i Lin (2019)	Charlotte (SAD)	Modeliranje volumena	Strava	Linearna regresija i Ordered Probit modeli
Jestico i dr. (2016)	Victoria (Kanada)	Kartriranje aktivnosti	Strava	GLM regresija (predikcija niska/srednja/visoka)
Kothuri i dr. (2022)	6 gradova (SAD)	Volumen cijele mreže	Strava, StreetLight	Fuzija podataka (RF/Poissonova regresija)
Nordback i dr. (2013)	Boulder (SAD)	Kratkotrajno brojanje za procjenu PGDBP-a	Ne (brojači)	Satni, dnevni i mjesečni faktori
Roll i Proulx (2018)	Eugene (SAD)	PGDBP (iz kratkotrajnog brojanja)	Ne (brojači)	Regresijski modeli sezonske prilagodbe

Venter i dr. (2023)	Oslo (Norveška)	Validacija rekreacijske aktivnosti	Strava	Korelacijska analiza s referentnim brojačima
------------------------	--------------------	--	--------	---

Drugi dio pregleda literature istražuje ulogu platforme Strava kao vodećeg globalnog izvora MPP-a u istraživanju biciklističkog prometa. Strava je osnovana 2009. godine, a evoluirala je od SDM-e do ključnog alata za transportno planiranje lansiranjem usluge Strava Metro 2014., koja od 2020. nudi besplatan pristup anonimiziranim i agregiranim podacima biciklističke aktivnosti. Strava Metro primjenjuje metodu grupiranja, kojom zaokružuje broj aktivnosti na najbliži višekratnik broja pet, a vrijednosti manje od tri zaokružuje na nulu. Istraživanja pokazuju da ove mjere uzrokuju značajan gubitak informacija, što može iskriviti rezultate analize sigurnosti, osobito na dionicama s malim volumenom, zbog čega se preporučuje korištenje mjesečnih agregacija kako bi se smanjio utjecaj zaokruživanja. Većina istraživanja, u kojima se provodi validacija Strava podataka, provedena je u gradovima Sjeverne Amerike i sjeverne Europe, gdje su biciklistička kultura i infrastruktura na visokom nivou. Postoji manjak istraživanja koja testiraju reprezentativnost i upotrebljivost podataka Strave u gradovima poput Zagreba, gdje infrastruktura i navike korisnika nisu na istoj razini razvoja. S obzirom da Grad Zagreb raspolaže samo jednim stalnim automatskim brojačem biciklističkog prometa, nemoguće je ikakvo modeliranje sigurnosti na području grada bez integracije MPP-a. Treba napomenuti da podaci Strave i dalje snažno naginju rekreacijskom biciklizmu, ostavljajući prazninu u razumijevanju tokova putovanja na posao (utilitarne aktivnosti) u gradovima bez razvijene mreže kontinuiranih automatskih brojača, što predstavlja izazov u kontekstu ovog istraživanja. U literaturi je vidljiva primjena naprednih modela strojnog učenja, no njihova prenosivost između gradova je upitna – modeli specifični za grad u pravilu nadmašuju generalizirane modele, što ukazuje na potrebu za lokalnom kalibracijom. U nastavku je prikazana **Error! Reference source not found.**, u kojoj je popis znanstvenih radova kod kojih su Strava podaci korišteni kao glavni izvor podataka u istraživanju.

Tablica 3. Pregled najznačajnijih istraživanja u kojima su Strava podaci glavni izvor podataka

Autori (godina)	Područje istraživanja	Izvori podataka (osim Strave)	Korištene metode	Ciljana varijabla
Alattar i dr. (2021b)	Glasgow (UK)	OSM (indeks centralnosti mreže)	Model prostorne pogreške (SEM) i OLS	Volumen prometa na raskrižjima
Boss i dr. (2018)	Ottawa (Kanada)	Automatski brojači (11 lokacija)	Lokalni indikatori prostorne autokorelacije (LISA)	Prostorni obrasci promjena prometa

Broach i dr. (2023)	6 gradova (SAD)	StreetLight, automatski brojači, popis stan., DMR	Poissonova regresija	PGDBP
Conrow i dr. (2018)	Sydney (Australija)	Kratkotrajna brojanja, socioekonomski podaci	Bivariatna LISA analiza	Reprezentativnost uzorka
Kothuri i dr. (2022)	6 gradova (SAD)	StreetLight, automatski brojači, sociodemografski, okolišne varijable	Fuzija podataka (RF)	Volumen cijele mreže (PGDBP)
Kwigizile i dr. (2022)	Michigan (SAD)	Meteorološki, popis stan., infrastruktura, demografski (spol, rasa)	NB, RF, SVM, ANN, KNN	Satni volumen biciklista
Lin i Fan (2020)	Charlotte (SAD)	Popis stan., nagib terena, zoniranje, biciklistički sadržaji	Ordered Probit / Linearna regresija	Razina volumena biciklista
Mintu Miah i dr. (2022)	Portland (SAD)	Automatski brojači, sustav javnih bicikala, izgrađen okoliš, meteorološki podaci	Duboke neuronske mreže (DNN), PCA	Dnevni biciklistički promet (DBP, engl. Daily Bicyclist Traffic – DBT)
Nelson i dr. (2021)	5 gradova (SAD, Kanada)	Službeni brojači, uporaba zemljišta	Poissonova regresija + LASSO	Rekreativni vs. utilitarni obrasci
Raturi i dr. (2021)	Glasgow (UK)	Kordon brojanja biciklista	Grupiranje, Local Moran's I	Korelacija brojanja i grupiranih Strava podataka
Roy i dr. (2019)	Maricopa County (SAD)	Ručna kratkotrajna brojanja, popis stan., uporaba zemljišta	Poissonova regresija + LASSO selekcija	PGDBP

Treći dio pregleda literature uvodi koncept izloženosti, kao ključne mjere za razumijevanje sigurnosti prometa. Budući da se rizik matematički izražava kao omjer broja PN-a i mjere izloženosti, nužno je u okviru objektivne analize rizika izračunati izloženost. Stoga su navedene mjere koje se koriste za računanje izloženosti. S obzirom da dio istraživanja zanemaruje ovaj podatak, postoji opasnost izvlačenja pogrešnih zaključaka o opasnosti lokacija koje su možda sigurne, ali imaju visok volumen prometa. Dio poglavlja posvećen je fenomenu „*sigurnosti u brojevima*“ (SiN), koji pokazuje da rizik za pojedinca opada kako raste ukupni broj biciklista na cestama. U pregledu je dan velik broj istraživanja koja koriste podatke Strave kao validan surogat za izloženost, potvrđujući nelinearnu vezu između volumena prometa i učestalosti nesreća. Iz toga proizlazi da se razumijevanje sigurnosti ne može promatrati izolirano kroz broj PN-a, već kao funkcija izloženosti riziku. Stoga je opravdana upotreba fuzije podataka (tradicionalnih i MPP-ih) za izračun PGDBP-a kako detekcija žarišta PN-a ne bi bila pristrana. Ako se u kontekstu istraživanja potvrdi SiN efekt, tada je potrebno preispitati vanjske čimbenike koji mogu imati utjecaj na pojavu opasnih mjesta.

Četvrti dio pregleda literature detaljno opisuje metodologije modeliranja PN-a, razlikujući apsolutne pokazatelje (ukupan broj PN-a, ozlijeđenih ili poginulih) i relativne pokazatelje (stopa PN-a normalizirana izloženošću), pri čemu se potonji smatraju znanstveno pouzdanijima. Modeliranje se provodi na makro-razini (prometne zone, gradovi) ili mikro-razini (raskrižja, dionice), uz primarni cilj otkrivanja čimbenika koji utječu na pojavu PN-a i predviđanja učestalosti, težine ishoda i identifikacije žarišta. Poglavlje prati tehnološki razvoj od tradicionalnih statističkih metoda poput Poissonove i negativne binomne (NB) regresije, koje se suočavaju s problemima prekomjerne disperzije i viška nula, prema modernim metodama strojnog učenja. Ističu se algoritmi poput RF i XGBoost zbog njihove sposobnosti obrade nelinearnih odnosa i prostorne heterogenosti, što potvrđuju studije koje dokazuju da isti faktori rizika ne djeluju jednako na svim geografskim lokacijama. Korištenje naprednih algoritama u okviru modeliranja i identifikacije žarišta PN-a, omogućuje rješavanje problema neuravnoteženosti podataka (jer su PN-e relativno rijetke pojave) i preciznije predviđanje rizika. Integracija ovih modela s GIS-om ključna je za vizualizaciju rezultata, čime istraživanje prelazi u domenu praktičnog alata za podršku odlučivanju u urbanom planiranju. Na dnu ovog poglavlja prikazana je **Error! Reference source not found.**, u kojoj je popis znanstvenih radova iz područja sigurnosti biciklističkog prometa i modeliranja PN-a, s posebnim naglaskom na prostornu razinu istraživanja (makro-razina: prometna zona, administrativna jedinica, grid; mikro-razina: dionice, raskrižja), metodu modeliranja PN-a i ciljanu varijablu predviđanja (učestalost, težina, analiza čimbenika, rizik, stopa).

U petom poglavlju pružen je popis statističkih metoda koje su prethodile upotrebi strojnog učenja u prometnom inženjerstvu. Stavljen je naglasak na prijelaz s tradicionalnih statističkih modela (poput Poissonove i NB regresije) prema algoritmima strojnog učenja koji su sposobni modelirati nelinearne i kompleksne odnose unutar heterogenih prostornih podataka. Dok su klasični modeli često ograničeni pretpostavkama o raspodjeli podataka i linearnosti, algoritmi strojnog učenja pokazuju superiornu preciznost u predviđanju učestalosti i težine PN-a. U poglavlju je prikazana podjela metoda strojnog učenja prema prirodi procesa učenja i vrsti povratne informacije koju algoritam dobiva tijekom rada, te pregled glavnih kategorija, ključnih algoritama i njihova primjena u prometnom inženjerstvu. Integracija strojnog učenja i geografskih informacijskih sustava (GIS) predstavlja novu paradigmu u analizi prometne sigurnosti, omogućujući prelazak s reaktivnog saniranja opasnih mjesta na proaktivnu predikciju rizika. Strojno učenje donosi izazove poput interpretabilnosti (problem „crne kutije”), tj. otežano je razumijevanje uzročno-posljedične veze između ulaznih podataka i odluka (predikcija) koje donosi računalni model. Unatoč tome, razvoj metoda za procjenu važnosti varijabli omogućuje dublji uvid u to kako infrastrukturni i društveni faktori variraju kroz urbani

prostor. Stoga je primjena ovih naprednih tehnologija ključna za razvoj sustava potpore odlučivanju koji mogu optimizirati sigurnosna ulaganja i prilagoditi infrastrukturu najranjivijim sudionicama u prometu.

Tablica 4. Pregled najznačajnijih istraživanja sigurnosti biciklističkog prometa i modeliranja PN-a

Autori (godina)	Prostorna razina (područje istraživanja)	Izvori podataka	Metoda modeliranja PN-a	Ciljana varijabla
Alkaabi (2023)	administrativne jedinice (Abu Dhabi, UAE)	ankete vozača, policijski izvještaji	Moran's I, Getis-Ord Gi*	analiza čimbenika, žarišta
Ammar i dr. (2023)	dionice, raskrižja (SAD)	nacionalna baza PN-a (CRSS)	Multinomijalna logistička regresija	težina
Berhanu i dr. (2024)	dionice, raskrižja (Adis Abeba, Etiopija)	povijest PN, OSM cestovna mreža	Random Forest (RF)	stopa i učestalost
Chen i dr. (2020)	raskrižja (Portland i Eugene, SAD)	Strava Metro, automatski brojači	NB i Poisson (SPF)	učestalost
Ćosić (2017)	administrativne jedinice / Žarišta (Zagreb, HR)	MUP, GIS, GUP, brojanje prometa	Binarna logistička regresija	analiza čimbenika, žarišta
Ejikeme (2025)	dionice / Mreža (3 države, SAD)	podaci PN-a, meteorološki	XGBoost	težina
Ferster i dr. (2021)	grid (Ottawa, Kanada)	Strava Metro, povijesni podaci PN-a	Kernel Density Estimation (KDE)	rizik
Islam i dr. (2025)	raskrižja (Utah, SAD)	10-godišnji podaci PN-a, Strava	ZINB i Ordered Logit	učestalost i težina
Malaghan i dr. (2025)	grid (Dublin, Irska)	BikeMaps (MPP), tekstualni opisi	NLP, K-means, Getis-Ord Gi*	analiza čimbenika, žarišta
Moridpour i dr. (2023)	dionice, raskrižja (ACT, Australija)	gustoća sudara, EPDO metoda	KDE (Kernel Density Estimation)	analiza čimbenika, žarišta
Nordback i dr. (2014b)	raskrižja (Boulder, SAD)	volumen biciklista i motornih vozila	NB (SPF)	stopa i učestalost
Pillonnet i dr. (2024)	dionice (Lyon i Marseille, FR)	podaci PN-a, upitnici o kretanju	Generalizirani linearni model (GLM)	stopa
Raihan i dr. (2019)	administrativne jedinice (Florida, SAD)	Strava Metro, geometrija cesta	Zero-Inflated Negative Binomial (ZINB)	analiza čimbenika (CMF)
Saha i dr. (2018)	administrativne jedinice (Florida, SAD)	Strava Metro, demografija, promet	Poisson-lognormal (CAR model)	učestalost
Sener i dr. (2019)	administrativne jedinice (Austin, SAD)	Strava Metro, sociodemografija	NB i Binarna logistička regresija	učestalost i Težina
Strauss i dr. (2013b)	raskrižja (Montreal, Kanada)	GPS podaci, brojanje prometa	Bivariatni Bayesov Poisson	rizik i učestalost

Wang i dr. (2016)	raskrižja (Portland i Seattle, SAD)	Strava Metro	NB / Poisson (SPF)	učestalost
Wang i dr. (2024)	administrativne jedinice (ZCTA) (SAD)	cestovna mreža, POI, socioekonomija	GW-RF, RF, GWR, OLS	učestalost

3. PODRUČJE ISTRAŽIVANJA, PRIKUPLJANJE I OBRADA PODATAKA

3.1 Područje obuhvata i vremenski okvir istraživanja

Kao područje obuhvata istraživanja odabran je glavni grad Republike Hrvatske (RH) – Grad Zagreb. Kao samostalna teritorijalna i upravna jedinica sa statusom županije, Zagreb zauzima površinu od 641,24 km², što je oko 1,1 % teritorija RH. Prema konačnim rezultatima Popisa stanovništva iz 2021. godine, u gradu živi 767131 stanovnik, odnosno svaki peti stanovnik RH živi u Zagrebu. Prema službenom ustroju, na području grada nalazi se ukupno 68 naselja, pri čemu u samom urbanom području živi velika većina (86,5 %). U administrativnom i samoupravnom smislu, Grad Zagreb je podijeljen na 17 gradskih četvrti (GC) i 218 mjesnih odbora (MO), koji funkcioniraju kao oblici mjesne samouprave. Prosječna gustoća naseljenosti iznosi 1196 stan./km², pri čemu postoje izrazite prostorne varijacije; naime, u rubnim dijelovima gustoća je znatno manja, dok u središnjim gradskim četvrtima poput Donjeg Grada premašuje 10300 stan./km². (Grad Zagreb, 2022)

Prometna infrastruktura Grada Zagreba u razdoblju od 2019. do 2022. godine obuhvaćala je više od 2200 km prometnica te preko 400 objekata poput vijadukata, nadvožnjaka i podvožnjaka. Značajno je da više od 700 km, odnosno oko 90 % cestovne mreže, čine nerazvrstane ceste. Kapacitet glavnih gradskih avenija iznosi između 1000 i 3000 vozila po smjeru na sat, no osnovnu uličnu mrežu karakterizira nedovoljna propusnost tijekom vršnih opterećenja (Grad Zagreb, 2023). Jedan od glavnih pritisaka na infrastrukturu jest kontinuirani porast broja registriranih vozila. U 2019. bilo je registrirano 404893 vozila, u 2020. broj raste na 413117, u 2021. na 427381 (353142 osobnih automobila), a 2022. godine evidentirano je čak 442049 motornih vozila, od kojih su 364924 bila osobna vozila. Usporedbe radi, 2013. broj registriranih vozila iznosio je 337591 (Statistički portal Grada Zagreba, 2026). Dominacija automobila vidljiva je i u raspodjeli vrste prijevoza (engl. *modal split*), gdje se procjenjuje da automobili čine 46 % svih putovanja, javni prijevoz 40 %, hodanje 11 %, a bicikl tek oko 3 % (Integrirani promet zagrebačkog područja, 2020).

Vremenski okvir istraživanja je period od 2018. do 2022. godine, a ograničen je dostupnošću pojedinih skupova podataka. Treba naglasiti da su neki skupovi podataka dostupni i izvan tog perioda (za 2023. godinu), no oni neće biti upotrijebljeni u izradi rezultata istraživanja. Razlog tome je što nisu prikupljeni na isti način te shodno tome nisu konzistentni u odnosu na ostale podatke istraživanja. Također, treba uzeti u obzir da je 2020. bila obilježena pandemijom

uzorkovanom pojavom virusa COVID-19 zbog čega se ta godina mora promatrati i interpretirati s posebnim oprezom. Kao odgovor na posljedice pandemije većina država ograničila je kretanje i uvela tzv. *lockdown* (hrv. zatvaranje, karantena), koji je u RH bio na snazi od 22. ožujka do 11. svibnja. To je rezultiralo nezapamćenim smanjenjem volumena prometa u većini zemalja, a u mnogim državama volumen prometa nije dosegao pretpandemijske razine niti tijekom 2021. godine (Armoogum i dr., 2022). U kontekstu urbanog transporta, strah od zaraze i epidemiološke mjere rezultirale su drastičnim padom korištenja sustava javnog prijevoza. Zbog istih razloga se biciklistička aktivnost značajno povećala, što će biti vidljivo i kroz ovo istraživanje.

3.2 Prikupljanje i obrada podataka biciklističke aktivnosti

Podaci biciklističke aktivnosti ključni su za razumijevanje biciklističkih tokova na području prometne mreže nekog područja. Podaci aktivnosti su također, uz podatke o PN-ama u kojima su sudjelovali biciklisti, ključni u procesu modeliranja sigurnosti biciklističkog prometa, jer bez podatka o volumenu na pojedinoj dionici (segmentu) ili križanju nije moguće izračunati izloženost biciklista riziku. U suvremenom prometnom inženjerstvu, praćenje i analiza volumena biciklističkog prometa provode se korištenjem tradicionalnih metoda te novih pristupa temeljenih na MPP-ima. U ovom istraživanju korišteni su sljedeći podaci biciklističke aktivnosti:

- MPP-i biciklističke aktivnosti iz aplikacije Strava,
- podaci automatskog (statičnog) brojača biciklističkog prometa (tzv. *bike totem*), koji su ustupljeni od Grada Zagreba,
- podaci kratkoročnog ručnog brojanja prometa, prikupljeni terenskim istraživanjem.

3.2.1 Podaci biciklističke Strava aktivnosti

Postupak prikupljanja započinje s korisnicima SDM-a, koji sustavno stvaraju prostorno-vremenske podatke korištenjem pametnih mobilnih uređaja, odnosno mobilnih telefona i nosivih uređaja poput pametnih satova ili tzv. ciklokompjuteru (Lee i Sener, 2021), koji su opremljeni GNSS-om. Razvojem tih pametnih uređaja, pojavio se veliki broj različitih mobilnih aplikacija, no sredinom 2010-ih je Strava u potpunosti preuzela primat na tržištu SDM-a. Zbog toga platforma Strava Metro posjeduje globalno najopsežniju bazu biciklističke aktivnosti te se nameće kao glavni izvor podataka ovog istraživanja u analizi i modeliranju biciklističkog prometa.


Korisnik aplikacije s visokom frekvencijom bilježi sirove podatke (prostorne koordinate, vrijeme, prosječnu brzinu i prevaljenu udaljenost) te ih po završetku aktivnosti učitava i dijeli na mreži

(Lee i Sener, 2021). Kako bi ti sirovi GNSS tragovi bili upotrebljivi za znanstvena istraživanja i planiranje prometne infrastrukture, Strava provodi proces čišćenja, agregacije i preslikavanja na prometnu mrežu. Pojedinačne GNSS točke preslikavaju se (engl. *map matching*) i poravnavaju na linijsku geometriju temeljne karte, u pravilu korištenjem otvorenih prostornih podataka OSM sustava (McArthur i Hong, 2019). Tako obrađene izlazne podatke Strava Metro isporučuje (u trenutku skidanja podataka tijekom 2023.) grupirane u formatu linijskih segmenata (ulični segmenti prometne mreže, engl. *edge*), unaprijed definiranih ruta (najčešći linijski pravci između dvije odabrane točke mreže) i heksagona izvorišta i odredišta (tzv. OD podaci, engl. *origin and destination*). Segment čini pojedinačni dio ulice, staze ili puta koji služi kao osnovna mjerna jedinica. Segmenti se izvode iz geometrije objekata OSM baze podataka i obično predstavljaju linijski objekt na tlu (kao što je cesta, staza ili biciklistička staza) između dva čvora mreže. Jedna OSM linija može biti podijeljena na više segmenata. Kod podataka na razini segmenata, bilježi se ukupan broj biciklističkih aktivnosti (vožnji; u daljnjem tekstu koristit će se istoznačno oba izraza) koje su prošle preko određenog dijela ceste ili staze između dva sjecišta mreže (križanja). Ti se brojevi sumiraju i agregiraju u specifičnim vremenskim intervalima koji omogućavaju prostornu analizu po satima u danu, danima u tjednu (vikend/radni dan), mjesecima ili sumiranim godišnjim vrijednostima. Pri tome se ne vodi računa o smislenom povezivanju linija mreže u cjelinu, već se linija lomi na svakom ikada zabilježenom sjecištu, čime se gubi cjelovitost i logička povezanost prometne mreže.

Pored samog broja vožnji na segmentu, Strava algoritmima razdvaja rekreacijske aktivnosti od utilitarnih. Utilitarne aktivnosti se definiraju kao svakodnevna putovanja, što može uključivati odlazak na posao, u školu ili na fakultet, obavljanje svakodnevnih zadataka (kupovina i sl.) ili odlazak do drugih svakodnevnih odredišta (Strava Metro, 2026a). Razvrstavanje se provodi pomoću eksplicitnih korisničkih oznaka unutar same aplikacije, analizom ključnih riječi u nazivu vožnje, te prostornom logikom prepoznavanja putovanja kod kojih početna i završna točka (izvorište i odredište) nisu iste, već su međusobno udaljene više od 1 kilometra unutar definiranog vremenskog praga (Miah i dr., 2022). Važno je metodološko ograničenje u obradi i korištenju ovih podataka, a usko se tiče zaštite privatnosti korisnika. Uvažavajući osjetljivost lokacijskih podataka i regulative o zaštiti osobnih podataka (poput GDPR-a), Strava Metro potpuno depersonalizira bazu. Uz to, u srpnju 2018. godine implementirana je restriktivna strategija grupiranja podataka. Za svaki segment na mreži, ukoliko je zabilježen broj aktivnosti u promatranom vremenskom agregatu manji ili jednak 3, taj se broj zbog zaštite anonimnosti zaokružuje i isporučuje kao 0. Vrijednosti iznad 3 zaokružuju se na najbliži višekratnik broja 5 (primjerice, 4 vožnje postaju 5, 8 postaje 10). Iako ovaj postupak osigurava privatnost na mikrolokacijskoj razini, on uzrokuje značajan gubitak informacija, pogotovo kod kraćih

vremenskih perioda (Raturi i dr., 2021). Stoga su za odabrani period skinuti podaci na mjesečnoj i godišnjoj razini za cjelokupno područje istraživanja, kako ne bi došlo do pogrešaka koje mogu značajno iskriviti statističke analize na dionicama s malim volumenom prometa.

Podaci mjesečne i godišnje aktivnosti za sve segmente mreže skinuti su sa *Strava Metro* web-platfome, gdje se unutar sučelja karte (tzv. *Metroview*) odabire cjelokupno područje i pojedinačni period te šalje zahtjev za dohvaćanjem podataka (slika 1). Zbog velike količine podataka i mogućnosti preopterećenja poslužitelja (engl. *server*), mjesečni i godišnji podaci mogu se skinuti samo za period od jedne godine. Broj zahtjeva za skidanjem podataka također je ograničen na isključivo jedan, te je moguće novi zahtjev poslati tek dok se prethodni provede i traženi podaci budu dostupni za skidanje. Pregled zahtjeva i generiranje podataka za skidanje traje je u pravilu od 6 do 24 sata. Stoga je za skidanje mjesečnih i godišnjih podataka bilo potrebno oko 10 dana. Uz to su, za potrebe usporedbe i eventualne interpolacije (nedostajućih) podataka automatskog brojača prometa, skinuti i dnevni podaci za cjelokupnu mrežu. Za usporedbu i računanje faktora multiplikacije Strava podataka u odnosu na kratkotrajno ručno brojanje prometa, skinuti su satni i dnevni podaci segmenata mreže koji su bili obuhvaćeni ručnim brojanjem, ali samo za dan kada je provedeno brojanje (25. studeni 2021.). S obzirom da se dnevni podaci cjelokupne mreže mogu skidati maksimalno za tromjesečno razdoblje, bilo je potrebno oko 20 dana za prikupljanje tog seta podataka.



Slika 1. Strava Metro sučelje s mogućnošću pretrage, filtriranja i pregleda podataka na karti (Strava Metro, 2026c)

Treba naglasiti da Strava povremeno ažurira temeljnu kartu baziranu na OSM podacima, pri čemu svaki put dolazi do mijenjanja jedinstvenog identifikatora *osm_reference_id* za svaki OSM linijski segment mreže. Nakon toga prethodno skinute podatke nije moguće povezati s novim, što predstavlja značajan problem. U tijeku skidanja podatka je upravo došlo do takvog ažuriranja zbog čega je bilo potrebno sve podatke još jednom skinuti. Uz to su prilikom drugog skidanja bili dostupni samo podaci za period od 2019. do 2022. (kasnije i 2023.), odnosno prethodno skinuti podaci za 2018. nisu mogli biti upotrijebljeni u istraživanju. S obzirom da će se model sigurnosti i identifikacija žarišta PN-a izrađivati za vremenski period od 2018. do 2022. godine, biciklistička aktivnost za taj petogodišnji period biti će uprosječena (izračunom PGDBP-a) iz podataka Strave za period od 2019. do 2022. godine.

Kod skidanja podataka preuzima se *zip* datoteka koja sadrži *shapefile* datoteku (*shp* format) s geometrijom odabranog područja i *csv* datoteku sa atributnim (tabličnim) podacima za svaki pojedini segment mreže. *Csv* tablica i *shapefile* povezani su preko jedinstvenog identifikatora ulice koji se zove *edge_uid*. *Csv* datoteka ne sadrži koordinate, već isključivo statističke podatke o aktivnostima, korisnicima (Strava koristi izraz 'ljudi', engl. people) i brzini koji su podijeljeni u stupcima na 'forward' (engl. naprijed; označava aktivnosti u smjeru u kojem je ulica digitalizirana u OSM-u) i 'reverse' (engl. natrag; označava aktivnosti u suprotnom smjeru od onoga kako je ulica digitalizirana u OSM-u). Stupci koji u nazivu sadrže izraz 'trip' označavaju ukupan broj biciklističkih prolazaka na tom segmentu tijekom zadanog vremenskog okvira, a koji sadrže 'people' označavaju broj jedinstvenih osoba (korisnika) koje su ostvarile biciklističku aktivnost (prolazak) na tom segmentu tijekom zadanog vremenskog okvira (npr. 15 ljudi je moglo napraviti ukupno 25 prolazaka na jednom segmentu unutar tog vremenskog okvira). Za svaki redak datoteke su dostupni sljedeći stupci (Strava Metro, 2026b):

a) općeniti dio:

- *edge_uid* - identifikator za segment mreže,
- *activity_type* - vrsta aktivnosti, npr. vožnja (eng. ride),
- *year/month/date/hour* - jedan redak po zbrojenom (agregiranom) vremenskom okviru u ISO 8601 formatu (GGGG-MM-DD-SAT),
- *osm_reference_id* - odnosi se na OSM *way id* (identifikator linije) povezan s tim određenim segmentom (više segmenata može imati isti *osm_reference_id*),

b) broj prolazaka (aktivnosti):

- *forward_trip_count*, *reverse_trip_count* (ukupan br. prolazaka naprijed/natrag)
- *forward_commute_trip_count*, *reverse_commute_trip_count* (br. utilitarnih putovanja)
- *forward_leisure_trip_count*, *reverse_leisure_trip_count* (br. rekreacijskih putovanja)

- *total_trip_count* (ukupan broj prolazaka)
- *ride_count* (odnosi se na tradicionalne/klasične bicikle)
- *ebike_ride_count* (aktivnosti koje su navedene kao vožnje električnim biciklom)

c) broj ljudi (korisnika):

- *forward_people_count, reverse_people_count* (br. jedinstvenih ljudi)
- *forward_male_people_count, reverse_male_people_count* (br. muškaraca)
- *forward_female_people_count, reverse_female_people_count* (br. žena)
- *forward_unspecified_people_count, reverse_unspecified_people_count* (br. osoba neizjašnjenog spola)
- *forward_18_34_people_count, reverse_18_34_people_count* (od 18 do 34 godine)
- *forward_35_54_people_count, reverse_35_54_people_count* (od 35 do 54 godine)
- *forward_55_64_people_count, reverse_55_64_people_count* (od 55 do 64 godine)
- *forward_65_plus_people_count, reverse_65_plus_people_count* (od 65 i više godina)

d) prosječna brzina:

- *forward_average_speed, reverse_average_speed* (prosječna brzina izražena u m/s)

Preuzeti podaci zatim su vizualno i tehnički provjereni upotrebom geografskog informacijskog sustava (GIS) otvorenog koda QGIS 3.40 i Microsoft (MS) Excel-a. Pregledom skinutih csv datoteka godišnjih podataka svih segmenata mreže ustanovljeno je oko 100 000 redaka po datoteci. Svaka godina sadrži zasebnu datoteka u kojoj svaki segment zauzima jedan redak s podacima za tu godinu. Isto tako su kod mjesečnih podataka datoteke podijeljene za svaku godinu, ali je svaki segment zastupljen za svaki mjesec u godini s jednim unosom ukoliko je imao zabilježenu aktivnost. Za csv datoteke mjesečnih podataka ustanovljeno je oko 750 000 redaka. Kod dnevnih podataka svih segmenata mreže ustanovljeno je preko 1 000 000 redaka po datoteci, pri čemu svaka datoteka pokriva period od 3 mjeseca, a svaki redak predstavlja podatak aktivnosti po jednom segmentu mreže za jedan dan u godini. U *shapefile* datoteci spremljeni su prostorni podaci linijskih segmenata mreže u geografskom koordinatnom referentnom sustavu WGS 84 (World Geodetic System 1984), koji ima jedinstvenu EPSG¹ oznaku EPSG:4326. Svaki linijski objekt mreže predstavlja jedan redak u tablici pa se javlja problem odnosa *one-to-many* (1-M; iz engl. znači 'jedan prema više') ukoliko se želi povezati linijski objekt s pripadajućim atributima iz csv tablica. Zbog same veličine podataka i spomenutog odnosa podataka biciklističke aktivnosti, odlučeno je cjelokupne Strava podatke spremiti u relacijsku bazu

¹ EPSG (European Petroleum Survey Group) je standardizirani registar prostornih referentnih sustava (koordinatnih sustava), geodetskih datuma i kartografskih projekcija, koji svakom koordinatnom sustavu na svijetu dodjeljuje jedinstveni broj, poznat kao SRID (Spatial Reference System Identifier)

podataka PostgreSQL 16 (Postgres), koja omogućuje lakši i fleksibilniji pristup podacima bez redundancije. PostgreSQL (Postgres) je objektno-relacijski sustav za upravljanje bazama podataka (engl. *Database Management System* – DBMS) otvorenog koda, a zahvaljujući proširenju *PostGIS 3.5*, Postgres omogućuje rad s prostornim tipovima podataka, nudi prostorne funkcije za analizu koje se izvršavaju izravno na bazi pomoću SQL-a (engl. *Structured Query Language*), te prostorno indeksiranje koje je vrlo važno prilikom analize velike količine podataka (PostgreSQL, 2026).

Podaci su u Postgres bazu podataka izvezeni izravno iz QGIS-a, pri čemu je svaki set podataka (godišnji, mjesečni, dnevni) spremljen kao zasebna tablica. Jednako tako je spremljena i geometrija u zasebnu tablicu. S obzirom na gore navedenu podjelu podataka aktivnosti pojedinog segmenata na smjer naprijed i nazad, bio je potrebno zbrojiti smjerove kako bi se dobila ukupna utilitarna i rekreativna aktivnost po svakom segmentu mreže. Isto je napravljeno i za ukupan broj korisnika po spolu i dobnim skupinama. U sljedećem su koraku za svaku promatranu godinu kreirani tzv. pogledi (engl. *views*). Riječ je o virtualnim tablicama koje ne pohranjuju fizičke podatke, već pomoću pohranjenog SQL upita dinamički spajaju (engl. *join*) attribute Strava aktivnosti s geometrijom cestovnih segmenata preko zajedničkog primarnog ključa (engl. *primary key*). Ovakav je pristup omogućio izravno učitavanje slojeva biciklističke aktivnosti u GIS okruženje, čime su stvoreni preduvjeti za daljnju provedbu složenih prostorno-vremenskih analiza.

3.2.2 Automatski brojač

Automatski (stalni) brojač biciklističkog prometa postavljen je na nogostupu u Ulici grada Vukovara uz Park Stjepana Srkulja, neposredno do zgrade gradskog poglavarstva (slika 2, slika 3). Podaci automatskog brojača (tzv. totem) dobiveni su od Gradskog ureda za gospodarstvo, ekološku održivost i strategijsko planiranje. Za svaku godinu u periodu od 2019. do 2022. dobivena je po jedna datoteka u csv formatu koja sadrži datum, smjer A, smjer B i ukupan broj prolaza po danu. Za potrebe istraživanja nije bilo nužno, kao ni kod podataka Strava aktivnosti, poznavati smjer kretanja, već samo ukupan broj biciklističke aktivnosti.



Slika 2. Stalni automatski brojač biciklističkog prometa u Ulici grada Vukovara (Google, 2026.)

Analizom cjelovitosti prikupljenih podataka uočen je značajan prekid u mjerenjima od 22. svibnja do 23. lipnja 2020. godine, tijekom kojeg brojač nije registrirao jedan smjer kretanja ili je potpuno prestao bilježiti prolaskе. Dodatno, 28. lipnja zabilježen je samo jedan smjer, a utvrđen je i kraci dvodnevni prekid rada uređaja od 4. do 5. studenoga 2020. Usporedbom ovih podataka s dnevnim aktivnostima na platformi Strava za promatrani segment mreže, potvrđeno je postojanje biciklističkog prometa u tim danima.

S obzirom na to da svibanj i lipanj predstavljaju mjesece s uobičajeno visokim intenzitetom biciklističkog prometa, provedena je interpolacija podataka kako bi se spriječila pogrešna interpretacija rezultata. Za duži period izostanka podataka, izračunat je prosjek ukupne dnevne Strava aktivnosti ($PDBP_{Strava} = 27$) za referentno razdoblje od 30 dana prije i nakon prekida mjerenja. Interpolirana vrijednost, za pojedini dan izostanka podataka, dobivena je množenjem prosječnog broja prolazaka na brojaču u referentnom razdoblju od 30 dana prije i nakon prekida mjerenja s omjerom Strava aktivnosti na pojedini dan i prosječne Strava aktivnosti u referentnom razdoblju. Uz navedene dnevne podatke, za potrebe analize prikupljeni su i satni podaci za 25. studenoga 2021. godine, odnosno za dan kada je provedeno kratkotrajno ručno brojenje prometa.


3.2.3 Kratkotrajno ručno brojanje

S ciljem utvrđivanja stvarnog intenziteta biciklističkog prometa u urbanoj sredini i njegove usporedbe s MPP-a, provedeno je kratkotrajno (vizualno) ručno brojenje prometa. Istraživanje je obavljeno u četvrtak, 25. studenoga 2021., na devet različitih lokacija (tablica 5, slika 3). Kako bi se istodobno obuhvatile sve točke mjerenja, u terenskom istraživanju sudjelovali su studenti prve godine diplomskog studija Geodetskog fakulteta. Podaci su se bilježili u pripremljene zapisnike (vidi prilog 1) tijekom jutarnjih (7:00 – 9:00 h) i poslijepodnevni (15:00 – 17:00 h) vršnih opterećenja, pri umjereno oblačnom vremenu od prosječno 6°C u jutarnjim i 8°C u poslijepodnevnim satima. Radi detaljnije analize prometnih tokova, mjerenja su izvođena u 15-minutnim intervalima, a sudionici su se bilježili odvojeno prema spolu kako bi se dobio uvid u demografsku strukturu biciklista.

Tablica 5. Popis lokacija kratkotrajnog brojanja biciklističkog prometa

ID	Lokacija	Opis	N	E
1	Savska - Kršnjavog	JZ dio raskrižja	45,8072762	15,9674077
2	Selska - Horvaćanska	SI strana raskrižja	45,788419	15,9461744
3	Vukovarska	kod Lisinskog (obje strane ceste)	45,8006989	15,9795717
4	Most slobode (Z)	zapadna strana ceste, južno od Save	45,7874095	15,9796035
5	Most slobode (I)	istočna strana ceste, južno od Save	45,7874095	15,9798308
6	Savska 25	kod SC-a (obje strane ceste)	45,8039533	15,9655581
7	Savska - Slavonska	SI dio raskrižja	45,794463	15,9592341
8	Svetice - Budakova	JI dio raskrižja	45,8150715	16,013313
9	Jadranski most	istočna strana ceste	45,7851497	15,952231

Prilikom interpretacije rezultata terenskoga ručnog brojenja, nužno je u obzir uzeti izmijenjene prometne okolnosti uzrokovane zatvaranjem Savskog (pješačkog) mosta, koji u redovitim uvjetima predstavlja jedan od ključnih transversalnih koridora za nemotorizirani promet između sjevernog i južnog dijela Zagreba. Zbog sanacijskih radova, koji su se odvijali u razdoblju od 25. siječnja 2021. do 29. ožujka 2022. godine, došlo je do značajne redistribucije biciklističkih tokova prema alternativnim prijelazima preko rijeke Save. Prometno opterećenje djelomično je preusmjereno na Jadranski most, koji je se nalazi u neposrednoj blizini, ali je primarno namijenjen motoriziranom prometu, te djelomično na Most slobode, na kojemu je u navedenom razdoblju evidentiran iznadprosječan volumen biciklističke aktivnosti u odnosu na prethodne godine.



Slika 3. Karta lokacija kratkotrajnog ručnog brojanja i automatskog brojača prometa

U pogledu metodologije prikupljanja podataka na odabranim raskrižjima (Savska cesta – Ulica I. Kršnjavoga, Selska cesta – Horvaćanska cesta, Savska cesta – Slavonska avenija te Ulica Svetice – Ulica D. Budaka), promatranjem je bio obuhvaćen isključivo jedan od četiriju kvadranta (uglova) raskrižja. Na taj način su zabilježeni biciklisti u svim smjerovima kretanja, ali isključivo za dva od postojeća četiri kraka pojedinog raskrižja. S druge strane, na dionicama u Ulici grada Vukovara (u blizini Koncertne dvorane Vatroslava Lisinskog) te u Savskoj cesti 25 (kod Studentskog centra), terenskim su mjerenjem istodobno obuhvaćene obje strane prometnice. Slijedom navedenoga, kako bi se osigurala metodološka dosljednost prilikom komparativne analize s podacima iz aplikacije Strava, za te su lokacije uzete u obzir zbirne vrijednosti pripadajućih linijskih segmenata s obje strane ceste.

3.3 Prikupljanje i obrada podataka prometnih nesreća u kojima su sudjelovali biciklisti

Policijske su uprave u RH 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 (PP) Zagreb i na Policijsku postaju Sesvete. Ministarstvo unutarnjih poslova (MUP) službeno evidentira samo PN-e u kojima je obavljen policijski očevid.

Postupak evidencije temelji se na obveznom ispunjavanju Upitnika o prometnoj nesreći (UPN), a koji policijski službenik popunjava prema Znakovniku za popunjavanje UPN-a (vidi prilog 2). Treba uzeti u obzir da prema važećoj zakonskoj regulativi policija više ne provodi očevid niti službeno evidentira PN-e isključivo s manjom materijalnom štetom (Ćosić, 2017b). U takvim slučajevima sudionici samostalno ispunjavaju Europsko izvješće o nesreći, zbog čega podatke o tim događajima posjeduju isključivo osiguravajuća društva. Budući da u tim evidencijama ne postoje klasificirani podaci o sudjelovanju ranjivih skupina (pješaka i biciklista), znatan broj lakših PN-a ostaje potpuno isključen iz službenog informacijskog sustava MUP-a. Navedeno izravno pridonosi problemu podizvješćenosti (engl. *underreporting*), odnosno nedovoljnom prijavljivanju incidenata, i stvaranju tzv. „sive brojke“ u općoj statistici PN-a.

Podaci PN-a prvotno su dobiveni za zapadni i južni dio područja istraživanja od odgovornih osoba iz II. Postaje PP-e. Podaci su zaprimljeni u papirnatom obliku te u jednoj *Microsoft Excel* datoteci (*xlsx* format), pri čemu je svaka godina bila u zasebnoj proračunskoj tablici (engl. *sheet*). Razdoblje podataka obuhvaća kalendarske godine od 2018. do 2022., te prva tri mjeseca 2023. godine, koja zbog nepotpunosti nije mogla biti korištena u istraživanju. Područje obuhvata podataka PN-a u kojima su sudjelovali biciklisti u II. Postaji PP-e obuhvaća zapadni i južni dio grada, odnosno gradske četvrti Podsused – Vrapče, Črnomerec, Stenjevec, Trešnjevka – sjever, Trešnjevka – jug, Novi Zagreb – zapad, Novi Zagreb – istok i Brezovica. Treba napomenuti da se radi o internoj tablici II. Postaje PP-e, koja je stavljena na raspolaganje isključivo za ovo istraživanje, a ne o službenom podatku MUP-a.

U tablici za pojedinu godinu svaki redak označava jednu PN-u za koju su dostupne sljedeće informacije:

- *Redni broj* – broj PN-e u pojedinoj kalendarskoj godini
- *Datum/mjesec* – dan u mjesecu i mjesec PN-e (razdvojeno točkom),
- *Dan* – dan u tjednu (zapisano s prva dva slova imena, npr. „po“, „ut“ ili „sr“)
- *Sat* – interval od dva sata unutar dana (npr. „0810“ označava od 8 do 10 sati)
- *Vrsta nesreće* – šifra vrste PN-e prema Znakovniku za popunjavanje UPN-a (šifra za nalet na bicikl je „09“)
- *Greška sudionika* – šifra okolnosti PN-e prema Znakovniku za popunjavanje UPN-a (dijeli se na greške vozača, greške pješaka i ostale greške i propuste)
- *Alkohol* – sadrži vrijednost „1“ ukoliko je sudionik bio pod utjecajem alkohola
- *Poginule osobe* – dio tablice podijeljen na tri stupca kojima se označava je li vozač, putnik ili pješak poginuo u PN-i

- *Teško ozljeđene* – dio tablice podijeljen na tri stupca kojima se označava je li vozač, putnik ili pješak teško ozlijeđen u PN-i
- *Lako ozljeđene* – dio tablice podijeljen na tri stupca kojima se označava je li vozač, putnik ili pješak lakše ozlijeđen u PN-i
- *Kriv/Nije kriv* – dva odvojena stupca kojima se označava je li sudionik kriv ili nije (unosi se broj „1“ u pojedini stupac ovisno o krivnji)
- *Starost vozača bicikla* – broj godina vozača (ukoliko nije poznat uneseno je „NN“)
- *Tip vozila* – osam različitih stupaca u kojima se za svaki tip vozila unosi šifra prema Znakovniku za popunjavanje UPN-a (bicikl nosi šifru „51“)
- *Gradska četvrtak* – skraćeni oblik naziva gradske četvrti u kojoj se dogodila PN-a (zapis s dva slova, npr. „pv“ za Podsused – Vrapče)
- *Naziv Lokacije (ulica, raksrižje)* – adresa lokacije PN-e zapisana nazivom ulice i kućnim brojem (npr. „V. Vukova kod kbr. 6“, „M. Baštijana 2a“), nazivom dvaju ulica koje se križaju (korištenjem veznika „i“ ili crtice; npr. „Hermanova kod Ul. I.Trokut i III.Trokut“, „Zagrebačka c.-D.Golika“), ili nazivom ulice i brojem stupa javne rasvjete (SJR) u blizini kojeg se dogodila PN-a (npr. „Zagrebačka av. sjr br. 3953-154“).

Kako bi se podaci PN-a spremili u Postgres bazu podataka za daljnju obradu i analizu, bilo je potrebno sustavno provjeriti i strukturirati sve zapise, a potom pripremiti datoteke za unos u bazu podataka. Tablica s podacima za svaku promatranu godinu izvezena je u *csv* (engl. *comma-separated value*) formatu, koji se uobičajeno koristi za razmjenu tabličnih podataka jer sprema tablicu u tekstualno čitljivom obliku odvajajući stupce s podacima jednostavnim graničnikom (engl. *delimiter*), odnosno znakom poput zareza ili točke sa zarezom.

Prvi dio obrade atributnih podataka PN-a izveden je u Excelu. Kako bi se svaki zapis u promatranom periodu mogao zasebno spremati u tablicu unutar relacijske baze podataka, prvotno je bilo potrebno izraditi jedinstveni identifikator. Budući da izvorni zapis sadrži isključivo redni broj PN-e unutar pojedine kalendarske godine, novi je identifikator izrađen u novom stupcu *id* spajanjem godine i rednog broja (npr. PN-a u 2021. s rednim brojem 24 dobila je *id* vrijednost od „202124“). Stupac s datumom *Datum/mjesec* preuređen je kako bi odgovarao izvornom datumskom zapisu u Postgres bazi podataka. Tip podataka *date* za rad s datumima u Postgres-u prati ISO 8601 standard za zapis datuma, a sastoji se od 4 znamenke za godinu (YYYY; od engl. *year*, što znači godina) te po dvije znamenke za mjesec (MM) i dan u mjesecu (DD). Iz tog slijedi da je svaki zapis datuma morao imati oblik YYYY-MM-DD (npr. zapis datuma „17.03.“ u tablici s podacima iz 2019. prebačen je u „2019-03-17“). Nakon toga uslijedilo je čišćenje tekstualnih zapisa uklanjanjem dvostrukih razmaka proizašlih iz tipografskih pogrešaka.

Atributi vezani uz utvrđivanje krivnje, inicijalno podijeljeni u dva zasebna stupca, konsolidirani su u jedinstven stupac binarnoga (logičkog) tipa, s mogućim vrijednostima "1" (kriv) i "0" (nije kriv). Zadnji dio tekstualne obrade obuhvaćao je ujednačavanje naziva lokacija. Radi postizanja uniformiranosti podataka je izbačeni su iz naziva izrazi „kbr.“ i „kod kbr.“, a za nazive lokacija kod kojih se dvije ili više ulica križaju izbačen je veznik „i“ te je zamijenjen crticom.

Budući da zaprimljeni podaci PN-a nisu sadržavali prostorne koordinate pojedinog događaja, bilo je potrebno provesti postupak georeferenciranja, odnosno pridruživanja koordinata pojedinim PN-ama. Time bi se omogućilo daljnje provođenje prostornih analiza nad podacima PN-a. Prvotno je zamišljeno provesti postupak automatiziranog geokodiranja, kojim se u GIS okruženju adrese automatski transformiraju u točne geografske (ili pravokutne) koordinate. Međutim, zbog neadekvatnih rezultata prilikom geokodiranja adresa na hrvatskom jeziku, odlučeno je ručno unijeti svaku pojedinu lokaciju PN-e unutar GIS-a. Premda je postupak manualnoga unosa lokacija bio iznimno vremenski zahtjevan, pokazao se kao jedini pouzdan pristup za precizno dodjeljivanje prostornih koordinata svakoj pojedinačnoj PN-i. Tablica s podacima PN-a uvezena je u QGIS te konvertirana u *GeoJSON* format radi učinkovitijeg upravljanja geometrijom. U QGIS-u je postavljena kartografska podloga (OSM), a zatim je svakoj PN-i dodijeljena točkasta geometrija, čija je prostorna točnost neposredno verificirana usporedbom s javno dostupnim kartografskim servisima Google Maps i OSM.

Za zapise PN-a čije su lokacije definirane isključivo nazivom ulice i brojem SJR-e, provedeno je terensko istraživanje u svrhu pronalaska lokacije SJR i prikupljanja pripadajućih koordinata. Od ukupno 516 zabilježenih PN-a u cjelokupnom promatranom periodu (2018. – 2022.), takvih specifičnih zapisa je bilo ukupno 35. Terenska su mjerenja provedena upotrebom mobilne aplikacije *QField* (QField, 2026), koja omogućuje integraciju s radnim okruženjem QGIS-a te prikupljanje i upravljanje prostornim podacima upotrebom mobilnog uređaja. Većina lokacija je uspješno identificirana i georeferencirana, a zanimljivost je da je 11 od 35 lokacija bilo na prostoru ŠRC-a Jarun u Aleji Matije Ljubeka.

Određeni dio izvornih zapisa PN-a nije mogao biti uključen u istraživanje jer na temelju adrese nije bilo moguće jednoznačno odrediti lokaciju događaja. U tu su skupinu svrstani zapisi čije adrese nisu imale naveden kućni broj (npr. „sjeverni kolnik Zagrebačke avenije“, „Sarajevska cesta“, „makadamska staza južnog Savskog nasipa“, i sl.) ili su umjesto kućnog broja imali oznaku „bb“ (bez broja, npr. „Islandska bb“). Nakon provedenog postupka terenskog istraživanja, validacije i filtriranja, konačni skup podataka iz evidencije PN-a II. Postaje PP-e uvezen u Postgres bazu obuhvaćao je 516 PN-a za promatrani period istraživanja. Važno je napomenuti da je pet evidentiranih PN-a iz tog skupa podataka prostorno izvan područja

istraživanja, točnije na području Donjeg Stupnika. Međutim, zbog blizine i prometne povezanosti s prometnim tokovima analiziranog područja, navedeni su zapisi uključeni u istraživanje. Završni postupak unosa izveden je u QGIS-u izravnim povezivanjem na bazu podataka.

Tijekom istraživanja su, zahvaljujući suradnji s kolegama s Fakulteta prometnih znanosti (FPZ), dobiveni podaci za istočni dio Grada Zagreba, tj. za područje nadležnosti I. Postaje PP-e (obuhvaća gradske četvrti Gornji Grad-Medveščak, Donji Grad, Maksimir, Gornja Dubrava, Donja Dubrava, Peščenica-Žitnjak, Trnje i Podsljeme). Podaci su zaprimljeni u vektorskom *shapefile* (*shp*) formatu za razdoblje od 2016. do 2020. i u *csv* formatu za 2021. i 2022. godinu. Budući da je novi skup podataka obuhvaćao zapise za područja obiju postaja PP-e, provedena je usporedba s postojećom bazom podataka te su uočene razlike u količini i strukturi podataka te vrsti i nazivima atributa.


Također, nakon što je u QGIS-u učitana *shp* datoteka te filtrirana za razdoblje od 2018. do 2020., uočene su grube greške u prostornom položaju PN-a. Za čak 58 zapisa je lokacija točkastog objekta koji predstavlja PN-u bio značajno pogrešan. Stoga je, kao i u podacima II. Postaje PP-e, lokacija PN-a za sve objekte ručno georeferencirana. S druge strane, provjerom lokacija adresa unutar *csv* datoteke (2021. i 2022.) utvrđeno je da su geografske koordinate (u WGS84) ispravno unesene. Nažalost, komparacijom je utvrđen značajan manjak broja PN-a u skupu podataka za područje II. Postaje PP-e. Usporedbe radi, od postojećih 516 objekata je svega 313 objekata bilo sadržano u novom skupu podataka, a samo su tri nova objekta preuzeta za područje II. Postaje PP-e. Bez obzira na uočeni manjak, svi raspoloživi zapisi za područje I. Postaje PP-e uključeni su u daljnje istraživanje.

Prije samog unosa u jedinstvenu bazu bilo je potrebno ujednačiti nazive atributnih polja, a to je značilo izbaciti atributna polja koji nisu zajednička u oba skupa podataka te prilagoditi zaprimljene podatke postojećoj strukturi baze podataka. Primarni podaci (II. Postaja

PP) sadržavali su detaljniji opis lokacije PN-e, specifične podatke o biciklistu (alkoholiziranosti, dob), detaljniju klasifikaciju posljedica PN-e (broj ozlijeđenih osoba i klasifikacija ozljede na lakšu i težu) te točan naziv gradske četvrti. Za razliku od toga, podaci zaprimljeni od FPZ-a sadrže drugačiji zapis lokacije PN-e i detaljne informacije o vanjskim okolnostima PN-a (karakteristike ceste, stanje kolnika, signalizacija, uvjeti vidljivosti, javna rasvjeta, atmosferske prilike), no nemaju specifične podatke o sudionicima (alkohol, dob) te drugačije klasificiraju posljedice PN-a. Radi prevladavanja tih razlika i zadržavanja isključivo zajedničkih varijabli, provedena je standardizacija i generalizacija atributa na sljedeći način:

- kategorizacija težine PN-e (klasifikacija posljedica) svedena je na tri klase prema Znakovniku za popunjavanje UPN-a: 1 (s poginulim osobama), 2 (s ozlijeđenim osobama) i 3 (s materijalnom štetom),
- zapis točnog vremena nastanka PN-e (npr. „1124“ za 11:24 h) generaliziran je u dvosatne intervale (npr. „1012“ za razdoblje od 10:00 do 12:00 h),
- numerički zapis dana u tjednu preoblikovan je u standardizirani tekstualni kod (npr. iz „4“ u „če“ za četvrtak, iz „2“ u „ut“ za utorak),
- adresni podaci lokacije PN-e, izvorno razdvojeni u četiri odvojena stupca (Ulica 1, Kućni broj 1, Podbroj, Ulica 2), spojeni su u jedinstven tekstualni zapis,
- atributno polje izvorno nazvano „greška sudionika“ preimenovano je u „okolnosti“ radi postizanja terminološke dosljednosti baze.

Sveukupno je u bazu podatka PN-a u razdoblju od 2018. do 2022. preuzeto 516 zapisa iz prvog izvora i 313 zapisa iz drugog skupa podataka. Time je za područje Grada Zagreba formiran jedinstveni skup podataka od 829 PN-a za promatrani period istraživanja (slika 4).



Slika 4. Prometne nesreće u kojima su sudjelovali biciklisti za razdoblje 2018.-2022.

3.4 Prikupljanje i obrada ostalih podataka istraživanja

Uz osnovne podatke o biciklističkoj aktivnosti i PN-ama, u istraživanju je korišten širok spektar sekundarnih prostornih i atributnih podataka koji obuhvaćaju prometnu infrastrukturu, demografske karakteristike, stvarno korištenje (uporabu) zemljišta, obilježja izgrađenog okoliša i meteorološke uvjete. Prilikom odabira izvora podataka, glavni cilj bio je primarno koristiti javno dostupne baze otvorenih podataka (engl. *open data*). Pri tome su odabrani prostorni podaci koji su tematski vezani za promet i vanjske čimbenike za koje se pretpostavlja da izravno ili neizravno utječu na dinamiku biciklističkog prometa i vjerojatnost nastanka PN-a u kojima sudjeluju biciklisti.

3.4.1 Administrativne granice

Osnovni podatak granice područja istraživanja jest administrativna (županijska) granica Grada Zagreba te granice jedinica lokalne samouprave za gradske četvrti (GC) i mjesne odbore (MO). Ti prostorni podaci skinuti su s Portala otvorenih podataka (Portal otvorenih podataka, 2026) u *shapefile* (*shp*) formatu. U administrativnom smislu, GC predstavlja viši oblik mjesne samouprave uspostavljen za područje koje čini zaokruženu gradsku, gospodarsku i društvenu cjelinu, povezanu zajedničkim interesima građana. Preuzeti skup prostornih podataka GC-i sastoji se od 17 poligonskih objekata s pripadajućim atributnim podacima (matični broj, naziv). Nižu razinu administrativne podjele čine MO-i, čiji vektorski skup podataka za područje Grada Zagreba obuhvaća 218 poligonskih objekata. Ovaj se oblik mjesne samouprave osniva za jedno naselje, više međusobno povezanih manjih naselja ili specifičan dio grada koji, u odnosu na okolni prostor, funkcionira kao neovisna i jasno razgraničena prostorno-funkcionalna cjelina. Podaci granica Grada Zagreba potom su konvertirani u GeoPackage (*gpkg*) format radi lakšeg rukovanja. Razlog tome je što *gpkg* format pohranjuje sve atributne i prostorne podatke unutar jedne (*SQLite*) datotetke, za razliku od *shp* formata koji se sastoji od minimalno tri do osam odvojenih datoteka. Uz to, *gpkg* ne podliježe strogim ograničenjima *shapefilea*, npr. nema ograničenje veličine datoteke na 2 GB te dozvoljava duljinu naziva atributnih stupaca veću od 10 znakova, što znatno olakšava strukturiranje baze.

3.4.2 Infrastrukturni podaci

Podaci iz OSM baze strukturirani su na temelju sustavu oznaka, koji funkcioniraju po principu parova *key:value* (od engl. za ključ:vrijednost). Pri tome *key* definira tematsku cjelinu ili kategoriju prostornog objekta (npr. *highway* za prometnu infrastrukturu, *amenity* za objekte društvenog sadržaja i usluga, i sl.), a *value* pobliže specificira podvrstu ili svojstvo unutar

tematske cjeline (npr. *cycleway* za biciklističku stazu, *fuel* za benzinsku crpku i sl.). Za preuzimanje OSM podataka korišten je QGIS dodatak (engl. *plugin*) *QuickOSM*, koji služi kao grafičko korisničko sučelje za slanje strukturiranih upita prema poslužitelju *Overpass API*. Postupak preuzimanja obuhvaća formuliranje atributnog upita, odnosno filtriranje željenog *key:value* para, zatim definiranje prostornog obuhvata (upisivanjem toponima ili prostorne jedinice, opsegom karte ili granicom postojećeg poligonskog sloja) te odabir tipa geometrije (točka, linija, poligon) vektorskog sloja koji se želi preuzeti. Preuzeti slojevi automatski su učitani u QGIS radno okruženje pokretanjem upita, a potom su lokalno pohranjeni u *GeoPackage* formatu.

Podaci biciklističke infrastrukture preuzeti su iz dvaju neovisnih izvora: OSM-a i web-portala GeoHub Zagreb. GeoHub je web-portal Grada Zagreba koji služi kao katalog podataka putem kojeg se mogu pretraživati, pregledavati i preuzimati prostorni podaci u različitim formatima (*csv*, *kml*, *shp*, *gdb*, *GeoJSON*, *wfs*) prema kategorijama (GeoHub Zagreb, 2026). Nakon usporedbe utvrđeno je da postoje minimalna odstupanja u geometriji pojedinih biciklističkih prometnica, većinom na području većih raskrižja (primjerice, raskrižje Heinzelove ulice i Slavonske avenije). Uz to, OSM sadrži veliki broj šumskih (biciklističkih) staza, namijenjenih brdskom biciklizmu, koji izlaze iz okvira ovog istraživanja. Iz tog razloga su geometrije obaju izvora spojene u jedan zajednički vektorski sloj koji sadrži geometriju biciklističke infrastrukture na području istraživanja. Pri tome su isključene neformalne i šumske staze koje su dio park-šuma unutar grada ili Parka prirode (PP) Medvednica, no to se ne odnosi na asfaltiranu Sljemensku cestu unutar PP Medvednica kao i savski nasip s obzirom na njihovu prometnu važnost.

Prilikom objedinjavanja podataka, podaci s web-portala GeoHub određeni su kao primarni izvor jer sadrže kvalitetniju i potpuniju atributnu tablicu od OSM-a (kategorija bic. prometnice, lokacija, završni sloj, MO i GC unutar kojih se infrastruktura nalazi). Tako izvedeni podaci bic. infrastrukture Grada Zagreba ukupne su duljine od gotovo 274 km (tablica 6) što je u skladu sa službenim podacima (273,8 km). U tablici 11 prikazana je statistika po kategoriji (tipu) bic. prometnice. Većinu bic. prometnica čine pješačko-biciklističke staze (187,4 km), dok kategorija biciklističkih puteva, koju isključivo čine sjeverni i južni savski nasip, ima prosječno najdulji biciklistički pravac (1944,5 m).

Tablica 6. Biciklistička prometnice na području istraživanja

ID	Kategorija	Br. objekata	Duljina biciklističkog pravca (m)			
			Ukupno	Prosjek	Min	Max
BP	biciklistički put	26	50556,3	1944,5	121,2	5271,0
BS	biciklistička staza	2	130,4	65,2	8,2	122,2

BT	biciklistička traka	53	9569,3	180,6	0,1	6321,2
CM	cesta – mješoviti promet	164	23207,4	141,5	1,3	2334,8
PB	pješačko-biciklistička staza	2663	187429,0	70,4	0,1	1505,7
JS	javne stube	12	104,2	8,7	0,2	14,9
PO	pothodnik	6	277,5	46,2	18,0	65,6
	nije poznato	85	2681,2	31,5	2,1	273,9
sve biciklističke prometnice		3011	273955,4	90,98	0,10	6321,2

Prema Pravilniku o biciklističkoj infrastrukturi (NN 28/16), biciklističke prometnice u RH klasificiraju se u nekoliko osnovnih kategorija, ovisno o tehničkim karakteristikama površine te razini odvojenosti od motornog i pješačkog prometa. Navedeni zakonodavni okvir definira biciklističku cestu kao prometnicu s uređenom kolničkom konstrukcijom (asfalt, beton i sl.) smještenu izvan profila javne ceste, dok se biciklistički put (BP) odnosi na sličnu prometnicu, ali izvedenu od šljunka ili srodnih propusnih materijala (primjer je savski nasip). Na području Grada Zagreba ne postoji tip biciklističke ceste koji je smješten izvan profila javne ceste, već je uobičajen slučaj ceste za mješoviti promet (CM) s ukupnom duljinom prometnica većom od 23 km. CM je vrsta bic. prometnice koja se definira kao prometna površina na kojoj se zajednički odvija biciklistički i motorni promet. I dok bi se u urbanom okruženju najčešće trebala primjenjivati biciklistička staza (BS), koja podrazumijeva prometnu površinu infrastrukturno i visinski odvojenu od kolnika namijenjenog motornim vozilima, u Zagrebu su na taj način izvedene samo dvije bic. prometnice. S druge strane, biciklistička traka (BT) predstavlja posebno obilježen dio samog kolnika namijenjen isključivo kretanju bicikala. Uz navedene tipove bic. prometnica, Pravilnik prepoznaje i mješovitu pješačko-biciklističku stazu (PB) kao integriranu prometnu površinu namijenjenu zajedničkom kretanju pješaka i biciklista (slika 5).



Slika 5. Tip biciklističke prometnice: a) BP, b) BT, c) CM, d) PB (Google, 2026)

Cestovna mreža za područje Grada Zagreba preuzeta je iz OSM-a putem QGIS dodatka *QuickOSM* upotrebom oznake (*key*) *highway*, koja obuhvaća kategoriju podataka prometne infrastrukture. Pri tome su odabrani linijski objekti svih potkategorija (vrijednosti), a pregledom atributne tablice su unutar QGIS-a filtrirane one vrijednosti koje su od interesa za istraživanje. Prilikom analize cestovne mreže važno je razlikovati da službena kategorizacija cesta u RH ne odgovara funkcionalnoj klasifikaciji u OSM-u (tablica 7). Prema Zakonu o cestama, javne se ceste dijele na autoceste, državne, županijske i lokalne ceste. Međutim, na području Grada Zagreba gotovo cjelokupna mreža administrativno potpada pod nadležnost lokalne samouprave te se pravno klasificira kao mreža nerazvrstanih cesta, neovisno o stvarnom prometnom opterećenju pojedinih dionica. Nasuprot tome, OSM koristi hijerarhijsku funkcionalnu klasifikaciju kojom se detaljnije definira svojstvo ceste u urbanom kontekstu. Prema OSM-u kategorija *motorway* označava autoceste, a na području istraživanja obuhvaća dio autoceste A1 i većinu obilaznice. U kontekstu istraživanja autoceste nisu uzete u obzir jer tamo vožnja biciklom zakonski nije dozvoljena. U kategoriju *primary* spadaju isključivo državne ceste koje prolaze rubnim dijelovima grada (ili ulaze u grad) te nisu značajne za ovo istraživanje, a na području grada obuhvaćaju cestu iz Sesveta prema Sv. Ivanu Zelini i Mariji Bistrici te dio tzv. stare karlovačke kod Lučkog. U cestovnoj mreži grada najvišu razinu čini kategorija *secondary*, koja obuhvaća glavne

gradske avenije, tranzitne koridore i arterijske pravce velikoga kapaciteta. U kategoriju *tertiary* spadaju sabirne ceste koje prikupljaju promet iz stambenih zona i kvartova i kanaliziraju ga prema najprometnijim ulicama. Većina ulične mreže unutar stambenih blokova nalazi se u kategoriji *residential* te je to ujedno i kategorija s daleko najvećom ukupnom duljinom (1678,5 km). Druge po ukupnoj duljini su uslužne i servisne prometnice (prilazi stambenim, industrijskim ili trgovačkim objektima, parkirališta i sl.) koje se nalaze unutar *service* kategorije. Posljednju kategoriju *unclassified* čine prometnice najniže funkcionalne važnosti (ne odnosi se na nerazvrstane ceste).

Tablica 7. Cestovna infrastruktura na području istraživanja

Kategorija ceste (OSM)	Broj linija (objekata)	Ukupna dužina (m)	Prosječna dužina linije (m)
motorway	560	134592	240,3
primary	109	24926	228,7
secondary	3058	426024	139,3
tertiary	2419	427760	176,8
residential	9239	1678490	181,7
service	17285	1204930	69,7
unclassified	968	236326	244,1

Daljnje prikupljanje podataka prometne infrastrukture putem OSM-a obuhvatilo je preuzimanje cestovnih prijelaza (oznaka *highway=crossing*). Na promatranom području identificirano je ukupno 8080 objekata točkaste geometrije od kojih he 61115 posjedovalo specifičan atribut *crossing*, koji detaljnije definira tip horizontalne i vertikalne signalizacije na prijelazu. Temeljem tog atributa omogućena je klasifikacija prijelaza na signalizirane, odnosno one regulirane semaforima (*traffic_signals*), te nesignalizirane prijelaze (zabilježene pod vrijednostima *uncontrolled*, *zebra*, *marked* i *unmarked*). Iz skupa je također dodatno izdvojeno i identificirano 1347 prijelaza koji nose oznaku namjene za biciklistički promet (engl. *cycle designated*).

Dodatno su iz područja prometne infrastrukture putem OSM-a preuzeti podaci tramvajske infrastrukture (oznaka *railway=tram*). S obzirom da prisutnost tramvajskih tračnica na prometnicama sigurnosni rizik u kontekstu biciklističkog prometa (Reynolds i dr., 2024), prvenstveno zbog opasnosti od proklizavanja ili zaglavljivanja kotača bicikla unutar žlijeba tračnice, provedena je atributna klasifikacija tramvajskih linija na one koje se nalaze na prometnici i one koje su segregirane van prometnice. Podjela je izvedena na temelju atributa *tracks*, pri čemu upisana vrijednost *road* označava tramvajsku trasu integriranu u cestovnu prometnicu.

3.4.3 Demografski podaci

Demografski podaci Grada Zagreba prikupljeni su jednim dijelom iz javno dostupnih skupova podataka sa službenih mrežnih stranica Državnog zavoda za statistiku (DZS). Drugim dijelom su podaci dobiveni od iste institucije na zahtjev putem službenog Obrasca za izdavanje podataka (prilog 3). Podaci strukture stanovništva za GC-i temelje se na podacima Popisa stanovništva iz 2021. te su dostupni na web-stranicama DZS-u. Iz dostupnih podataka preuzeti su podaci u *xls* formatu o ukupnom broj stanovnika, te njihovoj dobnoj i spolnoj strukturi. Budući da u trenutku provođenja ovog istraživanja DZS još nije objavio podatke obrazovne strukture iz Popisa 2021., podaci obrazovne strukture stanovništva po GC-ima preuzeti su iz prethodnog popisa stanovništva (2011. godine). Podaci o obrazovnoj strukturi agregirani su po gradskim četvrtima te obuhvaćaju udjele stanovništva sa završenom osnovnom školom, srednjom školom, visokim obrazovanjem te znanstvenim stupnjem doktorata. Podaci za područje MO-a ustupljeni su izravno od DZS-a putem zahtjeva, a obuhvaćaju ukupan broj stanovnika po MO-u te distribuciju prema dobi i spolu. Na temelju ukupnog broja i površine pojedine GC-i i MO-a izračunata je u QGIS-u gustoća stanovnika po km².

3.4.4 Podaci uporabe zemljišta i izgrađenog okoliša

Vektorski podaci o stvarnom korištenju (uporabi) zemljišta preuzeti su sa web-portala GeoHub. Putem mrežnog servisa WFS (*Web Feature Service*) dohvaćen je poligonski sloj u QGIS-u koji je potom konvertiran u *gpkg* format i spremljen lokalno za daljnju analizu. Uz podatke o uporabi zemljišta, s GeoHub-a preuzeti su i podaci točkaste geometrije (u *GeoJSON* formatu) koji definiraju lokacije objekata izgrađenoga okoliša na području Grada Zagreba. Pri tome su odabrani slojevi koji obuhvaćaju infrastrukturu obrazovnih institucija (osnovne i srednje škole, visokoškolske ustanove te studentska naselja), točke javnoga gradskog prijevoza (autobusna i tramvajska stajališta), specifičnu biciklističku infrastrukturu (sustav javnih bicikala i lokacije javnih parkirališta za bicikle) te objekte sportske i rekreacijske namjene.

3.4.5 Meteorološki podaci

Prikupljanje povijesnih meteoroloških podataka bilo je motivirano činjenicom da padaline i temperatura zraka izravno utječu na volumen biciklističkog prometa, a time i na nastanak te posljedice PN-a. Stoga je bilo potrebno prikupiti povijesne meteorološke podatke o temperaturama i padalinama na dnevnoj razini kako bi se ispitala njihova korelacija s učestalošću biciklističkoga prometa i PN-a. Ti podaci preuzeti su iz otvorene globalne baze klimatskih i meteorološki podataka pod nazivom *Meteostat*, koja agregira meteorološke podatke iz velikog broja mjernih postaja diljem svijeta, oslanjajući se na službene izvore poput američke

organizacije NOAA (National Oceanic and Atmospheric Administration), te njemačkog (Deutscher Wetterdienst) i kanadskog (Environment Canada) meteorološkog zavoda. Meteostat ima za područje Zagreba dostupne podatke sa četiri meteorološke postaje: Maksimir, Grič, Pleso i Puntijarka (planinarski dom blizu Sljemena). Pri tome su postaje Pleso i Puntijarka isključene jer se Pleso nalazi izvan područja istraživanja, dok Puntijarka zbog svoje mikrolokacije na Medvednici (značajna razlika u nadmorskoj visini te udaljena od centra grada) nije reprezentativna za klimatske uvjete unutar gradske sredine.

Pretragom raspoloživosti podataka utvrđeno je da za cjelokupno promatrano razdoblje (2018. – 2022.) isključivo postaja Grič (međunarodna oznaka 14236) posjeduje cjelovite dnevne podatke meteoroloških mjerenja. Podaci za navedenu postaju preuzeti su u csv formatu, nakon čega su iz izvorne tablice izdvojene sljedeće varijable: datum, prosječna, minimalna i maksimalna temperatura, ukupne padaline, količina snijega (visina pokrova). Prije izvoza csv tablice u Postgres bazu bilo je potrebno datumsko polje prilagoditi unosu kao i u slučaju podataka PN-a.

4. MODELIRANJE VOLUMENA BIKIKLISTIČKOG PROMETA

4.1 Statistika godišnje i mjesečne Strava aktivnosti


Prije nego je izvedena prostorno-vremenska analiza Strava aktivnosti za područje istraživanja, izračunati su statistički pokazatelji godišnje i mjesečne aktivnosti te broja korisnika Strava aplikacije za razdoblje dostupnosti podataka od 2019. do 2023. godine. Podaci za 2023. godinu prikazani su u statističkoj analizi kao pokazatelj nastavka trenda biciklističke aktivnosti, no nisu korišteni u kasnijem istraživanju za izračun PGDBP-a.

Tablica 8. Ukupna godišnja Strava aktivnost u razdoblju od 2019. do 2023. godine.

Godina	Ukupna	Rekreativna	%	Utilitarna	%
2019	133973	74021	55,25	59952	44,75
2020	183405	118940	64,85	64465	35,15
2021	178086	110464	62,03	67622	37,97
2022	189337	106636	56,32	82701	43,68
2023	186684	109458	58,63	77226	41,37

Tablica 8 prikazuje godišnju statistiku ukupne, utilitarne i rekreativne biciklističke aktivnosti zabilježene u Stravi na području Zagreba u razdoblju od 2019. do 2023. godine. U 2020. zabilježen je nagli porast ukupnog broja aktivnosti na 183405 što predstavlja rast od 36,9 % u odnosu na prethodnu godinu. Visoki rast primarno je vođen rekreativnim aktivnostima koje su skočile s 74021 na 118940, čineći vrhunac od 64,85 % svih aktivnosti u toj godini. Razlog tome mogao bi biti utjecaj pandemije COVID-19 i restriktivnih mjera, kada su se građani masovno okrenuli rekreaciji na otvorenom. Nakon pandemijskog rasta, ukupna aktivnost se nije vratila na razine prije 2020., već je ostala stabilna i visoka (iznad 178000 godišnje), dosegnuvši vrhunac u 2022. s 189337 aktivnosti.

Isto kao i aktivnost, broj korisnika Strave ostao je stabilan nakon pandemije, što se očitava narančastom linijom na slici 6. Dok su rekreativne aktivnosti blago opale nakon 2020. godine, utilitarne su zabilježile snažan rast te dosegnule vrhunac u 2022. s 82701 vožnjom (udio od 43,68 %), što sugerira da su mnogi korisnici aplikacije trajno integrirali biciklizam u svoje svakodnevne prijevozne navike.



Slika 6. Ukupna godišnja Strava aktivnost u razdoblju od 2019. do 2023.

U tablici 9 prikazan je rast prosječnog broja aktivnosti po segmentu za cjelokupno područje istraživanja. Tablica nudi detaljan uvid u distribuciju aktivnosti kroz četiri ključne statističke mjere: prosjek (aritmetičku sredinu), medijan (srednju vrijednost), standardnu devijaciju (u tablici označeno grč. slovom sigma „ σ “) i maksimum (najveći zabilježeni broj prolaza na jednom segmentu). Prosječan broj prolazaka po pojedinačnim segmentima porastao je s 515,08 u 2019. na preko 700 u 2021. godini, nakon čega se stabilizirao na oko 663 u 2023. To ukazuje na općenito veću gustoću biciklističkog prometa, osobito na visokofrekventnim dijelovima mreže. Najfrekventniji segment mreže u 2019. je bilježio gotovo 31000 aktivnosti dok je u 2023. skočio na preko 72000.

Tablica 9. Statistika ukupne Strava aktivnosti po svim segmentima mreže

Godina	Prosjek	Medijan	σ	Max
2019	515,08	120	1148,45	30905
2020	693,26	150	1546,43	41580
2021	706,93	155	1570,55	43220
2022	666,27	145	1458,93	36915
2023	663,35	145	1828,63	72055

Razlika u prosječnom broju aktivnosti koje su označene kao utilitarne ili rekreativne prikazana je u tablici 10. Usporedna godišnja statistika dviju vrsta biciklističkih aktivnosti na segmentima mreže prikazuje značajno veću upotrebu Strave u rekreativne svrhe u svim promatranim godinama i kroz sve statističke pokazatelje. Prosječan broj rekreativnih aktivnosti po segmentu mreže kreće se od 360 (2019.) do maksimuma od 540 u 2020., dok se za utilitarne aktivnosti kreće u znatno manjem rasponu od 152 (2020.) do 190 (2022.). Medijan aktivnosti (koji bolje opisuje tipičan segment jer eliminira utjecaj ekstremno popularnih lokacija) za rekreaciju iznosi

između 75 i 115, dok za utilitarne aktivnosti iznosi tek 25 do 30. To znači da uobičajeni (prosječni) segment mreže bilježi 3 do 4 puta više rekreativnih nego utilitarnih aktivnosti. Iz tablice se iznova jasno očitava porast rekreativne te stagnacija (blagi pad) utilitarne aktivnosti u pandemijskoj 2020. godini. Utilitarne aktivnosti postižu maksimum u 2022., dok su rekreativne na vrhuncu 2020. i 2021., a potom su se smanjile, ali su ostale na razini višoj nego prije 2020. Standardna devijacija (σ) je u svim godinama višestruko veća od prosjeka, što u kombinaciji s ogromnim maksimalnim vrijednostima ukazuje na to da je biciklistički promet izrazito koncentriran. To ukazuje na nekoliko iznimno popularnih koridora (biciklističke magistrale i popularna rekreacijska odredišta) koji privlače golemu većinu prometa, dok većina ostalih segmenata mreže bilježi vrlo skroman promet (medijan od samo 30 za utilitarne i 100 za rekreativne).


Tablica 10. Statistika ukupne utilitarne i rekreativne Strava aktivnosti po svim segmentima mreže

Godina	Prosjek		Medijan		σ		Max	
	Util	Rekr	Util	Rekr	Util	Rekr	Util	Rekr
2019	154,32	360,77	25	75	362,11	937,51	6850	28840
2020	152,35	540,94	25	115	348,32	1318,01	5520	39745
2021	167,92	539,04	25	115	400,40	1316,60	5895	41335
2022	190,44	475,85	30	100	462,10	1160,65	7765	35120
2023	177,55	485,82	30	100	438,83	1603,11	6970	69665


Statistički prikaz mjesečne distribucije ukupne rekreativne i utilitarne aktivnosti vidljiv je na dijagramima na slikama 7 i 8. Pri tome je izražena sezonalnost koja se očituje niskom količinom aktivnosti u zimskim mjesecima, proljetnim skokom aktivnosti i ljetnim vrhuncima. Također je jasno izraženo znatno odstupanje u broju zabilježenih ukupnih aktivnosti tijekom 2019. (slika 7), izrazito između travnja i rujna. Analizirajući navedene dijagrame moglo bi se zaključiti da se najviše aktivnosti tijekom promatranog razdoblja odvijalo u svibnju, pogotovo jer su svibanj 2020. (24019) i 2022. (24233) mjeseci s apsolutnim maksimumom aktivnosti, no ukupno gledano lipanj bilježi najviše aktivnosti s ukupno 104729 vožnji (62460 rekreativnih i 42269 utilitarnih). Izrazito značajno je da travanj 2020. ima najviši broj rekreativnih aktivnosti (16779) u čitavom razdoblju te je, gledano prema vrsti aktivnosti, mjesec s najvišim brojem zabilježene rekreativne aktivnosti. Uz to travanj 2020. bilježi ujedno i najniži broj utilitarnih aktivnosti uspoređujući s 4. mjesecom ostalih godina. Navedeno je posljedica pandemijskog zatvaranja koje je bilo na snazi tijekom čitavog mjeseca 2020. godine.

Najniža razina aktivnosti u razdoblju od 2019. do 2023. bilježi se tijekom prosinca s ukupno 31782 vožnje (18284 rekreativnih i 13498 utilitarnih), što je pad od gotovo 70 % u odnosu na lipanj.

Rekreativne aktivnosti doživljavaju ogroman skok u travnju, kada omjer rekreativnih u odnosu na utilitarne doseže najvišu razinu od 1,96 (gotovo dvostruko više rekreativnih aktivnosti). To ukazuje na to da prvo toplo proljetno vrijeme najbrže aktivira rekreativce.




Slika 7. Ukupna Strava aktivnost po mjesecima



Slika 8. Ukupna utilitarna i rekreativna Strava aktivnost po mjesecima

Mjesečni podaci otkrivaju vrlo predvidljive sezonske obrasce, s naglašenim padom tijekom 8. mjeseca. Značajan pad sezonalne krivulje tijekom kolovoza jasno se vidi u ukupnoj aktivnosti po mjesecima na slici 7, ali je još i jasnije vidljiv u udjelu aktivnosti prema vrsti po mjesecima (slika 9). Prema udjelu aktivnosti po mjesecima, kolovoz bilježi manje utilitarnih aktivnosti (8,82 % ukupnog godišnjeg broja) od svibnja, lipnja, srpnja, rujna i listopada, te manje rekreativnih aktivnosti od travnja, svibnja, lipnja, srpnja i rujna. Takav obrazac odstupanja od pravilne sezonalne krivulje može se objasniti činjenicom da je kolovoz uobičajeno namijenjen za godišnje odmore.

Ukupan mjesečni broj aktivnih korisnika aplikacije Strava u promatranom razdoblju od 2019. do 2023. (slika 9) usko odražava sezonske trendove aktivnosti. Broj aktivnih korisnika doseže najviše brojke u svibnju i lipnju, pada tijekom kolovoza, ponovno raste u rujna te potom pada na najniže razine zimi.



Slika 9. Broj aktivnosti prema vrsti po mjesečnom udjelu i broj korisnika po mjesecima

Ukupni godišnji broj aktivnih korisnika aplikacije Strava skočio je s 22460 u 2019. na 34151 u 2020. godini, što predstavlja izniman porast od 52 % (tablica 11). Ovaj nagli skok izravno se podudara s početkom pandemije COVID-19, kada su aktivnosti na otvorenom i individualni sportovi postali iznimno popularni. U idućim godinama se broj korisnika zadržao na stabilnoj razini bez značajnih padova što ukazuje na to da je Strava uspješno zadržala i dodatno proširila bazu korisnika stvorenu tijekom pandemije. Prosječan mjesečni broj korisnika kontinuirano je rastao: s 1872 u 2019. na 2846 u 2020., dosegnuvši vrhunac od 2992 mjesečna korisnika u 2023. godini. Izražena sezonalnost izražena je kao i kod ukupne aktivnosti tijekom ljetnih mjeseci. Lipanj je dosljedno najaktivniji mjesec u gotovo svim promatranim godinama, osim u svibnju 2020. kada je zabilježen najveći broj od čak 4503 korisnika. To je ujedno i apsolutni mjesečni rekord u cijelom petogodišnjem razdoblju, a vjerojatno je uzrokovan popuštanjem prvih strogih *lockdown* mjera.

Razdoblje od svibnja do rujna bilježi najveću koncentraciju korisnika (tablica 11). Primjerice, u 2023. godini broj korisnika se u tom razdoblju konstantno kretao blizu ili iznad granice od 4000. Najmanji broj korisnika bilježi se tijekom zimskih mjeseci kada su vremenski uvjeti nepovoljniji za aktivnosti na otvorenom. U 2019. (724 korisnika) i 2020. (1001 korisnik) najslabiji mjesec bio je siječanj, a od 2021. do 2023. najniži broj korisnika koristi aplikaciju tijekom prosinca: 1278 (2021.), 1258 (2022.) i 1637 (2023.). Razlika između najaktivnijeg i najmanje aktivnog mjeseca po

broju korisnika je izrazito velika. U 2023. godini aktivnost u lipnju (4072) bila je čak 2,5 puta veća nego u prosincu (1637), što potvrđuje da je korištenje aplikacije izrazito ovisno o godišnjim dobima, odnosno da prati prosječnu aktivnost u tijeku godine.

Tablica 11. Broj korisnika Strave po mjesecima u razdoblju od 2019. do 2023.

Mjesec	2019	2020	2021	2022	2023	Sve godine
1	724	1001	1477	1549	1693	6444
2	1232	1542	2631	1859	1665	8929
3	2081	2101	2938	2921	2657	12698
4	2093	3739	3372	3254	3159	15617
5	1985	4503	3939	3919	3883	18229
6	2600	3896	3988	4007	4072	18563
7	2456	3687	3590	3773	3985	17491
8	2504	3333	3400	3506	3585	16328
9	2371	3663	3644	3151	4010	16839
10	2164	3036	2727	3215	3478	14620
11	1252	2192	1735	2034	2076	9289
12	998	1458	1278	1258	1637	6629
Σ	22460	34151	34719	34446	35900	


4.2 Prostorno-vremenska analiza Strava aktivnosti

U svrhu utvrđivanja prostorno-vremenskih obrazaca biciklističkoga prometa na području Grada Zagreba, provedena je analiza godišnjega volumena Strava aktivnosti po svim linijskim segmentima prometne mreže. Klasifikacija i vizualizacija podataka, te izrada završnih kartografskih sadržaja, izvedene su u QGIS-u. Kako bi se izradila vizualizacija ukupne Strava aktivnosti po pojedinoj godini bilo je potrebno povezati se unutar QGIS-a na *view* iz Postgres baze (vidi poglavlje 3.2.1), koji je izrađen za svaku godinu te sadrži geometriju i podatak ukupne aktivnosti (*total_trip_count*) svakog linijskog segmenta mreže.

Kao temelj za određivanje razreda (klasa) poslužio je izračun histograma cjelokupnoga skupa podataka, pri čemu je minimalna zabilježena vrijednost po segmentu 5, dok je apsolutni maksimum 72105 zabilježenih aktivnosti. Kako bi se anulirao utjecaj ekstrema (engl. *outliers*) i postigla optimalna vizualna reprezentacija stvarnoga prometnog opterećenja, izrađen je histogram vrijednosti nakon čega je provedena klasifikacija primjenom deskriptivnih statističkih parametara: medijana, prosjeka i standardne devijacije. Linijski su segmenti svrstani za cjelokupnu mrežu u pet klasa prema ukupnoj godišnjoj Strava aktivnosti na sljedeći način:

- 1) vrlo niska aktivnost (5 – 145): vrijednosti od minimuma do medijana (*min – median*),

- 2) niska aktivnost (146 – 650): vrijednosti od medijana do prosjeka ($median - avg$),
- 3) prosječna (umjerena) aktivnost (651 – 1450): vrijednosti od prosjeka do zbroja prosjeka i polovine standardne devijacije ($avg - (avg + \sigma/2)$),
- 4) visoka aktivnost (1451 – 8760): vrijednosti od zbroja prosjeka i polovine standardne devijacije do šesterostruke vrijednosti standardne devijacije ($(avg + \sigma/2) - (\sigma*6)$),
- 5) iznimno visoka aktivnost (8761 – 75000): vrijednosti od šesterostruke vrijednosti standardne devijacije do maksimuma ($(\sigma*6) - max$).




Slika 10. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2019.

Stilizacija linijskog sloja karte, kojim se prikazuje pet klasa ukupne Strava aktivnosti po linijskom segmentu mreže (slika 10), izvedena je razlikom u boji i debljini linije. Pri tome se debljina linije povećava s vrijednostima ukupne aktivnosti po klasi, a odabrana skala boja (*viridis*) kreće se od tamnoljubičaste preko zelene do žute. Karte (slika 10 – 13) su izrađene u mjerilu 1:75000.

Karta prostorne distribucije za 2019. (slika 10) predstavlja referentno stanje prije pandemije koronavirusa. U klasi iznimno visoke aktivnosti, označene žutom bojom, nalaze se linijski segmenti unutar zona sportsko-rekreacijske namjene te slične lokacije koje su u rekreacijskim biciklističkim krugovima popularni biciklistički pravci za trening. U tu klasu spadaju ŠRC Jarun (i prilazna Jarunska ulica), Sljemenska cesta, Zelena magistrala, te Podsusedski most na

zapadnom izlazu grada (smjer Samobora). Jedini utilitarni bic. pravac u najvišoj klasi aktivnosti je Savski (pješački) most i njemu prilazeće ceste (okretište tramvaja na kraju Savske ulice).




Slika 11. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2020.

Usporednom analizom kartografskih prikaza vidljiv je postepeni razvoj volumena biciklističkog prometa kroz promatranom razdoblje. U referentnoj 2019. godini (slika 10) sve važnije tranzitne ulice imaju visoku količinu (zeleni boja) Strava aktivnosti – Ilica, Zagrebačka av., Savska cesta, Zagrebačka cesta, Ul. grada Vukovara, Av. Većeslava Holjevca, Klaićeva, Martićeva, Branimirova, Heinzelova, Maksimirska cesta, i dr. Uz tranzitne pravce, visoku aktivnost bilježe i značajne prometnice koje vode prema rekreativnim segmentima mreže, prije svega glavni izlazi (ulazi) u grad na zapadu, istoku i jugu, te glavne brdske prometnice podsljemenske zone (sjeverno od Ilice i Maksimirske ceste). U klasi visoke aktivnosti nalaze se i popularne rekreativne lokacije poput parka Maksimir i Dotrščina te jezera Bundeck. Vrlo niska i niska razina aktivnosti prostorno je raspoređena u zonama koje karakterizira nepovoljna morfologija terena (nagib), nedostatak biciklističke infrastrukture i visoka koncentracija teretnog prometa. U tim klasama nalaze se industrijske zone, južna i istočna predgrađa, manje lokalne (kvartovske) ceste te većina podsljemenske zone.

Značajna promjena primjetna je u pandemijskoj 2020. godini (slika 11), kada nastupa skok u iznimno visokoj aktivnosti na prometnicama povezanim sa već spomenutim rekreacijskim


lokacijama. Područje Sljemenske ceste povećava se, te obuhvaća dio spusta prema Šestinama kao i Gračansku cestu. Segment Zelene magistrale također se produljuje i ulazi cijelom dužinom u najvišu klasu, u koju ulazi i sjeverni dio savskog nasipa od Mosta slobode do Jaruna. Uz povećanje aktivnosti na rekreacijskim segmentima mreže, primjetna je snažna disperzija visokih vrijednosti diljem gradske ulične mreže. Poneki urbani koridori poput Ulice grada Vukovara, centralnog dijela grada uz Trg bana Jelačića te zapadnoga dijela grada (Samoborska cesta) postaju znatno frekventniji, što ukazuje na porast utilitarnih aktivnosti (dnevnih migracija).



Slika 12. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2021.


Kartografski prikaz za 2021. godinu (slika 12) ukazuje na zadržavanje visokoga volumena biciklističkoga prometa uspostavljenog tijekom 2020. Transitni bic. pravci kroz centar i širi centar grada nastavljaju bilježiti rast, formirajući kontinuirane koridore prosječne i visoke aktivnosti. Vidljivo je pojačano opterećenje na savskim mostovima (Most slobode i Jadranski most), što koincidira s infrastrukturnim radovima na Savskom mostu koji su trajali tijekom gotovo čitave 2021. S tim u vezi značajno se povećava i bic. promet na Av. Većeslava Holjevca.

U 2022. godini (slika 13) vidljivi su slični prostorni uzorci kao i prethodne godine što označava razdoblje stabilizacije biciklističke aktivnosti. Najveća promjena jest otvaranje Savskog (pješačkog) mosta, kojim se biciklistički promet velikim dijelom preusmjerava sa Mosta slobode i Jadranskog mosta na novouređenu pješačko-biciklističku stazu Savskog mosta.




Slika 13. Ukupan broj Strava aktivnosti po linijskim segmentima mreže u 2022.


U slučaju ukupne rekreativne (*leisure_trip_count*) i utilitarne (*commute_trip_count*) Strava aktivnosti ponovljen je isti proces klasifikacije volumena prometa temeljem histograma cjelokupnoga skupa podataka i upotrebom deskriptivnih statističkih parametara (maksimum zabilježenih aktivnosti, medijan, prosjek, standardna devijacija). Zbog sličnosti prostornog uzorka biciklističke aktivnosti između ukupne i rekreativne Strava aktivnosti u radu nije prikazana zasebna prostorno-vremenska analiza rekreativne aktivnosti (kartografski prikazi dostupni u prilogu 4). Za izradu karata ukupne utilitarne aktivnosti upotrijebljena je ista stilizacija kao i u prethodnim kartama ukupne aktivnosti, no karte (slika 14 – 17) su izrađene u krupnijem mjerilu (1:50000) kako bi jasnije prikazale centralni dio područja istraživanja, odnosno urbanu sredinu koji prednjači utilitarnim biciklističkim aktivnostima. Kao i u prijašnjim kartama ukupne aktivnosti, OSM je postavljen kao rasterska podloga putem mrežnog servisa WMS (*Web Map Service*). Također, zbog specifičnosti svakodnevnih putovanja, koja generiraju znatno manji apsolutni broj zapisa u odnosu na ukupnu (i rekreativnu) aktivnost unutar Strava aplikacije, granične vrijednosti klasa znatno su niže.




Slika 14. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2019.



Slika 15. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2020.



Slika 16. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2021.



Slika 17. Ukupan broj utilitarne Strava aktivnosti po linijskim segmentima mreže u 2022.

Kao i kod ukupne aktivnosti provedena je usporedna analiza kartografskih prikaza te je vidljivo povećanje volumena biciklističkog prometa u transportne (utilitarne) svrhe iz godine u godinu. U referentnoj 2019. godini utilitarni aktivnost jasno ocrtava primarnu tranzitnu strukturu Grada Zagreba, pri čemu je najveći broj aktivnosti zabilježen na ključnim točkama povezivanja sjevernog i južnog dijela grada, na glavnim prometnim pravcima i tranzitnim koridorima te pojedinim sjecištima pravaca visokog intenziteta (slika 14). To su ujedno dijelovi cestovne mreže s najvećim volumenom motoriziranog prometa, ali i odvojenom biciklističkom infrastrukturom. U najvišoj klasi prema utilitarnoj aktivnosti su Savski most i Most slobode, dok Most mladosti bilježi visoku aktivnost (a njemu pristupne prometnice čak iznimno visoku). Budući da su ta tri prijelaza preko Save jedini dostupni pravci za bicikliste, ne čudi njihovo visoko opterećenje. Posljedično, s mostovima povezane pristupne prometnice privlače biciklistički promet pa iznimno visoki volumen imaju i Av. V. Holjevca, južni dio Savske, ul. Ivana Rogića (Kajzerica) i Jarunska, ali i sjeverni dio savskog nasipa od Savskog mosta. To pokazuje da dio biciklista za svakodnevnu transportnu vožnju bira alternativne puteve bez uređene biciklističke infrastrukture, ali s minimalnim (ili nikakvim) intenzitetom motoriziranog prometa. Žutom bojom označene su i glavni longitudinalni pravci: Zagrebačka av. od Zagrebačke do Savske ceste, Slavonska av. od Savske ceste do Av. V. Holjevca, Vukovarska (sjeverni dio) od Ul. Florijana Andrašeca do financijske četvrti na Radničkoj cesti te Ul. kneza Branimira. Treba napomenuti da na Zagrebačkoj i Slavonskoj av. na pojedinim dijelovima (uz Selsku i Savsku) obje strane ceste bilježe iznimno visoke vrijednosti utilitarne aktivnosti. Također najvišoj klasi pripada i Strojarska cesta koja spaja Vukovarsku i Branimirovu, ali i dio Medarske ulice na zapadu kao alternativni longitudinalni pravac Ilici (koja nema bic. infrastrukturu, a ima visoku količinu motoriziranog prometa).

Sukladno obrascu prostorne distribucije ukupne Strava aktivnosti, utilitarne aktivnosti u 2020. godini (slika 15) bilježe disperziju visokih vrijednosti. Istodobno je primjetno ukupno povećanje broja linijskih segmenata niske i umjerene aktivnosti, što je naročito vidljivo na lokalnoj razini prometne mreže unutar stambenih četvrti i blokova. U klasi visoke i iznimno visoke aktivnosti vidljivo je uspostavljanje pravca od kružnog toka (tzv. rotora) Remetinec do Savskog mosta. Ovaj pravac u 2019. nije postojao zbog radova (rekonstruirani rotor je pušten u promet krajem siječnja 2020.). Dodatno, u najvišoj klasi pojavljuje se istočna strana Mosta mladosti, produžetak Av. V. Holjevca od mosta sve do Av. Dubrovnik i dio Tomislavove ulica od Fallerovog šetališta prema zapadu.

Ipak, najznačajniji novi koridor koji se u 2020. pojavljuje u klasi iznimno visoke utilitarne aktivnosti jest biciklistički pravac istočno od centra grada. Radi se o biciklističkom koridoru koji

se proteže od Martićeve ulice (kod tržnice Kvatrić, južno od Kvaternikovog trga), nastavlja preko ulica Dragutina Rakovca i Pavla Štoosa te se ulicom Ružmarinka povezuje sa Sveticama i Maksimirskom cestom. Zanimljivo i indikativno je što ovaj pravac nema visok intenzitet motoriziranog prometa, kao ni tramvajski promet, čime predstavlja sigurniju prometnu alternativu paralelnim tranzitnim koridorima (Vlaška ulica i Ulica kralja Zvonimira). Također valja istaknuti da u promatranoj 2020. na tom području nije bilo biciklističke prometnice (danas postoji bic. prometnica kategorije CM), ali da su unatoč tome biciklisti odabrali navedeni pravac za povezivanje infrastrukturnih dionica na Martićevoj (Kvaternikovom trgu) i Maksimirskoj cesti.


Za razliku od ukupne Strava aktivnosti, koja tijekom 2021. (slika 16) i 2022. (slika 17) godine doživljava stabilizaciju i svojevrsnu stagnaciju, utilitarni biciklistički promet u cjelokupnom razdoblju istraživanja pokazuje prostorno širenje i količinsko povećanje. Pri tome dio linijskih segmenata prelazi iz visoke u klasu vrlo visoke aktivnosti, kao npr. zapadni dio Ilice (kod Vrapča), Vrapčanska putina, dijelovi mreže oko Zapadnog kolodvora, središnji dio prilaza baruna Filipovića, ali i mnoga druga značajna raskrižja na kojima se spajaju važniji tranzitni smjerovi visoke biciklističke aktivnosti. I kod utilitarne aktivnosti je izrazito primjetan utjecaj zatvaranja Savskog (pješačkog) mosta, koji je zbog obnove bio izvan pogona od kraja siječnja 2021. do kraja ožujka 2022. Posljedica toga bila je izrazito visoka koncentraciju utilitarne aktivnost na susjednom Jadranskom mostu tijekom 2021., ali i povratak uobičajenom obrascu svakodnevnog prometa u 2022. godini.

4.2.1 Makro-lokacijska prostorna analiza Strava aktivnosti

Kao nadopunu prethodnoj detaljnoj analizi pojedinačnih linijskih segmenata, provela se vizualna analiza biciklističke aktivnosti na administrativnoj razini, koja omogućuje agregirani (makro) pogled na raspodjelu biciklističkog prometa u Zagrebu. Kao rezultat su izrađeni kartografski prikazi prosječne Strava aktivnosti po segmentu MO-a Grada Zagreba na godišnjoj razini. Prostornim upitom unutar QGIS-a izvedena je analiza geometrije i atributa Strava aktivnosti unutar pojedinog MO-a. Za svaki MO izračunate su ukupna dužina i broj svih linijskih segmenata te prosječna dužina linijskog segmenta, a potom je izračunat prosječan broj aktivnosti po linijskom segmentu pojedinog MO-a za pojedinu godinu promatranog razdoblja. Taj podatak poslužio je za vizualnu analizu prosječne godišnje Strava aktivnosti po MO-u Grada Zagreba (slika 18). Svrha ove analize bila je olakšati interpretaciju i vizualizaciju podataka Strave na administrativnoj razini za svaku godinu promatranog perioda istraživanja. Istom metodom izračunat je prosječni godišnji volumen utilitarne (slika 19) i rekreativne (slika 20) aktivnosti po segmentu MO-a. Kako bi se izbjeglo prikazivanje svih 12 izrađenih karata (ukupna, rekreativna i

utilitarna aktivnost kroz 4 godine) unutar glavnog dijela rada, u nastavku su prikazani isječci završnih kartografskih prikaza spojeni u jednu zajedničku sliku. Svi izvorni kartografski prikazi priloženi su i izvornom formatu na kraju rada (vidi prilog 5).

Pri interpretaciji ovih karata (slike 18, 19 i 20) nužno je uzeti u obzir specifičan statističko-geometrijski učinak odabrane metodologije (tzv. MAUP – *Modifiable Areal Unit Problem*). S obzirom da svaka karta za pojedini MO prikazuje prosjek (ukupne godišnje aktivnosti) po linijskom segmentu, MO-i koji obuhvaćaju velike neizgrađene i zelene površine s vrlo rijetkom cestovnom mrežom, ali posjeduju jedan izrazito opterećen rekreacijski koridor (poput Sljemenske ceste, ŠRC-a Jarun ili savskoga nasipa), generirat će iznimno visoke prosječne vrijednosti. S druge strane, u gusto izgrađenim urbanim MO-ima širega centra grada, gdje postoji gusta prometna mreža, ukupni se volumen biciklističkoga prometa disperzira na velik broj segmenata, što posljedično rezultira nižim do umjerenim prosječnim vrijednostima, unatoč visokom apsolutnom broju aktivnosti.




Slika 18. Prosječna godišnja Strava aktivnosti po linijskom segmentu mreže za područje MO-a

Usporednom analizom kartografskih prikaza (slika 18) jasno se ocrtavaju trendovi u intenzitetu, prostornom obuhvatu i promjeni biciklističkog prometa na području Grada Zagreba kroz promatrani period od 2019. do 2022. Za referentnu 2019. godinu karakteristične su niske i umjerene vrijednosti, prikazane nijansama plave i tamno-zelene boje. MO-i niže aktivnosti pretežno se nalaze na istočnoj polovici grada. To su područja koje karakterizira geografska udaljenost od urbane sredine, industrijske zone i brze tranzitne ceste (sekundarne kategorije prema OSM-u, npr. Slavenska avenija), fizičke prepreke (npr. željeznička pruga) te nepostojanje sigurne i kontinuirane biciklističke infrastrukture. Umjereno visoke vrijednosti Strava aktivnosti po prosječnom segmentu mreže MO-a vidljive su na područjima MO-a na jugozapadnom dijelu županije (GC Brezovica), MO-a Jarun, MO-a Mlinovi i Gračani (u blizini Sljemenske ceste) te MO-a Kašina (sjeverozapadni izlaz iz grada; državna cesta u smjeru Marije Bistrice). Sva navedena područja značajna su u kontekstu rekreativne bic. aktivnosti, stoga se može zaključiti da je tijekom 2019. aplikacija primarno upotrijebljavana za rekreaciju.


Najveća promjena događa se u 2020. godini, kada je vidljivo proporcionalno prostorno povećanje bic. aktivnosti na području čitavog grada. Pri tome MO-i niske prosječne aktivnosti na istoku i JI-u grada također doživljavaju značajan skok u brojnosti, no taj trend opada sa 2021. i 2022. godinom. Ukupno gledano, može se zaključiti da bic. aktivnost po MO-ima u 2021. i 2022. doživljava stabilizaciju. Unatoč tome, primjetan je trend smanjenja aktivnosti tijekom 2022. u predjelu pojedinih sjevernijih (brdskih) MO-a, pogotovo centralno iznad Ilice i na zapadu iznad Aleje grada Bolonje. Generalno gledano vidljiva je izrazita podijeljenost gradskog prostora na biciklistički aktivan zapadni i južni te neaktivan istočni dio grada.

Usporednom prostorno-vremenskom analizom ukupne (slika 18) i rekreativne (slika 19) Strava aktivnosti po prosječnom segmentu na razini MO-a Grada Zagreba uočava se gotovo potpuna prostorna i vremenska podudarnost obrazaca aktivnosti. Razlog tome leži u činjenici što je Strava aplikacija primarno namijenjena sportašima i rekreativcima. Osim toga, na području Zagreba se utilitarni bic. pravci često preklapaju s rekreacijskim koridorima. Primjer je savski nasip, kao sigurna biciklistička magistrala bez motoriziranog prometa. Jedina značajna razlika vidljiva je na području centralnih MO-a (GC-i Donji Grad, Trešnjevka – sjever i Trnje), gdje je ukupna aktivnost znatno viša od rekreativne, što je ujedno i potvrda značajno više utilitarne aktivnosti na tom području (slika 20).



Slika 19. Prosječna godišnja rekreativna Strava aktivnosti po linijskom segmentu mreže za područje MO-a

Karte prosječne godišnja utilitarne Strava aktivnosti po linijskom segmentu mreže za područje MO-a (slika 20) jasno pokazuje različite obrasce između rekreativne i utilitarne bic. aktivnosti. Utilitarna aktivnost na području Grada Zagreba izrazito je centralizirana u urbaniziranom dijelu, naročito u GC-ima Donji grad, Trešnjevka – sjever, Trnje i jugozapadnim MO-ima Maksimira. Najvišoj klasi utilitarne aktivnosti pripadaju svi MO-i koji prometno gravitiraju središtu grada. U urbanom centru nalazi se najveća gustoća radnih mjesta te sveučilišnih i javnih ustanova, a zajedno sa širim centrom grada karakterizira ih gusta prometna povezanost, ravna topografija (bez nagiba terena) i razvijena mreža biciklističke infrastrukture. Suprotno tome, MO-i s visokom rekreativnom aktivnosti na JZ-u i sjeveru grada bilježe izrazito malo svakodnevnih utilitarnih vožnji. Razlog tome jest velika udaljenost od centra grada, slabija razvijenost prometne mreže, nedostatak bic. infrastrukture i zahtjevna topografija terena (nagib u sjevernom dijelu).



Slika 20. Prosječna godišnja utilitarna Strava aktivnosti po linijskom segmentu mreže za područje MO-a

Usporedbom apsolutne vrijednosti klasifikacije može se uočiti da rekreativne aktivnosti po MO-ima imaju višestruko veće vrijednosti (najviša klasa iznosi 1599 – 2421 aktivnosti po segmentu) u odnosu na utilitarne (najviša klasa: 365 – 560). Unatoč tome, prostorna analiza obrazaca utilitarne aktivnosti dokazuje oprečnu prostornu svrhu u odnosu na rekreativne aktivnosti. Utilitarne aktivnosti vezane su za izgrađenu mrežu prometnica dok su rekreativne aktivnosti usmjerene prema prirodnim lokacijama i rubnim dijelovima grada. Uz to, vremenska analiza ukazuje na drugačiju dinamiku razvoja. Utilitarne aktivnosti ne bilježe visoki rast tijekom pandemijske 2020. godine nakon kojeg slijedi stagnacija, već kontinuirano rastu i prostorno (gotovo ekscentrično) se šire, kulminirajući u 2022. godini.

4.3 Statistička analiza automatskog brojača i usporedba sa Strava aktivnosti


S ciljem što preciznije procjene PGDBP-a na razini cjelokupnoga gradskog područja, provedena je komparativna analiza zapisa s automatskog brojača i podataka s platforme Strava za pripadajući linijski segment mreže. U tom su postupku egzaktni podaci automatskog brojača imali ulogu referentnih terenskih vrijednosti, neophodnih za kalibraciju biciklističke aktivnosti iz Strave. Sveobuhvatna analiza vremenskih obrazaca postignuta je usporedbom podataka u trima različitim vremenskim rezolucijama: godišnjoj (tablica 12), mjesečnoj (slika 21; prilog 6) i dnevnoj razini (slike 22 – 25). Tim su postupkom detaljno ispitana sezonska kolebanja i međugodišnje promjene, čime je stvoren temelj za procjenu zastupljenosti korisnika Strave u ukupnom volumenu biciklističkog prometa.

Tablica 12. Ukupan broj prolaza na automatskog brojaču i usporedba sa Strava aktivnosti na segmentu brojača na godišnjoj razini

Godina	Automatski brojač	Strava aktivnost na segmentu	Strava %	Rekreativne vožnje	%	Utilitarne vožnje	%
2019	437071	5865	1,34	2170	37,0	3695	63,0
2020	429073	6800	1,58	3740	55,0	3060	45,0
2021	429077	8225	1,92	4020	48,9	4205	51,1
2022	300989	8725	2,90	3630	41,6	5095	58,4

Ukupan broj Strava aktivnosti na segmentu mreže u Ulica grada Vukovara, na lokaciji automatskog brojača biciklističkog prometa, bilježi stabilan godišnji rast, povećavajući se s 5865 aktivnosti u 2019. na 6800 u 2020., zatim na 8225 u 2021. te dostiže vrhunac od 8725 aktivnosti u 2022. U tablici 12 je vidljivi da udio Strava aktivnosti u odnosu na podatke s automatskog brojača kontinuirano raste. U 2019. iznosio je 1,34 %, u 2020. 1,58 %, u 2021. 1,92 %, dok u 2022. skače na 2,90 % (za 2023. nisu dobiveni podaci automatskog brojača pa nije bilo moguće napraviti usporedbu). Ovaj trend ukazuje na sve veću popularnost aplikacije među svakodnevnim biciklistima ili promjenu profila korisnika prema digitalnim alatima. U uobičajenim okolnostima Ulica grada Vukovara primarno služi kao transportni koridor za svakodnevne (utilitarne) vožnje povezujući zapadni i središnji dio grada od Trešnjevačkog trga do poslovnog područja oko Radničke ulice. U 2019. utilitarne aktivnosti činile su većinu s 63 %. Međutim u 2020. godini, koja se zbog pandemija pokazala specifična, se struktura drastično mijenja u korist rekreativnih vožnji koje preuzimaju 55 % udjela (3740), dok utilitarne padaju na 45 % (3060). Nakon slabljenja pandemijskih mjera, utilitarne vožnje ponovno preuzimaju primat: u 2021. čine 51,12 % (4205 vožnji), u 2022. rastu na 58,40 % (5095 vožnji). Iako u tablici

12 nije prikazano, primjetan je snažan relativni rast popularnosti električnih bicikala (stupac 'e-bike' u tablici s podacima) među Strava korisnicima, čiji je broj porastao s tek 25 vožnji na segmentu u 2019. na 130 u 2022. te čak 350 vožnji u 2023. godini.



Slika 21. Usporedba ukupnog broja prolaza na automatskom brojaču i aktivnosti na Strava segmentu brojača


Ako se promatra sezonalna biciklistička aktivnost na mjesečnoj razini kroz cjelokupni period istraživanja na lokaciji brojača, tada je vidljiva (slika 21) snažna korelacija između dvaju skupova podataka. Najjasniji primjer jest 2019. godina, koja je ujedno i inicijalna godina istraživanja, u kojoj se kretanje obje linije gotovo preklapa. Na samom početku te godine ujedno je i mjesec s najmanjom Strava aktivnosti na lokaciji brojača (215). Jedina iznimka u 2019. dogodila se u rujnu gdje je Strava aktivnost bila slična aktivnosti u listopadu, dok automatski brojač bilježi znatno manji broj prolaza u rujnu (41561) u odnosu na listopad (52323).

Drugo odstupanje dvaju linija dogodilo se za vrijeme već spomenutog pandemijskog razdoblja, a vidljivo je u usporedbi broja prolaza na brojaču u travnju 2020. u odnosu na mjesec ranije dok linija Strave bilježi nagli skok na istom segmentu. Treće odstupanje jest skok Strava aktivnosti u odnosu na brojač u lipnju 2021., pri čemu Strava aktivnost bilježi maksimum za cjelokupno razdoblje (1470), a posljednje odstupanje u odnosu dvaju linija primjetno je u 2022. godini. Te godine vidljiv je relativni skok Strava aktivnosti u odnosu na godine prije koji, osim lipnja, korelira u odnosu na brojač, dok brojač bilježi relativno niže vrijednosti od prijašnjih godina. Gledajući cjelokupni period primjećuje se ukupni rast broja Strava aktivnosti na segmentu te porast udjela Strava aktivnosti u ukupnom broju prolaza na automatskom brojaču. Razdoblja kada raste broj prolaza na automatskom brojaču podudaraju s porastom Strava aktivnosti, što

ukazuje na to da su podaci iz aplikacije Strava koristan indikator trendova biciklističkog prometa.


Budući da su podaci s automatskog brojača za cjelokupno promatrano razdoblje prikupljeni u dnevnoj rezoluciji, provedena je njihova komparacija s dnevnim zapisima aplikacije Strava na pripadajućem infrastrukturnom segmentu. Ovaj je postupak omogućio detaljnu analizu kratkotrajnih fluktuacija i izračun godišnjih koeficijenata korelacije (slike 22 – 25). U svrhu optimizacije grafičkog prikaza i olakšane vizualne interpretacije, podaci su obrađeni metodom sedmodnevnog pomičnog prosjeka (tzv. linija trenda). Primjena navedene analitičke metode bila je neophodna za filtriranje šuma u podacima, odnosno dnevnih varijacija primarno uzrokovanih meteorološkim prilikama (oborine, niske temperature) te razlikama u volumenu prometa između radnih dana i vikenda. Ovako izgladnena krivulja omogućila je precizniju identifikaciju dugoročnih sezonskih obrazaca, kao i detekciju anomalija proizašlih iz vanjskih utjecaja.

Dijagrami na slikama 22 – 25 ilustriraju odnos ukupnog broja prolazaka registriranih na brojaču i agregirane dnevne Strava aktivnosti za svaku pojedinu godinu istraživanja. Pritom inicijalna 2019. godina (slika 22) služi kao referentno razdoblje za utvrđivanje baznih vrijednosti biciklističkoga prometa. Rezultati za spomenutu godinu ukazuju na stabilnost trendova, uz očekivanu eskalaciju aktivnosti tijekom toplijeg dijela godine. Utvrđena je vrlo visoka razina korelacije između dvaju promatranih izvora, što implicira stabilnu i ravnomjernu distribuciju korisničke strukture. Kao jedino značajnije odstupanje izdvaja se apsolutni maksimum zabilježen na automatskom brojaču u drugoj polovici listopada 2019., koji pritom nije bio popraćen adekvatnim porastom aktivnosti unutar same aplikacije Strava.




Slika 22. Odnos ukupnog broja prolaza na automatskom brojaču i ukupne aktivnosti na Strava segmentu u 2019. prikazan 7-dnevnom trend linijom

Godina 2020. (slika 23) bila je obilježena atipičnim oscilacijama prometnih tokova uzrokovanim pandemijom. Uvođenjem restriktivnih mjera sredinom ožujka zabilježen je oštar pad prometa, nakon čega je uslijedio brzi oporavak i opći porast biciklističke aktivnosti. U tom je razdoblju uočen snažniji rast Strava aktivnosti u usporedbi s podacima automatskog brojača. Takav je nesrazmjer trajao sve do ublažavanja epidemioloških mjera početkom svibnja, kada linija trenda automatskog brojača ponovno počinje bilježiti brži rast u odnosu na aplikaciju. Općenito, podaci ukazuju na to da se biciklizam tijekom ljeta 2020. godine značajno intenzivirao, što je vjerojatno izravna posljedica izbjegavanja javnog gradskog prijevoza i povećanog interesa za rekreaciju na otvorenom. Unatoč tom rastu, u prvoj polovici kolovoza evidentiran je izražen pad aktivnosti, što se može pripisati uobičajenom smanjenju urbanih migracija uslijed sezone godišnjih odmora.




Slika 23. Odnos ukupnog broja prolaza na automatskom brojaču i ukupne aktivnosti na Strava segmentu u 2020. prikazan 7-dnevnom trend linijom

Tijekom 2021. godine (slika 24) zabilježene su maksimalne vrijednosti biciklističkoga prometa u promatranom razdoblju. Analiza linija trenda ukazuje na snažan i kontinuiran rast aktivnosti tijekom proljetnih mjeseci, uz zadržavanje visokog intenziteta prometa kroz cijelu sezonu. Odstupanja između dviju promatranih krivulja su minimalna, a najviše dolaze do izražaja u prvoj polovici lipnja kada Strava aktivnost doseže svoj apsolutni vrhunac. U tom su razdoblju zabilježeni pojedinačni dani s dvostruko većim brojem aktivnosti (80) u odnosu na mjesečni prosjek, dok referentni automatski brojač istodobno bilježi očekivane, standardno visoke vrijednosti za taj dio godine. Ovi pokazatelji potvrđuju pouzdanost aplikacije i stabilnost reprezentativnosti biciklističkih tokova na zadanoj lokaciji, čak i u godinama s iznadprosječnim volumenom prometa.



Slika 24. Odnos ukupnog broja prolaza na automatskom brojača i ukupne aktivnosti na Strava segmentu u 2021. prikazan 7-dnevnom trend linijom

Godinu 2022. (slika 25) karakterizira povratak uobičajenim obrascima prometnog opterećenja i opća stabilizacija sustava. Iako se dinamika prometa dosljedno odvija prema očekivanom sezonskom modelu, maksimalne zabilježene vrijednosti pokazuju blagi pad u odnosu na ekstremne rezultate iz prethodne godine. Bez obzira na to smanjenje ukupnog intenziteta aktivnosti, očitavanja s automatskog brojača i podaci iz aplikacije Strava zadržavaju visoku razinu međusobne korelacije, potvrđujući tako stabilnost i reprezentativnost promatranih trendova.



Slika 25. Odnos ukupnog broja prolaza na automatskom brojača i ukupne aktivnosti na Strava segmentu u 2022. prikazan 7-dnevnom trend linijom

Analiza korelacije između podataka s automatskog brojača prometa i zapisa iz aplikacije Strava ukazuje na visoku statističku povezanost, čime se potvrđuje pouzdanost MPP-a u procjeni stvarnih prometnih tokova (tablica 13). Za izračun koeficijenta korelacije korišten je Excel,

unutar kojeg se izračun temelji na standardnoj matematičkoj metodi Pearsonova koeficijenta korelacije (r). Vrijednost navedenoga koeficijenta izračunata je prema sljedećoj jednadžbi (Sedgwick, 2012):

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (1)$$

gdje x_i predstavlja stvarni dnevni broj prolazaka zabilježen na automatskom brojaču za pojedini dan promatranja, $\bar{x}$ označava aritmetičku sredinu (prosjeak) svih dnevnih očitavanja brojača u analiziranom razdoblju, y_i predstavlja ukupan broj zabilježenih Strava aktivnosti na pripadajućem infrastrukturnom segmentu za taj isti dan, a $\bar{y}$ označava prosječni dnevni broj Strava aktivnosti za cjelokupno promatrano razdoblje. Ovakav je matematički pristup osigurao egzaktno vrednovanje usklađenosti dnevnih fluktuacija između dvaju promatranih neovisnih izvora podataka.

Tablica 13. Koeficijenti korelacije dnevnih podataka automatskog brojača i Strave

Godina	Ukupno	util	rekr
2019	0,797	0,846	0,177
2020	0,690	0,793	0,245
2021	0,741	0,842	0,387
2022	0,857	0,866	0,404
Ukupno	0,631	0,689	0,264

Posebno se ističe snažna pozitivna korelacija u segmentu utilitarnih aktivnosti, čiji koeficijenti premašuju vrijednost od 0,84 u gotovo svim promatranim godinama, s maksimumom zabilježenim 2022. godine ($r = 0,866$). Zanimljivo je primijetiti da su vrijednosti korelacije za utilitarne aktivnosti u većini godina čak i više od ukupne korelacije prometa, što dokazuje da podaci svakodnevnih korisnika Strave gotovo savršeno preslikavaju stvarne fluktuacije na terenu.


S druge strane, rekreativne aktivnosti pokazuju znatno slabiju povezanost, s koeficijentima koji se kreću od 0,177 (2019.) do 0,404 (2022.). Ovakav jasan nerazmjer sugerira da se infrastrukturni segment na kojem je smješten automatski brojač primarno koristi kao utilitarni tranzitni koridor, dok se rekreativni biciklistički tokovi odvijaju na drugim rutama. Potvrda toga jest činjenica da je prosječno dnevno prometno opterećenje na automatskom brojaču radnim danima (1342) više nego dvostruko veće u usporedbi s prometom tijekom vikenda (570). Nadalje, analiza Strava podataka ukazuje na jasnu inverziju obrazaca aktivnosti ovisno o danu u tjednu. Radnim danima unutar aplikacije prevladavaju utilitarne aktivnosti s prosječno 14,2 zabilježene

aktivnosti dnevno, naspram 8,2 rekreativne. Nasuprot tome, tijekom vikenda bilježi se drastičan pad utilitarnih aktivnosti na prosječno svega 1,87 po danu, dok učestalost rekreativnih istodobno raste na 11,35 dnevno.

Također, utvrđen je znakovit pad korelacije tijekom 2020. godine u svim kategorijama. Ova se anomalija može izravno pripisati utjecaju pandemije i epidemiološkim mjerama, odnosno mjerama ograničavanja kretanja, radu na daljinu i online nastavi, što je privremeno narušilo uobičajene obrasce dnevnih migracija. Unatoč tim pandemijskim oscilacijama, višegodišnji rezultati nedvojbeno potvrđuju da je kalibracija Strava podataka pomoću referentnih brojača znanstveno opravdana metoda za preciznu procjenu PGDBP-a.

4.4 Analiza kratkotrajnog brojanja


Rezultati kratkotrajnog ručnog brojenja biciklističkoga prometa pružaju detaljan uvid u vremenske karakteristike (slika 26) i demografsku strukturu (slika 27) prometnih tokova najfrekventnijih lokacija biciklističkog prometa. Prilikom interpretacije podataka nužno je uzeti u obzir da je zbog sanacije u tom razdoblju (od 25. siječnja 2021. do 29. ožujka 2022.) bio zatvoren Savski (pješački) most, što je rezultiralo značajnom redistribucijom prometa prema alternativnim prijelazima preko rijeke Save. Na slici 26 je vidljivo da su oba mosta preuzeli transportnu funkciju Savskog mosta. Na Mostu slobode je zabilježeno ukupno 563 biciklista na obje strane prometnice (288 na zapadnoj i 275 na istočnoj strani), uz izraženiji intenzitet u jutarnjim (324 prolaska) nego u poslijepodnevnim satima (239 prolazaka). Na Jadranskom mostu je mjereno samo na istočnoj strani, bližoj tramvajskom okretištu. Ondje je evidentirano ukupno 269 biciklista, no s jasnom dominacijom poslijepodnevnih prolazaka (163 prema 106 jutarnjih). Ako se usporede oba mosta, omjer zabilježenih prolazaka je veći u jutarnjim satima od popodnevnih (u korist Mosta slobode gdje su obje strane mjerene). Takva dinamika ukazuje na to da su biciklisti za povratna (utilitarna) putovanja češće birali Jadranski most, unatoč njegovoj primarnoj namjeni za motorizirani promet. Drugi razlog bi mogao biti taj što pozicija Jadranskog mosta omogućuju brži pristup rekreativnim koridorima južno od Zagreba, a rekreativne vožnje su češće u popodnevnim satima, nego u jutarnjim.



Slika 26. Ukupno biciklista na lokacijama kratkotrajnog brojanja u jutarnjim i popodnevnim vršnim satima

Od najfrekventnijih lokacija mjerenja, Ulica grada Vukovara (uz KD V. Lisinskog) pokazala se kao ključna longitudinalna (istočno-zapadna) magistrala s apsolutnim maksimumom od 983 prolaska (458 u jutarnjem i 525 u poslijepodnevnom vršnom satu), što ukazuje na kontinuirano visoko opterećenje tijekom cijeloga dana (treba uzeti u obzir da su mjerene obje strane prometnice). Nadalje, sjeveroistočni dio raskrižja Savske ceste i Slavonske avenije (783 prolaska ukupno) funkcionira kao primarni tranzitni čvor za migracije prema južnim i zapadnim dijelovima grada, bilježeći visoke vrijednosti u oba vršna razdoblja (357 ujutro i 426 poslijepodne). Značajna frekvencija od 592 biciklista utvrđena je i kod Studentskog centra (SC) u Savskoj cesti 25, s većim poslijepodnevnom brojem prolazaka (366, naspram 226 jutarnjih).

Promatrajući vremensku distribuciju na razini cjelokupnog uzorka, razvidno je da poslijepodnevno vršno opterećenje, koje koincidira s povratkom korisnika s radnih mjesta i fakulteta, generira veći volumen prometa na većini gradskih raskrižja. Primjerice, na raskrižju Savska–Kršnjavoga broj prolazaka raste sa 181 ujutro na 305 poslijepodne, dok na raskrižju Selska–Horvaćanska taj porast iznosi sa 100 na 194 prolaska.



Slika 27. Udio muških i ženskih biciklista na lokacijama kratkotrajnog brojanja u jutarnjim i popodnevnim vršnim satima

Analiza demografske distribucije (slika 27) ukazuje na visoku konzistentnost strukture spolova unutar biciklističke populacije na svim promatranim mikrolokacijama. Muškarci čine između 66 % i 74 % ukupnog prometa (s maksimumom od 74,1 % na raskrižju Selska–Horvaćanska), dok se udio žena kreće u rasponu od 26 % do 34 %, pri čemu je najveća zastupljenost ženskih vozača (34,0 %) zabilježena upravo na najopterećenijoj lokaciji u Ulici grada Vukovara. Detaljnija analiza vremenskih obrazaca kretanja, provedena na temelju 15-minutnih intervala (vidi prilog 7), ukazuje na specifične razlike u dinamici putovanja s obzirom na spol korisnika. Promatrajući jutarnje period mjerjenja (od 7:00 do 9:00 sati), zabilježena je razmjerno ravnomjerna distribucija muških biciklista, premda se na pojedinim mikrolokacijama (raskrižja Savska – Kršnjavoga, Selska – Horvaćanska, Savska – Slavonska i Svetice – Budakova) maksimalno prometno opterećenje bilježi u ranijem segmentu, odnosno između 7:00 i 8:00 sati. Nasuprot tome, uočeno je da ženski dio populacije izrazito preferira drugi dio jutarnjeg mjerjenja (od 8:00 do 9:00 sati). Takva se vremenska raspodjela potencijalno može objasniti boljom vidljivošću u kasnijim jutarnjim satima, što posljedično korelira s višom razinom percipirane prometne i osobne sigurnosti.

4.5 Računanje prosječnog godišnjeg dnevnog biciklističkog prometa (PGDBP)

Jedan od ključnih izazova modeliranja biciklističkog prometa jest računanje, odnosno bolje rečeno procjena, PGDBP-a iz uzoraka kratkotrajnog brojanja. Metode procjene PGDBP-a na temelju kratkotrajnih brojanja oslanjaju se na ekstrapolaciju kratkoročnih uzoraka u

cjelogodišnje prosjeke. Temeljni preduvjet za izračun faktora prilagodbe jest postojanje referentnih lokacija s uređajima za kontinuirano cjelogodišnje brojanje, čiji se prometni obrasci preslikavaju na lokacije sa samo povremenim mjerenjima. Za razliku od standardizirane metodologije izračuna faktora prilagodbe za motorizirani promet, kalibracija faktora za nemotorizirani, a posebice biciklistički promet, još uvijek nema jedinstven usvojeni standard. Razlog su značajne vremenske fluktuacije biciklističkih tokova na dnevnoj i mjesečnoj razini, ali i prostorna distribucija biciklističkog prometa koja je izrazito uvjetovana velikim brojem različitih varijabli – topografijom terena, meteorološkim prilikama (klimatskim uvjetima područja), prometnom infrastrukturom, namjenom bic. infrastrukture (rekreativna, utilitarna, mješovita), i mnogim drugim.

U ovom istraživanju podaci automatskog brojača prometa korišteni su kao referentni cjelogodišnji podatak za procjenu PGDBP-a na ostalim linijskim segmentima biciklističke mreže. Za procjenu PGDBP-a na lokacijama kratkotrajnog brojanja (tablica 14) korišteni su podaci brojanja prometa kao referentni dnevni biciklistički volumen (DBP_{KB}). Pri tome su podaci brojanja ekstrapolirani na cjelodnevnne vrijednosti pomoću faktora uvećanja f_{KB} , koji je dobiven iz omjera DBP-a automatskog brojača (DBP_{AB}) i promatranog broja biciklista tijekom kratkotrajnog brojanja (SDB_{KB}).

Pomoću podataka brojača i kratkotrajnog ručnog brojanja prometa izračunati su faktori prilagodbe dvjema različitim metodama – tradicionalnom i metodom raščlanjivanja. Temeljem faktora prilagodbe dobivene su procijenjene vrijednosti PDGBP-a na lokacijama kratkotrajnog brojanja (zasebno za svaku metodu). Tradicionalna metoda, u literaturi još nazvana AASHTO metoda (prema instituciji *American Association of State Highway and Transportation Officials*), izvorno je razvijena za motorizirani promet. Za nemotorizirani promet prilagođena je primjenom dvaju odvojenih faktora prilagodbe, faktora dana u tjedna (ili „dan-u-tjednu“, engl. *Day-of-Week* – DOW) i mjeseca u godini (engl. *Month-of-Year* – MOY), na sljedeći način (Nosal i dr., 2014):

$$PGDBP_{KB} = SDB_{KB} \times \frac{1}{DF_d} \times \frac{1}{MF_m} \quad (2)$$

gdje je $PGDBP_{KB}$ procijenjeni PGDBP kratkotrajnog brojanja pojedine lokacije za godinu u kojoj je mjerenje izvedeno, SDB_{KB} je volumen izbrojanog bic. prometa tijekom kratkotrajnog brojanja, DF_d je faktor dana u tjednu za dan d , a MF_m je faktor mjeseca u godini za mjesec m . Pri tome se DF_d i MF_m računaju iz podataka automatskog brojača – DF_d se računa iz omjera ukupnog PDGBP-a pojedinog dana u tjednu i ukupnog PGDBP-a, a MF_m iz omjera ukupnog prosječnog mjesečnog bic. prometa (PMBP) pojedinog mjeseca i PGDBP-a. Za dobivanje tih faktora prilagodbe kreirani

su zasebni SQL upiti kojima su se iz baze podataka automatskog brojača prometa izračunali (za svaku pojedinu godinu istraživanja) PDBP za pojedini dan u tjednu i PMBP za pojedini mjesec u godini (vidi prilog 8). S obzirom da je kratkotrajno brojanje izvedeno u četvrtak, 25. studenog 2021., za izračun $PGDBP_{KB}$ korišteni su faktori prilagodbe za četvrtak ($DF_{\text{čet}} = 0,802$) i za mjesec studeni ($MF_{11} = 1,229$) u 2021. godini (tablica 14).

Za razliku od tradicionalne metode, metoda raščlanjivanja (engl. *disaggregate factor method*) računa se jednostavnije koristeći isključivo faktor raščlanjivanja (ili „dan-u-godini“, engl. *Day-of-Year – DOY*). Procijenjena vrijednost PGDBP-a na lokaciji kratkotrajnog brojanja računa se na sljedeći način (Nosal i dr., 2014):

$$PGDBP_{KB} = SDB_{KB} \times \frac{1}{DF_i} \quad (3)$$

gdje je SDB_{KB} je volumen izbrojanog bic. prometa tijekom kratkotrajnog brojanja. Pri tome se faktor raščlanjivanja računa za svaki dan i u godini u kojoj je provedeno kratkotrajno brojanje tako da se podijeli ukupni broj biciklista u tom danu s PGDBP-om automatskog brojača u toj godini:

$$DF_i = \frac{DBP_{AB}}{PGDBP_{AB}} \quad (4)$$

gdje DBP_{AB} i $PGDBP_{AB}$ predstavljaju dnevni biciklistički volumen (DBP) na dan provedenog brojanja te PGDBP na referentnom automatskom brojaču u godini provedenog mjerenja. Na dan provedenog mjerenja automatski brojač registrirao je 1380 prolaza, a u 2021. godini PGDBP iznosio je 1176. Stoga je u procjeni PGDBP-a metodom raščlanjivanja (tablica 12) korišten faktor DF_i od 0,852.

Tablica 14. Računanje PGDBP-a za 2021.godinu na lokacijama kratkotrajnog brojanja

Lokacija	SDB_{KB}	DBP_{Str}	DBP_{KB}	$DBP \% (Str / KB)$	$PGDBP_{KB} (AASHTO)$	$PGDBP_{KB} (disagg.)$
Savska - Kršnjavog	486	10	909	1,10	923	1066
Selska - Horvaćanska	294	5	550	0,91	558	645
Vukovarska	983	20	1838	1,09	1866	2157
Most slobode (Z)	288	15	539	2,79	547	632
Most slobode (I)	275	20	514	3,89	522	603
Savska 25	592	10	1107	0,90	1124	1299
Savska - Slavonska	783	30	1464	2,05	1486	1718
Svetice - Budakova	115	5	215	2,33	218	252
Jadranski most	269	20	503	3,98	511	590

Iz tablice je vidljivo da PGDBP procijenjen metodom raščlanjivanja daje više cjelogodišnje vrijednosti od tradicionalne metode. To je prvenstveno zato jer su faktori DF_d i MF_m izračunati isključivo na temelju podataka s jednog referentnog brojača i potom linearno primijenjeni na sve ostale lokacije kratkotrajnog brojanja. Karakteristika metode raščlanjivanja je što uzima u obzir korekciju za utjecaj razdoblja (studeni) u kojem je mjereno, pretpostavljajući da su stvarni godišnji prosjeci u toplijim mjesecima znatno izraženiji nego što to tradicionalni faktori uspijevaju kompenzirati. S druge strane, omjer DBP_{Str} i DBP_{KB} pokazuje da su podaci dnevnih aktivnosti Strave najzastupljeniji na mostovima i lokaciji s najmanjim bic. prometom (Svetice – Budakova).

Izračunate vrijednosti PGDBP-a na lokacijama kratkotrajnog brojanja korištene su, zajedno s podacima automatskog brojača, kao referentne za usporedbu s procijenjenim PDGBP-om izvedenim iz podataka Strave ($PGDBP_{Str-KB}$). Na taj način analizirana je upotrebljivost Strava podataka u modeliranju volumena biciklističkog prometa za čitavu prometnu mrežu. Procijenjeni $PGDBP_{Str-KB}$ na lokacijama kratkotrajnog brojanja dobiven je iz omjera Strava aktivnosti na lokacijama kratkotrajnog brojanja i automatskog brojača, te množenjem s PDGBP-om na referentnom automatskom brojaču:

$$PGDBP_{Str-KB} = \frac{GBP_{Str-KB}}{GBP_{Str-AB}} \times PGDBP_{AB} \quad (5)$$

gdje je GBP_{Str-KB} ukupna godišnja Strava aktivnost na lokaciji kratkotrajnog brojanja, GBP_{Str-AB} ukupna godišnja Strava aktivnost na lokaciji automatskog brojača, a $PGDBP_{AB}$ prosječni godišnji dnevni biciklistički promet na lokaciji automatskog brojača.

Kao što je gore navedeno, namjena biciklističke infrastrukture važna je varijabla u interpretaciji rezultata PGDBP-a. Utilitarni promet odvija se tijekom cijele godine i izrazito je naglašen u vršnim satima radnog dana. Može se reći da su varijacije utilitarnih aktivnosti manje tijekom zimskih mjeseci. Rekreativni promet povećan je vikendom i u poslijepodnevnom satima, te povišen u toplijem dijelu godine. Stoga je na lokacijama kratkotrajnog brojanja izračunat omjer utilitarne i rekreativne Strava aktivnosti za cjelokupnu 2021. godinu ($U/R \% 2021$), ali i za mjesec studeni ($U/R \% 11/21$). Završno je izračunata apsolutna postotna pogreška (engl *Absolute Percentage Error* – APE; u daljnjem tekstu koristit će se engleska kratica) za pojedinu lokaciju kratkotrajnog brojanja na temelju PGDBP-a procijenjenog iz podataka Strave i izračunatog PGDBP-a iz podataka kratkotrajnog brojanja. Vrijednost APE-e dobivena je formulom (Nosal i dr., 2014b):

$$APE = 100\% \times \frac{|PGDBP_{Str} - PGDBP_{KB}|}{PGDBP_{KB}} \quad (6)$$

U tablici 15 može se, temeljem postotka omjera utilitarne i rekreativne Strava aktivnosti, izdvojiti profil biciklističkog prometa na pojedinim lokacijama brojanja. Sukladno dobivenim vrijednostima i terenskom predznanju, utvrđeno je da niti jedna lokacija nije dominantno rekreativna, već da se dijele na utilitarne (godišnji U/R % > 75) i mješovite (godišnji U/R % u rasponu 25-75). Klasificirano prema namjeni, kao utilitarne lokacije ističu se Vukovarska, Savska – Slavonska, Savska – Kršnjavog i Savska 25, dok su ostale lokacije u kategoriji mješovitog bic. prometa (mostovi, Svetice – Budakova, Selska – Horvaćanska). Jedina lokacija koja bi mogla biti klasificirana kao rekreativna (godišnji U/R % > 20) je križanje Svetice – Budakova, no ta lokacija nije uzeta u obzir jer zbog niskog volumena ne može biti reprezentativna za cjelokupnu skupinu rekreativne namjene. Na utilitarnim lokacijama, gdje je obrazac vožnje sličan onome na lokaciji automatskog brojača (Vukovarska), procijenjeni PGDBP iz Strave i kratkotrajnog brojanja postiže iznimno visoku točnost. Na mostovima i segmentima veće rekreativne aktivnosti, odnosno generalno niže bic. aktivnosti, APE raste. Izračun varijabli U/R % dokazuje da visoki APE na pojedinim lokacijama nije posljedica greške metodologije procijene PGDBP-a, već da je Strava aplikacija različito zastupljena na pojedinim profilima biciklističke infrastrukture te na tim segmentima prometne mreže precjenjuje volumen bic. prometa. To znači da bi ubuduće kratkotrajna mjerenja trebalo provoditi na lokacijama različite kategorije (namjene) i različitog volumena biciklističkog prometa.


Tablica 15. Usporedba izračunatih vrijednosti PGDBP-a i procijenjenih vrijednosti PGDBP-a iz podataka Strave za lokacije kratkotrajnog brojanja

Lokacija	U/R % (11/21)	U/R % (2021)	PGDBP _{Str-KB}	PGDBP _{KB} (AASHTO)	PGDBP _{KB} (disagg.)	APE % (Strava/ AASHTO)	APE % (Strava/ disagg.)
Savska - Kršnjavog	74	55	1002	923	1066	7,89	6,48
Selska - Horvaćanska	58	33	408	558	645	36,71	58,04
Vukovarska	171	107	2170	1866	2157	14,03	0,62
Most slobode (Z)	106	74	1520	547	632	64,03	58,42
Most slobode (I)	86	38	1424	522	603	63,34	57,63
Savska 25	74	50	1357	1124	1299	17,18	4,26
Savska - Slavonska	209	92	1516	1486	1718	1,93	13,36
Svetice - Budakova	42	20	580	218	252	62,40	56,53
Jadranski most	83	53	1869	511	590	72,68	68,41

Uzimajući u obzir dobivene podatke, izračunat je koeficijent uvećanja utilitarnih segmenata mreže iz omjera ukupnog broja prolaza na automatskom brojaču bic. prometa i ukupne Strava aktivnosti na tom linijskom segmentu. Na temelju dobivenog koeficijenta uvećanja ($k_U = 55,289$) izračunat je procijenjeni PGDBP_{Str} za čitavi period istraživanja za one linijske segmente mreže koji su prema namjeni klasificirani kao utilitarni, odnosno koji imaju ukupni $U/R \% > 75$. Za linijske segmente koji su mješovite ili rekreativne namjene ($U/R \% > 75$), izračunat je PGDBP_{Str} na temelju prosječnog koeficijenta uvećanja sa lokacija kratkotrajnog brojanja klasificiranih kao mješovite. Taj koeficijent uvećanja ($k_M = 41,384$) izračunat je za pojedini segment mreže na temelju omjera PGDBP-a (PGDBP_{KB} dobiven metodom raščlanjivanja ima prosječno manji APE za lokacije mješovitog prometa) na lokaciji brojača, ekstrapoliranog na godišnju razinu, i godišnje Strava aktivnosti na lokaciji kratkotrajnog brojača (GBP_{Str-KB}). Iz tog slijedi matematički izraz za izračun PGDBP_{Str} pojedinog segmenta mreže (slika 28):

$$PGDBP_{Str} = \frac{GBP_{Str} \times k}{365} \quad (7)$$

pri čemu je GBP_{Str} godišnja biciklistička aktivnost pojedinog segmenta mreže, a k koeficijent segmenta ovisno o klasifikaciji namjene segmenta.



Slika 28. Izračunati PGDBP po linijskom segmentu mreže za cjelokupno područje istraživanja

5. MODELIRANJE PROMETNIH NESREĆA

Na temelju uspostavljene baze podataka PN-a izvedena je detaljna prostorno-vremenska analiza na području istraživanja za razdoblje od 2018. do 2022. godine. Provedene analize podijeljene su u četiri temeljne skupine prema dostupnosti i vrsti podataka:

- vremenska analiza: istražuje raspodjelu PN-a na godišnjoj, mjesečnoj, tjednoj (radni dan vs. vikend) i satnoj razini (distribucija po satima u danu) kako bi se utvrdio utjecaj dnevnih migracija i sezonalnosti na sigurnost;
- prostorna analiza: daje pregled prostorne distribucije PN-a na razini cijelog grada te na razini GC-i i MO-a kako bi se utvrdila gustoća i učestalost PN-a te povezanost s drugim okolišnih varijablama (meteorološkim i infrastrukturnim);
- analiza demografskih pokazatelja i posljedica: prikazuje klasifikaciju PN-a prema starosti i težini ozljede sudionika.
- analiza SiN efekta: prikazuje odnos ukupnog broja PN-a i ukupne Strava aktivnosti normalizirane po kilometru duljine prometne mreže kako bi se ispitalo postojanje efekta smanjenja apsolutnog rizika od PN-a po pojedincu uslijed povećanja volumena biciklističkog prometa.

5.1 Vremenska analiza prometnih nesreća


Cilj vremenske analize je razlučiti vremenske obrasce i distribuciju PN-a na području Grada Zagreba. Analiza se temelji na kvantitativnim podacima o PN-ama: datumu, satu (odnosno 2-satnom intervalu) i danu u tjednu. Ukupan uzorak obuhvaća 829 PN-a u periodu od 2018. do 2022. godine na području I. i II. Postaje PP-e (tablica 16). Podaci su segmentirani i analizirani kroz četiri glavne vremenske dimenzije: godišnja distribucija prikazana je tablično (kao zbroj mjesečnih distribucija), dok su mjesečna, tjedna i dnevna distribucija prikazane dijagramom i tablično.

Tablica 16. PN-e po PPP-i za pojedinu godinu razdoblja istraživanja

PPP	2018	2019	2020	2021	2022	2018 - 2022
I.	54	76	65	49	66	310
II.	94	93	134	90	108	519
Ukupno	148	169	199	139	174	829

Dijagram ukupnog broja PN-a po mjesecu u godini za promatrani period istraživanja, prikazan na slici 29, pokazuje veliku sličnost s podacima ukupne biciklističke aktivnosti po mjesecima

(slika 7). Učestalost PN-a preslikava se iz sezonalnog karaktera biciklističkog prometa u Zagrebu. Topliji mjeseci (od travnja do listopada) generiraju preko 3/4 ukupnog broja PN-a. Najveći broj PN-a (tablica 17) događa se u lipnju (117 ili 14,1 %), rujnu (101 ili 12,2 %) i srpnju (100 ili 12,1 %). U tom periodu proljetni mjeseci uoči ljeta generiraju nešto manje PN-a od jesenskih mjeseci, što se može pripisati dužoj dnevnoj svjetlosti. Neuobičajeno niski broj PN-a tijekom kolovoza (63) prati neuobičajeno niski volumen bic. prometa. Iako su meteorološke prilike tijekom kolovoza idealne, pad broja PN-a uzrokovan je manjim intenzitetom biciklističkog i motoriziranog prometa unutar grada usred sezone godišnjih odmora. Najmanji broj nesreća zabilježen je u prosincu (23 ili 2,8 %) i siječnju (28 ili 3,4 %), što je zasigurno zbog značajnog nižeg broja biciklista na cestama uslijed hladnoće, padalina i poledice.



Slika 29. Ukupno PN-a po mjesecima za cjelokupno razdoblje istraživanja


Navedena mjesečna distribucija u tabličnom obliku (tablica 17) prikazuje lipanj 2020. (29) kao mjesec s najvećim brojem PN-a, a prosinac 2022. godine (2) u cjelokupnom promatranom periodu. Godišnja distribucija otkriva da je pandemija ne samo imala utjecaja na povećanje rekreativnog biciklizma i bic. aktivnosti u cjelini, već i na ukupno povećanje broja PN-a na području Grada Zagreba. To pokazuje da povećanje volumena bic. prometa izravno povećava izloženost biciklista potencijalnim konfliktnim situacijama u prometu.

Tablica 17. PN-e po mjesecima u godini za pojedinu godinu razdoblja istraživanja

Mjesec	2018	2019	2020	2021	2022	2018 - 2022
1	4	6	4	6	8	28
2	4	5	10	7	8	34
3	2	10	11	11	12	46
4	12	19	24	9	15	79

5	21	16	18	18	20	93
6	21	21	29	21	25	117
7	15	21	26	14	24	100
8	16	14	17	6	10	63
9	17	20	22	24	18	101
10	20	17	17	16	24	94
11	11	12	16	4	8	51
12	5	8	5	3	2	23
Ukupno	148	169	199	139	174	829

Unatoč izraženoj sezonalnosti zabilježenih mjesečnih distribucija (slika 30), pojedini mjeseci u godini više fluktuiraju od godine do godine. Primjer toga su travanj i studeni. Travanj 2020. bilježi jedan od najviših brojeva PN-a (24) tijekom cjelokupnog perioda, a razlog tome su već prethodno spomenute epidemiološke mjere koje su uzrokovale nagli porast biciklističke aktivnosti. Studeni iste 2020. godine predstavlja još jednu takvu negativnu anomaliju s 16 zabilježenih PN-a, što je gotovo trećina petogodišnjeg uzorka za studeni. suprotno tome, studeni 2021. predstavlja pozitivnu anomaliju sa samo 4 PN-e.




Slika 30. Prikaz PN-a po mjesecima u godini i ukupno po mjesecima za sve godine

Analiza distribucije PN-a po danima u tjednu (tablica 18, slika 31) pruža potvrdu da su PN-e u Zagrebu u direktnoj vezi s dnevnim migracijama (utilitarnim aktivnostima). Pri tome radni dani ukupno čine 81 % (672) PN-a, dok je vikendom subota (97 PN) značajno opasnija od najsigurnije nedjelje (60 PN). Iznimka iznova predstavlja nedjelja u pandemijskoj 2020.godini s čak 18 PN-a od ukupnih 60 u svim godinama zajedno. Najkritičniji dan u tjednu je petak sa 141 PN-om (17 %), a slijede ga utorak sa 135 PN-a (16,3 %) te ponedjeljak i četvrtak s po 133 PN-e. Tijekom promatranog razdoblja petkom u 2019. se dogodilo najviše PN-a, njih čak 39 (te godine petak je pao čak dva puta na 13. dan u mjesecu).

Tablica 18. PN-e prema danu u tjednu za pojedinu godinu razdoblja istraživanja

Dan u tjednu	2018	2019	2020	2021	2022	2018 - 2022
Pon	25	31	34	21	22	133
Uto	23	24	29	25	34	135
Sri	26	16	30	22	36	130
Čet	19	31	34	23	26	133
Pet	19	39	32	21	30	141
Sub	24	20	22	18	13	97
Ned	12	8	18	9	13	60
Ukupno	148	169	199	139	174	829



Slika 31. Prikaz PN-a po danima u tjednu po pojedinoj godini i ukupno za sve godine

Analizom križne tablice PN-e prema vremenu u danu za pojedinu dan u tjednu (tablica 19) jasno je vidljiva povezanost popodnevni vršnih sati prometnog opterećenja i učestalosti PN-a. U vrhuncu popodnevnog prometnog opterećenja između 16 i 18 sati dogodilo se gotovo petina svih PN-a (151). Prethodni vremenski period od 14 do 16 sati bilježi 118 PN-a (14 %), što znači da je od 14 do 18 sati zabilježena trećina svih PN-a. Neočekivano velik broj PN-a događa se od 12 do 14 sati (105) u odnosu na broj PN-a u jutarnjim vršnim satima. Tijekom radnih dana rano ujutro između 06 i 08 sati bilježe se ukupno 74 PN-e, dok se vikendom u tom ranom terminu dogode sveukupno tek 2 PN-e (što potvrđuje izostanak jutarnjih utilitarnih vožnji vikendom). Vikendom se PN-e disperziraju tijekom dana, no uočava se pojačan noćni rizik. Primjerice, subota bilježi 3 nesreće u terminu od 02 do 04 sata ujutro, što čini čak 75 % svih PN-a u tom dobu noći kroz cijeli tjedan.


Tablica 19. PN-e prema vremenu u danu za pojedini dan u tjednu

Vrijeme u danu	Pon	Uto	Sri	Čet	Pet	Sub	Ned	Ukupno
00-02	2	2	1	1	0	1	4	11

02-04	0	0	0	0	1	3	0	4
04-06	1	0	0	2	1	0	1	5
06-08	14	16	10	10	12	1	1	64
08-10	16	18	16	11	21	5	4	91
10-12	10	12	7	14	14	11	5	73
12-14	10	18	15	15	19	16	12	105
14-16	25	25	14	16	19	15	4	118
16-18	25	17	30	26	26	19	8	151
18-20	14	16	14	18	12	16	7	97
20-22	13	11	14	17	13	6	11	85
22-24	3	0	9	3	3	4	3	25
Ukupno	133	135	130	133	141	97	60	829

5.2 Prostorna analiza prometnih nesreća

Uzimajući u obzir prikazane varijacije u dnevnoj i tjednoj dinamici nastanka PN-a, izrađen je kartografski prikaz PN-a ovisno o radnom danu, prometnoj špici (vršnim satima) i vikendu. Karta na slici 18 pruža uvid u prostorni raspored PN-a razvrstanih u tri kategorije: radni dan u poslijepodnevnoj špici (14 – 18 sati), radni dan u ostalo vrijeme te vikend. U podlozi karte prikazane su postojeće biciklističke staze s pripadajućim pojasom (engl. *buffer*) od 50 m, koji predstavlja okolno područje cestovne mreže u kojem biciklisti gravitiraju prema bic. infrastrukturi. U glavnoj karti sitnijeg mjerila može se primijetiti da su plavi rombovi (PN-e koje su se dogodile vikendom) znatno češći od zelenih u perifernim dijelovima grada, pogotovo na južnom izlazu iz grada (na području Laništa, Sv. Klare i dalje prema jugoistoku), te u rekreacijskim i brdskim predjelima, npr. sjevernom dijelu grada uz PP Medvednica. U tim područjima većinu ostalih (zelenih) PN-a čine one koje su se dogodile od 14 do 18 sati. To potvrđuje uobičajeni prostorni i vremenski obrazac rekreativnih aktivnosti. Zbog gustoće PN-a u centralnom dijelu izrađena je umetnuta kata krupnijeg mjerila, koja pruža detaljniji uvid u širi centar grada. Vidljivo je da se najveći broj PN-a u području GC-i Donji grad (npr. zeleni val) i Trnje (Vukovarska) dogodio radnim danom na biciklističkoj infrastrukturi. Suprotno tome, GC Trešnjevka iskače jer se gusto naslagane lokacije PN-a protežu na području bez bic. infrastrukture. U tzv. trešnjevačkom trokutu, omeđenom zapadnim dijelom Vukovarske, Savskom cestom i Tratinskom ulicom, uočava se veliko žarište PN-a koje su gotovo isključivo vezane za radni dan. Pogotovo je izražen pravac Tratinskom i Ozaljskom ulicom od Savske do Selske ceste na kojima se dogodilo 18 PN-a radnim danom od 2018. do 2022. godine.



Slika 32. Karta PN-a ovisno o radnom danu ili vikendu


Karta na slici 32 vizualizira mikrolokacije PN-a, no gustoća i preklapanje PN-a na manjem području onemogućuje vizualno razlučivanje pojedinačnih objekata. Kako bi se prikaz pojedinačnih lokacija PN-a mogao kvantificirati i komparirati, izvedena je prostorna analiza na administrativnoj razini u QGIS-u kojom su prebrojane PN-e prema GC-i i MO-u u kojima se nalaze. Na temelju tog podatka izrađena je daljnja prostorna analiza PN-a po GC-ima i MO-ima. Tablica 20 prikazuje ukupan broj PN-a po GC-i Grada Zagreba za svaku godinu i ukupno za sve godine. Iz tablice je vidljivo da GC-i Trešnjevka – jug (116), Trešnjevka – sjever (110) i Novi Zagreb – zapad (100) imaju najveći broj zabilježenih PN-a, što predstavlja gotovo 40 % svih PN-a. Mjesečni maksimum od čak 35 PN-a zabilježen je 2020. godine u GC-i Trešnjevka – jug. Najniži broj PN-a zabilježen je u GC-ima Brezovica (7) i Podsljeme (6). Obje GC-i su na rubnom dijelu grada, pri čemu je Brezovica na periferiji, a Podsljeme na brdovitom terenu. Zajedničko im je također da nemaju razvijenu bic. infrastrukturu te da je bic. aktivnost primarno rekreativna. Podaci za Sesvete i Stupnik, označeni zvjezdicom, prikazani su u tablici jer su PN-e preuzete u bazu PN-a. Iako je broj PN-a na tim područjima vrlo nizak, podaci nisu mjerodavni jer oba područja nisu u administrativnoj nadležnosti I. i II. Postaje PP-e. Uz to se Stupnik nalazi izvan područja istraživanja (izvan službene granice grada). Stoga ti podaci nisu uzeti u obzir prilikom interpretacije rezultata analize.

Tablica 20. PN-e po GC-ima Grada Zagreba za pojedinu godinu

Gradska četvrt	2018	2019	2020	2021	2022	2018 - 2022
Brezovica	1	0	0	3	3	7
Črnomerec	5	10	11	8	14	48
Donja Dubrava	12	7	4	4	3	30
Donji grad	12	18	11	8	15	64
Gornja Dubrava	6	6	10	5	2	29
Gornji grad - Medveščak	3	2	4	3	3	15
Maksimir	5	13	6	10	6	40
Novi Zagreb - istok	11	8	10	7	4	40
Novi Zagreb - zapad	23	15	21	14	27	100
Peščenica - Žitnjak	6	15	15	6	12	54
Podsljeme	0	2	1	2	1	6
Podsused - Vrapče	6	8	13	5	7	39
*Sesvete	0	0	0	0	6	6
Stenjevec	6	6	14	13	8	47
Trešnjevka - jug	17	21	35	15	28	116
Trešnjevka - sjever	24	22	26	21	17	110
Trnje	11	14	17	13	18	73
*Stupnik	0	2	1	2	0	5
Ukupno	148	169	199	139	174	829

S namjerom da se izbjegne tablični prikaz učestalosti PN-a za svih 218 MO-a, ali i da se detaljnije prikaže prostorna distribucija po manjoj administrativnoj jedinici od GC-i, izrađena je koropletna karta ukupnog broja PN-a po MO-ima za period od 2018. do 2022. u mjerilu 1:125000 (slika 33). Klasifikacija MO-a prema ukupnom broju PN-a izvedena je metodom prirodnih granica (engl. *natural breaks*). Karta jasno pokazuje da unutar iste GC-i postoje značajne razlike, pri čemu važnu ulogu igra definiranje međusobnih granica MO-a. Većina velikih prometnica nije podijeljena (rascijepana) na sredini ulice, već u cijelosti dodijeljena jednom od dva granična MO-a. Tako MO u središtu GC-i Trešnjevka – sjever ne bilježi niti jednu PN-u dok okolni imaju visoke apsolutne vrijednosti. Isto vrijedi i za MO-e unutar Trnja (Veslačko naselje, Cvjetnica, Vrbik, Staro Trnje) i Donjeg grada (Andrija Medulić, Matko Laginja, Pavao Šubić), GC-ima s visokim ukupnim brojem PN-a. Uobičajeno najniže vrijednosti (0-1 PN), prikazane sivom, nalaze se u MO-ima na periferiji i brdovitim područjima. Iznimka su MO-i unutar GC-i Gornji grad – Medveščak, koji se nalaze u samom centru grada, sjeverno od Ilice, u stambenom području s pretežno obiteljskim kućama. MO-a u najvišoj klasi po ukupnom broju PN-a nalaze se na potezu od Savsku ceste prema jugu (Antun Mihanović, Knežija), uz Zagrebačku aveniju (Horvati – Srednjaci, Jarun, Rudeš) te uz glavne prometnice Novog Zagreba (Kajzerica). Jedini MO istočno od središta grada u najvišoj klasi je MO Kanal (26 PN-a). Treba napomenuti da se nalazi unutar

poslovnog područja na Radničkoj cesti i da je omeđen najprometnijim ulicama (Držićeva, Vukovarska, Heinzelova i Branimirova), ali mu prostorno pripadaju samo Držićeva i Vukovarska.



Slika 33. Karta PN-a po MO-ima Grada Zagreb za cjelokupni period istraživanja


Dok tablica 20 prikazuje učestalost PN-a za cjelokupnu GC koristeći apsolutne vrijednosti, tablica 21 prikazuje prostornu gustoću PN-a po km^2 . Uvođenjem varijable površine pojedine GC-i mijenja se percepcija prometnog rizika. Najupečatljivija razlika između apsolutnoga broja i prostorne gustoće vidljiva je na primjeru Donjega grada. Iako prema apsolutnom broju (64 PN) zaostaje za GC-ima s najvećim brojem PN-a, normalizacijom na iznimno malu površinu GC-i (svega $3,00 \text{ km}^2$) Donji grad postaje uvjerljivo najrizičnija četvrt. Prosječna gustoća od $4,27 \text{ PN/km}^2$ (s ekstremnim vrhuncem od $6,00 \text{ PN/km}^2$ u 2019. godini) ukazuje na opasnost kretanja unutar visoko opterećenoga urbanog centra grada. Primjer odstupanja prikazanih metrika predstavlja GC Novi Zagreb – zapad, koja s ukupno 100 PN-a spada u sam vrh učestalosti PN-a, no zbog velike površine ($62,33 \text{ km}^2$) njezina prosječna gustoća iznosi tek $0,32 \text{ PN/km}^2$. Suprotno tome, GC-i Trešnjevka – jug i Trešnjevka – sjever imaju visoke apsolutne vrijednosti i prostornu gustoću PN-a, čime nedvojbeno potvrđuju da je Trešnjevka najugroženije i prostorno najzasićenije prometno područje za bicikliste. Navedene GC-i, uz Trnje i Donji grad, imaju najmanju površinu, a najveći broj PN po jedinici površine. Niti jedna druga GC ne prelazi prosječno u promatranom razdoblju više od 1 PN/km^2 . S druge strane, površinom velike GC-i

Brezovica i Podsljeme zadržavaju minimalne vrijednosti u obje tablice što ih čini najsigurnijim područjima za bicikliste.

Tablica 21. PN-e po jedinici površine GC-i Grada Zagreba za pojedinu godinu

Gradska četvrt	Površina (km ²)	2018	2019	2020	2021	2022	Prosjek
Brezovica	127,37	0,01	0,00	0,00	0,02	0,02	0,01
Črnomerec	24,71	0,20	0,40	0,45	0,32	0,57	0,39
Donja Dubrava	10,87	1,10	0,64	0,37	0,37	0,28	0,55
Donji grad	3,00	4,00	6,00	3,67	2,67	5,00	4,27
Gornja Dubrava	40,55	0,15	0,15	0,25	0,12	0,05	0,14
Gornji grad - Medveščak	10,22	0,29	0,20	0,39	0,29	0,29	0,29
Maksimir	14,93	0,33	0,87	0,40	0,67	0,40	0,54
Novi Zagreb - istok	16,54	0,67	0,48	0,60	0,42	0,24	0,48
Novi Zagreb - zapad	62,33	0,37	0,24	0,34	0,22	0,43	0,32
Peščenica - Žitnjak	35,24	0,17	0,43	0,43	0,17	0,34	0,31
Podsljeme	58,83	0,00	0,03	0,02	0,03	0,02	0,02
Podsused - Vrapče	36,10	0,17	0,22	0,36	0,14	0,19	0,22
Stenjevec	12,00	0,50	0,50	1,17	1,08	0,67	0,78
Trešnjevka - jug	10,05	1,69	2,09	3,48	1,49	2,79	2,31
Trešnjevka - sjever	5,81	4,13	3,79	4,48	3,61	2,93	3,79
Trnje	7,42	1,48	1,89	2,29	1,75	2,43	1,97

Uz normalizaciju broj PN-a po površini GC-i, izvedena je i normalizacija broja PN-a na 10000 stanovnika. Uzimajući u obzir demografsku strukturu GC-i i MO-a omogućuje se pravedna usporedbu između gusto naseljenih urbanih četvrti i rjeđe naseljenih područja. Usporedbom karte s apsolutnim vrijednostima PN-a (slika 33) i karte PN-a na 10000 stanovnika po MO-ima i GC-ima (slika 34) vidljivo je da veliki dijelovi Novog Zagreba, Trešnjevke i Maksimira, koji su prvotno imali visok apsolutni broj PN-a, sada spadaju u niže ili srednje klase. To ukazuje na to da je rizik po pojedinom stanovniku na tim područjima zapravo umjeren, a visoke apsolutne brojke rezultat su velike gustoće naseljenosti. MO-i u području velikih prometnica (naročito Savske ceste, Vukovarske i zelenog vala), urbanih (Donji grad) i poslovnih zona (oko Radničke ceste) imaju relativno mali broj stalnih stanovnika u odnosu na dnevnu fluktuaciju ljudi i vozila. Na taj način preuzimaju veliki udio prometnog opterećenja svakodnevnih putovanja, ali ujedno i sigurnosni rizik koji s time dolazi.




Slika 34. Karta PN-a na 10000 stanovnika po MO-ima i GC-ima Grada Zagreb

Uvriježena metoda za vizualizaciju gustoće i identifikaciju žarišta PN-a u GIS okruženju je KDE. Metodom se procjenjuje intenzitet događaja (PN-a) na cjelokupnom području stvaranjem zaglađene površine gustoće, a rezultat je toplinska karta (slika 35) koja prikazuje rizik ili prostorno grupiranje PN-a. Prednosti ove metode su što precizno locira zone visoke koncentracije PN-a bez obzira na administrativne granice, pretvara raštrkane točke u neprekidnu površinu koju je lakše interpretirati donositeljima odluka, te smanjuje utjecaj manjih prostornih pogrešaka u koordinatama pojedinačnih PN-a. Nedostatak metode je što ističe učestalost PN-a u prostoru zanemarujući vanjske čimbenike koji utječu na nastanak PN-a.

Slika 21 prikazuje kartu ukupnog broja PN-a upotrebom KDE metode za cijelo područje istraživanja u mjerilu 1:150000 te umetnutu kartu u krupnijem mjerilu 1:50000. Završni raster izrađen je u QGIS-u odabirom širine pojasa od 500 m i oblikom matematičke funkcije jezgre (*Quartic*), kojima se definiraju razina glatkoće i utjecaj okolnih točaka na procjenu gustoće u zadanom radijusu. Pritom je odabrani radijus od 500 m osigurao optimalnu razinu zaglađivanja podataka, sprječavajući gubitak važnih detalja i nastanak rascjepkanih prikaza na razini cijelog istraživanog područja. Na temelju detaljnijeg kartografskog prikaza vidljivo je da se kao glavno žarište (označeno svijetložutom) ističe već spomenuti trešnjevački trokut, a potom i na zapadu križanje Zagrebačke avenije i Rudeške ceste. Iz karte (slika 21) se može zaključiti da se lokacije


visoke učestalosti PN-a (izražena narančasto-žutim nijansama) protežu primarnim gradskim prometnim pravcima, koji pripadaju sekundarnoj kategoriji cesta prema OSM kategorizaciji.



Slika 35. Karta ukupnog broja PN-a izrađena KDE metodom

U sklopu istraživanja provedena je dodatna prostorna analiza PN-a u korelaciji s meteorološkim uvjetima. Prvo su prikupljeni meteorološki podaci analizirani na dnevnoj, mjesečnoj i godišnjoj razini (vidi priloge 9 i 10), a potom je izračunat *Pearsonov* koeficijent korelacije između podataka biciklističke aktivnosti na automatskom brojaču i dnevnih meteoroloških podataka. Izračunati koeficijent korelacije (r) ukupnog dnevnog broja prolaza na brojaču i prosječne dnevne temperature za cjelokupni period istraživanja iznosi $r = 0,40$, što predstavlja umjerenu pozitivnu korelaciju. Suprotno tome, između podataka brojača i ukupne dnevne količine padalina ($r = -0,17$) očekivano je negativna, ali razmjerno slaba korelacija. Nakon toga su povezane tablice PN-a i meteoroloških podataka u Postgres bazi na temelju datuma, te su unutar QGIS-a filtrirane PN-e za dane bez (604) i sa (225) padalinama. U promatranom periodu ukupno 27 % svih PN-a dogodilo se u danima kada su izmjerene padaline. Potom su PN-e su klasificirane prema količini padalina. S obzirom da ne postoji međunarodni standard za klasifikaciju padalina prema količini, odabrane su tri klase ovisno o ukupnoj količini u 24 sata: 0,1 – 9,9 mm (slaba kiša), 10,0 – 29,9 mm (umjerena kiša), 30,0 i više (jaka i vrlo jaka kiša). Prema navedenoj klasifikaciji ukupno je 178 PN-a (79 %) zabilježeno za vrijeme slabe kiše, 39 PN-a za vrijeme umjerene (17,5


%), a samo 8 PN-a za vrijeme jake kiše (3,5 %). Završno je izrađen kartografski prikaz u mjerilu 1:100000 s umetnutom kartom krupnijeg mjerila 1:250000 (slika 36). U podlozi karte je prikazana bic. infrastruktura s pripadajućim okolnim pojasom od 50 m kako bi se vizualno analizirala moguća poveznica između meteoroloških uvjeta i bic. infrastrukture. Uvidom u cjelokupno područje primjetno je da rubnim dijelovima grada, prvenstveno sjevernom i jugoistočnom, dominiraju PN-e bez pojave padalina. U detaljnijem pregledu na umetnutoj karti dolaze do izražaja područja Ilice (gornji dio) i pravac po Tratinskoj, od Trešnjevačkog trga do Savske ceste, na kojima se bilježi značajan broj PN-a uz prisutnost padalina. Isto vrijedi i za pravac Maksimirskom cestom i Avenijom Dubrava. Zajedničko svim navedenim pravcima jest što se tramvajska infrastruktura miješa s cestovnim prometom.



Slika 36. Karta PN-a prema količini padalina

Stoga je odlučeno ispitati analizu zona potencijalnog konflikta biciklističkog prometa i tramvajske infrastrukture. U QGIS je uvezen linijski sloj tramvajske infrastrukture, te je vizualno klasificiran na segregiranu tramvajsku prugu (odvojenu od cestovnog prometa) i integriranu na prometnici. Na karti (slika 37) su izdvojene PN-e zabilježene uz padaline, a crvenom linijom je prikazana segregirana tramvajska pruga. Vizualnom analizom utvrđeno se da 26 PN-a od ukupno 225 PN-a dogodilo uz prisutnost padalina u neposrednoj blizini ili na samoj tramvajskoj infrastrukturi. Iako brojka nije visoka, zabrinjava činjenica da preko 3,1 % svih zabilježenih PN-

a, koje su se dogodile u petogodišnjem razdoblju na području Grada Zagreba, ispunjava oba specifična uvjeta – da su se dogodili na tramvajskoj infrastrukturi u danima kada su izmjerene padaline. Od toga su četiri PN-e na Ilici i Savskoj, tri na Av. Dubrava te čak po šest na Maksimirskoj i Tratinjskoj.



Slika 23. Karta PN-a uz prisutnost padalina u korelaciji s tramvajskom infrastrukturom

5.3 Analiza demografskih pokazatelja i posljedica prometnih nesreća

S obzirom da podaci PN-a zaprimljeni za područje I. Postaje PP-e ne sadrže informaciju o dobi sudionika, izrađen je tablični pregled PN-a prema starosti za područje II. Postaje PP-e (tablica 22). Potrebno je znati da je ukupan broj sudionika veći od samog broja PN-a jer je u nekim PN-ama sudjelovalo više sudionika. Ukupno uzorak sadrži 531 zapis, ali za 42 osobe nisu poznate informacije, stoga je dobna struktura analizirana na temelju 489 zapisa. Prosječna starost sudionika je 36,7 godina, medijan je 34 godine, a standardna devijacija je 18,2 godina. Najmlađi sudionik imao je u trenutku nastanka PN-e samo 5 godina, a najstariji 84 godine. Kategorizacija dobi izvedena je prema kategorizaciji dobne struktura unutar aplikacije Strava. Mlađi odrasli sudionici u dobnoj skupini od 18 do 34 godine sudjelovali su u gotovo 32 % svih PN-a (169). Sudionici srednje dobi (35 - 54) sudjelovali su u 28 % svih PN-a. Zabrinjava činjenica da je 81

maloljetna osoba u okviru biciklističkog prometa bila sudionik PN-e. Najveći postotni skok u jednoj godini doživjela je dobna skupina osoba starijih od 65 godina, i to u pandemijskoj 2020. u odnosu na 2019.

Tablica 22. PN-e prema starosti sudionika

Dob	2018	2019	2020	2021	2022	Sve godine
< 18	13	14	23	19	12	81
18 - 34	32	32	45	25	35	169
35 - 54	39	29	34	20	27	149
55- 64	8	10	13	5	7	43
65 +	7	5	14	7	14	47
np	2	7	7	13	13	42
Ukupno	101	97	136	89	108	531

Osim dobne strukture, podaci PN-a dobiveni od II. Postaje PP-e sadržavali su klasifikaciju posljedica PN-a koja se razlikuje od klasifikacije podataka I. Postaje PP-e. Iz tog razloga izravna statistička usporedba ovih dvaju skupova podataka nije moguća zbog različitih kriterija bilježenja ozljeda i materijalne štete. Kategorija težine PN-a prema posljedicama sudionika u I. Postaji PP-e definira klasu „materijalna šteta“ kao zasebnu varijablu (tablica 23), dok II. Postaja PP-e materijalnu štetu agregira unutar klase s lakšim ozljedama (tablica 24). Zbog tog spajanja nemoguće je podacima II. Postaje PP-e (tablica 24) izolirati PN-e koje su rezultirale isključivo materijalnom štetom od onih s lakšim tjelesnim ozljedama, no zato je moguće razlikovati PN-e s teškim ozljedama (64) od onih s lakšim ozljedama ili materijalnom štetom (449). Suprotno tome, I. Postaja PP-e (tablica 23) sve ozljede svrstava u istu kategoriju (224), zbog čega nije moguće razlikovati težinu ozljede. Jedini parametar za usporedbu je broj sudionika koji su smrtno stradali, pri čemu treba naglasiti da su u jednoj PN-i na području II. Postaje PP-e stradale 2 osobe (što čini ukupno 7 smrtnih ishoda unutar promatranog perioda).

Tablica 23. PN-e prema posljedicama za sudionike (I. Postaja PP-e)

Posljedica	2018	2019	2020	2021	2022	2018 - 2022
Materijalna šteta	14	24	15	14	18	85
Ozljeda	40	52	49	35	48	224
Smrt	0	1	1	0	0	2
Ukupno	54	77	65	49	66	311

Tablica 24. PN-e prema posljedicama za sudionike (II. Postaja PP-e)

Posljedica	2018	2019	2020	2021	2022	2018 - 2022
------------	------	------	------	------	------	-------------

Laka ozljeda/ mat. šteta	81	80	114	78	96	449
Teška ozljeda	12	13	19	8	12	64
Smrt	1	0	1	4	0	6
Ukupno	94	93	134	90	108	519

5.4 Sigurnost u brojevima

SiN u kontekstu biciklističkog prometa označava fenomen smanjenja apsolutnog rizika od PN-a po pojedincu uslijed povećanja volumena biciklističkog prometa. Na temelju dostupnih podataka Strava aktivnosti, lokacija PN-a i postojeće bic. infrastrukture izvedena je analiza SiN efekta na području istraživanja po pojedinoj godini (vidi prilog 11) i za cjelokupni promatrani period (tablica 25). Prvi korak u analizi obuhvaćao je definiranje pojedinih zona biciklističkog prometa, odnosno izrada pojasa bic. infrastrukture upotrebom funkcije *Buffer* u QGIS-u. Zona biciklističke infrastrukture i pojasa uz nju, određeni su na temelju analize veličina raskrižja, prostornog položaja biciklističkih staza (i problema prekidanja bic. pravaca na križanjima i pojedinim linijskim segmentima mreže) i generalnog područja koje je pod utjecajem bic. infrastrukture. Isprobane su različite veličine pojasa (20, 25, 50 i 100 m) te je odabrana, zbog prethodno navedenih razloga, odabrana opcija od 50 m. Osim samo pojasa bic. infrastrukture izrađen je i prsten koji okružuje tu zonu u razmaku od 50 do 200 m, a u kojem biciklističke aktivnosti gravitiraju prema bic. stazama. Ostatak mreže čini sav ostali prostor izvan zone bic. infrastrukture i okolnog prstena. Za svako pojedino područje su putem prostornih upita u QGIS-u izračunati sljedeće varijable za sve godine zasebno (vidi prilog 11) te za period preklapanja podataka PN-a i Strave (tablica 25):

- ukupan broj PN-a,
- dužina svih Strava segmenata (u km),
- godišnji prosjek biciklističkog prometa iz Strave za sve aktivnosti (*PGBP ukupno*), te za utilitarne (*PGBP util*) i za aktivnosti (*PGBP rekr*),
- omjer utilitarne i rekreativne Strava aktivnosti (*U/R % prosjek*) kao prosjek svih linijskih segmenata u pojedinoj zoni,
- ukupan broj svih, utilitarnih te rekreativnih Strava aktivnosti za cjelokupni period (po 10000 aktivnosti),
- omjer ukupne utilitarne i rekreativne Strava aktivnosti (*U/R %*),
- ukupna, utilitarna i rekreativna Strava aktivnost po kilometru mreže,

- indeks ukupnog, utilitarnog i rekreativnog SiN efekta: označava ukupan broj PN-a u odnosu na ukupnu, utilitarnu i rekreativnu aktivnosti po duljini (kilometru) prometne mreže.

Tablica 25. Usporedba SiN efekta na biciklističkoj infrastrukturi, oko nje i na ostatku mreže

2019 - 2022		Bic. Infrastruktura (50m)	Prsten oko bic. infra. (50-200m)	Ostatak mreže
PN		346	124	207
Strava	Duljina segmenata (km)	946,20	806,56	3279,83
	PGBP ukupno	950,66	412,56	566,65
	PGBP util	310,56	118,91	99,91
	PGBP rekr	640,12	293,68	466,78
	U/R % prosjek	54,87	51,53	36,33
	Ukupno (x 10k)	11113,27	4546,55	9838,23
	Util (x 10k)	3607,61	1291,20	1748,25
	Rekr (x 10k)	7505,83	3255,58	8090,47
	U/R %	48,06	39,66	21,61
	Ukupno (x 10k) / km	1,00	0,51	0,17
	Util (x 10k) / km	0,33	0,15	0,03
	Rekr (x 10k) / km	0,68	0,36	0,14
SiN indeks	SiN ukupno	344,38	242,42	1198,14
	SiN util	1054,19	841,10	6795,70
	SiN rekr	511,45	340,56	1454,50

U tablici 24 rizik je kvantificiran kroz SiN indeks, koji predstavlja omjer broja PN-a i ukupne Strava biciklističke aktivnosti normalizirane po kilometru duljine prometne mreže. Niža vrijednost SiN indeksa označava veću sigurnost, odnosno manji rizik od PN-e po biciklistu na 10000 aktivnosti. Viša vrijednost SiN indeksa označava manju sigurnost, odnosno veći rizik od PN po aktivnom biciklistu. Promatranjem ukupnih vrijednosti za razdoblje od 2019. do 2022. godine, uočava se značajna razlika u riziku između zona s visokom i zona s niskom biciklističkom aktivnosti. Unatoč tome što je duljina segmenata biciklističke mreže na kojoj se voze Strava korisnici više nego tri puta manji od ostatka mreže, ukupan broj aktivnosti u neposrednom području bic. infrastrukture je veći od ukupnih aktivnosti na ostatku mreže.

Zonu bic. infrastrukture karakterizira izrazito visoki broj aktivnosti po jedinici duljine mreže, pri čemu vrijednost od 1,00 označava ukupno 10000 aktivnosti po kilometru u promatranom razdoblju. Prsten oko područja infrastrukture ima dvostruko manji ukupan broj aktivnosti po kilometru (0,51) te najniži indeks SiN efekta (*SiN ukupno*) od 242,42. Ostatak mreže karakterizira

iznimno nizak ukupan broj aktivnosti po kilometru (0,17), no izrazito visok SiN indeks (1198,14). Na temelju toga može se zaključiti da je biciklist koji vozi na dijelovima mreže nepovezanim s biciklističkom infrastrukturom (ostatak mreže) izložen čak 3,48 puta većem riziku od PN-e u usporedbi s biciklistom koji se kreće na bic. infrastrukturi, odnosno gotovo 4,94 puta većem riziku nego unutar pojasa neposredno blizu infrastrukture.

Odvajanjem utilitarnih i rekreativnih aktivnosti moguće je analizirati rizik ovisno o vrsti biciklističke aktivnosti. Rezultati analize jasno pokazuju da je SiN efekt izraženiji kod utilitarnog tipa nego kod rekreativnog tipa aktivnosti. Utilitarne aktivnosti (*SiN util*) na ostatku mreže imaju izrazito visok indeks rizika od 6795,70, što je 6,45 puta više nego u zoni bic. infrastrukture (1054,19). Rekreativne aktivnosti (*SiN rekr*) na ostatku mreže imaju indeks od 1454,50, što je 2,84 puta više nego na infrastrukturi (511,45). Budući da se rekreativne aktivnosti često odvijaju izvan vršnih sati (u manje konfliktnim uvjetima), rizik je općenito niži, a samim time je i utjecaj rasta aktivnosti na sigurnost (iako i dalje prisutan) manje značajan nego kod utilitarnih aktivnosti.

6. IDENTIFIKACIJA ŽARIŠTA PROMETNIH NESREĆA

Identifikacija opasnih mjesta, tradicionalno poznatih kao „crne točke” ili žarišta predstavlja jedan od ključnih instrumenata za sustavno povećanje sigurnosti cestovnog prometa. U području motoriziranog prometa razvijene su različite metode za identifikaciju opasnih mjesta, no ne postoji međunarodni standard te velika većina država i dalje primjenjuje isključivo kriterij učestalosti PN-a (Aziz i Ram, 2022). Trenutno aktualna *Rate Quality Control* (RQC) metodologija u RH za identifikaciju opasnih mjesta u cestovnoj prometnoj mreži bazirana je na statističkom ispitivanju svake lokacije na kojoj se dogodila PN-a (Fakultet prometnih znanosti, 2016b). Za svaku lokaciju se, na temelju prosječne stope PN-a, provodi usporedba stope PN-a s kritičnom razinom nastanka PN-a, te se identificirana potencijalna opasna mjesta rangiraju prema omjeru između stope i kritične razine nastanka PN-e. Pri tome se za izračun stope PN-a koristi PGDP kao mjere prometnog opterećenja. Za razliku od jednostavnih numeričkih (apsolutnih) metoda koje lokacije vrednuju isključivo na temelju ukupnog broja prometnih nesreća (čime su neizbježno pristrane prema lokacijama s izrazito velikim volumenom prometa), RQC metoda predstavlja znanstveno utemeljeni statistički pristup koji u obzir uzima prometno opterećenje kao mjeru izloženosti riziku. S obzirom da međunarodno ne postoji jedinstvena metodologija identifikacije žarišta PN-a za cestovni (motorizirani) promet, očekivano ne postoji niti jedinstvena metodologija za biciklistički promet. U ovom poglavlju predlaže se prilagodba i primjena RQC metode kao temeljni model za analizu i identifikaciju opasnih mjesta u biciklističkom prometu na području Grada Zagreba. Rezultati ovog statističkog modela poslužit će kao referentno stanje za usporedbu i validaciju prediktivnog modela sigurnosti koji će se u kasnijoj fazi rada razviti primjenom naprednih algoritama strojnog učenja.

6.1 Definiranje i obrada podataka područja statističkog ispitivanja

Identifikacija opasnih mjesta u cestovnom prometu izvodi se za lokacije koje imaju natprosječan broj PN-a i slične su po karakteristikama. Obično se identifikacija radi za dionice cesta ili za raskrižja ili križanja. U slučaju biciklističkog prometa, dionice biciklističkih pravaca ne predstavljaju rizično područje ukoliko se ne sijeku s cestovnim pravcima. Suprotno tome, križanja u urbanoj sredini, poput Zagreba, predstavljaju rizične prometne površine na kojima dolazi do potencijalnog konflikta biciklističkog, motoriziranog i pješačkog prometa. Iz tog razloga su kao ključne lokacije nad kojima se provodi analiza opasnih mjesta i definira bazni model sigurnosti identificirani cestovni čvorovi, odnosno križanja. Križanje je po definiciji


prometna površina na kojoj se križa cesta i druga prometna infrastruktura (Fakultet prometnih znanosti, 2016), npr. biciklistička staza ili nogostup.

Za potrebe provođenja mrežne analize i statističkog ispitivanja RQC metodom, bilo je potrebno definirati točne lokacije križanja te utvrditi njihove geometrijske i prometne karakteristike, među kojima su koordinate, područje obuhvata i broj krakova cesta koje se križaju. Cjelokupni postupak obrade i analize geometrijskih podataka, te strukturiranje atributnih podataka svih križanja cestovne mreže izveden je u QGIS-u na temelju podataka cestovne infrastrukture preuzetih iz OSM-a. Izvorni linijski sloj cestovne mreže najprije je filtriran prema funkcionalnim kategorijama ulične mreže (atribut *highway*), navedenim u poglavlju 3.4.1, koje su značaje za kretanje biciklističkog prometa unutar urbanog područja. Za potrebe istraživanja odabrane su *primary*, *secondary*, *tertiary*, *unclassified* i *residential*. Pri tome su odbačene autoceste (*motorway*) i servisne ceste (*service*). Autoceste nisu odabrane jer na njima nije dozvoljeno prometovanje biciklom, dok servisne ceste nisu namijenjene tranzitnom prometu, već omogućuju pristup specifičnim objektima i površinama. One obuhvaćaju parkirališta stambenih blokova ili trgovačkih centara te zatvorene ulične mreže privatnih posjeda i industrijskih postrojenja.

Nad filtriranim linijskim slojem cesta iz OSM-a proveden je kompleksan prostorni proces ekstrakcije križanja (slika 37) s ciljem generiranja točkastih objekata koji predstavljaju čvorove cestovne mreže s atributom broja krakova (tipa križanja) koji u njih ulaze. Postupak je u QGIS-u realiziran kroz sljedeće sekvencijalne korake:

1. Izdvajanje vrhova, odnosno čvorova linijskih segmenata cestovne mreže (*Extract Vertices*): linijska geometrija ulične mreže rastavljena je na pojedinačne čvorove, pri čemu je generirano ukupno 143338 točaka na svim lomnim točkama i sjecištima linija.
2. Uklanjanje dvostrukih geometrija (*Delete Duplicate Geometries*): budući da se na svakom sjecištu cesta i granici linijskog segmenta kreira po jedna točka za svaki linijski objekt, uklonjeni su dvostruki objekti s istim prostornim koordinatama (preostalo ukupno 123418 jedinstvenih objekata).
3. Izrada manjeg poligona oko područja točke (*Buffer*): oko svake točke generirana je manja kružna zona, odnosno kružni poligon radijusa 0,1 m kako bi se omogućilo ispitivanje presjeka sjecišta te ustanovio broj linijskih segmenata koji se spaja u pojedinoj točki križanja. S obzirom da će se računati broj linija koje se sijeku unutar područja oko točke, važno je definirati minimalnu veličinu poligona jer bi u suprotnom moglo doći do preklapanja poligona što bi rezultiralo netočnim izračunom broja krakova.
4. Poligoni pretvoreni u linije (*Polygons to lines*): međukorak u kojem se dobila kružnica vanjskog ruba poligona.

5. Analiza mrežnih sjecišta (*Line Intersections*): proveden je prostorni presjek originalnih linija cesta i dobivenih kružnica kako bi se utvrdile točne lokacije na kojima se linije ulične mreže stvarno presijecaju, čime se definira tip križanja odnosno broj krakova koji se u toj točki spajaju (npr. trokraka, četverokraka ili višekraka raskrižja).
6. Brojanje točaka u poligonima (*Count Points in Polygons*): prebrojan broj sjecišta unutar svakog poligona pri čemu je dobivena vrijednost zapisana u novi atribut *br_krakova* (broj krakova), koji topološki klasificira točke cestovne mreže prema vrijednosti na:
 - 1 – krajnju točku linije (slijepa ulica),
 - 2 – običan čvor između dvaju linijskih segmenata (prijelazna točka bez promjene smjera),
 - 3 – označava trokrako križanje (tip T/Y),
 - 4 – označava četverokrako križanje (tip X),
 - 5 i više – označava višekrako križanje (multi-raskrižje, tip M).
6. Ekstrakcija središta poligona (*Centroids*): poligoni su ponovno pretvoreni u točkastu geometriju pozicioniranjem točke u geometrijsko središte (težište) svakog čvora mreže.
7. Filtriranje i izvoz: provedeno je završno filtriranje atributa *br_krakova* pri čemu su zadržani isključivo objekti s vrijednošću većom od 2 (čime su u eliminirane slijepo ulice i obične spojne točke na dionicama cesta), kako bi se ekstrahirala isključivo križanja. Nakon završetka procesa, za administrativno područje Grada Zagreba izvezeno je ukupno 11374 jedinstvenih točkastih objekata koji predstavljaju križanja.



Slika 37. Proces ekstrakcije križanja iz podataka cestovne infrastrukture

Za potrebe provođenja RQC metode identifikacije opasnih mjesta, bilo je nužno odrediti prostornu zonu utjecaja svakog raskrižja u kojoj će se vršiti pretraživanje i agregacija parametara

(PN-a i volumena prometa). Službeno prihvaćena *Metodologija za identifikaciju opasnih mjesta u cestovnoj mreži* (Fakultet prometnih znanosti, 2016) navodi da se u kontekstu raskrižja u obzir uzima i zona oko raskrižja (ili križanja), koja je određena na temelju prometne signalizacije koja upozorava na raskrižje (ili križanje). Sukladno metodološkim postavkama ovog rada, oko svake od 11374 točke križanja izrađen je mrežni pojas (engl. *network buffer*) radijusa 100 m i širine 20 m duž linija cestovne mreže. Pri tome je mrežni pojas (engl. *network buffer*) odabran, a ne standardni geometrijski (euklidski), jer odgovara uzorku distribucije cestovne mreže u prostoru, odnosno prati stvarno kretanje sudionika u prometu (Islam i dr., 2025). Pretpostavka je da će time biti bolje aproksimiran volumen biciklističkih tokova u neposrednoj okolini križanja.

Na većini prometnica se PN-e u kojima sudjeluju biciklisti obično događaju na samim pješačkim prijelazima, odnosno presjecima biciklističke staze i ceste. Vizualnom inspekcijom te mjerenjem udaljenosti unutar QGIS-a, ustanovljeno je da opseg pojedinih raskrižja na području grada, računajući od središnje točke raskrižja do najdaljeg pješačkog prijelaza, varira od samo nekoliko metara unutar stambenih naselja do udaljenosti između 35 i 60 m na glavnim gradskim avenijama. Stoga je, sukladno recentnoj literaturi (Islam i dr., 2025; Mahmoud i dr., 2021; Wang i dr., 2015), odabran veći opseg križanja, nego što je definiran metodološkim smjernicama (Fakultet prometnih znanosti, 2016) kako bi se mogli prikupiti, kvantificirati i analizirati podaci vanjskih čimbenika koji utječu na promet pojedinog križanja. Nadalje, udaljenost mrežnog pojasa odabrana je kako bi se obuhvatilo cjelokupni prostor prilaza pojedinom križanju te konfliktne zone u kojima se odvija interakcija biciklista i ostalih sudionika u prometu, te kako bi se izbjeglo ispuštanje PN-a koje su se dogodile u samoj blizini križanja, ili u području prometnog utjecaja na križanje, kao što je npr. označena pristupna biciklistička traka (slika 5). S obzirom da veći broj dostupnih podataka po križanju daje pouzdaniji rezultat pri upotrebi naprednih metoda strojnog učenja, nužno je bilo uključiti što veći broj PN-a kako bi se objedinio veći skup podataka za fazu modeliranja sigurnosti. Stoga su sve georeferencirane PN-e unutar pojedinog mrežnog pojasa pridružene predmetnom križanju.

6.2 Izrada baznog modela sigurnosti prilagođenom RQC metodom

Kvantificiranje izloženosti riziku predstavlja temeljni preduvjet za provođenje objektivne znanstvene analize i uklanjanje pristranosti prisutnih kod reaktivnih metoda koje se temelje isključivo na povijesnim podacima PN-a (Sener i dr., 2021). Identifikacija žarišta PN-a pomoću RQC metode pripada skupini reaktivnih pristupa utemeljenih na naprednom statističkom modeliranju koje integrira podatke PN-a i podatke o izloženosti. Provodi se na način da se na

temelju broja PN-a i podatka o izloženosti na promatranoj lokaciji odredi kritična razina nastanka PN-a. Na temelju usporedbe stope PN-a na pojedinoj lokaciji i izračunate kritične razine nastanka PN-a određuje se je li promatrana lokacija pripada skupini žarišta (Fakultet prometnih znanosti, 2016). Ukoliko stopa prelazi kritičnu razinu tada se smatra da se PN-e statistički ne događaju slučajno, već da se radi o potencijalnom žarištu.

Metodologija izračunavanja stope PN-a u kontekstu motoriziranog prometa podrazumijeva računanje izloženosti pojedine lokacije (dionice ceste ili raskrižja) na temelju prosječne količine prometa u razdoblju od jedne godine, a dobiva se na temelju PGDP-a. U kontekstu prilagodbe RQC metode biciklističkom prometu, izloženost se za svako križanje izračunala na temelju vrijednosti $PGDBP_{Str}$. Za izračun ukupnog prosječnog dnevnog volumena ulaznih krakova pojedinog križanja (Q) razvijen je matematički izraz koji integrira procijenjeni podataka o PGDBP-u dobivenom iz Strava aktivnosti i geometrijski atribut broja krakova:

$$Q = \overline{PGDBP_{Str}} \times br_krakova \quad (8)$$

gdje je Q ukupni PGDBP na svim ulaznim krakovima križanja, $\overline{PGDBP_{Str}}$ je izračunata aritmetička sredina procijenjenog PGDBP-a na svim linijskim segmentima unutar mrežne zone utjecaja raskrižja u promatranom razdoblju od 2019. do 2023. (vidi poglavlje 4.4), a $br_krakova$ jest broj krakova križanja, odnosno cestovnih segmenata koji ulaze u križanje, dobiven u procesu ekstrakcije križanja. Prosječna količina prometa u promatranom vremenskom razdoblju na pojedinom križanju (M) izražava se u milijunima biciklističkih aktivnosti i a računata je prema prilagođenom izrazu:

$$M = \frac{Q \times 365,25 \times P}{10^6} \quad (9)$$

gdje je M mjera izloženosti na križanju (izražena u milijunima bicikala), Q je ukupni PGDBP ulaznih krakova raskrižja, brojka 365,25 je prosječan broj dana u godini za promatrani period, a P duljina promatranog razdoblja u godinama. Stopa PN-a (C_R) za svako pojedino križanje izražava se kao broj PN-a na milijun ulaznih biciklističkih aktivnosti i izračunata je prema sljedećem izrazu:

$$C_R = \frac{PN}{M} = \frac{PN \times 10^6}{Q \times 365,25 \times P} \quad (10)$$

gdje je C_R stopa PN-a na križanju iskazana u PN-a na milijun biciklističkih aktivnosti, PN jest ukupan broj evidentiranih PN-a u kojima su sudjelovali biciklisti u promatranom petogodišnjem razdoblju, a M je izračunata mjera izloženosti na križanju izražena po milijun biciklističkih aktivnosti. Ovaj izračun stope PN-e uspješno normalizira podatke te omogućuje pravednu

komparaciju križanja s izrazito različitim intenzitetima biciklističkog prometa. Nakon izračuna stope PN-a (C_R) za svako križanje, provedeno se statističko ispitivanje opasnosti primjenom RQC metode. Temeljna pretpostavka ove metode jest da su PN-e rijetki i nasumični događaji čija se distribucija u prostoru i vremenu može aproksimirati Poissonovom distribucijom (Fakultet prometnih znanosti, 2016). RQC metoda omogućuje prepoznavanje lokacija kod kojih odstupanje (povećanje) broja nesreća nije rezultat puke slučajnosti, već je statistički značajno te je uzrokovano lokalnim faktorima rizika, odnosno vanjskim čimbenicima. Statistički prag iznad kojeg se križanje proglašava potencijalno opasnim mjestom definira se kao kritična razina nastanka PN-a (C_{CR}). Za svaku lokaciju je pojedinačno izračunata specifična vrijednost prema izrazu:

$$C_{CR} = C_{RA} + k \cdot \sqrt{\frac{C_{RA}}{M}} + \frac{1}{2 \cdot M} \quad (11)$$

gdje je C_{CR} kritična razina stope PN-a za promatrano križanje, C_{RA} je prosječna vrijednost stope PN-a za cjelokupni skup analiziranih križanja na mreži, k označava koeficijent statističke razine značajnosti (dobiven iz standardne normalne razdiobe za odabranu razinu pouzdanosti), a M je već spomenuta mjera izloženosti na križanju (izražena u milijunima bicikala) za promatrano vremensko razdoblje. Za potrebe ovog istraživanja, sukladno preporukama i znanstveno-stručnoj praksi autora metodologije, odabrana je razina značajnosti (pouzdanosti) od 95%. Za ovu razinu pouzdanosti, pripadajući koeficijent iznosi $k = 1,645$ (što znači da je zaključak o statističkoj značajnosti opasnosti točan s vjerojatnošću od 95%, odnosno da postoji svega 5% šanse da je povećana stopa PN-a rezultat slučajne fluktuacije). Vrijednost prosječne stope PN-a na razini mreže (C_{RA}) izračunata je kao omjer ukupnog broja PN-a i ukupne izloženosti na svim križanjima:

$$C_{RA} = \frac{\sum PN}{\sum M} \quad (12)$$

Dobivena vrijednost prosječne stope PN-a izračunata na temelju ulaznih podataka na razini mreže iznosi $C_{RA} = 0,6428$ (PN-a na milijun biciklističkih aktivnosti). Ukoliko izračunata stopa PN-a na nekom križanju premašuje njegovu kritičnu razinu ($C_R > C_{CR}$), to križanje zadovoljava statistički kriterij i klasificira se kao prostorna lokacija s nadprosječnim sigurnosnim rizikom (odnosno kao potencijalno opasno mjesto).

U svrhu definiranja redoslijeda prioriteta za planiranje i provedbu sigurnosnih mjera te olakšane vizualne interpretacije rezultata, raskrižja su rangirana na temelju omjera stope PN-a i kritične

razine nastanka PN-e (C_R/C_{CR}). Dobiveni omjer predstavlja izravnu kvantitativnu mjeru razine opasnosti lokacije:

- 0 označava da nije bilo PN-a i da se križanje može smatrati sigurnim,
- omjer s vrijednostima ispod 1 označava da se radi o umjereno sigurnom križanju, odnosno da je rizik nizak jer je stopa PN-a ispod razine kritične statističke granice,
- vrijednosti veće od 1 ukazuju na potencijalno opasno mjesto koje ima povišen rizik,
- dok najviše rangirane lokacije prema omjeru označavaju žarišta PN-a na kojim je ekstremno visok rizik od potencijalne PN-e.

Provjera izračunatih vrijednosti C_R/C_{CR} omjera pokazala je da skupom apsolutno dominiraju nule (9348 od 11374, odnosno više od 82 % uzorka). Ovaj fenomen, koji je uobičajen u modeliranju sigurnosti biciklističkog prometa (Raihan i dr., 2019; Sener i dr., 2021; Wei i Lovegrove, 2013), u statistici se naziva distribucija napuhana nulama (engl. *zero-inflated distribution*). Takvu distribuciju karakterizira histogram vrijednosti (funkcija gustoće vjerojatnosti) koji je izrazito asimetričan udesno (engl. *right-skewed*). Stoga računanje statističkih pokazatelja (prosjeaka i standardne devijacije) nije bilo izvedeno na cijelom skupu podataka jer bi prevladavajuća količina nula srušila prosjek blizu nule i potpuno izobličila brojke, čineći ih neupotrebljivima za definiranje žarišta. Iz tog razloga su, za potrebe rangiranja i klasifikacije križanja prema stupnju opasnosti, izračunati deskriptivni statistički parametri (tablica 26) samo za onih 2026 križanja koja imaju zabilježenu PN-u (zapravo je 2033, ali 7 križanja nema zabilježenu aktivnost u promatranom periodu). Izračunom statističkih pokazatelja za križanja koja su imala PN-u, uočeno je da veliki dio tog skupa ($n = 1497$, tablica 27) ima omjer $C_R/C_{CR} < 1$, što znači da pripadaju kategoriji križanja niskog rizika. Stoga su iznova izračunati deskriptivni statistički parametri (tablica 26) samo za ona križanja kod kojih izračunata stopa PN-a na nekom križanju premašuje njegovu kritičnu razinu ($n = 529$), odnosno koja imaju $C_R/C_{CR} > 1$, kako bi se podaci mogli adekvatno klasificirati. Na temelju tog podskupa izvedena je kategorizacija sigurnosti za križanja koja pripadaju skupini lokacija s nadprosječnim sigurnosnim rizikom.

Tablica 26. Statistički pokazatelji vrijednosti dobivenih RQC metodom za križanja koja imaju zabilježenu PN-u

Varijabla		Min	Max	Prosjek	Medijan	σ
$C_R > 0$ (n = 2026)	PN	1	9	1,69	1	1,34
	Q	2,58	3293	417,80	302,52	362,50
	C_R	0,24	212,24	4,59	2,55	10,54
	C_{CR}	1,51	128,66	4,91	3,72	6,13
	C_R/C_{CR}	0,15	3,17	0,77	0,64	0,48
$C_R > 1$ (n = 529)	PN	1	9	3,16	3	1,88
	Q	2,58	1513,50	400,64	271,86	356,14

C_R	1,81	212,24	10,56	5,50	19,22
C_{CR}	1,62	125,97	6,65	3,52	11,03
C_R/C_{CR}	1,00	3,60	1,59	1,40	0,55


Prvu klasu (0) čine križanja koja u promatranom razdoblju od 2018. do 2022. nisu imala evidentiranu niti jednu PN-u (tablica 27). Drugu klasu (1) čine sigurna križanja koja imaju omjer C_R/C_{CR} ispod 1, odnosno gdje stopa PN-a ne prelazi kritičnu razinu nastanka PN-a. Treću klasu (2) čine križanja povišenog rizika koja imaju omjer C_R/C_{CR} u intervalu od 1 do prosjeka (1,59) svih križanja iznad kritične statističke razine. To su križanja koja su prešla kritični prag (C_{CR}), ali su i dalje ispod prosjeka svih opasnih lokacija. Klasu žarišta (3) čine sva križanja iznad prethodnog praga (1,59) pa sve do maksimuma, odnosno križanja koja u kategoriji povišenog rizika spadaju u nadprosječno rizična. Žarišta su statistički ekstremi ($n = 181$) i čine tek 1,6 % svih križanja u cjelokupnoj mreži te 8,9 % svih križanja koja su imala zabilježenu PN-u.

Tablica 27. Klasifikacijski sustav sigurnosti križanja prema omjeru stope PN-a i kritične razine nastanka PN-e

Klasa	Kategorija	C_R/C_{CR}	Opis i interpretacija razine sigurnosti križanja	Broj križanja	Udio u mreži (%)
0	Sigurno	0	U petogodišnjem razdoblju nije evidentirana niti jedna PN-a.	9348	82,19 %
1	Nizak rizik	0 – 0,99	Niske rizik s omjerom ispod kritične razine nastanka PN-e.	1497	13,16 %
3	Povišen rizik	1,00 – 1,59	Raskrižja kod kojih stopa PN-a statistički premašuje kritičnu razinu ukazujući na prisutnost sustavnih lokalnih čimbenika rizika (potreban nadzor).	348	3,06 %
4	Žarište	$\geq 1,59$	Nadprosječno visoki omjer stope i kritične razine nastanka PN-e. Predstavljaju najkritičnije točke u gradu.	181	1,59 %

Ovaj klasifikacijski sustav pruža strukturiran i metodološki utemeljen uvid u stanje sigurnosti, odvajajući lokacije koje su sigurne od onih koje zahtijevaju hitnu stručnu i infrastrukturnu analizu na terenu. Prostorni raspored pojedinih kategorija križanja rangiranih prema sigurnosti, s posebnim naglaskom na najopasnija mjesta unutar prometne mreže, prikazan je na karti (slika 38). Ovaj bazni model identificiranih žarišta predstavlja osnovi uvid u stanje sigurnosti biciklističkog prometa u Zagrebu. Utemeljen na RQC metodologiji identifikacije opasnih mjesta u cestovnoj prometnoj mreži, prilagođen je računanju parametara upotrebom biciklističke mjere za izloženost. Kao takav, bazni model služi kao ključni analitički oslonac s kojim će se u idućem

poglavlju usporediti i evaluirati rezultati predikcije opasnih mjesta dobivenih primjenom naprednih algoritama strojnog učenja.



Slika 38. Model sigurnosti biciklističkog prometa izrađen RQC metodologijom s prikazom lokacija žarišta PN-a

7. MODELIRANJE SIGURNOSTI BICIKLISTIČKOG PROMETA PRIMJENOM METODA STROJNOG UČENJA

U prethodnom je poglavlju detaljno analizirana i primijenjena statistička RQC metoda za identifikaciju žarišta PN-a i klasifikaciju sigurnosti biciklističkog prometa u Gradu Zagrebu. Iako je RQC metoda pokazuje visoku razinu znanstvene utemeljenosti i daje vrijedan bazni model za procjenu relativne sigurnosti na temelju stope PN-a i izloženosti biciklističkog prometa, ona se suočava s nekoliko inherentnih ograničenja. Prvenstveno, kao neparametarska i reaktivna metoda oslanja se isključivo na povijesne podatke o PN-ama i jednostavne linearne odnose, zanemarujući kompleksne, nelinearne i višedimenzionalne prostorne korelacije između prometne infrastrukture, izgrađenog okoliša, demografskih pokazatelja i stvarnih obrazaca kretanja biciklista.

Kako bi se prevladala ova ograničenja, ovo poglavlje predstavlja iskorak prema proaktivnom i prediktivnom modeliranju sigurnosti i identifikaciji žarišta PN-a primjenom naprednih algoritama strojnog učenja. Cilj ovog dijela istraživanja jest razviti i evaluirati napredne klasifikacijske modele koji mogu prepoznati skrivene uzorke opasnosti na križanjima i klasificirati ih u odgovarajuće razrede sigurnosti, s posebnim naglaskom na točnu identifikaciju žarišta. Strojno učenje omogućuje istovremenu integraciju heterogenih i visokodimenzionalnih skupova podataka (prostorno-vremenski podaci, infrastrukturni parametri, socioekonomska obilježja, i sl.) bez potrebe da se apriori donose pretpostavke o statističkoj distribuciji podataka, što je ključno za modeliranje PN-a kao rijetkih, diskretnih i prostorno raspršenih događaja. Uz napredne algoritme strojnog učenja, upotrijebljena je interpretacijska metoda SHAP (*SHapley Additive exPlanations*) kojom se analizira i tumači utjecaj različitih fizikalnih i društvenih uzročnika prometnog rizika na nastajanje žarišta PN-a. U ovom poglavlju detaljno je opisan metodološki okvir izrade modela, proces selekcije varijabli, optimizacija tzv. hiperparametara, evaluacija triju odabranih algoritama (RF, XGBoost i SVM) te interpretacija njihovih rezultata.

7.1 Metodologija modeliranja

Modeliranje sigurnosti biciklističkog prometa na križanjima postavljeno je kao problem nadziranog višerazrednog klasifikacijskog modeliranja. Za ovaj podskup strojnog učenja specifično je da algoritam uči iz prethodno obilježenih podataka, a cilj je razviti model koji može mapirati ulazne značajke na ispravan izlaz (klasu) kako bi predvidio ishode na novim, neviđenim podacima (Nikparvar i Thill, 2021). Jedinica analize je pojedinačno križanje ($n = 11374$) na području Grada Zagreba, a prostor pretrage infrastrukturnih, prostornih i demografskih varijabli

definiran je pripadajućom mrežnom zonom (100 m) oko točke križanja (čija je ekstrakcija iz baze OSM podataka detaljno opisana u poglavlju 6.1).

Ciljna varijabla (engl. *target variable*) klasifikacijskih modela izvedena je iz rezultata baznog RQC modela. Na temelju omjera izračunate stope PN-a (C_R) i kritične stope nastanka PN-a (C_{CR}) uz razinu pouzdanosti od 95%, križanja su svrstana u četiri diskretna razreda sigurnosti (tablica 26):

- klasa 0 (sigurno križanje): $C_R/C_{CR} = 0$ ($n = 9348$),
- klasa 1 (križanje niskog rizika): $0 < C_R/C_{CR} < 0,999$ ($n = 1497$),
- klasa 2 (križanje povišenog rizika): $1,000 < C_R/C_{CR} < 1,587$ ($n = 348$),
- klasa 3 (križanje je žarište): $1,587 < C_R/C_{CR} < maksimum$ ($n = 181$).

Ovakva distribucija ukazuje na izrazitu neuravnoteženost skupa podataka, gdje nulta klasa (raskrižja bez PN-a) obuhvaća preko 82 % svih objekata na mreži, dok ključna klasa žarišta PN-a (klasa 3) predstavlja svega 1,59 % uzorka. Stoga je priprema modela strojnoga učenja zahtijevala specifičan pristup rješavanju ekstremne asimetrije klasa. Za rješavanje navedenoga problema odabrani su algoritmi RF, XGBoost i SVM, jer omogućuju izravno kažnjavanje pogrešaka na rijetkim klasama. Prvotna primjena neprilagođenih modela pokazala se neuspješnom jer su algoritmi stvarna prometna žarišta svrstavali u većinsku sigurnu klasu, stvarajući time opasne lažno negativne ishode.

7.2 Priprema prostorne matrice opažanja i selekcija varijabli

Jedan od ključnih koraka u razvoju modela strojnog učenja jest selekcija varijabli s ciljem uklanjanja višestruke kolinearnosti (engl. *multicollinearity*) i smanjenja dimenzionalnosti prostorne matrice opažanja. Prostorna matrica opažanja predstavlja skup podataka pojedinačnih opažanja (svih križanja), dok stupci u tablici skupa podataka predstavljaju dimenzije (zajedničke značajke ili varijable svakog križanja). Podaci matrice opažanja, odnosno skup atributnih podataka križanja, sadrže prethodno izračunate vrijednosti izloženosti te dodatno prikupljene značajke koje su dobivene u QGIS-u na temelju prostorne pretrage infrastrukturnih, prostornih (uporaba zemljišta, izgrađeni okoliš) i demografskih varijabli unutar definirane zone križanja. Konačni objedinjeni skup podataka obuhvaćao je 72 inicijalne varijable te je izvezen u obliku strukturirane csv datoteke za daljnju obradu.

Kako bi se osigurala metodološka ispravnost i stabilnost prediktivnih modela, provedeno je preprocesiranje i filtriranje podataka. Prvo su numerička obilježja podvrgnuta standardizaciji primjenom metode *StandardScaler*, a potom su konvertirani svi tekstualni (kategorički) atributi

u numeričke tehnikom *One-hot encodinga*. Uz to su uklonjene jedinstvene identifikacijske oznake (npr. *fid*), s obzirom na to da kategoričke varijable i identifikacijske oznake ne predstavljaju kontinuirane fizikalne vrijednosti pa nisu prikladne za izravno uključivanje u linearni korelacijski račun. Preostali prostorni atributi svjesno su zadržani u izvornom obliku, bez modifikacije mjernih jedinica, s ciljem omogućavanja izravnoga očitavanja točnih fizikalnih pragova iz dijagrama SHAP ovisnosti.

Za identifikaciju kolinearnosti izračunata je matrica korelacije primjenom skriptnog jezika Python (verzija 3.13) i biblioteke *Pandas*. Pri tome je izračunata Pearsonova matrica korelacije (slika 39), koja mjeri stupanj linearne povezanosti (r) između svakog para varijabli u rasponu od -1 (savršena negativna korelacija) do +1 (savršena pozitivna korelacija) (Saha i dr., 2018b). Prilikom uklanjanja varijabli postavljen je prag visoke korelacije na vrijednost $|r| > 0,7$.

Uz to je, iterativnim procesom, empirijski provedeno uklanjanje pojedinih varijabli kako bi se izbjegle prostorna pristranost i nepotrebna redundantnost podataka koja zagušuje model. Tako su izostavljene prostorne koordinate PN-a kako bi se spriječila prostorna autokorelacija, odnosno izbjeglo se da model „upamti“ pojedine lokacije i zanemari stvarne vanjske čimbenike koji uzrokuju PN-e. Uz to su isključene pojedinačne varijable Strava aktivnosti za pojedinu godinu, kao i sve ostale mjere izloženosti izvedene iz sirovih Strava aktivnosti (osim ukupne Strava aktivnosti za cjelokupni period te omjera utilitarne i rekreativne aktivnosti). Razlog tome je izrazito visoka kolinearnost, jer godišnji volumeni biciklističke aktivnosti po godinama pokazuju gotovo identične relativne odnose, pa su preliminarni rezultati pokazivali zagušenje modela, što je onemogućilo jasan uvid u utjecaj ostalih infrastrukturnih i demografskih čimbenika. Nakon analize korelacije i uklanjanja redundantnih varijabli formirana je konačna struktura prostorne matrica opažanja za provedbu algoritama strojnog učenja (tablica 28).

	2019_tot_trip_count_max	2019_commute_trip_count_max	2019_leisure_trip_count_max	2019_commute_leisure_pct_max	2020_tot_trip_count_max	2020_commute_trip_count_max	2020_leisure_trip_count_max	2020_commute_leisure_pct_max	2021_tot_trip_count_max	2021_commute_trip_count_max	2021_leisure_trip_count_max	2021_commute_leisure_pct_max	2022_tot_trip_count_max	2022_commute_trip_count_max	2022_leisure_trip_count_max	2022_commute_leisure_pct_max	OSM_leg	OSM_node_LENGTH	OSM_node_COUNT	OSM_node_type_num	OSM_junction_weighted	OSM_crossing	OSM_trafficSignal	OSM_BP	bicifra_LENGTH	bicifra_COUNT	bicifra_kategorija_dum	Z0_uporaba_dominantno_sum	Z0_uporaba_StamMjes	Z0_uporaba_Gosp	Z0_uporaba_JavnDus	Z0_uporaba_PoljivodeSume	Z0_uporaba_PoljivodeSpt	Z0_uporaba_Promet	Z0_uporaba_StamMjes_pc	Z0_uporaba_Gosp_pc	Z0_uporaba_JavnDus_pc	Z0_uporaba_PoljivodeSume_pc	Z0_uporaba_PoljivodeSpt_pc	Z0_uporaba_Promet_pc	Z0_bustajaliste	Z0_javniparking	Z0_sustavjambic	Z0_viskolska	Z0_srednjskola	Z0_smonnaskola	DZS_MO_Muskrn	DZS_MO_Dual_kmetz	DZS_MO_Zeme	DZS_MO_3-19	DZS_MO_20-34	DZS_MO_35-59	DZS_MO_60+	DZS_0C_obrazovanje_05	DZS_0C_obrazovanje_35	DZS_0C_obrazovanje_VSS	DZS_0C_obrazovanje_PHO	2019-2022_tot_trips_max	2019-2022_tot_trips_sum	2019-2022_segmet_count	mAADBJ	Qj	Cr.J			
2019_tot_trip_count_max	0.77	0.94	0.12	0.96	0.79	0.92	0.11	0.92	0.70	0.99	0.10	0.94	0.72	0.91	0.06	0.10	0.39	0.48	-0.04	0.23	0.41	0.34	0.38	0.34	0.32	0.24	-0.07	-0.18	0.13	0.10	-0.13	0.15	0.42	-0.28	0.12	0.09	-0.16	0.13	0.38	0.24	0.21	0.09	0.09	0.03	0.05	0.04	0.15	0.14	0.14	0.16	0.13	0.15	0.16	0.14	-0.26	-0.17	0.21	0.23	0.85	0.79	0.44	0.85	0.70	0.71	0.01	
2019_commute_trip_count_max	0.77	0.92	0.30	0.71	0.95	0.55	0.24	0.69	0.90	0.92	0.01	0.77	0.94	0.55	0.16	0.16	0.05	0.52	0.60	0.01	0.32	0.50	0.48	0.10	0.48	0.46	0.35	0.05	-0.18	0.14	0.10	-0.19	0.13	0.54	-0.29	0.12	0.08	-0.22	0.09	0.47	0.08	0.33	0.14	0.14	0.05	0.06	0.01	0.13	0.28	0.11	0.14	0.08	0.15	0.13	0.13	-0.22	-0.11	0.33	0.31	0.65	0.79	0.56	0.65	0.43	0.46	0.05
2019_leisure_trip_count_max	0.04	0.82	0.01	0.93	0.55	0.36	0.03	0.87	0.47	0.93	0.03	0.86	0.47	0.94	0.00	0.05	0.25	0.30	-0.05	0.15	0.30	0.22	0.06	0.22	0.20	0.14	0.06	-0.15	0.11	0.09	-0.08	0.14	0.28	-0.22	0.10	0.11	0.13	0.26	0.28	0.11	0.05	0.05	0.01	0.04	0.04	0.14	0.04	0.14	0.14	0.13	0.13	0.15	0.12	-0.23	-0.17	0.11	0.15	0.81	0.61	0.31	0.81	0.72	0.73	-0.02		
2019_commute_leisure_pct_mean	0.12	0.80	0.01	0.10	0.28	0.09	0.59	0.11	0.27	0.03	0.46	0.13	0.27	0.03	0.41	0.08	0.27	0.25	0.05	0.18	0.28	0.16	0.05	0.16	0.14	0.15	-0.06	0.09	0.13	0.08	-0.24	0.05	0.24	-0.05	0.12	0.07	-0.26	0.03	0.22	0.07	0.11	0.06	0.04	0.04	0.02	0.00	0.13	0.30	0.12	0.14	0.08	0.16	0.13	0.15	-0.13	-0.05	0.26	0.23	0.10	0.16	0.27	0.10	0.00	0.01	0.03	
2020_tot_trip_count_max	0.96	0.71	0.93	0.10	0.77	0.98	0.10	0.96	0.71	0.96	0.09	0.96	0.71	0.97	0.06	0.01	0.39	0.46	-0.05	0.22	0.41	0.34	0.09	0.35	0.34	0.25	0.06	-0.21	0.15	0.10	-0.12	0.16	0.43	-0.30	0.13	0.09	-0.16	0.13	0.40	0.28	0.21	0.09	0.09	0.03	0.05	0.04	0.14	0.12	0.14	0.15	0.12	0.14	0.16	0.13	-0.26	-0.18	0.20	0.23	0.88	0.76	0.44	0.88	0.74	0.75	0.00	
2020_commute_trip_count_max	0.78	0.95	0.58	0.28	0.77	0.91	0.61	0.26	0.77	0.96	0.60	0.23	0.82	0.86	0.92	0.17	0.16	0.54	0.62	0.00	0.32	0.53	0.51	0.12	0.49	0.47	0.36	0.07	-0.21	0.16	0.10	-0.20	0.14	0.57	-0.32	0.13	0.08	-0.24	0.10	0.51	0.13	0.33	0.16	0.15	0.06	0.07	0.02	0.14	0.29	0.13	0.15	0.09	0.16	0.14	0.14	-0.24	-0.12	0.34	0.34	0.70	0.82	0.58	0.70	0.48	0.51	0.04
2020_leisure_trip_count_max	0.92	0.55	0.96	0.03	0.88	0.51	0.03	0.92	0.55	0.97	0.03	0.93	0.55	0.98	0.00	0.06	0.30	0.36	-0.06	0.17	0.33	0.26	0.07	0.27	0.26	0.19	0.08	-0.19	0.13	0.09	-0.09	0.15	0.34	-0.27	0.12	0.09	-0.12	0.13	0.32	0.30	0.15	0.06	0.06	0.02	0.04	0.13	0.06	0.13	0.14	0.12	0.13	0.15	0.11	-0.24	-0.18	0.13	0.17	0.85	0.66	0.35	0.85	0.75	0.75	-0.01		
2020_commute_leisure_pct_mean	0.11	0.24	0.03	0.59	0.10	0.26	0.55	0.11	0.25	0.04	0.61	0.12	0.23	0.04	0.40	0.08	0.23	0.21	0.05	0.16	0.20	0.15	0.04	0.13	0.12	0.12	-0.06	0.02	0.14	0.05	-0.20	0.01	0.21	-0.05	0.13	0.05	-0.22	0.00	0.19	-0.03	0.09	0.04	0.03	0.01	0.00	0.12	0.23	0.11	0.13	0.08	0.14	0.11	0.13	-0.11	-0.04	0.23	0.20	0.10	0.15	0.23	0.10	0.02	0.02	0.01		
2021_tot_trip_count_max	0.92	0.69	0.87	0.11	0.94	0.77	0.93	0.11	0.77	0.96	0.10	0.97	0.74	0.94	0.06	0.10	0.41	0.48	-0.06	0.23	0.43	0.37	0.10	0.38	0.37	0.28	0.10	-0.23	0.15	0.10	-0.13	0.17	0.46	-0.32	0.14	0.09	-0.16	0.14	0.42	0.27	0.22	0.10	0.10	0.03	0.05	0.04	0.15	0.14	0.15	0.16	0.13	0.15	0.17	0.14	-0.28	-0.18	0.22	0.25	0.87	0.78	0.46	0.87	0.74	0.75	0.01	
2021_commute_trip_count_max	0.70	0.90	0.47	0.27	0.71	0.96	0.55	0.25	0.77	0.96	0.58	0.24	0.79	0.97	0.57	0.18	0.16	0.55	0.61	0.07	0.32	0.53	0.51	0.13	0.50	0.49	0.37	0.06	-0.23	0.16	0.10	-0.20	0.14	0.58	-0.33	0.14	0.08	-0.23	0.10	0.51	0.12	0.33	0.14	0.15	0.05	0.01	0.14	0.28	0.13	0.15	0.10	0.16	0.14	0.14	-0.23	-0.11	0.34	0.32	0.66	0.81	0.57	0.66	0.46	0.48	0.04	
2021_leisure_trip_count_max	0.89	0.52	0.93	0.03	0.95	0.60	0.97	0.04	0.96	0.58	0.03	0.92	0.55	0.97	0.00	0.06	0.31	0.37	-0.07	0.14	0.34	0.27	0.07	0.29	0.28	0.09	0.01	0.12	0.09	-0.09	0.16	0.35	-0.28	0.11	0.09	-0.12	0.10	0.34	0.30	0.15	0.07	0.07	0.02	0.04	0.04	0.17	0.07	0.14	0.15	0.13	0.15	0.16	0.13	-0.26	-0.19	0.15	0.19	0.85	0.67	0.36	0.85	0.76	0.77	-0.01		
2021_commute_leisure_pct_mean	0.10	0.21	0.03	0.46	0.09	0.23	0.03	0.61	0.10	0.24	0.03	0.11	0.22	0.04	0.57	0.05	0.20	0.18	0.05	0.14	0.17	0.13	0.04	0.11	0.11	0.10	-0.07	0.02	0.12	0.06	-0.18	0.02	0.18	-0.03	0.11	0.06	-0.20	0.01	0.16	-0.03	0.08	0.03	0.04	0.04	0.02	0.00	0.09	0.19	0.08	0.09	0.05	0.10	0.08	0.10	-0.08	-0.01	0.29	0.16	0.08	0.13	0.20	0.08	0.00	0.01	0.00	
2022_tot_trip_count_max	0.94	0.77	0.96	0.13	0.98	0.82	0.92	0.12	0.97	0.79	0.92	0.11	0.98	0.80	0.95	0.07	0.11	0.43	0.51	-0.05	0.24	0.41	0.36	0.10	0.40	0.29	0.09	-0.24	0.16	0.11	-0.13	0.15	0.48	-0.33	0.15	0.08	-0.17	0.12	0.44	0.25	0.23	0.09	0.03	0.04	0.03	0.15	0.15	0.16	0.13	0.16	0.17	0.14	-0.26	-0.16	0.25	0.25	0.87	0.80	0.67	0.87	0.75	0.73	0.01			
2022_commute_trip_count_max	0.77	0.94	0.47	0.27	0.71	0.96	0.55	0.23	0.74	0.97	0.55	0.22	0.80	0.97	0.57	0.18	0.16	0.56	0.63	0.06	0.32	0.51	0.52	0.12	0.51	0.51	0.37	0.06	-0.24	0.17	0.10	-0.19	0.13	0.58	-0.34	0.15	0.08	-0.22	0.09	0.52	0.11	0.33	0.13	0.14	0.04	0.05	0.01	0.13	0.26	0.12	0.13	0.13	-0.22	-0.10	0.33	0.31	0.66	0.82	0.57	0.66	0.45	0.47	0.04			
2022_leisure_trip_count_max	0.91	0.55	0.94	0.03	0.97	0.62	0.96	0.04	0.94	0.57	0.97	0.04	0.96	0.57	0.00	0.06	0.31	0.37	-0.06	0.16	0.34	0.25	0.07	0.29	0.28	0.09	0.08	-0.20	0.13	0.09	-0.08	0.14	0.35	-0.27	0.12	0.08	-0.11	0.12	0.33	0.28	0.14	0.06	0.06	0.01	0.01	0.04	0.15	0.07	0.14	0.15	0.13	0.14	0.16	0.12	-0.24	-0.16	0.18	0.18	0.85	0.67	0.36	0.85	0.75	0.75	-0.01	
2022_commute_leisure_pct_mean	0.06	0.16	0.00	0.41	0.05	0.17	0.00	0.40	0.06	0.18	0.00	0.07	0.07	0.18	0.00	0.04	0.17	0.15	0.01	0.11	0.13	0.11	0.01	0.09	0.09	0.04	0.01	0.13	0.04	-0.14	0.00	0.16	0.04	-0.16	0.01	0.14	-0.04	0.06	0.02	0.02	0.01	0.00	0.06	0.15	0.05	0.06	0.03	0.08	0.05	0.07	-0.04	0.00	0.14	0.10	0.04	0.16	0.04	0.03	0.02	0.01						
OSM_leg	0.10	0.16	0.05	0.08	0.09	0.16	0.06	0.08	0.10	0.07	0.05	0.11	0.16	0.06	0.06	0.32	0.25	0.16	0.16	0.26	0.29	0.04	0.23	0.20	0.15	0.01	0.01	0.06	0.04	-0.08	0.04	0.33	-0.10	0.03	0.02	-0.12	0.01	0.07	0.18	0.08	0.10	0.05	0.01	0.00	0.08	0.13	0.05	0.06	0.04	0.06	0.05	0.08	-0.02	0.01	0.10	0.10	0.09	0.20	0.25	0.03	0.03	0.12				
OSM_node_LENGTH	0.39	0.52	0.25	0.27	0.39	0.54	0.30	0.23	0.41	0.56	0.31	0.20	0.43	0.56	0.31	0.74	0.32	0.60	0.67	0.64	0.63	0.54	0.15	0.69	0.69	0.44	0.00	-0.05	0.36	0.13	-0.28	0.06	0.78	-0.31	0.01	0.08	-0.37	0.06	0.58	0.17	0.30	0.12	0.15	0.05	0.01	0.21	0.34	0.20	0.22	0.17	0.24	0.22	0.21	-0.15	-0.03	0.32	0.25	0.35	0.61	0.73	0.35	0.16	0.20	0.10		
OSM_node_COUNT	0.45	0.60	0.30	0.25	0.46	0.62	0.36	0.21	0.48	0.62	0.37	0.18	0.51	0.63	0.37	0.15	0.25	0.95	0.98	0.63	0.63	0.16	0.76	0.74	0.46	0.03	0.15	0.15	-0.27	0.10	0.78	-0.37	-0.12	0.11	-0.33	0.05	0.61	0.21	0.38	0.19	0.21	0.07	0.04	0.04	0.14	0.32	0.13	0.15	0.09	0.16	0.15	0.15	-0.19	-0.08	0.32	0.30	0.42	0.74	0.60	0.42	0.22	0.26	0.10			
OSM_node_type_num	-0.04	0.01	-0.05	0.05	-0.05	0.00	-0.06	0.05	-0.06	-0.01	-0.07	0.05	-0.05	0.00	-0.06	0.05	0.07	0.08	0.02	0.01	0.02	0.01	0.60	0.10	0.09																																									

Tablica 28. Deskriptivni statistički pokazatelji skupa podataka za sva križanja ($n = 11374$)

Naziv varijable	Opis	Prosjek	σ	Min	Max
Ciljna varijabla					
Cr/Ccr_95	Omjer stope PN-a i kritične razine nastanka PN-e	0,14	0,36	0	3,17
Izloženost					
2019-2022_U-R	Omjer utilitarne i rekreativne aktivnosti (%) svih segmenata	35,37	38,89	0	492,31
Qj	Ukupna izloženost na svim ulaznim krakovima križanja	256,73	325,23	0	4530,84
Infrastruktura					
br_krakova	Broj krakova koji se spaja u križanju (3, 4, 5 ili 6)	3,12	0,33	3	6,00
OSM_road_LENGTH	Ukupna duljina cestovnih segmenata	712,66	322,72	6,78	2740,60
OSM_road_COUNT	Ukupan broj cestovnih segmenata	13,26	11,71	1	92,00
OSM_road_type_num	Prevladavajući tip ceste prema OSM kategorizaciji (kategorička varijabla)	3,75	1,34	1	9,00
	0 primary	0	1	0,01	0,08
	1 secondary	0	1	0,14	0,35
	2 tertiary	0	1	0,21	0,41
	3 residential	0	1	0,55	0,50
	4 service	0	1	0,03	0,16
	5 cycleway	0	1	0,00	0,06
	6 path	0	1	0,03	0,17
	7 pedestrian	0	1	0,00	0,02
	8 other	0	1	0,03	0,17
OSM_junctionCount_weighted	Gustoća križanja (broj križanja X broj krakova pojedinog križanja)	14,62	10,70	3	96
OSM_crossing	Ukupan broj obilježenih pješačkih prijelaza	2,79	4,02	0	28
OSM_trafficSignal	Ukupan broj semaforiziranih pješačkih prijelaza	0,55	1,38	0	11
OSM_BP	Broj benzinskih postaja	0,02	0,15	0	1
bicInfra_LENGTH	Ukupna duljina biciklističke staze	58,13	146,89	0	1039

bicInfra_COUNT	Ukupan broj segmenata biciklističkih staza	1,52	4,57	0	45
bicInfra_kategorija_id_num	Prevladavajuća kategorija biciklističke infrastrukture (kategorička varijabla)	0,17	0,52	0	5
	0 Bez infrastrukture	0	1	0,87	0,34
	1 PB	0	1	0,11	0,32
	2 JS	0	1	0,00	0,02
	3 CM	0	1	0,01	0,12
	4 BT	0	1	0,00	0,04
	5 PO	0	1	0,00	0,04
bic-road_infraRatio	Omjer ukupne duljine bic. staze i cestovnih segmenata	0,05	0,12	0	1,06
Uporaba zemljišta					
ZG_uporaba_dominantno_num	Prevladavajući tip uporabe zemljišta (kategorička varijabla)	1,80	1,33	1	6
	1 stambena/mješovita	0	1	0,69	0,46
	2 gospodarska	0	1	0,07	0,25
	3 javna/društvena	0	1	0,04	0,19
	4 poljoprivredno/vode/šume	0	1	0,17	0,37
	5 javne površine/sport	0	1	0,03	0,16
ZG_uporaba_StamMjes_pc	stambena/mješovita (%)	47,43	24,78	0	100
ZG_uporaba_Gosp_pc	gospodarska (%)	3,29	9,17	0	100
ZG_uporaba_JavnDrus_pc	javna/društvena (%)	2,34	6,27	0	69,70
ZG_uporaba_PoljpVodeSume_pc	poljoprivredno/vode/šume (%)	15,1	18,65	0	100
ZG_uporaba_JavnZeLeSprt_pc	javne površine/sport (%)	1,91	6,13	0	100
Izgrađeni okoliš					
ZG_busStajaliste	Broj autobusnih stajališta	0,43	0,82	0	8
ZG_tramStajaliste	Broj tramvajskih stanica	0,10	0,44	0	6
ZG_javniParkingBic	Broj javnih parkirališta za bicikle	0,04	0,3	0	12
ZG_sustavJavnihBic	Broj stanica sustava javnih bicikala	0,01	0,08	0	1
ZG_visokaSkola	Broj visokoškolskih ustanova	0,01	0,12	0	4
ZG_srednjaSkola	Broj srednjih škola	0,01	0,13	0	3
ZG_osnovnaSkola	Broj osnovnih škola	0,02	0,13	0	2
Demografska struktura					

DZS_MO_Ukupno	Ukupan broj stanovnika po MO-u	4921,36	3088,23	63	13795
DZS_MO_Gust_st-km2	Gustoća naseljenosti po MO-u (stan/km ²)	4243,85	4377,70	29,52	24040
DZS_GC_obrazovanje_OS	Broj stanovnika s osnovnim obrazovanjem po GC-ima	4899,12	2378,80	1371	9570
DZS_GC_obrazovanje_SS	Broj stanovnika sa srednjim obrazovanjem po GC-ima	21810,10	7932,06	6212	34705
DZS_GC_obrazovanje_VSS	Broj stanovnika s visokim obrazovanjem po GC-ima	14909,27	5515,91	1759	26499
DZS_GC_obrazovanje_PhD	Broj stanovnika s doktoratom znanosti po GC-ima	470,25	287,55	24	1073

7.3 Podešavanje hiperparametara i kalibracija modela

Hiperparametri modela su vanjske postavke koje upravljaju procesom treniranja modela. Prilikom treniranja modela strojnog učenja, svaki skup podataka i svaki model zahtijevaju drukčiji skup hiperparametara, a jedini način da ih se odredi jest provođenje više eksperimenata tijekom kojih se odaberu i primjenjuju na model. Podešavanje ili optimizacija hiperparametara je postupak sustavnog pretraživanja i odabira vanjskih postavki modela koje algoritam ne može sam naučiti izravno iz podataka, a koristi se kako bi se prilagodila nelinearna složenost modela specifičnim podacima, spriječilo prekomjerno prilagođavanje te maksimizirala točnost predikcije na novim podacima (Miah i dr., 2023), što je od posebne važnosti kod neuravnoteženih klasifikacijskih problema kao što je slučaj u ovom istraživanju.

Testiranje različitih kombinacija parametara provedeno je upotrebom Python (verzija 3.13) i biblioteka *Scikit-learn* i *XGBoost*. Za potrebe testiranja, podaci su podijeljeni u omjeru 80% ($n = 9099$) za trening skup i 20% ($n = 2275$) za testni skup nad kojim je provedena završna evaluacija. Pri podjeli se koristilo tzv. stratificirano uzorkovanje, koje osigurava originalnu distribuciju, odnosno podjednak udio svake klase u oba skupa. U svim je testiranjima primijenjena *RandomizedSearchCV* metoda koja nasumično odabire i testira unaprijed zadani broj kombinacija parametara (n_iter) slučajno pretražujući uz višestruku unakrsnu validaciju (engl. *k-fold Cross-Validation* – CV). Nakon provedenog procesa optimizacije s 5-strukom unakrsnom validacijom ($k = 5$), utvrđeni su optimalni parametri za tri integrirana modela (tablici 29).

Tablica 29. Popis svih testiranih hiperparametara u procesu optimizacije

Parametri	RF	XGB	SVM
$n_estimators$ (broj stabala)	800	800	
max_depth (maks. dubina)	22	5	
$min_samples_split$ (min. br. uzoraka za podjelu)	5		
$min_samples_leaf$ (min. br. uzoraka u listu)	1		
$max_features$ (broj varijabli pri podjeli)	0,3		
$class_weight$ (težinski faktor klase)	{0: 1, 1: 5, 2: 18, 3: 55}		{0: 1, 1: 5, 2: 15, 3: 50}
$sample_weights$ (težine uzoraka)		{0: 1, 1: 3, 2: 8, 3: 25}	
n_iter (broj testiranih kombinacija)	60	50	30
$learning_rate$ (stopa učenja)		0,02	
$subsample$ (udio uzoraka po stablu)		0,9	
$colsample_bytree$ (udio varijabli po stablu)		0,9	
min_child_weight (min. težina u čvoru)		2	
$gamma$ (minimalno smanjenje gubitka)		0,1	0,01
reg_alpha (L1 regularizacija)		0,1	
reg_lambda (L2 regularizacija)		10	
C (parametar regularizacije)			100

Nakon podešavanja optimalnih hiperparametara kroz 5-struku stratificiranu unakrsnu validaciju, modeli su trenirani na 80% podataka, dok je njihova prediktivna sposobnost i robusnost provjerena na neovisnom testnom skupu od 2275 križanja. Nakon faze treniranja, klasifikacijski modeli dodjeljuju konačne oznake klase na temelju najveće izračunate vjerojatnosti. Standardna metoda predviđanja *argmax* pokazala se najboljim pristupom jer je u iterativnom procesu modeliranja potvrđeno da osigurava najbolji balans i sprječava drastičan pad preciznosti na testnom skupu (npr. RF primjenom ove metode pronalazi identičan broj žarišta uz značajno višu preciznost u usporedbi s modelima kod kojih su primijenjeni sniženi pragovi odlučivanja).

Budući da osnovni rezultat klasifikacije generira isključivo konačnu (diskretnu) oznaku klase, a ne i samu vjerojatnost njezine pojave, takav je izlaz nedovoljno informativan za prostornu vizualizaciju na karti. Zbog toga je implementiran postupak kalibracije vjerojatnosti (izotoničnom regresijom za RF). Dobiveni kalibrirani model osigurava precizne procjene vjerojatnosti pripadnosti svakoj od četiriju definiranih klasa (P_0, P_1, P_2, P_3), pri čemu je suma izračunatih vjerojatnosti za svaki objekt jednaka 1. Na temelju tako kalibriranih vjerojatnosti, definirana su i izračunata dva ključna pokazatelja namijenjena daljnjoj prostornoj analizi:

1. kumulativni kritični rizik:

$$P_{KR} = P_2 + P_3 \quad (13)$$

2. kontinuirani indeks opasnosti (engl. *hazard score*):

$$I_{HS} = 0 \times P_0 + 1 \times P_1 + 2 \times P_2 + 3 \times P_3 \quad (14)$$

pri čemu je P_n vjerojatnost pripadnosti pojedinoj klasi sigurnosti. Kumulativni kritični rizik P_{KR} predstavlja vjerojatnost da pojedino križanje pripada klasi povišenog rizika ili žarišta. Kontinuirani indeks opasnosti I_{HS} predstavlja očekivanu vrijednost razine opasnosti na pojedinom križanju, izraženu na kontinuiranoj skali od 0,0 do 3,0.

7.4 Rezultati modeliranja i evaluacija modela

S obzirom na ekstremnu neuravnoteženost klasa (jer su PN-e statistički rijetki događaji na cjelokupnoj mreži svih križanja), gdje klasa 0 (križanja bez PN-a) obuhvaća preko 82% svih objekata, ukupna točnost (engl. *overall accuracy*) nije mjerodavan pokazatelj uspješnosti. Evaluacija se stoga primarno temelji na koeficijentima unutar-klasnog slaganja (*Cohen's Kappa*, *Matthews Correlation Coefficient* – MCC) te klasno specifičnim metrikama za ključnu klasu 3 (žarišta PN-a): preciznost (engl. *precision*), odziv (engl. *recall*), F_1 -mjera (*F1-Score*) i F_2 -mjera (*F2-Score*).

Cohenov koeficijent *Kappa* je standardna statistička mjera koja korigira postignutu točnost klasifikacije za razinu slaganja koja se može pripisati čistom slučaju (Effati i dr., 2015). Za razliku od obične točnosti, koeficijent uzima u obzir vjerojatnost da se klasifikatori slože sasvim slučajno. To je čini iznimno korisnom kod neizbalansiranih skupova podataka, gdje visoka točnost može zavarati (Więckowska i dr., 2022). Matthewsov koeficijent korelacije (MCC) smatra se najpouzdanijom metrikom za evaluaciju neuravnoteženih podataka jer visoko ocjenjuje model samo ako je postigao dobre rezultate u sve četiri kategorije matrice zabune (Chicco i Jurman, 2020).

Uzevši u obzor da je primarni cilj modeliranja sigurnosti prometa u ovom istraživanju precizna identifikacija lokacija s visokim sigurnosnim rizikom, performanse pojedinog modela su evaluirane kroz:

- preciznost: označava vjerojatnost da je raskrižje stvarno žarište ako ga je model tako klasificirao;
- odziv: označava sposobnost modela da uspješno identificira sva stvarna žarišta na mreži, odnosno minimizira promašaje;
- F_1 -mjera: harmonijska sredina preciznosti i odziva koja se koristi za uravnoteženu ocjenu performansi modela klasifikacije;
- F_2 -mjera: daje dvostruko veću težinu odzivu u odnosu na preciznost.

S obzirom da je u prometnom planiranju i zaštiti ljudskih života daleko opasnije promašiti i ne identificirati stvarno žarište (lažno negativan ishod), nego označiti sigurno križanje kao potencijalno opasno (lažno pozitivan ishod), odziv je važniji od same preciznosti. Promašaj identifikacije žarišta ostavlja opasnu lokaciju nezaštićenom, dok lažno pozitivan ishod samo rezultira preventivnim pregledom lokacije. Stoga je kao optimalna metrika (kriterij odabira najboljeg modela) odabran rezultat F_2 -mjere usmjeren na žarišta (tablica 30).

Tablica 30. Komparativna analiza evaluacije rezultata pojedinog modela na testnom skupu podataka

Evaluacijska metrika	RF	XGB	SVM
Preciznost (klasa 3)	0,714	0,727	0,545
Odziv (klasa 3)	0,694	0,667	0,500
F_1 -mjera (klasa 3)	0,704	0,696	0,522
F_2 -mjera (klasa 3)	0,698	0,678	0,508
F_2 -mjera (ukupno)	0,736	0,682	0,467
Cohen's Kappa	0,636	0,565	0,280
MCC	0,641	0,567	0,330
Ukupna točnost	0,880	0,860	0,835


Komparativna analiza performansi ukazuje na to da je RF najuspješniji model za detekciju žarišta PN-a (klasa 3) s obzirom na to da ostvaruje najbolje rezultate u ključnim metrikama prilagođenim izrazito neuravnoteženom skupu prostornih podataka, što je uobičajeno u analizama prometne sigurnosti gdje žarišta čine manji udio u ukupnoj mreži. Iako RF ne ostvaruje najvišu preciznost, bilježi nedvojbeno najbolji odziv (0,694) i najviši rezultat F_2 -mjere (0,698). Također, RF ostvaruje za kritičnu klasu žarišta najvišu F_1 -mjeru (0,704), koja predstavlja ravnotežu preciznosti i odziva. XGBoost se pokazao kao snažan klasifikator koji uspješno prepoznaje klasu 3, ostvarujući visoku preciznost (0,727) i solidan odziv (0,667). Iako postiže vrlo dobru F_1 -mjeru (0,696) za najopasnije lokacije, ipak zaostaje za RF modelom u razlikovanju preostalih, nižih razina rizika. To se očituje na najnižim zabilježenim vrijednostima Cohenove Kappe (0,565) i MCC-a (0,567), što pokazuje jasnu nekonzistentnost na razini cijelog skupa podataka. SVM je rezultatski najslabiji algoritam koji je u potpunosti podbacio u rješavanju problema izrazito neuravnoteženih klasa. S odzivom od svega 0,500 za klasu 3, model propušta detektirati čak polovicu žarišta na mreži, što ga uz nisku preciznost i slabe F -mjere, te drastično niske vrijednosti složenih koeficijenata slaganja (Kappa = 0,280; MCC = 0,330) i najnižu ukupnu točnost, čini neupotrebljivim za daljnju upotrebu u ovom istraživanju.

RF uvjerljivo dominira u ukupnoj F_2 -mjeri (0,736) te ostvaruje najviše rezultate u složenim koeficijentima slaganja (Kappa = 0,636; MCC = 0,641). To dokazuje da uspješnije prepoznavanje žarišta kod RF-a nije narušilo njegovu sposobnost točnoga klasificiranja preostalih (nižih) razina rizika (slika 40). Usporedna analiza jasno pokazuje da RF predstavlja najpouzdaniji model za predikciju žarišta PN-a u kojima su sudjelovali biciklisti na križanjima na području Grada Zagreba. RF ostvaruje visoku ukupnu točnost na cjelokupnom skupu od 11 374 križanja, a pritom najuspješnije identificira prostorne ekstreme zbog kojih se analiza prometne sigurnosti prvenstveno i provodi.

	RF				XGBoost				SVM			
Stvarna klasa (Actual)	0	1	2	3	0	1	2	3	0	1	2	3
	1708 (91.3%)	150 (8.0%)	8 (0.4%)	4 (0.2%)	1708 (91.3%)	145 (7.8%)	14 (0.7%)	3 (0.2%)	1834 (98.1%)	23 (1.2%)	6 (0.3%)	7 (0.4%)
	64 (21.4%)	226 (75.6%)	8 (2.7%)	1 (0.3%)	93 (31.1%)	188 (62.9%)	15 (5.0%)	3 (1.0%)	244 (81.6%)	42 (14.0%)	7 (2.3%)	6 (2.0%)
	12 (17.1%)	11 (15.7%)	42 (60.0%)	5 (7.1%)	16 (22.9%)	14 (20.0%)	37 (52.9%)	3 (4.3%)	44 (62.9%)	9 (12.9%)	15 (21.4%)	2 (2.9%)
	2 (5.6%)	4 (11.1%)	5 (13.9%)	25 (69.4%)	2 (5.6%)	3 (8.3%)	7 (19.4%)	24 (66.7%)	13 (36.1%)	3 (8.3%)	2 (5.6%)	18 (50.0%)
	Predviđena klasa (Predicted)				Predviđena klasa (Predicted)				Predviđena klasa (Predicted)			

Slika 40. Usporedba matrica konfuzije izračunatih modela


Analiza distribucije predikcija unutar matrice konfuzije na slici 40 potvrđuje dijagonalnu koncentraciju i stabilnost RF modela u usporedbi s ostalim klasifikatorima. Na skupu neviđenih testnih podataka, RF je u klasu 3 točno klasificirao 25 od 36 žarišta, a samo 2 u nultu klasu. Uz to ima visoku točnost u preostalim razredima (91,34 % za klasu 0, 75,59 % za klasu 1 i 60,00 % za klasu 2). XGBoost model postiže nešto niži odziv (24 od 36 žarišta), ali uz izraženije prelijevanje predikcija među klasama. Nasuprot tome, SVM pokazuje pristranost prema većinskoj nultoj klasi (98,07 % točno svrstanih križanja u klasi 0), što rezultira slabim učinkom za klasu 3.



Slika 41. PR krivulja za klasu žarišta

Prilikom evaluacije rezultata klasifikacijskih modela uobičajeno je koristiti ROC (engl. *receiver operating characteristic*) krivulje, no u slučaju predikcije ishod koji je relativno rijedak preporuča se upotreba PR (Precision-Recall) krivulje (Cook i Ramadas, 2020). Uspješnost modela se na dijagramu (slika 41) generalno može interpretirati površinom ispod krivulje (engl. *area under curve* – PR-AUC), koja brojčano (u rasponu od 0 do 1) sažima ukupnu prediktivnu moć modela preko svih mogućih pragova klasifikacije, pri čemu veća površina označava uspješniji model. PR krivulja na grafikonu 15 prikazuje odnos između preciznosti i odziva na različitim pragovima odlučivanja za klasu žarišta. Profil plave PR krivulje za RF model zadržava visoku razinu preciznosti pri visokim vrijednostima odziva što dodatno potvrđuje stabilnost modela i njegovu nadmoć u odnosu na ostala dva ispitana modela. Narančasta (XGBoost) krivulja pokriva manju površinu od plave, a zelena (SVM) znatno najmanju, što potvrđuje lošiji rezultat SVM modela.


Na temelju indeksa opasnosti rangirana su sva križanja na području istraživanja (vidi prilog 12) te je izrađena završna vizualizacija najuspješnijeg klasifikacijskog modela (slika 42).



Slika 42. Karta kontinuiranog indeksa opasnosti za cjelokupno područje istraživanja

7.5 Interpretacija rezultata

Primjena modela strojnog učenja donosi izazov interpretacije rezultata zbog otežanog razumijevanja uzročno-posljedičnih veza između ulaznih podataka i izlaznih predikcija. Jedna od glavnih prednosti RF metode u razumijevanju rezultata modeliranja očituje se u mogućnosti izračuna važnosti značajki pod nazivom *Gini nečistoća* (engl. *Gini impurity*; alternativni naziv je *Mean Decrease in Impurity* – MDI). Ugrađena mjera temelji se na prosječnom smanjenju Gini nečistoće, a njome se izračunava doprinos svake varijable homogenosti čvorova u stablima odluka (Dadashova i dr., 2020). Treba naglasiti da je mjera značajnosti varijabli globalna mjera za cjelokupni model. Ona rangira značajke na temelju toga koliko doprinose istovremenom razlikovanju svih klasa, a u ovom istraživanju omogućuje rangiranje utjecajnih čimbenika na cjelokupni model.



Slika 43. Mjera značajnosti varijabli (*Gini impurity*)

Dijagram na slici 43 prikazuje 20 najznačajnijih varijabli RF modela za predikciju cjelokupnog modela. Duljina pojedinog stupca proporcionalna je prosječnom doprinosu varijable (srednje smanjenje Gini nečistoće), dok crne vodoravne linije na vrhovima stupaca označavaju standardnu devijaciju doprinosa po stablima, vizualizirajući varijabilnost ili stabilnost utjecaja pojedinog obilježja unutar modela. Na prikazanom dijagramu vidljivo je da na najveći utjecaj na


predikcije modela imaju varijable izloženosti, cestovne infrastrukture te demografske strukture. Najznačajnija varijabla je ukupna izloženost po svim ulaznim krakovima križanja, a slijede ju broj cestovnih segmenata i gustoća naseljenosti po MO-u, te potom varijable Strava ukupne aktivnosti i omjera utilitarne i rekreativne aktivnosti. Jedina varijabla iz neke druge kategorije unutar prvih deset jest udio stambeno-mješovita uporabe zemljišta.

Iako mjera srednjeg smanjenja Gini nečistoće prikazuje važnost pojedine varijable za ukupni klasifikacijski model, ova metoda ima nekoliko bitnih nedostataka: pristrana je prema varijablama koje imaju puno jedinstvenih vrijednosti (tzv. visoku kardinalnost), ne može utvrditi koji su čimbenici (značajke) ključni za pronalazak klase žarišta, te ne daje uvid u smjer utjecaja pojedinog čimbenika na klasu žarišta (smanjuju li ili povećavaju rizik). Iz toga razloga je primijenjena SHAP metoda u interpretaciji klasno specifičnih doprinosa pojedinih varijabli. Metoda SHAP, utemeljena na teoriji kooperativnih igara, omogućuje precizno kvantificiranje i smjera i intenziteta doprinosa svake pojedine varijable nastanku žarišta PN-a. Njezinom se primjenom ne otkriva isključivo hijerarhija važnosti analiziranih varijabli, već se točno utvrđuju i njihovi pragovi te stvarni smjer uzročno-posljedičnog utjecaja na sigurnost biciklističkog prometa (Borketey i Borketey, 2024).

Kako bi se povezala interpretacija rezultata između mjere srednjeg smanjenja Gini nečistoće i izračunatih globalnih SHAP vrijednosti, provedena je usporedba poretka važnosti prostorno-prometnih čimbenika (vidi prilog 13). Iako Gini metoda mjeri opći doprinos varijable smanjenju pogreške pri cjelokupnoj klasifikaciji, a metoda SHAP kvantificira marginalni doprinos usmjeren specifično na izdvajanje klase žarišta, usklađenost njihovih rezultata ključan je preduvjet za potvrdu stabilnosti i pouzdanosti modela. Za cjelokupni skup od 49 analiziranih varijabli izračunat je *Spearmanov* koeficijent rang-korelacije između poretka značajnosti varijabli dobivenog Gini metodom i poretka dobivenog SHAP metodom. Izračunata vrijednost koeficijenta ($r_s = 0,987$) ukazuje na gotovo savršeno slaganje dvaju neovisnih pristupa evaluaciji varijabli, što dokazuje iznimnu robusnost i stabilnost interpretacije izrađenog klasifikacijskog modela.

Dijagram na slici 44 prikazuje sažetak ukupnog utjecaj SHAP značajnosti pojedine varijable na predikciju žarišta upotrebom četiri dimenzije podataka (vertikalna os, horizontalna os, boja, gustoća i raspršenost točaka). Najznačajnijih 20 varijabli su na vertikalnoj osi poredane od vrha prema dnu prema njihovom globalnom utjecaju (srednjoj apsolutnoj SHAP vrijednosti). To znači da varijable pri samom vrhu (npr. gustoća naseljenosti i broj cestovnih segmenata) imaju najveću prediktivnu snagu pri identificiranju žarišta. Horizontalna os prikazuje utjecaj varijable na izlazni rezultat modela, pri čemu vrijednosti desno od nule (pozitivni SHAP) označavaju da

određeni uvjet (vrijednost varijable) povećava vjerojatnost da križanje bude klasificirano kao žarište, a lijevo od nule (negativni SHAP) označava da uvjet smanjuje vjerojatnost nastanka žarišta, odnosno da odvlači predikciju od klase 3. Gustoćom i raspršenost točaka unutar reda predstavlja vrijednosti pojedinih križanja u analiziranom skupu podataka.



Slika 44. Sažeti prikaz utjecaja SHAP vrijednosti na klasu žarišta

Analiza grafikona otkriva značajnu ulogu infrastrukturnih varijabli u predikciji žarišta. Na samom vrhu se, kao najutjecajnija varijabla, nalazi gustoća naseljenosti. Crvene točke, koje prikazuju visoke vrijednosti, protežu se od nule prema desnoj strani, što dokazuje da visoka gustoća naseljenosti u MO-u izravno povećava rizik od nastanka žarišta. Slijede količina i duljina cestovne infrastrukture te gustoća križanja, kod kojih se visoke vrijednosti također nalaze na desnoj strani, što potvrđuje da gustoća i kompleksnost cestovne infrastrukture u neposrednom okruženju križanja povećava vjerojatnost nastanka PN-a. Ukupna izloženost na križanju nalazi se na ovom dijagramu tek na 8. mjestu, a visoke vrijednosti su većinski na lijevoj strani što znači da povećanje izloženosti u križanju smanjuje mogućnost nastanka žarišta. Taj pad od sedam

mjesta prikazuje koliko je izloženost manje utjecajna na predikciju klasu žarišta, nego li na predikciju cjelokupne klasifikacije svih križanja. Zanimljivo je i da visoke vrijednosti ukupnog broja biciklističkih segmenata zapravo povećava predikciju žarišta. Jednako vrijedi za javnu i društvenu uporabu zemljišta kao i za broj tramvajskih stanica u blizini križanja. Suprotno tome, veći broj semafora očekivano negativno djeluje na nastanak žarišta. S obzirom na iznimno vrijedne i informativne pokazatelje utjecaja pojedinih čimbenika na predikciju žarišta PN-a, izrađeni su pojedinačni grafikoni SHAP ovisnosti (engl. *dependence plots*) kojim se omogućuje identificiranje točnih fizikalnih i prostornih pragova iznad kojih pojedini čimbenici počinju izrazito nepovoljno utjecati na biciklističku sigurnost.

Pojedinačni prikazi SHAP ovisnosti (slike 45 – 64) omogućuju utvrđivanje nelinearnih međusobnih odnosa i točnih pragova opasnosti koji uzrokuju pojavu žarišta PN-a. Za razliku od klasičnih regresijskih koeficijenata koji pretpostavljaju linearnu vezu, grafikoni SHAP ovisnosti prikazuju nelinearni profil utjecaja (Borketey i Borketey, 2024): na apscisi (x-os) je prikazana stvarna numerička vrijednost varijable u njezinoj izvornoj fizikalnoj jedinici na pojedinom križanju, dok ordinata (y-os) kvantificira marginalni doprinos te varijable predikciji klase 3 (SHAP vrijednost za klasu žarišta). Vrijednosti iznad nulte isprekidane linije ($SHAP > 0$) označavaju da određena vrijednost varijable povećava rizik i gura križanje u klasu žarišta, dok vrijednosti ispod nule ($SHAP < 0$) djeluju zaštitno.

Slika 45 prikazuje dijagram SHAP ovisnost za gustoću naseljenosti po MO-u, koja prikazuje strm i nelinearan prijelaz na pragu od 6000 st./km² iz negativnog područja za slabo naseljene MO-e u pozitivno. To znači da naseljenost iznad tog demografskog praga predstavlja potencijalnu opasnost za stvaranje žarišta PN-a usred gusto naseljenih stambenih dijelova šireg centra grada, koji pripadaju toj demografskoj skupini. Suprotno tome, ukupan broj stanovnika (slika 56) ima povišen rizik za niže vrijednosti između 1000 i 3000, dok veliki MO-i iznad 6000 stanovnika imaju nizak rizik. Time se potvrđuje da za rizik nije presudna sama apsolutna veličina mjesnog odbora, već prostorna stisnutost (gustoća) stanovništva.

Geometrija i kompleksnost prometne infrastrukture predstavlja najznačajniju skupinu čimbenika na potencijalni nastanak žarišta. Broj cestovnih segmenata, ukupna duljina cestovne mreže, gustoća križanja i broj označenih prijelaza (slike 46, 47, 48 i 51) jasno pokazuju da povećanjem vrijednosti (količine ili duljine) dolazi do povećanja rizika za bicikliste. Utjecaj količine cestovnih segmenata (slika 46) unutar zone križanja nizak je do praga od 18 segmenata, a potom sječe nultu liniju i kontinuirano raste do brojke od 40, nakon čega se stabilizira te postiže vrhunac rizika za križanja s preko 50 cestovnih segmenata. Broj segmenata zapravo odražava mrežnu fragmentiranost zbog koje križanja s preko 20 segmenata imaju prevelik broj sporednih

priključaka i krakova, što prisiljava bicikliste na neprekidno praćenje motornih vozila iz više smjerova te drastično povećava rizik od nastanka žarišta. Kod ukupne duljine cesta manje od 850 do 900 metara (slika 47), SHAP vrijednost je konstantno negativna (-0,12 do -0,02). Točno na pragu od 900 do 1000 metara bilježi se nagli skok u pozitivnu zonu (+0,02 do +0,10) gdje potom sve visoke vrijednosti ostaju. To znači da križanja koja se nalaze unutar kompleksnih višetračnih raskrižja s velikim pritokom sporednih priključaka generiraju najveću opasnost za nastanak žarišta. Prikaz SHAP vrijednosti za označene (pješačko-biciklističke) prijelaze (slika 51) pokazuje da do 2 prijelaza imaju negativan utjecaj, dok u rasponu od 4 do 15 prijelaza SHAP vrijednost naglo skače u pozitivnu zonu. S obzirom da označeni prijelazi imaju visoku frekvenciju interakcije biciklističkog i motoriziranog prometa, ne čudi da veće količine označenih prijelaza predstavljaju potencijalne konfliktne situacije za nastanak PN-a. Dijagram na slici 62 jasno prikazuje da semaforizirana križanja, s 2 ili više semafora, imaju zaštitni učinak koji vremenski razdvaja prometne tokove i sprječava potencijalne PN-e i time nastanak žarišta.


Kategorije izloženosti prema SHAP vrijednostima pokazuju manju značajnost prema predikciji klase žarišta, nego što imaju u odnosu na predikciju cjelokupnog modela. Iznimno omjer utilitarne i rekreativne vožnje (slika 49) izdvaja se kao peta najznačajnija varijabla u obje mjere. Pripadajući dijagram SHAP ovisnosti pokazuje da SHAP vrijednosti postaju dominantno pozitivne pri pomaku prema višim stvarnim vrijednostima (što označava povećanje udjela utilitarnih aktivnosti u odnosu na rekreativne). To ukazuje na uzročno-posljedičnu vezu prema kojoj povećanje utilitarnih aktivnosti izravno povećava rizik i gura predikciju križanja prema klasi žarišta. Ovaj je nalaz u korelaciji s rezultatima SiN efekta (poglavlje 5.4), koji je izraženiji kod utilitarnog prometa. Utilitarne aktivnosti izvan zone biciklističke infrastrukture ostvaruju indeks SiN efekta od gotovo 7000, nasuprot rekreativnih aktivnosti čiji indeks iznosi 1454,50. Glavni razlog ovakvog odstupanja leži u činjenici da se rekreativne aktivnosti pretežno odvijaju izvan vršnih sati i u manje konfliktnim uvjetima, dok se svakodnevna utilitarne aktivnosti odvijaju u uvjetima prometnih gužvi. Sukladno navedenom, varijabla ukupnog broja zabilježenih aktivnosti za sve segmente križanja (slika 50) bilježi složenu nelinearnost s jasnim pragovima pri kojima niske vrijednosti djeluju zaštitno (negativne SHAP vrijednosti), ali rastom aktivnosti dolazi do skokova u pozitivnom smjeru.

S druge strane, iznimno je važna analiza varijable ukupne izloženosti na ulaznim krakovima križanja (slika 52). Ova varijabla predstavlja tek osmi najvažniji čimbenik za predikciju žarišta, dok na predikcije klasifikacijskog modela ima najveći utjecaj. Analiza dijagrama SHAP ovisnosti za varijablu izloženosti pruža nedvosmislen empirijski dokaz koncepta sigurnosti u brojevima na analiziranom području istraživanja. Naime, dijagram na slici 22 jasno prikazuje da se pri vrlo


niskim vrijednostima ukupne izloženosti bilježi velika vertikalna raspršenost točaka s brojnim visokim pozitivnim SHAP iznosima. Iz toga proizlazi da izoliran i rijedak biciklistički promet na križanju stvara ranjivost i znatno povećava vjerojatnost nastanka žarišta. Nasuprot tome, rastom vrijednosti varijable po x-osi, SHAP vrijednosti postaju isključivo negativne (uz jedno iznimno križanje). Ovakva distribucija potvrđuje zaštitni učinak mase – povećanje ukupne izloženosti, odnosno broja biciklista u samom križanju, aktivno smanjuje mogućnost eskalacije PN-a te odvlači predikciju modela od klase žarišta. Navedeni zaključak podupire prijašnja istraživanja (Aldred i dr., 2018b; Chen i dr., 2020; Nordback i dr., 2018; Saad i dr., 2019; Vanparijs i dr., 2015; Y. Wang i dr., 2018) koja potvrđuju nelinearan odnos između volumena prometa i učestalosti PN-a, prema kojima prisutnost većeg broja biciklista djeluje zaštitno.

Dijagrami na slikama 53, 58, 60 i 64, koji pokazuju varijable biciklističke infrastrukture, daju važan doprinos razumijevanju sigurnosti biciklističkog prometa u Zagrebu. Naime, umjeren broj segmenata (10 – 20), duljina staza (400 – 600) te prisutnost izgrađene biciklističke infrastrukture (u grafikonu 36 za kategoriju 'Bez infrastrukture' vrijednost 0 označava da postoji bic. infrastruktura) pokazuju visoku pozitivnu vrijednost SHAP ovisnosti u odnosu na klasu žarišta, dok nepostojanje infrastrukture te vrlo visoke vrijednosti bic. infrastrukture pokazuju negativan utjecaj. Nekoliko je mogućih razloga za to – djelomično izgrađena i potencijalno nekvalitetna biciklistička infrastruktura u zonama križanja, lažni osjećaj sigurnosti biciklista zbog postojanja bic. staze, fragmentiranost bic. staza (prekidanja na i uoči pješačkih prijelaza) – no to je pitanje koje mora odgovoriti prometna struka.


U kontekstu namjene zemljišta, očekivano je negativan utjecaj na klasu žarišta za varijable koja označavaju udio poljoprivrednih, vodenih i šumskih (slika 55), te sportsko-rekreacijskih i zelenih površina (slika 59). Varijabla gospodarske uporabe zemljišta ne pokazuje značajan utjecaj prema SHAP dijagramu (slika 61). Suprotno tome, varijabla udjela javne i društvene namjene pokazuje pozitivne SHAP vrijednosti (slika 57), što je posljedica činjenice da zone javne i društvene namjene (škole, bolnice, fakulteti, javne ustanove) generiraju visoku koncentraciju biciklističkih aktivnosti, a time i interakcija u prometu. Kod varijable stambeno-mješovite namjene dijagram (slika 54) pokazuje rast pozitivnih SHAP vrijednosti pri visokom udjelu od preko 80 %. To pokazuje da križanja unutar zbijenih stambenih i trgovačkih zona, kao što su područje GC-i Donji Grad i Trešnjevka – sjever, imaju povišen rizik od PN-a, što to je u skladu s rezultatima prostorno-vremenske analize u poglavlju 4.2 ovog istraživanja. Dijagram SHAP ovisnosti za varijablu broja tramvajskih stajališta (slika 63) ukazuje na pozitivan utjecaj za nastajanje žarišta, što je također u korelaciji s rezultatima prostorne analize PN-a iz poglavlja 5.2.




Slika 45. SHAP ovisnost varijable 'DZS_MO_Gust_st-km2' na klasu žarišta




Slika 46. SHAP ovisnost varijable 'OSM_road_COUNT' na klasu žarišta




Slika 47. SHAP ovisnost varijable 'OSM_road_LENGTH' na klasu žarišta




Slika 48. SHAP ovisnost varijable 'OSM_junctionCount_weighted' na klasu žarišta




Slika 49. SHAP ovisnost varijable '2019-2022_U-R' na klasu žarišta




Slika 50. SHAP ovisnost varijable '2019-2022_tot_trips_sum' na klasu žarišta




Slika 51. SHAP ovisnost varijable 'OSM_crossing' na klasu žarišta




Slika 52. SHAP ovisnost varijable 'Qj' na klasu žarišta




Slika 53. SHAP ovisnost varijable 'bicInfra_COUNT' na klasu žarišta




Slika 54. SHAP ovisnost varijable 'ZG_uporaba_StamMjes_pc' na klasu žarišta




Slika 55. SHAP ovisnost varijable 'ZG_uporaba_PoljVodeSume_pc' na klasu žarišta




Slika 56. SHAP ovisnost varijable 'DZS_MO_Ukupno' na klasu žarišta




Slika 57. SHAP ovisnost varijable 'ZG_uporaba_JavnDrus_pc' na klasu žarišta




Slika 58. SHAP ovisnost varijable 'bicInfra_LENGTH' na klasu žarišta




Slika 59. SHAP ovisnost varijable 'ZG_uporaba_JavnZeLeSprt_pc' na klasu žarišta




Slika 60. SHAP ovisnost varijable 'bic-road_infraRatio' na klasu žarišta




Slika 61. SHAP ovisnost varijable 'ZG_uporaba_Gosp_pc' na klasu žarišta



Slika 62. SHAP ovisnost varijable 'OSM_trafficSignal' na klasu žarišta



Slika 63. SHAP ovisnost varijable 'ZG_tramStajaliste' na klasu žarišta



Slika 64. SHAP ovisnost varijable 'bicInfra_kategorija_id_num_0' na klasu žarišta

8. ZAKLJUČAK

Ovo istraživanje provedeno je s temeljnim ciljem ispitivanja mogućnosti izrade cjelovitoga modela sigurnosti biciklističkog prometa za područje Grada Zagreba, na čijim se temeljima zasniva predikcija za buduću sigurnost i razvoj prometne infrastrukture. Kroz opsežnu prostorno-vremensku analizu, ostvarena je integracija povijesnih podataka o PN-ama s MPP-a biciklističke aktivnosti iz platforme Strava. Na taj način formiran je jedinstveni skup podataka od 829 zabilježenih PN-a u kojima su sudjelovali biciklisti za promatrano razdoblje od 2018. do 2022. godine. U tradicionalnom prometnom planiranju, nedostatak pouzdanih podataka o izloženosti biciklista riziku kontinuirano je predstavljao ključno ograničenje u donošenju egzaktnih prostornih procjena. Međutim, korištenjem podataka Strave, kao suvremenog surogata izloženosti, u kombinaciji s podacima automatskog brojača biciklističkog prometa i kratkotrajnim ručnim brojanjem prometa, izračunat je volumen biciklističke aktivnosti u obliku PGDBP-a te je procijenjena izloženost na ukupno 11374 križanja unutar zagrebačke prometne mreže. Takvim je metodološkim pristupom neposredno ispunjen glavni cilj rada te je uspješno potvrđena prva hipoteza istraživanja, čime je dokazano da je integracijom i višeparametarskom geovizualnom analizom MPP-a biciklističkog prometa i podataka o PN-ama moguće izraditi pouzdan model sigurnosti biciklističkog prometa.

Razvoj okvira za modeliranje započeo je primjenom RQC (engl. *Rate Quality Control*) metode, koja je poslužila kao bazni model za identifikaciju potencijalnih žarišta na temelju statistički značajnih odstupanja stope PN-a u odnosu na njezinu kritičnu razinu nastanka na pojedinim križanjima. Iako ta metoda pokazuje visoku razinu znanstvene utemeljenosti jer normalizira podatke uzimajući u obzir izloženost, RQC posjeduje određena ograničenja. Kao strogo reaktivna i neparametarska metoda, oslanja se isključivo na povijesne podatke o PN-ama te promatra isključivo jednostavne linearne odnose, potpuno zanemarujući kompleksne, nelinearne i višedimenzionalne prostorne korelacije između prometne infrastrukture, socioekonomskih pokazatelja i izgrađenog okoliša. Kako bi se ta ograničenja prevladala i ostvario iskorak prema proaktivnom planiranju, razvijen je prediktivni model primjenom naprednih algoritama strojnog učenja. Time je izravno potvrđena druga hipoteza rada koja nalaže da se novi model sigurnosti biciklističkog prometa može uspješno koristiti za identifikaciju, predikciju i geovizualizaciju opasnih mjesta za biciklistički promet.

Usporednom evaluacijom triju klasifikacijskih modela (RF, XGBoost i SVM) utvrđeno je da algoritam slučajnih šuma (RF) dominira u rješavanju kompleksnog problema ekstremno neuravnoteženih klasa, karakterističnog za prostorne analize prometnog sustava, gdje većina

križanja nema zabilježenu PN-u. S obzirom na to da je u sigurnosti prometa ključno ne propustiti stvarno žarište (izbjegavanje lažno negativnih ishoda), RF model ostvario je iznimno visoku ukupnu točnost od 0,880 na cjelokupnom testnom skupu, pri čemu je za najvažniju klasu žarišta (klasu 3) zabilježio najviši odziv od 0,694 te optimalan rezultat F_2 -mjere od 0,698. Ovi klasifikacijski pokazatelji neosporno dokazuju uspješnost primjene metoda strojnog učenja na analizirani problem, jer RF algoritam najuspješnije identificira prostorne ekstreme, bez narušavanja sposobnosti točnog prepoznavanja ostalih (nižih i sigurnijih) razina prometnog rizika na mreži.

Izuzetno važan znanstveni doprinos predloženog istraživanja očituje se u postavljanju novog procesa modeliranja sigurnosti koji uključuje naprednu interpretaciju modela integracijom SHAP metode utemeljene na teoriji kooperativnih igara. Analiza rezultata pokazala je da na klasifikaciju žarišta i sigurnost biciklista ne utječu dominantno samo parametri izloženosti i prometne infrastrukture, već i demografski i okolišni faktori, pri čemu je gustoća naseljenosti prepoznata kao jedna od najutjecajnijih varijabli u modelu. Primjenom SHAP metode ostvareno je egzaktno kvantificiranje stvarnog smjera i intenziteta uzročno-posljedičnog utjecaja svake pojedine varijable. Jedno od najznačajnijih otkrića koje proizlazi iz takve interpretacije jest empirijska potvrda fenomena "sigurnosti u brojevima" (SiN) na analiziranom području Grada Zagreba. Dijagrami SHAP ovisnosti za varijablu ukupne izloženosti na ulaznim krakovima križanja (Q) matematički su potvrdili zaštitni učinak mase; izoliran i rijedak biciklistički promet stvara ranjivost i vertikalnu raspršenost točaka s pozitivnim (nepovoljnim) SHAP iznosima, dok svako daljnje povećanje izloženosti i broja biciklista u križanju aktivno smanjuje mogućnost eskalacije nesreće i odvlači predikciju od klase žarišta. Također, dubljom analizom biciklističke aktivnosti dokazano je da se fenomen SiN-a znatno snažnije očituje kod utilitarnog prometa u odnosu na rekreativni. Povećanjem omjera utilitarne aktivnosti izravno raste prometni rizik jer se utilitarni i transportni promet biciklom odvija tokom dnevnih migracija unutar najzahtjevnijih uvjeta prometnih gužvi (često na segmentima koji ne posjeduju izgrađenu infrastrukturu), dok rekreativne vožnje ostvaruju osjetno niži rizik jer se pretežno odvijaju izvan vršnih sati, vikendima i na području izvan prometnih gužvi.

Konačno, izradom i validacijom ovoga jedinstvenoga klasifikacijskog modela sigurnosti, ostvaren je operativan, primjenjiv i znanstveno utemeljen okvir za prostorno-vremensko planiranje. Prediktivni model strojnog učenja omogućio je dodjeljivanje kontinuiranog indeksa opasnosti svakom križanju na području grada, na temelju kojeg su klasificirani prioriteti sanacije te izrađena kartografska vizualizacija prostornog rasporeda najopasnijih mjesta. Ovaj novi način proaktivnog modeliranja u potpunosti mijenja paradigmu sigurnosnih procesa u urbanizmu,

preusmjeravajući djelovanje struke s reaktivnog saniranja evidentiranih opasnih mjesta na ranu predikciju i pravovremeno sprječavanje nastanka novih žarišnih točaka. Integracijom MPP-a, PN-a te prostornih i infrastrukturnih parametara snažno je produbljeno razumijevanje biciklističke aktivnosti na području Grada Zagreba u cjelini. Stečena znanja o specifičnim čimbenicima koji pozitivno ili negativno utječu na sigurnost i fenomen SiN-a pružaju donositeljima odluka transparentan i objektivan alat, čime ovaj doktorski rad izravno doprinosi razvoju sigurnije i održivije urbane infrastrukture prilagođene najranjivijim sudionicima u prometu.

Iako je ovim doktorskim istraživanjem postavljen metodološki okvir za proaktivno modeliranje sigurnosti biciklističkog prometa, postoje jasne smjernice za daljnja unaprjeđenja i potencijalni nastavak istraživanja. Prva mogućnost odnosi se na integraciju podataka o volumenu motoriziranog prometa (PGDP) kao dodatne nezavisne varijable u prediktivnim modelima. Uključivanje tih podataka omogućilo bi kvalitetnije i točnije modeliranje interakcija između najranjivijih i motoriziranih sudionika. Uz to bi trebalo ispitati mogućnosti procjene PGDBP-a isključivo na temelju terenskih mjerenja i automatskog brojača prometa, bez oslanjanja na MPP-e. U tu bi svrhu trebalo uspostaviti sustavno i redovito kratkotrajno brojanje prometa u razdoblju povišene biciklističke aktivnosti, primarno u razdoblju od travnja do listopada. Takva bi se mjerenja trebala provoditi u trajanju od minimalno 3 do 5 radnih dana te na znatno većem broju lokacija u gradu, obuhvaćajući ne samo utilitarne koridore s visokim prometnim opterećenjem, već i manje aktivne segmente mreže te specifične rekreativne rute, čime bi se postigla viša reprezentativnost. Dodatni problem prilikom prikupljanja podataka PN-a predstavlja nedovoljno prijavljivanje PN-a u kojima sudjeluju biciklisti. Stoga je potrebno postojeću bazu PN-a nadopuniti ciljanim anketnim upitnicima. Taj bi pristup omogućio otkrivanje neprijavljenih incidenata (najčešće onih s manjom materijalnom štetom) te preciznu identifikaciju onih lokacija koje sami biciklisti u svakodnevnoj vožnji percipiraju kao potencijalno opasne. Konačno, na institucionalnoj razini grada (i države) je potrebno uskladiti prikupljanje podataka o PN-ama. Standardizacija i digitalizacija evidencije trajno bi riješila problem neusklađenosti atributnih podataka između različitih postaja PP-e (posljedice PN-a, dobi sudionika, točno vrijeme nastanka i sl.), a nužno mora obuhvatiti i promjenu prikupljanja i upisa lokacije. Prelazak s dosadašnjeg upisivanja uličnih adresa na izravno bilježenje prostornih koordinata na terenu eliminirao bi pogreške pri geokodiranju te drastično podigao detaljnost i pouzdanost svih budućih prostorno-vremenskih analiza sigurnosti prometa.

LITERATURA

- Abdulhafedh, A. (2016): Crash Frequency Analysis. *Journal of Transportation Technologies*, 06(04), 169–180. <https://doi.org/10.4236/jtts.2016.64017>
- Alattar, M. A., Cottrill, C., i Beecroft, M. (2021a): Public participation geographic information system (PPGIS) as a method for active travel data acquisition. *Journal of Transport Geography*, 96(August), 103180. <https://doi.org/10.1016/j.jtrangeo.2021.103180>
- Alattar, M. A., Cottrill, C., i Beecroft, M. (2021b): Accounting for Spatial Heterogeneity Using Crowdsourced Data. *Findings*, 1–9. <https://doi.org/10.32866/001c.22495>
- Aldred, R., Goodman, A., Gulliver, J., i Woodcock, J. (2018): Cycling injury risk in London: A case-control study exploring the impact of cycle volumes, motor vehicle volumes, and road characteristics including speed limits. *Accident Analysis and Prevention*, 117, 75–84. <https://doi.org/10.1016/j.aap.2018.03.003>
- Aldred, R., Woodcock, J., i Goodman, A. (2016): Does More Cycling Mean More Diversity in Cycling? *Transport Reviews*, 36(1), 28–44. <https://doi.org/10.1080/01441647.2015.1014451>
- Alkaabi, K. (2023): Identification of hotspot areas for traffic accidents and analyzing drivers' behaviors and road accidents. *Transportation Research Interdisciplinary Perspectives*, 22. <https://doi.org/10.1016/j.trip.2023.100929>
- Ammar, D., Misra, A., Feng, F., i Bao, S. (2023): Identifying Factors Related to Crash Injury Levels Involving Bicyclists at Different Locations Through Crash Data Analysis. *Transportation Research Record*, 2677(6), 418–432. <https://doi.org/10.1177/03611981221148486>
- Anderson, M., Sharfi, K., i Gholston, S. (2006): Direct Demand Forecasting Model for Small urban Communities Using Multiple Linear Regression. *Transportation Research Record*, 1981, 114–117. <https://doi.org/10.3141/1981-18>
- Arellana, J., Saltarín, M., Larrañaga, A. M., González, V. I., i Henao, C. A. (2020): Developing an urban bikeability index for different types of cyclists as a tool to prioritise bicycle infrastructure investments. *Transportation Research Part A: Policy and Practice*, 139(January 2019), 310–334. <https://doi.org/10.1016/j.tra.2020.07.010>
- Armoogum, J., Borgato, S., Fiorello, D., Garcia, C., Gopal, Y., Maffi, S., Mars, K.-J., Popovska, T., Vincent, V., i Bogaert, M. (2022): *Study on New Mobility Patterns in European Cities: EU-Wide Passenger Mobility Survey*. <https://hal.science/hal-03894185v1>

- Aziz, S., i Ram, S. (2022): A Meta-analysis of the methodologies practiced worldwide for the identification of Road Accident Black Spots. *Transportation Research Procedia*, 62, 790–797. <https://doi.org/10.1016/j.trpro.2022.02.098>
- Basiri, A., Haklay, M., Foody, G., i Mooney, P. (2019): Crowdsourced geospatial data quality: challenges and future directions. *International Journal of Geographical Information Science*, 33(8), 1588–1593. <https://doi.org/10.1080/13658816.2019.1593422>
- Battiston, A., Napoli, L., Bajardi, P., Panisson, A., Perotti, A., Szell, M., i Schifanella, R. (2023): Revealing the determinants of gender inequality in urban cycling with large-scale data. *EPJ Data Science*, 12(1): <https://doi.org/10.1140/epjds/s13688-023-00385-7>
- Beitel, D., McNee, S., McLaughlin, F., i Miranda-Moreno, L. F. (2018): Automated Validation and Interpolation of Long-Duration Bicycle Counting Data. *Transportation Research Record*, 2672(43), 75–86. <https://doi.org/10.1177/0361198118783123>
- Beitel, D., McNee, S., i Miranda-Moreno, L. F. (2017): Quality measure of short-duration bicycle counts. *Transportation Research Record*, 2644(1), 64–71. <https://doi.org/10.3141/2644-08>
- Berhanu, Y., Schröder, D., Wodajo, B. T., i Alemayehu, E. (2024): Machine learning for predictions of road traffic accidents and spatial network analysis for safe routing on accident and congestion-prone road networks. *Results in Engineering*, 23. <https://doi.org/10.1016/j.rineng.2024.102737>
- Bopp, M., Sims, D., i Piatkowski, D. (2018): Measuring Bicycling Within the Community. *Bicycling for Transportation*, (3), 45–64. <https://doi.org/10.1016/b978-0-12-812642-4.00003-9>
- Borketey, B., i Borketey, D. (2024): Real-Time Fraud Detection Using Machine Learning. *Journal of Data Analysis and Information Processing*, 12(02), 189–209. <https://doi.org/10.4236/jdaip.2024.122011>
- Boss, D., Nelson, T., Winters, M., i Ferster, C. J. (2018): Using crowdsourced data to monitor change in spatial patterns of bicycle ridership. *Journal of Transport and Health*, 9(March), 226–233. <https://doi.org/10.1016/j.jth.2018.02.008>
- Brauer, A., Mäkinen, V., i Oksanen, J. (2021): Characterizing cycling traffic fluency using big mobile activity tracking data. *Computers, Environment and Urban Systems*, 85. <https://doi.org/10.1016/j.compenvurbsys.2020.101553>
- Broach, J., Kothuri, S., Miah, M. M., McNeil, N., Hyun, K., Mattingly, S., Nordback, K., i Proulx, F. (2023): Evaluating the Potential of Crowdsourced Data to Estimate Network-Wide Bicycle Volumes. *Transportation Research Record*. <https://doi.org/10.1177/03611981231182388>

- Büchel, B., Marra, A. D., i Corman, F. (2022): COVID-19 as a window of opportunity for cycling: Evidence from the first wave. *Transport Policy*, 116, 144–156. <https://doi.org/10.1016/j.tranpol.2021.12.003>
- Buehler, R., i Pucher, J. (2022): Cycling through the COVID-19 Pandemic to a More Sustainable Transport Future: Evidence from Case Studies of 14 Large Bicycle-Friendly Cities in Europe and North America. *Sustainability (Switzerland)*, 14(12): <https://doi.org/10.3390/su14127293>
- Chen, C., Wang, H., Roll, J., Nordback, K., i Wang, Y. (2020): Using bicycle app data to develop Safety Performance Functions (SPFs) for bicyclists at intersections: A generic framework. *Transportation Research Part A: Policy and Practice*, 132, 1034–1052. <https://doi.org/10.1016/j.tra.2019.12.034>
- Chicco, D., i Jurman, G. (2020): The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(1), 6. <https://doi.org/10.1186/s12864-019-6413-7>
- Conrow, L., Wentz, E., Nelson, T., i Pettit, C. (2018): Comparing spatial patterns of crowdsourced and conventional bicycling datasets. *Applied Geography*, 92, 21–30. <https://doi.org/10.1016/j.apgeog.2018.01.009>
- Cook, J., i Ramadas, V. (2020): When to consult precision-recall curves. *Stata Journal*, 20(1), 131–148. <https://doi.org/10.1177/1536867X20909693>
- Cooper, C. H. V. (2017): Using spatial network analysis to model pedal cycle flows, risk and mode choice. *Journal of Transport Geography*, 58, 157–165. <https://doi.org/10.1016/j.jtrangeo.2016.12.003>
- Ćosić, M. (2017): *Kontekstualna analiza prometnih nesreća pješaka i biciklista u urbanim sredinama*. Doktorski rad. Preuzeto 17. travanj 2024., od <https://urn.nsk.hr/urn:nbn:hr:119:501664>
- Dadashova, B., Griffin, G. P., Das, S., Turner, S., i Sherman, B. (2020): Estimation of Average Annual Daily Bicycle Counts using Crowdsourced Strava Data. *Transportation Research Record*, 2674(11), 390–402. <https://doi.org/10.1177/0361198120946016>
- Ding, H., Sze, N. N., Li, H., i Guo, Y. (2020): Roles of infrastructure and land use in bicycle crash exposure and frequency: A case study using Greater London bike sharing data. *Accident Analysis and Prevention*, 144. <https://doi.org/10.1016/j.aap.2020.105652>
- Effati, M., Thill, J. C., i Shabani, S. (2015): Geospatial and machine learning techniques for wicked social science problems: analysis of crash severity on a regional highway corridor. *Journal of Geographical Systems*, 17(2), 107–135. <https://doi.org/10.1007/s10109-015-0210-x>
- Ejikeme, P. K. (2025): *Integrating Gis And Machine Learning To Uncover Spatial, Temporal, And Contributing Factors To Bicycle Crashes*.

- El Esawey, M. (2014): Estimation of annual average daily bicycle traffic with adjustment factors. *Transportation Research Record*, 2443, 106–114. <https://doi.org/10.3141/2443-12>
- El Esawey, M. (2016): Toward a better estimation of annual average daily bicycle traffic: Comparison of methods for calculating daily adjustment factors. *Transportation Research Record*, 2593, 28–36. <https://doi.org/10.3141/2593-04>
- El Esawey, M. (2018a): *Daily Bicycle Traffic Volume Estimation : Comparison of Historical Average and Count Models*. d(2), 1–9. [https://doi.org/10.1061/\(ASCE\)UP.1943-5444.0000443](https://doi.org/10.1061/(ASCE)UP.1943-5444.0000443).
- El Esawey, M. (2018b): Impact of data gaps on the accuracy of annual and monthly average daily bicycle volume calculation at permanent count stations. *Computers, Environment and Urban Systems*, 70, 125–137. <https://doi.org/10.1016/j.compenvurbsys.2018.03.002>
- El Esawey, M. El, Lim, C., Sayed, T., i Mosa, A. I. (2013): Development of daily adjustment factors for bicycle traffic. *Journal of Transportation Engineering*, 139(8), 859–871. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000565](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000565)
- El Masri, O., i Bigazzi, A. Y. (2019): Road grade estimates for bicycle travel analysis on a street network. *Transportation Research Part C: Emerging Technologies*, 104(May), 158–171. <https://doi.org/10.1016/j.trc.2019.05.004>
- Elvik, R., i Goel, R. (2019): *Safety-in-numbers : An updated meta-analysis of estimates*. 129(May), 136–147.
- Fakultet prometnih znanosti (2016): *METODOLOGIJA ZA IDENTIFIKACIJU OPASNIH MJESTA U CESTOVNOJ PROMETNOJ MREŽI*.
- Fan, W., Lin, Z., Liu, S., Searcy, S., Carter, B., University of North Carolina, C., North Carolina State University, R., Transportation, N. C. D. of, i Administration, F. H. (2021): *Bicycle Volume: Counting Machine Validation i Correction, Estimating i Forecasting, and Analysis of Injury Risk*. (August), 101p.
- Ferster, C. J., Nelson, T., Winters, M., i Laberee, K. (2017): Geographic age and gender representation in volunteered cycling safety data: A case study of BikeMaps.org. *Applied Geography*, 88, 144–150. <https://doi.org/10.1016/j.apgeog.2017.09.007>
- Ferster, C., Nelson, T., Laberee, K., i Winters, M. (2021): Mapping bicycling exposure and safety risk using Strava Metro. *Applied Geography*, 127. <https://doi.org/10.1016/j.apgeog.2021.102388>
- Figliozzi, M., Johnson, P., Monsere, C., i Nordback, K. (2014): Methodology to characterize ideal short-term counting conditions and improve AADT estimation accuracy using a regression-based correcting function. *Journal of Transportation Engineering*, 140(5), 1–8. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000663](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000663)

- Fournier, N., Christofa, E., i Knodler, M. A. (2017): A sinusoidal model for seasonal bicycle demand estimation. *Transportation Research Part D: Transport and Environment*, 50, 154–169. <https://doi.org/10.1016/j.trd.2016.10.021>
- Francke, A. (2022): Cycling during and after the COVID-19 pandemic. *Advances in Transport Policy and Planning*, 10, 265–290. <https://doi.org/10.1016/bs.atpp.2022.04.011>
- Fuller, G., McGuinness, K., Waitt, G., Buchanan, I., i Lea, T. (2021): The reactivated bike: Self-reported cycling activity during the 2020 COVID-19 pandemic in Australia. *Transportation Research Interdisciplinary Perspectives*, 10(April), 100377. <https://doi.org/10.1016/j.trip.2021.100377>
- Garber, M. D., Watkins, K. E., i Kramer, M. R. (2019): Comparing bicyclists who use smartphone apps to record rides with those who do not: Implications for representativeness and selection bias. *Journal of Transport and Health*, 15. <https://doi.org/10.1016/j.jth.2019.100661>
- Gehrke, S. R., i Reardon, T. G. (2021): Direct demand modelling approach to forecast cycling activity for a proposed bike facility. *Transportation Planning and Technology*, 44(1), 1–15. <https://doi.org/10.1080/03081060.2020.1849959>
- GeoHub Zagreb (2026): *GeoHub Zagreb*. Preuzeto 26. lipanj 2026., od <https://geohub-zagreb.hub.arcgis.com/>.
- Google (2026): *Google Maps*. Preuzeto 28. lipanj 2026., od <https://www.google.com/maps/>.
- Grad Zagreb (2022): *POPIS STANOVNIŠTVA, KUĆANSTVA I STANOVA 2021. – KONAČNI REZULTATI GRAD ZAGREB*.
- Grad Zagreb (2023): *Plan razvoja Grada Zagreba za razdoblje 2021. - 2027*.
- Hankey, S., Lindsey, G., i Marshall, J. (2014): Day-of-year scaling factors and design considerations for nonmotorized traffic monitoring programs. *Transportation Research Record*, 2468, 64–73. <https://doi.org/10.3141/2468-08>
- Harirforoush, H., i Bellalite, L. (2019): A new integrated GIS-based analysis to detect hotspots: A case study of the city of Sherbrooke. *Accident Analysis and Prevention*, 130, 62–74. <https://doi.org/10.1016/j.aap.2016.08.015>
- Hong, J., McArthur, D. P., i Livingston, M. (2020): The evaluation of large cycling infrastructure investments in Glasgow using crowdsourced cycle data. *Transportation*, 47(6), 2859–2872. <https://doi.org/10.1007/s11116-019-09988-4>
- Howe, i Jeff. (2006): The Rise of Crowdsourcing. *Wired*, 14.

- Hrvatske Ceste (2026): *Hrvatske Ceste - Sigurnost i zaštita cesta*. Preuzeto 26. lipanj 2026., od <https://hrvatske-ceste.hr/hr/stranice/promet-i-sigurnost/dokumenti/12-sigurnost-i-zastita-cesta>
- Integrirani promet zagrebačkog područja (2020): *MASTER PLAN PROMETNOG SUSTAVA GRADA ZAGREBA, ZAGREBAČKE ŽUPANIJE I KRAPINSKO-ZAGORSKE ŽUPANIJE*.
- Islam, A. (2021): *Safety in Numbers: Models of Pedestrian and Bicycle Crash Frequency and Severity at Signalized Intersections in Utah using Innovative Measure of Exposure*. Utah State University.
- Islam, A., Mekker, M., i Singleton, P. A. (2025): *Investigating bicycle crash frequency , severity , and safety in numbers at signalized intersections in Utah using crowdsourced data*. 4(July 2024), 0–2.
- Jacobsen, P. (2003): Safety in numbers: More walkers and bicyclists, safer walking and bicycling. *Injury prevention : journal of the International Society for Child and Adolescent Injury Prevention*, 9, 205–209. <https://doi.org/10.1136/ip.9.3.205>
- Jestico, B., Nelson, T., i Winters, M. (2016): Mapping ridership using crowdsourced cycling data. *Journal of Transport Geography*, 52, 90–97. <https://doi.org/10.1016/j.jtrangeo.2016.03.006>
- Khan, A. A., i Hussain, J. (2024): Utilizing GIS and Machine Learning for Traffic Accident Prediction in Urban Environment. *Civil Engineering Journal (Iran)*, 10(6), 1922–1935. <https://doi.org/10.28991/CEJ-2024-010-06-013>
- Kothuri, S., Broach, J., McNeil, N., Kate Hyun, M., Mattingly, S., Mintu Miah Krista Nordback, M., Proulx, F., Hyun, K., Miah, Md. M., Nordback, K., Proulx, F., Mattingly, S., Miah, Md. M., Nordback, K., i Proulx, F. (2022): *Exploring Data Fusion Techniques to Estimate Network-Wide Bicycle Volumes*. <https://doi.org/10.15760/trec.273>
- Kwayu, K. M., Lyimo, S. M., i Kwigizile, V. (2021): Characteristics of cyclists using fitness tracker apps and its implications for planning of bicycle transport systems. *Case Studies on Transport Policy*, 9(3), 1160–1166. <https://doi.org/10.1016/j.cstp.2021.06.004>
- Lee, K., i Sener, I. N. (2021): Strava Metro data for bicycle monitoring: a literature review. *Transport Reviews*, 41(1), 27–47. <https://doi.org/10.1080/01441647.2020.1798558>
- Lin, Z., i Fan, W. (David): (2020): Modeling bicycle volume using crowdsourced data from Strava smartphone application. *International Journal of Transportation Science and Technology*, 9(4), 334–343. <https://doi.org/10.1016/j.ijtst.2020.03.003>
- Mahmoud, N., Abdel-Aty, M., Cai, Q., i Zheng, O. (2021): Vulnerable road users' crash hotspot identification on multi-lane arterial roads using estimated exposure and considering context classification. *Accident Analysis and Prevention*, 159. <https://doi.org/10.1016/j.aap.2021.106294>

- Malaghan, V., Pilla, F., Tafidis, P., i Rogers, B. (2025): Behavioral insights and hotspot identification: Integrating natural language processing, machine learning and geospatial analyses of cyclist crashes. *Transportation Research Part F: Traffic Psychology and Behaviour*, 113, 452–480. <https://doi.org/10.1016/j.trf.2025.05.005>
- McArthur, D. P., i Hong, J. (2019): Visualising where commuting cyclists travel using crowdsourced data. *Journal of Transport Geography*, 74(October 2018), 233–241. <https://doi.org/10.1016/j.jtrangeo.2018.11.018>
- Miah, M., Hyun, K., i Mattingly, S. (2022): *Machine Learning Approach to Estimate Daily Bike Traffic (DBT) Using Emerging Data Source STRAVA. Conference on Sustainability and Emerging Transportation Technology*. <https://www.researchgate.net/publication/359221932>
- Miah, M. M., Hyun, K. K., Mattingly, S. P., i Khan, H. (2023): Estimation of daily bicycle traffic using machine and deep learning techniques. *Transportation*, 50(5), 1631–1684. <https://doi.org/10.1007/s11116-022-10290-z>
- Miah, Md. M., Hyun, K. K., Mattingly, S. P., Broach, J., McNeil, N., i Kothuri, S. (2021): Challenges and Opportunities of Emerging Data Sources to Estimate Network-Wide Bike Counts. *Journal of Transportation Engineering, Part A: Systems*, 148(3): <https://doi.org/10.1061/jtepbs.0000634>
- Misra, A., Gooze, A., Watkins, K., Asad, M., i Le Dantec, C. (2014): Crowdsourcing and its application to transportation data collection and management. *Transportation Research Record*, (2414), 1–8. <https://doi.org/10.3141/2414-01>
- Moridpour, S., Tay, R., i Toran Pour, A. (2023): *Identifying the pedestrian and cyclist crash black spots in ACT road network*.
- Morrissey, M. (2018): *Modeling Cycling Counts Using Crowd-Sourced Data*.
- NACTO (2022): *Urban Bikeway Design Guide - Making Bikes Count* (Izdanje March):
- Nam, Y., Hawkins, J., Butler, D., Highway, P. E., Aldridge, N., Elayan, M., i Yoo, K. il (Jason): (2024): *Modeling Pedestrian and Bicyclist Crash Exposure with Location-Based Service Data*. <http://ntc.unl.edu>
- National Association of City Transportation Officials (2022): *Urban Bikeway Design Guide - Making Bikes Count*. <https://civic.mit.edu/2016/03/22/missing-women-blank-maps-and-data-voids-what->
- National Cooperative Highway Research Program (NCHRP) (2019): *Evaluation of Walk and Bicycle Demand Modeling Practice ii Acknowledgements*.

- Nelson, T. A., Ferster, C., Roy, A., i Winters, M. (2023): Bicycle streetscapes: a data driven approach to mapping streets based on bicycle usage. *International Journal of Sustainable Transportation*, 17(8), 931–941. <https://doi.org/10.1080/15568318.2022.2121670>
- Nelson, T., Ferster, C., Laberee, K., Fuller, D., i Winters, M. (2021): Crowdsourced data for bicycling research and practice. *Transport Reviews*, 41(1), 97–114. <https://doi.org/10.1080/01441647.2020.1806943>
- Nelson, T., Roy, A., Ferster, C., Fischer, J., Brum-Bastos, V., Laberee, K., Yu, H., i Winters, M. (2021): Generalized model for mapping bicycle ridership with crowdsourced data. *Transportation Research Part C: Emerging Technologies*, 125(November 2020), 102981. <https://doi.org/10.1016/j.trc.2021.102981>
- Nikparvar, B., i Thill, J. C. (2021): Machine learning of spatial data. U *ISPRS International Journal of Geo-Information* (Sv. 10, Izdanje 9): MDPI. <https://doi.org/10.3390/ijgi10090600>
- Nordback, K., Kothuri, S., Gibson, G., Marshall, W., i Ferencsak, N. (2018): *IMPROVING BICYCLE CRASH PREDICTION FOR URBAN ROAD SEGMENTS Final Report NITC-RR-756*.
- Nordback, K., Kothuri, S., Johnstone, D., Lindsey, G., Ryan, S., i Raw, J. (2019): Minimizing Annual Average Daily Nonmotorized Traffic Estimation Errors: How Many Counters Are Needed per Factor Group? *Transportation Research Record*, 2673(10), 295–310. <https://doi.org/10.1177/0361198119848699>
- Nordback, K., Marshall, W. E., i Janson, B. N. (2014): Bicyclist safety performance functions for a U.S. city. *Accident Analysis and Prevention*, 65, 114–122. <https://doi.org/10.1016/j.aap.2013.12.016>
- Nordback, K., Marshall, W., Janson, B., i Stolz, E. (2013): Estimating annual average daily bicyclists. *Transportation Research Record*, (2339), 90–97. <https://doi.org/10.3141/2339-10>
- Nosal, T., Miranda-Moreno, L. F., i Krstulic, Z. (2014): Incorporating weather: Comparative analysis of annual average daily bicyclist traffic estimation methods. *Transportation Research Record*, 2468, 100–110. <https://doi.org/10.3141/2468-12>
- Oksanen, J., Bergman, C., Sainio, J., i Westerholm, J. (2015): Methods for deriving and calibrating privacy-preserving heat maps from mobile sports tracking application data. *Journal of Transport Geography*, 48, 135–144. <https://doi.org/10.1016/j.jtrangeo.2015.09.001>
- Pillonnet, P. J., Clabaux, N., Fournier, J. Y., i Hernandez, F. (2024): Commuter Cyclist Crash Incidence Rate on Cycling Infrastructure in Lyon and Marseille (France): *Journal of Road Safety*, 35(4), 19–29. <https://doi.org/10.33492/JRS-D-24-4-2442359>

- Pogodzinska, S., Kiec, M., i D'Agostino, C. (2020): Bicycle Traffic Volume Estimation Based on GPS Data. *Transportation Research Procedia*, 45(2019), 874–881. <https://doi.org/10.1016/j.trpro.2020.02.081>
- Portal otvorenih podataka (2026): *Portal otvorenih podataka*. Preuzeto 8. srpanj 2026., od <https://data.gov.hr/ckan/hr/organization/grad-zagreb>.
- PostgreSQL. (2026): *PostgreSQL: About*. <https://www.postgresql.org/about/>
<https://www.postgresql.org/about/>
- Pravilnik o biciklističkoj infrastrukturi (2016): *Narodne novine*, br. 28/2016
- QField. (2026): *QField*. <https://qfield.org/>.
- Rahman, R. (2022): *Network-Wide Pedestrian and Bicycle Crash Analysis with Statistical and Machine Learning Models in Utah*. <https://digitalcommons.usu.edu/etd/8423>
- Raihan, M. A., Alluri, P., Wu, W., i Gan, A. (2019): Estimation of bicycle crash modification factors (CMFs) on urban facilities using zero inflated negative binomial models. *Accident Analysis and Prevention*, 123, 303–313. <https://doi.org/10.1016/j.aap.2018.12.009>
- Raturi, V., Hong, J., McArthur, D. P., i Livingston, M. (2021): The impact of privacy protection measures on the utility of crowdsourced cycling data. *Journal of Transport Geography*, 92(March), 103020. <https://doi.org/10.1016/j.jtrangeo.2021.103020>
- Reynolds, J., Bhuiyan, R., Currie, G., i Johnson, M. (2024): Cyclist safety around trams: A market survey. *Accident Analysis and Prevention*, 205. <https://doi.org/10.1016/j.aap.2024.107635>
- Robinson, P., Johnson, P. A., Vernoooy, M., i Klein, L. (2025): Strava Metro Data as an Urban Planning Input: Seizing Opportunities and Managing Limitations. *International Journal of E-Planning Research*, 14(1), 1–14. <https://doi.org/10.4018/IJEPR.368846>
- Roll, J. F., i Proulx, F. R. (2018): Estimating Annual Average Daily Bicycle Traffic without Permanent Counter Stations. *Transportation Research Record*, 2672(43), 145–153. <https://doi.org/10.1177/0361198118798243>
- Roy, A., Nelson, T. A., Fotheringham, A. S., i Winters, M. (2019): Correcting Bias in Crowdsourced Data to Map Bicycle Ridership of All Bicyclists. *Urban Science*, 3(2), 1–37. <https://doi.org/10.3390/urbansci3020062>
- Roy, A., Nelson, T., i Turaga, P. (2023): Functional data analysis approach for mapping change in time series: A case study using bicycle ridership patterns. *Transportation Research Interdisciplinary Perspectives*, 17. <https://doi.org/10.1016/j.trip.2022.100752>

- Rupi, F., Poliziani, C., i Schweizer, J. (2019): Data-driven Bicycle Network Analysis Based on Traditional Counting Methods and GPS Traces from Smartphone. *ISPRS International Journal of Geo-Information*, 8(8), 1–16. <https://doi.org/10.3390/ijgi8080322>
- Saad, M., Abdel-Aty, M., Lee, J., i Cai, Q. (2019): Bicycle Safety Analysis at Intersections from Crowdsourced Data. *Transportation Research Record*, 2673(4), 1–14. <https://doi.org/10.1177/0361198119836764>
- Saha, D., Alluri, P., Gan, A., i Wu, W. (2018): Spatial analysis of macro-level bicycle crashes using the class of conditional autoregressive models. *Accident Analysis and Prevention*, 118(February), 166–177. <https://doi.org/10.1016/j.aap.2018.02.014>
- Sajed, Y., Shafabakhsh, G., i Bagheri, M. (2019): Hotspot location identification using accident data, traffic and geometric characteristics. *Engineering Journal*, 23(6), 191–207. <https://doi.org/10.4186/ej.2019.23.6.191>
- Sanders, R. L., Frackelton, A., Gardner, S., Schneider, R., i Hintze, M. (2017): Ballpark method for estimating pedestrian and bicyclist exposure in Seattle, Washington: Potential option for resource-constrained cities in an age of big data. *Transportation Research Record*, 2605(1), 32–44. <https://doi.org/10.3141/2605-03>
- Sedgwick, P. M. (2012): Pearson's correlation coefficient. *BMJ: British Medical Journal*, 345. <https://api.semanticscholar.org/CorpusID:72771340>
- Sener, I. N., Lee, K., Hudson, J. G., Martin, M., i Dai, B. (2021): The challenge of safe and active transportation: Macrolevel examination of pedestrian and bicycle crashes in the Austin District. *Journal of Transportation Safety and Security*, 13(5), 525–551. <https://doi.org/10.1080/19439962.2019.1645778>
- Sener, I. N., Munira, S., i Zhang, Y. (2021): *Data Fusion for Nonmotorized Safety Analysis*.
- Senkondo, E., Chimba, D., Madalo, M., Yeboah, A., i Blue, S. (2025): Comparative Analysis of Machine Learning and Statistical Models for Railroad–Highway Grade Crossing Safety. *Vehicles*, 7(4): <https://doi.org/10.3390/vehicles7040163>
- Shakya, L. M. (2023): *Supervised vs. Unsupervised Machine Learning: A Comparative Analysis*.
- Shin, H., Cagnina, C., i Basiri, A. (2022): The Impact of Built Environment on Bike Commuting: Utilising Strava Bike Data and Geographically Weighted Models. *AGILE: GIScience Series*, 3, 1–9. <https://doi.org/10.5194/agile-giss-3-15-2022>
- Songchitruksa, P., i Zeng, X. (2010): Getis-ord spatial statistics to identify hot spots by using incident management data. *Transportation Research Record*, (2165), 42–51. <https://doi.org/10.3141/2165-05>

- Sørensen, M. W. J. . (2007): *Best practice guidelines on blackspot management and safety analysis of road networks*. Transportøkonomisk institutt.
- Statistički portal Grada Zagreba (2026, srpanj 7): *Registrirana vozila* | *Statistički portal Grada Zagreba*. Preuzeto 26. lipanj 2026., od <https://statisticki-portal-zagreb.hub.arcgis.com/datasets/motorna-vozila>.
- Strauss, J., Miranda-Moreno, L. F., i Morency, P. (2013): Cyclist activity and injury risk analysis at signalized intersections: A Bayesian modelling approach. *Accident Analysis and Prevention*, 59, 9–17. <https://doi.org/10.1016/j.aap.2013.04.037>
- Strava Metro (2026a): *Commutes in Metroview*. Preuzeto 24. lipanj 2026., od <https://stravametro.zendesk.com/hc/en-us/articles/360045856354-Commutes-in-Metroview>.
- Strava Metro (2026b): *Glossary i Data Dictionary*. Preuzeto 24. lipanj 2026., od <https://stravametro.zendesk.com/hc/en-us/articles/1500001573281-Glossary-Data-Dictionary>.
- Strava Metro (2026c): *Strava Metro*. Preuzeto 25. lipanj 2026., od <https://metro.strava.com/>.
- Tejashwini, A. G., Singh, C. K., Sinha, C., Karnani, D., i Pandey, A. (2024): *Road Accident Severity Prediction Using Random Forest Algorithm*. (April):
- United Nations (2017): *The Sustainable Development Goals Report*.
- Tin Tin, S., Woodward, A., Robinson, E., i Ameratunga, S. (2012): Temporal, seasonal and weather effects on cycle volume: An ecological study. *Environmental Health: A Global Access Science Source*, 11(1), 1–9. <https://doi.org/10.1186/1476-069X-11-12>
- Turner, S., Sener, I., Martin, M., White, L. D., Das, S., Hampshire, R., Colety, M., Fitzpatrick, K., i Wijesundera, R. (2018): *GUIDE FOR SCALABLE RISK ASSESSMENT METHODS FOR PEDESTRIANS AND BICYCLISTS*.
- Vanparijs, J., Int Panis, L., Meeusen, R., i De Geus, B. (2015): Exposure measurement in bicycle safety analysis: A review of the literature. *Accident Analysis and Prevention*, 84, 9–19. <https://doi.org/10.1016/j.aap.2015.08.007>
- Venter, Z. S., Gundersen, V., Scott, S. L., i Barton, D. N. (2023): Bias and precision of crowdsourced recreational activity data from Strava. *Landscape and Urban Planning*, 232. <https://doi.org/10.1016/j.landurbplan.2023.104686>
- Wang, H., Chen, C., Wang, Y., Assistant, G. R., i Lowry, M. B. (2015): *BICYCLE SAFETY ANALYSIS: CROWDSOURCING BICYCLE TRAVEL DATA TO ESTIMATE RISK EXPOSURE AND CREATE SAFETY PERFORMANCE FUNCTIONS*. www.pacTrans.org

- Wang, S., Gao, K., Zhang, L., Yu, B., i Easa, S. M. (2024): Geographically weighted machine learning for modeling spatial heterogeneity in traffic crash frequency and determinants in US. *Accident Analysis and Prevention*, 199(March): <https://doi.org/10.1016/j.aap.2024.107528>
- Wang, Y., Monsere, C. M., Chen, C., i Wang, H. (2018): Development of a Crash Risk-Scoring Tool for Pedestrian and Bicycle Projects in Oregon. *Transportation Research Record*, 2672(32), 30–39. <https://doi.org/10.1177/0361198118794285>
- Wei, F., i Lovegrove, G. (2013): An empirical tool to evaluate the safety of cyclists: Community based, macro-level collision prediction models using negative binomial regression. *Accident Analysis and Prevention*, 61, 129–137. <https://doi.org/10.1016/j.aap.2012.05.018>
- Więckowska, B., Kubiak, K. B., Jóźwiak, P., Moryson, W., i Stawińska-Witoszyńska, B. (2022): Cohen's Kappa Coefficient as a Measure to Assess Classification Improvement following the Addition of a New Marker to a Regression Model. *International Journal of Environmental Research and Public Health*, 19(16), 10213. <https://doi.org/10.3390/ijerph191610213>
- Xin, R., Ai, T., Ding, L., Zhu, R., i Meng, L. (2022): Impact of the COVID-19 pandemic on urban human mobility - A multiscale geospatial network analysis using New York bike-sharing data. *Cities*, 126. <https://doi.org/10.1016/j.cities.2022.103677>
- Yiannakoulis, N., Bennet, S. A., i Scott, D. M. (2012): Mapping commuter cycling risk in urban areas. *Accident Analysis and Prevention*, 45, 164–172. <https://doi.org/10.1016/j.aap.2011.12.002>
- Zayed, M. A. (2016): Towards an index of city readiness for cycling. *International Journal of Transportation Science and Technology*, 5(3), 210–225. <https://doi.org/10.1016/j.ijtst.2017.01.002>

PRILOZI

Prilog 1. Primjer zapisnika kratkotrajnog manualnog brojanja

Zapisnik brojanja biciklističkog prometa

Loakcija: _____

Koordinate (N / E): _____

Datum: _____

Zapisnik vodi: _____

Vrijeme	Spol M	Ukupno M	Spol Ž	Ukupno Ž
	Ukupno:			Ukupno:

Prilog 2. Znakovnik Upitnika o prometnoj nesreći (UPN)

ZNAKOVNIK ZA POPUNJAVANJE UPITNIKA O PROMETNOJ NESREĆI (UPN)			
PODACI O PROMETNOJ NESREĆI I SUDIONICIMA			
ZNAK	POSLEDICE PROMETNE NESREĆE	ZNAK	OKOLNOSTI KOJE SU PRETHODILE
1	s poginulim osobama	01	GREŠKA – PROPUST VOZAČA
2	s ozlijeđenim osobama	02	nepropisna brzina
3	s materijalnom štetom	03	brzina neprimjerena uvjetima
ZNAK	VRSTA PROMETNE NESREĆE	04	vožnja na nedovoljnoj udaljenosti
	MEĐUSOBNI SUDAR VOZILA U POKRETU	05	zakašnjelo uočavanje opasnosti
01	iz suprotnih smjerova	06	nepropisno pretjecanje
02	bočni sudar	07	nepropisno obilaženje
03	usporodna vožnja	08	nepropisno mimoilaženje
04	vožnja u slijedu	09	nepropisno uključivanje u promet
05	vožnja unatrag	10	nepropisno skretanje
06	udar vozila u parkirano vozilo	11	nepropisno okretanje
08	slijetanje vozila s ceste	12	nepropisna vožnja unatrag
09	nalet na bicikl	13	nepropisno prestrojavanje
10	nalet na pješaka	14	nepoštivanje prednosti prolaska
11	nalet na motocikl ili moped	15	nepropisno parkiranje
12	sudar sa željezničkim vozilom	16	naglo usporavanje – kočenje
14	ostalo	17	nepoštivanje svjetlosnog znaka
15	udar vozila u objekt na cesti	18	neosiguran teret na vozilu
16	udar vozila u objekt kraj ceste	19	nemarno postupanje s vozilom
	NALET NA ŽIVOTINJU	20	ostale greške vozača
17	domaća životinja		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	odmlja 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

ZNAK	OKOLIŠ	ZNAK	HORIZONTALNA SIGNALIZACIJA
1	okoliš ureden	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	lakí 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		

Prilog 3. **Obrazac za izdavanje podataka DZS-a**

Adam Vinković

PODNOŠITELJ

ADRESA

avinkovic@geof.hr

E-MAIL

TELEFON

01.03.2024.

DATUM

GRADSKI URED ZA GOSPODARSTVO, EKOLOŠKU
ODRŽIVOST I STRATEGIJSKO PLANIRANJE
Sektor za stratezijske informacije i istraživanja
Odjel za prostorne informacije i istraživanja
Sv. Ćirila i Metoda 5
10 000 Z A G R E B
geos@zagreb.hr

Predmet: ZAMOLBA ZA IZDAVANJE PROSTORNIH PODATAKA

1. Svrha izdavanja podataka:

Znanstveno istraživanje u okviru doktorskog rada. U istraživanju analiziram prostorne podatke prometnih nesreća u kojima su sudjelovali biciklisti u kombinaciji s mnoštveno prikupljenim podacima, a socio-demografski podaci mjesnih odbora služili bi kao parametri predikcije prom. nesreća.

2. Vrsta podataka (koji kartografski prikazi)


Podaci za mjesne odbore grada Zagreba iz popisa 2021. koji se odnose na strukturu stanovništva (broj, gustoća, prostorni razmještaj, udio djece i starijih). Ukoliko postoje, podaci o obrazovnoj strukturi po mjesnim odborima. Prostorne granice mjesnih odbora s ID-em kojim bih mogao povezati ostale tablice.

3. Obuhvat

Grad Zagreb

4. Format


Xls (ili csv) ili neki drugi tekstualni format za tablične podatke, te geojson (ili shp) za prostorne podatke.




POTPIS

Prilog 4. Karte prostorno-vremenske analize rekreativne Strava aktivnosti


Rekreativne aktivnosti u 2019.




Rekreativne aktivnosti u 2020.



Rekreativne aktivnosti u 2021.




Rekreativne aktivnosti u 2022.



Prilog 5. Karte prosječne godišnje Strava aktivnosti (ukupne, rekreativne i utilitarne) po linijskom segmentu mreže za područje MO-a

Prosječna vrijednost ukupnog
broja STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2019.




Prosječna vrijednost ukupnog broja STRAVA aktivnosti

- 31 - 290
- 291 - 481
- 482 - 695
- 696 - 1060
- 1061 - 1499
- 1500 - 2614


Mjerilo 1: 175 000

Karta izrađena u okviru doktorskog istraživanja.
Izvori podataka: STRAVA, DZS, OSM.


Prosječna vrijednost ukupnog
broja STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2020.




Prosječna vrijednost ukupnog
broja STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2021.




Prosječna vrijednost ukupnog
broja STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2022.



Prosječna vrijednost ukupnog broja
rekreativnih STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2019.



Prosječna vrijednost ukupnog broja
rekreativnih STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2020.




Prosječna vrijednost ukupnog broja
rekreativnih STRAVA aktivnosti

- 30 - 260
- 261 - 435
- 436 - 698
- 699 - 1034
- 1035 - 1598
- 1599 - 2421

Mjerilo 1: 175 000

Karta izrađena u okviru doktorskog istraživanja.
Izvori podataka: STRAVA, DZS, OSM.

Prosječna vrijednost ukupnog broja
rekreativnih STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2021.



Prosječna vrijednost ukupnog broja rekreativnih STRAVA aktivnosti za područje MO-a Grada Zagreba u 2022.

Prosjek ukupnog broja rekreativnih aktivnosti

- 30 - 260
- 261 - 435
- 436 - 698
- 699 - 1034
- 1035 - 1598
- 1599 - 2421


Mjerilo 1: 175 000

Karta izrađena u okviru doktorskog istraživanja.
Izvori podataka: STRAVA, DZS, OSM.

■ 30 - 260
 ■ 261 - 435
 ■ 436 - 698
 ■ 699 - 1034
 ■ 1035 - 1598
 ■ 1599 - 2421

Karta izrađena u okviru doktorskog istraživanja.
Izvori podataka: STRAVA, DZS, OSM.

Prosječna vrijednost ukupnog broja
utilitarnih STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2019.



Prosječna vrijednost ukupnog broja
utilitarnih STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2020.


Prosječna vrijednost ukupnog broja
utilitarnih aktivnosti

0,1 - 47
48 - 120
121 - 183
184 - 250
251 - 364
365 - 560


Mjerilo 1: 175 000

Karta izrađena u okviru doktorskog istraživanja.
Izvori podataka: STRAVA, DZS, OSM.

Prosječna vrijednost ukupnog broja
utilitarnih STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2021.



Prosječna vrijednost ukupnog broja
utilitarnih STRAVA aktivnosti za
područje MO-a Grada
Zagreba u 2022.



Prilog 6. Usporedba ukupnog broja prolaza na automatskog brojaču i Strava aktivnosti na segmentu brojača na mjesečnoj razini

Mjesec	Automatski brojač	Strava - ukupna aktivnost	Strava %	Rekreativne vožnje	%	Utilitarne vožnje	%
01-2019	16143	215	1,33	50	23,26	170	79,07
02-2019	23418	370	1,58	125	33,78	245	66,22
03-2019	36615	560	1,53	210	37,50	350	62,50
04-2019	33552	470	1,40	150	31,91	320	68,09
05-2019	30554	440	1,44	155	35,23	285	64,77
06-2019	43625	660	1,51	275	41,67	385	58,33
07-2019	47421	725	1,53	285	39,31	440	60,69
08-2019	34893	505	1,45	250	49,50	260	51,49
09-2019	41561	625	1,50	230	36,80	395	63,20
10-2019	52323	635	1,21	225	35,43	410	64,57
11-2019	40563	365	0,90	135	36,99	230	63,01
12-2019	36403	290	0,80	95	32,76	195	67,24
01-2020	32598	305	0,94	70	22,95	235	77,05
02-2020	35390	420	1,19	140	33,33	280	66,67
03-2020	41060	450	1,10	175	38,89	275	61,11
04-2020	31046	740	2,38	540	72,97	200	27,03
05-2020	33881	790	2,33	510	64,56	275	34,81
06-2020	46988	670	1,43	400	59,70	270	40,30
07-2020	56843	820	1,44	445	54,27	380	46,34
08-2020	38238	545	1,43	345	63,30	200	36,70
09-2020	57511	835	1,45	420	50,30	415	49,70
10-2020	42003	530	1,26	290	54,72	235	44,34
11-2020	25383	410	1,62	225	54,88	180	43,90
12-2020	17624	290	1,65	170	58,62	115	39,66
01-2021	17440	290	1,66	155	53,45	135	46,55
02-2021	25872	550	2,13	295	53,64	255	46,36
03-2021	38568	730	1,89	295	40,41	430	58,90
04-2021	30787	620	2,01	300	48,39	320	51,61
05-2021	39520	825	2,09	425	51,52	400	48,48
06-2021	50778	1470	2,89	745	50,68	725	49,32
07-2021	45749	970	2,12	475	48,97	500	51,55
08-2021	34769	630	1,81	300	47,62	330	52,38
09-2021	53379	830	1,55	420	50,60	410	49,40
10-2021	40310	635	1,58	320	50,39	315	49,61
11-2021	28709	375	1,31	165	44,00	205	54,67
12-2021	23196	305	1,31	120	39,34	180	59,02
01-2022	12538	305	2,43	175	57,38	130	42,62
02-2022	15345	440	2,87	185	42,05	255	57,95
03-2022	24863	805	3,24	290	36,02	515	63,98
04-2022	24608	800	3,25	295	36,88	505	63,13

Mjesec	Automatski brojč	Strava - ukupna aktivnost	Strava %	Rekreativne vožnje	%	Utilitarne vožnje	%
05-2022	36588	1135	3,10	475	41,85	660	58,15
06-2022	34135	865	2,53	375	43,35	490	56,65
07-2022	31788	1055	3,32	455	43,13	595	56,40
08-2022	25053	770	3,07	360	46,75	410	53,25
09-2022	27419	740	2,70	280	37,84	460	62,16
10-2022	32622	930	2,85	410	44,09	525	56,45
11-2022	21966	575	2,62	190	33,04	385	66,96
12-2022	14064	310	2,20	125	40,32	180	58,06


Prilog 7. Podaci kratkotrajnog brojanja biciklističkog prometa

	Savska - Kršnjavog		Selska - Horvaćanska		Vukovarska (Lisinski)		Most slobode (Z)		Most slobode (I)		Savska 25		Savska - Slavonska		Svetice - Budakova		Jadranski most (I)	
Vrijeme	M	Ž	M	Ž	M	Ž	M	Ž	M	Ž	M	Ž	M	Ž	M	Ž	M	Ž
07:00-07:15	12	3	4	1	21	8	10	4	4	8	15	5	14	6	7	1	5	3
07:15-07:30	15	2	6	3	23	14	9	6	16	5	11	6	40	14	5	3	3	2
07:30-07:45	16	9	12	4	30	32	17	5	22	8	16	11	34	13	6	4	2	3
07:45-08:00	19	14	24	5	47	22	13	9	18	6	22	18	43	16	4	3	16	9
08:00-08:15	9	12	8	5	53	25	16	9	11	13	23	16	37	15	7	1	15	9
08:15-08:30	14	10	4	2	36	15	16	6	20	2	14	13	31	15	3	3	8	1
08:30-08:45	13	9	6	1	49	16	8	7	17	6	23	7	28	8	3	3	12	6
08:45-09:00	11	13	9	6	44	23	12	3	14	4	11	15	31	12	4	2	9	3
Σ	109	72	73	27	303	155	101	49	122	52	135	91	258	99	39	20	70	36
Σ jutro	181		100		458		150		174		226		357		59		106	
15:00-15:15	20	9	13	5	46	16	13	6	12	5	27	8	28	8	3	1	20	5
15:15-15:30	34	10	14	6	36	20	15	4	9	5	28	11	29	12	8	4	12	2
15:30-15:45	32	7	17	4	43	26	13	8	14	0	32	11	37	14	4	2	15	1
15:45-16:00	24	10	27	11	37	21	18	10	10	2	41	14	20	13	4	3	16	2
16:00-16:15	36	12	24	8	46	27	9	5	5	5	41	14	44	23	7	2	19	6
16:15-16:30	26	17	18	3	47	24	10	4	12	0	37	14	53	17	6	1	23	12
16:30-16:45	20	14	20	8	53	22	12	5	7	1	33	10	57	16	4	2	12	5
16:45-17:00	26	8	12	4	38	23	5	1	13	1	33	12	39	16	3	2	8	5
Σ	218	87	145	49	346	179	95	43	82	19	272	94	307	119	39	17	125	38
Σ popodne	305		194		525		138		101		366		426		56		163	
Σ po spolu	327	159	218	76	649	334	196	92	204	71	407	185	565	218	78	37	195	74
Σ ukupno	486		294		983		288		275		592		783		115		269	

Prilog 8. Faktori prilagodbe dana u tjednu (DOW) i mjeseca u godini (MOY) za izračun procijenjenog PGDBP-a

2019			2020			2021			2022			2019 - 2022		
Dan u tjednu	PDBP	DF	Dan u tjednu	PDBP	DF	Dan u tjednu	PDBP	DF	Dan u tjednu	PDBP	DF	Dan u tjednu	PDBP	DF
Pon	1354	0,884	Pon	1438	0,896	Pon	1307,00	0,900	Pon	944	0,874	Pon	1242	0,903
Uto	1467	0,816	Uto	1481	0,870	Uto	1517,00	0,775	Uto	1025	0,805	Uto	1343	0,835
Sri	1498	0,799	Sri	1554	0,829	Sri	1537,00	0,765	Sri	1048	0,787	Sri	1380	0,813
Čet	1538	0,778	Čet	1639	0,786	Čet	1467,00	0,802	Čet	995	0,829	Čet	1377	0,814
Pet	1456	0,822	Pet	1400	0,920	Pet	1295,00	0,908	Pet	871	0,947	Pet	1230	0,912
Sub	601	1,992	Sub	834	1,544	Sub	647,00	1,818	Sub	462	1,786	Sub	599	1,874
Ned	463	2,585	Ned	659	1,955	Ned	457,00	2,573	Ned	435	1,897	Ned	475	2,362

2019			2020			2021			2022			2019 - 2022		
Mjesec	PDBP	MF	Mjesec	PDBP	MF	Mjesec	PDBP	MF	Mjesec	PDBP	MF	Mjesec	PDBP	MF
1	521	2,299	1	1052	1,225	1,00	562,58	2,090	1	404	2,040	1	635	1,767
2	836	1,431	2	1220	1,055	2,00	924,00	1,273	2	548	1,505	2	885	1,267
3	1181	1,013	3	1325	0,972	3,00	1244,12	0,945	3	802	1,029	3	1138	0,986
4	1118	1,070	4	1035	1,245	4,00	1026,23	1,146	4	820	1,006	4	1000	1,122
5	986	1,214	5	1433	0,899	5,00	1274,83	0,922	5	1180	0,699	5	1133	0,989
6	1454	0,823	6	1566	0,822	6,00	1692,60	0,695	6	1138	0,725	6	1217	0,922
7	1530	0,783	7	1834	0,702	7,00	1475,77	0,797	7	1025	0,805	7	1466	0,765
8	1126	1,063	8	1233	1,044	8,00	1121,58	1,049	8	808	1,021	8	1072	1,046
9	1385	0,864	9	1917	0,672	9,00	1779,30	0,661	9	914	0,903	9	1499	0,748
10	1688	0,709	10	1355	0,951	10,00	1300,32	0,904	10	1052	0,784	10	1349	0,831
11	1352	0,885	11	846	1,522	11,00	956,96	1,229	11	732	1,127	11	972	1,154
12	1174	1,019	12	569	2,264	12,00	748,25	1,572	12	454	1,819	12	736	1,523

Prilog 9. Grafikon dnevnih meteoroloških podataka

Prilog 10. Mjesečni meteorološki podaci

	2018		2019		2020		2021		2022	
Mjesec	Prosjeck	Oborine	Prosjeck	Oborine	Prosjeck	Oborine	Prosjeck	Oborine	Prosjeck	Oborine
1	6,2	55,7	2,4	35,5	2,6	6,0	3,5	52,1	3,0	27,2
2	1,0	102,3	6,9	16,7	8,9	37,3	6,9	18,3	6,8	41,0
3	6,1	72,6	11,3	39,5	9,7	24,7	8,2	29,8	8,3	23,6
4	17,9	59,5	14,0	86,7	15,4	41,8	10,6	56,7	12,3	70,7
5	21,2	108,3	14,7	121,6	17,1	76,1	15,6	117,5	20,2	55,8
6	23,1	66,6	25,3	83,9	21,5	105,8	24,3	32,6	24,7	55,7
7	24,4	102,1	24,7	76,8	23,3	200,3	25,0	0,0	25,6	51,1
8	25,8	44,3	24,8	43,6	24,2	115,2	22,9	40,6	24,8	18,7
9	19,7	54,6	18,8	131,6	19,3	61,4	19,2	33,6	17,8	235,9
10	15,4	65,6	15,0	43,5	13,4	182,8	11,2	68,3	15,2	27,9
11	8,9	77,5	10,0	177,4	6,4	36,9	7,0	95,6	8,6	95,1
12	4,2	17,5	5,8	96,0	4,3	84,0	4,1	79,0	5,0	110,4
Prosjeck	14,5	68,9	14,5	79,4	13,9	81,0	13,2	52,0	14,4	67,8

Prilog 11. Analiza SiN efekta po godinama

	2019	Bic. Infrastruktura (50m)	Prsten oko bic. infra. (50-200m)	Ostatak mreže
	PN	95	31	42
Strava	Duljina segmenata (km)	918,46	751,64	2975,28
	PGBP ukupno	728,51	333,64	463,66
	PGBP util	286,67	112,08	90,08
	PGBP rekr	441,86	221,58	373,59
	U/R % prosjek	73,78	71,01	46,17
	Ukupno (x 10k)	2055,64	861,22	1868,43
	Util (x 10k)	805,03	286,53	367,74
	Rekr (x 10k)	1250,67	574,76	1500,73
	U/R %	64,37	49,85	24,50
	Ukupno (x 10k) / km	2,24	1,15	0,63
	Util (x 10k) / km	0,88	0,38	0,12
	Rekr (x 10k) / km	1,36	0,76	0,50
SiN indeks	SiN ukupno	42,45	27,06	66,88
	SiN util	108,39	81,32	339,81
	SiN rekr	69,77	40,54	83,27
	2020	Bic. Infrastruktura (50m)	Prsten oko bic. infra. (50-200m)	Ostatak mreže
	PN	99	37	62
Strava	Duljina segmenata (km)	962,95	837,64	3437,86
	PGBP ukupno	1013,24	442,76	618,02
	PGBP util	279,17	111,02	95,54
	PGBP rekr	734,09	331,78	522,53
	U/R % prosjek	40,68	37,17	26,79
	Ukupno (x 10k)	3013,02	1254,40	2774,76
	Util (x 10k)	827,49	310,97	433,60
	Rekr (x 10k)	2185,59	943,52	2341,32
	U/R %	37,86	32,96	18,52
	Ukupno (x 10k) / km	1,05	0,53	0,18
	Util (x 10k) / km	0,29	0,13	0,03
	Rekr (x 10k) / km	0,76	0,40	0,15
SiN indeks	SiN ukupno	94,09	70,00	344,89
	SiN util	341,48	279,16	2230,97
	SiN rekr	129,86	93,41	407,91

	2021	Bic. Infrastruktura (50m)	Prsten oko bic. infra. (50-200m)	Ostatak mreže
	PN	60	26	51
Strava	Duljina segmenata (km)	953,74	825,01	3360,63
	PGBP ukupno	1050,43	448,74	617,85
	PGBP util	313,95	118,70	102,76
	PGBP rekr	736,49	330,05	515,12
	U/R % prosjek	44,93	42,03	32,28
	Ukupno (x 10k)	3091,17	1257,29	2731,78
	Util (x 10k)	920,26	328,48	458,61
	Rekr (x 10k)	2170,97	928,86	2273,37
	U/R %	42,39	35,36	20,17
	Ukupno (x 10k) / km	1,10	0,54	0,18
	Util (x 10k) / km	0,33	0,14	0,03
	Rekr (x 10k) / km	0,77	0,40	0,15
SiN indeks	SiN ukupno	54,48	47,80	277,40
	SiN util	182,27	180,71	1667,89
	SiN rekr	77,70	64,99	332,72

	2022	Bic. Infrastruktura (50m)	Prsten oko bic. infra. (50-200m)	Ostatak mreže
	PN	92	30	52
Strava	Duljina segmenata (km)	949,66	811,94	3345,54
	PGBP ukupno	1010,46	425,10	567,07
	PGBP util	362,44	133,83	111,24
	PGBP rekr	648,02	291,29	455,86
	U/R % prosjek	60,09	55,91	40,08
	Ukupno (x 10k)	2953,44	1173,64	2463,26
	Util (x 10k)	1054,84	365,22	488,31
	Rekr (x 10k)	1898,60	808,44	1975,05
	U/R %	55,56	45,18	24,72
	Ukupno (x 10k) / km	1,06	0,52	0,17
	Util (x 10k) / km	0,38	0,16	0,03
	Rekr (x 10k) / km	0,68	0,36	0,14
SiN indeks	SiN ukupno	86,46	57,30	306,78
	SiN util	241,06	182,01	1563,90
	SiN rekr	134,82	83,62	381,63

Prilog 12. Rang lista prvih 100 križanja prema indeksu opasnosti I_{HS}

fid	PN	Q _j	C _R	C _{CR}	C _R /C _{CR}	Predikcija (RF)	P klasa 3 (RF)	P (kalibr.) klasa 0	P (kalibr.) klasa 1	P (kalibr.) klasa 2	P (kalibr.) klasa 3	P _{KR}	I _{HS}	y (HTRS96)	x (HTRS96)
3411	4	250,92	8,729	3,682	2,371	3	0,9978	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	460978,445	5075059,986
5584	3	223,23	7,359	3,935	1,870	3	0,9998	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	457681,3365	5073938,814
5589	3	244,83	6,710	3,734	1,797	3	1,0000	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	457672,0223	5073951,091
5590	3	239,85	6,849	3,777	1,813	3	1,0000	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	457642,2063	5073942,259
3848	9	568,23	8,673	2,419	3,585	3	0,9974	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	456863,2559	5072194,786
3847	8	567,96	7,713	2,420	3,187	3	0,9992	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	456885,6611	5072231,274
5585	3	224,55	7,316	3,922	1,866	3	1,0000	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	457681,0377	5073944,017
4054	5	323,94	8,452	3,203	2,639	3	0,9959	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	456783,5824	5070440,932
5925	3	235,86	6,965	3,813	1,827	3	0,9978	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	457636,4754	5073945,377
5921	3	239,85	6,849	3,777	1,813	3	1,0000	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	457621,1827	5073931,288
6153	8	898,84	4,874	1,977	2,465	3	1,0000	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	454874,4497	5072979,966
4422	4	228,09	9,603	3,887	2,471	3	0,9943	0,0000	0,0000	0,0002	0,9998	1,0000	2,9998	460943,9242	5075055,235
5052	4	308,64	7,097	3,287	2,159	3	0,9958	0,0000	0,0000	0,0005	0,9995	1,0000	2,9995	460997,1473	5075016,012
4052	5	324,24	8,444	3,201	2,638	3	0,9931	0,0000	0,0000	0,0007	0,9993	1,0000	2,9993	456794,3672	5070456,205
3882	8	644,12	6,801	2,284	2,978	3	0,9969	0,0000	0,0000	0,0007	0,9993	1,0000	2,9993	456930,6504	5072176,436
6032	5	328,5	8,334	3,179	2,622	3	0,9971	0,0000	0,0000	0,0007	0,9993	1,0000	2,9993	456793,4001	5070461,425
5164	7	1142,08	3,356	1,796	1,869	3	0,9984	0,0000	0,0000	0,0007	0,9993	1,0000	2,9993	460566,347	5074163,693
6120	9	895,32	5,504	1,980	2,780	3	0,9959	0,0000	0,0000	0,0007	0,9993	1,0000	2,9993	454872,3915	5072958,841
5540	7	1123,96	3,410	1,807	1,887	3	0,9984	0,0000	0,0000	0,0007	0,9993	1,0000	2,9993	460547,9139	5074157,008
5422	3	210,9	7,789	4,066	1,916	3	0,9947	0,0000	0,0000	0,0007	0,9993	1,0000	2,9993	457692,2211	5073928,859
5431	8	1215,25	3,605	1,753	2,056	3	0,9955	0,0000	0,0000	0,0010	0,9990	1,0000	2,9990	458191,6882	5073412,449
6157	8	696,6	6,289	2,205	2,852	3	0,9980	0,0000	0,0000	0,0010	0,9990	1,0000	2,9990	454894,5617	5072977,741
5544	7	1138,2	3,368	1,798	1,873	3	0,9942	0,0000	0,0000	0,0015	0,9985	1,0000	2,9985	460540,1243	5074175,174
5165	7	1164,72	3,291	1,782	1,847	3	0,9961	0,0000	0,0000	0,0017	0,9983	1,0000	2,9983	460574,6523	5074166,752

fid	PN	Q _j	C _R	C _{CR}	C _R /C _{CR}	Predikcija (RF)	P klasa 3 (RF)	P (kalibr.) klasa 0	P (kalibr.) klasa 1	P (kalibr.) klasa 2	P (kalibr.) klasa 3	P _{KR}	I _{HS}	y (HTRS96)	x (HTRS96)
4031	8	879,04	4,983	1,995	2,498	3	0,9896	0,0000	0,0000	0,0017	0,9983	1,0000	2,9983	454878,0124	5073016,639
6134	8	913,52	4,795	1,964	2,442	3	0,9983	0,0000	0,0000	0,0017	0,9983	1,0000	2,9983	454875,996	5072995,914
4044	3	147,3	11,152	5,044	2,211	3	0,9718	0,0000	0,0000	0,0017	0,9983	1,0000	2,9983	457494,5376	5073263,838
5142	8	1260,85	3,474	1,729	2,009	3	0,9957	0,0000	0,0000	0,0017	0,9983	1,0000	2,9983	458201,368	5073432,289
6156	8	702,63	6,235	2,197	2,838	3	0,9961	0,0000	0,0000	0,0022	0,9978	1,0000	2,9978	454896,4736	5072992,654
5598	7	900,39	4,257	1,975	2,155	3	0,9949	0,0000	0,0011	0,0007	0,9982	0,9989	2,9970	458240,8933	5073446,639
5599	7	900,39	4,257	1,975	2,155	3	0,9742	0,0000	0,0011	0,0007	0,9982	0,9989	2,9970	458240,5536	5073446,985
4051	4	338,52	6,470	3,129	2,068	3	0,9939	0,0000	0,0020	0,0002	0,9977	0,9980	2,9957	456755,7055	5070452,951
6181	8	448,38	9,770	2,711	3,604	3	0,9932	0,0000	0,0011	0,0023	0,9966	0,9989	2,9955	456968,9374	5072184,406
2371	2	15,44	70,929	26,229	2,704	3	0,9888	0,0000	0,0000	0,0048	0,9952	1,0000	2,9952	455992,6672	5068241,575
5924	3	239,4	6,862	3,781	1,815	3	0,9999	0,0000	0,0032	0,0002	0,9966	0,9968	2,9934	457623,1714	5073940,222
5920	3	239,4	6,862	3,781	1,815	3	0,9991	0,0000	0,0032	0,0002	0,9966	0,9968	2,9934	457622,7706	5073939,58
5420	3	225,33	7,290	3,914	1,863	3	0,9978	0,0000	0,0032	0,0002	0,9966	0,9968	2,9934	457674,5603	5073931,135
5918	3	235,68	6,970	3,815	1,827	3	0,9883	0,0000	0,0032	0,0005	0,9963	0,9968	2,9932	457623,4695	5073925,816
6174	8	646,28	6,778	2,281	2,972	3	0,9631	0,0000	0,0032	0,0007	0,9961	0,9968	2,9929	456920,0477	5072193,703
5051	4	340,05	6,441	3,122	2,063	3	0,9925	0,0000	0,0020	0,0040	0,9940	0,9980	2,9921	460982,2043	5075007,693
5596	8	759,27	5,769	2,123	2,717	3	0,9877	0,0000	0,0020	0,0040	0,9940	0,9980	2,9921	458163,8697	5073377,271
9596	4	367,72	5,956	2,997	1,988	3	0,9906	0,0000	0,0036	0,0017	0,9948	0,9964	2,9912	459793,8484	5070346,631
5370	5	424,08	6,456	2,787	2,316	3	0,9929	0,0000	0,0036	0,0017	0,9948	0,9964	2,9912	459652,6371	5073598,608
5620	9	865,02	5,697	2,009	2,836	3	0,9891	0,0000	0,0036	0,0021	0,9943	0,9964	2,9907	458232,1955	5073469,926
3798	8	851,64	5,144	2,022	2,544	3	0,9953	0,0000	0,0041	0,0016	0,9943	0,9959	2,9902	457186,3654	5072853,064
5586	3	242,67	6,769	3,752	1,804	3	0,9957	0,0000	0,0048	0,0005	0,9948	0,9952	2,9900	457644,4737	5073927,095
4012	8	1018,71	4,300	1,879	2,289	3	0,9906	0,0000	0,0046	0,0019	0,9936	0,9954	2,9890	457186,4634	5072867,289
3781	4	217,29	10,080	3,997	2,522	3	0,9856	0,0000	0,0052	0,0007	0,9941	0,9948	2,9889	454622,6103	5073152,347
4045	4	335,13	6,536	3,146	2,078	3	0,9873	0,0000	0,0052	0,0019	0,9930	0,9948	2,9878	456814,5321	5070481,628
5923	3	244,38	6,722	3,737	1,799	3	0,9956	0,0000	0,0060	0,0005	0,9935	0,9940	2,9875	457636,9636	5073921,211

fid	PN	Q _j	C _R	C _{CR}	C _R /C _{CR}	Predikcija (RF)	P klasa 3 (RF)	P (kalibr.) klasa 0	P (kalibr.) klasa 1	P (kalibr.) klasa 2	P (kalibr.) klasa 3	P _{KR}	I _{HS}	y (HTRS96)	x (HTRS96)
6035	8	710,08	6,169	2,187	2,821	3	0,9979	0,0000	0,0011	0,0104	0,9885	0,9989	2,9875	456897,2806	5072193,594
5960	3	250,02	6,570	3,690	1,781	3	0,9930	0,0000	0,0060	0,0005	0,9935	0,9940	2,9875	457613,3509	5073936,376
3839	8	494,34	8,861	2,585	3,428	3	0,9765	0,0000	0,0060	0,0007	0,9933	0,9940	2,9872	456954,5135	5072141,683
1886	2	80,85	13,545	7,462	1,815	3	0,9907	0,0000	0,0060	0,0012	0,9927	0,9940	2,9867	460840,8395	5074450,011
3849	8	606,09	7,228	2,348	3,078	3	0,9942	0,0000	0,0060	0,0015	0,9925	0,9940	2,9865	456860,3237	5072171,144
4032	8	751,68	5,828	2,133	2,733	3	0,9985	0,0000	0,0019	0,0097	0,9884	0,9981	2,9865	454849,8677	5072998,283
6154	8	742,71	5,898	2,144	2,751	3	0,9935	0,0000	0,0019	0,0097	0,9884	0,9981	2,9865	454847,5521	5072982,395
6044	8	619,02	7,077	2,326	3,043	3	0,9847	0,0000	0,0019	0,0102	0,9879	0,9981	2,9860	454889,4108	5073048,921
5204	7	1497,1	2,560	1,623	1,577	3	0,9534	0,0000	0,0032	0,0086	0,9882	0,9968	2,9851	460558,3743	5074182,415
3842	8	611,97	7,158	2,338	3,062	3	0,9000	0,0000	0,0060	0,0035	0,9905	0,9940	2,9845	456928,6417	5072136,794
5494	8	916,68	4,779	1,961	2,437	3	0,9947	0,0000	0,0074	0,0010	0,9916	0,9926	2,9842	458266,1137	5073436,544
3813	5	334,68	8,181	3,148	2,599	3	0,9939	0,0000	0,0074	0,0015	0,9911	0,9926	2,9837	456765,6925	5070440,734
1919	4	378,16	5,792	2,954	1,961	3	0,9910	0,0000	0,0074	0,0015	0,9911	0,9926	2,9837	459794,1003	5070336,282
4204	4	252,93	8,660	3,666	2,362	3	0,9902	0,0000	0,0074	0,0015	0,9911	0,9926	2,9837	460954,0106	5075108,175
10996	3	237,51	6,916	3,798	1,821	3	0,9869	0,0000	0,0074	0,0018	0,9908	0,9926	2,9834	464616,2894	5076362,77
4010	8	1009,53	4,339	1,885	2,302	3	0,9861	0,0000	0,0074	0,0018	0,9908	0,9926	2,9834	457278,3395	5072873,548
11013	3	239,16	6,869	3,783	1,816	3	0,9872	0,0000	0,0076	0,0022	0,9902	0,9924	2,9825	464601,1485	5076355,099
3884	8	723,32	6,056	2,169	2,792	3	0,9976	0,0000	0,0044	0,0102	0,9854	0,9956	2,9810	456905,9088	5072171,928
4037	3	159	10,332	4,812	2,147	3	0,9748	0,0000	0,0069	0,0084	0,9847	0,9931	2,9777	457496,9732	5073257,353
4206	4	228,9	9,569	3,879	2,467	3	0,9569	0,0000	0,0122	0,0007	0,9871	0,9878	2,9749	460947,0232	5075077,166
5139	7	707,97	5,414	2,189	2,473	3	0,9773	0,0000	0,0115	0,0023	0,9862	0,9885	2,9746	458124,7253	5073407,999
3413	4	220,35	9,940	3,964	2,507	3	0,9332	0,0000	0,0146	0,0007	0,9847	0,9854	2,9701	460971,0899	5075076,814
6175	8	510	8,589	2,546	3,373	3	0,9909	0,0000	0,0148	0,0009	0,9843	0,9852	2,9696	456902,0852	5072230,515
5120	6	809,16	4,060	2,066	1,965	3	0,9813	0,0000	0,0146	0,0037	0,9817	0,9854	2,9671	459655,692	5073531,559
5430	5	334,83	8,177	3,147	2,598	3	0,9884	0,0103	0,0034	0,0016	0,9848	0,9863	2,9608	461675,4724	5073651,383
3866	4	338,16	6,477	3,131	2,069	3	0,8761	0,0000	0,0186	0,0038	0,9776	0,9814	2,9590	456787,92	5070471,932

fid	PN	Q _j	C _R	C _{CR}	C _R /C _{CR}	Predikcija (RF)	P klasa 3 (RF)	P (kalibr.) klasa 0	P (kalibr.) klasa 1	P (kalibr.) klasa 2	P (kalibr.) klasa 3	P _{KR}	I _{HS}	y (HTRS96)	x (HTRS96)
5371	5	367,77	7,445	2,997	2,484	3	0,9741	0,0000	0,0182	0,0131	0,9687	0,9818	2,9505	457919,988	5073413,017
9526	4	327,36	6,691	3,185	2,101	3	0,9594	0,0000	0,0074	0,0365	0,9560	0,9926	2,9486	456822,741	5070372,375
3710	3	278	5,909	3,479	1,699	3	0,9705	0,0000	0,0256	0,0016	0,9728	0,9744	2,9473	453289,242	5072860,733
9098	2	35,4	30,936	13,564	2,281	3	0,9908	0,0175	0,0000	0,0020	0,9804	0,9825	2,9454	465595,3681	5076269,532
5863	2	84,54	12,954	7,238	1,790	3	0,9896	0,0137	0,0069	0,0014	0,9780	0,9794	2,9437	460836,858	5074442,301
5236	3	185,58	8,852	4,384	2,019	3	0,9925	0,0133	0,0082	0,0010	0,9774	0,9784	2,9425	457816,8312	5073583,951
5367	5	426,63	6,417	2,779	2,310	3	0,9936	0,0131	0,0081	0,0046	0,9742	0,9788	2,9400	459650,2219	5073640,858
5153	5	352,59	7,765	3,063	2,535	3	0,8976	0,0000	0,0202	0,0199	0,9600	0,9798	2,9398	457907,2642	5073412,169
11342	2	99,36	11,022	6,495	1,697	3	0,9706	0,0138	0,0101	0,0002	0,9759	0,9761	2,9382	465358,6854	5076302,045
11343	2	97,26	11,260	6,587	1,709	3	0,9756	0,0242	0,0110	0,0002	0,9646	0,9648	2,9053	465357,4924	5076294,339
9081	2	40,11	27,303	12,342	2,212	3	0,9858	0,0361	0,0000	0,0014	0,9624	0,9639	2,8901	465564,2842	5076291,321
5216	3	207,04	7,934	4,110	1,930	3	0,9883	0,0355	0,0033	0,0014	0,9597	0,9611	2,8853	457982,1553	5073693,428
3623	8	632,97	6,921	2,302	3,006	3	0,9711	0,0000	0,0387	0,0387	0,9226	0,9613	2,8839	457188,5687	5072802,735
3858	7	1058,61	3,621	1,850	1,957	3	0,9847	0,0158	0,0296	0,0121	0,9424	0,9545	2,8811	457285,5994	5072857,494
5571	3	175,95	9,336	4,526	2,063	3	0,9796	0,0368	0,0049	0,0004	0,9579	0,9583	2,8794	457843,2092	5073600,277
2356	2	15,96	68,618	25,523	2,689	3	0,9847	0,0420	0,0000	0,0044	0,9536	0,9580	2,8696	455947,4865	5068269,046
5429	5	308,64	8,871	3,287	2,699	3	0,9840	0,0413	0,0035	0,0037	0,9516	0,9552	2,8656	461688,2469	5073605,193
3667	4	270,27	8,104	3,533	2,294	3	0,9695	0,0272	0,0206	0,0127	0,9395	0,9522	2,8645	454597,3682	5073159,923
3808	4	333,66	6,564	3,153	2,082	3	0,9701	0,0245	0,0263	0,0242	0,9250	0,9493	2,8498	456758,4142	5070468,914
3764	3	226,02	7,268	3,907	1,860	3	0,9697	0,0259	0,0301	0,0195	0,9245	0,9440	2,8426	454643,6906	5073149,726
5971	3	167,28	9,820	4,666	2,105	3	0,9924	0,0480	0,0090	0,0009	0,9421	0,9430	2,8372	457872,4799	5073620,217
615	2	12,42	88,176	31,444	2,804	3	0,9856	0,0507	0,0000	0,0109	0,9384	0,9493	2,8370	455915,9842	5068215,277
11351	2	104,25	10,505	6,292	1,670	3	0,9812	0,0496	0,0069	0,0017	0,9419	0,9436	2,8359	465367,2509	5076390,287
5408	4	260,64	8,404	3,605	2,331	3	0,6670	0,0000	0,0462	0,0757	0,8781	0,9538	2,8318	457804,1099	5073414,036

Prilog 13. Usporedba značajnosti varijabli na temelju srednjeg smanjenja Gini nečistoće i globalnih SHAP vrijednosti

Poredak (SHAP)	Varijabla	SHAP značajnost	Poredak (GINI)	GINI udio	Razlika u poretku (značajsnosti)
1	DZS_MO_Gust_st-km2	0,057272	3	0,0967	+2
2	OSM_road_COUNT	0,043246	2	0,1008	0
3	OSM_road_LENGTH	0,039208	6	0,0819	+3
4	OSM_junctionCount_weighted	0,020787	7	0,053	+3
5	2019-2022_U-R	0,018759	5	0,0842	0
6	2019-2022_tot_trips_sum	0,017986	4	0,0922	-2
7	OSM_crossing	0,017493	10	0,0429	+3
8	Qj	0,016901	1	0,1023	-7
9	bicInfra_COUNT	0,013328	13	0,0277	+4
10	ZG_uporaba_StamMjes_pc	0,011721	9	0,043	-1
11	ZG_uporaba_PoljpVodeSume_pc	0,011277	11	0,0407	0
12	DZS_MO_Ukupno	0,011231	8	0,0463	-4
13	ZG_uporaba_JavnDrus_pc	0,011182	12	0,0291	-1
14	bicInfra_LENGTH	0,008645	14	0,0256	0
15	ZG_uporaba_JavnZeZeSprt_pc	0,007615	17	0,0197	+2
16	bic-road_infraRatio	0,007506	16	0,0222	0
17	ZG_uporaba_Gosp_pc	0,005622	15	0,0227	-2
18	OSM_trafficSignal	0,002268	18	0,0128	0
19	ZG_tramStajaliste	0,002137	19	0,0076	0
20	bicInfra_kategorija_id_num_0	0,001711	25	0,004	+5
21	bicInfra_kategorija_id_num_1	0,00164	24	0,0041	+3
22	OSM_road_type_num_4	0,001194	21	0,0053	-1
23	OSM_leg	0,001143	22	0,0051	-1
24	OSM_road_type_num_3	0,001049	23	0,0044	-1
25	ZG_busStajaliste	0,000951	20	0,0059	-5

Poredak (SHAP)	Varijabla	SHAP značajnost	Poredak (GINI)	GINI udio	Razlika u poretku (značajsnosti)
26	OSM_road_type_num_2	0,000755	27	0,003	+1
27	ZG_uporaba_dominantno_num_1.0	0,000742	26	0,0031	-1
28	ZG_uporaba_dominantno_num_2.0	0,000509	30	0,0016	+2
29	OSM_BP	0,000387	28	0,0026	-1
30	OSM_road_type_num_5	0,000262	33	0,0012	+3
31	ZG_uporaba_dominantno_num_3.0	0,00025	31	0,0013	0
32	ZG_javniParkingBic	0,000225	29	0,0019	-3
33	ZG_uporaba_dominantno_num_4.0	0,000192	32	0,0013	-1
34	bicInfra_kategorija_id_num_3	0,000113	36	0,0004	+2
35	ZG_osnovnaSkola	0,000061	38	0,0004	+3
36	ZG_uporaba_dominantno_num_5.0	0,000055	35	0,0006	-1
37	OSM_road_type_num_7	0,000048	34	0,0006	-3
38	OSM_road_type_num_6	0,000038	41	0,0002	+3
39	ZG_uporaba_dominantno_num_6.0	0,000029	39	0,0003	0
40	ZG_srednjaSkola	0,000023	37	0,0004	-3
41	ZG_sustavJavniBic	0,000012	40	0,0002	-1
42	ZG_visokaSkola	0,000008	44	0,0001	+2
43	OSM_road_type_num_9	0,000006	42	0,0002	-1
44	bicInfra_kategorija_id_num_4	0,000003	43	0,0001	-1
45	OSM_road_type_num_8	0,000001	48	0,00000	+3
46	OSM_road_type_num_1	0	45	0,0001	-1
47	bicInfra_kategorija_id_num_2	0	49	0	+2
48	bicInfra_kategorija_id_num_5	0	46	0	-2
49	ZG_uporaba_dominantno_num_nan	0	47	0	-2

ŽIVOTOPIS