

УНИВЕРЗИТЕТ У БЕОГРАДУ  
САОБРАЋАЈНИ ФАКУЛТЕТ

Сретен Г. Јевремовић

**Моделовање, предикција и управљање  
ризиком у друмском саобраћају применом  
метода рачунарске интелигенције**

Докторска дисертација

Београд, 2026. година

UNIVERSITY OF BELGRADE  
FACULTY OF TRANSPORT AND TRAFFIC ENGINEERING

Sreten G. Jevremović

**Modeling, prediction and risk management in  
road traffic using computational intelligence  
methods**

Doctoral Dissertation

Belgrade, 2026

**Ментор:**

**Др Милица Шелмић**, редовни професор  
Универзитет у Београду, Саобраћајни факултет

**Чланови комисије:**

**Др Милош Николић**, редовни професор  
Универзитет у Београду, Саобраћајни факултет

**Др Борис Антић**, редовни професор  
Универзитет у Београду, Саобраћајни факултет

**Др Александра Коларски**, виши научни сарадник  
Универзитет у Београду, Институт за физику

Датум одбране: \_\_\_\_\_

## ЗАХВАЛНИЦА

Приказана тема докторске дисертације под називом *Моделовање, предикција и управљање ризиком у друмском саобраћају применом метода рачунарске интелигенције* представља мултидисциплинарни резултат моје сарадње са професорима са Катедре за Операциона истраживања у саобраћају и Катедре за безбедност друмског саобраћаја Саобраћајног факултета Универзитета у Београду, као и истраживача из Лабораторије за астрофизику и физику јоносфере Института за физику у Београду Универзитета у Београду.

Докторска дисертација обухвата више области, те аутор посебно захваљује:

- менторки проф. др Милице Шелмић, на разумевању, корисним саветима и менторству током израде докторске дисертације;
- др Филипу Арнауту, на корисним саветима и сугестијама током израде докторске дисертације, а у вези са поглављем које се односи на екстратерестричке утицаје на настанак саобраћајних незгода са животињама;
- члановима комисије, на корисним сугестијама и саветима током реализације докторске дисертације, који су значајно допринели њеном квалитету;
- Катедри за друмске саобраћајнице и Катедри за теорију саобраћајног тока и капацитет друмских саобраћајница Саобраћајног факултета Универзитета у Београду, на стручној подршци, корисним сугестијама и доприносу унапређењу квалитета ове докторске дисертације;
- Јавном предузећу „Путеви Србије”, а посебно колегама Марији Дото, Милошу Милосављевићу и Ивани Куљанин на уступању великог сета података о карактеристикама пута, коришћених у овој докторској дисертацији;
- др Александру Медаревићу, на великој подршци, помоћи и сарадњи током израде првог важног поглавља докторске дисертације, које се односи на глобално оптерећење болестима.

Такође, захваљујем на могућности да користим информације организација, предузећа и мрежа отворених података, а то су Агенција за безбедност саобраћаја Републике Србије, Министарство унутрашњих послова Републике Србије, пројекат Global Burden of Disease и платформе Open Data Hub, Meteogram и OpenStreetMaps.

Посебну и најдубљу захвалност дугујем својој породици, која ми је током читавог процеса израде докторске дисертације пружала безрезервну подршку, разумевање и снагу. Њихова подршка је била моја највећа мотивација и темељ на којем почива овај рад, који сматрам и њиховим успехом.

## РЕЗИМЕ

У докторској дисертацији је дато свеобухватно истраживање, чији је циљ развој и примена метода рачунарске интелигенције за класификацију критичних локација (опасних места) и предикцију саобраћајних незгода у Републици Србији, уз процену терета саобраћајних повреда (процену година изгубљеног живота, година живота са инвалидитетом итд.), насталих као последица саобраћајних незгода. Истраживање је обухватило широк спектар података: од јавноздравствених и просторних до саобраћајно-корисничких и временских, у оквиру којих су примењене комбинације техника машинског учења, рачунарске интелигенције, пре свега вештачких неуронских мрежа и фази логике, статистике и геоаналитичких метода како би се добили применљиви и интерпретабилни модели за подршку доношењу одлука у области саобраћајних политика.

Први део докторске дисертације обухвата примену методологије Глобалног терета болести (енг. *Global Burden of Disease, GBD*), на основу које је анализирано оптерећење становништва Србије због повреда у саобраћају за период од 2002. до 2024. године. Коришћени су званични подаци о морталитету и повредама, који су агрегирани по старосним групама и регионима. Израчунавањем индикатора године изгубљеног живота (енг. *Years of Life Lost, YLL*), године живота са инвалидитетом (енг. *Years Lived with Disability, YLD*) и укупног броја изгубљених година здравог живота (енг. *Disability-Adjusted Life Year, DALY*), указано је на смањење YLL-a на територији Србије након 2009. године, али и на пораст YLD-a у Војводини и централној Србији, што указује на потребу за регионализованим мерама рехабилитације и превенције.

У оквиру другог дела докторске дисертације представљен је методолошки поступак за идентификацију и категоризацију опасних места у Србији, применом кластер анализе и методе типизације, као и фази логике. Уместо класичних методологија, уведен је модел који интегрише изложеност, геометрију пута и тежину последица. На основу тих параметара формиране су категорије опасних места, од којих највећи број у Србији припада категоријама експлозивних и тихих локација. Ово су уједно и најопасније категорије опасних места.

У трећем делу докторске дисертације приказан је развијени модел предикције броја незгода на ванградским путевима ИБ реда у Србији. Коришћени су подаци о просечном годишњем дневном саобраћају, просечној брзини, геометријским елементима (ширина траке, радијус кривина итд.) и стању пута, као и додатне изведене променљиве. Израђени су различити модели и тестиране технике попут RandomForest-a, XGBoost-a, AdaBoost-a, вештачких неуронских мрежа и CatBoost-a, који се уједно показао као најефикаснији модел. Применом модификованог CatBoost модела и SHAP (енг. *SHapley Additive exPlanations*) анализе добијен је коефицијент детерминације  $R^2$  од 79%.

Четврти део даје приказ модела временских серија и машинског учења за предикцију броја незгода по сату за различите категорије возила (аутомобили, теретна возила, мотоцикли, аутобуси, бицикли) и врсте незгода (повређени, погинули, материјална штета), посебно за градску и ванградску мрежу у Србији. Модели су тренирани на подацима од 2016. до 2023.

године, а тестирани на подацима из 2024. године. SARIMA (енг. *Seasonal Autoregressive Integrated Moving Average*) и CatBoost модели дали су просечан коефицијент детерминације  $R^2$  од 93%.

У оквиру петог поглавља анализиран је утицај лунарних фаза Месеца на незгоде са животињама у Србији. Анализирано је 2767 незгода са животињама које су се догодиле током ноћи. Резултати показују статистички значајан пораст незгода овог типа током фазе пуног Месеца у односу на остале фазне периоде ( $p = 0,042$ ; Cohen's  $d = 1,05$ ). Просторном анализом идентификовани су Јужнобачки и Подунавски округ као најризичније области. У оквиру овог истраживања израђен је и модел предикције саобраћајних незгода са животињама, трениран и тестиран на подацима од 2016. до 2024. године. Коришћен је модификован CatBoost модел којим је постигнут коефицијент детерминације  $R^2$  од 81% у предикцији незгода по сату.

Резултати дисертације показују да интеграција метода машинског учења, рачунарске интелигенције, пре свега вештачких неуронских мрежа и фази логике, као и статистике и геопросторних анализа, пружа снажан и флексибилан оквир за процену ризика, просторну категоризацију и предикцију ретких и комплексних догађаја у транспортним системима. Иако је примарно примењен на саобраћај у Србији, развијени методолошки оквир има потенцијал за широку примену у другим областима, где је потребно интегрисати хетерогене податке и подржати проактивно управљање ризицима.

**Кључне речи:** предикција саобраћајних незгода, опасна места, временске серије, године изгубљеног живота (енг. *Years of Life Lost, YLL*), године живота са инвалидитетом (енг. *Years Lived with Disability, YLD*), године изгубљеног здравог живота (енг. *Disability-Adjusted Life Year, DALY*), машинско учење, вештачке неуронске мреже, фази логика, незгоде са животињама, просторна анализа.

**Научна област:** Саобраћај

**Ужа научна област:** Операциона истраживања у саобраћају

**УДК број:**

**ABSTRACT**

The doctoral dissertation presents comprehensive research aimed at developing and applying Computational Intelligence models to classify critical locations (dangerous locations), and predicting traffic accidents in the Republic of Serbia, with focus on assessing the burden of road traffic injuries (i.e., estimating Years of Life Lost, Years Lived with Disability, and related indicators). The research integrates a broad spectrum of data sources, ranging from public health and spatial datasets to traffic, behavioral, and meteorological variables, and applies a combination of Machine Learning and Computational Intelligence techniques, including Artificial Neural Networks, and Fuzzy Logic, along with statistical and geo-analytical methods, to produce applicable and interpretable models for evidence-based decision support in traffic safety policy.

The first part of the dissertation applies the Global Burden of Disease methodology to analyze the population-level burden of road traffic injuries in Serbia from 2002 to 2024. Official mortality and injury data, disaggregated by age group, and region, were used to calculate the indicators Years of Life Lost (YLL), Years Lived with Disability (YLD), and Disability-Adjusted Life Years (DALY). The results show that the decrease in YLL has been observed across Serbia after 2009, accompanied by an increase in YLD in Vojvodina and Central Serbia, highlighting the need for regionally targeted rehabilitation and prevention measures.

The second part introduces a methodological framework for the identification and categorization of dangerous locations in Serbia through cluster analysis, typification methods, and Fuzzy Logic, representing an integrated Computational Intelligence approach for network-based safety analysis. Instead of conventional methods, the proposed model combines exposure, road geometry, and crash severity to define dangerous locations categories. The results indicate that all locations in Serbia belong to the “explosive” and “silent” categories, which also represent the most hazardous types of locations.

The third part presents an accident prediction model for IB rural roads in Serbia. The model incorporates data on Annual Average Daily Traffic, average speed, road geometry (lane width, curve radius, etc.), and pavement condition, along with several derived variables. Various models such as: Random Forest, XGBoost, AdaBoost, Artificial Neural Networks, CatBoost etc., were developed and tested, with CatBoost demonstrating the highest performance. Using a modified CatBoost model coupled with SHAP analysis, the model achieved a coefficient of determination ( $R^2$ ) of 79%.

The fourth part focuses on time-series and machine learning models for hourly accident prediction, disaggregated by vehicle category (passenger cars, trucks, motorcycles, buses, bicycles) and accident type (injury, fatal, property damage), for both urban and rural networks in Serbia. The models were trained on data from 2016–2023 and tested on 2024 data. The SARIMA and CatBoost models achieved an average  $R^2$  of 93%, indicating strong predictive accuracy.

The fifth part investigates the influence of lunar phases on wildlife-vehicle collisions (WVCs) in Serbia. A total of 2,767 nighttime WVCs were analyzed. The results revealed a statistically significant increase in the number of such collisions during the full moon phase compared to other lunar periods ( $p = 0.042$ ; Cohen’s  $d = 1.05$ ). Spatial analysis identified the South Bačka and

Podunavlje districts as the most at-risk areas. A predictive model for WVCs was also developed using a modified CatBoost algorithm trained and tested on the 2016. to 2024. accident data, achieving an  $R^2$  of 81% for hourly-level prediction.

The findings of the dissertation demonstrate that the integration of Machine Learning, Computational Intelligence methods: Artificial Neural Networks, and Fuzzy Logic, together with statistics and geospatial analytics, provides a robust and flexible framework for risk assessment, spatial categorization, and prediction of rare and complex events in transportation systems. Although primarily applied to traffic safety in Serbia, the proposed methodological framework has broad applicability in other domains that require the integration of heterogeneous datasets and proactive risk management.

**Key words:** Prediction of traffic accidents, dangerous locations, time series, Years of Life Lost (YLL), Years Lived with Disability (YLD), Disability-Adjusted Life Years (DALY), machine learning, Artificial Neural Networks (ANN), Fuzzy Logic, Wildlife-Vehicle Collisions (WVCs), spatial analysis.

**Scientific field:** Traffic engineering

**Scientific subfield:** Operational research in transport

**UDC number:**

**САДРЖАЈ**

УВОДНА РАЗМАТРАЊА .....	1
1.1    Мотивација .....	1
1.2    Предмет и циљ истраживања .....	4
1.3    Полазне хипотезе .....	5
1.4    Организација – садржај дисертације .....	6
ПРЕГЛЕД КОРИШЋЕНИХ МЕТОДА .....	8
2.1    Фази логика .....	8
2.2    Вештачке неуронске мреже .....	10
2.3    Стабло одлучивања .....	12
2.4    Ансамбл технике засноване на дрвећу .....	13
2.5    Модел временских серија .....	15
2.6    Анализа главних компоненти .....	16
ПРИМЕНА КОНЦЕПТА ГЛОБАЛНОГ ОПТЕРЕЋЕЊА БОЛЕСТИМА У ДОМЕНУ САОБРАЋАЈА У СРБИЈИ .....	18
3.1    Опис проблема .....	18
3.2    Преглед најважнијих истраживања у области примене методологије глобалног оптерећења болестима у домену саобраћаја .....	19
3.3    Методологија истраживања за потребе примене концепта глобалног оптерећења болестима у домену саобраћаја у Србији .....	20
3.4    Резултати примене концепта глобалног оптерећења болестима у домену саобраћаја у Србији, за период од 2002. год 2024. године .....	22
3.4.1    Лонгитудинална анализа индикатора друштвеног терета у Србији .....	23
3.4.2    Анализа индикатора друштвеног терета по регионима у Србији .....	28
3.4.3    Поређење индикатора друштвеног терета Србије са осталим земљама света и позиција Србије на глобалном плану .....	35
3.5    Дискусија резултата добијених применом методологије глобалног оптерећења болестима у домену саобраћаја у Србији за период од 2002. до 2024. године .....	41
.....	43
РАЗВОЈ МЕТОДОЛОГИЈЕ ЗА КАТЕГОРИЗАЦИЈУ ОПАСНИХ МЕСТА НА ПУТЕВИМА ІБ РЕДА .....	43
4.1    Опис проблема .....	43
4.2    Приказ најзначајнијих истраживања у области дефинисања и анализе опасних места на саобраћајној мрежи .....	44
4.3    Методологија истраживања за потребе категоризације опасних места на саобраћајној мрежи ІБ реда у Србији .....	48

4.3.1	Подручје истраживања и извори података.....	48
4.3.2	Алати и софтвери .....	50
4.3.3	Идентификација опасних места.....	51
4.3.4	Тестирање статистичке значајности идентификованих опасних места .....	51
4.3.5	Фази категоризација.....	52
4.3.6	Валидација и унапређење израђеног фази модела.....	53
4.4	Резултати развоја методологије за категоризацију опасних места на државним путевима ИБ реда у Србији, за период од 2021. до 2023. године.....	55
4.4.1	Основне карактеристике улазних података .....	55
4.4.2	Идентификација и валидација опасних места у Србији.....	56
4.4.3	Фази категоризација опасних места у Србији.....	61
4.4.4	Примена предложене фази категоризације.....	74
4.4.5	Валидација израђеног фази система.....	78
4.5	Дискусија резултата добијених применом методологије за категоризацију опасних места на државним путевима ИБ реда у Србији .....	82
ИЗРАДА МОДЕЛА ПРЕДИКЦИЈЕ САОБРАЋАЈНИХ НЕЗГОДА ЗА МРЕЖУ ИБ РЕДА У СРБИЈИ .....		85
5.1	Опис проблема .....	85
5.2	Преглед релевантних истраживања за предикцију саобраћајних незгода.....	87
5.3	Методологија истраживања за потребе израде модела предикције саобраћајних незгода по километру пута на подручју Србије .....	88
5.4	Резултати израде модела предикције саобраћајних незгода за путну мрежу ИБ реда у Србији за период од 2021. до 2023. године.....	92
5.4.1	Основне карактеристике деоница.....	92
5.4.2	Развој модела предикције саобраћајних незгода за подручје Србије.....	93
5.4.3	Израда и тестирање модела предикције саобраћајних незгода применом вештачких неуронских мрежа.....	99
5.5	Дискусија резултата добијених применом модела предикције саобраћајних незгода за путну мрежу ИБ реда у Србији за период од 2021. до 2023. године.....	107
РАЗВОЈ МОДЕЛА ВРЕМЕНСКИХ СЕРИЈА ЗА ПРЕДИКЦИЈУ САОБРАЋАЈНИХ НЕЗГОДА....		109
.....		109
6.1	Опис проблема .....	109
6.2	Преглед релевантних истраживања у области развоја модела временских серија за предикцију саобраћајних незгода у Србији.....	110
6.3	Методологија истраживања за потребе израде модела временских серија за предикцију саобраћајних незгода на подручју Србије.....	111

6.4	Резултати развоја модела временских серија за предикцију саобраћајних незгода на подручју Србије за период од 1997. до 2024. године .....	113
6.4.1	Опште карактеристике улазних података .....	113
6.4.2	Предикција незгода по врсти на подручју Србије у анализираном периоду .....	117
6.4.3	Предикција незгода по типу учесника у зависности од категорије мреже у Србији за анализирани период .....	119
6.5	Дискусија резултата добијених применом модела временских серија за предикцију саобраћајних незгода у Србији за период од 1997. до 2024. године.....	124
АНАЛИЗА ЕКСТРАТЕРЕСТРИЧКИХ УТИЦАЈА НА ПОЈАВУ НЕЗГОДА СА ЖИВОТИЊАМА У СРБИЈИ .....		126
7.1	Опис проблема .....	126
7.2	Преглед релевантних истраживања у области екстратерестричких утицаја на настанак саобраћајних незгода са животињама .....	127
7.3	Методологија истраживања за потребе анализе екстратерестричких утицаја на настанак саобраћајних незгода са животињама у Србији .....	128
7.3.1	Статистичке поставке, тестови и алати.....	130
7.3.2	Методолошке поставке за потребе израде модела предикције саобраћајних незгода са животињама на подручју Србије за период од 2016. до 2024. године.....	131
7.4	Резултати анализе екстратерестричких утицаја на појаву саобраћајних незгода са животињама у Србији, за период од 2015. до 2023. године .....	131
7.5	Дискусија резултата добијених на основу анализе екстратерестричких утицаја на појаву саобраћајних незгода са животињама у Србији за период од 2015. до 2023. године.....	140
ЗАКЉУЧАК .....		143
Литература .....		149
Биографија аутора .....		172
Изјава о ауторству .....		173
Изјава о истовестности штампане и електронске верзије докторског рада .....		174
Изјава о коришћењу .....		175

## СПИСАК ТАБЕЛА

<b>Табела 1.</b> Категоризација узрока смрти/повреде према типу возила у Србији, формирана према методологији GBD-а .....	22
<b>Табела 2.</b> Преглед изабраних дефиниција и карактеристика опасних места (Šarić et al., 2016; Aziz and Ram, 2022; Karamanlis et al., 2023).....	47
<b>Табела 3.</b> Опште карактеристике анализиране мреже ванградских путева у Србији .....	49
<b>Табела 4.</b> Дужина путне мреже и број незгода у Србији .....	49
<b>Табела 5.</b> Предложена категоризација опасних места и њихове карактеристике .....	52
<b>Табела 6.</b> Карактеристике анализираних деоница државних путева IБ реда у Србији .....	56
<b>Табела 7.</b> Карактеристике опасних места након њихове идентификације.....	60
<b>Табела 8.</b> Функције припадности фази бројева за улазну променљиву Квалитет коловоза.....	64
<b>Табела 9.</b> Функције припадности фази бројева за улазну променљиву Изложеност.....	66
<b>Табела 10.</b> Функције припадности фази бројева за улазну променљиву Тежина саобраћајних незгода.....	69
<b>Табела 11.</b> Функције припадности фази бројева за излазну променљиву Категорија опасног места .....	70
<b>Табела 12.</b> Фази правила у оквиру првог фазилогичког система.....	72
<b>Табела 13.</b> Првих десет фази правила другог фазилогичког система .....	73
<b>Табела 14.</b> Фази правила трећег фазилогичког система .....	74
<b>Табела 15.</b> Резултати након дефазификације променљиве и степени припадности за опасна места .....	76
<b>Табела 16.</b> Детаљи и карактеристике опасних места .....	77
<b>Табела 17.</b> Преклапање суседних функција припадности .....	81
<b>Табела 18.</b> Карактеристике деоница путева IБ реда анализираних у докторској дисертацији .....	92
<b>Табела 19.</b> Расподела незгода по врсти на државним путевима IБ реда у Србији .....	93
<b>Табела 20.</b> Резултати тестирања CatBoost алгорита за предикцију саобраћајних незгода.....	98
<b>Табела 21.</b> Сумарни приказ карактеристика и резултата израђених алгоритама ANN.....	106
<b>Табела 22.</b> Сумарни резултати модела предикције по врсти незгода за 2024. годину у Србији.....	119
<b>Табела 23.</b> Сумарни резултати модела предикције по типу мреже и врсти учесника у саобраћајним незгодама за 2024. годину у Србији .....	123
<b>Табела 24.</b> Годишња, процентуална расподела незгода са животињама, по врсти у Србији .....	131
<b>Табела 25.</b> Годишња расподела незгода са животињама током специфичних периода у Србији ...	133
<b>Табела 26.</b> Просечан годишњи број НЖ <sub>пм</sub> и НЖ <sub>од</sub> за анализирани период у Србији.....	134

## СПИСАК СЛИКА

Слика 1. Пример фази функција припадности за брзину возила .....	9
Слика 2. Графичка интерпретација дисјунктивног система правила (Teodorović and Šelmić, 2019).....	9
Слика 3. Процесни елемент: вештачки неурон и активациона функција (Teodorović and Šelmić, 2019).....	10
Слика 4. Тренирање вишеслојног перцептрона: простирање сигнала унапред и простирање израчунате грешке уназад (Teodorović and Šelmić, 2019).....	11
Слика 5. Адалине са више излазних неурона.....	12
Слика 6. Временске промене стопа а) смртности и б) повреда у Србији за период 2002–2024.....	24
Слика 7. Промене параметара а) YLL и б) YLD у Србији за период 2002–2024.....	25
Слика 8. Промене индикатора DALY у Србији за период 2002–2024.....	26
Слика 9. Трендови стандардизованих показатеља YLL, YLD и DALY у периоду 2006–2012, са освртом на усвајање Закона о безбедности саобраћаја на путевима (2009).....	27
Слика 10. Трендови стандардизованих показатеља YLL, YLD и DALY у периоду 2012–2018, са освртом на усвајање Националне стратегије безбедности саобраћаја (2015–2020).....	28
Слика 11. Број погинулих на 100.000 становника по регионима Србије.....	29
Слика 12. Број повређених на 100.000 становника по регионима Србије.....	30
Слика 13. YLL индикатор на 100.000 становника по регионима Србије.....	32
Слика 14. YLD индикатор на 100.000 становника по регионима Србије.....	33
Слика 15. DALY индикатор на 100.000 становника по регионима Србије.....	34
Слика 16. Упоредна анализа земаља према YLD индикатору за 2022. годину.....	36
Слика 17. Упоредна анализа земаља према DALY индикатору за 2022. годину.....	37
Слика 18. Поређење земаља према YLD индикатору за старосну категорију 15–49 година, за 2022. годину.....	39
Слика 19. Поређење земаља према DALY индикатору за старосну категорију 15–49 година, за 2022. годину.....	40
Слика 20. Државни путеви IB реда у Србији анализирани у овој докторској дисертацији (мрежа путева у складу са референтним системом из 2025. године).....	48
Слика 21. Улазни подаци коришћени за категоризацију опасних места у Србији.....	50
Слика 22. Кораци алгоритма у оквиру израђене методологије за категоризацију опасних места...	51
Слика 23. Незгоде груписане на деоници пута краћој од 1 km, са међусобним растојањем од највише 250 m.....	57
Слика 24. Незгоде груписане на деоници пута дужој од 1 km, са међусобним растојањем од 150 m.....	58
Слика 25. Варијабилност опасних места у времену, за подручје Србије.....	61
Слика 26. Фазилогички систем за категоризацију опасних места.....	62
Слика 27. Дистрибуција вредности променљивих: а) ширина траке, б) ири, в) радијус, г) вертикални нагиб, д) ПГДС, њ) брзина, е) % прекорачења, ж) % прекорачења за више од 20 km/h и назначени 25, 50. и 75. перцентил.....	63
Слика 28. Функције припадности улазних променљивих: а) ширина траке, б) храпавост коловоза, с) радијус хоризонталне кривине, д) уздужни нагиб.....	64
Слика 29. Функција припадности излазне променљиве Квалитет.....	66
Слика 30. Функције припадности улазних променљивих: а) ПГДС, б) брзина, с) проценат прекорачења, д) проценат прекорачења >20 km/h.....	67
Слика 31. Функција припадности излазне променљиве Изложеност:.....	69
Слика 32. Функција припадности улазне променљиве Тежина саобраћајних незгода.....	70

<b>Слика 33.</b> Функција припадности излазне променљиве Категорија опасног места.....	71
<b>Слика 34.</b> Пример првог фазилогичког система (Квалитет коловоза) у Matlab-у.....	74
<b>Слика 35.</b> Пример другог фазилогичког система (Изложеност) у Matlab-у.....	75
<b>Слика 36.</b> Пример трећег фазилогичког система (Категорија опасног места) у Matlab-у.....	75
<b>Слика 37.</b> Оригиналне и оптимизоване функције припадности за фази систем Квалитет.....	79
<b>Слика 38.</b> Оригиналне и оптимизоване функције припадности за фази систем Изложеност.....	80
<b>Слика 39.</b> Оригиналне и оптимизоване функције припадности за фази број Тежина саобраћајних незгода.....	80
<b>Слика 40.</b> Стабилност функција припадности по променљивама.....	81
<b>Слика 41.</b> Примарне променљиве коришћене у изради модела предикције саобраћајних незгода за државне путеве IB реда у Србији.....	89
<b>Слика 42.</b> Кораци за припрему, анализу података и развој модела предикције саобраћајних незгода за државне путеве IB реда у Србији.....	91
<b>Слика 43.</b> Утицај променљивих на предвиђени ризик од настанка саобраћајне незгоде.....	95
<b>Слика 44.</b> Рангирање важности улазних променљивих за израду модела предикције.....	95
<b>Слика 45.</b> Корелациона матрица зависности улазних променљивих.....	96
<b>Слика 46.</b> Компарација изабраних алгоритама за предикцију саобраћајних незгода у Србији.....	97
<b>Слика 47.</b> Резултат дијаграма а) предвиђен у односу на стварни број незгода по km, б) расподела остатака.....	99
<b>Слика 48.</b> Кораци у развоју и тестирању ANN.....	100
<b>Слика 49.</b> Резултати првог алгоритма ANN за расподелу 90-5-5: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру.....	102
<b>Слика 50.</b> Резултати другог алгоритма ANN за расподелу 80-10-10: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру.....	103
<b>Слика 51.</b> Резултати трећег алгоритма ANN за расподелу 75-15-10: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру.....	103
<b>Слика 52.</b> Резултати четвртог алгоритма ANN за расподелу 70-15-15: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру.....	104
<b>Слика 53.</b> Резултати петог алгоритма ANN за расподелу 60-20-20: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру.....	105
<b>Слика 54.</b> Архитектура вештачке неуронске мреже која је постигла најбоље резултате (75-15-10 модел).....	106
<b>Слика 55.</b> Годишњи број незгода према врсти: а) незгоде са погинулима, б) незгоде са повређенима, в) незгоде са материјалном штетом, г) укупан број незгода у Србији.....	113
<b>Слика 56.</b> Расподела незгода по сатима у току дана, за подручје Србије.....	114
<b>Слика 57.</b> Годишња расподела броја незгода по типу учесника – незгоде са: а) бициклистима, б) мотоциклистима, в) аутомобилима, г) аутобусима, д) теретним возилима, њ) видовна расподела на градској и ванградској мрежи.....	115
<b>Слика 58.</b> Часовна расподела незгода по типу учесника – незгоде са: а) бициклистима, б) мотоциклистима, в) аутомобилима, г) аутобусима, д) теретним возилима, њ) видовна расподела на градској и ванградској мрежи.....	116
<b>Слика 59.</b> Стваран и предвиђен укупан број незгода по сатима у току дана за 2024. годину у Србији.....	117
<b>Слика 60.</b> Стваран и предвиђен број незгода са материјалном штетом по сатима у току дана за 2024. годину.....	118
<b>Слика 61.</b> Стваран и предвиђен број незгода са повређенима по сатима у току дана за 2024. годину у Србији.....	118

<b>Слика 62.</b> Стваран и предвиђен број незгода са погинулима по сатима у току дана за 2024. годину у Србији .....	119
<b>Слика 63.</b> Стваран и предвиђен број незгода са бициклистима на градској мрежи за 2024. годину у Србији .....	120
<b>Слика 64.</b> Стваран и предвиђен број незгода са мотоциклистима на градској мрежи за 2024. годину у Србији .....	120
<b>Слика 65.</b> Стваран и предвиђен број незгода са путничким аутомобилима на градској мрежи за 2024. годину у Србији.....	121
<b>Слика 66.</b> Стваран и предвиђен број незгода са теретним возилима на градској мрежи за 2024. годину у Србији.....	121
<b>Слика 67.</b> Стваран и предвиђен број незгода са аутобусима на градској мрежи за 2024. годину у Србији .....	122
<b>Слика 68.</b> Стваран и предвиђен број незгода са путничким аутомобилима на ванградској мрежи за 2024. годину у Србији.....	122
<b>Слика 69.</b> Стваран и предвиђен број незгода са теретним возилима на ванградској мрежи за 2024. годину у Србији.....	123
<b>Слика 70.</b> Административни региони Републике Србије и дигитални елевациони модел (Eurostat, 2025) .....	129
<b>Слика 71.</b> Месечна а) и часовна б) расподела незгода са животињама, током анализираниог периода, у Србији.....	132
<b>Слика 72.</b> Тестирање нормалности података: а) дијаграм квантила (црвена линија – идеална расподела), б) дијаграм остатака .....	133
<b>Слика 73.</b> Модификовани ризик за административне регионе Републике Србије.....	136
<b>Слика 74.</b> Стваран и предвиђен број незгода са животињама по сату, у Србији, за 2024. годину .	137
<b>Слика 75.</b> Хистограм грешака при предикцији саобраћајних незгода са животињама.....	138
<b>Слика 76.</b> Стваран број незгода са животињама по сату, по години, на подручју Србије.....	139
<b>Слика 77.</b> Излаз из CatBoost модела – број незгода са животињама по сату, по години, на подручју Србије.....	139

**ЛИСТА КОРИШЋЕНИХ СКРАЋЕНИЦА**

AdaBoost	Adaptive Boosting
ADAS	Advanced Driver Assistance Systems
ANN	Artificial Neural Network
ANOVA	Analysis of Variance
ARIMA	Autoregressive Integrated Moving Average
CatBoost	Categorical Boosting
DALY	Disability-Adjusted Life Year
GBD	Global Burden of Disease
GIS	Geographic Information System
IHME	Institute for Health Metrics and Evaluation
IRI	International Roughness Index
JASP	Jeffreys's Amazing Statistics Program
LightGBM	Light Gradient Boosting Machine
MAE	Mean Absolute Error
PCA	Principal Component Analysis
QGIS	Quantum Geographic Information System
RMSE	Root Mean Square Error
SARIMA	Seasonal ARIMA
SHAP	SHapley Additive exPlanations
Std Dev	Standard Deviation
UI	Uncertainty Interval
VMS	Variable Message Sign
WHO	World Health Organization
XGBoost	eXtreme Gradient Boosting
YLD	Years Lived with Disability
YLL	Years of Life Lost
АБС	Аутоматски бројач саобраћаја
ЈР	Јавни ризик
НЖ	Саобраћајне незгоде са животињама
ПГДС	Просечан годишњи дневни саобраћај
ПР	Путни ризик
РП	Ризик пошумљености
СЗО	Светска здравствена организација

---

---

# УВОДНА РАЗМАТРАЊА

---

---



# 1

## 1.1 Мотивација

Савремени саобраћајни систем представља динамичан и комплексан ентитет, чије функционисање зависи од широког спектра међусобно повезаних фактора – од карактеристика инфраструктуре и понашања учесника у саобраћају до временских, амбијенталних и друштвено-економских услова. Управљање овако комплексним системом захтева не само разумевање појединачних утицаја већ и примену методолошких оквира способних да интегришу различите врсте података и обезбеде поуздану основу за доношење одлука. У том контексту, методе рачунарске интелигенције, пре свега вештачке неуронске мреже и фази логика, уз машинско учење, статистичку анализу и примену геоаналитичких техника, пружају снажан алат за квантитативно разумевање, предикцију и оптимизацију саобраћајних процеса.

Саобраћај, са својим кључним параметрима (брзина, проток, густина, капацитет, као и број саобраћајних незгода, број конфликта, трошкови саобраћајних незгода итд.), представља веома сложен систем за чије разумевање и дубинску анализу обично није довољно узети у обзир појединачне утицаје поменутих параметара (*Grđinić-Rakonjac et al., 2021; Antić et al., 2025*) – тек је њиховом интеграцијом у шири оквир и применом савремених метода рачунарске интелигенције могуће развити сложене и транспарентне моделе који истовремено узимају у обзир динамику система, структурне факторе и екстерне утицаје. Такав приступ омогућава доносиоцима одлука да креирају ефикасне, безбедне и одрживе стратегије управљања саобраћајем и транспортом, које превазилазе класичне статистичке анализе и реактивне мере. Међутим, и поред савремених методолошких оквира, последице саобраћајних незгода и даље представљају један од кључних изазова савременог друштва, како са аспекта јавног здравља, тако и са аспекта безбедносног и инфраструктурног управљања (*Gopalakrishnan, 2012*).

Један од кључних предуслова за примену проактивних политика јесте квантификација последица и ризика. У том контексту, глобално оптерећење (терет) болестима (енг. *Global Burden of Disease, GBD*), методологија која се заснива на индикаторима као што су године изгубљеног живота услед преране смрти (енг. *Years of Life Lost, YLL*), године живота са

инвалидитетом (енг. *Years Lived with Disability, YLD*) и укупни број изгубљених година здравог живота (енг. *Disability-Adjusted Life Year, DALY*), омогућава прецизнији увид у реалне, здравствене и друштвене последице незгода. Применом ове методологије на територији Републике Србије, у периоду од 2002. до 2024. године, установљено је да саобраћајне незгоде не представљају само тренутни ризик за појединце укључене у конкретне догађаје већ носе дугорочне импликације по здравствени систем, економију и друштвену продуктивност (*Atanasković-Marković et al., 2002*). Овакви резултати наглашавају потребу за проактивним приступима у планирању и управљању саобраћајем који превазилазе традиционалне оквири анализе „црне” статистике и укључују конкретније разумевање динамике саобраћајног тока и његове интеракције са окружењем.

Након квантификације последица примењене су технике кластер анализе и геопросторног моделирања за идентификацију и категоризацију „опасних места” – критичних локација на саобраћајној мрежи. Додатно, са циљем да се моделирају непрецизни улазни подаци примењена је фази логика, техника која је посебно погодна јер омогућава моделовање и анализу у ситуацијама где су подаци нејасни, делимично одређени или неизвесни. Идентификација и класификација опасних места на саобраћајној мрежи (тзв. опасних места), од суштинске су важности за стратешко планирање и избор адекватних мера превенције. Међутим, у савременој литератури често се запажа да је идентификација ових локација статична и зависи искључиво од броја незгода у одређеном периоду (*Flahaut et al., 2003; Montella, 2010; Ghadi and Török, 2017a*). У дисертацији је први пут развијен и коришћен приступ који комбинује податке о саобраћајном току (брзина, проток и њихови међусобни односи), геометријске карактеристике пута (радијуси кривина, ширине трака, квалитет коловоза и сл.) и врсту незгода (тежина последица) за категоризацију опасних места. На овај начин омогућена је класификација опасних места у функционалне категорије попут експлозивних, тихих и других типова ових локација (како је предложено у оквиру ове докторске дисертације). Такав методолошки оквир представља значајан допринос практичним применама метода рачунарске интелигенције у саобраћају јер омогућава прилагођавање стратегија интервенције специфичним механизмима ризика. Развијена методологија пружа могућности за стандардизацију процедура приликом детектовања ризичних локација и може се примењивати независно од локације, како на националном, тако и на међународном нивоу.

Да би се системом управљало проактивно, потребно је предвидети његово понашање у будућности. У ту сврху развијени су модели предикције броја саобраћајних незгода на државним путевима ИБ реда у Србији, за период од 2021. до 2023. године, којима је обухваћена веома обимна база података и у оквиру које су коришћени софистицирани алгоритми машинског учења – укључујући XGBoost, Random Forest, CatBoost, затим вештачке неуронске мреже (за које је развијено и тестирано 5 модела) и други. Коришћењем улазних променљивих (већ поменуте карактеристике саобраћајног тока и геометрија пута), најефикаснији модел (модификовани CatBoost) остварио је прецизност предикције  $R^2 = 79\%$ . За саобраћајне инжењере и доносиоце одлука овакав модел нуди конкретан алат за идентификацију критичних зона пре него што до проблема дође, омогућавајући адекватно и превентивно стратешко управљање и циљане интервенције.

Додатно, модели временских серија (енг. *Seasonal Autoregressive Integrated Moving Average*, SARIMA и хибридни приступи) примењени су за прогнозу динамике незгода по сату, категоријама возила и врстама последица, са прецизностима које у већини случајева премашују 90%. Ови модели не зависе искључиво од просторне дистрибуције саобраћаја, већ откривају сезонске и трендовске обрасце, што је од суштинске важности за адаптивно управљање системом. На основу података за период од 1997. до 2024. године, израђени су модели који предвиђају број незгода по врстама учесника (пешаци, бициклисти, путнички аутомобили, аутобуси и теретни саобраћај), као и по врсти незгода (број незгода са материјалном штетом, са повређенима, са погинулима и укупан број саобраћајних незгода). Ова анализа представља најкомплетнију временску предикцију до сада урађену у Србији, са прецизностима које у већини дефинисаних модела прелазе 90%. У контексту планирања и доношења одлука, овакав модел има додатну вредност јер не зависи искључиво од просторне дистрибуције саобраћаја, већ омогућава сагледавање сезонских, дневних и дугорочних образаца понашања система, што је од кључног значаја за оперативно управљање саобраћајним системом у различитим периодима током године.

Као допуна класичним аналитичким и моделским приступима, посебну вредност у истраживачком оквиру добијају и иновативне студије које истражују мање конвенционалне, али потенцијално значајне факторе утицаја на појаву саобраћајних незгода. Таква анализа, спроведена у оквиру ове докторске дисертације, усмерена је на испитивање могуће повезаности између екстратерестричних утицаја (Месечевих мена) и учесталости саобраћајних незгода са животињама (*Iio and Lord, 2024*) на подручју Србије за период од 2015. до 2023. године. Резултати анализе, спроведене у оквиру ове докторске дисертације, указали су на значајно повећање броја оваквих незгода током пуног Месеца, што отвара простор за разматрање нових хипотеза у оквиру планирања и управљања ризиком, нарочито у руралним и областима са појачаном и густом вегетацијом. Иако још увек недовољно истражена, у односу на доминантне токове саобраћајних анализа, ова тема указује на могућност проширења аналитичког оквира и на факторе који се традиционално не налазе у фокусу саобраћајног инжењеринга, али могу постати релевантни у специфичним контекстима.

Све наведене истраживачке целине повезује јединствени методолошки оквир чију окосницу чине методе рачунарске интелигенције (фази логика, вештачке неуронске мреже), затим машинско учење (XGBoost, Random Forest, CatBoost), статистички модел за анализу и прогнозирање временских серија (SARIMA), просторне и временске анализе и интерпретабилност резултата, са циљем подршке стратешком и оперативном управљању саобраћајним системима. Иако је примена у овом раду усмерена на Србију, предложени приступ има висок степен преносивости на друге инфраструктурне и логистичке системе.

Иако се у светској литератури могу наћи различити радови који се баве појединачним аспектима идентификације опасних места, моделирањем саобраћајних незгода или анализом утицаја параметара саобраћајног тока, интеграција свих ових елемената у јединствен, интерпретабилан и оперативно примењив методолошки оквир и даље изостаје. Веома је мали број истраживања која истовремено обједињују квантитативну процену

здравствених и економских последица, класификацију ризичних локација засновану на карактеристикама тока и геометрији пута, као и предикцију будућих догађаја на различитим просторним и временским скалама. Управо тај недостатак свеобухватних и примењивих решења представљао је главну мотивацију за израду ове дисертације, чији је циљ да кроз интегрисани оквир понуди систематичан приступ који би могао послужити као модел за будуће истраживање и управљање саобраћајним системима.

## 1.2 Предмет и циљ истраживања

Предмет ове докторске дисертације заснива се на примени метода и техника рачунарске интелигенције, фази логике и вештачких неуронских мрежа, као и на примени напредних алгоритама машинског учења за моделирање и анализу сложених процеса у саобраћајном систему. Истраживање обухвата развој и примену квантитативних модела који интегришу податке различите природе (инфраструктурне, временске, карактеристике понашања и сл.) ради предикције и превенције ретких и комплексних догађаја у саобраћају и транспорту.

Како у Србији не постоји свеобухватан методолошки оквир који систематски примењује савремене методе за ове проблеме, структура докторске дисертације дефинисана је кроз следеће целине:

1. примена методологије Глобалног оптерећења (терета) болестима као алата за квантификацију негативних ефеката саобраћајног система, са могућношћу адаптације и у другим инфраструктурним доменима;
2. развој методологије засноване на фази логици за идентификацију и класификацију опасних, критичних места на мрежи путева, која интегрише инфраструктурне карактеристике, изложеност и тежину саобраћајних незгода;
3. израда модела предикције саобраћајних незгода применом техника машинског учења (XGBoost, Random Forest, CatBoost), паралелно са применом вештачких неуронских мрежа, ради процене могућности настанка ризика и специфичних догађаја у друмском саобраћају;
4. примена модела временских серија за прогнозу динамике појава које носе ризике, укључујући трендове и сезонске варијације, са могућношћу генерализације на друге области;
5. интеграција астрофизичких и метеоролошких података у квантитативне моделе ради истраживања утицаја спољашњих фактора на ретке и ризичне појаве у друмском саобраћају.

На основу приказаног предмета истраживања формиран је примарни циљ ове докторске дисертације: развити и применити напредне методе рачунарске интелигенције и машинског учења ради бољег разумевања, предикције и управљања ризичним и комплексним појавама у друмском саобраћају, са посебним освртом на интеграцију података различитог формата.

Секундарни циљеви ове докторске дисертације јесу:

1. прилагодити и применити методологију Глобалног оптерећења болестима за квантификацију негативних ефеката у друмском саобраћају;
2. развити свеобухватне моделе за детекцију и категоризацију опасних места у друмском саобраћају, на основу карактеристика пута, нивоа саобраћајне изложености и тежине последица незгода, за државне путеве IB реда у Републици Србији, засноване на фази логици;
3. развити моделе предикције саобраћајних незгода засноване на савременим техникама машинског учења;
4. развити моделе предикције засноване на методама временских серија како би се идентификовали трендови и сезонске варијације у настанку саобраћајних незгода у Србији;
5. истражити потенцијални утицај соларних феномена на појаву саобраћајних незгода са животињама у Србији, с циљем бољег разумевања различитих фактора ризика.

### 1.3 Полазне хипотезе

Из претходно дефинисаних предмета и циљева докторске дисертације постављено је пет полазних хипотеза, детаљно објашњених у наставку.

1. Међународно призната методологија Глобалног оптерећења болестима пружа оквир за свеобухватну процену тежине повреда и смртности, чиме омогућава упоредивост резултата између земаља и унутар региона. Применом ове методологије на националном нивоу могу се добити увиди у здравствене и економске негативне последице друмског саобраћаја.  
**Хипотеза 1 (X1):** Методологија Глобалног оптерећења болестима применљива је и у националном контексту Србије за процену јавноздравственог утицаја различитих догађаја у саобраћају, чиме се обезбеђује основ за поређење са међународним подацима.
2. Просторно-структурна анализа представља основу за разумевање ризика на путној мрежи. Узимањем у обзир геометријских карактеристика, нивоа изложености и тежине последица омогућава се дефинисање циљаних зона интервенције и превенције. У таквим анализама, методе рачунарске интелигенције, пре свега фази логика, омогућавају адекватније (реалније) класификовање и процену неизвесности у подацима.  
**Хипотеза 2 (X2):** Примена фази логике на просторно-структурне индикаторе, као што су геометријске карактеристике пута, нивои изложености и тежине последица, омогућава развој поуздане методологије за идентификацију и класификацију опасних места на државним путевима IB реда у Републици Србији.
3. Односи између физичких параметара кретања возила и услова на путу могу се боље разумети и предвидети кроз моделовање засновано на машинском учењу и вештачким неуронским мрежама. Испитивање утицаја динамичких и геометријских

фактора на појаву и карактер критичних догађаја у саобраћајном систему представља основу за креирање интелигентних модела ризика.

**Хипотеза 3 (Х3):** Комбинација параметара окружења и изложености, анализирана кроз примену техника рачунарске интелигенције, има статистички значајан утицај на учесталост и тежину негативних последица у друмском саобраћају, што је могуће доказати моделима предикције високих перформанси.

4. Подаци о саобраћају често садрже уочљиве временске обрасце који указују на сезонске, дневне, сатне и цикличне компоненте. Примена статистичких модела за анализу и прогнозу временских серија омогућава боље разумевање динамике догађаја и спровођење правовремених интервенција.

**Хипотеза 4 (Х4):** Интеграција метода временских серија са техникама машинског учења може адекватно да открије сезонске трендове и цикличне компоненте у динамици појава у друмском саобраћају, чиме се значајно унапређује ефикасност и поузданост временски осетљивих модела предикције.

5. Иако је још увек недовољно истражена у оквиру саобраћајног инжењерства, све више аутора указује на могући утицај природних, соларних и екстратерестричких феномена на понашање људи и животиња. Понашање животиња у саобраћајном окружењу, нарочито током појединих лунарних фаза, може се боље разумети уз анализу зависности у процесу препознавања понављајућих образаца у подацима.

**Хипотеза 5 (Х5):** Број саобраћајних незгода са животињама статистички је значајно већи током фазе пуног Месеца у односу на друге лунарне периоде, што указује на постојање везе између лунарних циклуса и понашања животиња у саобраћајном окружењу.

## 1.4 Организација – садржај дисертације

Докторска дисертација уређена је на следећи начин: након Увода и општег прегледа коришћених метода рачунарске интелигенције, треће поглавље обухвата примену методологије Глобалног оптерећења болестима у домену саобраћаја у Србији, са кратким освртом на најзначајнија светска достигнућа, разраду методолошког оквира који је прилагођен домаћем контексту и приказ резултата истраживања. У четвртном поглављу развијена је методологија, базирана на фази логици, која се користи за категоризацију опасних места на државним путевима ИБ реда у Србији. Пето поглавље посвећено је развоју модела предикције саобраћајних незгода на примеру ванградске мреже ИБ реда у Србији. У оквиру овог поглавља приказани су резултати израде, тренирања и тестирања модела машинског учења, али су развијене и вештачке неуронске мреже на националном нивоу. Шесто поглавље обрађује развој модела временских серија за предвиђање саобраћајних незгода, користећи SARIMA статистички модел, уз преглед најважнијих светских достигнућа у овој области. Посебан део у оквиру овог поглавља посвећен је тестирању израђених модела на подручју Србије. Иако безбедност саобраћаја, односно настанак саобраћајних незгода, зависи од мноштва утицајних фактора и носи широку лепезу специфичности, у седмом поглављу идеја је била да се обради управо један од специфичних утицајних елемената, односно сегмент ризика у саобраћају, те су анализирани екстратерестрички утицаји – Месечеве мене – на појаву незгода са животињама, кроз

посебно развијен методолошки поступак приказан у оквиру овог поглавља докторске дисертације. Завршно, осмо поглавље садржи закључак са сумарним приказом најважнијих резултата и кључним разматрањима спроведених истраживања.

---

---

# ПРЕГЛЕД КОРИШЋЕНИХ МЕТОДА

---

---



## 2

### 2.1 Фази логика


Фази логика (енг. *Fuzzy Logic*) представља једну од савремених метода у оквиру Операционих истраживања, која омогућава моделовање система уводећи појам „неизвесности” онда када нам жељени подаци нису доступни или када када не поседују захтевани ниво прецизности. Фази логика се заснива на теорији фази скупова коју је дефинисао Лотфи Задех (*Zadeh, 1965*), са основном идејом да одређени елемент може делимично припадати неком скупу са вредностима у интервалу  $[0, 1]$ , за разлику од класичне логике, где је припадност искључиво бинарна. Степен припадности дефинише се функцијом  $\mu_A(x)$ , која сваком елементу  $x$  додељује ниво припадности скупу  $A$ .

$$\mu_A(x) : X \rightarrow [0,1] \quad (1)$$

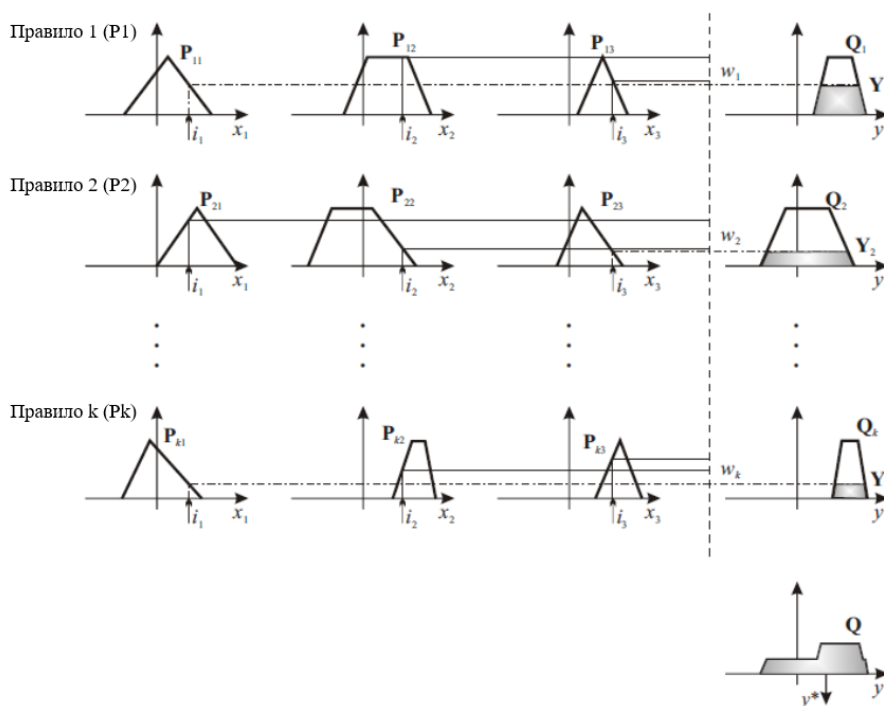
У практичној примени најчешће се користе троугласте и трапезне функције припадности јер једноставно описују концепте попут „мала брзина”, „средња брзина” или „велики проток”. Процес фазилогичког закључивања обухвата фазификацију улазних података, примену скупа правила у форми АКО – ОНДА, и дефазификацију, односно превођење добијених резултата у конкретне нумеричке вредности.

На Слици 1 дат је пример функција припадности за брзину возила, где се интервал брзина (0 km/h – 120 km/h) дели на три фази скупа: мала, средња и велика брзина. Видљиво је да возило које се креће, на пример, 85 km/h истовремено припада и скупу „средња брзина” (са већим степеном припадности) и скупу „велика брзина” (са мањим степеном припадности).

Фазилогички систем се пројектује тако што се прво изврши избор улазних и излазних променљивих, затим се формирају правила на основу знања експерта (лингвистичке променљиве и њихово представљање фази скуповима и дефинисање АКО – ТАДА правила) и коначно примењује алгоритам апроксимативног резоновања (Слика 2) на основу кога се добија конкретна вредност на излазу из модела.



Слика 1. Пример фази функција припадности за брзину возила



Слика 2. Графичка интерпретација дисјунктивног система правила (Teodorović and Šelmić, 2019)

У области саобраћаја ова метода има значајне примене: управљање светлосном сигнализацијом на раскрсницама, динамичка контрола протока возила на ауто-путевима, процена ризика, моделирање понашања возача, доношење одлука у условима непотпуних или недоступних података, као и решавање других комплексних саобраћајних проблема у условима неизвесности (Teodorović and Šelmić, 2019). Сходно наведеном, ниво ризика на деоници пута може се изразити као фази комбинација параметара, као што су радијус

кривине, ограничење брзине и интензитет саобраћаја, што омогућава реалније вредновање него класичне бинарне класификације.

На тај начин, фази логика делује као важна веза између математичке „строгости” и реалних услова у саобраћају, што је чини неизоставним алатом рачунарске интелигенције за контролу и унапређење безбедности и ефикасности саобраћајних система.


## 2.2 Вештачке неуронске мреже

Вештачке неуронске мреже (енг. *Artificial Neural Networks*, ANN) представљају једну од основних метода у оквиру рачунарске интелигенције, настале по узору на структуру и функционисање људског мозга. Идеја је први пут формално разрађена педесетих година прошлог века (*Rosenblatt*, 1958), а данас се овај приступ користи за решавање сложених проблема у различитим дисциплинама. Њихова предност у односу на класичне статистичке методе огледа се у способности да нелинеарне односе међу подацима опишу на флексибилан начин и да „уче” из примера.

Основна градивна јединица је неурон, који прима више улазних сигнала ( $x_1, x_2, \dots, x_n$ ), сваком сигналу придружује тежински коефицијент  $w_i$ , а затим израчунава линеарну комбинацију излазног сигнала из излазног неурона  $z$ :

$$z = \sum_{i=1}^n w_i x_i + b \quad (2)$$

Где  $w_i$  представља тежину улазног сигнала  $x_i$ , а параметар  $b$  представља шум. На Слици 3 је приказан вештачки неурон и одговарајућа активациона функција. Приказани неурон је типичан процесни елемент у вештачкој неуронској мрежи. Најчешће се за активациону функцију користи нелинеарна, континуална, монотono растућа, ограничена, диференцијабилна логистичка функција. Основни циљ активационе функције је да помоћу „S” криве вредности тежинске суме улазних сигнала НЕТ трансформише у вредности променљиве ИЗЛАЗ, које узимају релативно мале вредности без обзира на вредности променљиве НЕТ. Најчешће коришћене активационе функције јесу степ функција, сигмоидна функција, хипертангентна функција и симетрала првог квадранта.

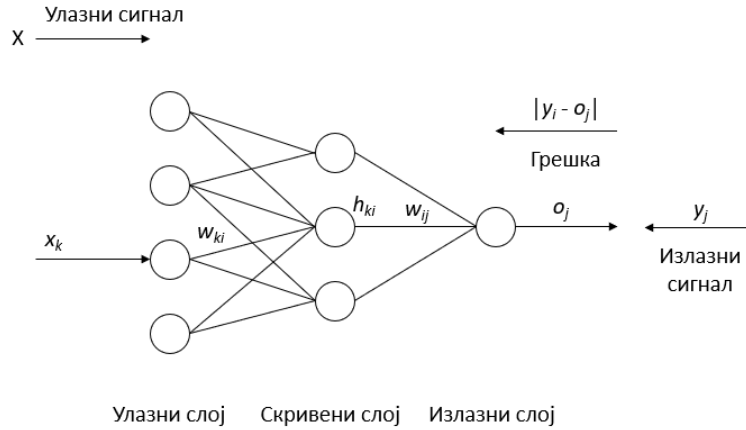


Слика 3. Процесни елемент: вештачки неурон и активациона функција (*Teodorović and Šelmić, 2019*)

Након примене активационе функције  $\varphi(z)$  излаз из неурона постаје:

$$y = \varphi(z) \quad (3)$$

Вештачке неуронске мреже престављају вишеслојну структуру повезаних неурона: улазни слој, један или више скривених слојева и излазни слој (Слика 4). Процес учења одвија се кроз оптимизацију тежина  $w_i$ , на основу функције грешке која мери разлику између прогнозираних и стварних вредности.



**Слика 4.** Тренирање вишеслојног перцептрона: простирање сигнала унапред и простирање израчунате грешке уназад (Teodorović and Šelmić, 2019)

У оквиру ове докторске дисертације коришћени алгоритам за обучавање вештачких неуронских мрежа базира се на алгоритму за обучавање Адалине (енг. *Adaptive Linear Neuron*), једнослојне неуронске мреже. Алгоритам се састоји из следећих корака (Teodorović and Šelmić, 2019):

Корак 0: Иницијализација тежина и шума (најједноставније је да на почетку све тежине и шум буду једнаке нули). Одабрати вредности интензитета учења  $a$  из интервала  $0 \leq a \leq 1$  (најједноставније је да је  $a = 1$ ).

Корак 1: Све док услови за завршетак алгоритма нису задовољени понављати кораке 2–6.

Корак 2: За сваки тренинг пар  $s : t$  извршити кораке 3–5.

Корак 3:  $x_i = s_i$

Корак 4: Израчунати излазну вредност из излазног неурона:


$$y_i = b + \sum_i x_i w_i \quad (4)$$

Корак 5: Иновирати вредности тежина и шума уколико приказани вектор није класификован на задовољавајући начин:

$$w_i^{(\text{нова})} = w_i^{(\text{стара})} + a(t - y_i)x_i \quad (5)$$

$$b(\text{нова}) = b(\text{стара}) + a(t - y_i) \quad (6)$$

Може се размотрити и случај када Адалине има више неурона у излазном слоју (Слика 5).



Слика 5. Адалине са више излазних неурона

Означимо са  $t_j$  жељену излазну вредност  $j$ -тог излазног неурона. Такође, означимо респективно са  $y_j$  и  $w_{ij}$  вредност сигнала који улази у  $j$ -ти излазни неурон и тежину гране која повезује  $i$ -ти неурон у улазном слоју са  $j$ -тим неуроном у излазном слоју. Делта правило у случају постојања више излазних неурона гласи:

$$\Delta w_{ij} = a(t_i - y_j)x_i \quad (7)$$

У саобраћајном инжењерству вештачке неуронске мреже налазе широку примену и то најчешће за: предвиђање броја саобраћајних незгода на основу историјских података, моделирање односа између параметара саобраћајног тока (проток, густина, брзина), детекцију ризичних ситуација у реалном времену, процену капацитета путева и оптимизацију управљања саобраћајем (*Ghanim et al.*, 2022; *S. Ahmed et al.*, 2023; *Ahmad et al.*, 2024).

### 2.3 Стабло одлучивања

Стабло одлучивања (енг. *Decision Tree*) представља један од најједноставнијих и најинтуитивнијих модела у оквиру операционих истраживања и машинског учења. Као техника класификације и регресије, оно доноси одлуке по принципу „разгранавња” – проблем се поступно дели на мање, хомогене групе, кроз низ бинарних питања. Први радови који су увели ову методу потичу из шездесетих и седамдесетих година, док је метод постао популаран након израде и примене алгоритама као што су ID3 (*Quinlan*, 1986), C4.5 и CART (*Breiman et al.*, 1984).

Основна идеја овог приступа јесте да се у свакој тачки (чвору) стабла подаци деле према једном критеријуму који обезбеђује највеће смањење „шума”, „нетачних” података. Овај параметар се мери помоћу Гинијевог индекса или ентропије. На пример, ако је  $p_i$  вероватноћа да случај припада класи  $i$ , ентропија се дефинише као:

$$H(S) = -\sum_{i=1}^k p_i \log_2(p_i) \quad (8)$$

А Гинијев индекс као:

$$G(S) = 1 - \sum_{i=1}^k p_i^2 \quad (9)$$

Избор најбољег атрибута за поделу врши се тако да добијени чворови имају минималну ентропију или Гинијев индекс, односно да су што „чистији”. Алгоритам се понавља рекурзивно док се не добије финална структура стабла.

У области саобраћаја, стабла одлучивања се користе за идентификацију фактора ризика и прогнозу понашања система. На пример, могу се користити за класификацију саобраћајних незгода у категорије тежине (лаке, тешке, са смртним исходом), на основу параметара као што су ограничење брзине, интензитет саобраћаја, геометрија пута и метеоролошки услови (*Chong et al.*, 2004). Такође, могу се применити у одлукама о управљању раскрсницама, предвиђању застоја у саобраћајном току и процени ефикасности безбедносних мера (*Rithesh et al.*, 2018).

## 2.4 Ансамбл технике засноване на дрвећу

Ансамбл технике засноване на дрвећу представљају проширење основног модела стабла одлучивања и један су од најефикаснијих приступа у оквиру вештачке интелигенције и машинског учења. Основна идеја ансамбл модела јесте да се уместо једног стабла гради већи број стабала, а њихове се одлуке затим комбинују како би се добила робуснија и тачнија предвиђања. Постоје два основна приступа: *bagging* (енг. *Bootstrap Aggregating*) и *boosting*. У првом случају, више стабала се тренира на различитим подскуповима података, а резултати се агрегирају, док *boosting* методе граде низ стабала која уче једно након другог, при чему свако ново стабло исправља грешке претходних.

Random Forest (*Breiman*, 2001) представља класичан *bagging* алгоритам у коме се гради велики број стабала одлучивања на насумично изабраним подскуповима података и атрибута, а коначна одлука у регресији добија се просеком:

$$\hat{f}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (10)$$

Где је  $T_b(x)$  предвиђање појединачног стабла, а за класификацију већинским гласањем:

$$\hat{y} = \text{mode}\{T_1(x), T_2(x), \dots, T_B(x)\} \quad (11)$$

На овај начин Random Forest добија стабилна и она предвиђања која су отпорна на оптерећење модела и неприродну генерализацију.

С друге стране, AdaBoost представља први популарни *boosting* алгоритам (*Freund and Schapire*, 1997) који динамички прилагођава тежине подацима. Узорци који су били погрешно класификовани добијају већу тежину у следећем кораку, а коначна хипотеза добија облик:

$$H(x) = \text{sign}(\sum_{m=1}^M a_m h_m(x)) \quad (12)$$

Где је  $h_m(x)$  класификатор изграђен у  $m$ -тој итерацији, а  $a_m$  његова тежина која расте са тачношћу.

Даљи развој boosting приступа довео је до Gradient Boosting методе (Friedman, 2001) која оптимизује функцију грешке. Модел се гради итеративно додавањем нових стабала  $h_m(x)$  у функцији губитака:

$$F_m(x) = F_{m-1}(x) + v * h_m(x), \quad m = 1, \dots, M \quad (13)$$

Где је  $v$  корак учења (eng. *Learning rate*), а  $h_m(x)$  стабло које апроксимира негативни пад (градијент).

HistGradientBoosting метода додатно убрзава овај процес хистограмском апроксимацијом, што омогућава примену на веома великим скуповима података. Новије методе, као што су XGBoost (Chen and Guestrin, 2016), LightGBM (Ke et al., 2017) и CatBoost (Prokhorenkova et al., 2018), представљају савремена решења која оптимизују процес грађења boosting модела. XGBoost је познат по ефикасности и флексибилности, LightGBM користи „leaf-wise” стратегију грађења стабала која смањује потрошњу меморије, док CatBoost има предност у обради категоричких података и стабилности на малим скуповима (узорцима). Математичка интерпретација CatBoost модела дата је кроз наредне једначине.

Овај модел врши предикцију као збир појединачних стабала:

$$F(x) = F_0(x) + \sum_{m=1}^M \sum_{i=1}^N f_m(x_i) \quad (14)$$

Где су:

$F(x)$  – коначна предикција коју даје модел, на основу улазног узорка  $x$ ;

$F_0(x)$  – почетна претпоставка модела, основна вредност од које модел полази;

$\sum_{m=1}^M$  – агрегација преко  $M$  стабала. Свако стабло представља побољшање предикције;

$\sum_{i=1}^N$  – агрегација преко  $N$  тренинг узорака. Свако стабло учи из свих тренинг примера;

$f_m(x_i)$  – предикције  $m$ -тог стабла за узорак  $x_i$ . Свако стабло даје свој допринос у укупној предикцији.

За евалуацију (разумевање) модела и његових најбољих карактеристика користи се следећа једначина:

$$\hat{y}_i = \Phi_0 + \sum_{j=1}^n \Phi_j^{(i)} \quad (15)$$

Где су:

$\Phi_j^{(i)}$  – допринос особине  $j$  за предикцију узорка  $i$  (рачуна се помоћу SHAP (енг. *SHapley Additive exPlanations*) вредности, како је рађено и у овом истраживању);

$\Phi_0$  – почетна вредност.

У области саобраћајног инжењерства, ансамбл технике засноване на дрвећу показале су се као изузетно ефикасне у задацима као што су предвиђање броја саобраћајних незгода, класификација тежине последица незгода, процена ризика на путним деоницама и предвиђање протока возила (*Ateksa et al.*, 2022; *Dong et al.*, 2022; *S. Ahmed et al.*, 2023; *G. Li et al.*, 2023). Њихова предност у односу на једноставна стабла одлучивања огледа се у знатно већој тачности, отпорности на грешке и способности да идентификују сложене нелинеарне односе између параметара као што су проток, брзина, геометрија пута, услови вожње итд. На тај начин ансамбл модели омогућавају поузданије одлучивање у саобраћајним системима и пружају снажну подршку за дефинисање превентивних мера и политика безбедности.

## 2.5 Модели временских серија

Модели временских серија представљају важну класу техника намењену прогнозирању величина које се мењају током времена. Њихова примена у саобраћају је од посебног значаја јер многи параметри, попут интензитета саобраћаја, брзине кретања возила или броја саобраћајних незгода, имају временску компоненту и јасне сезонске обрасце. Најпознатији класични приступ је ARIMA модел (енг. *Autoregressive Integrated Moving Average*), који комбинује ауторегресију (AR), диференцирање серије ради постизања стационарности (I) и компоненту померајног просека (MA) (*Box and Jenkins*, 1990). Овај модел је погодан за податке без изражене сезонности.

Када временска серија садржи јаке сезонске обрасце (нпр. месечне или дневне варијације), примењује се SARIMA модел, који проширује основни ARIMA додавањем сезонских параметара. Општа форма модела записује се као:

$$SARIMA(p, d, q)(P, D, Q)_s \quad (16)$$

Где су:

$p$  – ред ауторегресије (AR);

$d$  – степен диференцирања (I);

$q$  – ред померајног просека (MA);

$P, D, Q$  – сезонске компоненте (AR, I, MA);

$s$  – сезонски период (12 месеци, 24 часа и сл.).

Сходно наведеном, SARIMA модел се може дефинисати као:

$$\Phi_p(B^s)\Phi_p(B)(1-B)^d(1-B^s)^D y_t = \theta_q(B)\epsilon_t \quad (17)$$

Где су:

$B$  – оператор пропагације уназад, (нпр.  $B y_t = y_t - 1$ );

$\Phi_p(B)$  – AR полином реда  $p$ ;

$\theta_q(B)$  – MA полином реда  $q$ ;

$\Phi_p(B^s)$  – сезонски AR;

$\theta_q(B^s)$  – сезонски MA;

$\epsilon_t$  – резидуална грешка (остатак).

Оваква структура омогућава да модел истовремено апроксимира краткорочне и сезонске зависности у подацима.

Поред класичних статистичких модела, у последњој деценији развијени су и савременији приступи, међу којима је најпознатији Prophet модел (*Taylor and Letham, 2018*). Prophet је развијен од стране Facebook-а као модел погодан за податке који садрже трендове, вишеструке сезоналности и ефекте специфичних догађаја (нпр. празници). Заснован је на адитивној декомпозицији:

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (18)$$

Где су:

$g(t)$  – тренд;

$s(t)$  – сезонска компонента;

$h(t)$  – ефекат догађаја (нпр. празника);

$\epsilon_t$  – резидуална грешка (остатак).

Овај модел је практичан због једноставне имплементације и способности да обрађује велике скупове података уз минимално подешавање параметара.

У контексту анализе ризика и прогнозе у саобраћају често је важно не само предвидети очекивану вредност, већ и распон могућих исхода. Ту се користи Quantile Regression метода (*Koenker and Bassett, 1978*), која омогућава процену условних квантила зависне променљиве. За разлику од класичне регресије која моделира средњу вредност, квантилна регресија омогућава да се добију, на пример, 10, 50. или 90. проценат расподеле. Иако није искључиво модел временских серија, квантилна регресија може бити саставни део модела као метод за одређивање интервала прогнозе и процену екстремних вредности (нпр. максималне вредности протока или ризик од екстремно високог броја незгода). На тај начин, ова метода допуњује већ објашњене ARIMA, SARIMA и Prophet моделе, обезбеђујући робуснију анализу.

## 2.6 Анализа главних компоненти

Анализа главних компоненти (енг. *Principal Component Analysis, PCA*) представља једну од најчешће коришћених статистичких метода, чија је основна функција смањење димензионалности података уз задржавање што већег дела укупне варијабилности оригиналног скупа података. Ова метода је посебно корисна у ситуацијама када постоји велики број међусобно зависних променљивих јер омогућава њихову трансформацију у мањи број нових, међусобно независних променљивих.

Основна идеја РСА заснива се на линеарној трансформацији почетних променљивих, тако да прва главна компонента објашњава највећи могући део укупне варијансе података, друга главна компонента објашњава највећи део преостале варијансе уз услов ортогоналности у односу на прву и тако редом. На овај начин се сложена структура података може представити у компактнијем облику, што олакшава анализу, визуелизацију и интерпретацију резултата.

У математичком смислу, главна компонента представља линеарну комбинацију оригиналних променљивих:

$$PC_k = a_{k1}X_1 + a_{k2}X_2 + \dots + a_{kp}X_p \quad (19)$$

Где су:

$X_1, X_2, \dots, X_p$  – оригиналне променљиве;

$a_{kj}$  – елементи сопствених вектора корелационе матрице;

$\lambda_k$  – величина варијансе објашњена одговарајућом компонентом (веза са елементима сопствених вектора).

Процент укупне варијансе који објашњава  $k$ -та главна компонента може се изразити као:

$$\text{Објашњена варијанса}_k = \frac{\lambda_k}{\sum_{i=1}^p \lambda_i} \quad (20)$$

У пракси се задржава само ограничен број главних компоненти, најчешће на основу критеријума кумулативне објашњене варијансе (нпр. 70%–90%), чиме се постиже значајно смањење броја променљивих без већег губитка информација.

---

---

# ПРИМЕНА КОНЦЕПТА ГЛОБАЛНОГ ОПТЕРЕЋЕЊА БОЛЕСТИМА У ДОМЕНУ САОБРАЋАЈА У СРБИЈИ

---

---



## 3

### 3.1 Опис проблема

Саобраћајне незгоде представљају један од најзначајнијих изазова у области јавног здравља на глобалном нивоу, при чему у значајној мери имају велики утицај на укупну стопу смртности становништва (*Inada et al.*, 2020; *James et al.*, 2020). Укупан терет који произилази из повреда у друмском саобраћају укључује не само смртне исходе већ и последице у виду трајног инвалидитета, нарушеног квалитета живота, као и значајне економске губитке (*S. K. Ahmed et al.*, 2023). Светска здравствена организација често указује на неопходност спровођења свеобухватних мера у саобраћају у циљу ублажавања штетних ефеката које овај систем проузрокује на становништво, при чему је од пресудног значаја адекватно разумевање овог проблема и системска процена његовог утицаја на здравље становништва.

Република Србија се, као и бројне друге земље, суочава са трајним изазовима у смањењу броја повређених и погинулих у друмском саобраћају. Иако су тестиране и примењиване различите мере – од унапређења инфраструктуре и законске регулативе (*Službeni glasnik RS br. 30/18*, 2018; *Road Traffic Safety Agency*, 2023) до едукативних кампања – саобраћајне незгоде и даље представљају један од водећих узрока смртности и инвалидитета у нашој земљи (*Агенција за безбедност саобраћаја*, 2022; *Rajčević et al.*, 2024), те је процена друштвеног оптерећења које саобраћајне незгоде носе од кључног значаја за дефинисање превентивних мера и активности и предузимање циљаних интервенција.

Циљ овог дела истраживања јесте квантификовање терета саобраћајних незгода у Србији кроз анализу релевантних здравствених индикатора: смртности, повреда, изгубљених година живота (енг. *Years of Life Lost, YLL*), година живота са инвалидитетом (енг. *Years Lived with Disability, YLD*) и година изгубљеног здравог живота (енг. *Disability-Adjusted Life Year, DALY*) (*Jevremović and Medarević*, 2026). Поређењем стања у оквиру двадесетогодишњег периода, између 2002. и 2024. године, настоји се идентификовати смер кретања, степен напретка и приоритетне области за будуће деловање.

Значај ове анализе огледа се у могућности за правовремено информисање доносилаца одлука, јавних институција и осталих релевантних актера о тренутном стању безбедности у друмском саобраћају, а на основу добијених података. Кроз дугорочну процену друштвеног

терета током протекле две деценије, могуће је сагледати ефекте спроведених мера и идентификовати преостале (нерешене) проблеме и изазове. Резултати могу допринети подизању јавне свести о значају овог проблема и подстаћи деловање потребно за обликовање будућих стратегија. Истовремено, компаративна анализа омогућава боље разумевање утицаја демографских кретања, економских промена, измена законодавства и других домаћих и глобалних фактора на динамику саобраћајних незгода. Ово истраживање пружа нову перспективу засновану на најновијим подацима из домена саобраћаја чиме се даје допринос актуелној бази знања у области саобраћајног инжењерства.

### **3.2 Преглед најважнијих истраживања у области примене методологије глобалног оптерећења болестима у домену саобраћаја**

Питање друштвеног терета болести, повреда и фактора ризика привукло је значајну пажњу у научној заједници, како на глобалном (*Brauer et al., 2024; Ferrari et al., 2024*), тако и на националном нивоу (*GBD 2021 US Burden of Disease and Forecasting Collaborators, 2024; Naghavi et al., 2025*). Један од најобимнијих истраживачких подухвата у овој области јесте пројекат под називом Глобално оптерећење болестима (GBD), где у оквиру међународне мреже различити профили стручњака сарађују на темама везаним за процену морталитета, инвалидитета и здравствених последица различитих болести, повреда и фактора ризика. У оквиру овог пројекта анализирано је више од 370 стања и повреда, као и преко 80 ризичних фактора, уз примену стандардизованих индикатора као што су године живота изгубљене услед превремене смрти, година живота са инвалидитетом, укупан терет болести изражен кроз године изгубљеног здравог живота и очекивани здрав животни век (енг. *Health-Adjusted Life Expectancy*, HALE) (*Institute for Health Metrics and Evaluation (IHME), 2025*). Значај овог истраживања огледа се у томе што обезбеђује емпиријску подршку доносиоцима одлука приликом дефинисања здравствених приоритета и интервенција.

У оквиру бројних области које се третирају у GBD пројекту, повреде настале у саобраћају издвајају се као посебно анализирана категорија, и то како у глобалним истраживањима (*Hu and Mamady, 2013; Lin, 2016; Gu et al., 2025; Wang and Li, 2025*), тако и у бројним националним студијама (*Polinder et al., 2015; Bhatti et al., 2017; Dávila-Cervantes, 2021; Khalaf et al., 2023; Sadeghian Tafti et al., 2023; Wen et al., 2024; Faizi, 2025*).

Упркос глобалном значају ове проблематике, Србија и даље нема свеобухватну, ажурирану и методолошки усклађену анализу друштвеног терета саобраћајних повреда, што представља један од кључних мотива за спровођење овог истраживања у оквиру докторске дисертације. Системска процена поменутог терета има потенцијал да пружи релевантне информације потребне за креирање ефикасних мера унапређења безбедности саобраћаја, у складу са Националном стратегијом безбедности саобраћаја (*Službeni glasnik RS br. 30/18, 2018*) и циљевима одрживог развоја који се односе на смањење броја повреда у друмском саобраћају.

Последња детаљнија национална анализа овог типа урађена је за 2000. годину, а резултати су објављени 2003. године под покровитељством Министарства здравља Републике Србије (*Atanasković-Marković et al., 2002*). Циљ студије био је да тестира применљивост GBD

методологије на националном нивоу. Анализирано је 135 узрока болести, укључујући кључне факторе ризика попут употребе дувана и алкохола, физичке неактивности, неадекватног уноса воћа и поврћа, гојазности, повишеног крвног притиска и холестерола. Повреде у саобраћају анализирани су на нивоу Србије и за град Београд, при чему су индикатори YLL, YLD и DALY распоређивани по полу и старосним групама. Примера ради, 2000. године YLL за саобраћајне незгоде износио је 13.340 за мушкарце и 3893 за жене, док су вредности DALY индикатора износиле 24.038 и 6430. За узраст 15–24 године саобраћајне повреде су представљале водећи узрок губитка година живота код оба пола (YLL: 3503 за мушкарце и 1401 за жене). Слични резултати добијени су и за Београд.

Наредне студије (*Janković et al.*, 2007; *Vlajinac et al.*, 2008; *Milicevic et al.*, 2009) и извештаји (*Institute of Public Health of Serbia 'Dr Milan Jovanović Batut'*, 2009) који су се бавили овом проблематиком у великој мери су се ослањали на податке из поменуте анализе за 2000. годину. Последњи познати рад који се фокусира на повреде у саобраћају објављен је 2013. године (*Šipetic et al.*, 2013), али се у њему користе подаци из 2002. године, са посебним освртом на повреде у контексту употребе алкохола. Утврђени показатељи у овом раду били су: YLL – 5227 (мушкарци) и 972 (жене), YLD – 4094 (мушкарци) и 608 (жене), те DALY – 9321 и 1580 за мушкарце и жене респективно.

На основу претходних истраживања, јасно је да Србији недостаје свеобухватна и актуелна процена терета од повреда у саобраћајним незгодама. Управо овај недостатак отвара простор за спровођење савремене анализе на актуелним подацима којом се омогућава праћење различитих трендова током времена, што је урађено у оквиру ове докторске дисертације. Резултати овакве анализе могли би послужити као основ за унапређење јавних политика и прилагођавање интервенција у складу са променама у друштвеној, демографској и нормативној структури Србије.

### 3.3 Методологија истраживања за потребе примене концепта глобалног оптерећења болестима у домену саобраћаја у Србији

У оквиру овог истраживања примењена је методолошка поставка коју су развили (*Bhalla and Harrison*, 2016), као и пратећи аналитички алат истих аутора (*Bhalla and Harrison*, 2015). Њихов приступ представља адаптацију основне методологије коју је иницијално формулисао Институт за здравствене метрике и евалуацију у оквиру пројекта GBD. Основне метрике (YLL, YLD и DALY) задржане су у својој суштини, али су у овој варијанти прилагођене за примену у контексту националних и локалних анализа.

Примена ове методологије омогућава израчунавање наведених индикатора у складу са специфичностима података на нивоу појединачне земље или региона, чиме се обезбеђује релевантнији увид у терет болести и повреда у конкретном социјално-здравственом окружењу. Основни поступци израчунавања YLL-а, YLD-а и DALY-ја у складу са овим моделом биће детаљно описани у наставку, у складу са изворним процедурама које су представили (*Bhalla and Harrison*, 2015):

$$YLL_{f(\text{пол,старост,екстерни узроци})} = D_{f(\text{пол,старост,екстерни узроци})} * L_{f(\text{пол,старост})} \quad (21)$$

Где су:

$D$  – број смртних случајева;

$L$  – очекивана старост особе.

$$YLD = N * p_{perm} * DW_{perm} * L_p + N * (1 - p_{perm}) * DW_{st} * D_{st} \quad (22)$$

$$N_{f(\text{пол,старост,екст.узроци,последике})} = E_{f(\text{пол,старост,екст.узроци,последике})} * P_{f(\text{пол,старост,екст.узроци,последике})} \quad (23)$$

Где су:

$DW_{perm}$  – тежина сталног инвалидитета;

$N$  – број инцидентних случајева за конкретну последицу;

$P_{perm}$  – проценат особа са сталним инвалидитетом;

$DW_{perm}$  – тежина инвалидитета (0 – здрава особа, 1 – преминула особа);

$L_p$  – животни век популације;

$DW_{st}$  – тежина привременог инвалидитета;

$D_{st}$  – трајање привременог инвалидитета.

При чему DALY представља збир утицаја YLL-а и YLD-а, илустровано наредном једначином:

$$DALY = YLL + YLD \quad (24)$$

Подаци који се односе на карактеристике саобраћајних незгода прикупљени су са званичне интернет платформе Агенције за безбедност саобраћаја Републике Србије (<https://bazaabs.abs.gov.rs/absPortal/>). Обухваћени период анализе протеже се од 2002. до 2024. године.

Класификација смртних исхода и повреда извршена је према утврђеним GBD критеријумима, како би се омогућила доследна примена индикатора терета болести у оквиру истраживања. У наставку је приказана методологија категорисања појединачних исхода у складу са захтевима анализе (Табела 1).

Подаци о демографским карактеристикама становништва преузети су са званичне интернет странице Завода за статистику Републике Србије (<https://data.stat.gov.rs/?caller=SDDDB&languageCode=sr-Latn>), за временски интервал од 2002. до 2024. године. Циљна популација је класификована у 18 старосних група, у интервалима од по пет година.

У циљу обезбеђивања упоредивости података, спроведен је процес старосне стандардизације у складу са препорукама Светске здравствене организације (*Ahmad et al.*,

2001). На основу тога, индикатори морталитета, повреда, као и изведене мере терета болести (YLL, YLD и DALY) изражени су као стандардизоване вредности по старосним групама.

**Табела 1.** Категоризација узрока смрти/повреде према типу возила у Србији, формирана према методологији GBD-а

Узрок смрти/повреде	Опис
Употреба бицикла	Смрт или инвалидитет настали услед инцидента (као бициклиста или путник на бициклу).
Употреба моторног возила са два точка	Смрт или инвалидитет настали као резултат вожње мотоцикла (као возач или путник).
Употреба моторног возила са три точка	Смрт или инвалидитет настали као резултат вожње троточкаша (лака и тешка возила).
Употреба моторног возила са четири и више точкова	Смрт или инвалидитет настали као резултат вожње возила са четири и више точкова (аутомобили, камиони итд.).
Коришћење аутобуса	Смрт или инвалидитет настали као резултат вожње аутобуса (као возач или путник).
Друго превозно средство	Смрт или инвалидитет настали као резултат вожње осталих возила: радне машине, трактори и сл.

Просторна дистрибуција анализирана је у складу са званичном административном поделом на 25 региона коју је дефинисао Завод за статистику Републике Србије (*Statistical Office of the Republic of Serbia*, 2014).

За обраду, визуелизацију и статистичку анализу података коришћени су Microsoft Excel и статистички софтверски пакет R (верзија 4.4.2), уз примену Tidyverse библиотека (*Wickham et al.*, 2019), које су омогућиле ефикасно управљање подацима и израду графичких приказа.

### 3.4 Резултати примене концепта глобалног оптерећења болестима у домену саобраћаја у Србији, за период од 2002. год 2024. године

Ово поглавље структурирано је у три тематске целине. У првом делу приказане су временске промене показатеља повезаних са повредама у друмском саобраћају на територији Републике Србије, укључујући стопу смртности, број повређених, као и индикаторе изгубљених година живота (YLL), година живота са инвалидитетом (YLD) и укупног терета болести (DALY).

Други сегмент поглавља посвећен је детаљнијој анализи наведених индикатора према полу и старосним категоријама, чиме се омогућава увид у демографске обрасце ризика и последица саобраћајних повреда.

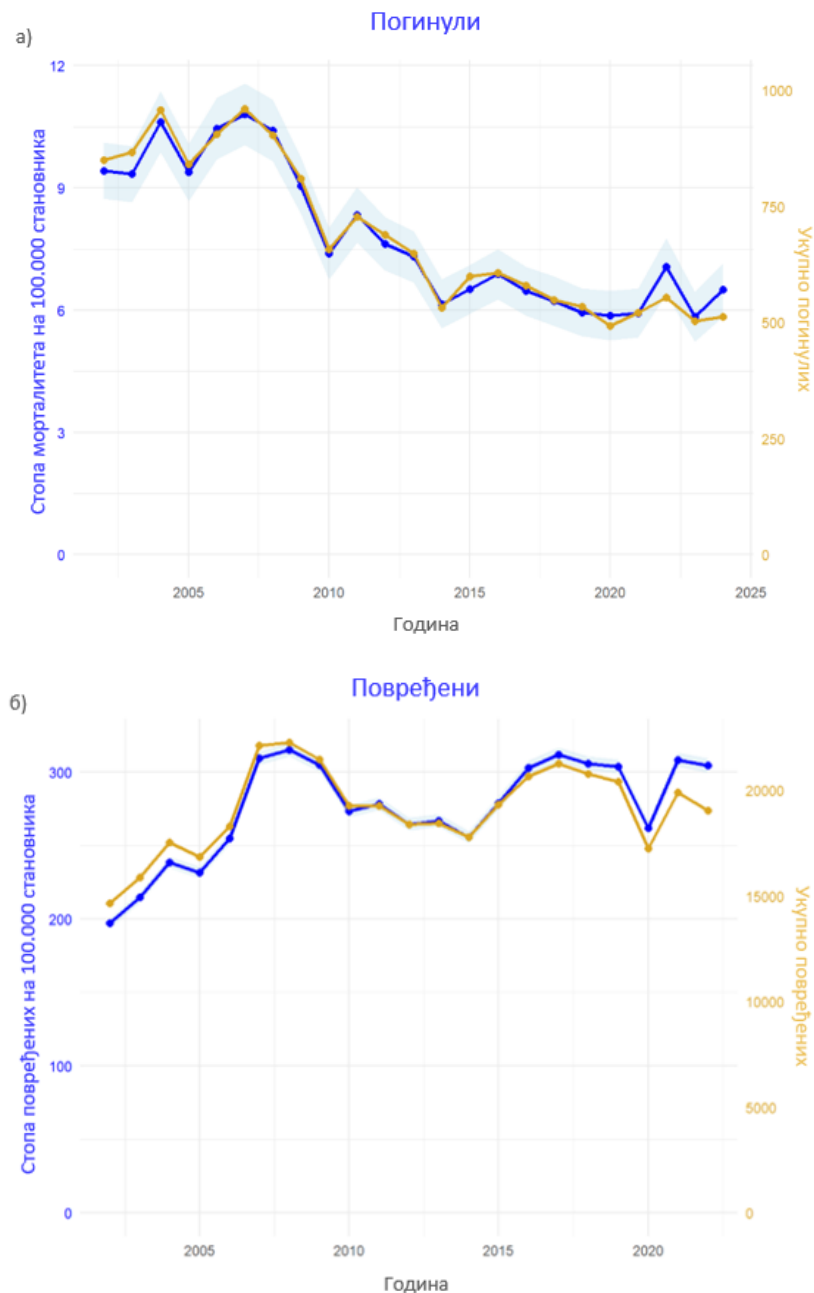
У трећем потпоглављу анализирана је територијална расподела показатеља YLL-а, YLD-а, DALY-ја, морталитета и повреда по административним регионима Републике Србије, чиме се указује на просторне неједнакости и регионалне специфичности у погледу друштвеног терета саобраћајних незгода.

### 3.4.1 Лонгитудинална анализа индикатора друштвеног терета у Србији

Спровођење свеобухватне лонгитудиналне анализе омогућава праћење динамике промена током времена, укључујући идентификацију периода значајних помака (било у правцу напретка или стагнације), као и благовремено откривање новонасталих ризичних образаца. Истовремено, овакав приступ доприноси поузданијој евалуацији ефеката спроведених интервенција у области безбедности саобраћаја.

Ово поглавље пружа детаљан преглед временских трендова индикатора терета повреда у друмском саобраћају на територији Републике Србије у периоду од 2002. до 2024. године. Кретање стопе смртности и броја повређених у посматраном интервалу графички је представљено на Слици 6, чиме се омогућава идентификација критичних периода и структурних промена у обрасцима ризика.


На основу података приказаних на Слици 6, уочава се континуиран пад броја смртних исхода током анализираног периода, што упућује на могуће позитивне ефекте спроведених мера превенције у области безбедности саобраћаја. Такав тренд указује на присуство систематских интервенција усмерених ка смањењу смртности као најтежег исхода саобраћајних незгода.



**Слика 6.** Временске промене стопа а) смртности и б) повреда у Србији за период 2002–2024.

Међутим, када је реч о броју повређених лица, резултати показују знатно већу нестабилност. У периоду од 2002. до 2008. године регистрован је нагли пораст броја повреда, након чега следи фаза осцилација: смењивање периода раста и пада без јасног тренда. Такав образац може указивати на одсуство конзистентне политике или системског приступа у спречавању повреда у саобраћају, што доводи у питање ефикасност постојећих механизма контроле и праћења.

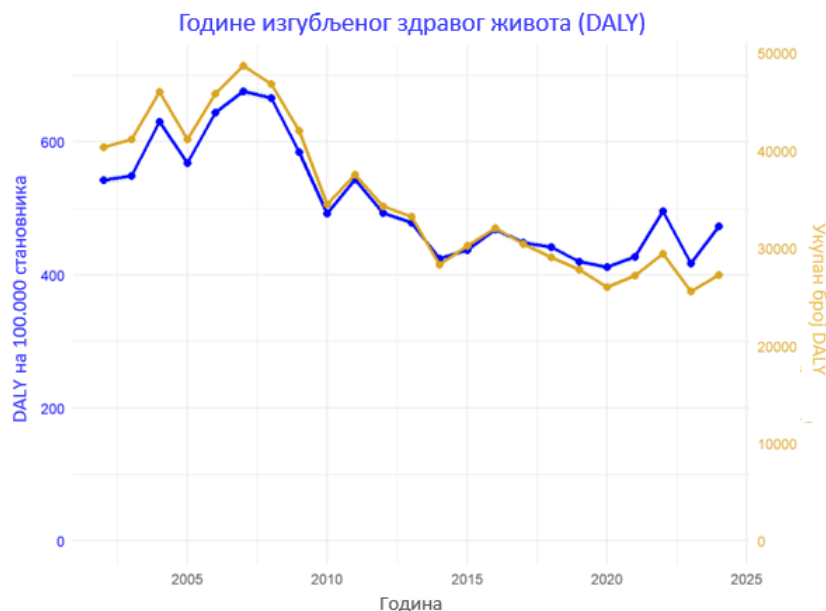
Слика 7 приказује кретање индикатора YLL-а и YLD-а на годишњем нивоу у анализираном периоду:



Слика 7. Промене параметара а) YLL и б) YLD у Србији за период 2002–2024.

Сличан образац може се уочити и у овом случају: индикатор YLL показује стабилан силазни тренд, уз одређене варијације у последњим годинама (2022–2024), што је у складу са смањењем смртности. Насупрот томе, вредности YLD индикатора варирају током анализираног периода, без јасне тенденције смањења, што указује на сложеност и дугорочност последица које повреде остављају на здравље погођених особа, као и на потребу за циљаним мерама рехабилитације и подршке.

Слика 8 приказује временске промене у вредностима индикатора DALY (године изгубљеног здравог живота) током анализираниог периода од 2002. до 2024. године. Анализа показује изражен опадајући тренд укупног терета повреда у друмском саобраћају, посебно изражен у интервалу од 2007. до 2014. године, што може указивати на ефективност интервенција спроведених у том периоду. Након тог интервала, вредности се стабилизују, уз присуство умерених флукуација, док су у последњих неколико година анализираниог периода (од 2020. до 2024. године) присутне изражене флукуације. То указује на потребу увођења како превентивних мера, тако и мера које циљано третирају одређене недостатке уочене у постојећем стању.

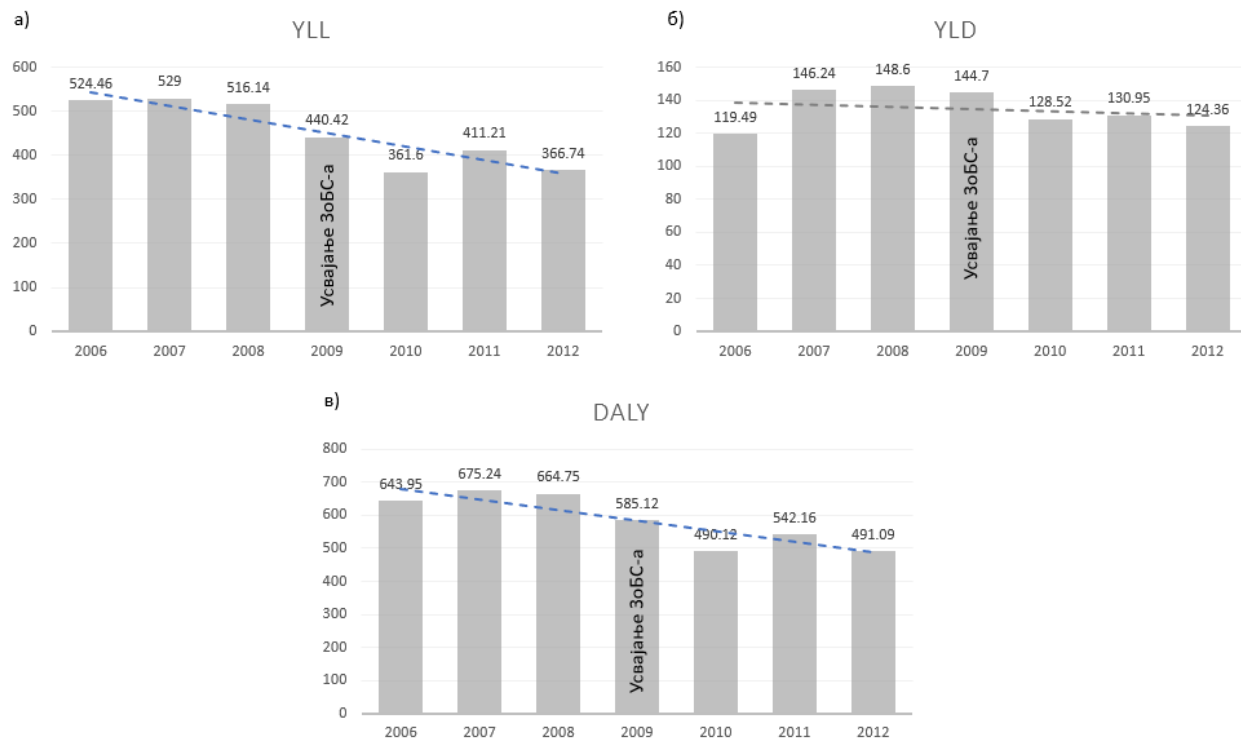


**Слика 8.** Промене индикатора DALY у Србији за период 2002–2024.

Овај пораст може бити последица сложених фактора, укључујући индиректне ефекте пандемије COVID-19, као и могуће демографске и епидемиолошке промене које су утицале на учесталост и последице саобраћајних повреда (*Ebrahim Shaik and Ahmed, 2022*). Оваква кретања захтевају додатну анализу и контекстуално тумачење у оквиру ширих друштвено-здравствених околности.

У циљу сагледавања потенцијалних промена наведених показатеља, анализирана су два временска периода повезана са кључним интервенцијама у области безбедности саобраћаја у Србији. Први период односи се на доношење Закона о безбедности саобраћаја на путевима 2009. године (Слика 9), док се други период односи на усвајање Националне стратегије безбедности саобраћаја за период од 2015 до 2020. године (Слика 10). За оба случаја посматран је интервал од три године пре и три године након наведених догађаја.

Са Сlike 9 може се видети да резултати указују на јасну промену тренда након увођења Закона о безбедности саобраћаја на путевима:



**Слика 9.** Трендови стандардизованих показатеља YLL, YLD и DALY у периоду 2006–2012, са освртом на усвајање Закона о безбедности саобраћаја на путевима (2009)

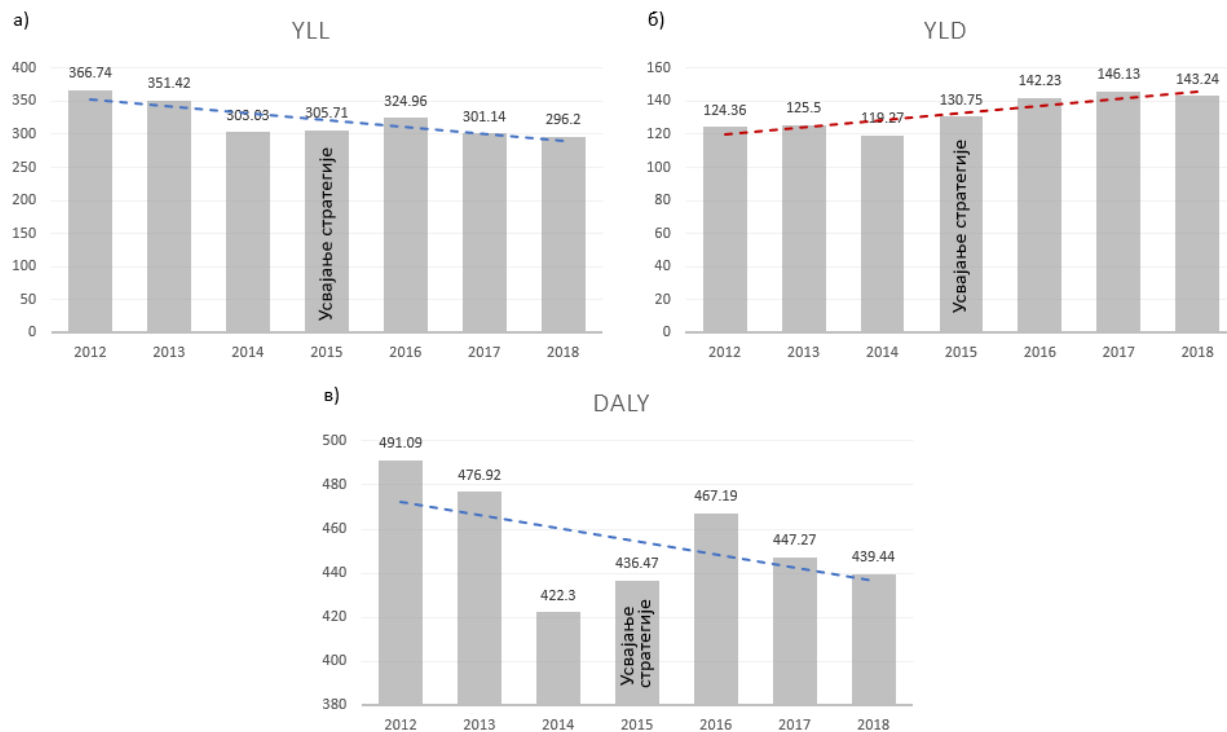
У периоду пре доношења закона (2006–2008), вредности индикатора YLL и DALY показују релативно високе нивое, уз опадајући тренд, док YLD бележи благе осцилације и практично је без промене током анализираног периода. Међутим, након 2009. године уочава се израженији пад вредности индикатора YLL и DALY, што указује на смањење укупног терета саобраћајних незгода.

С друге стране, YLD показатељ и даље не бележи никакав значајнији пад у периоду након усвајања и примене новог Закона, што може указивати да су последице незгода у виду повреда и даље присутне, али са мањим интензитетом у погледу смртности. Генерално посматрано, DALY као збирни показатељ прати доминантно кретање индикатора YLL, што је и очекивано јер губитак година живота има већи утицај на укупни терет. Ови резултати сугеришу да је након увођења Закона дошло до општег побољшања безбедности саобраћаја, што је видљиво кроз смањење најтежих последица саобраћајних незгода (смртних исхода), али уједно без значајног смањења повреда у саобраћају.

Слика 10 приказује промену тренда показатеља YLL, YLD и DALY за период 2012–2018.

У посматраном периоду уочава се различита динамика кретања појединачних показатеља након усвајања Стратегије. Показатељ YLL има опадајући тренд и након 2015. године, што указује на његово континуирано смањење. Овај тренд је релативно стабилан и не показује значајне осцилације, што може указивати на постепено унапређење безбедности саобраћаја у домену најтежих последица.

Са друге стране, YLD показује умерен раст након 2015. године, што указује на повећање терета повреда, односно последица које не доводе до смртног исхода, али утичу на квалитет живота. Ово може указивати на промену структуре последица саобраћајних незгода, где се број или тежина повреда релативно повећава у односу на смртне исходе.




**Слика 10.** Трендови стандардизованих показатеља YLL, YLD и DALY у периоду 2012–2018, са освртом на усвајање Националне стратегије безбедности саобраћаја (2015–2020)

Показатељ DALY прати опадајући тренд током читавог периода, али са благим порастом непосредно након 2015. године, након чега се наставља тенденција смањења. Ово указује да укупни терет саобраћајних незгода и даље опада, али да се унутрашња структура тог терета делимично мења, са релативно већим учешћем повреда у односу на смртне исходе.

### 3.4.2 Анализа индикатора друштвеног терета по регионима у Србији

У оквиру овог поглавља анализиран је друштвени терет саобраћајних незгода по регионима у Србији, са посебним фокусом на временске промене и ефекте кључних институционалних интервенција. Као референтне тачке, и у овом поглављу, посматране су 2009. година, када је усвојен важећи Закон о безбедности саобраћаја на путевима, и 2015. година, када је донета прва национална Стратегија безбедности саобраћаја за период од 2015. до 2020. године. Анализа је заснована на упоредном посматрању више временских пресека (2002, 2007, 2013, 2019. и 2024), чиме се омогућава сагледавање дугорочних трендова и регионалних разлика.

На Слици 11 приказан је број погинулих на 100.000 становника по регионима:




Слика 11. Број погинулих на 100.000 становника по регионима Србије

Уочава се да су највише вредности броја погинулих на 100.000 становника доминантно присутне у периоду пре 2009. године, посебно 2007. године, када поједини региони (нпр. Сремски, Јужнобанатски, Подунавски) достижу максимуме. Након 2009. године долази до генералног пада у већини региона, што указује на снажан ефекат законских мера. Тај пад је највидљивији у већ претходно поменутих регионима (у Сремском, Јужнобанатском, Подунавском), али и у већем броју осталих региона, где вредности након 2013. године остају на нижем нивоу.

Након 2015. године и усвајања Националне стратегије безбедности саобраћаја на путевима, тренд смањења се у већини региона наставља, али са мањим интензитетом и уз израженије

регионалне разлике. Поједини региони задржавају стабилно ниске вредности (нпр. Златиборски, Нишавски, Севернобанатски), док се у другима (нпр. у Борском, Јабланичком, Браничевском) јављају осцилације или поновни пораст до 2024. године. Ово указује да су након иницијалног ефекта Закона даља побољшања зависила од локалних услова и специфичних фактора ризика, што наглашава значај регионално прилагођених мера безбедности саобраћаја.

На Слици 12 приказан је број повређених на 100.000 становника по регионима:



Слика 12. Број повређених на 100.000 становника по регионима Србије

За разлику од броја погинулих, код броја повређених се не уочава тако јасан и конзистентан пад након 2009. године. Напротив, у великом броју региона (нпр. у Јужнобачком, Средњебанатском, Сремском) максимум се јавља управо у периоду од 2007. до 2013. године, што указује да је увођење Закона имало ограничен непосредни ефекат на овај индикатор. У неким регионима (у Колубарском, Топличком, Јабланичком, Јужнобанатском) долази до благог смањења након 2013. године, али су вредности и даље релативно високе и варијабилне, односно осцилирају.


Након 2015. године не уочава се јединствени тренд, већ доминирају осцилације и у већини случајева поновни раст до 2024. године – овакву ситуацију региструјемо у нпр. Браничевском, Јужнобанатском, Борском, Колубарском, Сремском округу. Посебно се издвајају урбанији и саобраћајно интензивни региони (Београдски, Јужнобачки и делом Колубарски и Подунавски), који задржавају високе вредности, што може указивати на снажан утицај саобраћаја, односно повећања броја возила на мрежи. Уједно, овакви резултати су веома интересантни јер са једне стране указују на видљиво смањење броја погинулих (јасно видљиве ефекте примењених мера и увођења закона), док се са друге стране број повређених у одређеним ситуацијама чак и повећавао. То упућује на чињеницу да иако су донесени нови закони и стратегије они нису имали ефеката на третирање последица саобраћајних незгода.

Генерално, може се закључити да је код повређених доминантан утицај обима саобраћаја и изложености, док су ефекти законских и стратешких мера мање изражени него код погинулих. Ово указује да смањење тежине последица (фаталних исхода) јесте постигнуто, али да укупна безбедност саобраћаја, посматрана и кроз број повређених, захтева додатне мере и активности.

На Слици 13 приказан је YLL индикатор на 100.000 становника по регионима.

Посматрајући овај индикатор уочава се пад након 2009. године (за већину региона), што је и очекивано јер овај индикатор посебно наглашава фаталне исходе у млађим старосним групама. Највише вредности доминирају у периоду од 2002. до 2007. године (нпр. у Сремском, Јужнобанатском, Подунавском, Средњебанатском округу), док након 2013. године већина региона бележи значајно смањење.


Након 2015. године тренд смањења углавном се наставља или се вредности стабилизују на нижем нивоу (нпр. у Београдском, Нишавском, Јужнобачком, Сремском округу), што указује на дугорочни ефекат мера усмерених ка смањењу најтежих последица саобраћајних незгода. Ипак, у појединим регионима јављају се осцилације и поврени раст до 2024. године (нпр. у Јабланичком, Борском, Колубарском, Тимочком, Моравичком, Браничевском), што указује на присуство локалних ризика који и даље доводе до високих вредности овог индикатора.



Слика 13. YLL индикатор на 100.000 становника по регионима Србије

На Слици 14 приказан је YLD индикатор на 100.000 становника по регионима.

Код овог индикатора уочава се знатно мање изражен пад након 2009. године у односу на YLL, што указује да су последице саобраћајних незгода које доводе до повреда остале дугорочно присутне. Вредности у великом броју региона достижу максимум у периоду око 2007. године (нпр. у Јужнобачком, Сремском, Средњебанатском, Колубарском, Подунавском), након чега следи умерено смањење, али не и континуирани опадајући тренд.




**Слика 14.** YLD индикатор на 100.000 становника по регионима Србије

Након 2015. године доминирају осцилације, са честим поновним растом до 2024. године (нпр. у Браничевском, Сремском, Севернобачком, Расинском, Јужнобанатском округу), док само два региона показују релативну стабилизацију на нижем нивоу (нпр. Рашки и Пчињски). Урбанији региони и они са већим обимом саобраћаја (Београдски, Јужнобачки) задржавају више вредности, што и даље указује на снажан утицај саобраћаја.

Генерално, YLD потврђује да, иако је дошло до смањења најтежих исхода (броја погинулих), терет незгода кроз повреде и последични инвалидитет није у истој мери редукован, већ показује различите осцилације и зависност од локалних услова.

На Слици 15 приказан је DALY индикатор на 100.000 становника по регионима.



Слика 15. DALY индикатор на 100.000 становника по регионима Србије

Укупни индикатор друштвеног терета, који обједињује YLL и YLD, показује трендове који су у највећој мери вођени променама у броју погинулих. Највише вредности доминирају у периоду пре 2009. године, посебно у 2007. години (нпр. Сремски, Јужнобанатски, Средњебанатски округ), након чега у већини региона долази до израженог пада до 2013. године. Ово потврђује да је увођење Закона о безбедности саобраћаја имало кључни утицај на смањење укупног друштвеног терета.

Након 2015. године уочавају се стабилизација или умерене осцилације, при чему део региона задржава ниже вредности (нпр. Београдски, Златиборски, Нишавски, Севернобачки), док се у појединим јавља поновни раст до 2024. године (нпр. у Борском,

Колубарском, Тимочком, Јабланичком, Браничевском). Сходно наведеном, DALY јасно показује да је након 2009. године дошло до значајног смањења укупног друштвеног терета саобраћајних незгода, док је период након 2015. године обележен одржавањем тог нивоа уз изражене регионалне разлике, што указује на потребу за даљим, циљаним мерама у безбедности саобраћаја.

### **3.4.3 Поређење индикатора друштвеног терета Србије са осталим земљама света и позиција Србије на глобалном плану**

У овом потпоглављу приказани су најинтересантнији резултати поређења Србије са осталим земљама света према YLD и DALY индикаторима у односу на пол и старост. Као референца узета је 2022. година, јер је то година за коју су били доступни најновији подаци.

#### *Поређење индикатора на глобалном нивоу по полу*


Циљ ове анализе је да се Србија позиционира у ширем, глобалном контексту, те да се сагледају релативне специфичности у терету повреда насталих услед саобраћајних незгода.

На Слици 16 приказана је позиција Србије на глобалном нивоу по индикатору YLD, посматрано по полу. Овај визуелни приказ омогућава идентификацију Србије у односу на друге државе, као и процену неједнакости по полу у контексту терета нефаталних повреда.

Анализа вредности YLD-а по државама указује на значајне разлике у терету повреда проузрокованих саобраћајним незгодама. Србија се позиционира у средишњем делу расподеле приказаних земаља, што указује на умерено висок ниво инвалидитета услед повреда у саобраћају, у поређењу са другим државама. Посебно је уочљиво да мушкарци у Србији имају више YLD вредности од жена, што је у складу са већом изложеношћу мушкараца ризичном понашању у саобраћају – попут брзе вожње, некоришћења сигурносног појаса и вожње под утицајем алкохола.

Велики распон вредности између држава показује да терет инвалидитета услед саобраћајних незгода није само последица броја незгода већ и ефикасности система медицинске помоћи, доступности рехабилитације и трајања опоравка. Земље са већим YLD вредностима могу имати нижу стопу морталитета, али дуже периоде инвалидитета, док оне са ниским вредностима могу бележити већи удео смртних исхода. У том контексту, позиција Србије указује на потребу за унапређењем система након догађања незгоде и програма за смањење дуготрајних последица повреда, како би се смањило укупни терет који саобраћајне незгоде остављају на појединце, здравствени систем и економију земље.


Са друге стране, на основу анализе расподеле DALY индикатора (Слика 17) по државама, уочава се да Србија припада доњем делу лествице, што указује на релативно мањи укупан терет саобраћајних незгода по становништву у поређењу са већином других земаља.



Слика 16. Упоредна анализа земаља према YLD индикатору за 2022. годину

Овај индикатор може указивати на одређене недостатке у (не)пријављивању и (не)евидентирању последица незгода, нарочито у случају лакших повреда или материјалне штете. Као и у већини других земаља, DALY вредности су знатно више код мушкараца него код жена, што потврђује познати образац веће изложености мушкараца ризичним

понашањима у саобраћају. Иако ниска позиција Србије на овој скали делује повољно, она не сме довести до релаксираног деловања у превенцији, већ треба да представља подстицај за даље унапређење система, системске рехабилитације и прецизније праћење индикатора друштвеног терета.



Слика 17. Упоредна анализа земаља према DALY индикатору за 2022. годину

### *Поређење индикатора на глобалном нивоу по старосним категоријама*

Имајући у виду чињеницу да су у Србији млади најизложенији учешћу у незгодама, као и то да млади трпе највеће последице саобраћајних незгода у поређењу са свим осталим старосним категоријама, у овом поглављу биће анализирана старосна категорија од 15 до 49 година и позиција Србије на глобалној мапи света према YLD и DALY индикаторима.


На Слици 18 приказане су вредности индикатора YLD по земљама света и полу, за старосну категорију од 15 до 49 година, која је у претходно описаним анализама идентификована као група која подлеже највећем ризику од последица незгода.

Србија се налази међу државама са највишим YLD вредностима у овој популацији (шеста у свету), што указује на изражен терет повреда у саобраћају код млађих особа. Ово је посебно значајно јер се последице повреда у овом узрасту не односе само на здравље појединца већ и на економску продуктивност, друштвени капитал и оптерећење здравственог система. Подаци такође показују доминацију мушкараца у YLD вредностима, што указује на виши ниво ризичног понашања у саобраћају у односу на жене у истој старосној категорији.


Високо позиционирање Србије на овој лествици треба посматрати као сигнал за интервенцију у домену превенције, образовања младих возача, контроле саобраћаја и посттрауматске неге. Такође, чињеница да су неке економски снажне и институционално стабилне државе боље позициониране указује да ниска изложеност инвалидитету услед повреда није искључиво повезана са економским ресурсима, већ и са формираним стратегијама у безбедности саобраћаја, културом понашања и системским приступом опоравку.

Уколико се анализира DALY показатељ (Слика 19), може се видети да се Србија налази у средишњем делу расподеле, што указује на умерен али и даље значајан терет саобраћајних незгода у најпродуктивнијем животном добу. Ова старосна група обухвата популацију од кључног економског и друштвеног значаја, што значи да последице повреда утичу не само на индивидуални ниво већ и на целокупни систем рада, здравствену потрошњу и демографске токове.

Приметна је доминантна заступљеност мушкараца у укупном броју YLL-а, што је у складу са глобалним трендовима и одражава већу учесталост ризичног понашања код мушкараца у саобраћају, укључујући брзу вожњу, небезбедно управљање и мање поштовање саобраћајних прописа. Позиционирање Србије у средишњем делу лествице треба да служи као основ за прецизније дефинисање политика безбедности у саобраћају, са акцентом на младу мушку популацију и радно способно становништво, а у циљу смањења дугорочних здравствених и економских последица повреда.



Слика 18. Поређење земаља према YLD индикатору за старосну категорију 15–49 година, за 2022. годину



Слика 19. Поређење земаља према DALY индикатору за старосну категорију 15–49 година, за 2022. годину

На основу до сада приказаних резултата и извршеног поређења на међународном нивоу, може се прихватити Хипотеза 1.

### 3.5 Дискусија резултата добијених применом методологије глобалног оптерећења болестима у домену саобраћаја у Србији за период од 2002. до 2024. године

Спроведно је истраживање које је обухватало временску и просторну анализу терета повреда у саобраћају у Србији у периоду од 2002. до 2024. године. Упркос уочљивим побољшањима током наведеног периода, укупан терет незгода на путевима и даље остаје значајан, са израженим неједнакостима како регионално, тако и унутар различитих демографских група.

Са популацијом од приближно 6,7 милиона становника (*Republički zavod za statistiku, 2025*) Србија и даље бележи висок терет повреда у саобраћају у поређењу са земљама западне Европе (*Transport Community, 2023; European Commission, 2024*). Према најновијим подацима пројекта Глобалног терета болести, стандаризована стопа изгубљених година здравог живота услед повреда у саобраћају у Србији, током анализираниог периода, премашује европски просек (за скоро 13%), сврставајући је ближе земљама источне Европе (*Institute for Health Metrics and Evaluation (IHME), 2022*).

У периоду од 2002. до 2024. године забележено је значајно смањење морталитета и изгубљених година живота услед саобраћајних незгода, при чему је нарочито изражен пад након 2009. године, када је усвојен први савремени Закон о безбедности саобраћаја на путевима. Ова законска интервенција донела је одређене измене попут поштрених казни, обавезног коришћења сигурносног појаса и кациге, побољшану техничку контролу возила и системско планирање безбедније инфраструктуре. Временска корелација између усвајања Закона и наглог пада у броју смртних исхода, YLL-а и DALY-ја, указује на његов мерљив јавноздравствени утицај. Ипак, смањење смртности може делимично бити повезано и са сталним растом броја нефаталних али „онеспособљавајућих” повреда, нарочито у узрасту до 25 година. Иако је број фаталних незгода у опадању, број преживелих са трајним последицама расте, посебно код мушкараца, што указује на промену у типологији повреда и потребу за јачањем система рехабилитације, трауматолошке неге и подршке након незгода.

Пандемија вируса COVID-19 током 2020. и 2021. године представљала је изненадни спољни утицај за трендове у саобраћају. Смањена мобилност током периода изолације довела је генерално до привременог пада броја незгода и смртности (*Yasin et al., 2021; Ebrahim Shaik and Ahmed, 2022*). Међутим, током 2024. године у Србији, упркос даљем смањењу укупног броја случајева, дошло је до поновног пораста стопе DALY параметра, што може указивати на већу тежину повреда, ризичније понашање (нпр. брза вожња на празнијим путевима) или слабу реакцију хитних служби у условима пандемијских ограничења и кризе.

Период након 2015. године карактерише одређена стабилизација система, али и појава израженијих регионалних разлика – док су неки региони достигли и задржали ниже нивое друштвеног терета, други показују осцилације или чак поновни раст појединих индикатора. Ово указује да иницијални ефекти националних политика временом достижу свој максимум, након чега даљи напредак зависи од локалних карактеристика: инфраструктуре, саобраћајног оптерећења, просторне расподеле ризика и ефикасности спровођења мера.

Другим речима, систем је прешао из фазе „општег побољшања” у фазу где доминирају специфични, регионално условљени фактори. Посебно је значајно уочити да региони са већом изложеношћу саобраћају (урбани и транзитни коридори) конзистентно задржавају више вредности индикатора повреда и индикатора YLD, чак и када се смртност смањује. Ово потврђује да изложеност остаје кључни покретач друштвеног терета, док мере безбедности пре свега утичу на тежину последица.

Сходно наведеном, регионалне неједнакости (према анализираним индикаторима) додатно наглашавају потребу за интервенцијама прилагођеним локалном контексту. Северни и централни окрузи, попут Колубарског и Борског, доследно бележе највише стопе индикатора DALY, YLL и YLD, што може бити последица већег саобраћајног оптерећења, инфраструктуре са повишеним ризиком и слабије контроле. Супротно томе, поједини јужни региони показују ниже стопе током 2024. године, мада се мора имати у виду и честа појава неадекватног пријављивања, односно непријављивања незгода. Стога су циљане мере, попут регионалне идентификације опасних места, јачања локалне контроле на нивоу заједница и образовање млађих и нарочито најмлађих категорија популације, кључне за смањење ових негативних последица. Разматрајући стратешке мере, на основу резултата добијених истраживањем спроведеним у овој дисертацији, намећу се три кључна аспекта:

1. неопходно је наставити модернизацију и доследну примену законских мера у саобраћају, са фокусом на факторе као што су коришћење сигурносног појаса, контрола брзине вожње, контрола употребе психоактивних супстанци и аклохола у вожњи и употреба мобилних телефона;
2. неопходно је повећати улагање средстава у развој регионалне здравствене инфраструктуре, пре свега у области трауматологије и рехабилитације, како би се ублажио негативан утицај растућег терета инвалидитета;
3. неопходно је плански вршити унапређења инфраструктуре и радити на подизању нивоа јавне свести о последицама незгода. У примени обеју мера неопходно је ослањање на просторне податке о оптерећењу повредама. На пример, интеграција ревизија у урбанистичко планирање и проширење улоге Савета за безбедност саобраћаја на локалном нивоу могу значајно допринети ефикаснијем управљању ризицима.

Иако је Србија након 2009. године остварила значајан напредак у смањењу броја смртних исхода у саобраћају, терет инвалидитета и просторне неједнакости у исходима повреда и даље представљају озбиљан проблем. Потребно је усмерити пажњу на превенцију повреда, смањење инвалидитета и инклузивно планирање у саобраћају, како би се очувани резултати додатно унапредили и ускладили са националном Стратегијом безбедности саобраћаја и глобалним циљевима Деценије акције за безбедност саобраћаја на путевима 2021–2030. (*World Health Organization (WHO) and United Nations Regional Commission, 2021*).

---

---

# РАЗВОЈ МЕТОДОЛОГИЈЕ ЗА КАТЕГОРИЗАЦИЈУ ОПАСНИХ МЕСТА НА ПУТЕВИМА IБ РЕДА

---

---



## 4.1 Опис проблема

Очување ефикасности и безбедности саобраћајног система представља један од кључних изазова у планирању саобраћаја, посебно у земљама са ниским и средњим приходима, где је учесталост саобраћајних незгода несразмерно висока (*World Health Organization (WHO), 2023a*). На глобалном нивоу, у друмском саобраћају сваке године живот изгуби приближно 1,19 милион људи, а број тешко повређених је знатно већи (између 20 и 50 милиона), што има значајне социоекономске последице, како на појединце и друштво, тако и на здравствени систем (*World Health Organization (WHO), 2023a*).

Иако се очекује да ће ванградски путеви, због обично нижег интензитета саобраћаја, имати мањи број незгода, у пракси се често дешава супротно. Ванградску инфраструктуру, посебно на путевима нижих категорија, карактеришу различити недостаци попут нередовног одржавања, што са собом повлачи лоше стање пута и његовог окружења, а посебно непредвидиве обрасце понашања возача, што резултира повећаним ризиком од настанка саобраћајних незгода. У таквом контексту, идентификовање и детаљно разумевање локација са повишеним ризиком, тзв. „опасних места”, представља предуслов за формулисање циљаних и делотворних мера интервенције, како на локалном, тако и на националном нивоу.

Опасна места се дефинишу као локације на којима се бележи знатно већа учестаност незгода у поређењу са окружењем. Оне се могу јављати на различитим типовима саобраћајне инфраструктуре – од деоница у правцу и кривина, до раскрсница, тунела или мостова (*Elvik, 2007*). Конвенционални приступи идентификацији опасних места углавном се ослањају на фреквенцију незгода или тежину исхода, често занемарујући шири контекст, као што су карактеристике пута, ниво изложености и структурни ризици. Штавише, овакви приступи обично подразумевају статичко посматрање феномена, без увида у његову еволутивну природу или трансформације током времена.

У новијој литератури приметан је помак ка свеобухватнијим и динамичнијим моделима анализе опасних места (*Montella, 2010; Sadeghi et al., 2013; Fan et al., 2019; Ghadi and Török, 2019; Aziz and Ram, 2022; Karamanlis et al., 2023*). Ипак, многе постојеће методологије и

даље не обезбеђују довољно робустан аналитички оквир који би омогућио праћење промене ризика током времена и његову диференцијацију по узрочним механизмима. Такође, недостаје типологија која би омогућила инжењерима и доносиоцима одлука не само да идентификују опасна места већ и да приоритизују и третирају различите подтипове у складу са њиховим специфичним карактеристикама.

Полазећи од наведених ограничења, циљ овог дела истраживања јесте развој система класификације опасних места у Србији заснованог на примени техника рачунарске интелигенције. Предложена методологија обухвата интеграцију параметара саобраћајног тока, геометријских карактеристика пута, нивоа изложености и тежине последица и примењена је на мрежу ванградских путева IB реда у Србији, за период од 2021. до 2023. године. Посебна пажња посвећена је раздвајању динамичких профила опасних места (новонастала, прелазна и трајна опасна места), као и њиховој класификацији по подтипovima који одражавају скривене обрасце ризика и понашања учесника у саобраћају.

Поменута класификација представља практичан алат намењен како саобраћајним инжењерима, тако и доносиоцима одлука. Њена примена омогућава прецизније вршење приоритизације мера интервенција, адекватно управљање ризиком и правовремено реаговање на просторно-временске промене у типовима опасних места у Србији.

## **4.2 Приказ најзначајнијих истраживања у области дефинисања и анализе опасних места на саобраћајној мрежи**

Током последњих деценија развијен је велики број различитих методолошких приступа за идентификацију опасних места, чиме је потврђена важност њиховог благовременог откривања и прецизног лоцирања на саобраћајној мрежи. Већина постојећих метода ослања се на статистичку обраду података о незгодама уз примену техника као што су модели вероватноће, просторне функције густине, алгоритми за кластеризацију, као и алати географских информационих система (*Geurts et al.*, 2004; *Huang et al.*, 2009; *Chang and Kim*, 2012; *Gregoriades and Mouskos*, 2013; *Zovak et al.*, 2014; *Elyasi et al.*, 2016; *Dereli and Erdogan*, 2017; *Khatun et al.*, 2024).

Једну од најсвеобухватнијих компаративних анализа метода за идентификацију локација са повећаним ризиком пружа *Montella* (2010), који је упоредио седам уобичајено коришћених техника, укључујући фреквенцију незгода, учесталост незгода са процењеном материјалном штетом, стопу незгода, метод пропорција, емпиријску Бајесову процену за све незгоде, за тешке незгоде и индикатор потенцијала за побољшање. Емпиријски Бајесов модел за процену свих незгода показао се супериорним у односу на остале коришћене моделе, што је у складу са резултатима других истраживања (*Ghadi and Török*, 2017a, 2019).

Различите студије, које се баве применом ових приступа, додатно илуструју методолошку разноврсност, али се углавном фокусирају на традиционалне приступе идентификацији ризичних локација (*Sadeghi et al.*, 2013; *Borsos et al.*, 2016; *Debrabant et al.*, 2018; *Abuaddous et al.*, 2022; *Cui et al.*, 2022).

Посебно је значајан допринос домаћих аутора који су развијали нове приступе идентификацији ризичних локација у Србији. Један од важних примера јесте модел заснован на континуалној анализи варијансе, који омогућава откривање небезбедних деоница пута кроз статистичко тестирање разлика у варијансама између суседних сегмената, без потребе за подацима о протоку (*Andelković et al.*, 2018). Овај приступ представља нов начин идентификације опасних места, али и даље остаје у оквиру квантитативне анализе фреквенције и тежине незгода. Поред тога, развијен је интегрисани метод који комбинује анализу незгода, субјективну конфликт технику и истраживање перцепције ризика код учесника у саобраћају, чиме се омогућава идентификација и рангирање пешачких подручја повећаног ризика (*Pešić et al.*, 2012). Иако тај модел представља напредак у интеграцији реактивних и проактивних индикатора безбедности, он је првенствено усмерен на приоритизацију пешачких локација, а не на њихову функционалну категоризацију. У том смислу, оба приступа дају одређен допринос у области безбедности саобраћаја, али се методолошки разликују од овде предложеног система који први уводи структурирану класификацију опасних места засновану на физиолошком моделу.

Важан допринос методолошкој еволуцији даје *Мурат* (2011), који користи ентропијску анализу ради процене безбедносног нивоа опасних места. У својој анализи, он укључује карактеристике као што су геометрија пута, проток возила, просечне брзине и типови незгода. Ипак, овај модел остаје у оквиру статистичког оквира и не нуди ширу типологију која би се ослањала на узрочне механизме ризика.

Такође, постоје и другачији приступи у којима је, на пример, примењена просторна кластеризација заснована на растојању између појединачних незгода, чиме су идентификоване високо ризичне локације у урбаној средини Пекинга (*Cui et al.*, 2022). Међутим, као и већина других метода, овај приступ не прави разлику међу типовима опасних места, већ их третира као једнородну категорију.

Савремени тренд у литератури све више препознаје потребу за дубљом анализом која укључује узрочне факторе као што су геометријске карактеристике пута, понашање учесника у саобраћају и тежина саобраћајних незгода, што представља значајан корак ка функционалној категоризацији опасних места (*Elvik*, 2007). У том контексту, студија коју су спровели Вашингтон и сарадници (*Washington et al.*, 2014) истиче значај увођења тежине незгода кроз EPDO вредности и примену квантилне регресије ради превазилажења ограничења класичних техника бројања. Овај приступ посебно наглашава утицај изложености и карактеристика инфраструктуре као што су ограничење брзине, хоризонталне кривине, нагиби итд. на ниво ризика.

Методолошки оквир развијен у овој дисертацији ослања се управо на гореописану логичку поставку, али је значајно проширен увођењем структуриране класификације опасних места у шест функционално различитих подтипова, што је објашњено касније. Ова класификација се заснива на интеграцији следећих компоненти: геометријске карактеристике пута, ниво изложености саобраћају, врста и тежина саобраћајних незгода, као и просторно-временска стабилност. Кроз ову типологију омогућено је прецизније разумевање механизма који стоје иза настанка и трајности ризика на одређеним локацијама.

Већина доступних публикованих истраживања фокусира се превасходно на статистичку детекцију високоризичних локација – опасних места. Иако неки аутори истичу важност тежине последица или елемената инфраструктурног ризика, изостаје формализовани оквир који интегрише све кључне димензије – инфраструктуру, проток, изложеност и тежину саобраћајних незгода – у јединствен систем класификације.

Овај део докторске дисертације управо попуњава ту празнину, уводећи вишедимензионални приступ идентификацији и категоризацији опасних места, са циљем стварања функционалног алата за дубинску анализу ризика, стратешко планирање и приоритизацију интервенција на путној мрежи у Србији.

У наставку докторске дисертације приказане су различите дефиниције и приступи формулацији појма опасног места.

Прецизна идентификација и дефинисање карактеристика опасних места представља један од централних изазова у области безбедности саобраћаја и били су предмет бројних емпиријских и теоријских истраживања (*Chang and Kim, 2012; Elyasi et al., 2016; Ghadi and Török, 2017b; Abuaddous et al., 2022*). У доступној литератури присутна је велика разноликост у приступима дефинисања овог појма, при чему се најчешће разликују три основне категорије: дефиниције засноване на моделима, статистичке дефиниције и нумеричке (праговне) дефиниције (*Elvik, 2007*). Свака од ових категорија ослања се на различите концептуалне основе и методолошке претпоставке, што указује на сложеност самог појма и на потребу за прилагођавањем дефиниције у складу са специфичним циљем истраживања.

У складу са циљем истраживања спроведеног у овом делу дисертације, било је неопходно формулисати јасне критеријуме за идентификацију опасних места и предложити радну дефиницију која ће бити у складу са постављеним истраживачким оквиром. Иако је у досадашњим радовима анализиран велики број различитих карактеристика, од саобраћајног оптерећења и инфраструктурних елемената до типова незгода и временске стабилности (*Elvik, 2007; Zovak et al., 2014; Borsos et al., 2016; Ghadi and Török, 2017b; Aziz and Ram, 2022*), у оквиру овог истраживања издвојен је ограничен, али репрезентативан број индикатора који на адекватан начин илуструју сложеност и вишеслојност појма опасних места у Србији.

Преглед одабраних карактеристика приказан је у Табели 2, која представља основу за даљу типологију и класификацију у оквиру коришћене методологије у овој докторској дисертацији.

Уочава се да у литератури постоје значајне разлике у начину дефинисања опасних места, нарочито када је реч о праговима вредности, односно минималном броју незгода који је потребан да би се одређена локација квалификовала као високоризична. Ове разлике одражавају различите националне приступе, институционалне капацитете и доступност података, те указују на потребу за флексибилним дефиницијама које могу бити прилагођене контексту анализе.

**Табела 2.** Преглед изабраних дефиниција и карактеристика опасних места (Šarić et al., 2016; Aziz and Ram, 2022; Karamanlis et al., 2023)

Регион	Држава	Пружање опасних места (m)	Временски оквир	Број саобраћајних незгода и опис
Африка	Тунис	1000	5 година	10 незгода са повређенима
Америка	Кентаки	н. п.*	3 године	5 незгода
Америка	Колорадо	н. п.	3 године	<ul style="list-style-type: none"> <li>• 7 незгода са материјалном штетом;</li> <li>• или 7 незгода са повређенима;</li> <li>• или 3 незгоде са погинулима.</li> </ul>
Азија	Индија	500	3 године	<ul style="list-style-type: none"> <li>• 5 незгода у 3 године;</li> <li>• или 10 незгода са погинулима у 3 године.</li> </ul>
Азија	Кина	н. п.	1 година, 5 година	<ul style="list-style-type: none"> <li>• 6 незгода са пешацима;</li> <li>• или 9 незгода са повређенима;</li> <li>• или 2 незгоде са погинулима у 5 година.</li> </ul>
Азија	Турска	1000	5 година	3 незгоде са повређенима
Аустралија	Нови Зеланд	30	5 година	5 или 3 незгоде
Европа	Аустрија	250	1 година, 5 година	3 или више незгода у 3 године са коефицијентом ризика минимум 0,8.
Европа	Белгија	100	3 године	3 незгоде у 3 године и скором приоритета изнад 15
Европа	Немачка	н. п.	1 година, 3 године	<p>Незгоде приказане на мапи чији број превазилази критичне вредности за било коју од следећих категорија:</p> <ul style="list-style-type: none"> <li>• једногодишња мапа – 5 незгода истог типа;</li> <li>• трогодишња мапа – 5 незгода са повређенима;</li> <li>• трогодишња мапа – 3 незгоде са погинулима.</li> </ul>
Европа	Мађарска	100 1000	3 године	3 незгоде
Европа	Норвешка	100	3 године, 5 година	4 незгоде са повређенима у 3 године на деоници од 100 m
Европа	Енглеска	300	3 године	12 незгода са повређенима
Европа	Хрватска	300 1000	1 година	Ако је $C_R$ (стопа незгода) $> C_{CR}$ (критична стопа незгода) подразумева се да незгоде нису последица случајности, па се због тога такво место сматра опасним местом
Европа	Чешка	250	1 година	3 незгоде са повређенима
Европа	Данска	н. п.	5 година	Најмање 4 незгоде

\* н. п. – нема доступних података

У оквиру овог истраживања усвојена је модификована дефиниција опасног места, која се заснива на препорукама и стандардима преузетим из европских пракси, али је додатно адаптирана у складу са специфичностима саобраћајне мреже и доступних података у Републици Србији. Оваква методолошка прилагодљивост омогућава примену предложене дефиниције у различитим просторним и институционалним контекстима, чиме се обезбеђује њена практична вредност и широка примењивост.

### 4.3 Методологија истраживања за потребе категоризације опасних места на саобраћајној мрежи IБ реда у Србији

Методолошки оквир коришћен у оквиру овог дела докторске дисертације комбинује просторно груписање, тестирање статистичке значајности и модел фази класификације. Циљ овог поглавља јесте да се опише ток и структура рада, док је поступак категоризације детаљно објашњен у резултатима рада.

#### 4.3.1 Подручје истраживања и извори података

За анализу опасних места у Србији је изабрана мрежа државних путева IБ реда (Слика 20).



**Слика 20.** Државни путеви IБ реда у Србији анализирани у овој докторској дисертацији (мрежа путева у складу са референтним системом из 2025. године)

Опште саобраћајно-пројектне карактеристике путева који припадају анализираној категорији приказане су у Табели 3. Табела обухвата кључне параметре који дефинишу

геометрију, функционалну класификацију и пројектне услове путне инфраструктуре и представља основу за разумевање контекста у коме се врши идентификација и класификација опасних места у оквиру овог истраживања.

**Табела 3.** Опште карактеристике анализираних мреже ванградских путева у Србији

Тип пута	$L_{pd}$	$V_{lmax}$	ПГДС
<b>Ванградски</b>	1 + 1 (2 + 1)	80	300–22.000

$L_{pd}$  – бр. трака по смеру;  $V_{lmax}$  – максимално ограничење брзине; ПГДС – просечан годишњи дневни саобраћај

У овом истраживању фокус је стављен на путеве категорије ИБ реда, што је утврђено као најприкладнији избор на основу више критеријума од значаја за спровођење аналитичког поступка:

- категорија ИБ реда обухвата најдужи део путне мреже у Републици Србији за коју су били доступни транспарентни, структурисани и редовно ажурирани подаци (*Public enterprise Roads of Serbia, 2025*), што је приказано у Табели 4;
- путеви ИБ реда бележе највећи годишњи број саобраћајних незгода у поређењу са другим категоријама (Табела 4), што је од суштинског значаја за спровођење статистички релевантних анализа (*Road Traffic Safety Agency, 2025*);
- путеви ИБ реда припадају ванградској мрежи путева ниже категорије у односу на ауто-путеве, који представљају највиши ниво у хијерархији саобраћајне инфраструктуре (категирија IA реда). Ауто-путеви су искључени из овог истраживања јер су пројектовани у складу са највишим стандардима безбедности и нивоа услуге – карактеришу их велики радијуси хоризонталних кривина, минимални попречни и уздужни нагиби, као и широке саобраћајне траке, што све заједно омогућава већу ефикасност и мањи ниво конфликта у саобраћају.

Пораст комплексности услова вожње доводи до повећања ризика од незгода (*Zhu et al., 2019; Awasthi et al., 2024*). Стога, у циљу испитивања ризичних зона у реалним, технички мање контролисаним условима, путеви ИБ реда представљају најрелевантнији предмет анализе у оквиру овог рада.

**Табела 4.** Дужина путне мреже и број незгода у Србији

Категорија пута	Дужина (km) у 2023	Број незгода у 2023
<b>IA</b>	962,8	1508
<b>IB</b>	4455,2	2323
<b>IIA</b>	7822,5	1933
<b>IIB</b>	3195,3	479

Подаци који се односе на карактеристике путева и саобраћајних оптерећења (Слика 21) прибављени су од стране Јавног предузећа „Путеви Србије”. Наведени подаци чине основу за анализу структурних и функционалних параметара путне мреже.

Подаци о саобраћајним незгодама (Слика 21) преузети су са званичне интернет странице Министарства унутрашњих послова Републике Србије (*Ministry of Interior of the Republic of Serbia*, 2026). Анализа је обухватила трогодишњи период, односно календарске године 2021, 2022. и 2023, што омогућава идентификацију временских образаца и поуздано праћење динамике опасних места.

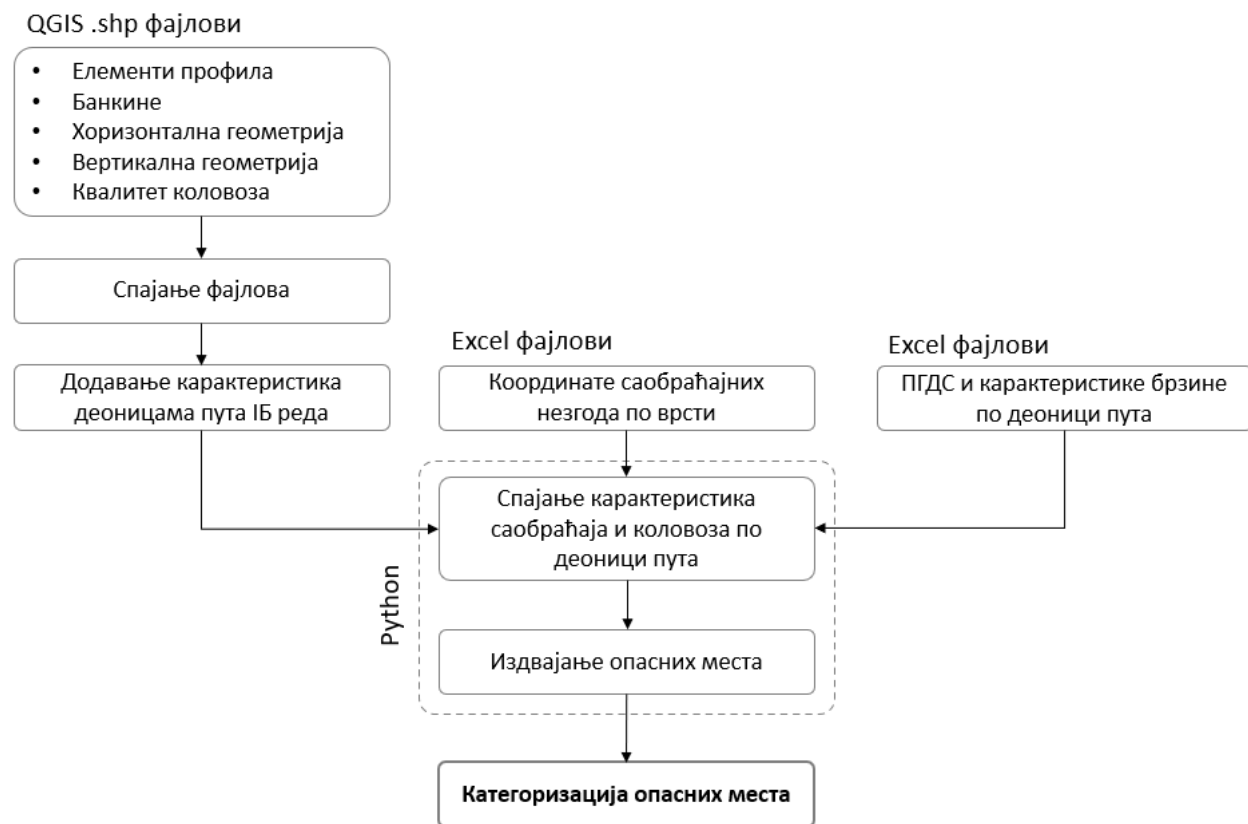
Карактеристике пута	Елементи профила	Карактеристике саобраћаја	ПДГС	Карактеристике саобраћајних незгода	Координате
	<ul style="list-style-type: none"> <li>• Број трака</li> <li>• Ширина коловоза</li> </ul>		<ul style="list-style-type: none"> <li>• Стандардно одступање ПДГС-а</li> </ul>		<ul style="list-style-type: none"> <li>• Дужина, ширина</li> </ul>
	Банкине		Брзина		Врста
	<ul style="list-style-type: none"> <li>• Ширина банке</li> <li>• Позиција банке</li> </ul>		<ul style="list-style-type: none"> <li>• Стандардно одступање брзине</li> <li>• % прекорачења брзине</li> <li>• % возила који прекорачују брзину за више од 20km/h</li> </ul>		<ul style="list-style-type: none"> <li>• Незгоде са материјалном штетом</li> <li>• Незгоде са повређенима</li> <li>• Незгоде са погинулима</li> </ul>
	Хоризонтална геометрија				
	<ul style="list-style-type: none"> <li>• Елемент</li> <li>• Радијус</li> <li>• Дужина радијуса</li> </ul>				
Вертикална геометрија					
<ul style="list-style-type: none"> <li>• Елемент</li> <li>• Нагиб</li> <li>• Дужина нагиба</li> </ul>					
Квалитет коловоза					
<ul style="list-style-type: none"> <li>• ИРИ</li> </ul>					

Слика 21. Улазни подаци коришћени за категоризацију опасних места у Србији

#### 4.3.2 Алати и софтвери

За анализу су коришћена три комплементарна алата. QGIS 3.26.3 је коришћен за просторну анализу, укључујући почетне манипулације датотекама, визуелизацију итд. MS Excel је коришћен за „пречишћавање” података, припрему и прелиминарна филтрирања. Python 3.10 је коришћен за алгоритамску имплементацију, укључујући логику кластеровања, статистичку верификацију и фази класификацију.

Ток рада је пратио редослед илустрован на Слици 22, који обухвата кораке од уноса основног скупа података до коначне категоризације опасних места.



Слика 22. Кораци алгоритма у оквиру израђене методологије за категоризацију опасних места

### 4.3.3 Идентификација опасних места

Први корак у оквиру приказане методологије јесте издвајање кандидата за опасна места. У ту сврху примењено је правило груписања засновано на близини. Постављен је услов минималне учесталости (најмање четири незгоде годишње) у комбинацији са просторним ограничењима (међусобна просторна удаљеност незгода не треба да износи више од 250 m између узастопних незгода). Поред тога, постављен је додатни услов: дужина кластера дуж пута није смела прећи 1000 m. У супротном, примењене су процедуре поделе коришћењем покретног прозора (енг. *Sliding window*) за локализацију места већег накупљања незгода.

Овај приступ се ослања на добру међународну праксу, са праговима калибрисаним према европским референтним вредностима. Улога оваквог приступа није само да пружи коначну класификацију већ и да осигура да се локације са високим бројем незгода идентификују као кандидати за даље тестирање. Детаљне једначине и услови за ову фазу представљени су у наредним поглављима, где је предложена методологија примењена на мрежи државних путева IB реда у Србији.

### 4.3.4 Тестирање статистичке значајности идентификованих опасних места

Кластери кандидати морају се разликовати од случајно насталих кластера. Да би се задовољио наведени услов, друга фаза подразумева тестирање статистичке значајности.

Број незгода се трансформише у стопе незгода, узимајући у обзир изложеност саобраћају и упоређује се са критичним вредностима које обухватају просеке и варијансу на нивоу целе мреже.

Примењују се два комплементарна критеријума (прага тестирања): стопа заснована на учесталости незгода и стопа пондерисана тежином. Овај двоструки начин анализе осигурава да се опасна места са мање незгода али са већим последицама не превиђају. Кластери се задржавају ако се пређе било који праг.

Овај корак верификације спроводи се као филтер: само локације са статистички значајним ризиком остају у скупу података потврђених опасних места. Математичке формуле за стопу незгода ( $TA_r$ ), тежину ( $TAS_r$ ) и критичне прагове ( $CTA_r$ ) дати су у поглављу 4.4.2.

#### 4.3.5 Фази категоризација

Претпоследња фаза јесте категоризација верификованих опасних места. Конвенционални приступи додељују сваку локацију (свако опасно место) једном типу на основу стриктно дефинисаних прагова. Међутим, путно окружење може варирати, а саме карактеристике (елементи) путева могу често бити делови различитих категорија.

Табела 5. Предложена категоризација опасних места и њихове карактеристике

Категорија	(Q, E, S) комбинације	Опис
<b>Експлозивно опасно место</b>	(добар, средња, висока) (добар, велика, висока) (лош, средња, висока) (лош, велика, висока)	Висока тежина последица уз средњу/високу изложеност, без обзира на геометрију. Незгоде са погинулима концентрисане у кратким периодима, велика варијабилност, висок $TAS_r$ .
<b>Тихо опасно место</b>	(лош, мала, висока) (добар, мала, висока)	Висока тежина последица упркос ниској изложености. Ниска учесталост, али висок удео тежих последица.
<b>Флукутирајуће опасно место</b>	(лош, велика, ниска) (лош, средња, ниска)	Лоша инфраструктура, ниска тежина последица, уз високу изложеност.
<b>Инертно опасно место</b>	(лош, мала, ниска)	Лош квалитет коловоза уз малу изложеност и ниску тежину последица.
<b>Аномално опасно место</b>	(добар, средња, ниска) (добар, мала, ниска)	Повољни услови и ниске последице незгода, стабилно ниске стопе током година.
<b>Опасно место са опраштајућим карактеристикама</b>	(добар, велика, ниска)	Висок обим саобраћаја, али ниска тежина последица, висока изложеност, али контролисани исходи незгода; низак $TAS_r$ .

$TAS_r$  – стопа тежине саобраћајних незгода

На пример, ширина траке од 3 m или 3,5 m може бити гранична, обим саобраћаја може варирати око прагова категорије, а тежина може варирати из године у годину. То практично значи да један кластер (опасно место) може имати карактеристике више подврста (поткатегорија) опасних места, односно може припадати двома поткатегоријама опасних места.

Како би се манипулисало наведеним подацима и кластерима дале одговарајуће категорије, уведена је фази логика. Уместо бинарног приступа, свака објашњавајућа димензија (квалитет пута (Q), изложеност (E) и тежина саобраћајних незгода (S)) представљена је фази скуповима са трапезоидним или троугластим функцијама припадности. Ови скупови омогућавају делимично припадање вишеструким категоријама истовремено.

Композитне вредности припадања се затим комбинују у фази правила која дефинишу шест концептуалних категорија опасних места (експлозивне, тихе, места са опасном геометријом, деградиране локације, аномалне локације и опасна места са опраштајућим карактеристикама, Табела 5). Овај принцип омогућава преклапање категорија, одражавајући адекватније реално стање на терену.

#### **4.3.6 Валидација и унапређење израђеног фази модела**

Последња фаза обухвата валидацију израђеног фази модела. Оптимизација параметара функција припадности извршена је применом еволуционог алгорита диференцијалне еволуције (енг. Differential Evolution) имплементираног у програмском окружењу Python 3.10. Овај алгорита је изабран јер представља робусну глобалну оптимизациону технику погодну за нелинеарне и недиференцијабилне проблеме који су типично присутни у оптимизацији параметара функција припадности у фази системима. Предност овог алгорита је што не захтева израчунавање градијента функције циља и ефикасно претражује сложене просторе параметара, што га чини погодним за оптимизацију фази модела са више међусобно зависних параметара.

У анализи је акценат стављен на испитивање робусности и унутрашње кохерентности фази система, укључујући процену стабилности, анализу преклапања суседних функција припадности и испитивање осетљивости параметара. На тај начин је омогућена методолошка провера и унапређење нумеричке конзистентности модела, уз очување концептуалне структуре и логике одлучивања дефинисане у претходним корацима.

Простор претраге параметара функција припадности ограничен је на интервал  $\pm 10\%$  у односу на оригинално дефинисане вредности. Ово ограничење уведено је како би се очувала експертски дефинисана структура фази система и спречило нереално преобликовање функција припадности током оптимизације.

Валидација модела вршена је кроз следеће анализе:

##### **Анализа прецизности функција припадности:**

Анализа прецизности функција припадности коришћена је за процену квалитета расподеле вредности унутар фази скупова. У овој анализи се „кажњавају” ситуације у којима ниједна

функција нема довољно висок степен припадности или када је разлика између две највеће припадности мала. Овај корак рађен је коришћењем једначине:

$$\text{вар}_{\text{казна}} = \frac{1}{N} \sum_{j=1}^N \left[ \left( 1 - m_1(x_j) \right) + \max(0, \Phi - \sum_i \mu_i(x_i)) + \max(0, m - (m_1(x_j) - m_2(x_j))) \right] \quad (25)$$

Где су:

$m_1$  – највећи степен припадности;

$m_2$  – други по величини степен припадности;

$\Phi$  – минимална покривеност функција припадности;

$m$  – минимална разлика између две највеће припадности.

Овај корак је урађен како би се сачувала интерпретабилност и избегло нереално преобликовање фази бројева.

#### **Анализа конфликта:**

Анализа конфликта (једначина 26) процењује степен неодређености у процесу класификације. У овој анализи посматра се разлика између степена припадности две најактивније категорије за сваки узорак. Ако је та разлика мала, сматра се да постоји конфликт у одлучивању јер систем није у стању да јасно разликује између две потенцијалне категорије.

$$\text{конф}_{\text{казна}} = \frac{1}{N} \sum_{j=1}^N \left[ \max(0, w_{\min} - w_j) + \max(0, c_{\min} - (w_j - s_j)) \right] \quad (26)$$

Где су:

$w_j$  – степен припадности доминантне категорије;

$s_j$  – степен припадности друге категорије;

$c_{\min}$  – минимална разлика између категорија;

$w_{\min}$  – минимална јачина победничке категорије.

Овај параметар има за циљ да обезбеди јаснију диференцијацију између категорија опасних места.

#### **Анализа стабилности:**

Стабилност класификације је процењена поређењем класа добијених са оригиналним функцијама припадности и онима добијеним након оптимизације. Овај приступ омогућава да се утврди да ли оптимизација функције припадности доводи до промена у доминантном распоређивању самих категорија. Овај параметар мери робусност класификације помоћу следеће једначине:

$$\text{стаб}_{\text{стопа}} = \frac{\text{број узорака који је променио класу}}{\text{укупан број узорака}} \quad (27)$$

Важно је напоменути да је број узорака који су променили класу одређен рекласификацијом свих узорака са оптимизованим функцијама припадности и њиховим упоређивањем са почетним функцијама припадности. Процент промена је затим израчунат да би се проценило да ли је оптимизација параметара функције припадности променила коначну категорију опасног места. Ова процедура је спроведена да би се проверила структурна стабилност система класификације након оптимизације.

Функција циља је дефинисана на следећи начин:

$$\Phi_{\text{Ц}} = w_1 \text{вар}_{\text{казна}} + w_2 \text{конф}_{\text{казна}} + w_3 \text{стаб}_{\text{стопа}} \quad (28)$$

Минимизација функције циља извршена је применом алгоритма диференцијалне еволуције, који итеративно претражује простор параметара функција припадности у задатом интервалу. Тежине у функцији ( $w_1$ ,  $w_2$ ,  $w_3$ ) циља нису биране да би се унапредиле перформансе модела, већ да би се спровела фазихијерархијска оптимизација. Робусност класификације третирана је као примарно ограничење. Међу робусним решењима, казна за конфликт је минимизирана како би се смањило преклапање између суседних лингвистичких термина. Казна за варијансу ограничила је прекомерно одступање од облика које је дефинисао експерт како би се сачувала интерпретабилност, стога тежине представљају редослед приоритета, а не параметре за унапређење ефикасности модела.

#### **4.4 Резултати развоја методологије за категоризацију опасних места на државним путевима IБ реда у Србији, за период од 2021. до 2023. године**

Ово поглавље је подељено на неколико делова. Први део садржи кратак опис општег скупа података који се користи за изоловање опасних места. Објашњење идентификације (изоловања) опасних места дато је у другом одељку. Процес припреме података и поткатегоризације опасних места описан је у трећем делу, док је примена предложене методологије дата у четвртом поглављу.

##### **4.4.1 Основне карактеристике улазних података**

Анализа је обухватила укупно 186 деоница државних путева IБ реда, које представљају репрезентативни узорак у оквиру просторног опсега овог истраживања.

Табела 6 приказује опште карактеристике наведених деоница, укључујући параметре као што су дужина, број саобраћајних трака, просечан годишњи дневни саобраћај (ПГДС), геометријске карактеристике и друге релевантне атрибуте, који су послужили као основ за интеграцију са подацима о саобраћајним незгодама и класификацију ризичних локација.

Поред основних параметара база података обухватала је и категоричке променљиве које су омогућиле прецизније просторно-функционално профилисање сваке анализиране деонице. Конкретно, за сваку деоницу је назначено да ли се она налази у хоризонталној кривини или на праволинијском делу пута, при чему вредност 1 означава присуство кривине, а 0 правац.

Сличан бинарни код користио се и за означавање позитивног или негативног вертикалног нагиба, што је такође кодирано вредностима 1 и 0, у складу са геометријским својствима терена.

**Табела 6.** Карактеристике анализираних деоница државних путева IБ реда у Србији

Карактеристика	Минимум	Максимум	Просек	Std Dev
Дужина деонице (km)	0,75	39,05	13,70	8,56
Ширина банке (m)	0,00	3,85	1,35	0,46
Ширина коловоза (m)	3,40	16,50	7,40	1,52
Број саобраћајних трака	1,00	4,00	2,00	0,11
Ширина саобраћајних трака* (m)	2,75	3,75	3,40	0,75
Квалитет површине коловоза (ИРИ)	0,58	15,97	2,87	1,62
Дужина хориз. кривине (m)	11,07	6216,40	462,94	597,84
Радијус хориз. кривине (m)	30,00	5000,00	659,83	2921,65
Вертикални нагиб (%)	-8,60	9,30	0,00	1,57
ПГДС (воз/дан)	318,00	21177,00	7202,44	4324,07
Брзина (km/h)	33,85	90,03	69,07	8,54
% прекорачења брзине	0,00	99,00	49,00	29,00
% прекорачења за више од 20km/h	0,00	81,00	14,00	15,00

\* Због непостојања прецизних података о ширини трака, ширина траке је процењена дељењем ширине коловоза са бројем трака.


Осим тога, база садржи географске координате за сваку појединачну саобраћајну незгоду, што омогућава просторну везу између догађаја и структуре пута. За сваку незгоду било је назначено којој врсти припада, да ли се ради о незгодама са материјалном штетом, са повређеним лицима или са погинулим учесницима, чиме је омогућено касније типолошко рангирање локација по тежини последица.

#### 4.4.2 Идентификација и валидација опасних места у Србији

Узимајући у обзир разноврсност постојећих дефиниција опасних места у литератури, у оквиру овог истраживања примењена је модификована дефиниција, прилагођена конкретном контексту анализе и заснована на стандардима који се користе у неким европским земљама, попут Норвешке и Данске (Табела 2).

Сходно томе, опасно место је у овом раду дефинисано као **локација на којој се годишње догоде најмање четири саобраћајне незгоде било ког типа**. Поред квантитативног критеријума укључени су и просторни услови за груписање незгода: удаљеност између било које две узастопне незгоде не сме прелазити 250 m (иницијални услов за просторну агрегацију), док максимално растојање између најудаљенијих незгода унутар исте групе не сме прећи 1000 m.

Ови критеријуми су примењени у просторној анализи уз подршку QGIS алата, а илустративни приказ просторне логике груписања дат је на Слици 23.



**Слика 23.** Неоздама груписане на деоници пута краћој од 1 km, са међусобним растојањем од највише 250 m

За овај део процеса почетно груписање засновано је на међусобном растојању (близини) саобраћајних неоздама. То значи да се неоздама које се дешавају у непосредној близини, односно на растојању не већем од 250 m једна од друге, могу сматрати делом исте просторне групе. Овај критеријум се користи како би се идентификовале зоне повећаног ризика, односно потенцијална опасна места, која представљају подручја са просторно концентрисаним појавама неоздама.

У складу са претходно описаним текстом, нека је:

$A = \{a_1, a_2, \dots, a_n\}$  скуп неоздама у датој години,

Свака неоздама  $a_i$  догађа се на локацији  $s(a_i)$  дуж одређеног пута/деонице,

$d(a_i, a_j)$  представља најкраћи пут између пара неоздама  $a_i$  и  $a_j$  рачунат дуж реалне деонице.

Иницијални кластер неоздама дефинисан је условом  $C \subseteq A$ , као сет неоздама који задовољава следеће критеријуме:

Услов учесталости:

$$|C| \geq 4 \quad (29)$$

Услов близине:

$$\forall a_i, a_j \in C, \exists \text{ веза } a_i \rightarrow a_k \rightarrow \dots \rightarrow a_j \text{ тако да важи } d(a_k, a_{k+1}) \leq 250m \quad (30)$$

С обзиром на то да су у питању деонице ванградских путева, овај приступ омогућава да се у анализу укључе шира подручја и додатни фактори који могу утицати на настанак саобраћајних неоздама. За потребе овог дела истраживања модел за дефинисање почетне удаљености између неоздама заснован је на упоредивим моделима из међународне праксе: од 30 m у Новом Зеланду, преко 100 m у Белгији и Норвешкој, до 250 m у Аустрији и Чешкој, те 300 m у Енглеској.

У дисертацији је усвојен праг од 250 m у складу са праксом Аустрије и Чешке (Табела 2). Ова удаљеност оцењена је као најприкладнија за кластерисање неоздама на ванградским деоницама IB реда јер обезбеђује балансирану идентификацију зона са просторно концентрисаним неоздамама. Овај приступ са једне стране омогућава да се повежу неоздама

које су географски блиске и потенцијално повезане, док са друге стране спречава формирање превише просторно распрострањених и непрактично великих кластера. Удаљеност од 250 m такође је усклађена са европским стандардима и у складу је са реалним просторним распоредом незгода на посматраној категорији путева у Србији.


Глобално ограничење дужине кластера:

$$\max_{a_1, a_n \in C} d(a_1, a_n) \leq 1000 \text{ m} \quad (31)$$

Кластери који испуњавају сва три постављена услова – најмање четири саобраћајне незгоде годишње, међусобно растојање незгода до 250 m и укупно растојање незгода мање од 1000 m – категоришу се као опасна места.

Уколико се, међутим, утврди да се подручје кластера простире на дужини већој од 1000 m, то указује да се незгоде догађају континуирано, унутар растојања мањег од 250 m. Такав образац карактеристичан је за просторе са високим протоком возила и комплексним саобраћајним условима, као што су велике раскрснице, зона прикључења или искључења са ауто-пута и делови урбане мреже.

У тим случајевима, да би се избегла „обимна” генерализација, уводи се техника сегментације дужине на мање делове. Овај процес подразумева примену клизног прозора дужине 150 m, који се постепено „помера” преко целокупне дужине иницијалног кластера. На тај начин, уместо једног опасног места које се простире на већој дужини деонице, добија се једна или више зона са већим бројем незгода (Слика 24).



**Слика 24.** Незгоде груписане на деоници пута дужој од 1 km, са међусобним растојањем од 150 m

За овај случај, дељење проширеног кластера врши се на следећи начин:

Ако иницијални кластер  $C$  крши глобално ограничење дужине кластера, онда је иницијални кластер подељен коришћењем приступа „покретног прозора”, како би се локализовала концентрација незгода:

$$\max_{a_1, a_n \in C} d(a_1, a_n) > 1000 \text{ m} \quad (32)$$

Дужина прозора од  $w = 150 \text{ m}$  коришћена је за добијање новог подскопа незгода, при чему се прозор помера унапред за корак  $\delta = 10 \text{ m}$ . Овакав приступ омогућава прецизније детектовање локалних концентрација незгода и спречава да дугачке деонице буду

класификоване као једно опасно место. Уместо тога, идентификују се ужи сегменти са стварном концентрацијом незгода, што омогућава циљано деловање и прилагођавање конкретне мере локацијским специфичностима. Сходно томе, прозор на позицији  $x$  обухвата све саобраћајне незгоде чије се координате налазе у интервалу:

$$W(x) = \{a_i \in C | x \leq s(a_i) < x + 150\} \quad (33)$$

За сваки прозор  $W(x)$ , ако је задовољено:

$$|W(x)| \geq 4 \quad (34)$$

Такво подручје се дефинише као локално опасно место. Коначан скуп опасних места добија се на следећи начин:

$$\beta = C_{valid} \cup C_{split} \quad (35)$$

Где су:

$C_{valid}$  – скупови/кластери који задовољавају све услове у оквиру иницијалног издвајања опасних места;

$C_{split}$  – подскупови опасних места добијени на основу покретног „прозора”.

Након просторног издвајања опасних места кандидата, спроведена је друга фаза верификације: анализа статистичке значајности на основу које би се од потенцијалних опасних места добила „коначна” опасна места на мрежи. За анализу статистичке значајности коришћен је модификован хрватски модел (*Šarić et al., 2016*), који је изабран због просторне, саобраћајне и мрежне сличности двеју земаља.

Хрватски модел (*Šarić et al., 2016*) заснива се на поређењу стопе саобраћајних незгода ( $TA_r$ ) и критичне стопе саобраћајних незгода ( $C_{TA_r}$ ).  $TA_r$  се израчунава на основу једначине 36, док је за потребе овог истраживања формулисан додатни параметар: стопа тежине саобраћајних незгода ( $TAS_r$  – једначина 37).

$$TA_r = \frac{N}{M} \quad (36)$$

$$TAS_r = \frac{\sum \text{severity score}}{M} \quad (37)$$

Где је:

$N$  – број саобраћајних незгода у кластеру;

$M$  – изложеност у саобраћају, израчунато према једначини 38.

$$M = \frac{Q \cdot d \cdot 365}{10^6} \quad (38)$$

Где је:

$Q$  – просечан годишњи дневни саобраћај;

$d$  – дужина деонице.

У циљу стабилизације прорачуна и минимизације грешке, извршена је процена просечне стопе незгода на нивоу целе мреже ( $TAA_r$ ) и процена просечне тежине незгода ( $TASA_r$ ) током анализираниог периода (Једначина 39). На овај начин спречава се формирање грешака услед евентуалног непостојања одређених података и сл.

$$TAA_r = \overline{TA}_r \text{ и } TASA_r = \overline{TAS}_r \quad (39)$$

Критична стопа саобраћајних незгода ( $CTA_r$ ) прорачунава се на основу једначине 40.

$$CTA_r = TAA_r + k * \sqrt{\frac{TAA_r}{M}} + \frac{1}{2 * M} \quad (40)$$

где је  $k$  ниво коефицијента статистичке значајности (*Šarić et al.*, 2016).

$CTA_r$  се израчунава одвојено за метрике засноване на броју и метрике засноване на тежини ( $TAA_r$ ,  $TASA_r$ ).

На крају се кластер (опасно место) задржава ако је било који услов (метрика) задовољен:

- примарни критеријум:  $TA_r > CTA_r$ ;
- секундарни критеријум:  $TAS_r > CTAS_r$ .


На овај начин избегнута је ситуација у којој би кластеру припадале саобраћајне незгоде настале као последица случајности, док се са друге стране осигурава да локације са високом тежином (локације са незгодама са повређенима и/или са погинулима) не буду одбачене искључиво због малог броја незгода ( $N$ ). Након издвајања и анализе опасних места, добијени општи резултати приказани су у Табели 7.

**Табела 7.** Карактеристике опасних места након њихове идентификације

Карактеристика	2021	2022	2023
	просек	просек	просек
Дужина одсека (km)	12,4	12,7	14,4
Ширина саобраћајне траке (m)	3,1	3,3	3,2
Квалитет површине коловоза (ИРИ)	4,12	3,64	3,11
Радијус (m)	211,4	589,5	95,0
Вертикални нагиб (%)	-0,67	0,36	-2,9
ПГДС (воз/дан)	3888	5918	4026
Брзина (km/h)	73,4	61,8	62,3
% прекорачења брзине	39,0	52,0	7,0
% прекорачења за више од 20 km/h	9,0	14,0	0,4
Број опасних места	8	7	1

Чињеница да укупан број опасних места бележи континуиран пад од 2021. године представља занимљив резултат. Међутим, важно је истаћи да се ова опасна места значајно разликују у погледу своје просторне стабилности. Нека опасна места су временом нестала, док су се друга појавиле на потпуно другим локацијама. Слика 25 приказује одрживост опасних места кроз временски оквир од три анализирание године. Само једно опасно место

је остало на истој микролокацији током двогодишњег периода (означено црвеном бојом на Слици 25). Сва остала опасна места – 7 у 2021. години, 6 у 2022. години и 1 у 2023. години – појавила су се на различитим локацијама. Иако ова статистика може, привидно, деловати добро, због малог броја одрживих опасних места, преостали број опасних места заправо представља највећи проблем. Због просторног померања микролокације, већина опасних места појављује се само у једној години пре него што нестане до краја периода истраживања, што их чини много опаснијим и тежим за лоцирање. Стога је очекивано предвидети да ће већи број опасних места постати динамичан у блиској будућности, што сугерише потребу за усвајањем проактивних, а не реактивних стратегија за решавање овог проблема.



Слика 25. Варијабилност опасних места у времену, за подручје Србије

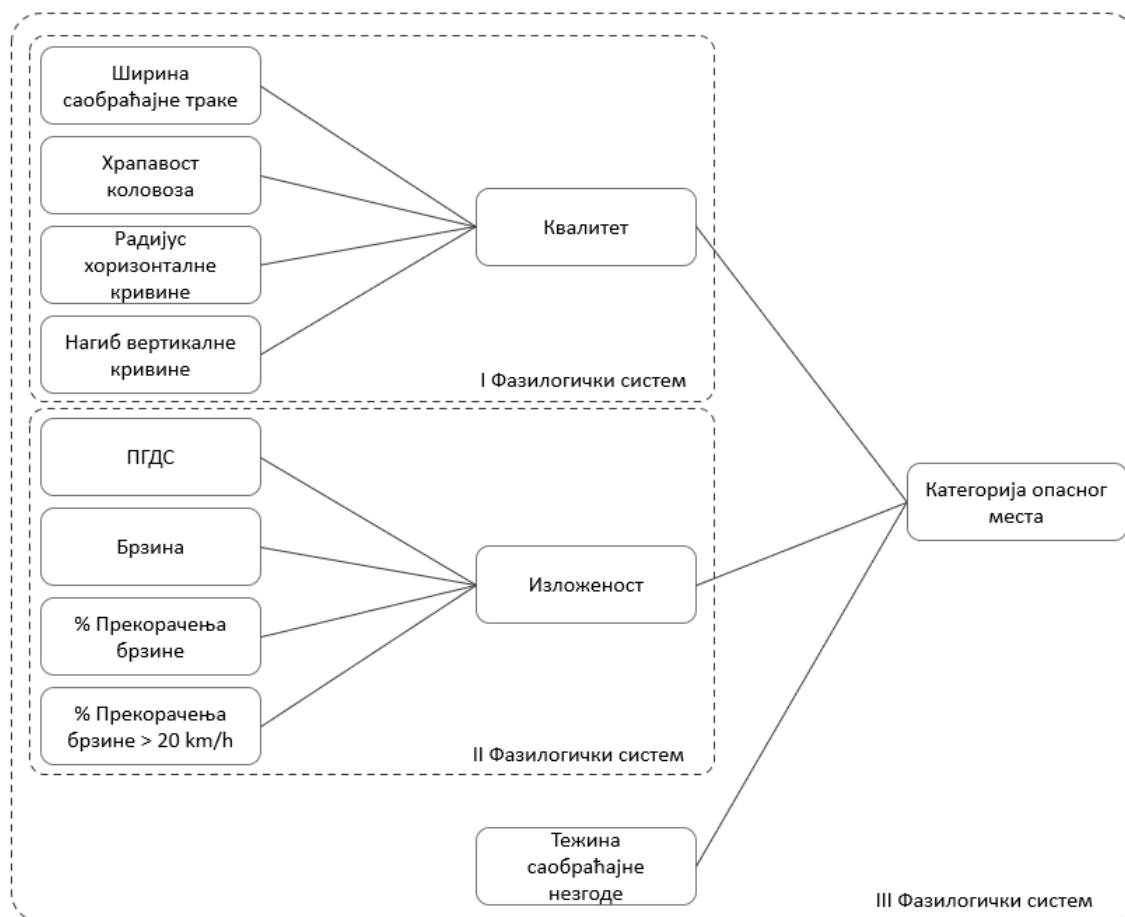
#### 4.4.3 Фази категоризација опасних места у Србији

Идентификација подручја са високим бројем незгода (као што је наведено у претходним поглављима) пружила је основу за дефинисање опасних места. Међутим, да би се ова подручја трансформисала у локације које би пружале корисне информације за доношење одлука, био је потребан додатни корак – поткатегоризација. Циљ овог корака био је да се свако опасно место додели одговарајућем типу, чиме би се интервенције усмериле не само према локацији већ и према основном механизму проблема. Поткатегоризација је извршена применом фази логике и то тако што на излазну променљиву (категорија опасног места) утичу улазне променљиве: квалитет пута (Q), изложеност саобраћају (E) и тежина саобраћајних незгода (S), као што је приказано на Слици 26.

Како би се формирале адекватне поткатегорије опасних места, извршена је фазификација улазних променљивих (квалитет, изложеност и тежина саобраћајних незгода) у односу на главне параметре који на њих утичу. Даље, да би се правилно моделирао проблем, прве две улазне променљиве представљају излаз из сопственог фазилогичког система у коме улазне променљиве чине респективно:

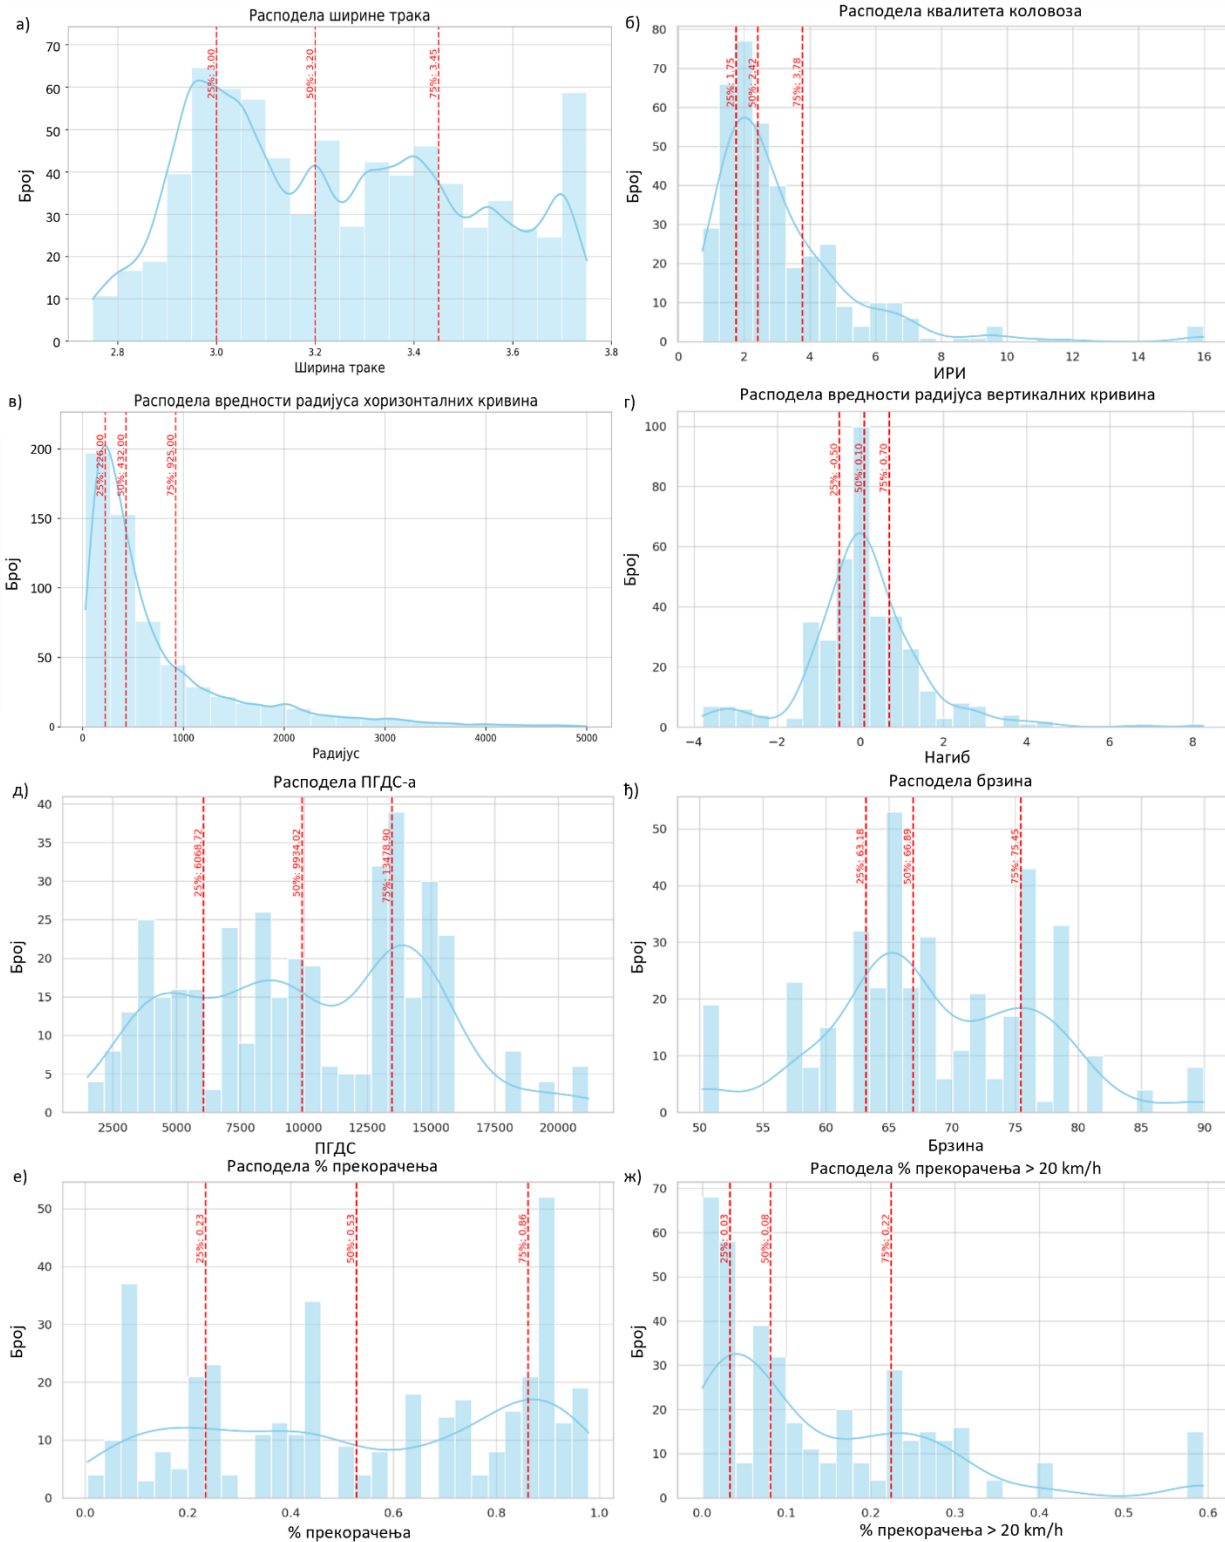
- квалитет: ширина траке (m), храпавост, хоризонтални нагиб (m) и вертикални нагиб (%);
- изложеност: ПГДС (воз/дан), брзина (km/h), % прекорачења брзине (%), % прекорачења брзине за више од 20 km/h.

Додатно, тежина саобраћајних незгода представља пондерисан број саобраћајних незгода на одређеној локацији.



**Слика 26.** Фазилогички систем за категоризацију опасних места

Свака улазна/излазна променљива покривена је одређеним бројем функција припадности. Функције припадности одређене су на основу постојећих расподела улазних променљивих приказаних на Слици 27.

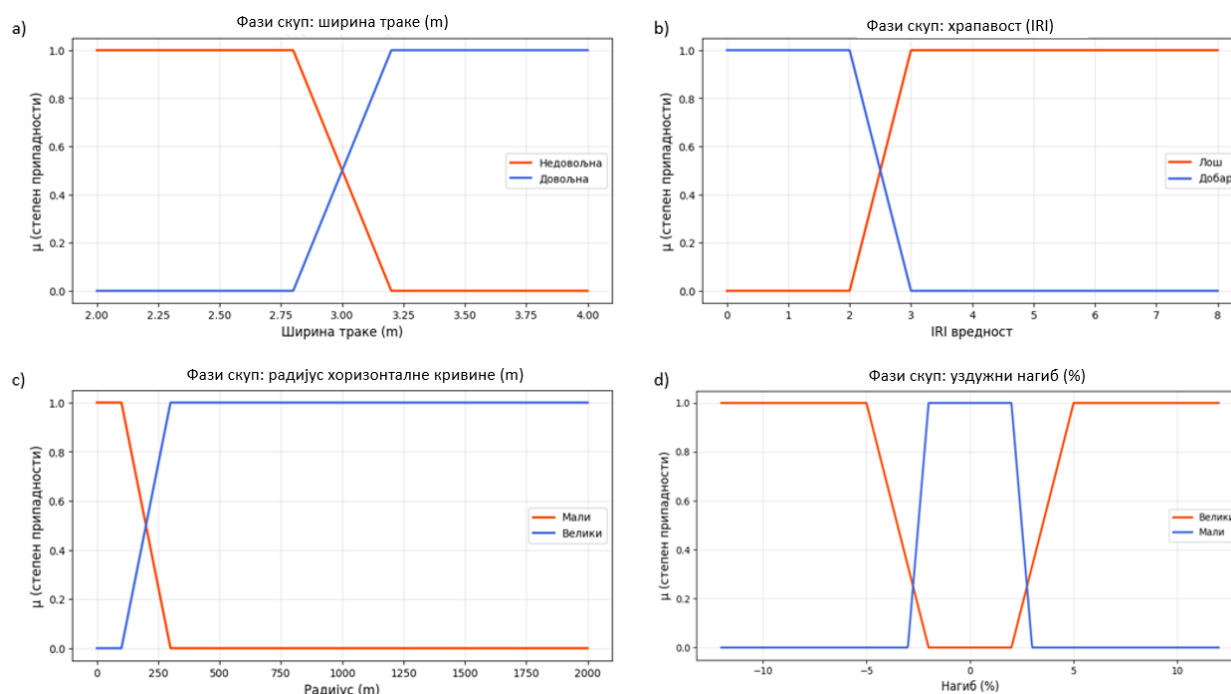


Слика 27. Дистрибуција вредности променљивих: а) ширина траке, б) ири, в) радијус, г) вертикални нагиб, д) ПГДС, њ) брзина, е) % прекорачења, ж) % прекорачења за више од 20 km/h и назначени 25, 50. и 75. перцентил

Функције припадности фази бројева у оквиру прве улазне променљиве (*Квалитет коловоза*) приказане су у Табели 8, док је визуелизација сваког фази броја дата на Слици 28.

**Табела 8.** Функције припадности фази бројева за улазну променљиву *Квалитет коловоза*

Ширина саобраћајне траке (m)		
Категорија	Тип	Функција прип. (a, b, c, d)
Недовољна	Леви трапез	(0,0, 0,0, 2,8, 3,2)
Довољна	Десни трапез	(2,8, 3,2, 3,6, 4,0)
Храпавост (СРТ)		
Категорија	Тип	Функција прип. (a, b, c, d)
Добар	Леви трапез	(0,0, 0,0, 2,0, 3,0)
Лош	Десни трапез	(2,0, 3,0, 6,0, 8,0)
Радијус хоризонталне кривине (m)		
Категорија	Тип	Функција прип. (a, b, c, d)
Мали	Леви трапез	(0, 0, 100, 300)
Велики	Десни трапез	(100, 300, 1000, 2000)
Нагиб вертикалне кривине (%)		
Категорија	Тип	Функција прип. (a, b, c, d)
Мали	Трапезоидна	(-3, -2, 2, 3)
Велики	Комбинована (два трапеза)	(2, 5, 7, 10) ∪ (-10, -7, -5, -2)



**Слика 28.** Функције припадности улазних променљивих: а) ширина траке, б) храпавост коловоза, с) радијус хоризонталне кривине, д) уздужни нагиб

Поред поменутог, у наставку је дат и аналитички запис фази бројева приказаних у претходној табели.

*Ширина траке:*

$$\mu_{\text{недовољна}}(x) = \begin{cases} 1, & x \leq 2,8 \\ 2,5(3,2 - x), & 2,8 < x \leq 3,2 \\ 0, & x > 3,2 \end{cases} \quad (41)$$

$$\mu_{\text{довољна}}(x) = \begin{cases} 0, & x \leq 2,8 \\ 2,5(x - 2,8), & 2,8 < x \leq 3,2 \\ 1, & x > 3,2 \end{cases} \quad (42)$$

*Храпавост:*

$$\mu_{\text{добар}}(x) = \begin{cases} 1, & x \leq 2,0 \\ (3 - x), & 2 < x \leq 3 \\ 0, & x > 3 \end{cases} \quad (43)$$

$$\mu_{\text{лош}}(x) = \begin{cases} 0, & x \leq 2 \\ (x - 2), & 2 < x \leq 3 \\ 1, & x > 3 \end{cases} \quad (44)$$

*Радијус хоризонталне кривине:*

$$\mu_{\text{мали}}(x) = \begin{cases} 1, & x \leq 100 \\ 0,005(300 - x), & 100 < x \leq 300 \\ 0, & x > 300 \end{cases} \quad (45)$$

$$\mu_{\text{велики}}(x) = \begin{cases} 0, & x \leq 100 \\ 0,005(x - 100), & 100 < x \leq 300 \\ 1, & x > 300 \end{cases} \quad (46)$$


*Нагиб вертикалне кривине:*

$$\mu_{\text{мали}}(x) = \begin{cases} 0, & x \leq -3 \\ (x + 3), & -3 < x \leq -2 \\ 1, & -2 < x \leq 2 \\ (3 - x), & 2 < x \leq 3 \\ 0, & x > 3 \end{cases} \quad (47)$$

$$\mu_{\text{велики}+}(x) = \begin{cases} 0, & x \leq 2 \\ 0,333(x - 2), & 2 < x \leq 5 \\ 1, & x > 5 \end{cases} \quad (48)$$

$$\mu_{\text{велики}-}(x) = \begin{cases} 1, & x \leq -5 \\ 0,333(-2 - x), & -5 < x \leq -2 \\ 0, & x > -2 \end{cases} \quad (49)$$

Сходно наведеном, функције припадности за излазну променљиву *Квалитет* могу се приказати помоћу два фази скупа (Слика 29 и једначине 50 и 51): лош квалитет (0, 0, 0,3, 0,6) и добар квалитет (0,4, 0,7, 1, 1).



Слика 29. Функција припадности излазне променљиве *Квалитет*

$$\mu_{\text{лош}}(x) = \begin{cases} 1, & x \leq 0,3 \\ 3,333(0,6 - x), & 0,3 < x \leq 0,6 \\ 0, & x > 0,6 \end{cases} \quad (50)$$

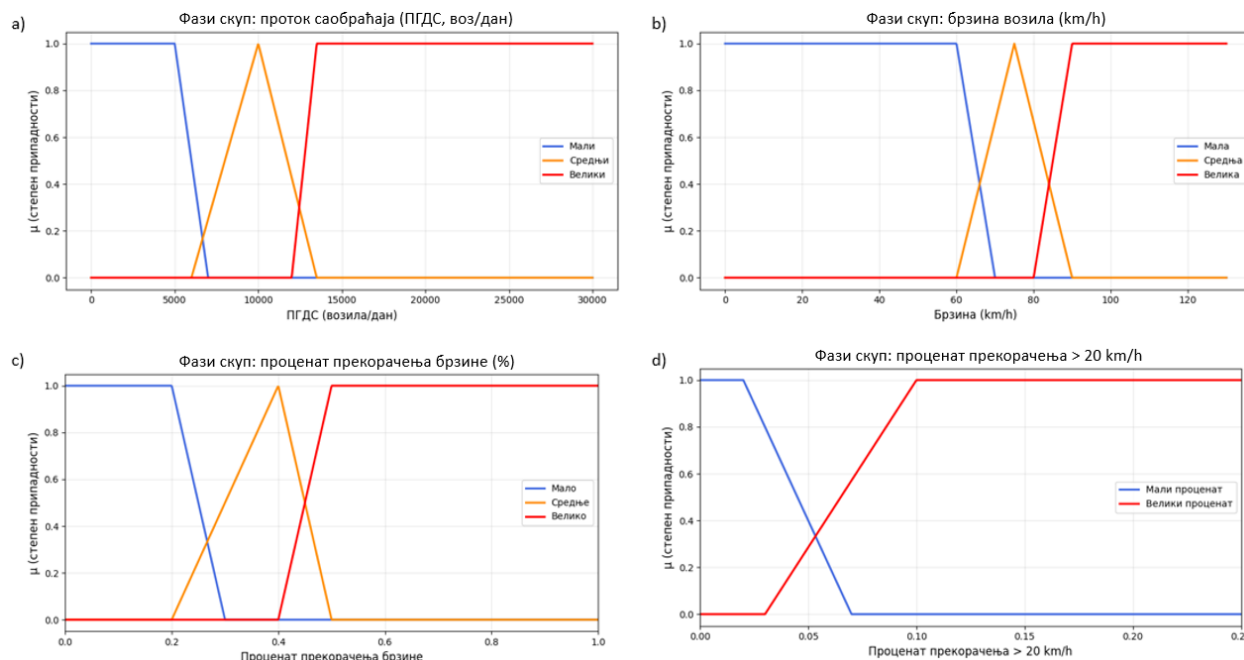
$$\mu_{\text{добар}}(x) = \begin{cases} 0, & x \leq 0,4 \\ 3,333(x - 0,4), & 0,4 < x \leq 0,7 \\ 1, & x > 0,7 \end{cases} \quad (51)$$

Функције припадности фази бројева у оквиру друге излазне променљиве (*Изложеност*) приказане су у Табели 9, док је визуелизација сваког фази броја дата на Слици 30.

Табела 9. Функције припадности фази бројева за улазну променљиву *Изложеност*

ПДГС (воз/дан)		
Категорија	Тип	Функција прип. (a, b, c, d)
Мали	Леви трапез	(0, 0, 5000, 7000)
Средњи	Троугаони	(6000, 10.000, 13.500)
Велики	Десни трапез	(12.000, 13.500, 20.000, 25.000)
Брзина (km/h)		
Категорија	Тип	Функција прип. (a, b, c, d)
Мала	Леви трапез	(0, 0, 60, 70)
Средња	Троугаони	(60, 75, 90)
Велика	Десни трапез	(80, 90, 120, 120)
Процент прекорачења брзине		
Категорија	Тип	Функција прип. (a, b, c, d)
Мало	Леви трапез	(0, 0, 0,2, 0,3)
Средње	Троугаони	(0,2, 0,4, 0,5)
Велико	Десни трапез	(0,4, 0,5, 1,0, 1,0)

Процент прекорачења >20 km/h		
Категорија	Тип	Функција прип. (a, b, c, d)
Мало	Леви трапез	(0, 0, 0,02, 0,07)
Велико	Десни трапез	(0,03, 0,1, 0,5, 0,5)



**Слика 30.** Функције припадности улазних променљивих: а) ПГДС, б) брзина, с) проценат прекорачења, д) проценат прекорачења >20 km/h

Поред поменутог, у наставку је дат и аналитички запис фази бројева приказаних у претходној табели.

ПГДС:

$$\mu_{\text{мали}}(x) = \begin{cases} 1, & x \leq 5000 \\ 0,0005(7000 - x), & 5000 < x \leq 7000 \\ 0, & x > 7000 \end{cases} \quad (52)$$

$$\mu_{\text{средњи}}(x) = \begin{cases} 0, & x \leq 6000 \\ 0,00025(x - 6000), & 6000 < x \leq 10000 \\ 0,000286(13500 - x), & 10000 < x \leq 13500 \\ 0, & x > 13500 \end{cases} \quad (53)$$

$$\mu_{\text{велики}}(x) = \begin{cases} 0, & x \leq 12000 \\ 0,000667(x - 12000), & 12000 < x \leq 13500 \\ 1, & x > 13500 \end{cases} \quad (54)$$

Брзина:

$$\mu_{\text{мала}}(x) = \begin{cases} 1, & x \leq 60 \\ 0,1(70 - x), & 60 < x \leq 70 \\ 0, & x > 70 \end{cases} \quad (55)$$

$$\mu_{\text{средња}}(x) = \begin{cases} 0, & x \leq 60 \\ 0,0667(x - 60), & 60 < x \leq 75 \\ 0,0667(90 - x), & 75 < x \leq 90 \\ 0, & x > 90 \end{cases} \quad (56)$$

$$\mu_{\text{велика}}(x) = \begin{cases} 0, & x \leq 80 \\ 0,1(x - 80), & 80 < x \leq 90 \\ 1, & x > 90 \end{cases} \quad (57)$$

Процент прекорачења брзине:

$$\mu_{\text{мало}}(x) = \begin{cases} 1, & x \leq 0,2 \\ 10(0,3 - x), & 0,2 < x \leq 0,3 \\ 0, & x > 0,3 \end{cases} \quad (58)$$

$$\mu_{\text{средње}}(x) = \begin{cases} 0, & x \leq 0,2 \\ 5(x - 0,2), & 0,2 < x \leq 0,4 \\ 10(0,5 - x), & 0,4 < x \leq 0,5 \\ 0, & x > 0,5 \end{cases} \quad (59)$$

$$\mu_{\text{велико}}(x) = \begin{cases} 0, & x \leq 0,4 \\ 10(x - 0,4), & 0,4 < x \leq 0,5 \\ 1, & x > 0,5 \end{cases} \quad (60)$$

Процент прекорачења брзине  $>20 \text{ km/h}$ :


$$\mu_{\text{мало}}(x) = \begin{cases} 1, & x \leq 0,02 \\ 20(0,07 - x), & 0,02 < x \leq 0,07 \\ 0, & x > 0,07 \end{cases} \quad (61)$$

$$\mu_{\text{велико}}(x) = \begin{cases} 0, & x \leq 0,03 \\ 14,286(x - 0,03), & 0,03 < x \leq 0,1 \\ 1, & x > 0,1 \end{cases} \quad (62)$$

Сходно наведеном, функција припадности за излазну променљиву *Изложеност* изражена је помоћу три фази скупа (Слика 31 и Једначине 63, 64, 65): мала изложеност (0, 0, 0,2, 0,4), средња изложеност (0,3, 0,5, 0,7) и велика изложеност (0,6, 0,8, 1, 1).

$$\mu_{\text{мала}}(x) = \begin{cases} 1, & x \leq 0,2 \\ 5(0,4 - x), & 0,2 < x \leq 0,4 \\ 0, & x > 0,4 \end{cases} \quad (63)$$

$$\mu_{\text{средња}}(x) = \begin{cases} 0, & x \leq 0,3 \\ 5(x - 0,3), & 0,3 < x \leq 0,5 \\ 5(0,7 - x), & 0,5 < x \leq 0,7 \\ 0, & x > 0,7 \end{cases} \quad (64)$$



Слика 31. Функција припадности излазне променљиве *Изложеност*:

$$\mu_{\text{велика}}(x) = \begin{cases} 0, & x \leq 0,6 \\ 5(x - 0,6), & 0,6 < x \leq 0,8 \\ 1, & x > 0,8 \end{cases} \quad (65)$$

Функције припадности треће улазне променљиве (*Тежина саобраћајних незгода*) приказане су у Табели 10, док је визуелизација овог фази броја дата на Слици 32. Границе функција припадности за променљиву *Тежина саобраћајних незгода* дефинисане су на основу пондерисане структуре незгода, која је израчуната у складу са националним препорукама Агенције за безбедност саобраћаја, према једначини:

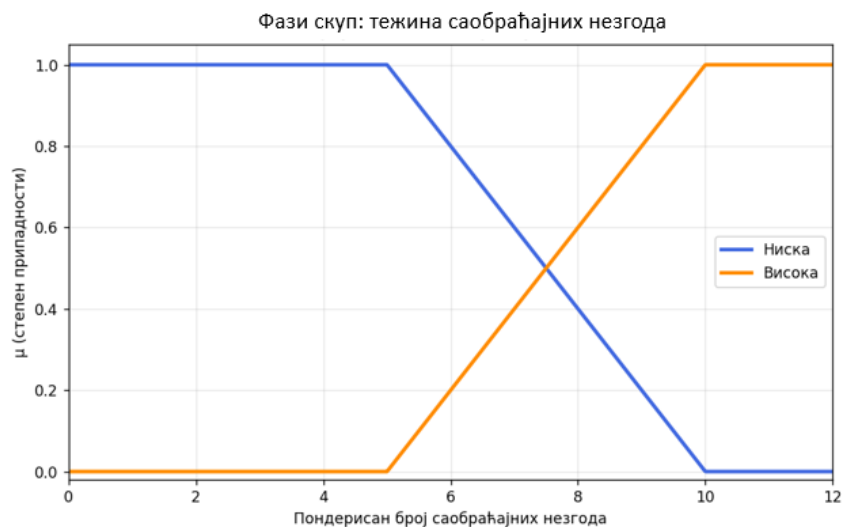
$$\text{Пондерисана тежина (ПТ)} = \text{материјална штета} \times 1 + \text{повређени} \times 10 + \text{погинули} \times 85 \quad (66)$$

Табела 10. Функције припадности фази бројева за улазну променљиву *Тежина саобраћајних незгода*

Тежина саобраћајних незгода (изражено у незгодама са материјалном штетом)		
Категорија	Тип	Функција прип. (a, b, c, d)
Ниска	Леви трапез	(0, 0, 5, 10)
Висока	Десни трапез	(5, 10, 12, 12)

Приказана формула приказује различиту тежину последица незгода, при чему незгоде са материјалном штетом имају најмањи пондер, док присуство повређених или погинулих нагло повећава укупну вредност показатеља. На основу тога, вредности пондера мање од 10 интерпретирају се као ситуације у којима су регистроване искључиво незгоде са материјалном штетом, без повређених или погинулих, и оне су у моделу описане као „ниска” тежина. Са друге стране, вредности веће од 10 подразумевају најмање једну незгоду са повређеним лицима, па су такве вредности класификоване као „висока” тежина. С обзиром на неизвесност и постепену промену између ових стања, прелаз између категорија

није дефинисан оштрим прагом, већ преклапањем функција припадности у интервалу од 5 до 10.



Слика 32. Функција припадности улазне променљиве *Тежина саобраћајних незгода*

Аналитички запис овог фази броја дат је у наставку:

$$\mu_{\text{ниска}}(x) = \begin{cases} 1, & x \leq 5 \\ 0,2(10 - x), & 5 < x \leq 10 \\ 0, & x > 10 \end{cases} \quad (67)$$

$$\mu_{\text{висока}}(x) = \begin{cases} 0, & x \leq 5 \\ 0,2(x - 5), & 5 < x \leq 10 \\ 1, & x > 10 \end{cases} \quad (68)$$

Свака од променљивих (ширина траке, нагиб, ПГДС итд.) представља улазну променљиву за свој фазилогички систем (*Квалитет, Изложеност*). Коначни излаз из целокупног фазилогичког система јесте фази скуп *Категорија опасног места* (Табела 11, Слика 33).

Табела 11. Функције припадности фази бројева за излазну променљиву *Категорија опасног места*

Категорија опасног места		
Категорија	Тип	Функција прип. (a, b, c, d)
Опасно место са опраштајућим карактеристикама	Леви трапез	(0, 0, 1, 1,5)
Аномално опасно место	Троугаони	(1, 2, 3)
Инертно опасно место	Троугаони	(2,5, 3,5, 4,5)
Флукутирајуће опасно место	Троугаони	(4, 5,5, 7)
Тихо место	Троугаони	(6,5 8, 9,0)
Експлозивно место	Десни трапез	(8,5, 9,5, 10, 10)

Границе функција припадности за излазну променљиву *Категорија опасног места* иницијално су постављене на основу експертске процене карактеристичних комбинација улазних параметара које указују на различите нивое ризика. При томе су узети у обзир типични обрасци који се јављају у посматраном скупу података, као и позната логика функционисања система безбедности саобраћаја (нпр. комбинације високог протока и адекватне геометрије пута, односно комбинације неповољних геометријских услова, високе изложености и веће тежине незгода). Након иницијалног постављања, границе функција припадности додатно су прилагођене како би се обезбедило постепено преклапање суседних категорија и избегле нагле промене из категорије у категорију, што је у складу са основним принципима фази логике.



**Слика 33.** Функција припадности излазне променљиве *Категорија опасног места*

Аналитички записи ових фази бројева дати су у наставку:

$$\mu_{\text{место са опраштајућим каракт.}}(x) = \begin{cases} 1, & x \leq 1 \\ 2(1,5 - x), & 1 < x \leq 1,5 \\ 0, & x > 1,5 \end{cases} \quad (69)$$

$$\mu_{\text{аномално опасно место}}(x) = \begin{cases} 0, & x \leq 1 \\ x - 1, & 1 < x \leq 2 \\ 3 - x, & 2 < x \leq 3 \\ 0, & x > 3 \end{cases} \quad (70)$$

$$\mu_{\text{инертно опасно место}}(x) = \begin{cases} 0, & x \leq 2,5 \\ x - 2,5, & 2,5 < x \leq 3,5 \\ 4,5 - x, & 3,5 < x \leq 4,5 \\ 0, & x > 4,5 \end{cases} \quad (71)$$

$$\mu_{\text{флукутирајуће опасно место}}(x) = \begin{cases} 0, & x \leq 4 \\ 0,667(x - 4), & 4 < x \leq 5,5 \\ 0,667(7 - x), & 5,5 < x \leq 7 \\ 0, & x > 7 \end{cases} \quad (72)$$

$$\mu_{\text{тихо место}}(x) = \begin{cases} 0, & x \leq 6,5 \\ 0,667(x - 6,5), & 6,5 < x \leq 8 \\ 9 - x, & 8 < x \leq 9 \\ 0, & x > 9 \end{cases} \quad (73)$$

$$\mu_{\text{експлозивно место}}(x) = \begin{cases} 0, & x \leq 8,5 \\ x - 8,5, & 8,5 < x \leq 9,5 \\ 1, & x > 9,5 \end{cases} \quad (74)$$

Да би се одредила припадност посматраног сегмента одговарајућој излазној категорији, примењена су фази правила (IF (АКО) – THEN (ОНДА)), заснована на принципима конјункције (AND (И)) и дисјункције (OR (ИЛИ)). Ова правила дефинишу пресликавање комбинација улазних фази скупова у одговарајуће излазне категорије ризика.

У Табели 12 дато је првих пет фази правила (од укупно 24) која се односе на први креирани фазилогички систем чија је излазна променљива *Квалитет коловоза*.

**Табела 12.** Фази правила у оквиру првог фазилогичког система

Р. бр.	Фази правило
1.	АКО је ширина траке довољна, И храпавост добра, И радијус велики, И нагиб мали, ОНДА је квалитет ДОБАР.
2.	АКО је ширина траке недовољна, И храпавост лоша, И радијус мали, И нагиб мали, ОНДА је квалитет ЛОШ.
3.	АКО је ширина траке недовољна, И храпавост лоша, И радијус мали, И нагиб велики, ОНДА је квалитет ЛОШ.
4.	АКО је ширина траке недовољна, И храпавост лоша, И радијус велики, И нагиб мали, ОНДА је квалитет ЛОШ.
5.	АКО је ширина траке недовољна, И храпавост лоша, И радијус велики, И нагиб велики, ОНДА је квалитет ЛОШ.

У Табели 13 је дато првих десет фази правила (од укупно 54) која се односе на други фазилогички систем чија је излазна променљива *Изложеност*.

Коначно, дефинисањем фази правила трећег фазилогичког система (Табела 14) који повезује основне улазне променљиве (*Квалитет* – Q, *Изложеност* – E и *Тежина саобраћајних*

незгода – S) са излазном променљивом, омогућено је одређивање припадности посматраног сегмента једној од шест поткатегија опасних места (поткатегија ризика).

**Табела 13.** Првих десет фази правила другог фазилогичког система

Р. бр.	Фази правило
1.	АКО је ПГДС мали, И брзина мала, И проценат прекорачења мали, И проценат прекорачења >20 km/h мали, ОНДА је изложеност МАЛА.
2.	АКО је ПГДС мали, И брзина мала, И проценат прекорачења мали, И проценат прекорачења >20 km/h велико, ОНДА је изложеност СРЕДЊА.
3.	АКО је ПГДС мали, И брзина мала, И проценат прекорачења средње, И проценат прекорачења >20 km/h мало, ОНДА је изложеност СРЕДЊА.
4.	АКО је ПГДС мали, И брзина мала, И проценат прекорачења средње, И проценат прекорачења >20 km/h велико, ОНДА је изложеност СРЕДЊА.
5.	АКО је ПГДС мали, И брзина мала, И проценат прекорачења велико, И проценат прекорачења >20 km/h мало, ОНДА је изложеност СРЕДЊА.
6.	АКО је ПГДС мали, И брзина мала, И проценат прекорачења велико, И проценат прекорачења >20 km/h велико, ОНДА је изложеност СРЕДЊА.
7.	АКО је ПГДС мали, И брзина средња, И проценат прекорачења мало, И проценат прекорачења >20 km/h мало, ОНДА је изложеност СРЕДЊА.
8.	АКО је ПГДС мали, И брзина средња, И проценат прекорачења мало, И проценат прекорачења >20 km/h велико, ОНДА је изложеност СРЕДЊА.
9.	АКО је ПГДС мали, И брзина средња, И проценат прекорачења средње, И проценат прекорачења >20 km/h мало, ОНДА је изложеност СРЕДЊА.
10.	АКО је ПГДС средњи, И брзина висока, И проценат прекорачења велик, ОНДА је изложеност ВЕЛИКА.

Правила на тај начин описују логичке односе између комбинација улазних променљивих и одговарајућих излазних категорија опасних места.

На овом месту важно је напоменути да примена фази логике представља најадекватнији приступ за категоризацију ризичних локација. Док би класична категоризација сваку локацију бинарно груписала, приказани приступ омогућава да једна локација истовремено поседује карактеристике више категорија. На тај начин реалније се одражавају сложене комбинације фактора који утичу на ризик. На пример, коловоз може бити лош али са умереном изложеношћу, или обрнуто. Овај приступ омогућава флексибилнију процену, јер локације више не морају бити „строго” безбедне или небезбедне, већ се њихова опасност описује континуирано, у складу са степеном изражености појединих карактеристика. Тако се добија реалистичнија класификација опасних места која боље одговара условима реалног саобраћајног окружења и његовој сложености.

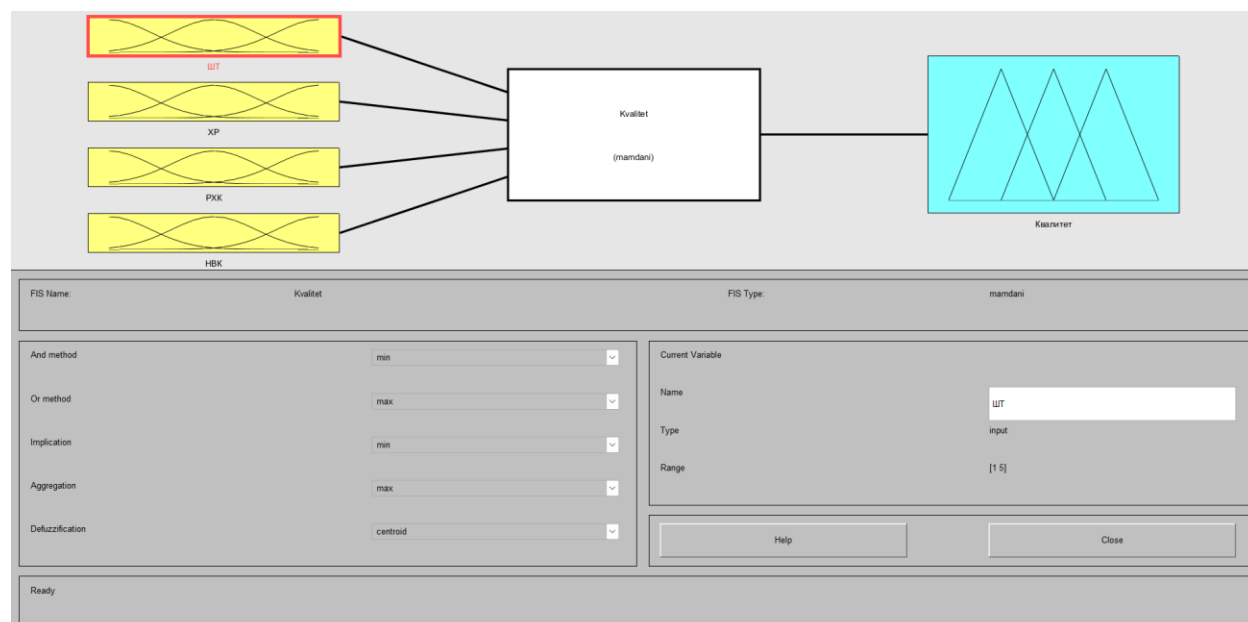
Табела 14. Фази правила трећег фази логичког система

Р. бр.	Фази правило	Категорија
1.	АКО Q добар, E средња, S висока Q добар, E велика, S висока Q лош, E средња, S висока Q лош, E велика, S висока	ОНДА Експлозивно место
2.	АКО Q лош, E мала, S висока Q добар, E мала, S висока	ОНДА Тихо место
3.	АКО Q лош, E велика, S ниска Q лош, E средња, S ниска	ОНДА Флукутирајуће опасно место
4.	АКО Q лош, E мала, S ниска	ОНДА Инертно опасно место
5.	АКО Q добар, E средња, S ниска Q добар, E мала, S ниска	ОНДА Аномална локација
6.	АКО Q добар, E велика, S ниска	ОНДА Место са опраштајућим карактеристикама

#### 4.4.4 Примена предложене фази категоризације

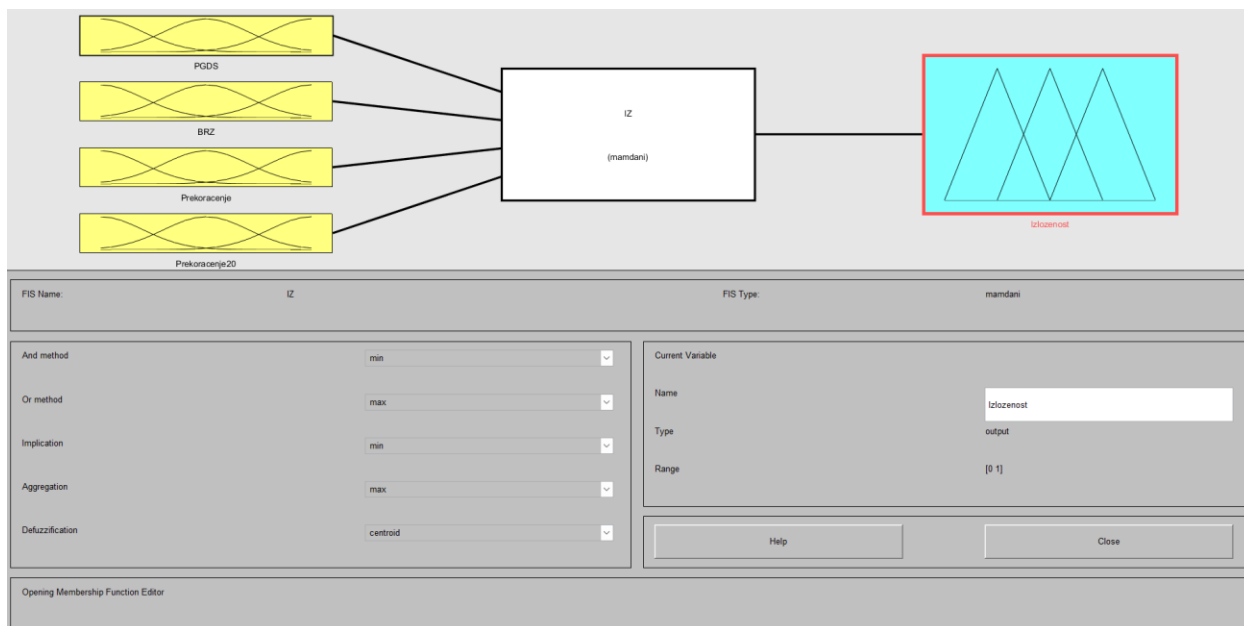
За примену дефинисане методологије и решавање приказаног фазилогичког проблема коришћен је Matlab R2016а софтверски пакет. Резултати су приказани даље у раду.

Први фазилогички систем – *Квалитет коловоза* – дефинисан у Matlab-у, приказан је на Слици 34.



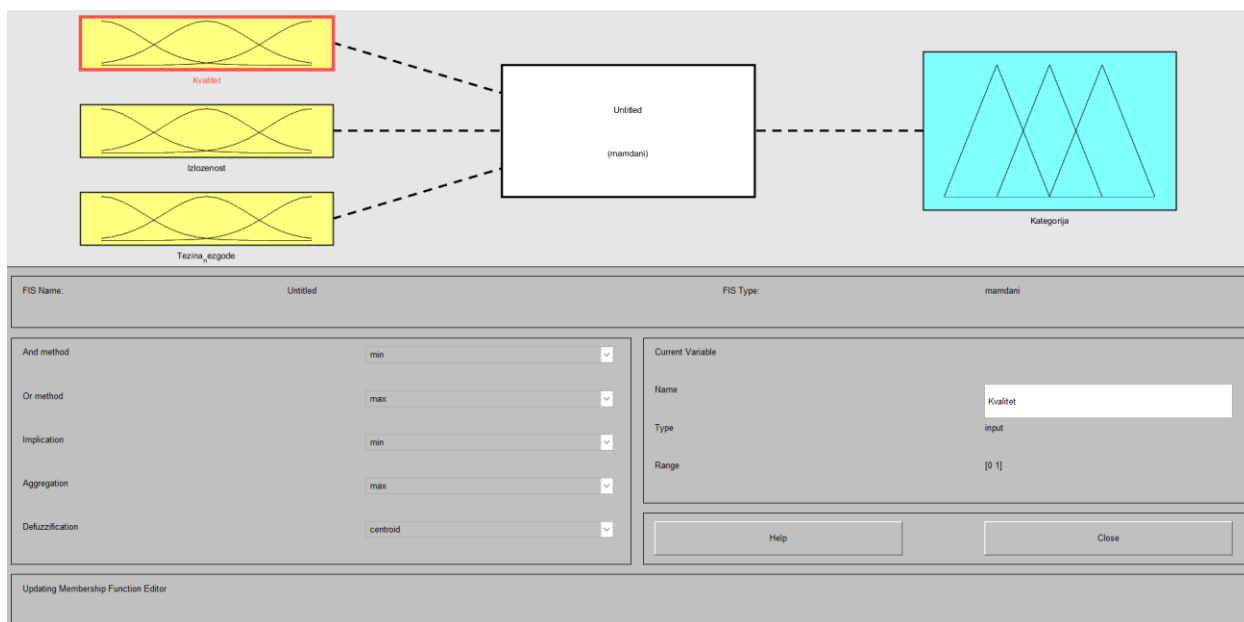
Слика 34. Пример првог фазилогичког система (*Квалитет коловоза*) у Matlab-у

На Слици 35 је приказан други фазилогички систем – *Изложеност* – у Matlab-у.



Слика 35. Пример другог фазилогичког система (*Изложеност*) у Matlab-у

На Слици 36 је приказан трећи фазилогички систем у Matlab-у који обједињује претходне две излазне зависне променљиве – *Квалитет* и *Изложеност* – са променљивом *Тежина саобраћајних незгода*, пружајући финалну фазиизлазну променљиву – *Категорија опасног места*.



Слика 36. Пример трећег фазилогичког система (*Категорија опасног места*) у Matlab-у

Добијени резултати приказани су у Табели 15 у којој су дате вредности променљивих након дефазификације, као и степен припадности по категоријама опасних места, док су у Табели 16 приказани детаљи и додатне карактеристике опасних места.

Вредност категорије опасног места израчуната је применом фазиинференцијског система заснованог на *Mamdani* приступу. У систему су дефинисане три улазне променљиве – *Квалитет (Q)*, *Изложеност (E)* и *Тежина саобраћајних незгода (S)* – које су описане одговарајућим фази скуповима и функцијама припадности. На основу дефинисаних фази правила типа IF – THEN врши се инференција, при чему се најпре одређују степени припадности улазних вредности одговарајућим фази скуповима, након чега се активирају правила и врши агрегација излазних фази скупова. Коначна нумеричка вредност излазне променљиве добија се поступком дефазификације применом центроид методе. Генерално, дефазификована вредност излазне променљиве одређује се као тежиште агрегиране функције припадности. Добијена вредност представља позицију унутар континуалног интервала излазне променљиве, док се степен припадности појединачним категоријама одређује евалуацијом њихових функција припадности у тој тачки.

**Табела 15.** Резултати након дефазификације променљиве и степени припадности за опасна места

Р. бр.	ID опасног места	Вредност након дефазификације				Степен припадности	
		Квалитет	Изложеност	Тежина саобр. незгода	Категорија опасног места	Експлозивна	Тиха
1.	2021_2	0,262	0,500	42	9,433	<b>0,933</b>	0,000
2.	2021_3	0,501	0,499	31	9,430	<b>0,930</b>	0,000
3.	2021_38	0,764	0,583	98	9,425	<b>0,925</b>	0,000
4.	2021_39	0,260	0,153	51	8,100	0,000	<b>0,900</b>
5.	2021_40	0,786	0,833	31	9,412	<b>0,912</b>	0,000
6.	2021_41	0,503	0,500	60	9,414	<b>0,914</b>	0,000
7.	2021_7	0,353	0,844	13	9,431	<b>0,931</b>	0,000
8.	2021_8	0,257	0,501	22	9,434	<b>0,934</b>	0,000
9.	2022_16	0,823	0,812	127	9,422	<b>0,912</b>	0,000
10.	2022_2	0,433	0,500	32	9,423	<b>0,923</b>	0,000
11.	2022_20	0,288	0,511	117	9,432	<b>0,932</b>	0,000
12.	2022_22	0,264	0,157	97	8,100	0,000	<b>0,900</b>
13.	2022_23	0,259	0,172	40	7,911	0,000	<b>0,941</b>
14.	2022_3	0,502	0,504	23	9,411	<b>0,911</b>	0,000
15.	2022_8	0,258	0,510	106	9,433	<b>0,933</b>	0,000
16.	2023_18	0,276	0,219	41	8,098	0,000	<b>0,902</b>

Сва регистрована опасна места спадају у две најопасније поткатеорије: експлозивне локације (12 локација) или тихе локације (4 локације). Интересантно је напоменути и то да све тихе локације имају карактеристике експлозивних локација, што се може видети по резултатима степена припадности. То уједно упућује на тенденцију тихих локација да у будућности могу потенцијално постати експлозивне, што је и показано лонгитудиналном анализом. Наиме, лонгитудиналном анализом примећена је трансформација опасног места

које је категорисано као тиха локација 2021. године у опасно место експлозивног ризика у 2022. години, првенствено због повећања просечног годишњег дневног саобраћаја.

Геометријски услови и стање коловоза остали су углавном непромењени, али је промена обима саобраћаја повећала нивое изложености, интензивирајући профил ризика локације. Ова промена посебно је забрињавајућа јер тихе локације обично привлаче мање пажње због смањене изложености. Међутим, када се саобраћај повећа, комбинација лоших карактеристика пута и постојећа историја незгода стварају сценарио у којем вероватноћа и потенцијална тежина незгоде нагло расту.

**Табела 16.** Детаљи и карактеристике опасних места

Р. бр.	ID опасног места	Локација опасног места	Регион
1.	2021_2	Пут ИБ реда бр. 12 (раскрсница Оџаци, укрштање са путем ИБ реда бр. 3)	Западнобачки
2.	2021_3	Пут ИБ реда бр. 12 (раскрсница Оџаци, укрштање са путем ИБ реда бр. 111)	Западнобачки
3.	2021_38	Пут ИБ реда бр. 12 (излаз из Мишићева ка Суботици)	Севернобачки
4.	2021_39	Пут ИБ реда бр. 23 (Дријетањ, Ужице)	Златиборски
5.	2021_40	Пут ИБ реда бр. 34 (раскрсница, скретање за Баре, Пожаревац)	Браничевски
6.	2021_41	Пут ИБ реда бр. 35 („Дебело брдо”, између Меровине и Југбогдановца)	Топлички
7.	2021_7	Пут ИБ реда бр. 18 (раскрсница, скретање за Лаудоновац, ближе Вршцу)	Јужнобанатски
8.	2021_8	Пут ИБ реда бр. 21 (прва кривина од „Бјелоперице” ка Косјерићу)	Златиборски
9.	2022_16	Пут ИБ реда бр. 26 (шире подручје раскрснице са путем бр. 136, Петловача)	Мачвански
10.	2022_2	Пут ИБ реда бр. 21 („Гага” петрол, Пожега)	Златиборски
11.	2022_20	Пут ИБ реда бр. 27 („Парт маркет 1300 Каплара”, Лазаревац)	Београд
12.	2022_22	Пут ИБ реда бр. 24 („Euro Line”, Вучковица)	Шумадијски
13.	2022_23	Пут ИБ реда бр. 39 (укрштање са путем Гложане–Стајковце)	Јабланички
14.	2022_3	Укрштање путева 23 и 21, ресторан „Терминал” Пожега	Златиборски
15.	2022_8	Улаз у насеље Прогорелица, смер од Краљева	Рашки
16.	2023_18	Пут ИБ реда бр. 35 (раскрсница са путем „Бораца НОБ-а”, Врело, пут за Сврљиг)	Нишавски

Такав прелаз наглашава динамичну природу ризика од настанка опасних места и истиче потребу за континуираним праћењем, јер чак и места која су раније сматрана мање

приоритетним могу брзо ескалирати у зоне високог ризика које захтевају хитну интервенцију. Сходно наведеном, може се прихватити Хипотеза 2.

На основу приказаних локација опасних места у периоду, може се уочити одређена просторна концентрација у појединим регионима, али без конкретног обрасца. Пре свега, издваја се Златиборски регион, који се појављује више пута, што указује на одређене проблеме који се појављују у овом региону, а који захтевају детаљније анализе узрока. Може се претпоставити да су овакви резултати последица различитих карактеристика, попут планинског терена – због чега се појављује и велики број кривина, мешовит саобраћајни ток и сл. Поред Златиборског, два пута се појављује још и Западнобачки округ, док су остала опасна места евидентирана у другим регионима, што указује на уочљиву дисперзију по којој се опасна места појављују на мрежи.

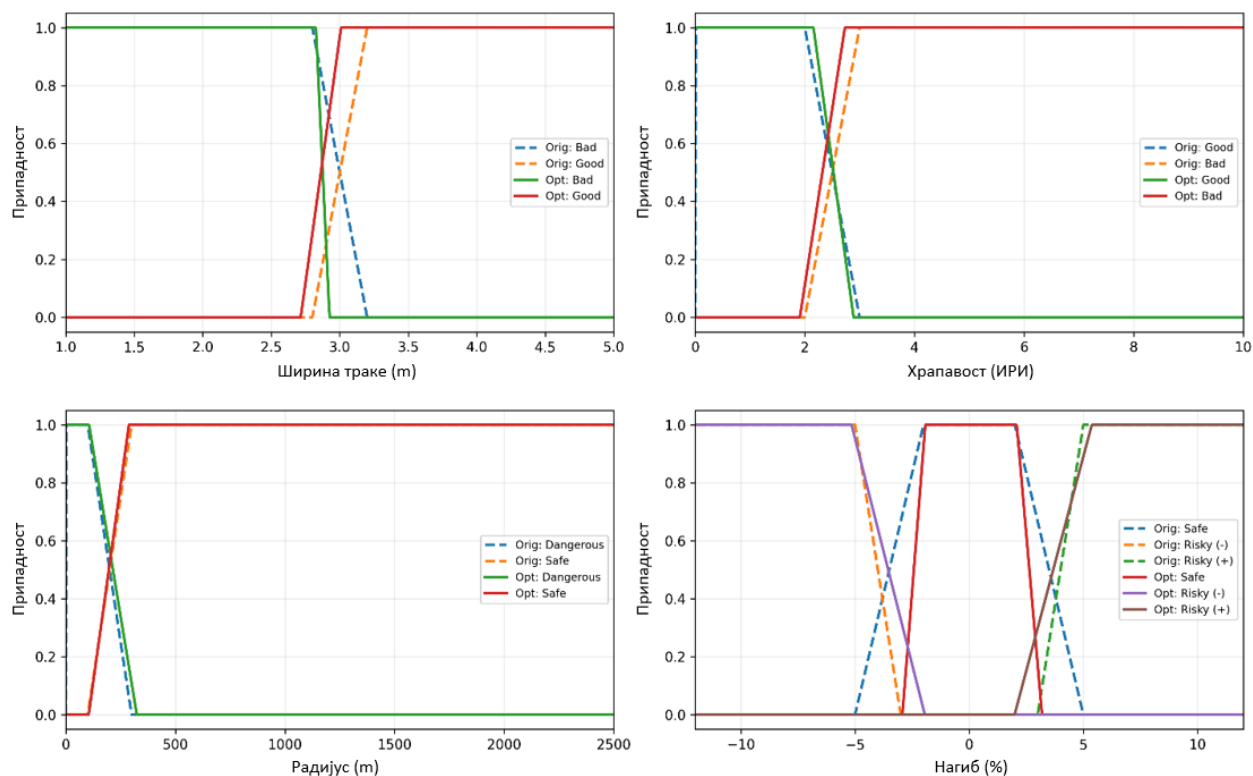
Уколико се ови резултати доведу у везу са показатељима друштвеног ризика (YLL, YLD, DALY), могу се уочити делимична поклапања, али не и потпуна зависност. На пример, региони са већим вредностима индикатора YLL и DALY укључују и регионе са већим бројем опасних места, што указује да повећана учесталост ризичних локација може допринети већем здравственом оптерећењу. Међутим, ова веза није линеарна, поједини региони са мањим бројем идентификованих опасних места (или без идентификованих опасних места) могу имати релативно високе вредности индикатора YLL или DALY, што указује на већу тежину последица (нпр. већи удео тешких и смртних исхода). С друге стране, региони са више опасних места не морају нужно имати највеће вредности индикатора YLD, што може указивати на различиту структуру незгода (обично више незгода са материјалном штетом).

#### 4.4.5 Валидација израђеног фази система

Да би се побољшала робусност и интерпретабилност фази система, параметри функција припадности оптимизовани су под ограничењима која су кажњавала недовољну прецизност функција припадности, конфликте у одлучивању и нестабилност класификације. Оптимизација је конвергирала ка компактном и стабилном решењу, дајући малу казну за прецизност (1,1623) и минималну казну за конфликт (0,0750), уз постизање минималне стопе нестабилности, што указује да ниједан узорак (опасно место) није променило категорију након оптимизације. Ово потврђује да прилагођени параметри функција припадности прецизирају границе партиције без промене глобалне структуре одлучивања.

Резултати функција припадности за фази систем *Квалитет* (Слика 37) показују да оптимизоване функције чувају оригиналну семантичку интерпретацију свих променљивих, док уводе умерено померање граница и оштрије прелазе.

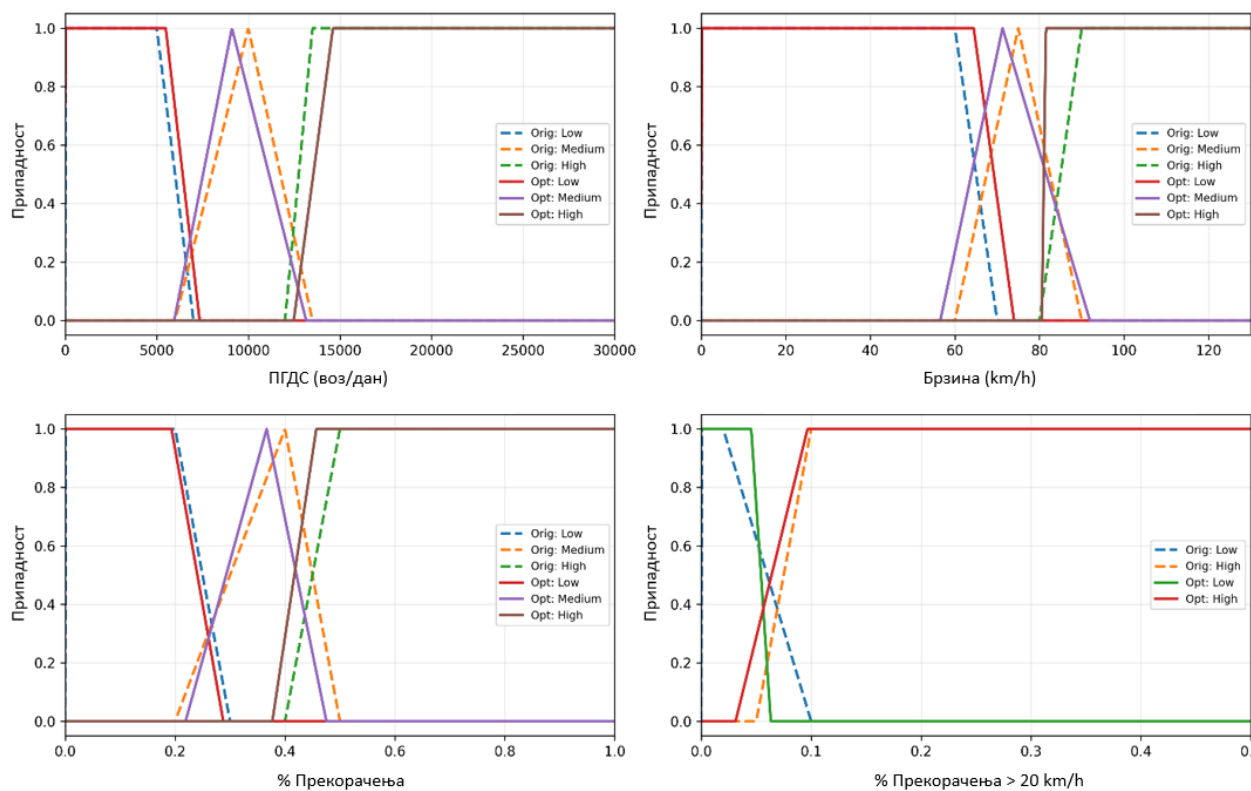
За ширину траке и ИРИ, оптимизоване функције показују израженије прелазе око прагова одлучивања, што доводи до јаснијег раздвајања између „добрих” и „лоших” услова. Најмање разлике између оригиналних и оптимизованих функција припадности примећене су за променљиву радијус. За нагиб, оптимизоване функције одржавају структуру са три региона, уз умерено сужење централне „безбедне” зоне. Генерално, оптимизација првенствено побољшава дискриминацију и конзистентност класификације, задржавајући оригиналну логику експерата при одлучивању.



Слика 37. Оригинале и оптимизоване функције припадности за фази систем *Квалитет*


Подешавања функција припадности за фази систем *Изложеност* (Слика 38) показују слично стабилно понашање са умереним променама параметара. За све променљиве, оптимизоване функције прате оригиналне облике, уз побољшану диференцијацију између суседа. За ПГДС и брзину, прелази између „ниске”, „средње” и „високе” одреднице постају стрмији и локализованији, што резултира јаснијим раздвајањем различитих интензитета саобраћаја. Променљива проценат прекорачења брзине показује сужену средњу област, концентришући средњу експозицију око централног опсега и ограничавајући неодређеност на границама. За велика прекорачења брзине ( $>20$  km/h), оптимизовани скупови формирају израженије прелазе, ефикасно раздвајајући услове ниског и високог ризика.

Модул *Тежине последице* показује најстабилније понашање након оптимизације (Слика 39). Оптимизоване функције припадности ниске и високе озбиљности остају у великој мери у складу са оригиналним дефиницијама. Раздвајање између две класе остаје изражено, чувајући јасну бинарну категоризацију овог параметра.




Слика 38. Оригиналне и оптимизоване функције припадности за фази систем *Изложеност*

Није примећена значајна промена у облику функција припадности, што указује да оптимизација првенствено регулише параметре функција, а не мења прагове одлучивања. Ово понашање је у складу са стопом стабилности и потврђује да категоризација тежине незгода остаје потпуно непромењена, уз истовремено постизање побољшане нумеричке конзистентности.



Слика 39. Оригиналне и оптимизоване функције припадности за фази број *Тежина саобраћајних незгода*

Квантитативна процена стабилности потврдила је да је оптимизација сачувала оригиналну категоризацију (Слика 40). Стопа промене класификације је занемарљива, што потврђује да није дошло до промена у коначној категоризацији опасних места.



**Слика 40.** Стабилност функција припадности по променљивама

Истовремено, оптимизација је довела до побољшане диференцијације између суседних категорија за већину променљивих (Табела 17). Најизраженије промене примећене су за нагиб (−65,6%), ширину траке (−43,6%), велико прекорачење брзине (−35,9%) и ПГДС (−25,4%), што указује на јасније раздвајање између суседних категорија и смањену неодређеност у системима изложености и квалитета.

**Табела 17.** Преклапање суседних функција припадности

Фази систем	Променљива	Оригинал	Оптимизовано	Преклапање Δ	Редукција (%)
Квалитет	Ширина траке (m)	0,100	0,056	0,044	43,6
	Храпавост (IRI)	0,250	0,310	−0,060	−23,9
	Радијус (m)	50,000	60,024	−10,024	−20,0
	Нагиб (%)	0,800	0,275	0,525	65,6
Изложеност	ПГДС (воз/дан)	308,331	229,955	78,376	25,4
	Брзина (km/h)	4,000	9,260	−5,260	−131,5
	% Прекорачења	0,042	0,035	0,006	15,0
	% Прекорачења >20 km/h	0,010	0,006	0,003	35,9
<b>Тежина саобраћајних незгода</b>		2,461	2,467	−0,006	−0,2

Највеће промене параметара функција припадности примећене су код променљиве брзина (131,5%), док су за остале променљиве забележене само мање корекције које нису утицале на стабилност категоризације. На основу приказаних резултата може се генерално закључити да је оптимизација довела до прецизније дефинисаних функција припадности,

али је и побољшала робусност система, уз очување оригиналне структуре одлучивања и категоризације.

#### **4.5 Дискусија резултата добијених применом методологије за категоризацију опасних места на државним путевима IБ реда у Србији**

Фази категоризација примењена у оквиру овог дела дисертације показала се адекватном за тумачење профила ризика опасних места. Уместо да сваки кластер буде бинарно класификован у једну категорију, фази приступ је омогућио могућност припадности у више категорија, показујући да опасна места могу истовремено делити карактеристике више подтипова. Ово је било очигледно у кластерима који су показали делимичну припадност и тихим и експлозивним категоријама ризика, где су се изложеност и озбиљност комбиновали да би се створио хибридни профил ризика. Такви резултати наглашавају важност кретања кроз једнозначне таксономије, јер истичу прелазну природу многих локација високог ризика и пружају адекватнију основу за дефинисање и избор мера превенције.

Резултати истраживања на примеру путева IБ реда у периоду од 2021. до 2023. године, указују на значај и практичну применљивост мултидимензионалног система класификације опасних места. Интеграцијом карактеристика пута, изложености и тежине последица незгода у јединствен аналитички оквир, предложени модел превазилази традиционалне приступе засноване искључиво на фреквенцији или тежини незгода. Овакав приступ омогућава детаљније разумевање механизма настанка и еволуције опасних места, те сходно томе и избор адекватних мера превенције. Овакво полазиште у складу је са савременим трендовима управљања саобраћајем који се заснивају на доказима и превентивном деловању (*Elvik, 2007, 2008; Montella, 2010*).

Међу локацијама које се појављују у више узастопних година доминирају експлозивни подтипови – сегменти које карактеришу високи проток, велика просечна брзина и честе тешке последице саобраћајних незгода. Управо комбинација интензивног протока возила и повећаног ризика по јединици површине пута указује на потребу да се ове локације посматрају не само као статистичке аномалије већ и као резултати интеракције између геометрије пута и параметара саобраћајног тока. Истовремено, тихе локације, мање учестале, али изразито опасне, показују висок ниво тежине незгода упркос релативно ниској изложености, што поново истиче значај контекста у саобраћајној анализи, укључујући и локалну густину саобраћаја и визуелну перцепцију пута.

Класификациони оквир предложен у овој дисертацији омогућава формулисање сета мера усклађених са доминантним механизмима ризика унутар сваке поткатегије. На пример, за експлозивне локације настале као резултат ризичног понашања возача на инфраструктурно адекватним деоницама, ефикасне мере могу укључити видео-надзор, контролу брзине путем камера, друге видове контроле и санкционисања, као и кампање усмерене на корекцију понашања свих учесника у саобраћају. Са друге стране, посебно је интересантан тип опасних места који обједињује лошу инфраструктуру, велику изложеност и високу тежину незгода (експлозивне локације). У овом контексту, параметри саобраћајног тока попут

средње брзине или прекорачења брзине указују на висок степен агресивног понашања возача, који се јавља управо на местима где карактеристике пута нису у стању да „апсорбују” ризик који долази са повећаним протоком.

С друге стране, тихе локације у подручјима ниске изложености али изражених негативних последица, захтевају микропровере и адекватне интервенције на локалном нивоу. Сегменти са лошим геометријским карактеристикама и малим обимом саобраћаја али великом тежином незгода, представљају класичан пример парадокса у безбедности, где побољшање услова може довести до нежељених ефеката. Наиме, бољи услови на путу могу довести до повећања брзине кретања, што доводи до већег ризика од тешких последица (*Elvik et al.*, 2004; *Aarts and Van Schagen*, 2006). Без пажљиво изабраних мера прилагођених локалном контексту, овакве локације могу прерасти у експлозивна опасна места.

Остале категорије, у којима доминирају незгоде са материјалном штетом, мање су сложене за анализу, али и даље захтевају надзор. Посебно се издваја категорија „аномалијских” опасних места, које обухватају сегменте са добрим карактеристикама пута, ниском изложеношћу и ниском тежином последица. Уколико дође до пораста саобраћајног оптерећења, постоји могућност повећања ризика, а тиме и транзиције овог типа у неке од ризичнијих типова опасних места. У овом смислу, теорија саобраћајног тока нуди аналитички оквир у коме комбинација високе изложености и повољних услова може деловати као подлога за повећање брзине и нарушавање безбедности. Слично томе, места са опраштајућим карактеристикама – са великим протоком и ниском тежином последица – указују на системе који апсорбују ризик. Ипак, према методолошким критеријумима, ове локације се и даље третирају као критичне (као опасна места), што подразумева потребу за интервенцијама у циљу спречавања деградације тренутног стања.

Један од највећих изазова у анализи опасних места, потврђен истраживањем спроведеним у овој докторској дисертацији, као и кроз практична искуства других земаља (попут Хрватске), јесте динамичка (временска) нестабилност појављивања опасних места. Највећи број опасних места (у овом раду) идентификованих у једном периоду, не појављују се у наредним годинама. Управо због тога поједине методологије, попут те примењене у Хрватској, користе двофазни приступ за идентификацију оваквих места: прво кроз статистичку селекцију на основу фреквенције, а затим кроз теренску проверу од стране сертификационих лица и тела за безбедност саобраћаја (*Šarić et al.*, 2016). Овакав приступ уједно илуструје вредност комбиновања квантитативних алата и професионалног деловања (искуства) у процесу класификације ризика.

Важно је напоменути и то да је истраживање спроведено у овој докторској дисертацији базирано на раду Вашингтона и сарадника (*Washington et al.*, 2014), који су применом квантилне регресије и индекса EPDO указали на значај изложености и карактеристика пута у моделирању ризика. Ипак, њихова методологија није обезбедила типологију опасних места, што је управо допуњено истраживањем спроведеним у овој дисертацији. Интеграцијом саобраћајног оптерећења, карактеристика пута и тежине последица, предложен је модел који омогућава идентификацију латентних ризичних профила и њихове временске динамике. Категоризација у подтипове, као што су експлозивне и тихе локације,

пружа концептуалну надградњу која обухвата разнородну природу ризика и трансформише је у оперативно применљиве категорије. На тај начин, приказани модел не само да проширује домен досадашњих истраживања већ омогућава прелаз од чисто аналитичког до стратешког управљања.

Такође, фази приступ омогућава да доношење одлука одражава неизвесност својственоу подацима (*Pačković et al.*, 2022). Задржавањем информација о преклапајућим категоријама, доносиоци одлука могу дати приоритет интервенцијама које не обухватају само места високог ризика, већ и локације које показују знаке преласка у опаснија стања. Ова способност откривања „раних упозорења” о ескалацији ризика наглашава практичну предност фази класификације у поређењу са осталим методама.

Сходно свему до сада наведеном, може се рећи да класификација предложена у оквиру ове докторске дисертације представља дијагностички алат који омогућава прелаз са униформног приступа проблематици на контекстуално осетљиве мере. Повезујући сваку издвојену категорију опасних места са доминантним извором ризика, било да је реч о инфраструктурним недостацима или прекомерном саобраћајном оптерећењу, приказани модел пружа основу за адекватно усмерене интервенције. Овакав свеобухватни приступ истовремено подржава концепт отпорног система и доприноси холистичком разумевању узрочности саобраћајних незгода (*OECD*, 2008). Поред тога, подстиче и промену парадигме: од реактивног реаговања ка проактивном, системском управљању безбедности у саобраћају. Овако постављен модел пружа подршку актуелним политикама, али поставља и основу за адаптивне, дугорочне и контекстуално усклађене стратегије деловања на путевима, које се лако могу адаптирати различитим сценаријима у будућности.

---

---

# ИЗРАДА МОДЕЛА ПРЕДИКЦИЈЕ САОБРАЋАЈНИХ НЕЗГОДА ЗА МРЕЖУ ІБ РЕДА У СРБИЈИ

---

---

5

## 5.1 Опис проблема

Предвиђање броја и тежине саобраћајних незгода представља и даље један од највећих изазова у области саобраћаја, нарочито када је реч о ванградској мрежи. У овом контексту, интеракција више чинилаца као што су: инфраструктурне карактеристике, ниво саобраћајне изложености, спољашњи услови и понашање возача, ствара врло сложену динамику. Иако постоји велики број модела који су кроз различита истраживања и студије развијани и примењивани на глобалном нивоу (*Choi et al.*, 2021; *Shaik et al.*, 2021; *Hussain and Ashraf*, 2023; *Behboudi et al.*, 2024; *Rúa et al.*, 2024; *He et al.*, 2025), они се најчешће израђују за конкретне локације (градови, региони) или се адаптирају у складу са специфичностима локалне средине.

Када је реч о Србији, путеви категорије ІБ реда, који имају значајан удео у ванградској мрежи, често се издвајају као ризични делови инфраструктуре због скупова различитих геометријских решења, профила кретања и специфичности протока, што се често одражава на повећан број незгода (*Road Traffic Safety Agency*, 2023). Један већи број истраживања у нашој земљи заснивао се на анализама временских серија (*Deretić et al.*, 2022; *Pljakić et al.*, 2022), уз ограничен просторни обухват или уз анализу ограниченог броја фактора (*Gatarić et al.*, 2023; *Ranković et al.*, 2024).

Са друге стране, када је реч о класичним моделима предикције, они су се у домаћој литератури најпре појављивали у оквиру студија економског вредновања путних пројеката и анализа безбедности саобраћаја. Први систематизовани приступи дати су од стране *Кузовића* (1984, 1994, 1997), где су приказани општи емпиријски модели зависности броја саобраћајних незгода од саобраћајног оптерећења и геометријских карактеристика путева различитих типова. Модели су били засновани на линеарним и мултипликативним релацијама, при чему су као основне променљиве коришћени ПГДС, ширина саобраћајне траке, ширина банке и бочне сметње, уз корекционе факторе за тип пута и геометријске услове. Ови модели представљали су један од првих покушаја формализације зависности између саобраћајних незгода и карактеристика пута у домаћим условима.

Значајнији развој модела предикције саобраћајних незгода у Србији интензивирао је током последње деценије. Применом једноструке регресионе анализе анализиран је утицај

саобраћајних и путних карактеристика на број саобраћајних незгода на деоницама двотрачних путева у Србији. Истраживање је обухватило формирање интегрисане базе података која је садржала податке о незгодама, ПГДС-у и геометрији пута, док су као независне променљиве коришћени ПГДС, удео комерцијалних возила, радијус хоризонталне кривине, уздужни нагиб и ширина коловоза (Миленковић, 2014). Наредна истраживања проширила су анализу и на ауто-путеве у Србији, где је применом регресионе анализе испитиван утицај путних и саобраћајних карактеристика на незгоде са погинулим лицима на ауто-путу М-1 у периоду 2004–2013. године, при чему су модели представљали један од првих покушаја квантитативног моделовања незгода на ауто-путевима у Србији (Миленковић *et al.*, 2017). Поред наведеног, још једно важно истраживање представља уједно и један од првих радова у међународној литератури који је систематично приказао развој модела предикције саобраћајних незгода за ванградске двотрачне путеве у Србији, уз примену униваријантних и мултиваријантних регресионих анализа и поређење резултата са иностраним моделима (Glavić *et al.*, 2016).

Новија истраживања у Србији усмерена су ка примени напреднијих статистичких и регресионих метода, као и ка анализи већег броја параметара саобраћајног тока. На пример, развој и примена биномних регресионих модела за укупан број незгода, незгоде са материјалном штетом и незгоде са настрадалим лицима, при чему су анализирани параметри као што су разлика слободне и ограничене брзине, дисперзија брзина, ПГДС и удео тешких возила (Stepanović, 2023). Једно од најновијих истраживања о моделима предикције користило је сличан приступ (као и код претходног аутора), при чему су развијена три негативна биномна модела за различите типове незгода на двотрачним путевима I реда у Србији, уз анализу утицаја ПГДС-а, удела тешких теретних возила и различитих карактеристика брзине (Stepanović *et al.*, 2025).

Иако су наведена истраживања представљала значајан допринос развоју модела предикције саобраћајних незгода у Србији, већина досадашњих анализа била је ограничена на одређене узорке, појединачне путне правце или ужи скуп променљивих. У том смислу, у оквиру ове докторске дисертације, израђен је модел предикције применом савремених метода машинског учења, укључујући велике интегрисане базе података и различите просторне анализе, који представља значајан искорак и допринос досадашњим истраживањима.

Предложени модел комбинује кључне факторе као што су геометријски параметри, изложеност саобраћају (нпр. просечан годишњи дневни саобраћај – ПГДС, просечна брзина), као и изведене индикаторе ризика који адекватније одражавају комплексне услове у којима се саобраћај реализује. Посебна вредност модела лежи у способности да повеже више различитих утицаја, што је омогућено управо применом техника машинског учења и рачунарске интелигенције, за разлику од традиционалних приступа који се често ослањају на изоловане анализе појединачних параметара. Захваљујући овом приступу, модел врши ефикаснију предикцију броја саобраћајних незгода.

Један од највећих доприноса овог дела дисертације јесте у географском и методолошком обиму израђеног модела. За разлику од ранијих студија које су се базирале на одређеном броју деоница (Glavić *et al.*, 2016; Pljakić *et al.*, 2019; Mičić *et al.*, 2022), овај модел обухвата

целокупну мрежу IB реда, пружајући могућност систематске анализе и подршке при доношењу одлука на државном нивоу (*Jevremović and Šelmić, 2026*). Осим тога, модел је конципиран тако да буде лако употребљив, иако је калибрисан на основу локалних услова, може бити једноставно адаптиран и на друге државе или регионе са сличном структуром података.

## 5.2 Преглед релевантних истраживања за предикцију саобраћајних незгода

Израда модела за предвиђање саобраћајних незгода представља значајну област, посебно када је циљ препознавање опасних места и разумевање фактора који утичу на појаву незгода. Модели најчешће укључују индикаторе као што су ПГДС (*Chen and Xie, 2016; Dutta and Fontaine, 2019; Basso et al., 2020; Yocum and Gayah, 2022; Xiao et al., 2024*), просечне брзине (*Sun and Sun, 2015; Mujalli et al., 2023; Bhattarai et al., 2025*), геометријске особине (као што су ширина саобраћајне траке и радијус кривина) (*Anastasopoulos and Mannering, 2009; Xie et al., 2012; Das et al., 2021; Rahman et al., 2021; Silva et al., 2021*), стање и квалитет коловоза (*Li et al., 2013; Elghriany et al., 2016; Choudhary et al., 2024*) као и карактеристике животне средине или понашања возача (*Asadi et al., 2022; Astarita et al., 2023; S. Ahmed et al., 2023; Shaffiee Haghshenas et al., 2025*).

ПГДС се готово универзално користи као основни индикатор изложености, док се геометријске карактеристике пута често везују за конструктивне ризике. Брзина се, у зависности од контекста, може тумачити и као показатељ начина вожње и као индиректан показатељ прилагођености пута. Са друге стране, новије студије чешће примењују регресионе технике попут Поасонових и биномних модела, као и различите методе машинског учења које омогућавају бољу обраду комплексних интеракција (*Goh et al., 2014; Karacasu et al., 2014; Wang et al., 2015; Dereli and Erdogan, 2017; Hyodo and Hasegawa, 2021; Nasri and Aghabayk, 2021*).

У региону југоисточне Европе, бројне студије су се бавиле испитивањем узрочника незгода на просторно ограниченим нивоима. У Мађарској, *Borsos (2014)* је израдио моделе за двотрачне ванградске путеве користећи променљиве попут ПГДС-а, ширине пута и радијуса кривина, чиме је указао на снажан утицај геометрије и саобраћајног оптерећења. У Румунији је утврђено да високи нивои протока имају значајан утицај на фреквенцију незгода (*Cadar et al., 2017*), док су хрватска истраживања ишла ка демографским моделима ризика, анализирајући старосну структуру страдалих (*Vorko-Jović and Jović, 1992*).

Истраживања у Србији добијају на значају у последњој деценији. Једно од иницијалних истраживања био је рад *Главића et al. (2016)*, који су се ослонили на класичне регресионе технике за процену утицаја геометријских елемената, као што су радијуси кривина и ширина пута, али на ограниченом узорку деоница. Други аутори су применили методе временских серија (нпр. ARIMA, SARIMA) за анализу трендова незгода у појединим општинама или градовима (*Pljakić et al., 2021*) или већим урбаним центрима као што је Београд (*Deretić et al., 2022*), али без укључивања просторних и инфраструктурних аспеката, што ограничава интерпретацију добијених резултата.

Претходних неколико година, јављају се напреднији приступи засновани на машинском учењу. Тако су примењивани алгоритми као што су Random Forest (*Pljakić et al.*, 2024) и вештачке неуронске мреже (*Gatarić et al.*, 2023; *Ranković et al.*, 2024), али углавном у ужим географским оквирима, као што је град Нови Сад (*Pljakić et al.*, 2019), или у циљу анализе одређених профила корисника (*Čubranić-Dobrodolac et al.*, 2017). Међутим, ниједна од ових студија није обухватила модел на националном нивоу који би систематски интегрисао геометријске, изложене и понашајне факторе за целу категорију путева. Насупрот томе, истраживање које је овде представљено доноси свеобухватан модел предикције за државну мрежу путева IB реда у Србији. Овај модел обједињује велики број променљивих, укључујући не само основне податке попут ширине траке, радијуса и нагиба, већ и ПГДС, брзину, као и изведене променљиве које повезују више карактеристика у интегралне параметре ризика. За разлику од претходних истраживања која су користила ограничен скуп променљивих (обично мање од пет), овај модел нуди ширу и реалнију слику услова на терену. У том смислу, модел успешно недомешћује недостатке у постојећој научној литератури у Србији, док његова модуларна структура омогућава примену и у другим земљама са сличним саобраћајним и социоекономским контекстом.

### **5.3 Методологија истраживања за потребе израде модела предикције саобраћајних незгода по километру пута на подручју Србије**

Српска државна путна мрежа класификована је у пет основних категорија (видети Табелу 4), при чему је критеријум поделе заснован на техничко-експлоатационим особинама и просторном значају сваке категорије пута.

За потребе овог истраживања, анализирана је мрежа ванградских путева IB реда у Србији (приказана на Слици 20). Укупна дужина мреже је 4455,2 km (Табела 4), док је укупан број анализираних деоница 186.

Као што је већ поменуто у претходном поглављу дисертације, мрежа државних путева IB реда изабрана је из неколико разлога:

- ово је категорија са најдужом мрежом у Републици Србији за коју су били доступни потпуни и актуелни подаци ([https://www.putevi-srbije.rs/images/pdf/referentni-sistem/2.1\\_ukupna\\_duzina\\_drzavnih\\_puteva.pdf](https://www.putevi-srbije.rs/images/pdf/referentni-sistem/2.1_ukupna_duzina_drzavnih_puteva.pdf)) (Табела 4);
- ова категорија мреже индукује највећи број саобраћајних незгода у односу на друге категорије, што је од важности за статистичке анализе и моделирање које је спроведено у оквиру овог дела истраживања (<https://bazaabs.abs.gov.rs/absPortal/>) (Табела 4);
- путеви у овој категорији представљају део ванградске мреже која је ниже категорије од ауто-путева који су највиша категорија у Србији. Ауто-путеви су искључени због својих карактеристика које дају приоритет оптималном нивоу услуге, комфора и безбедности: карактеришу их велики радијуси хоризонталних кривина, минимални нагиби и најшире саобраћајне траке, а све са циљем максимизирања ефикасности и омогућавања већих брзина. Бројни истраживачи су показали да сложеност

саобраћајних услова повећава вероватноћу саобраћајних незгода (Zhu et al., 2019; Awasthi et al., 2024), те зато ауто-путеви нису узети у обзир у овом делу истраживања.

Информације о карактеристикама путева и саобраћајном оптерећењу прибављене су од стране Јавног предузећа „Путеви Србије”, док су подаци о саобраћајним незгодама за период 2021–2023. године преузети са званичне платформе Министарства унутрашњих послова Републике Србије (<https://data.gov.rs/sr/datasets/podatsi-o-saobratshajnim-nezgodama-po-politsijskim-upravama-i-opshtinama/>). За потребе развоја модела предикције, коришћене променљиве класификоване су у две основне категорије – примарне (све променљиве које су приказане на Слици 41) и изведене.

Карактеристике пута	Генерални елементи пута	Карактеристике пута	Хоризонтална геометрија	Карактеристике саобраћаја	ПГДС
	<ul style="list-style-type: none"> <li>Дужина деонице</li> <li>Број трака</li> <li>Ширина коловоза</li> <li>Ширина траке</li> </ul>		<ul style="list-style-type: none"> <li>Елемент</li> <li>Радијус</li> <li>Дужина радијуса</li> </ul>		<ul style="list-style-type: none"> <li>Просечан годишњи дневни саобраћај</li> </ul>
	Банкине		Вертикална геометрија		Брзина
	<ul style="list-style-type: none"> <li>Ширина банке</li> </ul>	<ul style="list-style-type: none"> <li>Елемент</li> <li>Нагиб</li> <li>Дужина нагиба</li> </ul>	<ul style="list-style-type: none"> <li>% прекорачења брзине</li> <li>% возила који прекорачују брзину за више од 20km/h</li> </ul>		
	Квалитет коловоза				
	<ul style="list-style-type: none"> <li>ИРИ</li> </ul>				

Слика 41. Примарне променљиве коришћене у изради модела предикције саобраћајних незгода за државне путеве IБ реда у Србији

Полазећи од основног скупа од 15 примарних променљивих, израчунат је проширени скуп од 51 изведене променљиве, са циљем да модел боље одрази реалне услове на терену и обухвати сложене аспекте као што су конфигурација пута, саобраћајно окружење и карактеристике понашања учесника у саобраћају. Иако укупни број изведених променљивих обухвата велики број комбинација и трансформација, у наставку је ради прегледности приказан само ограничен број репрезентативних примера.

Параметар који представља однос између стања коловоза и брзине кретања возила (ОИБ) користи се као индикатор утицаја који карактеристике пута имају на понашање возача. Више вредности овог односа обично указују на повећани ризик од настанка саобраћајних незгода, јер одражавају неповољну интеракцију између физичког стања пута и начина на који се возила крећу том деоницом.

$$\text{ОИБ} = \text{ИРИ/Брзина} \quad (75)$$

Показатељ густине саобраћајног тока (ГС) директно одражава степен оптерећења пута. Када ова вредност расте, то обично указује на већу вероватноћу настанка загушења, што може негативно утицати на проток и безбедност саобраћаја.

$$ГС = ПГДС/Дужина деонице \quad (76)$$

Индекс променљивости/варијабилности протока (ИВП) служи за процену колико је саобраћај стабилан или непредвидив. Високе вредности овог индикатора сигнализирају да долази до честих осцилација у интензитету саобраћаја, што може довести до нестабилних услова на путу и самим тим повећати ризик од незгода.

$$ИВП = st. dev \text{ ПГДС}/\text{ПГДС} \quad (77)$$

Индекс прилагођења протока проценту прекорачења брзине (ИПТП) представља показатељ који комбинује оптерећење пута са учесталашћу прекорачења брзине. Ова мера одражава процењени број возача који током дана возе брже од дозвољеног на посматраној деоници. Индекс модификује вредност укупног протока (ПГДС) у складу са уделом возача који крше ограничења брзине. Виша вредност ИПТП-а указује на већу концентрацију прекорачења брзине, што сугерише повишен ризик од саобраћајних инцидентата.

$$ИПТП = ПГДС \times \left( \frac{\% \text{ прекорачења}}{100} \right) \quad (78)$$

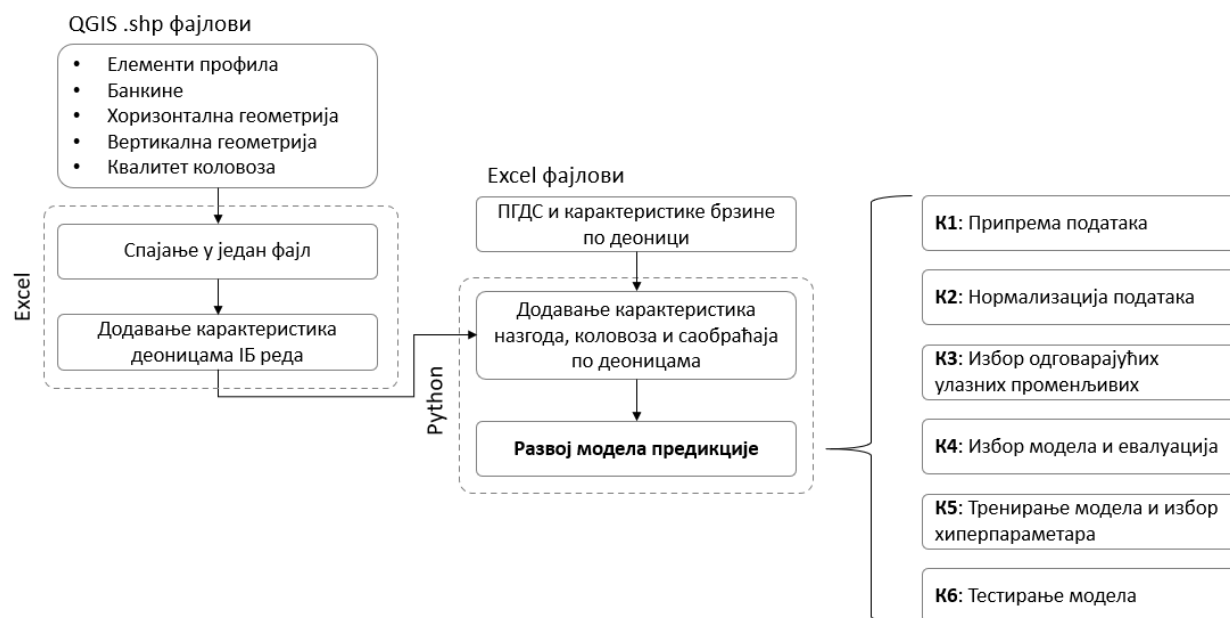
Индекс варијабилности брзине (ИВБ) представља меру флукуација у брзини вожње и користи се за идентификацију нестабилних услова у саобраћајном току. Више вредности овог индекса указују на значајне разлике у брзини између возила, што повећава ризик од настанка незгода.

$$ИВБ = st. dev \text{ Брзина}/\text{Брзина} \quad (79)$$

У процесу анализе података коришћени су софтвери QGIS 3.26.3, MS Excel и Python 3.10. Слика 42 приказује општу шему која обухвата кораке од припреме података до спровођења анализе.

Развој модела за предикцију саобраћајних незгода спроведен је кроз више узастопних корака, при чему је циљ био предвиђање броја саобраћајних незгода по километру пута на државној путној мрежи ИБ реда у Републици Србији. Као излазна променљива у моделу коришћен је укупан број саобраћајних незгода по километру пута, који обухвата све категорије незгода (са материјалном штетом, са повређеним лицима и са погинулим лицима). У првом кораку извршена је припрема података. Ова фаза обухватила је преглед и уређивање базе података, уклањање непотребних колона и проверу конзистентности података. Празне или непотпуне вредности су кориговане или уклоњене како би се обезбедила поузданост и употребљивост скупа података за даљу анализу.

Након припреме података извршена је нормализација свих улазних променљивих. Нормализација је примењена како би се различите променљиве, које имају различите опсеге вредности и јединице мере, довеле на упоредив ниво. На тај начин се спречава да променљиве са већим нумеричким вредностима имају непропорционално велики утицај на процес учења модела, чиме се побољшава стабилност и ефикасност алгоритама машинског учења.



**Слика 42.** Кораци за припрему, анализу података и развој модела предикције саобраћајних незгода за државне путеве IБ реда у Србији

У наредном кораку извршен је избор релевантних променљивих за израду модела. Полазни скуп података садржао је 15 основних променљивих, којима су додате њихове изведене променљиве, тако да је укупан број потенцијалних улазних променљивих износио 51. Због великог броја променљивих било је неопходно извршити њихову селекцију, како би се избегла прекомерна сложеност модела и могућност пренапрегнутости (енг. *overfitting*). За ту сврху примењена је SHAP (енг. SHapley Additive exPlanations) анализа (спроведена у Python 3.10. окружењу), на основу које је идентификовано 12 најзначајнијих променљивих које су укључене у коначни модел предикције. Додатно је извршена корелација између изабраних променљивих како би се проверило да ли постоји висока међусобна зависност, при чему није уочена значајна мултиколинеарност. SHAP метода омогућава процену релативног доприноса сваке улазне променљиве у формирању излазне вредности модела, засновану на концепту теорије игара. Предност SHAP приступа је у томе што омогућава интерпретацију сложених модела машинског учења и квантитативну процену значаја сваке променљиве у односу на предикцију циљне променљиве. На тај начин могуће је идентификовати оне факторе који имају највећи утицај на предвиђени број саобраћајних незгода по километру пута. Поред тога, SHAP анализа је посебно погодна у контексту алгоритама машинског учења заснованих на стаблима одлучивања, који су примењени у овој докторској дисертацији, јер омогућава директну процену утицаја сваке променљиве на предикцију модела.

У четвртном кораку извршен је избор одговарајућих алгоритама машинског учења за предикцију. У анализу су укључени најчешће коришћени алгоритми који су се у претходним истраживањима показали ефикасним у проблемима предвиђања саобраћајних незгода, укључујући AdaBoost, CatBoost, XGBoost, ANN и друге сродне методе, при чему је укупно тестирано десет различитих модела. Перформансе модела упоређене су на основу

коэффициента детерминације ( $R^2$ ), применом поступка унакрсне валидације, како би се обезбедила стабилна и поуздана процена њихове предиктивне способности. Модел који је остварио највећу вредност коэффициента  $R^2$  изабран је као најпогоднији за даљу примену.

Након избора најбољег алгоритма извршено је финално тренирање модела и подешавање његових хиперпараметара. У процесу оптимизације посебна пажња посвећена је параметрима који имају највећи утицај на перформансе модела, као што су максимална дубина стабла, корак учења и број итерација. Подешавањем ових параметара настојало се да се постигне оптималан баланс између тачности модела и његове способности генерализације. У последњем кораку спроведено је тестирање коначног модела на издвојеном скупу података, како би се проверила његова способност предвиђања на подацима који нису коришћени током процеса тренирања. Ова фаза омогућила је додатну проверу стабилности и применљивости развијеног модела.

#### 5.4 Резултати израде модела предикције саобраћајних незгода за путну мрежу ИБ реда у Србији за период од 2021. до 2023. године

Ово потпоглавље обухвата више сегмената у којима су представљене кључне особине улазних података (променљивих), као и кораци развоја и евалуације модела за прогнозирање саобраћајних незгода.

##### 5.4.1 Основне карактеристике деоница

Укупно је обрађено 186 деоница државних путева категорије ИБ. Њихове основне карактеристике дате су у Табели 18, као што је већ било представљено у претходном поглављу овог рада.

Табела 19 приказује временску расподелу саобраћајних незгода према типу.

Табела 18. Карактеристике деоница путева ИБ реда анализираних у докторској дисертацији

Карактеристике	Минимум	Максимум	Просек	Std Dev
Дужина одсека (km)	0,75	39,05	11,26	8,56
Ширина банке (m)	0,00	3,85	1,32	0,46
Ширина коловоза (m)	3,40	16,50	7,24	1,52
Број саобраћајних трака	1,00	4,00	2,00	0,11
Ширина траке* (m)	2,75	3,75	3,40	0,75
Квалитет стања коловоза (ИРИ)	0,58	15,97	2,94	1,62
Дужина хориз. кривине (m)	11,07	6216,40	459,36	597,84
Радијус хориз. кривине	30,00	5000,00	640,86	2921,65
Подужни нагиб (%)	-8,60	9,30	-0,04	1,57
Дужина подужног нагиба (m)	135,71	1929,39	482,55	219,39
ПГДС (воз/дан)	318,00	21177,00	5514,94	4324,07
Брзина (km/h)	33,85	90,03	68,40	8,54
% прекорачења брзине	0,00	99,0	47,0	29,0
% прекорачења за >20 km/h	0,00	81,0	13,0	15,0

\* Пошто база није садржала тачну ширину траке, она је израчуната као ширина коловоза / број трака

Укупно је анализирано 4065 незгода, од којих је 1766 било са материјалном штетом, 2151 са повређеним лицима и 148 са смртним исходом. Уочава се опадајући тренд и у укупном броју незгода и у броју незгода по врсти током периода од 2021. до 2023. године. Такав образац може бити индикација позитивних структурних или политичких интервенција у области безбедности саобраћаја.

Такође је важно истаћи да је укупан број саобраћајних незгода на терену већи од оног који је обухваћен анализом у овом истраживању. То је последица чињенице да неке деонице путева, иако су категорисане као ванградске, пролазе кроз урбана или насељена подручја и као такве су биле део почетне ГИС базе.

**Табела 19.** Расподела незгода по врсти на државним путевима IБ реда у Србији

	Материјална штета	Повређени	Погинули	Укупно
<b>2021</b>	734	830	61	1625
<b>2022</b>	606	715	47	1368
<b>2023</b>	426	606	40	1072
<b>Σ</b>	<b>1766</b>	<b>2151</b>	<b>148</b>	<b>4065</b>

Како се истраживање у оквиру дисертације фокусира искључиво на деонице ванградске мреже, све деонице које се физички налазе унутар градских зона искључене су из финалне анализе и одстрањене из почетног скупа података.

#### 5.4.2 Развој модела предикције саобраћајних незгода за подручје Србије

Процес развоја модела за предвиђање саобраћајних незгода реализован је у шест међусобно повезаних фаза, које су детаљно објашњене у наредним деловима рада.

##### *Корак 1: Припрема података*

Почетни скуп података увезен је из јединствене базе која обједињује информације о саобраћајним и инфраструктурним карактеристикама, обухватајући трогодишњи период, од 2021. до 2023. године. У фокусу анализе налази се зависна променљива – нормализована стопа саобраћајних незгода – која је дефинисана на следећи начин:

$$\text{Укупно незгода по } km = \text{Укупно незгода} / \text{Дужина одсека } (km) \quad (80)$$

У почетној фази, испитано је више алтернативних решења, укључујући засебно моделирање броја незгода са материјалном штетом, повређеним лицима и смртним исходом, као и њихових стопа по јединици дужине пута. Међутим, показало се да укупан број незгода по километру пружа најстабилније и најпоузданије резултате у свим тестираним моделима.

Иако је оправдано претпоставити да различите врсте незгода имају специфичне карактеристике и тежину, агрегирана мера је одабрана због своје робусности и способности да обухвати укупни ниво безбедности одређене деонице пута. Моделирање озбиљнијих исхода, као што су незгоде са повређенима или погинулима, остаје као правац за будућа истраживања, под условом да се обезбеди детаљнија и поузданија база података.

У оквиру припреме података, из изворног Excel фајла уклоњене су колоне које нису биле релевантне за анализу (нпр. иницијални број незгода), а за редукцију утицаја екстремних вредности примењено је уклањање на 1. и 99. перцентилу за сваку променљиву. Пошто је број недостајућих вредности био занемарљиво мали (мање од 1% укупног скупа), оне су замењене медијаном по колони, прилагођеној конкретної деоници пута.

### **Корак 2:** *Нормализација података*

Све бројчане променљиве нормализоване су применом z-стандардизације, како би се обезбедила упоредивост вредности различитих размера:

$$z = (x - \mu) / \sigma \quad (81)$$


При томе,  $x$  представља почетну вредност променљиве,  $\mu$  просечну вредност, а  $\sigma$  стандардно одступање. Ова трансформација омогућава да се променљиве различитих јединица мерења и опсега доведу на заједничку скалу и међусобно пореде.

### **Корак 3:** *Избор одговарајућих улазних променљивих*

Одабир улазних променљивих извршен је применом SHAP методологије, која омогућава процену утицаја сваке појединачне променљиве на тачност модела. Вредности SHAP-а су израчунате ради мерења релативне важности, при чему је рангирање извршено према просечној апсолутној вредности SHAP коефицијента. Да би се смањио ефекат мултиколинеарности међу независним променљивим, извршена је анализа парцијалних корелација, где су парови са апсолутном вредношћу корелације већом од 0,5 идентификовани као високо повезани. У таквим случајевима, задржавана је променљива са већим SHAP утицајем, док је друга искључена из модела.

У овом делу рада приказани су само статистички значајне улазне променљиве које су задржане након финалне селекције. На збирном SHAP графикону (Слика 43), највећи утицај показује променљива густина саобраћајног тока, која има не само висок просечни допринос, већ и велику дисперзију у утицају, што указује на њену стабилну и значајну улогу у моделирању стопе незгода.


Поред ње, високу предиктивну снагу исказују и карактеристике као што су тип хоризонталног елемента и однос радијуса кривине у односу на њену дужину. Неки индикатори повезани са геометријом и изложеношћу, мада ранжирани ниже, и даље имају релевантан утицај. Графички приказ боја SHAP тачака указује на правац утицаја – више вредности, као што је случај са ГС-ом, углавном доводе до повећаног ризика (црвена боја на десној страни), док ниже вредности имају супротан ефекат. Ови резултати наглашавају значај интеграције саобраћајног протока и геометријских атрибута у прогнозирању стопе незгода по јединици дужине пута.



**Слика 43.** Утицај променљивих на предвиђени ризик од настанка саобраћајне незгоде


Графички приказ просечних SHAP вредности (Слика 44) пружа увид у релативну важност сваког улаза у структури модела. Најмање утицајни атрибути су ширине банке или неки димензиони параметри пута, који показују знатно мањи утицај на предикцију, што указује на њихову ограничену применљивост у овом контексту.

Ови резултати додатно поткрепљују тезу да параметри везани за интензитет саобраћаја, као и кључне геометријске одлике пута, представљају централне ослоњце у развоју робусних модела за предвиђање ризика од саобраћајних незгода.



**Слика 44.** Рангирање важности улазних променљивих за израду модела предикције

Завршни корак у верификацији погодности изабраних променљивих подразумевао је анализу међусобне повезаности, спроведену коришћењем корелационе анализе (приказано на Слици 45).



Слика 45. Корелациона матрица зависности улазних променљивих

У складу са раније утврђеним критеријумом искључења ( $|r| > 0,5$ ), све променљиве које су задржане за даљу анализу нису међусобно снажно повезане, што омогућава избегавање проблема мултиколинеарности у моделирању.

#### Корак 4: Избор модела и његова евалуација


Пратећи општеприхваћене методолошке оквире у овој области, за потребе овог истраживања примењен је приступ селекције најприкладнијег алгорита за предиктивно моделирање, заснован на релевантној литератури и доказаним резултатима. Технике (алгоритми) машинског учења представљене у наставку изабране су због своје потврђене ефикасности у сличним истраживачким сценаријима, као и због њихове честе примене у претходним студијама. Поред тога, изабране технике су током иницијалне фазе тестирања у оквиру овог рада показале задовољавајуће перформансе, што је додатно потврдило њихову применљивост у контексту анализе ванградске путне мреже.

Коришћени су различити алгоритми засновани на boosting техници и ансамбл дрвећу (decision trees), као што су Gradient Boosting (Elyassami et al., 2021; Ameksa et al., 2022; Dong

et al., 2022), HistGradientBoosting (Tamim Kashifi and Ahmad, 2022), CatBoost (Ma et al., 2021; G. Li et al., 2023), LightGBM (W. Zhang et al., 2022; S. Ahmed et al., 2023; Charm et al., 2024), XGBoost (Z. Zhang et al., 2022; Hou, 2023), AdaBoost (Labib et al., 2019; Ariannezhad et al., 2020; J. Li et al., 2023), Random Forest (Venkat et al., 2020; Alagarsamy et al., 2021; Augustine and Shukla, 2022; Zeng et al., 2022) и једноставни Decision Trees (Geyik and Kara, 2020; Parra et al., 2020; Almanie, 2023). Такође је разматран метод Quantile Regression (Khattak et al., 2016; Xu and Duan, 2017; Pitarque and Guillen, 2022). Ради обезбеђивања поуздане и непристрасне процене перформанси алгоритама, иницијални скуп података подељен је у различите размере за тренинг и тестирање – 90 : 10, 85 : 15, 80 : 20, 75 : 25 и 70 : 30. За сваки од ових односа, подскуп намењен за тренинг коришћен је за спровођење петоструке унакрсне валидације на више модела предикције. Оваква процедура омогућила је директно поређење алгоритама у различитим сценаријима расподеле података, уз очување независности тест-сета ради финалне евалуације.

Комбинације алгоритама и пропорције података са најбољим просечним резултатом  $R^2$  током унакрсне валидације идентификоване су као најпогодније. Одабрани алгоритам је затим додатно тестиран на свом издвојеном тест-сету, при чему су упоређени резултати добијени са подразумеваним и одабраним (тј. подешеним) хиперпараметрима. На овај је начин процес селекције и фино подешавање параметара извршено искључиво на тренинг подацима, чиме је избегнута потенцијална пристрасност услед „цурења” информација, при чему је постигнута боља способност алгорита у примени на новим подацима.

Преглед упоредних резултата свих тестираних алгоритама дат је на Слици 46.



Слика 46. Компарација изабраних алгоритама за предикцију саобраћајних незгода у Србији

Од свих алгоритама који су дали најбоље резултате, укључујући CatBoost, Gradient Boosting и XGBoost, као финално решење за предикцију броја незгода одабран је CatBoost. Иако су сва три алгоритма показала веома сличне просечне вредности коефицијента детерминације ( $R^2$ ) током петоструке унакрсне валидације, CatBoost се истакао највишом средњом  $R^2$  вредношћу (0,6491), као и најмањом вредношћу стандардне девијације (0,0592). Ово указује на то да је ова техника не само најефикаснија у просеку већ и најстабилнија у перформансама кроз различите подскупове података.

#### **Корак 5:** Финално тренирање модела и избор хиперпараметара

CatBoost алгоритам одабран је као најадекватнији на основу иницијалне процене учинка на подацима за тренирање. Ради унапређења предиктивне ефикасности, спроведено је детаљно подешавање хиперпараметара уз примену технике мрежне претраге (енг. *grid search*) и уз троструку унакрсну валидацију. Тако добијени резултати упоређени су са онима који су добијени применом подразумеваних вредности параметара у оквиру CatBoost модела.

Параметри који су били предмет подешавања обухватили су:

- **максималну дубину стабала** (енг. *depth*): [4, 6, 8], која одређује капацитет модела и његову тенденцију ка zasiћењу;
- **корак учења** (енг. *learning rate*): [0,01, 0,05, 0,1], који контролише брзину конвергенције и утиче на стабилност и тачност;
- **број итерација** (енг. *iterations*): фиксирано на 200, како би се обезбедила равномерна основа за упоређивање различитих конфигурација.

Критеријум за избор најбољег скупа параметара била је вредност коефицијента детерминације ( $R^2$ ). По избору најбоље комбинације параметара, финална верзија алгоритма поново је тренирана, а затим тестирана на независном скупу података користећи  $R^2$ , MAE и RMSE као метрике перформанси. Овим је обезбеђено да и тачност и способност моделирања нових података буду објективно процењене и унапређене.

#### **Корак 6:** Тестирање модела

CatBoost алгоритам, у својој иницијалној конфигурацији са подразумеваним вредностима параметара, остварио је знатно боље резултате у односу на верзију са ручно подешеним хиперпараметрима (видети Табелу 20).

**Табела 20.** Резултати тестирања CatBoost алгоритма за предикцију саобраћајних незгода

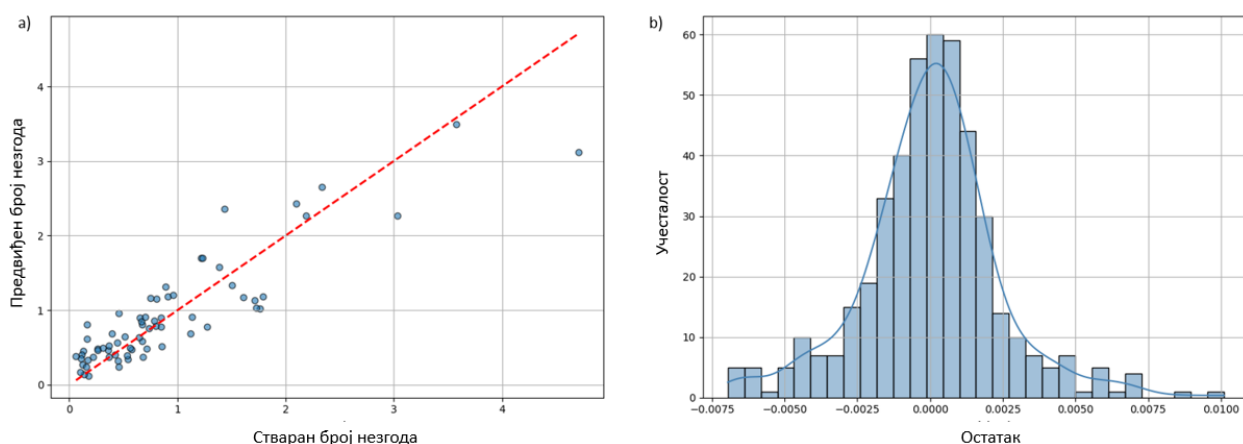
Параметри модела	$R^2$	MAE	RMSE
Подразумевани	0,7934	0,2805	0,3822
Подешени	0,7230	0,3020	0,4426

Постигнути резултати показују да је модел заснован на CatBoost алгоритму у својој подразумеваној конфигурацији (дубина стабала 6, learning rate 0,03 и до 1000 итерација са механизмом раног заустављања) већ био изузетно добро усклађен са структуром података коришћених у овом истраживању. Са друге стране, верзија алгоритма са ручно подешеним

параметрима базирана је на уском опсегу вредности (дубина од 4 до 8, брзина учења од 0,01 до 0,1 и фиксно 200 итерација), што је могло ограничити способност алгоритма да идентификује сложеније обрасце или да се адекватно прилагоди разноврсности података. Посебно, ограничење у броју итерација вероватно је утицало на капацитет алгоритма да постигне конвергенцију у пуној мери.

На Слици 47 приказани су резултати примене CatBoost алгоритма. Слика 47а приказује везу између реалних и предвиђених вредности, при чему се уочава јасна корелација дуж линије идеалног подударарања (црвена испрекидана линија), уз благи тренд прецењивања код већих стварних вредности. Слика 47б представља дистрибуцију остатака која има скоро симетричан, звонасти облик, што указује на приближно нормалну расподелу грешака. Ови налази заједно потврђују да алгоритам CatBoost обезбеђује добру генерализацију и нема значајне системске грешке.

На основу добијених резултата показано је да параметар густина саобраћаја (ГС) има највећи значај и највећи утицај на настанак и предикцију саобраћајних незгода. Овај параметер је изведен на основу базне вредности ПГДС-а. Такође, добијени модел предикције показао је висок ниво ефикасности уз коефицијент детерминације  $R^2 = 79\%$ . Сходно наведеном, може се прихватити Хипотеза 3.



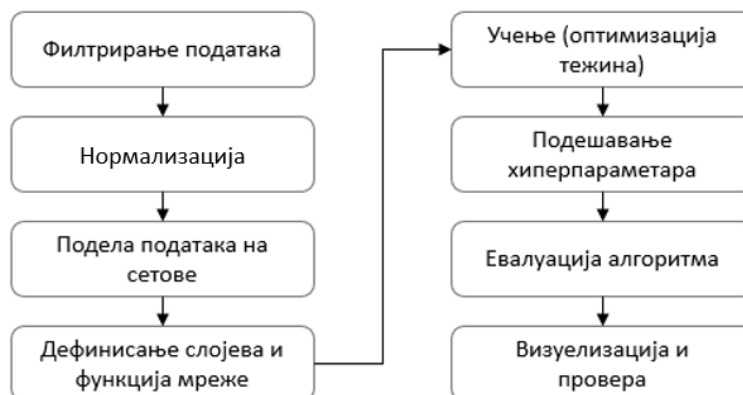
Слика 47. Резултат дијаграми а) предвиђен у односу на стварни број незгода по km, б) расподела остатака

### 5.4.3 Израда и тестирање модела предикције саобраћајних незгода применом вештачких неуронских мрежа

У циљу разматрања модела којима би се добила потенцијално већа прецизност (од претходно приказаних), израђен је и тестиран модел базиран на вештачким неуронским мрежама (енг. *Artificial Neural Networks*, ANN). ANN су примењене управо због своје способности да препознају сложене, нелинеарне односе између улазних променљивих, што их чини посебно погодним за анализу и предвиђање појава као што су саобраћајне незгоде. За разлику од класичних регресионих или статистичких модела, ANN могу да „науче” обрасце у подацима и да их генерализују на нове, непознате ситуације, чиме се повећава њихова предиктивна моћ. Имајући у виду да број незгода по километру пута зависи од више

међусобно повезаних фактора, као што су геометрија пута, брзина, проток и сл., ANN омогућавају поузданије моделирање тих односа у односу на линеарне приступе. У циљу постизања вишег нивоа прецизности и стабилније генерализације, разрађен је и тестиран модел заснован на вештачким неуронским мрежама.

Кораци израде модела ANN дати су на Слици 48, док је детаљно објашњење сваког корака приказано у наставку.



Слика 48. Кораци у развоју и тестирању ANN

**Корак 1. Филтрирање података:** У оквиру овог корака извршена је провера иницијалне базе података која обухвата уклањање редова (у Excel фајлу) који не садрже податке (празна поља), провера логичности постојећих података, провера екстремних вредности и сл. Имајући у виду да је ова процедура већ извршена приликом иницијалне модификације базе података (приликом израде и тестирања претходних модела), у овом кораку није било додатних измена.

**Корак 2. Нормализација:** Како би се омогућило манипулисање подацима (који су представљени на истој скали), извршена је стандардизација:

$$z_i = \frac{x_i - \bar{x}}{s} \quad (82)$$

Где су:

$x_i$  – вредност променљиве за конкретан узорак;

$\bar{x}$  – аритметичка средина (просек) променљиве у целом скупу;

$s$  – стандардна девијација променљиве;

$z_i$  – стандардизована вредност.

**Корак 3. Подела података на скупове:** Овај корак обухвата поделу основног скупа података на скупове за тренирање, валидацију и тестирање. Сходно резултатима досадашњих истраживања у овој области (*Abdelwahab and Abdel-aty, 2002; Xu and Goodacre, 2018; Chinmayi et al., 2025; Vutukuri, 2025*), изабрано је 5 расподела које се најчешће примењују и то:

- 90-5-5
- 80-10-10
- 75-15-10
- 70-15-15
- 60-20-20

За сваку од расподела извршено је претраживање најбољих карактеристика неуронске мреже (броја слојева, неурона, стопе учења, активационе функције итд.), што је обухваћено наредним кораком.

**Корак 4. Дефинисање карактеристика модела:** Број скривених слојева, број неурона по слоју, тип активационе функције, стопа учења и вредност dropout параметра одређени су процесом оптимизације хиперпараметара уз помоћ Keras Tuner библиотеке. Примењен је алгоритам Random Search, који насумично испитује више комбинација параметара и за сваку конфигурацију израчунава вредност грешке (MAE). На основу најмање грешке, одабира се комбинација која даје најбоље резултате.

У оквиру претраге тестиране су следеће групе параметара:

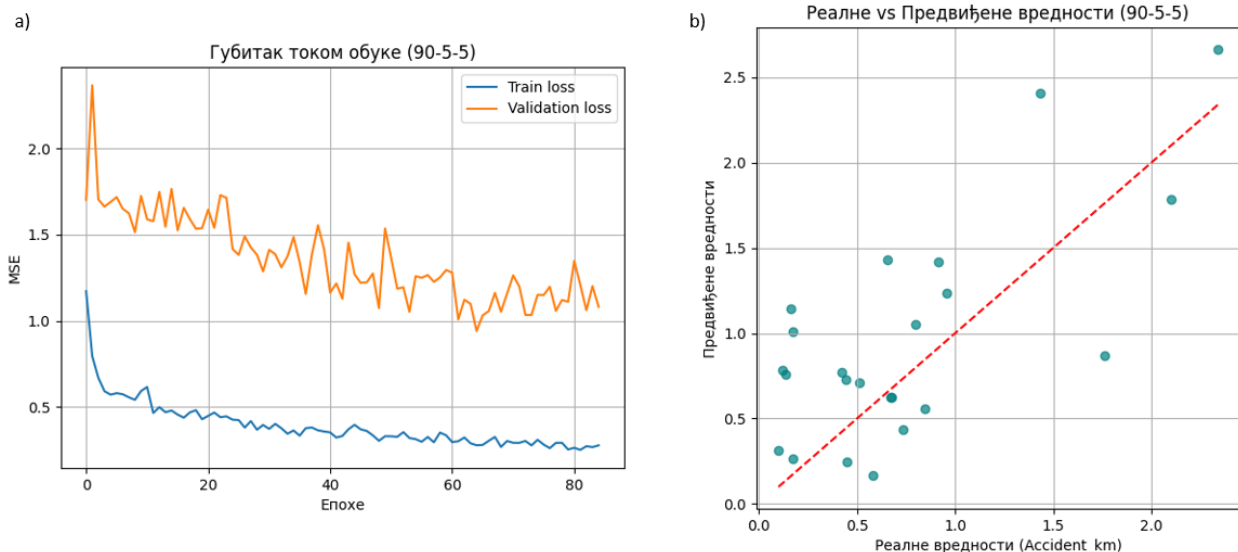
- број скривених слојева: 1, 2 или 3;
- број неурона по слоју: од 8 до 64 (у корацима од 8);
- активационе функције: ReLU, tanh, ELU, sigmoid и softmax;
- стопа учења: 0,001, 0,003, 0,005, 0,007, 0,009 и 0,01;
- dropout вредност: од 0,1 до 0,3 (у корацима од 0,05).

Одабрани опсежи параметара представљају најчешће коришћене вредности у литератури и пракси приликом примене вештачких неуронских мрежа за регресионе задатке јер у већини случајева обезбеђују стабилну конвергенцију и поуздану генерализацију модела. Поред тога, избор ограниченог скупа комбинација броја слојева, неурона, активационих функција и стопа учења омогућио је да процес оптимизације буде ефикасан и временски прихватљив, имајући у виду да би проширивање простора претраге захтевало значајно боље перформансе коришћеног рачунара и знатно дуже време обуке модела.

На овај начин тестирање је спроведено засебно за сваку од пет различитих расподела података на тренинг, валидациони и тест-скуп (90-5-5, 80-10-10, 70-15-15, 60-20-20 и 75-15-10), што је омогућило идентификацију неуронске мреже најбољих карактеристикае.

**Корак 5. Евалуација** алгоритама извршена је применом стандардних метрика: MAE, RMSE и  $R^2$  које су коришћене у исте сврхе и за претходне алгоритме.

На Слици 49 приказани су резултати губитака током обуке, као и реални и предвиђени бројеви саобраћајних незгода по километру пута, за расподелу података 90-5-5.



**Слика 49.** Резултати првог алгоритма ANN за расподелу 90-5-5: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру

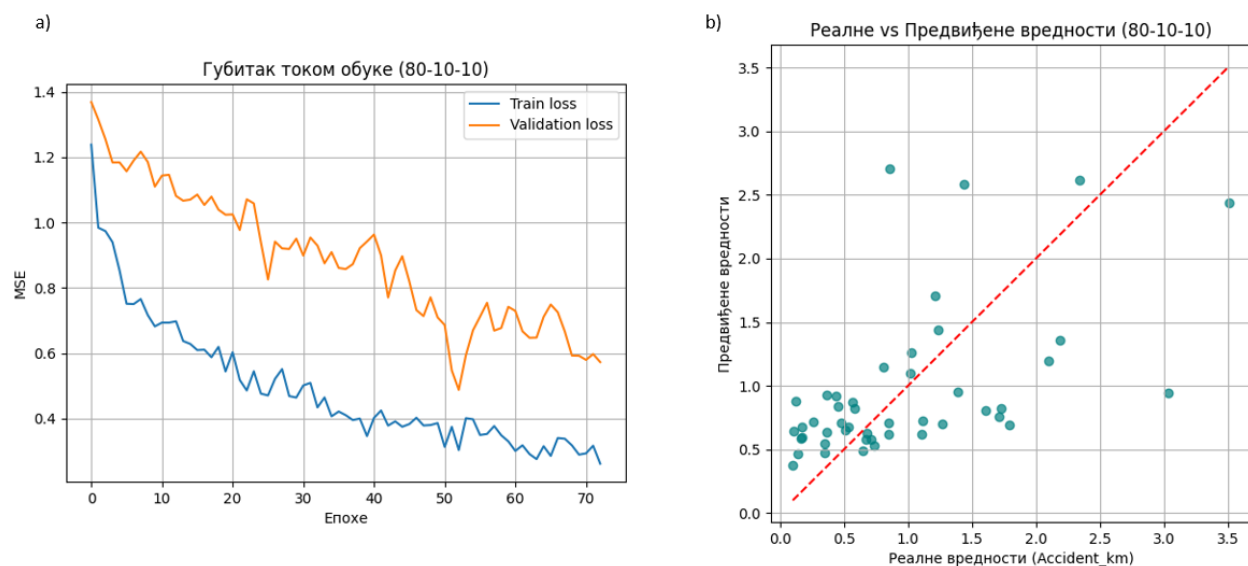
Резултати показују одређен ниво тачности у предвиђању броја саобраћајних незгода по километру пута, што је очекивано имајући у виду комплексност процеса настанка незгода и ограничен број улазних променљивих. На основу графика губитка током обуке, уочава се стабилан пад грешке током тренирања, док валидациона грешка задржава релативно константан ниво уз мање осцилације, што указује да алгоритам има одређену способност генерализације. Ипак, вредности  $R^2$  од 0,28 и нешто веће грешке ( $MAE \approx 0,43$ ,  $RMSE \approx 0,51$ ) показују да алгоритам није у потпуности успео да обухвати све варијације у подацима, вероватно због хетерогености деоница и различитих утицаја геометријских, саобраћајних и контекстуалних фактора који нису обухваћени у моделу.

Дијаграм реалних и предвиђених вредности потврђује постојање позитивне везе између стварних и прорачунатих вредности, али показује и извесну распршеност тачака око дијагонале, што указује да алгоритам добро репродукује општи тренд, али са ограниченом прецизношћу за поједине случајеве. Упркос лошијим резултатима, алгоритам показује потенцијал као основа за даљу оптимизацију, пре свега кроз проширење скупа улазних променљивих (нпр. временски услови, видљивост, тип пута и сл.).

На Слици 50 приказани су резултати губитака током обуке, као и реални и предвиђени бројеви саобраћајних незгода по километру пута, за расподелу података 80-10-10.

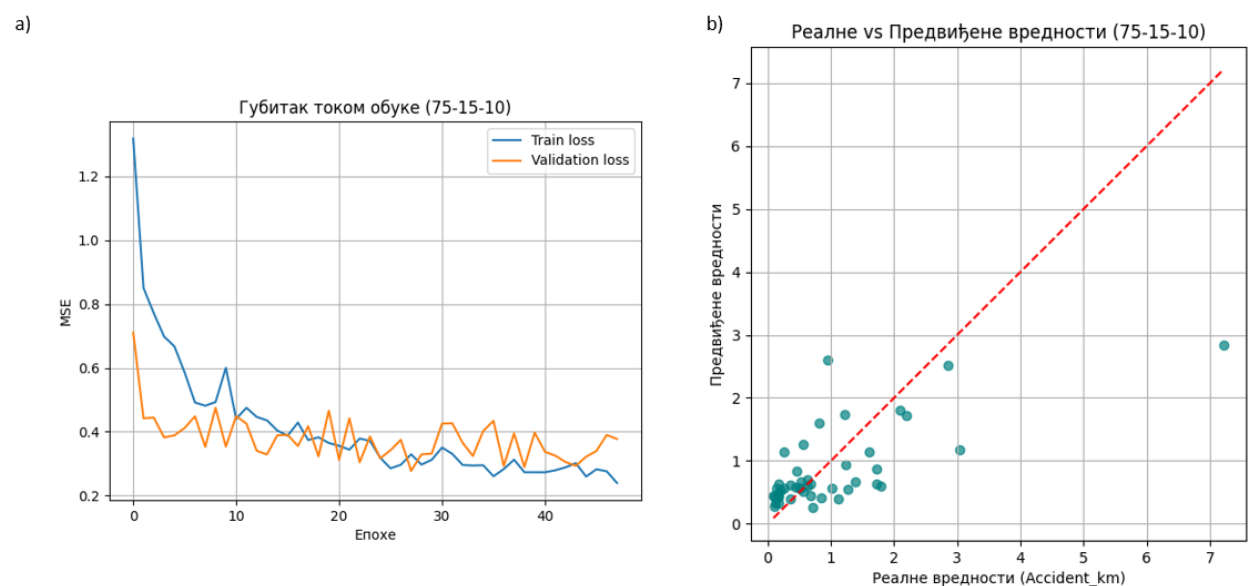
Приказани резултати за расподелу 80-10-10 показују да алгоритам током обуке бележи постепено смањење и тренинг и валидационе грешке, што указује на стабилан процес учења. Разлика између кривих остаје умерена, што значи да је алгоритам задржао способност генерализације и на подацима који нису били обухваћени учењем. Ипак, вредности грешака ( $MAE: 0,49$ ,  $RMSE: 0,66$ ) и  $R^2: 0,28$  указују да предвиђања нису прецизна, што може бити последица комплексности процеса који доводе до саобраћајних незгода и ограниченог скупа улазних променљивих. Дијаграм реалних и предвиђених

вредности показује позитивну корелацију између стварних и прорачунатих вредности, али и присуство већег броја одступања у доњем делу дијаграма, где алгоритам има тенденцију да потцењује више вредности броја незгода по километру.



**Слика 50.** Резултати другог алгоритма ANN за расподелу 80-10-10: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру

На Слици 51 су приказани резултати губитака током обуке, као и реални и предвиђени бројеви саобраћајних незгода по километру пута, за расподелу података 75-15-10.



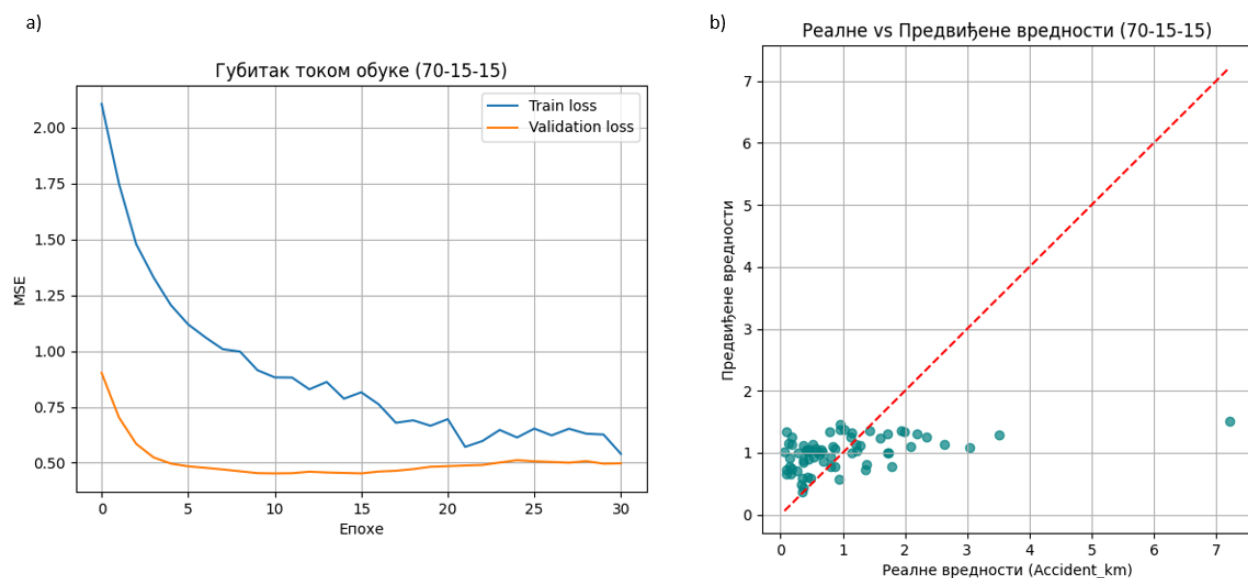
**Слика 51.** Резултати трећег алгоритма ANN за расподелу 75-15-10: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру

На приказаној слици уочава се да модел показује релативно стабилан процес учења са јасним опадањем губитка током епоха, при чему се криве губитака приближавају након

почетних епоха и задржавају у уском опсегу. Такав тренд указује на добру конвергенцију алгоритма и уравнотежено учење, што потврђује и стабилност валидационе грешке. Ипак, дијаграм реалних и предвиђених вредности показује да иако постоји одређена позитивна зависност, предвиђене вредности често потцењују стварне, нарочито у случајевима са већим бројем незгода по километру. Највећа концентрација тачака у доњем левом делу дијаграма сугерише да је већина података концентрисана у домену нижих вредности, што алгоритам релативно добро описује, док су екстремни случајеви мање прецизно предвиђени. Томе сведоче и добијени подаци грешака MAE: 0,53, RMSE: 0,87 и коефицијента детерминације  $R^2$ : 0,45. Ово је уједно алгоритам који је показао најбоље резултате, у односу на све остале алгоритме вештачких неуронских мрежа.

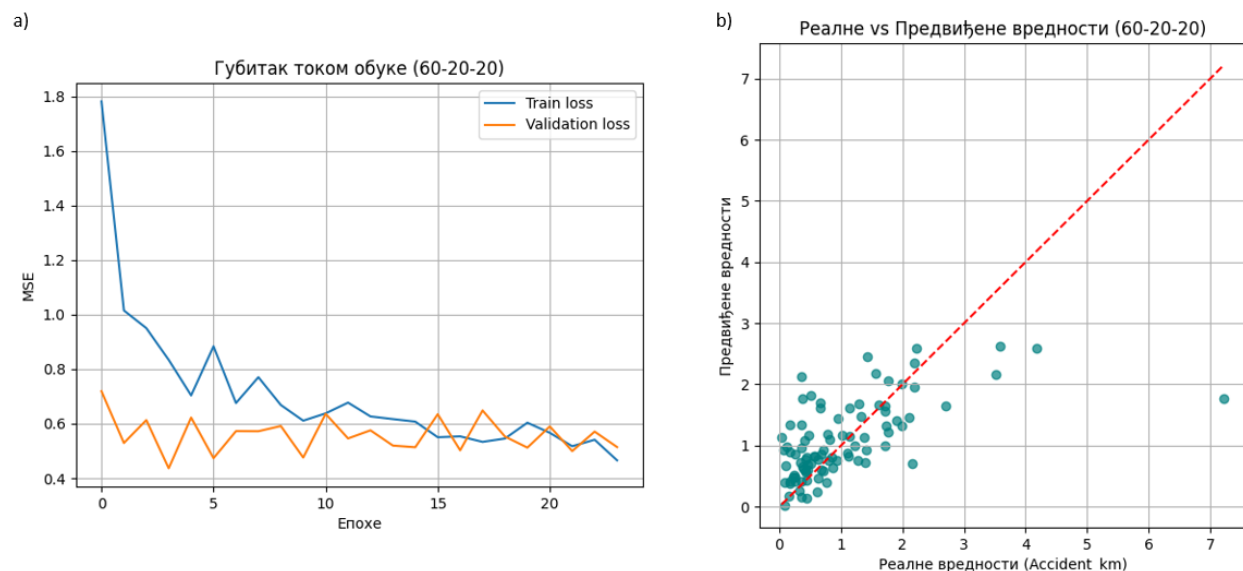
На Слици 52 приказани су резултати губитака током обуке, као и реални и предвиђени бројеви саобраћајних незгода по километру пута, за расподелу података 70-15-15.

Резултати за расподелу 70-15-15 показују да је алгоритам током обуке постигао одређен ниво стабилности конвергенције, уз континуирано смањење губитка током епоха. Криве губитка задржавају приближно паралелан ток, при чему је вредност валидационе грешке нешто нижа од тренинг грешке, што указује на стабилно и конзистентно понашање алгоритма. Овај тренд сугерише да је алгоритам успешно научио основне релације између улазних променљивих и излазне променљиве, али да је његова способност прецизног предвиђања ограничена. Дијаграм реалних и предвиђених вредности потврђује присуство позитивне корелације, али и показује да алгоритам има тенденцију да потцењује више вредности броја незгода по километру, што доводи до већег расипања тачака око дијагонале. Концентрација података у нижем интервалу вредности указује да алгоритам боље описује деонице са мањим ризиком, док су случајеви са већим бројем незгода слабије предвиђени. MAE износи 0,97, RMSE 0,66, а  $R^2$  0,16, што уједно представља и неуронску мрежу са најлошијим резултатима.



**Слика 52.** Резултати четвртог алгоритма ANN за расподелу 70-15-15: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру

На Слици 53 приказани су резултати губитака током обуке, као и реални и предвиђени бројеви саобраћајних незгода по километру пута, за расподелу података 60-20-20.



**Слика 53.** Резултати петог алгоритма ANN за расподелу 60-20-20: а) губици током обуке, б) реалне и предвиђене вредности незгода по километру

Резултати за расподелу 60-20-20 такође указују на стабилан процес обуке алгоритма, при чему се криве губитака постепено приближавају и задржавају у уском интервалу вредности током целог процеса учења. Овакво понашање сугерише да алгоритам постиже одређен баланс између сложености и способности генерализације. На дијаграму реалних и предвиђених вредности уочава се изражена позитивна корелација, где већина тачака прати дијагоналу. Алгоритам добро репродукује тренд раста броја незгода по километру са порастом стварних вредности, мада су присутна мања одступања код већих вредности, што је уобичајено за овакве типове података. MAE у овом случају износи 0,51, RMSE 0,83, док је  $R^2$  0,37.

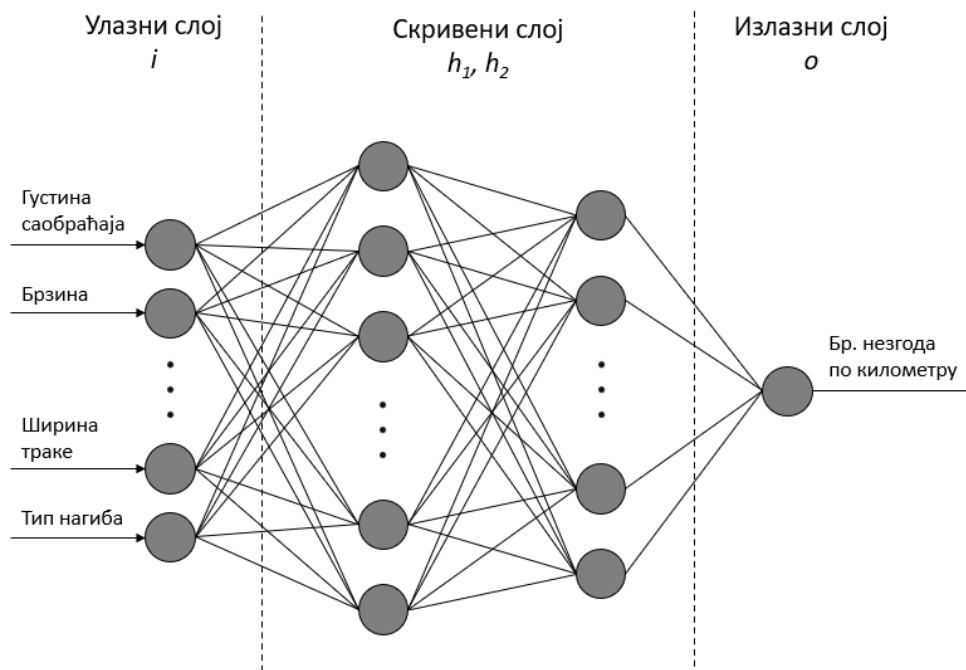
У Табели 21 дате су сумарне карактеристике и резултати израђених неуронских мрежа, док је на Слици 54 приказана структура мреже која је постигла најбоље резултате у предикцији саобраћајних незгода по километру пута. Важно је напоменути да су у Табели 21, као и претходно у тексту, дати само најбољи резултати за сваки од алгоритама, док су за сваки алгоритам појединачно испитиване све наведене комбинације параметара и архитектуре мрежа – стопа учења, активациона функција, број слојева, број неурона итд.

Резултати приказани у Табели 21 показују да су вештачке неуронске мреже постигле одређени ниво прецизности у предвиђању броја саобраћајних незгода по километру пута, али да њихове перформансе нису на задовољавајућем нивоу.

Табела 21. Сумарни приказ карактеристика и резултата израђених алгоритама ANN

Карактеристике мреже	90-5-5	80-10-10	75-15-10	70-15-15	60-20-20
Активациона функција	tanh	relu	relu	softmax	tanh
Слојеви	3	2	2	1	3
Неурони у првом слоју	64	24	48	16	48
Неурони у другом слоју	56	64	8	/	40
Неурони у трећем слоју	8	/	/	/	32
Стопа учења	0,009	0,007	0,01	0,009	0,009
Dropout	0,1	0,25	0,1	0,2	0,2
MAE	0,43	0,49	0,53	0,63	0,51
RMSE	0,51	0,66	0,87	0,97	0,83
R <sup>2</sup>	0,28	0,26	0,45	0,16	0,37

Вредности грешака (MAE и RMSE) указују на умерена одступања између предвиђених и стварних вредности, док су добијени коефицијенти детерминације (R<sup>2</sup>), који се крећу у распону од 0,16 до 0,45, релативно ниски и указују да модели објашњавају ограничени део варијабилности у подацима. Најбоље резултате показале су расподеле 60-20-20 и 75-15-10, али и поред тога степен прилагођености није био довољно висок да би се модел сматрао поузданим за практичну примену.



Слика 54. Архитектура вештачке неуронске мреже која је постигла најбоље резултате (75-15-10 модел)

Из тих разлога, иако ови алгоритми демонстрирају способност препознавања општих трендова, задржани су резултати претходно развијених техника базираних на машинском

учењу који су показали значајно веће вредности коефицијента детерминације и мање вредности грешака, те самим тим обезбеђују поузданију основу за процену ризика и предвиђање саобраћајних незгода.

### **5.5 Дискусија резултата добијених применом модела предикције саобраћајних незгода за путну мрежу IB реда у Србији за период од 2021. до 2023. године**

Модел за предикцију саобраћајних незгода развијен је за ванградске путеве IB реда у Србији применом техника машинског учења постигао је коефицијент детерминације  $R^2 = 0,79$ . Иако поједини национални модели показују веће вредности  $R^2$  – изнад 0,95 (*Pljakić et al.*, 2022; *Gatarić et al.*, 2023) – такви резултати морају се тумачити у светлу специфичних методолошких приступа, инфраструктурних и просторних ограничења (*Glavić et al.*, 2016; *Pljakić et al.*, 2019; *Mićić et al.*, 2022; *Gatarić et al.*, 2023).

Истраживање спроведено у овој дисертацији обухвата широку просторну мрежу ванградских путева, укључујући различите топографске услове. У модел су интегрисане карактеристике пута (радијус кривина, ширина траке и пута и сл.), стање коловоза (храпавост), као и индикатори изложености: ПГДС, просечна брзина, варијабилност брзине и додатни изведени параметри. Постигнута вредност  $R^2$  не само да указује на релативно високу прецизност модела већ одражава и сложеност моделовања незгода у контексту ванградске мреже, где је возња често хетерогена, надзор неадекватан, а инфраструктурни подаци делимично непотпуни. У оквиру овог истраживања, предност је дата свеобухватности и интерпретабилности модела уместо прекомерног прилагођавања подацима, што модел чини једноставним и прикладним за примену у реалним условима.

SHAP анализа је показала да су густина саобраћаја и параметри геометрије пута (врста елемента, однос радијуса и дужине, ширина траке) били најзначајнији предиктори. Ови налази потврђују ранија истраживања која указују на критичну улогу геометрије пута у моделирању незгода (*Mićić et al.*, 2022; *Pljakić et al.*, 2024). Јасне разлике између кластера на основу SHAP профила додатно потврђују унутрашњу валидност модела и пружају увид у то које комбинације фактора највише утичу на вероватноћу настанка незгода.

Просторна анализа је показала да су зоне са највишом предвиђеном густином саобраћаја, а тиме и највећим ризиком од незгода, концентрисане дуж путева који повезују периферију са Београдом. Ови путни правци карактеришу изразито променљиви токови, нарочито током периода миграције и празника. Такви обрасци саобраћаја захтевају додатну пажњу у моделирању јер одступају од стандардне динамике тока која се претпоставља у многим приступима. Резултати су у складу са налазима Главића et al. (2016) и макроанализама Пљакића et al. (2019), који наглашавају значај ванградске мреже.

Ово истраживање допуњује један важан аспект истраживања у домаћој литератури – развој интегрисаних модела предикције саобраћајних незгода за ванградске путеве. Постојећи напори често су били ограничени на временске серије (*Pljakić et al.*, 2021; *Deretić et al.*, 2022), психолошке аспекте (*Ћубранић-Dobrodolac et al.*, 2017) или урбане контексте (*Pljakić*

*et al.*, 2019). Обједињавањем различитих инжењерских и саобраћајних фактора у један предиктивни оквир, овај модел поставља основу за холистички приступ у адекватном планирању мера превенције.

Ипак, потребно је нагласити и ограничења овог истраживања. Пре свега, модел не укључује одређене факторе ризика, попут употребе алкохола, психоактивних супстанци или агресивне вожње, који се у Србији често повезују са настанком незгода (*Road Traffic Safety Agency*, 2023). Такође, метеоролошки фактори попут падавина, магле и температуре нису обухваћени, иако је њихов утицај јасно документован у светској литератури (*Pavlou et al.*, 2023; *Hsu*, 2024; *Zou et al.*, 2024). Важно ограничење односи се и на недостатак јавно доступних података о саобраћајној сигнализацији, посебно у кривинама и на раскрсницама, где ови елементи могу значајно утицати на одлуке и понашање возача. Иако модел постиже добру интерпретабилност, даљи напредак се може постићи применом техника као што су надоградња или слагање модела. Такође, резултати се односе искључиво на ванградску мрежу и не могу се директно пренети на урбане зоне или ауто-путеве који имају различите карактеристике тока, структуре учесника у саобраћају и врсте возила.

У оквиру будућих истраживања планирана је интеграција додатних скупова података високе резолуције, као што су временски услови, понашање (нпр. вожња под дејством алкохола, прекорачење брзине и сл.), као и процене квалитета сигнализације, осветљења и уређаја за управљање саобраћајем. Поред тога, планирано је проширење модела и на друге типове путева, укључујући ауто-путеве, који носе различите карактеристике тока, укључујући већи проценат теретних возила и возила са напредним системима асистенције (ADAS). Надовезујући се на постојећи методолошки оквир, будућа истраживања могу допринети изградњи јединствене националне платформе за предикцију незгода, применљиве у различитим просторним и временским условима.

---

---

# РАЗВОЈ МОДЕЛА ВРЕМЕНСКИХ СЕРИЈА ЗА ПРЕДИКЦИЈУ САОБРАЋАЈНИХ НЕЗГОДА

---

---



## 6.1 Опис проблема

У претходном поглављу представљен је модел предикције саобраћајних незгода заснован на интеграцији саобраћајно-просторних карактеристика (ПГДС, брзина, геометријске карактеристике пута и др.), док су у овом поглављу развијени и анализирани засебни модели који користе дугорочне временске серије високе резолуције, будући да ова два приступа обухватају различите, али узајамно допуњујуће димензије предикције ризика. Већина досадашњих истраживања у домаћој литератури ограничена је на краће временске периоде и агрегиране податке (нпр. на месечном или годишњем нивоу (*Pljakić et al.*, 2021, 2022)), што сужава увид у динамичне и краткорочне промене у појави саобраћајних незгода. Саобраћајни системи, међутим, поседују јасне дневне, недељне и сезонске обрасце, што указује на значај анализе са прецизнијим временским оквиром попут, на пример, часовног.

Употреба временских серија у анализи и предвиђању саобраћајних незгода последњих година добија све већи значај јер омогућава моделовање образаца у времену и препознавање сезонских трендова и неочекиваних/нетипичних одступања. У свету је ова методологија већ дала значајне резултате (*Yousefzadeh-Chabok et al.*, 2016; *Kaunitz*, 2022; *Agyemang et al.*, 2023), али је у Србији и даље недовољно примењивана, посебно у погледу дугорочних и високофреквентних временских серија. Иако су нека претходна истраживања у Србији обрађивала ову тему, она су углавном била ограничена на краће временске периоде (*Pljakić et al.*, 2021) или мању просторну резолуцију (*Deretić et al.*, 2022), као што су месечни или годишњи подаци.

Сходно наведеном, у оквиру овог дела докторске дисертације представљени су резултати израђеног модела предикције саобраћајних незгода који врши предвиђање на часовном нивоу. При изради, тренирању и тестирању модела, коришћен је опсежан скуп података о саобраћајним незгодама у Србији који обухвата период од 1997. до 2024. године. Осим укупног броја незгода, развијени су и модели за предикцију незгода по врсти (са материјалном штетом, са повређеним лицима и са погинулима), као и модели за предикцију незгода по врсти учесника (бициклисти, мотоциклисти, путнички аутомобили, возила јавног превоза и теретна возила). На овај начин омогућено је ефикасније разумевање узрочно-

последичних веза и ризика од настанка незгода, као и прецизније планирање превентивних мера у области саобраћаја.

## **6.2 Преглед релевантних истраживања у области развоја модела временских серија за предикцију саобраћајних незгода у Србији**

У претходном поглављу извршен је преглед литературе која се бави предикцијом саобраћајних незгода, како на глобалном, тако и на националном нивоу, узимајући у обзир карактеристике коловоза, понашање корисника, изложеност и сл. У овом поглављу пажња је усмерена на истраживања која у предикцији користе временске серије на подручју Републике Србије. Треба напоменути да је број радова релативно мали – пронађено је свега неколико истраживања која се директно баве овом тематиком – што указује на значајан простор за даље унапређење овог методолошког приступа.

Један од пионирских радова на ову тему бави се моделовањем броја саобраћајних незгода на основу временских серија и користи месечне податке за период од 2011. до 2020. године, примењујући класичне методе као што су ARIMA и сезонски ARIMA (SARIMA) модели (*Pljakić et al.*, 2021). Њихов рад је значајан јер показује да сезонска компонента у подацима има снажан утицај на тачност предикције, посебно код незгода са погинулима. Међутим, истраживање је ограничено по обиму и резолуцији – анализира се агрегирани број незгода на месечном нивоу, без разлике по типу учесника или врсти последица. Уз то, посматрани период и број опсервација (120 месеци-тачака) релативно су мали у односу на потенцијале дужих серија.

У накнадном раду истих аутора, проширен је методолошки оквир коришћењем вештачких неуронских мрежа поред ARIMA модела (*Pljakić et al.*, 2022). Анализирани су подаци од 2001. до 2020. године, такође на месечном нивоу, а резултати указују да ARIMA модели дају боље резултате уколико се у модел укључе сезонске варијације. Вредност овог истраживања лежи у упоредној анализи класичних статистичких техника и вештачких неуронских мрежа. Ипак, слично као и у претходном истраживању, простор за детаљније раслојавање и раздвајање података остаје неискоришћен: предвиђања су ограничена на укупне бројеве погинулих и повређених, без раздвајања предикције по учесницима.

Једини рад који се специфично бави градским подручјем је студија која примењује SARIMA модел за краткорочну прогнозу броја незгода у Београду (*Deretić et al.*, 2022). Аутори користе јавнодоступне податке за период од 2016. до 2019. године и утврђују да четврти квартал (посебно децембар) има највећу концентрацију незгода. Овај рад представља важан допринос за доносиоце одлука на локалном нивоу. Међутим, истраживање се заснива на релативно кратком периоду од само 48 временских тачака (4 године) и не улази у детаљнију анализу по врстама незгода, последицама или категоријама учесника. Такође, подаци се анализирају искључиво на месечном нивоу, што значајно смањује могућност праћења динамике понашања у краћим временским интервалима.

Узимајући у обзир наведена истраживања, може се закључити да су у Србији већ начињени први кораци у примени временских серија за анализу и предикцију саобраћајних незгода, али да постоје значајна ограничења у смислу обима и фреквенције података, као и у погледу

деталности сегментације по врстама учесника и последицама. Овим истраживањем се тај недостатак смањује кроз употребу најобимнијег досадашњег скупа података (1997–2024), као и применом предикције на часовном нивоу, што омогућава идентификацију краткорочних образаца и потенцијалних критичних интервала током дана. Поред укупног броја незгода, модел се фокусира на предвиђања по врстама исхода (материјална штета, повређени, погинули) и категоријама учесника (бициклисти, мотоциклисти, путничко возило (аутомобил), теретно возило, возила јавног превоза (аутобуси)), што омогућава јасније разумевање проблема и адекватнији избор стратешких мера и мера превенције. На тај начин, овај део дисертације не само да проширује постојећу методолошку основу већ поставља темеље за развој софистицираних система за подршку одлучивању заснованих на великом броју података и детаљној сегментацији саобраћајног ризика.

### **6.3 Методологија истраживања за потребе израде модела временских серија за предикцију саобраћајних незгода на подручју Србије**

За потребе овог дела истраживања коришћена је база података Агенције за безбедност саобраћаја Републике Србије (<https://bazaabs.abs.gov.rs/smartPortal/saobNezgode>) одакле су преузети подаци за моделирање.

У оквиру овог дела вршена су два типа истраживања:

1. **Први део** који се односи на целокупно подручје Србије, где су незгоде предвиђане по сатима и врсти (са материјалном штетом, са повређенима, са погинулима) и укупан број незгода. Временски период узет за овај део истраживања је од 1997. године до 2024. године, при чему је 2024. година одвојена као тест-сет за евалуацију модела предикције.
2. **Други део** истраживања односи се на предвиђање незгода по типу мреже (ванградска и градска) и према врсти учесника (бицикл, мотоцикл, путнички аутомобил, теретно возило и аутобус). Имајући у виду да је категоризација мреже, као променљива, у базу уведена тек од 2014. године, временски период узет за овај део истраживања је од 2014. године до 2024. године, при чему је 2024. година одвојена као тест-сет за евалуацију модела предикције.

Сходно наведеном, формиране су две базе података које су преузете са сајта Агенције за безбедност саобраћаја и које су касније коришћене за моделирање. У првом сету података дефинисане су следеће променљиве: година незгоде, сат, врста незгоде (са материјалном штетом, са повређенима, са погинулима) и укупан број незгода.

Други сет података садржао је следеће променљиве: година незгоде, сат, тип мреже (да ли се ради о градској или ванградској мрежи), врсту учесника (бициклиста, мотоциклиста, путничко возило, теретно возило и аутобус). У складу са доступним подацима, извршено је анализирање свих комбинација мреже и врсте учесника и на основу тога је формиран модел предикције. Важно је поменути да сви модели зависе од обима података – што је више података за тренирање модела, то ће модел (у већини случајева) бити ефикаснији и прецизнији. У том смислу, одређене врсте учесника на одређеној мрежи нису анализиране

јер није постојао довољан узорак којим би се постигла задвољавајућа прецизност модела.

За потребе предикције саобраћајних незгода примењен је приступ заснован на анализи временских серија. На почетку истраживања тестирано је више различитих модела предикције, укључујући ARIMA, SARIMA, Prophet, XGBoost и CatBoost моделе. Након иницијалног тестирања и упоредне евалуације перформанси модела, утврђено је да SARIMA модел даје најстабилније и најпрецизније резултате за већину анализираних временских серија, док се за незгоде са погинулима овај модел није показао адекватним услед изражене нестабилности и малог броја догађаја, те је за ту категорију незгода примењен CatBoost модел, који је показао боље перформансе у моделовању ретких догађаја.

Пре примене модела извршена је припрема и обрада података. Подаци су агрегирани по сату, години и категоријама које су предмет анализе (врста незгоде, тип мреже и врста учесника). Приликом припреме базе извршено је уклањање редова са непотпуним или недостајућим подацима, као и провера конзистентности вредности у временским серијама. За потребе моделирања формиране су континуалне временске серије у којима су вредности представљале број незгода у одређеном временском интервалу. Након тога подаци су подељени на тренинг и тест скуп, при чему је последња година посматраног периода (2024) издвојена као тест-сет за евалуацију модела.

За већину анализираних комбинација категорија примењен је SARIMA модел који омогућава моделовање трендова, сезонских образаца и аутокорелације у временским серијама. Параметри модела одређивани су на основу структуре временске серије и анализе аутокорелације и парцијалне аутокорелације, при чему је тестирано више комбинација параметара како би се добио модел са најбољим перформансама предикције.

За серије које се односе на незгоде са погинулима примењен је CatBoost модел машинског учења. Овај модел је изабран јер се показао погоднијим за моделовање ретких појава. Приликом примене CatBoost модела извршено је подешавање кључних хиперпараметара, укључујући дубину стабала (енг. *depth*), стопу учења (енг. *learning rate*) и број итерација (енг. *iterations*). Параметри су тестирани у више комбинација како би се пронашла конфигурација која даје најбоље резултате предикције.

Тачност модела процењена је упоређивањем предвиђених вредности са стварним вредностима из тест-скупа података користећи показатеље  $R^2$ , MAE, RMSE, што је омогућило процену способности модела да адекватно репродукује обрасце у временским серијама и да пружи поуздане прогнозе.

За наведена истраживања коришћен је Excel програмски пакет и Python 3.10. програмски језик за пречишћавање, анализу и визуелизацију података.

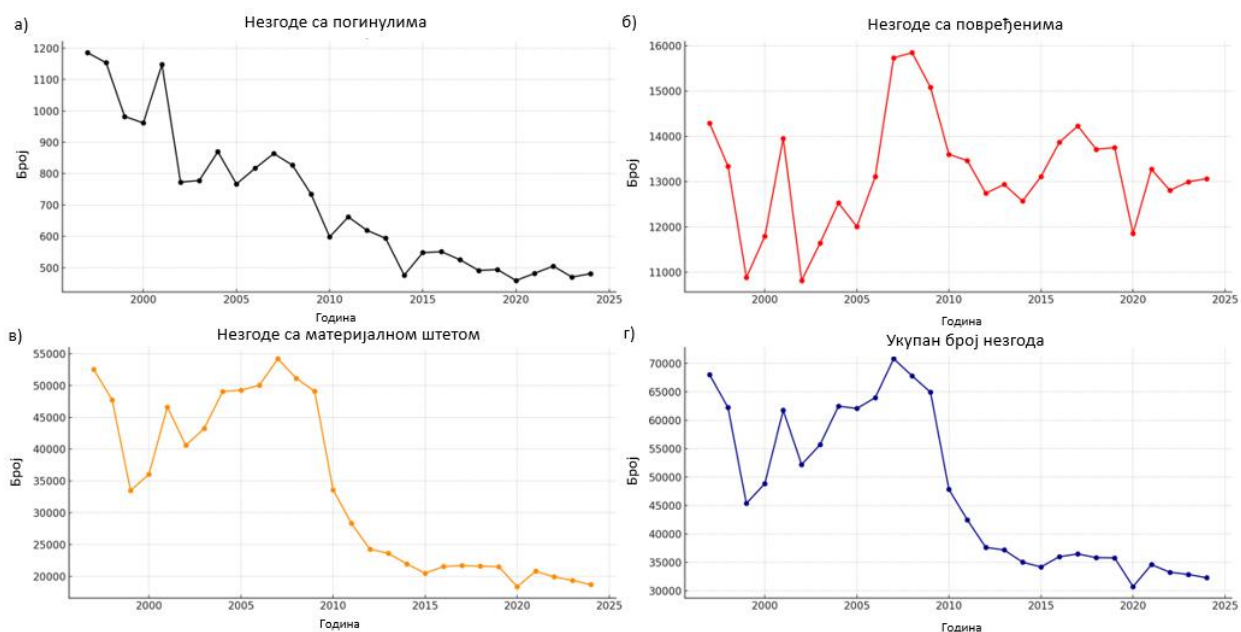
## 6.4 Резултати развоја модела временских серија за предикцију саобраћајних незгода на подручју Србије за период од 1997. до 2024. године

Ово поглавље је подељено на три дела. У оквиру првог дела приказане су опште карактеристике података – саобраћајних незгода за обе базе података – док други и трећи део представљају опис, тренирање и тестирање формираних модела предикције.

### 6.4.1 Опште карактеристике улазних података

Укупан број анализираних незгода у периоду од 1997. године до 2024. године је 1.327.695 – од тог броја 70,7% чине незгоде са материјалном штетом, 27,8% јесу незгоде са повређенима, а 1,5% незгоде са погинулима.

На Слици 55 приказана је промена броја незгода по годинама у односу на врсту.




**Слика 55.** Годишњи број незгода према врсти: а) незгоде са погинулима, б) незгоде са повређенима, в) незгоде са материјалном штетом, г) укупан број незгода у Србији

Приказане слике илуструју годишње промене у укупном броју саобраћајних незгода, као и њихову поделу по тежини последица: са смртним исходом, са повређенима и са материјалном штетом. Видљиво је да је укупан број евидентираних незгода током година подложен флукуацијама, при чему је највећа учесталост регистрована у раздобљу од 2005. до 2010. године. Од тог тренутка, уочава се опадајући тренд, при чему 2020. година бележи историјски минимум броја незгода. Овај пад је у великој мери последица ограничења кретања наметнутих током пандемије COVID-19, која је довела до смањења саобраћајне фреквенције и изложености ризику.

У погледу незгода са смртним исходом, број оваквих догађаја је значајно мањи у односу на друге категорије и показује континуирани пад током времена. Овај тренд може указивати на

делимичну ефикасност превентивних политика и интервенција. Ипак, када се вредности упореде са просецима земаља Европске уније, Србија и даље бележи релативно високу стопу ових незгода. Насупрот томе, број незгода са повређеним лицима показује велике годишње варијације, без јасне узрочно-последичне структуре, што може указивати на одсуство систематске контроле или недовољно циљаних мера. Та непредвидивост у флукуацији броја ових незгода упућује на то да се ради о статистички нестабилној категорији.

Расподела незгода са материјалном штетом у великој мери прати динамику укупног броја незгода, што је логично, с обзиром на то да оне чине велики део свих пријављених саобраћајних инцидената. Ако се посматрају незгоде у току дана (Слика 56), можемо уочити законитости које одражавају понашање корисника, односно учесталост дневних кретања у земљи.



**Слика 56.** Расподела незгода по сатима у току дана, за подручје Србије

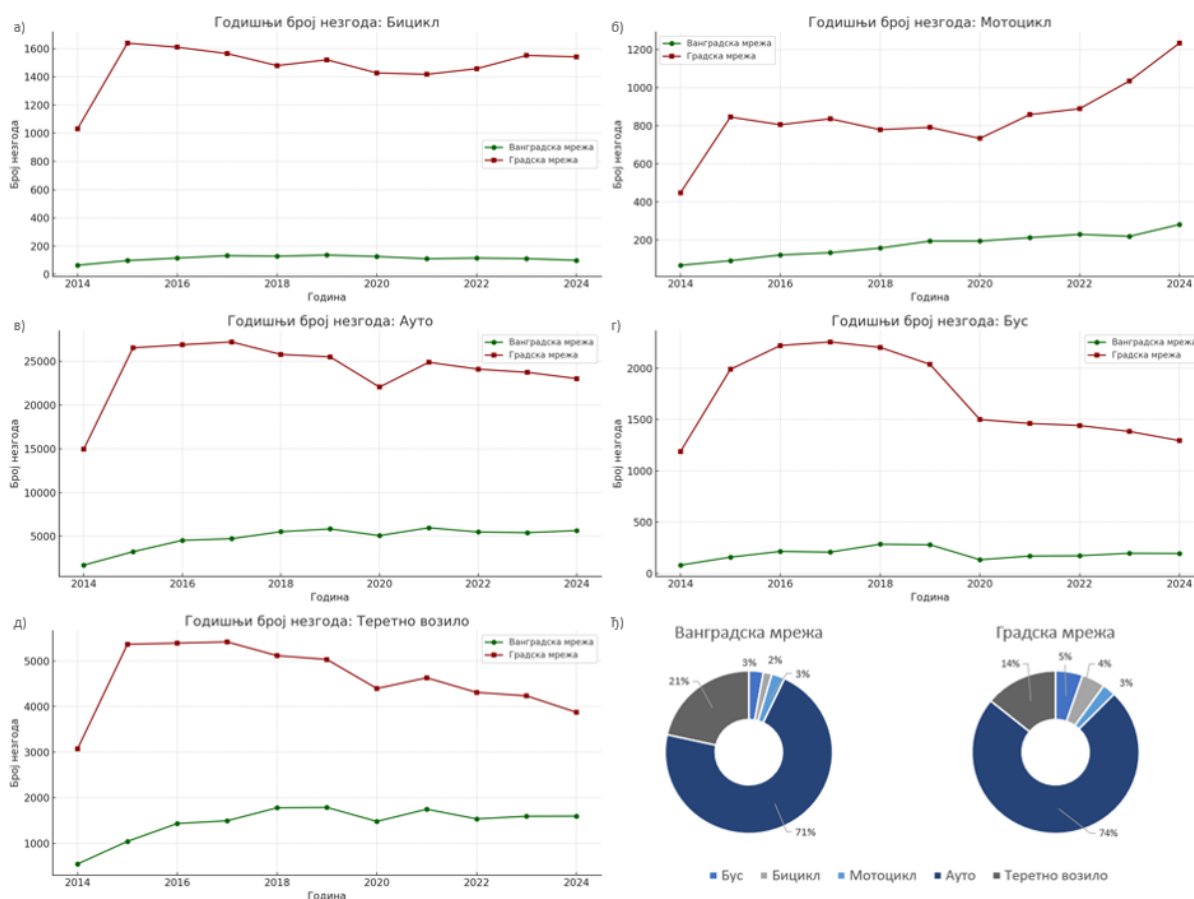
Из анализе се види да је појава саобраћајних незгода најнижа у раним јутарњим сатима, посебно око 4 и 5 часова. Након тога долази до постепеног пораста, који кулминира у интервалу од 12 до 14 часова, што представља јасан дневни врхунац у фреквенцији незгода. Овај образац прати општи ритам дневних активности и повећане изложености. По завршетку овог интервала, број незгода се смањује, што је у складу са смањењем обима кретања. За анализирани временски распон, израчуната стандардна девијација износи 979 незгода, што указује на релативно високу дисперзију.

Поред наведеног, у другом делу анализе коришћени су подаци који укључују просторну категоризацију незгода (насељено подручје наспрам ненасељеног), као и типове учесника у незгодама. Укупно је евидентирано 434.556 незгода у периоду од 2014. до 2024. године. Од тог броја, 59,3% представља незгоде са само материјалном штетом, 39,3% обухвата незгоде са повређеним лицима, док их је само 1,4% било са смртним исходом. Просторна расподела указује да се 82,9% незгода догодило у урбаним (насељеним) зонама, а преосталих 17,1% ван њих (ванградска подручја).

Графички приказ на Слици 57 показује временску промену броја незгода по врсти, сагледану кроз просторну димензију (градска/ванградска мрежа) и тип учесника. Посебно је упечатљиво да је 2015. година означена као врхунац по броју незгода за готово све категорије учесника, изузев за категорију аутобуса. Након тог периода, учача се континуирани опадајући тренд, што може указивати на побољшање ситуације или примену одређених мера превенције у саобраћају.

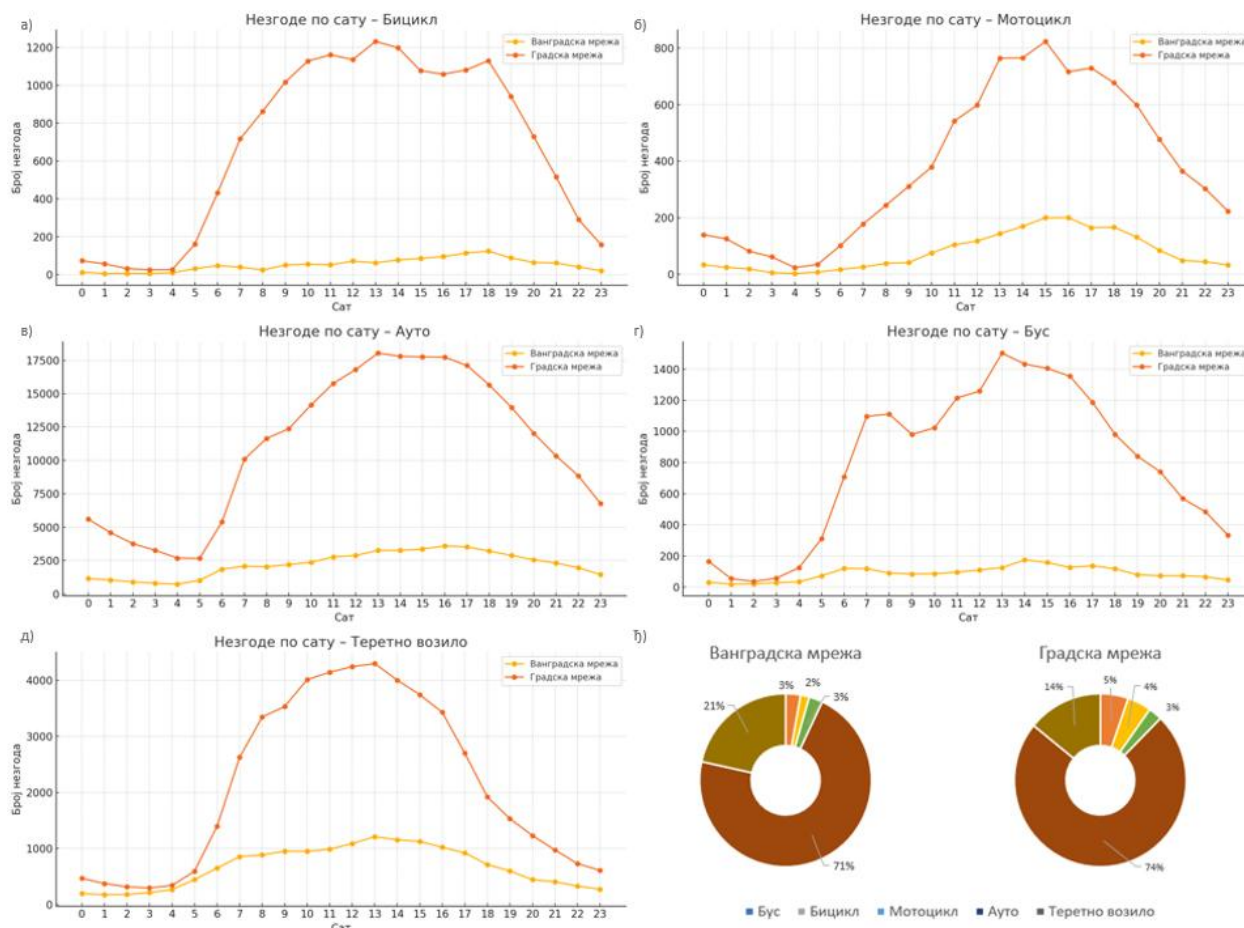
Неколико закључака које је важно изнети на овом месту су:

- евидентиран је нагли пораст незгода са мотоциклистима, како на градској, тако и на ванградској мрежи;
- успостављен је видљив тренд смањења броја незгода са теретним возилима на градској мрежи;
- на ванградској мрежи је број незгода скоро непроменљив по годинама, за све категорије учесника;
- расподела учесника у незгодама практично је идентична на градској и ванградској мрежи.



**Слика 57.** Годишња расподела броја незгода по типу учесника – незгоде са: а) бициклистима, б) мотоциклистима, в) аутомобилима, г) аутобусима, д) теретним возилима, ђ) видовна расподела на градској и ванградској мрежи

На Слици 58 приказана је часовна расподела незгода према типу учесника који су у учествовали у њима.



**Слика 58.** Часовна расподела незгода по типу учесника – незгоде са: а) бициклистима, б) мотоциклистима, в) аутомобилима, г) аутобусима, д) теретним возилима, љ) видовна расподела на градској и ванградској мрежи

Један од занимљивијих увида односи се на уочљиве шаблоне у току дана када се анализирају незгоде у зависности од типа учесника. У случају аутобуса, на пример, врло су изражени саобраћајни вршни интервали у јутарњим и поподневним часовима на урбаној мрежи, што одражава редован ритам јавног превоза. За моторна возила, као што су мотоцикли, путнички аутомобили и теретна возила, врхунац се углавном јавља око поднева, што се може приписати интензивном кретању у том делу дана.

Када је реч о бициклистима, њихов образац се издваја по томе што постоје два периода повећане учесталости незгода: један у послеподневним, а други у вечерњим сатима, око 18 часова, што може бити последица повратка са посла или рекреативног коришћења бицикла након радног времена.


На путевима изван насељених места, тј. на ванградској мрежи, ови обрасци нису толико наглашени. Вршни часови могу се детектовати једино за мотоцикле и теретна возила, док

се за остале категорије, попут бициклиста, релативно већи број незгода и даље јавља у вечерњим сатима, што је слично ситуацији урбаних подручја. Оваква разлика у расподели указује на различите обрасце употребе саобраћајне мреже у зависности од категорије саобраћаја и типа учесника.

#### 6.4.2 Предикција незгода по врсти на подручју Србије у анализираном периоду

Поред приказаних збирних резултата, у оквиру овог дела дисертације, додатно је урађена предикција саобраћајних незгода применом временских серија за подручје Србије. Додатно, предикција је рађена за сваку од врста саобраћајних незгода: незгоде са материјалном штетом, незгоде са повређенима, незгоде са погинулима, као и укупан број незгода. Важно је напоменути да је у већини случајева у овом истраживању за предикцију броја саобраћајних незгода примењен SARIMA модел, управо због веома добрих резултата добијених применом овог модела – коефицијент детерминације ( $R^2$ ) је изнад 95%. Иако постоје и други модели, попут Prophet-а, који у одређеним условима могу пружити нешто боље резултате, употреба SARIMA модела показала се као најбољи избор са становишта баланса између тачности, стабилности и интерпретабилности. У специфичним случајевима где је примењен другачији модел, разлози за ту одлуку детаљно су објашњени у засебним деловима рада.

Резултати предикције укупног броја незгода по сатима у току дана за 2024. годину, која је коришћена као тест-година, дати су на Слици 59.




**Слика 59.** Стваран и предвиђен укупан број незгода по сатима у току дана за 2024. годину у Србији

Модел остварује веома добру предиктивну моћ укупног броја незгода са чак 96%  $R^2$  (MAE износи 93,90, а RMSE 124,21). Модел је примењен на претходно оптимизованим параметрима и то: несезонски параметри (2, 0, 2) и сезонски параметри (1, 0, 1, 24).


Уколико се анализирају резултати предвиђања незгода са материјалном штетом (Слика 60) може се видети да је модел постигао још већу вредност коефицијента детерминације ( $R^2$ ) од

98% (MAE износи 34,84, а RMSE 41,11). Параметри коришћени у овом делу предикције исти су као и за укупан број саобраћајних незгода.



**Слика 60.** Стваран и предвиђен број незгода са материјалном штетом по сатима у току дана за 2024. годину


У случају предикције саобраћајних незгода са повређенима (Слика 61), резултати се не разликују превише у односу на предикцију незгода са материјалном штетом. Коefицијент детерминације ( $R^2$ ) износи 98%, док су MAE 26,36 и RMSE 31,71.



**Слика 61.** Стваран и предвиђен број незгода са повређенима по сатима у току дана за 2024. годину у Србији

Процедура предикције незгода са погинулима нешто је другачија (и захтевнија), пре свега због веома малог узорка података у укупном броју незгода – 1,5% – те је зато било веома тешко достићи нивое ефикасности као код осталих врста незгода. Такође, није било могуће користити класичне моделе предикције као што су ARIMA, SARIMA, Prophet итд., већ је у ову сврху коришћен CatBoost модел, који се, након спроведеног тестирања, показао као

најбољи у примени сетова са малим узорцима података. Резултати предикције незгода са погинулима приказани су на Слици 62.



**Слика 62.** Стваран и предвиђен број незгода са погинулима по сатима у току дана за 2024. годину у Србији

Модел у доброј мери реплицира општи тренд кретања броја незгода са погинулима, тј. препознаје фазе раста и пада током временске серије. Међутим, детектовање наглих осцилација, као што су екстремуми у подацима у вези са локалним максимумима и минимумима, представља значајан изазов, пре свега услед ограничене величине узорка. Најбоље перформансе постигнуте су при следећим вредностима: дубина = 4, број итерација = 200 и стопа учења = 0,1. Са оваквим подешавањима хиперпараметара модел је остварио коефицијент детерминације ( $R^2$ ) од 61%, док су средња апсолутна грешка (MAE) и корен средње квадратне грешке (RMSE) износили 4,55, односно 5,25.

У Табели 22 дати су сумарни резултати предикције саобраћајних незгода по врстама.


**Табела 22.** Сумарни резултати модела предикције по врсти незгода за 2024. годину у Србији

Параметри квалитета	Незгоде са погинулима	Незгоде са повређенима	Незгоде са материјалном штетом	Укупан број незгода
Модел	CatBoost	SARIMA	SARIMA	SARIMA
MAE	4,55	26,36	34,84	93,90
RMSE	5,25	31,71	41,11	124,21
$R^2$	61%	98%	98%	96%

### 6.4.3 Предикција незгода по типу учесника у зависности од категорије мреже у Србији за анализирани период


У овом поглављу приказани су резултати предикције незгода по типу учесника у зависности од категорије мреже где се незгода догодила, а типови учесника који су анализирани јесу

бициклисти, мотоциклисти, возачи путничких аутомобила, возачи теретних возила и возачи аутобуса. У спроведеној анализи посматрана је градска и ванградска мрежа путева у Србији за анализирани период. На Слици 63 приказани су резултати предикције незгода са бициклистима на градској мрежи.




**Слика 63.** Стваран и предвиђен број незгода са бициклистима на градској мрежи за 2024. годину у Србији

Са слике се може видети да предиктивна крива модела добро прати стваран број незгода. Овим моделом постигнут је коефицијент детерминације  $R^2$  93%, док су MAE 8,66 и RMSE 11,29. Оптимални параметри за овај модел су (2, 1, 3) и (1, 0, 1, 24). Код предикције незгода са мотоциклистима на градској мрежи (Слика 64), модел такође остварује веома добру предиктивну моћ. Коефицијент детерминације ( $R^2$ ) у овом случају износи 93%, док су MAE 7,27 и RMSE 9,02. Оптимални параметри добијени за овај модел јесу (2, 2, 2) и (1, 1, 0, 24).



**Слика 64.** Стваран и предвиђен број незгода са мотоциклистима на градској мрежи за 2024. годину у Србији


Резултати предикције незгода са путничким аутомобилима на градској мрежи приказани су на Слици 65.



**Слика 65.** Стваран и предвиђен број незгода са путничким аутомобилима на градској мрежи за 2024. годину у Србији

Криве стварних података и излаза модела скоро се подударају, што такође показује и коефицијент детерминације од 99%. Ово је уједно модел који је постигао најбоље резултате у предикцији незгода. MAE износи 35,22, док RMSE износи 48,70. Оптимални параметри коришћени у овом моделу јесу (2, 0, 2) и (1, 0, 1, 24).


Резултати предикције незгода са теретним возилима на градској мрежи приказани су на Слици 66.



**Слика 66.** Стваран и предвиђен број незгода са теретним возилима на градској мрежи за 2024. годину у Србији

Достигнути коефицијент детерминације, у овом случају, износи 96%, док су MAE 14,90 и RMSE 20,99.

Резултати предикције незгода са аутобусима на градској мрежи приказани су на Слици 67.




**Слика 67.** Стваран и предвиђен број незгода са аутобусима на градској мрежи за 2024. годину у Србији

Иако постоје одређене, неравномерне, флукуације у броју незгода по сатима, модел се успешно прилагодио тим променама и достигао коефицијент детерминације од 94%, док су MAE 6,24 и RMSE 7,62.

Предикције незгода по врсти учесника на ванградској мрежи рађена је само за случајеве путничких аутомобила и теретних возила, због постојања потпуних података само за ове две категорије.


На Слици 68 приказани су резултати предикције незгода са путничким аутомобилима на ванградској мрежи.



**Слика 68.** Стваран и предвиђен број незгода са путничким аутомобилима на ванградској мрежи за 2024. годину у Србији

У случају ванградске мреже крива реалног броја незгода не изгледа исто као и у случају градске мреже, али је модел успео да се прилагоди специфичним околностима дајући веома добре резултате. Достигнути коефицијент детерминације у овом случају износи 97%, док су MAE 1282 и RMSE 16,98. Оптимални параметри за овај модел јесу (2, 1, 3) и (1, 0, 1, 24).

У случају предикције незгода са теретним возилима на ванградској мрежи (Слика 69) модел остварује добру предиктивну моћ. Коефицијент детерминације износи 95%, а MAE и RMSE 6,55 и 8,12 редом.



**Слика 69.** Стваран и предвиђен број незгода са теретним возилима на ванградској мрежи за 2024. годину у Србији

У Табели 23 дати су сумарни резултати предикције саобраћајних незгода по типу учесника и врсти мреже.

**Табела 23.** Сумарни резултати модела предикције по типу мреже и врсти учесника у саобраћајним незгодама за 2024. годину у Србији

Мрежа	Метрика	Бицикл	Мотоцикл	Путнички аутомобил	Теретно возило	Аутобус
Градска	MAE	8,66	7,27	35,22	14,90	6,24
	RMSE	11,29	9,02	48,70	20,99	7,62
	R <sup>2</sup>	<b>93%</b>	<b>93%</b>	<b>99%</b>	<b>96%</b>	<b>94%</b>
Ванградска	MAE	/	/	12,82	6,55	/
	RMSE	/	/	16,98	8,12	/
	R <sup>2</sup>	/	/	<b>97%</b>	<b>95%</b>	/

Приказани подаци јасно указују на могућност једноставног поређења резултата добијених на основу предикције незгода применом модела временских серија. Сходно наведеном, прихвата се Хипотеза 4.

## 6.5 Дискусија резултата добијених применом модела временских серија за предикцију саобраћајних незгода у Србији за период од 1997. до 2024. године

У оквиру овог дела истраживања предложени су SARIMA и CatBoost модели предикције саобраћајних незгода који се односе на временске серије. Предвиђане су незгоде по врсти (на подручју Србије), као и незгоде по типу учесника и врсти мреже (градска и ванградска). Остварени резултати потврђују да модели временских серија могу успешно предвидети појаву саобраћајних незгода у различитим просторним и временским контекстима, уз добру стабилност и интерпретабилност. У овом истраживању примењени су модели SARIMA и CatBoost за предикцију незгода по сату, при чему су посебно анализирани саобраћајне незгоде са материјалном штетом, са повређенима и са погинулима и врстом учесника: возачи бицикла, мотоцикла, путничког аутомобила, теретних возила и аутобуса. Модели су развијени одвојено за градску и ванградску мрежу, чиме је омогућено поређење предиктивних образаца у зависности од саобраћајне динамике, изложености и врсте корисника пута.

Подаци указују да је на градској мрежи приметна виша фреквенција незгода у послеподневним сатима, што кореспондира са интензивнијим кретањем и повишеним саобраћајним оптерећењем у тип периодима. Ванградска мрежа, са друге стране, има вршни сат у раним јутарњим и каснијим вечерњим сатима, што указује на различите обрасце кретања, али и могући утицај просечне брзине, која у ванградским условима често прелази дозвољене границе. У том смислу, укрштање параметара саобраћајног тока, попут густине, брзине и временске варијабилности протока, може дати додатна појашњења обрасца предвиђених незгода, што представља потенцијал за даља унапређења модела.

Упоредном анализом са радом Пљакића et al. (2021), који су користили сезонски ARIMA модел на месечном нивоу за целу Србију, може се уочити важна разлика у временској резолуцији. Док наведени рад препознаје сезоналност као доминантан фактор на нивоу месеци, резултати у овој докторској дисертацији показују да је дневна и чак сатна варијабилност веома значајна, посебно код врста незгода са повређенима. Добијени резултат у складу је са ставовима Деретића et al. (2022), који су истакли да унутардневне варијације у саобраћајној динамици могу значајно утицати на појаву негативних последица у саобраћају.

Анализе по типовима возила показују да је највећа учесталост незгода са путничким и теретним возилима у градским условима повезана са саобраћајним загушењима, док су мотоциклисти и бициклисти знатно изложенији ризику у ванградским условима, где повећане брзине и слабија инфраструктурна подршка (нпр. одсуство бициклистичких стаза) повећавају ризик. Модели предикције у овим случајевима пружају веома висок ниво прецизности са коефицијентом детерминације већим од 95%, како за градску, тако и за ванградску мрежу.

Услед недостатака података за све категорије возила и за оба типа мреже (ванградска и градска), у истраживању спроведеном у овј дисертацији било је могуће израдити моделе

предикције само за путничке аутомобиле и теретна возила. Такође, модели су рађени на нивоу Србије, чиме се добија само генерална слика на националном нивоу. За адекватно третирање различитих проблема у саобраћају мора се посматрати локални ниво. Сходно томе, потребно је изградити моделе предикције који се везују за општине, односно градове или чак нека још мања подручја у оквиру градова, за специфичну (локалну) категоризацију мреже, узимајући у обзир локалне узроке настанка незгоде, микролокације, понашање корисника и сл. На основу наведеног, модели представљени у оквиру ове докторске дисертације пружају адекватне смернице и основу за даљу разраду и унапређења у оквиру планираних будућих истраживања.


---

---

# АНАЛИЗА ЕКСТРАТЕРЕСТРИЧКИХ УТИЦАЈА НА ПОЈАВУ НЕЗГОДА СА ЖИВОТИЊАМА У СРБИЈИ

---

---



## 7.1 Опис проблема

Саобраћајне незгоде са животињама представљају значајан безбедносни и економски изазов, нарочито у руралним подручјима, где најчешће узрокују материјалну штету, али могу довести и до повреда, па и до фаталних исхода – губитка живота. Према већ наведеним подацима Светске здравствене организације (*World Health Organization (WHO)*, 2023b), више од 1,19 милиона људи годишње изгуби живот у саобраћајним незгодама широм света, док одређени проценат ових инцидената укључује сударе са дивљим или домаћим животињама (*Creech et al.*, 2019; *Skroch and Hilaire*, 2021). Такве незгоде чешће су у зонама које се поклапају са миграционим коридорима животиња или у областима са густом популацијом животињског света. Учесталост ових догађаја често је условљена факторима као што су временски услови, доба дана, месеца или годишњег доба (*Arevalo et al.*, 2017; *Akrim et al.*, 2019; *Wilkins et al.*, 2019). Један од потенцијално утицајних, али недовољно истражених аспеката јесте улога лунарних фаза у појави незгода са животињама, нарочито фазе пуног Месеца. Док неки радови указују на повећан број таквих инцидената током фазе пуног Месеца (*Templer et al.*, 1982; *Colino-Rabanal et al.*, 2018; *Steiner et al.*, 2021), други сугеришу да је важније узети у обзир комплекснију комбинацију спољашњих фактора (фактори окружења), инфраструктурних фактора и фактора понашања (*Sitar*, 1994; *Onozuka et al.*, 2018). Ови различити резултати указују на потребу за јаснијим и детаљнијим разумевањем интеракције природних и антропогених утицаја у контексту безбедности саобраћаја. Истраживање везе између Месечевих мена и учесталости незгода са животињама није само академски изазов већ може имати конкретне последице за пројектовање ефикасног и сигурног саобраћајног система. Наведени резултати могу помоћи при дефинисању и избору мера попут постављања изменљиве сигнализације, уређења коридора за прелаз животиња, увођења адаптивних ограничења брзине и бољег информисања учесника у саобраћају.

Међутим, ова тема је још увек недовољно обрађена у научној литератури, нарочито у домену саобраћајног инжењерства. Сходно наведеном, циљ овог дела докторске дисертације јесте да се истраже и утврде могуће везе између фаза Месеца и појаве незгода са животињама на територији Србије применом различитих статистичких метода. Са једне стране, оваквим

приступом допуњује се постојећи веома мали корпус светске литературе, док поред академског значаја, добијени резултати могу помоћи надлежним органима и институцијама у креирању ефикаснијих политика и при идентификацији зона које захтевају дефинисање и спровођење специфичних мера и активности, а све у циљу унапређења безбедности саобраћаја.

## **7.2 Преглед релевантних истраживања у области екстратерестричких утицаја на настанак саобраћајних незгода са животињама**

Узроци саобраћајних незгода могу се сврстати у четири основне категорије: људски фактор, возило, пут и окружење (*Lipovac, 2008*). Посебну групу представљају незгоде које укључују сударе са животињама. Иако људска непажња често игра кључну улогу, сама природа појављивања животиња на коловозу, нагла и непредвидива, оставља веома мало времена возачу за адекватну реакцију. Понашање животиња, под утицајем светлосних или звучних стимуланса, може додатно повећати ризик од судара (*Murphy, 2021*). У различитим студијама анализирани су различити фактори који утичу на појаву незгода са животињама. Тако је доказано да фреквенција саобраћаја (*Jakubas et al., 2018; Llagostera et al., 2022; Su et al., 2023*), брзина кретања возила (*Sullivan, 2011*), као и карактеристике саме инфраструктуре (*Laliberté and St-Laurent, 2020*) играју значајну улогу. На пример, постављање заштитних ограда доказано смањује број оваквих инцидената (*Kučas and Balčiauskas, 2021*), док садња вегетације уз пут има супротан ефекат (*Keken et al., 2019*). Исто тако, врста окружења, особине терена и временски период (дан, годишње доба) утичу на учесталост ових догађаја (*Pagany, 2020; Bénard, 2023*). Један од екстерних елемената који и даље изазива научну пажњу јесте утицај Месеца, односно његове светлости и мена, на учесталост судара са животињама. Иако још увек не постоји јасан консензус у литератури, одређене студије показују потенцијалну повезаност. Истраживања у САД-у, обухватајући Калифорнију, Тексас и Илиноис, указала су на повећан број оваквих незгода током периода пуног Месеца (*Templer et al., 1982*), док је канадска студија (*Laverty et al., 1992*) закључила да лунарне фазе не утичу статистички значајно на број незгода. Фокус одређених радова био је на специфичним врстама, најчешће јеленима (*Murphy, 2021; Delisle et al., 2024*) и дивљим свињама (*Karami and Tavakoli, 2022; Bil et al., 2024*), које су идентификоване као чести учесници у овим незгодама. Студија из Шпаније показала је повећање од 70% незгода са јеленима током пуног Месеца у односу на млади Месец (*Colino-Rabanal et al., 2018*), док су истраживачи у Аустрији потврдили статистички значајне дневне разлике током недеље у периоду пуног Месеца (*Steiner et al., 2021*). Скорашња анализа из Тексаса, која је обухватила податке од 4,5 милиона незгода од 2011. до 2020. године, показала је да се 46% више незгода са животињама догоди током пуног Месеца у поређењу са младим Месецом, уз напомену да побољшана видљивост може довести до лажног осећаја сигурности возача (*Iio and Lord, 2024*).

Два новија истраживања из региона, релевантна због географске и инфраструктурне сличности са Србијом, спроведена су у Словенији и Хрватској. У Словенији је анализирано преко 49.000 незгода у периоду од 2010. до 2019. године, где је утврђена извесна повезаност месечеве светлости и незгода са животињама (*Cerri et al., 2023*). Супротно томе, у Хрватској

су анализирани подаци између 2012. и 2016. године, при чему није пронађена статистички значајна повезаност (*Vrkljan et al.*, 2017).

Већина постојећих истраживања и развијених модела усмерена је пре свега на предвиђање локација на којима је вероватноћа настанка оваквих незгода повећана, кроз идентификацију опасних места (*Ha and Shilling*, 2018; *Jaafari et al.*, 2019; *González-Vélez et al.*, 2021), утицаја близине зеленила или шума (*Gonçalves et al.*, 2018; *Perez-Guerra et al.*, 2024), миграционих коридора и густине саобраћаја. Међутим, само мали број истраживања бави се директном временском предикцијом ових незгода, односно развојем модела који предвиђају када ће у току дана доћи до незгоде, а не само где.

У оквиру новијих студија, поједини су се аутори бавили управо директном предикцијом саобраћајних незгода са животињама коришћењем савремених модела машинског учења модела. Истраживачи у Баварској применили су више модела машинског учења – Random Forest (RF), вештачке неуронске мреже са простирањем унапред (енг. *Feedforward Neural Networks* – FNN) и Support Vector Machine (SVM) – укључујући и аутоматизовану селекцију модела путем AutoML алата. Најуспешнији резултати у предвиђању ризика од незгода са животињама остварени су моделима RF-а (тачност 86,6%) и FNN-а (86,7%), што показује потенцијал ових техника у идентификовању комплексних образаца заснованих на великом броју улазних карактеристика (*Pagany*, 2022).

Посебно је значајан рад аутора који су применили хибридни генерализовани адитивни модел за предикцију тежине незгода са животињама у савезној држави Њу Хемпшир (САД) (*Laflamme et al.*, 2024). Модел је укључивао како линеарне, тако и нелинеарне варијације за предикцију исхода у погледу тежине незгоде. Аутор је користио податке од 2002. до 2019. године, узимајући у обзир факторе као што су доба дана, брзина, густина људске и животињске популације, услови пута, временски услови, ПГДС и просторне карактеристике пута. Његов приступ показао је да су незгоде са погинулима чешће током ноћи и у условима влажних коловоза, као и на путевима са умереним брзинама (45–60 km/h). Овакав модел, уз валидацију путем ROC криве, показао је добру прецизност и представља успешан пример предикције тежине незгода са животињама, али и практичан алат за доносиоце одлука при избору адекватних мера превенције (*Laflamme et al.*, 2024).

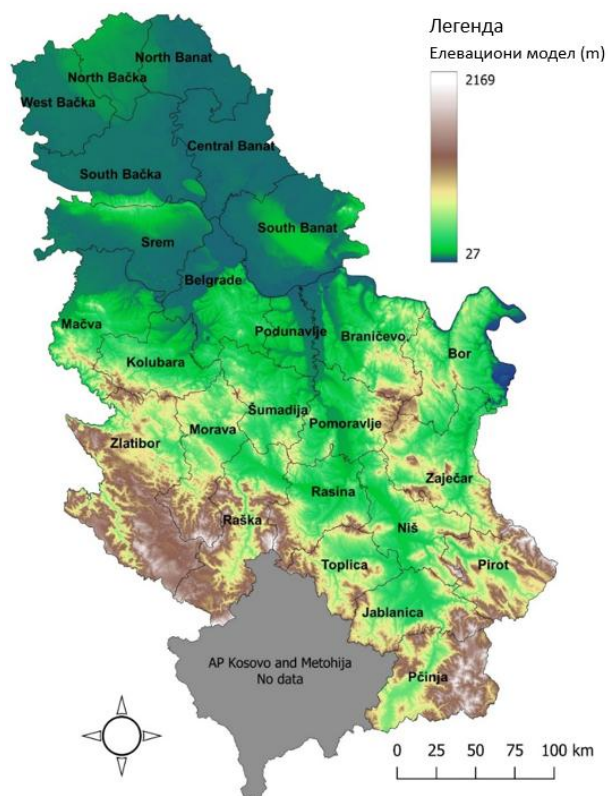
У контексту Србије, где још увек недостају системи за праћење и прогнозу незгода са животињама, употреба временских серија нуди потенцијал за превазилажење овог проблема. Такви модели могу служити као алат за унапред планиране интервенције, од постављања привремене или трајне саобраћајне сигнализације, преко измена у режиму саобраћаја, до просторно-временског управљања ризиком и избора погодних стратешких решења, што је предмет планираних будућих истраживања.

### **7.3 Методологија истраживања за потребе анализе екстратерестричких утицаја на настанак саобраћајних незгода са животињама у Србији**

У оквиру овог истраживања коришћени су подаци из званичне и јавно доступне базе саобраћајних незгода, коју је објавило Министарство унутрашњих послова Републике Србије (2024). Анализа је обухватила период од 2015. до 2023. године, при чему је 2020.

година изостављена због поремећаја у обрасцима саобраћајног кретања проузрокованих пандемијом COVID-19. Укупно је у наведеном периоду евидентирано 283.564 саобраћајних незгода, од чега је 5127 инцидената укључивало сударе са животињама. За потребе овог рада, у фокус анализе стављени су искључиво догађаји који су се одиграли у ноћним условима, при чему је укупан број таквих случајева износио 2767 (53,9%).

Територијални обухват истраживања покривао је цело подручје Републике Србије изузев подручја Косова и Метохије, за које у релевантној бази нису били доступни подаци. Просторна категоризација заснивала се на административној подели државе на 25 области, у складу са NUTS3 нивоом класификације територијалних јединица (*Statistical Office of the Republic of Serbia, 2024a*), што је приказано на Слици 70.



**Слика 70.** Административни региони Републике Србије и дигитални елевациони модел (Eurostat, 2025)

Методолошки приступ примењен у овом истраживању заснива се на студији спроведеној у Тексасу (*Iio and Lord, 2024*), уз одређене модификације прилагођене у складу са специфичностима локалног контекста и расположивим подацима у Србији. У оквиру овог дела истраживања спроведене су две засебне аналитичке целине:

### 1. Упоредна анализа утицаја лунарних фаза

Поменута анализа односи се на поређење укупног броја незгода са животињама током различитих фаза Месеца: млад Месец, прва четврт, трећа четврт и пун Месец. Подаци о лунарним фазама, укључујући време изласка и заласка Месеца, преузети

су са платформе Meteogram (2024). У складу са том поделом, формулисана је прва истраживачка хипотеза ( $H_{17}$ ): *Постоји статистички значајна разлика у броју саобраћајних незгода са животињама током ноћи пуног Месеца у поређењу са осталим фазама лунарног циклуса.*

## **2. Поређење броја незгода током пуног Месеца са бројем незгода током осталих ноћи**

Поменута анализа упоређује просечан годишњи број незгода са животињама током ноћи пуног Месеца са просечним бројем таквих незгода током свих преосталих ноћи у години (изузимајући ноћи младог Месеца, прве и треће четвртине које су већ обухваћене анализом  $H_{17}$ ). Овај приступ представља методолошки адаптирану варијанту контролне групе предложене у раду (*Redelmeier and Shafir, 2017*), с циљем да се испита следећа ставка (Хипотеза  $H_{27}$ ): *Да ли се током пуног Месеца бележи значајно различит број незгода са животињама у односу на било који други период који не обухвата специфичне лунарне фазе?*

### **7.3.1 Статистичке поставке, тестови и алати**

У овом истраживању као зависна променљива разматран је број саобраћајних незгода са учешћем дивљих животиња, посматраних у односу на дефинисане лунарне фазе Месеца. Независне променљиве обухватале су проценат осветљене Месечеве површине (%), дужину трајања дана (у минутима) и фазу Месеца, дефинисану кроз четири класе (млади Месец, прва четврт, последња четврт и пун Месец), у складу са подацима лунарног календара. Ноћни период је дефинисан као интервал између 18.00 и 6.00 часова (локалног времена), користећи астрономске параметре сумрака на основу података са сајта Meteogram (2024). Коначни скуп података обухватао је 2767 потврђених незгода уочених у временском распону од 2015. до 2023. године. У циљу прецизнијег издвајања ефеката пуног Месеца, уведена је бинарна променљива која означава само ноћи у којима се јавља фаза пуног Месеца.

Пре приступања статистичкој обради подаци су филтрирани – избачени су непотпуни или нетачни подаци. Екстремне вредности нису искључене из анализе јер је сваки запис представљао документован случај незгоде. Основне дескриптивне статистике коришћене су за опис централних тенденција и мере расипања у оквиру различитих категорија. Да би се обезбедила валидност примене параметарских техника, испитиване су претпоставке о нормалности и хомогености варијанси. Нормалност расподеле зависне променљиве тестирана је уз помоћ *Shapiro-Wilk* теста, док је *Levene-ов* тест коришћен за проверу једнакости варијанси између категорија лунарних фаза. У случајевима када су претпоставке биле испуњене, примењене су параметарске технике као што су *t*-тест за независне узорке, једнофакторска ANOVA и поновљена ANOVA. Тамо где су претпоставке нарушене, резултати су потврђени алтернативним непараметарским тестовима, укључујући *Kruskal-Wallis* тест, који је показао конзистентност у налазима.

Сва статистичка поређења третирали су фазе Месеца као независне временске групе. Иако подаци имају временску структуру, није примењен формалан модел временских серија јер је фокус био на унапред дефинисаним лунарним интервалима, а не на континуалном тренду кроз време. У циљу процене валидности примењених модела, извршена је дијагностичка

визуелизација, укључујући Q-Q дијаграме и хистограме резидуала (остатка), како би се проверила нормалност и равномерност расподеле.

Статистичка анализа реализована је коришћењем Microsoft Excel-а, Python-а (верзија 3.13.1) и JASP софтвера (верзија 0.19), а праг статистичке значајности постављен је на уобичајену вредност од  $p < 0,05$ .

### 7.3.2 Методолошке поставке за потребе израде модела предикције саобраћајних незгода са животињама на подручју Србије за период од 2016. до 2024. године

За овај део истраживања коришћени су јавно доступни подаци Агенције за безбедност саобраћаја Републике Србије (<https://bazaabs.abs.gov.rs/absPortal/>). Подаци су обухватили саобраћајне незгоде са животињама за период од 2016. до 2024. године, на подручју Србије. За тестирање модела коришћене су незгоде које су се догодиле током 2024. година, док су незгоде које су се догодиле током осталих година коришћене као тренинг подаци. Приликом анализе и обраде података, коришћени су MS Excel пакет и Python.

## 7.4 Резултати анализе екстратерестричких утицаја на појаву саобраћајних незгода са животињама у Србији, за период од 2015. до 2023. године

У оквиру овог истраживања коришћена је база са укупно 5127 саобраћајних незгода са животињама у посматраном периоду. Од тог броја, 4736 (92,4%) резултирало је материјалном штетом, 387 (7,5%) повредама, док је у 4 случаја (0,1%) исход био смртан. Ноћне незгоде чине значајан део укупног броја незгода, са 2767 случајева (54%).

Расподела незгода по годинама и врсти дата је у Табели 24. Иако овакве незгоде могу имати озбиљне последице, у већини случајева се завршавају без тежих исхода по учеснике.


**Табела 24.** Годишња, процентуална расподела незгода са животињама, по врсти у Србији

Година	Са погинулима (%)	Са повређенима (%)	Са материјалном штетом (%)
2015	0,92	8,26	90,83
2016	0,00	8,69	91,31
2017	0,00	6,85	93,15
2018	0,00	6,86	93,14
2019	0,00	9,12	90,88
2020	0,16	7,72	92,13
2021	0,28	6,21	93,51
2022	0,00	8,41	91,59
2023	0,00	6,84	93,16

Посебно је интересантно приметити да је највећи број ових незгода регистрован током 2021. и 2022. године, што се временски поклапа са периодом током и након пандемије COVID-19. Иако није директно доказано, могуће је да специфични услови током пандемије, попут промене навика кретања људи и животиња, смањеног интензитета саобраћаја и повећаног

присуства животиња у близини саобраћајница, представљају факторе који су допринели порасту учесталости ових инцидената.

На Слици 71 приказана је месечна и часовна расподела саобраћајних незгода са животињама током анализираниог периода. Ове расподеле омогућавају идентификацију потенцијално критичних временских интервала у којима је ризик од настанка оваквих инцидената повећан.



**Слика 71.** Месечна а) и часовна б) расподела незгода са животињама, током анализираниог периода, у Србији

Посматрањем дијаграма месечне расподеле саобраћајних незгода са животињама могу се издвојити три временска периода у години са значајно већом учесталошћу инцидената: април, август и зимски месеци (децембар–фебруар). Ови максимуми у дистрибуцији могу бити повезани са специфичним фазама сезонске активности животиња – у априлу и августу могу се довести у везу са периодима миграције или повећане покретљивости, док је током зиме повећан ризик услед ограничене видљивости, краћег дана и могућег кретања животиња у потрази за храном.

Када је у питању часовна расподела незгода током дана, подаци јасно указују на концентрацију инцидената у вечерњим сатима, нарочито у интервалу од 18 до 21 часа. Овај образац је у складу са претходним налазима у литератури који указују на повишен ризик у условима сумрака и смањене видљивости, али и на временске периоде када је саобраћајни ток и даље релативно интензиван. Ови резултати могу имати директне импликације на планирање превентивних мера, попут постављања изменљиве саобраћајне сигнализације или контроле брзине.

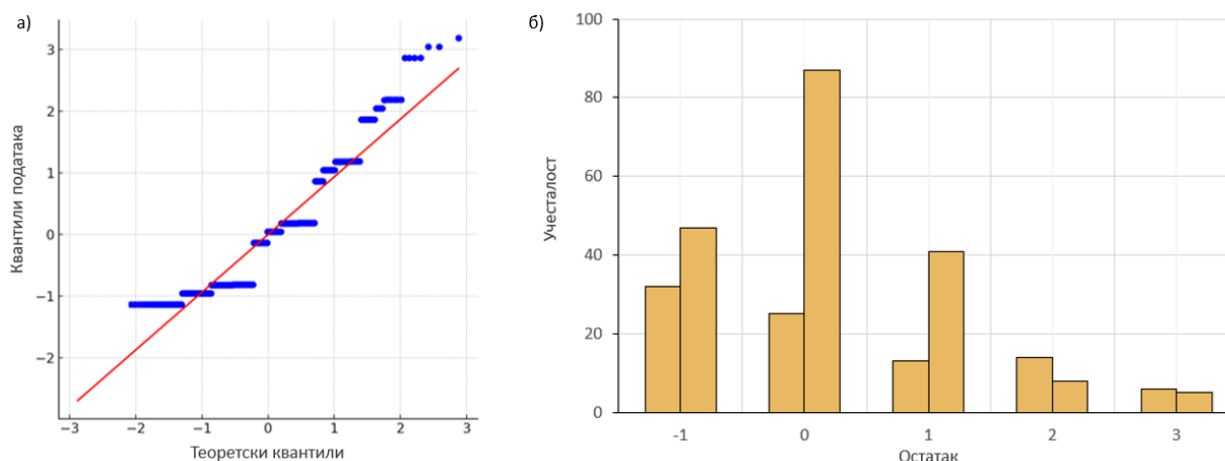
Сprovedена је упоредна анализа укупног броја саобраћајних незгода са учешћем животиња у зависности од одређених фаза Месеца. Посматрани временски оквири обухватају четири главне лунарне фазе – млад Месец, прву четвртину, трећу четвртину и пун Месец – у периоду од 2015. до 2023. године. Основни циљ анализе био је да се утврди постоји ли статистички значајна разлика у учесталости ових незгода у различитим фазама лунарног циклуса. Из анализе су изостављене 2020. година, услед специфичних услова проузрокованих пандемијом COVID-19, и 2015. година, с обзиром на то да представља почетак систематског прикупљања релевантних података, па су подаци у бази делом непотпуни.

Табела 25 приказује годишњу расподелу броја незгода са животињама у Србији током сваке од наведених лунарних фаза, у анализираном периоду.

**Табела 25.** Годишња расподела незгода са животињама током специфичних периода у Србији

	2016	2017	2018	2019	2021	2022	2023
Млад Месец	14	7	10	10	15	10	14
Прва четвртина	7	11	6	14	13	11	9
Трећа четвртина	10	9	8	6	16	13	7
Пун Месец	8	16	7	16	19	21	14

С обзиром на то да су претпоставке нормалности, хомогености варијансе и случајног узорковања биле задовољене, али претпоставка независности није, за тестирање постављене хипотезе примењен је ANOVA тест са поновљеним мерењима. Нормалност дистрибуције података испитана је коришћењем Шапиро–Вилковог теста ( $W_1 = 0,884$ ,  $p_1 = 0,245$ ;  $W_2 = 0,950$ ,  $p_2 = 0,727$ ;  $W_3 = 0,927$ ,  $p_3 = 0,528$ ;  $W_4 = 0,919$ ,  $p_4 = 0,460$ ), као и визуелним прегледом хистограма и Q-Q графикана (Слика 72).



**Слика 72.** Тестирање нормалности података: а) дијаграм квантила (црвена линија – идеална расподела), б) дијаграм остатака

Q-Q дијаграм (лево) показује како се стандардизовани остаци поклапају са теоријском нормалном расподелом – већина вредности налази се у непосредној близини дијагонале, што указује на приближно нормалну расподелу. Одступања су највише приметна на крајевима расподеле. Хистограм (десно) приказује учесталост остатака, са симетричном расподелом око нуле и постепеним смањењем на крајевима, што је у складу са претпоставком нормалности. Ови налази потврђују адекватност примене параметарских техника као што су ANOVA и  $t$ -тест, будући да нема изражене асиметрије или груписања одступајућих вредности.

Хомогеност варијансе потврђена је *Levene-овим* тестом ( $F(3,24) = 0,579, p = 0,635$ ). Независност узорака испитана је Хи-квадрат тестом ( $X^2 = 15,238, p < 0,01$ ), који указује на значајну повезаност и нарушавање претпоставке независности. Резултати ANOVA анализе са поновљеним мерењима ( $F(3,18) = 3,045, p = 0,06$ ) показују да не постоји статистички значајна разлика у броју незгода са животињама током различитих фаза Месеца. Сходно томе, хипотеза  $H_1$  је одбачена.

Извршено је и поређење просечне годишње стопе саобраћајних незгода са животињама током периода пуног Месеца ( $H_{\text{пм}}$ ) и током преосталих дана у години који не обухватају лунарне фазе ( $H_{\text{од}}$ ). Циљ ове анализе био је да се утврди постоји ли статистички значајна разлика у учесталости незгода са животињама у наведеним временским оквирима. Резултати анализе приказани су у Табели 26.

**Табела 26.** Просечан годишњи број  $H_{\text{пм}}$  и  $H_{\text{од}}$  за анализирани период у Србији

	2016	2017	2018	2019	2021	2022	2023
$H_{\text{пм}}$	0,667	1,231	0,538	1,231	1,583	1,615	1,077
$H_{\text{од}}$	0,543	0,626	0,684	0,964	1,038	0,976	0,906

$H_{\text{пм}}$  – просечан број незгода са животињама током пуног Месеца;  $H_{\text{од}}$  – просечан број незгода са животињама за преостале дане осим дана младог Месеца, прве четвртине и последње четвртине

За потребе овог истраживања примењен је  $t$ -тест, уз претходну проверу статистичких претпоставки нормалности, хомогености варијансе и независности података. Нормалност дистрибуције испитана је Шапиро–Вилковим тестом ( $W_1 = 0,916, p_1 = 0,437; W_2 = 0,885, p_2 = 0,251$ ), а резултати су потврђени и визуелном анализом хистограма и QQ графика. Хомогеност варијанси испитана је *Levene-овим* тестом ( $F(1,12) = 1,660, p = 0,221$ ), док је независност потврђена Хи-квадрат тестом ( $X^2 = 0,193, p = 0,660$ ). Резултати  $t$ -теста показују постојање статистички значајне разлике између просечне годишње стопе незгода са животињама током пуног Месеца ( $H_{\text{пм}}$ :  $M = 1,135, SD = 1,028$ ) и током осталих дана ( $H_{\text{од}}$ :  $M = 0,819, SD = 0,233$ );  $t(12) = 1,82, p = 0,042$ . Вредност Коеновог  $d$  коефицијента је 1,05, што указује на снажан ефекат (*Téllez et al., 2015*), односно на значајну разлику између посматраних група. Ово потврђује да је ризик од појаве незгода са животињама током пуног Месеца већи ( $H_{\text{пм}} = 1,135$ ) у односу на остале ноћне периоде ( $H_{\text{од}} = 0,820$ ).

С обзиром на територијалну организацију Републике Србије, која је подељена на 25 административних области, извршена је додатна просторна анализа ризика од појаве  $H_{\text{пм}}$ -а. Циљ ове анализе био је да се идентификују потенцијално угрожене области. У ту сврху, примењен је модификован индикатор ризика, дефинисан као агрегирана мера заснована на три компоненте (*Ha and Shilling, 2018*):

Јавни ризик:

$$JR = \frac{\text{Укупан број НЖ}}{\text{Популација}} \times 100.000 \text{ (НЖ на 100.000 становника)} \quad (83)$$

Путни ризик:

$$PR = \frac{\text{Укупан број НЖ}}{\text{Дужина путне мреже (km)}} \times 100 \text{ (НЖ на } 100 \text{ km пута)} \quad (84)$$

Ризик пошумљености:

$$RP = \frac{\text{Укупан број НЖ}}{\text{Пошумљеност (ha)}} \times 1000 \text{ (НЖ на } 1000 \text{ ha шуме)} \quad (85)$$

У циљу објективног одређивања тежинских коефицијената за агрегирани показатељ ризика, примењена је анализа главних компоненти (енг. *Principal Component Analysis, PCA*), користећи вредности индивидуалних ризика.

Јужнобачки и Подунавски округ показују изразито позитивне вредности на првој главној компоненти (PC1), што указује на снажан кумулативни утицај свих анализираних индикатора ризика. Такав образац потенцијално указује на већу изложеност или интензивнију интеракцију између станишта дивљих животиња и саобраћајне инфраструктуре у овим регионима. Насупрот томе, окрузи са негативним вредностима на PC1 имају сасвим другачију ризичну структуру, што је вероватно последица мање густине насељености. Друге две компоненте, PC2 и PC3, омогућавају додатну просторну диференцијацију и препознавање специфичних регионалних карактеристика. Тако, Колубарски и Борски округ имају високе вредности на другој компоненти, што може указивати на специфичан однос између инфраструктуре и природних обележја у тим подручјима. Са друге стране, Севернобанатски округ се издваја по трећој компоненти (PC3), што указује на посебан образац ризика који није обухваћен претходним двама димензијама.

Генерално, прва главна компонента објашњава 67,97% укупне варијансе у анализираним подацима, што указује да једна латентна димензија поседује већину информација садржаних у сва три индикатора ризика. Утврђене вредности тежина за ову компоненту износе:  $PR = 0,49$ ,  $RNR = 0,66$  и  $FAR = 0,57$ . Управо су ове вредности коришћене као статистички изведени тежински коефицијенти у формули за израчунавање укупног композитног индекса ризика.

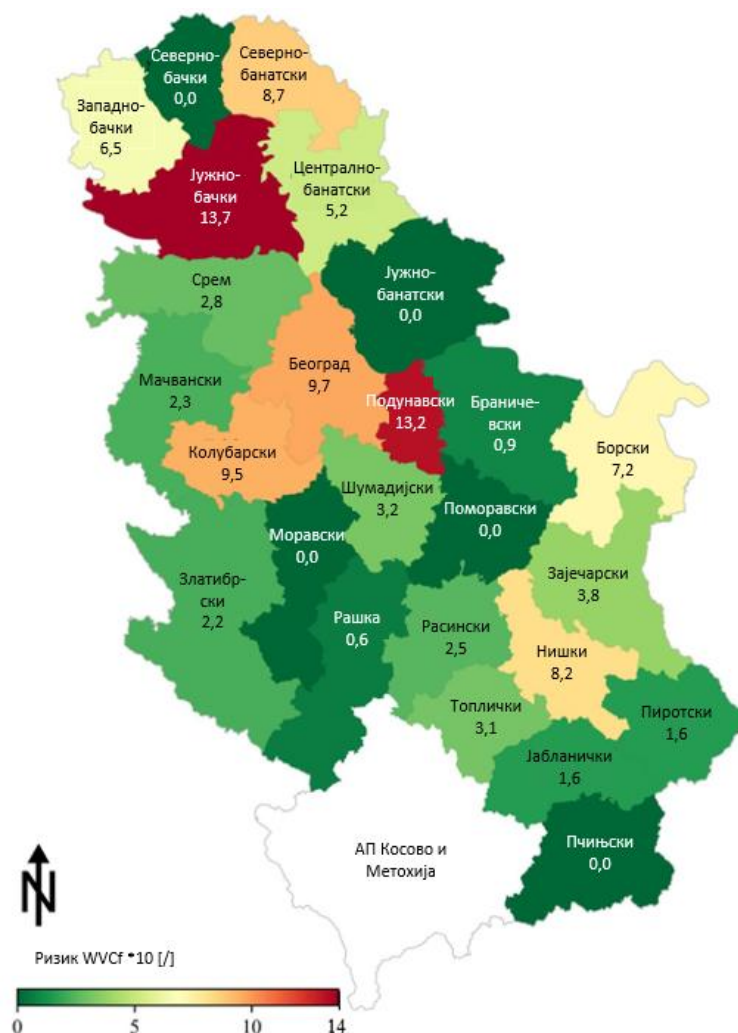
Сходно томе, агрегирана вредност ризика може се израчунати као:

$$P_{\text{ук}} = w_1 \times JP + w_2 \times PR + w_3 \times RP \quad (86)$$

Где су:

$w_1$ ,  $w_2$ ,  $w_3$ , тежинске вредности (добијене на основу PCA анализе) додељене сваком индикатору ( $JP$ ,  $PR$  и  $RP$ ), тако да су:  $w_1 = 0,49$ ,  $w_2 = 0,66$  и  $w_3 = 0,57$ .

На тај начин добијен је композитни индекс ризика који омогућава поређење административних области на основу укупне изложености ризику од незгода са животињама током пуног Месеца. Резултати анализе визуелизовани су на Слици 73. Подаци о броју становника, површини и дужини путева (без Косова и Метохије, за које није било доступних података) преузети су из годишњег извештаја Републичког завода за статистику (*Statistical Office of the Republic of Serbia, 2024b*).



Слика 73. Модификовани ризик за административне регионе Републике Србије

Јужнобачки округ (ризик = 13,7) и Подунавски округ (ризик = 13,2) представљају административне области са највишим агрегатним ризиком од појаве саобраћајних незгода са животињама током пуног месеца (НЖ<sub>пм</sub>). Средњи ниво ризика идентификован је у Колубарском округу (9,5) и граду Београду (9,7), док најнижи ризик показују Севернобачки, Јужнобанатски, Моравски, Поморавски и Пчињски окрузи, у којима током анализираних периода није документован ниједан случај НЖ<sub>пм</sub>.


Просторна анализа ризика указује на концентрацију ризика у централним и северно-централним деловима Србије. Посебно је интересантна појава да Јужнобачки округ, који нема значајну пошумљеност или познате миграционе коридоре дивљих животиња, показује највиши ниво ризика. Овај налаз делимично се може објаснити апсолутним бројем забележених НЖ<sub>пм</sub>, где је Јужнобачки округ (заједно са Београдом) имао највећи број таквих инцидената током испитиваног периода (14 и 28 незгода са животињама, респективно). С друге стране, очекивани већи ризик у јужним областима, као што су Пчињски (0) и Топлички округ (3,1), није потврђен, иако те области обухватају простране шумске пределе.

Ови резултати указују на потенцијалне ограничености постојећих индикатора и потребу за проширењем анализе у правцу укључивања еколошких и геопросторних променљивих, као што су густина пошумљености, врста и бројност дивљих животиња, близина природних миграционих коридора, као и присуство препрека или привлачних фактора у близини путне инфраструктуре. Будућа истраживања усмерена на ове аспекте могу значајно допринети развоју прецизнијих просторних модела ризика и ефикаснијих мера превенције.

У наставку докторске дисертације приказани су резултати развијеног модела за предикцију саобраћајних незгода са животињама у Србији, тренираног на подацима за период од 2016. до 2024. године.

Имајући у виду да се ради о саобраћајним незгодама са животињама, које представљају ретке догађаје у укупном броју незгода, примена класичних модела за анализу временских серија, као што су ARIMA, SARIMA или Prophet, није била методолошки оправдана. Ограниченост обима података, као и присутна хетерогеност у учесталости инцидената, онемогућили су адекватно прилагођавање ових модела. Уместо тога, за потребе тренирања модела коришћен је CatBoost модел, који је посебно ефикасан са категоријским променљивима и мањим скуповима података. Након спроведеног тестирања CatBoost се показао као најпоузданије решење у оквиру спроведеног експеримента, са бољим метрикама прецизности у односу на алтернативни модел XGBoost. Резултати XGBoost модела били су лошији у погледу мере грешке и прилагођености тренду, па је овај модел искључен из даље анализе.


Приликом моделовања, подаци су подељени у односу 80 : 20, при чему је 80% коришћено за тренирање модела, а преосталих 20% за тестирање његове ефикасности. Након спроведене оптимизације хиперпараметара, као најбоља конфигурација издвојени су следећи параметри: дубина стабла (depth) = 4, број итерација = 200 и стопа учења (learning rate) = 0,1. Ова комбинација параметара обезбедила је најбољу равнотежу између прецизности и избегавања „претренираности” модела.



**Слика 74.** Стваран и предвиђен број незгода са животињама по сату, у Србији, за 2024. годину

На Слици 74 приказано је поређење стварног и предвиђеног броја незгода по сатима. Визуелни приказ омогућава процену квалитета модела у смислу праћења дневне динамике незгода, при чему се уочава да модел задовољавајуће прати општи тренд (коэффицијент детерминације износи 81%), уз веома мала одступања код локалних максимума и минимума, што је и очекивано с обзиром на ограничен обим и варијабилност података.


На Слици 75 приказан је хистограм грешака израђеног модела.



**Слика 75.** Хистограм грешака при предикцији саобраћајних незгода са животињама

Хистограм грешака (разлика између стварног и предвиђеног броја незгода) приказује асиметричну дистрибуцију, са благом нагнутошћу ка негативним вредностима. Ово указује да CatBoost модел у одређеном броју случајева прецени број незгода са животињама у односу на стварне вредности. Већина грешака се креће у интервалу од  $-5$  до  $+5$ , што указује на релативно добру прецизност модела. Међутим, присутне су и екстремније вредности, што може указивати на постојање атипичних сати са наглим скоковима или падовима у броју незгода које модел није успео адекватно да „открије”.


Сличан закључак произилази и на основу метрике приказане на наредним двама сликама које дају податке о стварном броју незгода са животињама по сатима у зависности од године (Слика 76) и предвиђени број незгода по сатима у зависности од године (Слика 77).



Слика 76. Стваран број незгода са животињама по сату, по години, на подручју Србије

Уочљив је јасан образац пораста учесталости незгода у вечерњим и ноћним сатима (између 18 h и 23 h), што је вероватно повезано са смањеном видљивошћу, дневном миграцијом животиња и сл. Поред тога, може се приметити да је нпр. 2022. година са већим бројем незгода по години. Ово указује на потенцијалну улогу спољашњих фактора, као што су временски услови или пораст популације дивљачи у тим годинама.

Слика 77 приказује број незгода као излаз из CatBoost модела, по сату и години.



Слика 77. Излаз из CatBoost модела – број незгода са животињама по сату, по години, на подручју Србије

Оно што је важно напоменути на овом месту јесте то да је циљ оваквог приказа да се покаже колико добро модел „реконструише” историјски образац. На основу приказаних резултата, примећује се да модел добро репродукује постојеће шаблоне. Интензитет излазних вредности такође расте у вечерњим сатима, што указује на то да је модел успешно „открио” главне обрасце у подацима. Међутим, у поређењу са стварним вредностима, модел показује расподелу са мањим одступањима и мањим екстремним вредностима, што је типично за моделе који имају тенденцију регуларизације. Посебно је важно напоменути да је за 2024. годину модел одржао конзистентност, што говори о његовој способности да добро генерализује на новим подацима.

Сходно приказаним резултатима и доказу да пун Месец у одређеном смислу може имати утицај на учесталост саобраћајних незгода са животињама, прихвата се Хипотеза 5.

### **7.5 Дискусија резултата добијених на основу анализе екстратерестричких утицаја на појаву саобраћајних незгода са животињама у Србији за период од 2015. до 2023. године**

У овом делу докторске дисертације анализирана је појава незгода између возила и дивљих животиња током периода пуног Месеца у Републици Србији (од 2015. до 2023. године). Утврђено је да је број незгода са животињама статистички значајно већи током ноћи пуног Месеца у односу на друге дане у месецу, што имплицира да лунарна фаза, односно повећано природно осветљење, може утицати на понашање дивљих животиња и њихову изложеност саобраћају. Ипак, комплетно поређење између свих Месечевих фаза (пун Месец, млад Месец, прва и последња четврт) није дало статистички значајне разлике, што указује на то да и други фактори, попут сезоне, станишта и људског утицаја, играју важну улогу у настанку догађаја саобраћајних незгода у којима учествују животиње. Спроведеним истраживањем потврђују се резултати претходних студија (*Colino-Rabanal et al., 2018; Iio and Lord, 2024*), које су указале на појачану активност животиња у вечерњим часовима. Боља видљивост омогућава животињама лакше уочавање предатора, што може подстаћи њихову кретање и потребу за преласком путева. Овакво понашање, међутим, истовремено повећава ризик од саобраћајних незгода, нарочито у условима већих брзина, мање густине саобраћаја и смањене пажње возача на ванградским подручјима, параметара који у контексту теорије саобраћајног тока могу значајно повећати вероватноћу незгоде. Немогућност да се утврде значајне разлике између лунарних фаза потврђује налазе из Литваније (*Ignatavičius et al., 2021*), где је такође указано на сложену међузависност између фазе Месеца и других фактора, као што су сезонске миграције, локалне екосистемске карактеристике и специфично понашање врста. Таква комплексност указује на ограничену применљивост лунарног фактора као изоловане улазне променљиве, што захтева вишефакторске приступе у анализи ових догађаја.

На основу просторне анализе у овом делу истраживања издвојени су Јужнобачки и Подунавски округ као жаришта незгода са животињама током пуног Месеца. Ово додатно указује и на утицај регионалних карактеристика, као што су густина путне мреже, обим саобраћаја, близина шумских подручја и река, али и структура станишта. Иако је Београд имао највећи апсолутни број оваквих незгода ( $n = 28$ ), ризик није био највећи због велике

густине становништва и саобраћаја, што у односу броја ових незгода снижава релативни ризик. Овакав налаз у складу је са концептима теорије тока, где је вероватноћа догађаја резултат интеракције између фреквенције, брзине и просторне концентрације возила.

На основу идентификованих просторних жаришта, у оквиру овог истраживања препоручене су опште мере превенције и унапређења постојећег стања које укључују:

- идентификацију типичних места укрштања путева животиња са саобраћајном мрежом;
- постављање и одржавање заштитних ограда на критичним деоницама, односно местима укрштања миграционих путева животиња и саобраћајне мреже;
- постављање, одржавање и унапређење сталне сигнализације на критичним деоницама;
- примену изменљиве саобраћајне сигнализације (VMS) током ноћи пуног Месеца, када се ризик повећава. Овакви системи упозорења могу имати значајан утицај на смањење ризика, посебно на путевима са нижом осветљеношћу и вишом просечном брзином.

Такође, истраживање спроведено од стране Вркљана и сарадника (2017) указује на сезонску осетљивост незгода са животињама, посебно у периодима миграције и парења, који временски могу бити усклађени са фазама пуног Месеца. Важно је нагласити да комплексност ових догађаја произилази и из антропогених фактора као што су дизајн пута, интензитет саобраћаја и понашање возача, што потврђују светска истраживања (*Pagany, 2020*). Комбинација ових елемената може лунарне утицаје учинити маргиналним и отежати идентификацију доминантних фактора. Планирано је да се у оквиру будућих истраживања обухвате и укључе параметри као што су карактеристике пута, густина и проток возила, понашање корисника и сл., како би се модели унапредили у складу са принципима теорије саобраћајног тока.

Додатно, у оквиру овог дела докторске дисертације представљен је и модел за предикцију саобраћајних незгода са животињама по часу трениран за период од 2016. до 2024. године. Достигнут је коефицијент детерминације од 81%, што представља висок ниво разумевања и генерализације на тест-примеру. Израђени модел, у комбинацији са претходно приказаном методологијом за идентификовање и анализу саобраћајних незгода са животињама током пуног Месеца, могу послужити као адекватна основа и алат у процесу идентификације, анализе, третирања, превенције и предикције овог типа незгода на подручју Србије.

Треба напоменути и значај отворених и ажурних база података у оваквим истраживањима. Само кроз одговарајуће базе које укључују и врсту животиње, тачну локацију, услове на путу али и остале доступне детаље из записника сачињених приликом увиђаја, могуће је постићи потпуну аналитичку валидност планираних истраживања. У том смислу, потребно је фокусирати се и на квалитет евидентирања саобраћајних незгода са животињама, што би омогућило ефикасније моделирање, предикцију и превенцију оваквих типова незгода у будућности.

Будућа истраживања ће, поред већ постојећих анализа (*Jevremović et al., 2025a*), проширити палету потенцијалних екстратерестричних и метеоролошких утицаја на настанак саобраћајних незгода са животињама, кроз примену посебно развијеног софтвера за обраду и анализу ECMWF ERA5 NetCDF података (*Jevremović et al., 2025b*). Такође, уколико доступни подаци то буду омогућивали, анализа ће бити усмерена на утицаје и настанак незгода са животињама по врсти животиња.

---

---

## ЗАКЉУЧАК



---

---

У оквиру ове докторске дисертације анализирани су и квантификовани различити негативни утицаји ризика у друмском саобраћају у Републици Србији кроз пет тематски и методолошки повезаних истраживачких целина. Циљ истраживања био је да се кроз анализу и интеграцију различитих типова података (саобраћајни (карактеристике коловоза, карактеристике саобраћаја, понашање корисника, карактеристике параметара безбедности у саобраћају), просторни подаци и подаци који се односе на здравствени ризик корисника (године изгубљеног живота, године живота са инвалидитетом и године изгубљеног здравог живота)) развију и примене напредни алати и модели за процену, класификацију и предикцију саобраћајног ризика на државној мрежи путева IB реда у Србији. За потребе наведених истраживања примењене су савремене технике рачунарске интелигенције, статистичког моделовања, геопросторне обраде и машинског учења, уз поштовање принципа интерпретабилности, транспарентности, применљивости и репродуктивности.

Један од кључних предуслова за унапређење система безбедности саобраћаја јесте детаљна процена здравствених и просторних последица саобраћајних незгода по становништво. Применом методологије Глобалног терета болести (GBD) на податке за период 2002–2022, израчунате су најновије вредности индикатора оптерећења становништва повредама у саобраћају, агрегиране по регионима Србије. Истраживање је дало најобухватнији и најновији увид у здравствене последице саобраћаја, представљајући прву анализу те врсте у Србији. Од увођења Закона о безбедности саобраћаја 2009. године примењено је смањење морталитета, али истовремено и раст броја преживелих са дугорочним последицама (повредама). Просторна анализа указала је на изражене регионалне неједнакости, при чему су Војводина и источни део централне Србије идентификовани као региони са највећим оптерећењем у домену инвалидитета. 2015. година такође представља важну временску одредницу јер је тада донета прва Стратегија безбедности саобраћаја на путевима. Ипак, не може се у потпуности тврдити да је након тог периода евидентиран значајни пад анализираних индикатора. Смањење постоји само у одређеним регионима, док поједини региони бележе чак и пораст укупног индикатора DALY (Борски, Моравички, Тимочки). Генерално, резултати указују да су законске и стратешке мере биле ефикасне у смањењу

најтежих исхода, али да даљи напредак захтева прецизније, циљано усмерене мере који ће истовремено адресирати и изложеност и учесталост незгода. То подразумева интеграцију како инфраструктурних, тако и управљачких мера на регионалном нивоу, уз континуирано праћење индикатора који обухватају не само смртност већ и шири друштвени терет саобраћајних незгода. Допринос овог дела докторске дисертације огледа се у првој примени GBD методологије у Србији на регионалном нивоу, са циљем објективне процене оптерећења становништва повредама у саобраћају.

Ефективно управљање саобраћајним ризиком захтева не само идентификацију опасних места већ и њихову типизацију ради адекватног избора мера превенције. У оквиру дисертације развијен је први национални методолошки приступ за идентификацију и фази категоризацију опасних места на мрежи државних путева IB реда у Србији за период 2021–2023, који интегрише геометријске карактеристике пута, изложеност саобраћају и тежину последица незгода. Ово је уједно прво истраживање које је категоризацију опасних места формално дефинисало и применило на националном нивоу, што представља значајан методолошки допринос у области безбедности саобраћаја, како у домаћем, тако и у међународном контексту. Дефинисано је шест типова опасних места: експлозивне, тихе, флукутирајуће, инертне, аномалне и локације са опраштајућим карактеристикама. Најзаступљеније и најризичније биле су експлозивне и тихе локације, чија временска појава показује високу нестабилност. Та чињеница указује на изостанак или неадекватност превентивних и санационих мера. Научни допринос овог дела рада огледа се у развоју првог систематизованог приступа категоризацији и праћењу опасних места у Србији.

За планирање интервенција и унапређење безбедности саобраћаја на путној мрежи, посебно је важно предвидети будуће обрасце незгода. У дисертацији су развијени и тестирани модели предикције броја саобраћајних незгода за ванградску мрежу IB реда, уз примену SHAP анализе за тумачење утицаја појединачних променљивих. Модели су примењени на подацима за период 2021–2023, уз обухват обимног сета података. Постигнут је високи коефицијент детерминације ( $R^2 = 79\%$ ), при чему су најзначајније улазне променљиве биле просечни годишњи дневни саобраћај (ПГДС) и типови елемената пута. Допринос овог дела рада огледа се у развоју свеобухватног и интерпретабилног модела предикције саобраћајних незгода за ванградску мрежу IB реда у Србији.

Да би се добио детаљнији увид и разумевање ризика од настанка саобраћајних незгода, потребни су модели који анализирају незгоде на часовном нивоу и прилагођавају се различитим типовима саобраћаја и мрежа, те је зато у овој докторској дисертацији развијен модел предикције саобраћајних незгода по сату за период 1997–2024, користећи временске серије и напредне машинске методе. Изабрани модели, SARIMA и CatBoost, постигли су просечну тачност од 93%, уз највећи  $R^2$  од 99% за незгоде са путничким возилима на градској мрежи и најнижи  $R^2$  од 61% за незгоде са погинулима. Предвиђање је обухватило 11 категорија – по врсти незгоде, врсти учесника и типу мреже – што овај модел, по обиму и разноврсности, чини првим такве врсте у Србији. Научни допринос огледа се у развоју високорезолуцијског система за временску предикцију незгода на националном нивоу, који може бити основа за динамичко управљање ризиком у саобраћају.

Иако се саобраћајне незгоде са животињама све чешће препознају као значајан проблем безбедности саобраћаја, у Србији је анализа спољашњих утицаја, посебно екстратерестричких фактора, још увек недовољно истражена. Управо тај недостатак био је полазиште за спровођење првог систематског приступа анализи екстратерестричких утицаја на настанак незгода са животињама на националном нивоу. Посебна пажња посвећена је анализи утицаја Месечевих фаза, са фокусом на незгоде током ноћи у периоду 2015–2023. године. Обрађено је 2767 ноћних незгода, што чини 50% укупних незгода са животињама у анализираном периоду. Утврђена је статистички значајна разлика у фреквенцији незгода током пуног Месеца у односу на остале ноћи ( $p = 0,042$ ; *Cohen's d* = 1,05), док се значајне разлике нису показале између различитих фаза Месеца (млад Месеца, прва и трећа четвртина, пун Месеца). Просторна анализа ризика указала је на Јужнобачки (13,7) и Подунавски округ (13,2), као подручја са највишим ризиком, при чему је развијен и примењен композитни индикатор ризика који укључује јавни, путни и ризик пошумљености. На овај начин успостављен је нов и транспарентан методолошки оквир за рангирање области према вероватноћи настанка незгода са животињама током пуног Месеца. Поред тога, развијен је и модел за предикцију броја незгода са животињама по сату, трениран за период 2016–2024, при чему је CatBoost алгоритам показао највећу прецизност ( $R^2 = 81\%$ ) и стога је одабран као финални модел. Допринос овог дела дисертације огледа се у успостављању првог интегрисаног приступа анализи незгода са животињама у Србији, који обједињује идентификацију екстратерестричких утицаја, просторно рангирање ризичних области и временску предикцију. Овакви резултати пружају основу за доношење ефикаснијих и прилагођених мера превенције у специфичним условима, где традиционални модели управљања ризиком често нису довољни.

Научни допринос овог докторског рада огледа се у интеграцији савремених техника рачунарске интелигенције и машинског учења са реалним проблемима безбедности саобраћаја на мрежи државних путева у Србији. Синергијом оваквог приступа, од фази логике, вештачких неуронских мрежа, до напредних модела предикције заснованих на временским серијама, омогућено је формирање адекватне базе за управљање и категоризацију ризика, као и моделовање просторних и временских образаца саобраћајних незгода са високим нивоом прецизности. Овај приступ представља методолошку иновацију која преошћује јаз између различитих и међусобно зависних фактора човек–пут и окружења и потребе за применљивим, прецизним и одрживим алатима за доношење одлука у управљању безбедношћу саобраћаја.

У складу са наведеним, научни доприноси ове докторске дисертације огледају се у следећем:

- извршено је прво прилагођавање и примена GBD методологије у Србији, за период од 2002. до 2024. године, са детаљном анализом DALY, YLL и YLD индикатора по полу, старости и регионима, као последица саобраћајних незгода;
- развијен је први модел за фази категоризацију опасних места на мрежи државних путева IB реда у Србији, за период од 2021. до 2023. године;

- израђен је свеобухватни модел предикције саобраћајних незгода са SHAP предикцијом на ванградској мрежи путева IB реда у Србији, за период од 2021. до 2023. године. Израђеним моделом достигнут је коефицијент детерминације  $R^2 = 79\%$ ;
- израђени су модели предикције саобраћајних незгода по сату, за четири врсте незгода (саобраћајне незгоде са материјалном штетом, са повређенима, са погинулима и укупан број саобраћајних незгода) и пет врста возила (бицикл, мотоцикл, аутомобил, теретно возило и аутобус), у зависности од типа мреже (градска и ванградска мрежа). Просечан коефицијент детерминације добијен израђеним моделима износи  $R^2 \approx 93\%$ ;
- доказано је постојање статистички значајне разлике у броју саобраћајних незгода са животињама током пуног Месеца, у односу на број саобраћајних незгода са животињама које су се догодиле током осталих дана, не рачунајући остале фазе Месеца, ( $p = 0,042$ ; *Cohen's d* = 1,05);
- развијен је модел предикције саобраћајних незгода са животињама на подручју Србије, трениран за период од 2016. године до 2024. године. Израђеним моделом достигнут је коефицијент детерминације  $R^2 = 81\%$ .

Практична примена резултата ове докторске дисертације огледа се у могућности њиховог коришћења у процесима планирања, управљања и доношења одлука у области безбедности саобраћаја. Развијени модели, индикатори и методолошки поступци пружају научно заснован оквир за препознавање просторне и временске расподеле ризика, идентификацију приоритетних деоница и региона, као и избор мера које су усклађене са доминантним типовима ризика, као што су висока изложеност саобраћају, неповољне геометријске карактеристике пута или висока тежина последица саобраћајних незгода. На тај начин омогућава се прелазак са реактивног на проактивни приступ управљању безбедношћу саобраћаја, кроз примену модела предикције и индикатора ризика који се могу прилагођавати различитим условима и нивоима управљања.

Посебан значај дисертације огледа се у примени методологије глобалног оптерећења болестима и њених индикатора, који омогућавају да се последице саобраћајних незгода сагледају не само кроз број незгода и страдалих лица већ и кроз њихове шире здравствене, друштвене и економске последице. Овакви приступи могу представљати значајну подршку у процесу дефинисања јавних политика, расподеле ресурса, планирања превентивних активности и креирања националних и регионалних стратегија безбедности саобраћаја.

Практична вредност резултата посебно је изражена у могућности њихове примене од стране институција као што су министарства, управљачи путева, локалне самоуправе и агенције за безбедност саобраћаја, али и у ширем контексту инжењерске праксе. Развијени системи за категоризацију опасних места, модели предикције и аналитички оквири могу се интегрисати у постојеће системе управљања саобраћајем и користити као основа за развој интелигентних транспортних система и алата за подршку одлучивању. Истовремено, предложени методолошки приступи довољно су флексибилни да се, уз одређене адаптације, могу применити и на друге типове путне мреже и у различитим државама, чиме се

обезбеђује њихова шира научна и практична применљивост. На овај начин, дисертација доприноси не само теоријском разумевању ризика у саобраћају већ и развоју одрживог и систематичног приступа управљању безбедношћу друмског саобраћаја заснованог на подацима и савременим аналитичким методама.

Иако дисертација обухвата обиман скуп података, више различитих методолошких приступа и анализа, одређена ограничења истраживања ипак постоје и потребно их је узети у обзир приликом тумачења резултата и могуће практичне примене предложених модела и методологија.

Једно од основних ограничења односи се на доступност и просторну расподелу улазних података. Иако је коришћен један од најобимнијих скупова података за државне путеве у Србији, поједини параметри нису били доступни континуално дуж целокупне путне мреже, већ су преузимани са фиксних локација бројача саобраћаја. Ово се посебно односи на податке о брзинама кретања возила. У раду је претпостављено да измерене вредности брзине на локацијама бројача репрезентују карактеристике деонице или сегмента пута коме су придружене. У реалним условима, брзина саобраћајног тока може варирати услед локалних геометријских карактеристика, временских услова, присуства раскрсница, насеља или других ограничења, што представља извесно ограничење анализе. Међутим, имајући у виду да је значајан део дисертације усмерен на развој и тестирање методолошког оквира, као и чињеницу да брзина у појединим предиктивним моделима није показала доминантан утицај у односу на друге факторе, наведено ограничење не умањује суштинску применљивост предложених приступа.

Приликом анализе и идентификације опасних места, потенцијално ограничење произилази из квалитета и резолуције доступних просторних података. Иако су коришћене савремене GIS методе и поступци сегментације, део података о геометријским карактеристикама пута заснива се на постојећим базама управљача путева, које могу садржати локална одступања, грешке, генерализацију или временска кашњења у ажурирању.

У оквиру фазификације и развоја фази система за категоризацију опасних места, одређени параметри и границе припадности дефинисани су на основу доступне литературе, инжењерске праксе, експертских процена и анализе података. Иако су спроведене анализе осетљивости које су показале релативну стабилност система, треба имати у виду да би употреба другачијих прагова могла довести до делимично различитих резултата категоризације.

Уколико се посматрају модели предикције, чињеница је да су они развијани првенствено за мрежу државних путева IB реда у Републици Србији. Иако предложени приступи имају потенцијал за ширу примену, њихова директна примена на урбану мрежу, ауто-путеве или путеве другачијих функционалних и саобраћајних карактеристика захтевала би додатну адаптацију и валидацију. Такође, детаљнијим моделирањем карактеристика коловоза (подужног нагиба, ширина трака, радијуса хоризонталних кривина и сл.) могуће је добити и другачије резултате за појединачне деонице, што би био добар додатни корак за још детаљније испитивање робусности модела. Са друге стране, појава и настанак саобраћајних

незгода може се анализирати са различитих аспеката и у зависности од различитих узрока (које је врло захтевно контролисати у моделу) попут: понашања возача, тренутног психофизичког стања, умора и других сличних карактеристика. Због тога чак и модели са високим степеном тачности не могу у потпуности описати све варијације у настанку саобраћајних незгода.

Такође, важно је напоменути и то да се део анализа заснивао се на историјским подацима о саобраћајним незгодама, што подразумева могућност постојања непријављених или различито евидентираних незгода, посебно код незгода са мањом материјалном штетом. Овај проблем је карактеристичан за већину студија из области безбедности саобраћаја и представља ограничење које је тешко у потпуности елиминисати.

Упркос наведеним ограничењима, дисертација обезбеђује свеобухватан методолошки оквир, развија више оригиналних приступа анализи безбедности саобраћаја и представља значајну основу за даља истраживања, од којих су само неки од праваца наведени у наставку:

- анализирање и укључивање фактора везаних за психофизичке и метеоролошке услове (алкохол, умор; падавине, магла, температура) у моделирање ризика;
- додатно раздвајање предложених категорија опасних места на подгрупе у зависности од утицајног фактора и комбинације улазних критеријума;
- развој и тестирање модела предикције незгода у реалном времену са интегрисаним подацима о брзини, густини, протоку и карактеристикама учесника у саобраћају;
- израда и калибрисање модела предикције за остале категорије саобраћајница, које нису обухваћене анализом у оквиру овог доктората, нпр. ауто-путеви или градска мрежа;
- израда модела предикције незгода (са временским серијама) на просторно мањим подручјима – градови, насеља, одређена област у оквиру града – као и за додатне кориснике, на пример кориснике возила микромобилности;
- израда модела за процену трошкова незгода у зависности од изложености и друштвеног терета;
- спровођење додатних анализа саобраћајних незгода са животињама по врсти животиња и сезонским променама.

## Литература

- Aarts, L., and Van Schagen, I., 2006: Driving speed and the risk of road crashes: A review. *Accident Analysis and Prevention*, 38, 215–224. doi:10.1016/j.aap.2005.07.004
- Abdelwahab, H.T., and Abdel-aty, M.A., 2002: Artificial Neural Networks and Logit Models for Traffic Safety Analysis of Toll Plazas. *Transportation Research Record*, 1784, 115–125.
- Abuaddous, M., Al-Hares, A., Faten Albtoush, A.M., and Aldiabat Al-Btoosh, J.A., 2022: Identification and Ranking of Accident Black Spots in Jordan. *Civil Engineering and Architecture*, 10, 1661–1674. doi:10.13189/cea.2022.100435
- Agyemang, E.F., Mensah, J.A., Ocran, E., Opoku, E., and Nortey, E.N.N., 2023: Time series based road traffic accidents forecasting via SARIMA and Facebook Prophet model with potential changepoints. *Heliyon*, 9, e22544. doi:10.1016/j.heliyon.2023.e22544
- Ahmad, A., Armiyanti Maharani, R., and Zitty Sarah, I., 2024: Artificial Intelligence in Urban Traffic Noise Prediction: A Systematic Review. *International Journal of Research and Innovation in Social Science*, VIII, 4353–4364. doi:https://dx.doi.org/10.47772/IJRISS.2024.8120364 Received:
- Ahmad, O., Boschi-Pinto, C., Lopez, A., Murray, C., Lozano, R., and Inoue, M., 2001: Age standardization of rates: A new WHO standard.
- Ahmed, S., Hossain, M.A., Ray, S.K., Bhuiyan, M.M.I., and Sabuj, S.R., 2023: A study on road accident prediction and contributing factors using explainable machine learning models: analysis and performance. *Transportation Research Interdisciplinary Perspectives*, 19, 100814. doi:10.1016/j.trip.2023.100814
- Ahmed, S.K., Mohammed, M.G., Abdulqadir, S.O., El-Kader, R.G.A., El-Shall, N.A., Chandran, D., Rehman, M.E.U., and Dhama, K., 2023: Road traffic accidental injuries and deaths: A neglected global health issue. *Health Science Reports*, 6. doi:10.1002/hsr2.1240
- Akrim, F., Mahmood, T., Andleeb, S., Hussain, R., and Collinson, W.J., 2019: Spatiotemporal patterns of wildlife road mortality in the Pothwar Plateau, Pakistan. *Mammalia*, 83, 487–495. doi:10.1515/mammalia-2017-0101
- Alagarsamy, S., Malathi, M., Manonmani, M., Sanathani, T., and Kumar, A.S., 2021: Prediction of Road Accidents Using Machine Learning Technique, In: 5th International Conference on Electronics, Communication and Aerospace Technology (ICECA). 1695–1701. doi:10.1109/ICECA52323.2021.9675852
- Almanie, T., 2023: Quantitative Study of Traffic Accident Prediction Models: A Case Study of Virginia Accidents. *The International Journal of Advanced Networking and Applications*, 14, 5582–5589. doi:10.35444/ijana.2023.14501
- Ameksa, M., Mousannif, H., Al Moatassime, H., and Elamrani Abou El Assad, Z., 2022: Crash Prediction using Ensemble Methods, In: BML 2021 - International Conference on Big Data, Modelling and Machine Learning. 211–215. doi:10.5220/0010731200003101
- Anastasopoulos, P.C., and Mannering, F.L., 2009: A note on modeling vehicle accident frequencies with random-parameters count models. *Accident Analysis and Prevention*, 41, 153–159. doi:10.1016/j.aap.2008.10.005
- Anđelković, D., Antić, B., Lipovac, K., and Tanackov, I., 2018: Identification of hotspots on roads using continual variance analysis. *Transport*, 33, 478–488. doi:10.3846/16484142.2017.1289479
- Antić, B., Grdinić-Rakonjac, M., and Pajković, V., 2025: Novel hybrid model for addressing uncertainty of the road safety composite indicator: integration of DEA and weighted GRA. *Transport*, 40, 327–342. doi:10.3846/transport.2025.20539
- Arevalo, J.E., Honda, W., Arce-Arias, A., and Häger, A., 2017: Spatio-temporal variation of roadkills show mass mortality events for amphibians in a highly trafficked road adjacent to a national park, Costa Rica. *Revista de Biología Tropical*, 65, 1261. doi:10.15517/rbt.v65i4.27903

- Arianezhad, A., Karimpour, A., Qin, X., Wu, Y.-J., and Salmani, Y., 2020: No Title. *Journal of Transportation Engineering, Part A: Systems*, 147, 16. doi:<https://doi.org/10.1061/JTEPBS.0000499>
- Asadi, M., Ulak, M.B., Geurs, K.T., Weijermars, W., and Schepers, P., 2022: A comprehensive analysis of the relationships between the built environment and traffic safety in the Dutch urban areas. *Accident Analysis and Prevention*, 172, 106683. doi:10.1016/j.aap.2022.106683
- Astarita, V., Haghshenas, S.S., Guido, G., and Vitale, A., 2023: Developing new hybrid grey wolf optimization-based artificial neural network for predicting road crash severity. *Transportation Engineering*, 12, 100164. doi:10.1016/j.treng.2023.100164
- Atanasković-Marković, Z., Bjegović, V., Janković, S., Kocev, N., Laaser, U., Marinković, J., Marković-Denić, L., Pejin-Stokić, L., Penev, G., Stanisavljević, D., Šantrić-Milićević, M., Šaulić, A., Šipetić-Grujičić, S., Terzić-Šupić, Z., and Vlajinac, H., 2002: The Burden of Disease and Injury in Serbia. Ministry of Health of the Republic of Serbia. doi:86-83607-13-5
- Augustine, T., and Shukla, S., 2022: Road Accident Prediction using Machine Learning Approaches, In: 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE). 808–811. doi:1PNDV7sctbonS1t5xCBm2ncuVNEctXhmJs
- Awasthi, D., Parti, R., and Mahajan, K., 2024: Effect of spatial relationship between curves on crash severity at horizontal curves in a mountainous terrain. *Accident Analysis & Prevention*, 206, 107714. doi:<https://doi.org/10.1016/j.aap.2024.107714>
- Aziz, S., and 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. doi:10.1016/j.trpro.2022.02.098
- Basso, F., Basso, L.J., and Pezoa, R., 2020: The importance of flow composition in real-time crash prediction. *Accident Analysis and Prevention*, 137, 105436. doi:10.1016/j.aap.2020.105436
- Behboudi, N., Moosavi, S., and Ramnath, R., 2024: Recent Advances in Traffic Accident Analysis and Prediction: A Comprehensive Review of Machine Learning Techniques. *arXiv*, 2406.13968, 26. doi:<https://doi.org/10.48550/arXiv.2406.13968>
- Bénard, A., 2023: Road ecology: toward a predictive model of wildlife-vehicle collisions. Université Claude Bernard Lyon, 236 p.
- Bhalla, K., and Harrison, J.E., 2015: Burden Calculator.
- Bhalla, K., and Harrison, J.E., 2016: Burden calculator: A simple and open analytical tool for estimating the population burden of injuries. *Injury Prevention*, 22, i23–i26. doi:10.1136/injuryprev-2015-041816
- Bhattacharai, N., Lin, C., Zhang, Y., and Liu, H., 2025: In-depth investigation of contributing factors of fatal/severe-injury crashes at highway merging areas using machine learning classification methods. *Journal of Traffic and Transportation Engineering (English Edition)*, 12, 434–446. doi:10.1016/j.jtte.2023.06.007
- Bhatti, J.A., Rafique, I., Azad, A., Hamid, M.A., Saqib, M.A.N., and Qureshi, H., 2017: Possible doubling of road traffic injury burden in Pakistan: findings from a population-based survey in 2013–2014. *Public Health*, 150, 166–169. doi:10.1016/j.puhe.2017.07.017
- Bil, M., Andrášik, R., and Bilova, M., 2024: Wildlife-vehicle collisions: The disproportionate risk of injury faced by motorcyclists. *Injury*, 55, 111301. doi:<https://doi.org/10.1016/j.injury.2023.111301>
- Borsos, A., 2014: Accident Prediction Models for Hungarian Two-Lane Rural First-Class Main Roads. *Acta Technica Jaurinensis*, 7, 280–293. doi:10.14513/actatechjaur.v7.n3.315
- Borsos, A., Cafiso, S., D'Agostino, C., and Miletics, D., 2016: Comparison of Italian and Hungarian Black Spot Ranking. *Transportation Research Procedia*, 14, 2148–2157. doi:10.1016/j.trpro.2016.05.230

- Box, G.E.P., and Jenkins, G., 1990: *Time Series Analysis, Forecasting and Control*. Holden-Day, Inc. Sansome St. San Francisco, CA United States, 500 p.
- Brauer, M., Roth, G.A., Aravkin, A.Y., Zheng, P., Abate, K.H., Abate, Y.H., Abbafati, C., Abbasgholizadeh, R., Abbasi, M.A., Abbasian, M., Abbasifard, M., Abbasi-Kangevari, M., Abd ElHafeez, S., Abd-El salam, S., Abdi, P., Abdollahi, M., Abdoun, M., Abdulah, D.M., Abdullahi, A., Abebe, M., Abedi, Aidin, Abedi, Armita, Abegaz, T.M., Zuñiga, R.A.A., Abiodun, O., Abiso, T.L., Aboagye, R.G., Abolhassani, H., Abouzid, M., Aboye, G.B., Abreu, L.G., Abualruz, H., Abubakar, B., Abu-Gharbieh, E., Abukhadajah, H.J.J., Aburuz, S., Abu-Zaid, A., Adane, M.M., Addo, I.Y., Addolorato, G., Adedoyin, R.A., Adekanmbi, V., Aden, B., Adetunji, J.B., Adeyeoluwa, T.E., Adha, R., Adibi, A., Adnani, Q.E.S., Adzighli, L.A., Afolabi, A.A., Afolabi, R.F., Afshin, A., Afyouni, S., Afzal, M.S., Afzal, S., Agampodi, S.B., Agbozo, F., Aghamiri, S., Agodi, A., Agrawal, A., Agyemang-Duah, W., Ahinkorah, B.O., Ahmad, A., Ahmad, D., Ahmad, F., Ahmad, N., Ahmad, S., Ahmad, T., Ahmed, Ali, Ahmed, Anisuddin, Ahmed, Ayman, Ahmed, L.A., Ahmed, M.B., Ahmed, S., Ahmed, S.A., Ajami, M., Akalu, G.T., Akara, E.M., Akbarialiabad, H., Akhlaghi, S., Akinosoglou, K., Akinyemiju, T., Akkaif, M.A., Akkala, S., Akombi-Inyang, B., Al Awaidy, S., Al Hasan, S.M., Alahdab, F., Al-Ahdal, T.M.A., Alalalmeh, S.O., Alalwan, T.A., Al-Aly, Z., Alam, K., Alam, N., Alanezi, F.M., Alanzi, T.M., Albakri, A., AlBataineh, M.T., Aldhaleei, W.A., Aldridge, R.W., Alemayohu, M.A., Alemu, Y.M., Al-Fatly, B., Al-Gheethi, A.A.S., Al-Habbal, K., Alhabib, K.F., Alhassan, R.K., Ali, Abid, Ali, Amjad, Ali, B.A., Ali, I., Ali, L., Ali, M.U., Ali, R., Ali, S.S.S., Ali, W., Alicandro, G., Alif, S.M., Aljunid, S.M., Alla, F., Al-Marwani, S., Al-Mekhlafi, H.M., Almustanyir, S., Alomari, M.A., Alonso, J., Alqahtani, J.S., Alqutaibi, A.Y., Al-Raddadi, R.M., Alrawashdeh, A., Al-Rifai, R.H., Alrousan, S.M., Al-Sabah, S.K., Alshahrani, N.Z., Altaany, Z., Altaf, A., Al-Tawfiq, J.A., Altirkawi, K.A., Aluh, D.O., Alvis-Guzman, N., Alvis-Zakzuk, N.J., Alwafi, H., Al-Wardat, M.S., Al-Worafi, Y.M., Aly, H., Aly, S., Alzoubi, K.H., Al-Zyoud, W., Amaechi, U.A., Mohammadi, M.A., Amani, R., Amiri, S., Amirzade-Iranaq, M.H., Ammirati, E., Amu, H., Amugsi, D.A., Amusa, G.A., Ancuceanu, R., Anderlini, D., Anderson, J.A., Andrade, P.P., Andrei, C.L., Andrei, T., Anenberg, S.C., Angappan, D., Angus, C., Anil, A., Anil, S., Anjum, A., Anoushiravani, A., Antonazzo, I.C., Antony, C.M., Antriyandarti, E., Anuoluwa, B.S., Anvari, D., Anvari, S., Anwar, S., Anwar, S.L., Anwer, R., Anyabolo, E.E., Anyasodor, A.E., Apostol, G.L.C., Arabloo, J., Bahri, R.A., Arafat, M., Areda, D., Aregawi, B.B., Aremu, A., Armocida, B., Arndt, M.B., Ärnlöv, J., Arooj, M., Artamonov, A.A., Artanti, K.D., Aruleba, I.T., Arumugam, A., Asbeutah, A.M., Asgary, S., Asgedom, A.A., Ashbaugh, C., Ashemo, M.Y., Ashraf, T., Askarinejad, A., Assmus, M., Astell-Burt, T., Athar, M., Athari, S.S., Atorkey, P., Atreya, A., Aujayeb, A., Ausloos, M., Avila-Burgos, L., Awoke, A.A., Quintanilla, B.P.A., Ayatollahi, H., Portugal, C.A., Ayuso-Mateos, J.L., Azadnajafabad, S., Azevedo, R.M.S., Azhar, G.S., Azizi, H., Azzam, A.Y., Backhaus, I.L., Badar, M., Badiye, A.D., Bagga, A., Baghdadadi, S., Bagheri, N., Bagherieh, S., Taghanaki, P.B., Bai, R., Baig, A.A., Baker, J.L., Bakkannavar, S.M., Balasubramanian, M., Baltatu, O.C., Bam, K., Bandyopadhyay, S., Banik, B., Banik, P.C., Banke-Thomas, A., Bansal, H., Barchitta, M., Bardhan, M., Bardideh, E., Barker-Collo, S.L., Bärnighausen, T.W., Barone-Adesi, F., Barqawi, H.J., Barrero, L.H., Barrow, A., Barteit, S., Basharat, Z., Basiru, A., Basso, J.D., Bastan, M.M., Basu, S., Batchu, S., Batra, K., Batra, R., Baune, B.T., Bayati, M., Bayileyegn, N.S., Beaney, T., Behnoush, A.H., Beiranvand, M., Béjot, Y., Bekele, A., Belgaumi, U.I., Bell, A.W., Bell, M.L., Bello, M.B., Bello, O.O., Belo, L., Beloukas, A., Bendak, S., Bennett, D.A., Bennitt, F.B., Bensenor, I.M., Benzian, H., Beran, A., Berezvai, Z., Bernabe, E., Bernstein, R.S., Bettencourt, P.J.G., Bhagavathula, A.S., Bhala, N., Bhandari, D., Bhardwaj, N., Bhardwaj, P., Bhaskar, S., Bhat, A.N., Bhat, V., Bhatti, G.K., Bhatti, J.S., Bhatti, M.S., Bhatti, R., Bhuiyan, M.A., Bhutta, Z.A., Bikbov, B., Bishai, J.D., Bisignano, C., Biswas, A., Biswas, B., Biswas, R.K., Bjørge, T., Boachie, M.K., Boakye, H., Bockarie, M.J., Bodolica, V., Bodunrin, A.O., Bogale, E.K., Bolla, S.R., Bolor, A., Hashemi, M.B., Boppana, S.H., Basara, B.B., Borhany, H., Carvajal, A.B., Bouaoud, S., Boufous, S., Bourne, R., Boxe, C., Braithwaite, D., Brant,

L.C., Brar, A., Breitborde, N.J.K., Breitner, S., Brenner, H., Briko, A.N., Britton, G., Brown, C.S., Browne, A.J., Brunoni, A.R., Bryazka, D., Bulamu, N.B., Bulto, L.N., Buonsenso, D., Burkart, K., Burns, R.A., Busse, R., Bustanji, Y., Butt, N.S., Butt, Z.A., dos Santos, F.L.C., Cagney, J., Cahuana-Hurtado, L., Calina, D., Cámera, L.A., Campos, L.A., Campos-Nonato, I.R., Cao, C., Cao, F., Cao, Y., Capodici, A., Cárdenas, R., Carr, S., Carreras, G., Carrero, J.J., Carugno, A., Carvalho, F., Carvalho, M., Castaldelli-Maia, J.M., Castañeda-Orjuela, C.A., Castelpietra, G., Catalá-López, F., Catapano, A.L., Cattaruzza, M.S., Caye, A., Cederroth, C.R., Cegolon, L., Cenderadewi, M., Cercy, K.M., Cerin, E., Chadwick, J., Chakraborty, C., Chakraborty, P.A., Chakraborty, S., Chan, J.S.K., Chan, R.N.C., Chandan, J.S., Chandika, R.M., Chaturvedi, P., Chen, A.T., Chen, C.S., Chen, H., Chen, M.X., Chen, M., Chen, S., Cheng, C.Y., Cheng, E.T.W., Cherbuin, N., Chi, G., Chichagi, F., Chimed-Ochir, O., Chimoriya, R., Ching, P.R., Chirinos-Caceres, J.L., Chitbeer, A., Cho, W.C.S., Chong, B., Chopra, H., Chowdhury, R., Christopher, D.J., Chu, D.T., Chukwu, I.S., Chung, E., Chung, S.C., Chutiya, M., Cioffi, I., Cogen, R.M., Cohen, A.J., Columbus, A., Conde, J., Corlateanu, A., Cortese, S., Cortesi, P.A., Costa, V.M., Costanzo, S., Criqui, M.H., Cruz, J.A., Cruz-Martins, N., Culbreth, G.T., da Silva, A.G., Dadras, O., Dai, X., Dai, Z., Daikwo, P.U., Dalli, L.L., Damiani, G., D'Amico, E., D'Anna, L., Darwesh, A.M., Das, J.K., Das, S., Dash, N.R., Dashti, M., Dávila-Cervantes, C.A., Weaver, N.D., Davitioiu, D.V., De la Hoz, F.P., de la Torre-Luque, A., De Leo, D., Debopadhaya, S., Degenhardt, L., Bo, C.D., Delgado-Enciso, I., Delgado-Saborit, J.M., Demoze, C.K., Denova-Gutiérrez, E., Dervenis, N., Dervišević, E., Desai, H.D., Desai, R., Devanbu, V.G.C., Dewan, S.M.R., Dhali, A., Dhama, K., Dhane, A.S., Dhimal, M.L., Dhimal, M., Dhingra, S., Dhulipala, V.R., Dhungana, R.R., da Silva, D.D., Diaz, D., Diaz, L.A., Diaz, M.J., Dima, A., Ding, D.D., Dinu, M., Djalalinia, S., Do, T.C., Do, T.H.P., do Prado, C.B., Dodangeh, M., Dohare, S., Dokova, K.G., Dong, W., Dongarwar, D., D'Oria, M., Dorostkar, F., Dorsey, E.R., Doshi, R., Doshmangir, L., Dowou, R.K., Driscoll, T.R., Dsouza, A.C., Dsouza, H.L., Dumith, S.C., Duncan, B.B., Duraes, A.R., Duraisamy, S., Dushpanova, A., Dzianach, P.A., Dziedzic, A.M., Ebrahimi, A., Echieh, C.P., Ed-Dra, A., Edinur, H.A., Edvardsson, D., Edvardsson, K., Efendi, F., Eftekharmehrabad, A., Eini, E., Ekholuenetale, M., Ekundayo, T.C., El Arab, R.A., El Sayed Zaki, M., El-Dahiyat, F., Elemam, N.M., Elgar, F.J., ElGohary, G.M.T., Elhabashy, H.R., Elhadi, M., Elmehrath, A.O., Elmeligy, O.A.A., Elshaer, M., Elsohaby, I., Emeto, T.I., Esfandiari, N., Eshrati, B., Eslami, M., Esmaili, S.V., Estep, K., Etaee, F., Fabin, N., Fagbamigbe, A.F., Fagbule, O.F., Fahimi, S., Falzone, L., Fareed, M., e Sá Farinha, C.S., Faris, M.A.I.E.M., Faris, P.S., Faro, A., Fasina, F.O., Fatehizadeh, A., Fauk, N.K., Fazylov, T., Feigin, V.L., Feng, X., Fereshtehnejad, S.M., Feroze, A.H., Ferrara, P., Ferrari, A.J., Ferreira, N., Fetensa, G., Feyisa, B.R., Filip, I., Fischer, F., Fitriana, I., Flavel, J., Flohr, C., Flood, D., Flor, L.S., Foigt, N.A., Folley, M.O., Force, L.M., Fortuna, D., Foschi, M., Franklin, R.C., Freitas, A., Friedman, S.D., Fux, B., Sridevi, G., Gaal, P.A., Gaihre, S., Gajdács, M., Galali, Y., Gallus, S., Gandhi, A.P., Ganesan, B., Ganiyani, M.A., Garcia, V., Gardner, W.M., Garg, R.K., Gautam, R.K., Gebi, T.G., Gebregergis, M.W., Gebrehiwot, M., Gebremariam, T.B.B., Gebremeskel, T.G., Gerema, U., Getacher, L., a Getahun, G.K., Getie, M., Ghadirian, F., Ghafarian, S., Jolfayi, A.G., Ghailan, K.Y., Ghajar, A., Ghasemi, M.R., Dabaghi, G.G., Ghasemzadeh, A., Ghassemi, F., Ghazy, R.M., Gholami, A., Gholamrezanezhad, A., Gholizadeh, N., Ghorbani, M., Gil, A.U., Gil, G.F., Gilbertson, N.M., Gill, P.S., Gill, T.K., Gindaba, E.Z., Girmay, A., Glasbey, J.C., Gnedovskaya, E.V., Göbölös, L., Godinho, M.A., Goel, A., Golechha, M., Goleij, P., Golinelli, D., Gomes, N.G.M., Gopalani, S.V., Gorini, G., Goudarzi, H., Goulart, A.C., Gouravani, M., Goyal, A., Graham, S.M., Grivna, M., Grosso, G., Guan, S.Y., Guarducci, G., Gubari, M.I.M., Guha, A., Guicciardi, S., Gulati, S., Gulisashvili, D., Gunawardane, D.A., Guo, C., Gupta, A.K., Gupta, B., Gupta, M., Gupta, Rahul, Gupta, R.D., Gupta, Rajeev, Gupta, S., Gupta, V.B., Gupta, Vijai Kumar, Gupta, Vivek Kumar, Habibzadeh, F., Habibzadeh, P., Hadaro, T.S., Hadian, Z., Haep, N., Haghi-Aminjan, H., Haghmorad, D., Hagins, H., Haile, D., Hailu, A., Ali, A.H., Halboub, E.S., Halimi, A., Hall, B.J., Haller, S., Halwani, R., Hamadeh,

R.R., Hamdy, N.M., Hameed, S., Hamidi, S., Hammoud, A., Hanif, A., Hanifi, N., Haq, Z.A., Haque, M.R., Harapan, H., Hargono, A., Haro, J.M., Hasaballah, A.I., Hasan, I., Hasan, M.J., Hasan, S.M.M., Hasani, H., Hasanian, M., Hashmeh, N., Hasnain, M.S., Hassan, A., Hassan, I., Hassan Zadeh Tabatabaei, M.S., Hassani, S., Hassanipour, S., Hassankhani, H., Haubold, J., Havmoeller, R.J., Hay, S.I., Hebert, J.J., Hegazi, O.E., Hegena, T.Y., Heidari, G., Heidari, M., Helfer, B., Hemmati, M., Henson, C.A., Herbert, M.E., Herteliu, C., Heuer, A., Hezam, K., Hinneh, T.K., Hiraike, Y., Hoan, N.Q., Holla, R., Hon, J., Hoque, M.E., Horita, N., Hossain, S., Hosseini, S.E., Hosseinzadeh, H., Hosseinzadeh, M., Hostiuc, M., Hostiuc, S., Hoven, H., Hsairi, M., Hsu, J.M., Hu, C., Huang, J., Huda, M.N., Hulland, E.N., Hultström, M., Hushmandi, K., Hussain, J., Hussein, N.R., Huynh, C.K., Huynh, H.H., Ibitoye, S.E., Idowu, O.O., Ihler, A.L., Ikeda, N., Ikuta, K.S., Ilesanmi, O.S., Ilic, I.M., Ilic, M.D., Imam, M.T., Immurana, M., Inbaraj, L.R., Irham, L.M., Isa, M.A., Islam, M.R., Ismail, F., Ismail, N.E., Iso, H., Isola, G., Iwagami, M., Iwu, C.C.D., Iwu-Jaja, C.J., Vinothini, J., Jaafari, J., Jacob, L., Jacobsen, K.H., Jadidi-Niaragh, F., Jahankhani, K., Jahanmehr, N., Jahrami, H., Jain, A., Jain, N., Jairoun, A.A., Jaiswal, A., Jakovljevic, M., Yengejeh, R.J., Jamora, R.D.G., Jatau, A.I., Javadov, S., Javaheri, T., Jayaram, S., Jeganathan, J., Jeswani, B.M., Jiang, H., Johnson, C.O., Jokar, M., Jomehzadeh, N., Jonas, J.B., Joo, T., Joseph, A., Joseph, N., Joshi, V., Joshua, C.E., Jozwiak, J.J., Jürisson, M., Kaambwa, B., Kabir, A., Kabir, Z., Kadashetti, V., Kahn, E.M., Kalani, R., Kaliyadan, F., Kalra, S., Kamath, R., Kanagasabai, T., Kanchan, T., Kandel, H., Kanmiki, E.W., Kanmodi, K.K., Kansal, S.K., Kapner, D.J., Kapoor, N., Karagiannidis, E., Karajizadeh, M., Karakasis, P., Karanth, S.D., Karaye, I.M., Karch, A., Karim, A., Karimi, H., Karmakar, S., Kashoo, F.Z., Kasraei, H., Kassahun, W.D., Kassebaum, N.J., Kassel, M.B., Katikireddi, S.V., Kauppila, J.H., Kawakami, N., Kaydi, N., Kayode, G.A., Kazemi, F., Keiyoro, P.N., Kemmer, L., Kempen, J.H., Kerr, J.A., Kesse-Guyot, E., Khader, Y.S., Khafaie, M.A., Khajuria, H., Khalaji, A., Khalil, M., Khalilian, A., Khamesipour, F., Khan, A., Khan, M.N., Khan, M., Khan, M.J., Khan, M.A.B., Khanmohammadi, S., Khatlab, K., Khatatbeh, H., Khatatbeh, M.M., Khatib, M.N., Khavandegar, A., Kashani, H.R.K., Khidri, F.F., Khodadoust, E., Khormali, M., Khorrami, Z., Khosla, A.A., Khosrowjerdi, M., Khreis, H., Khusun, H., Kifle, Z.D., Kim, K., Kim, M.S., Kim, Y.J., Kimokoti, R.W., Kisa, A., Kisa, S., Knibbs, L.D., Knudsen, A.K.S., Koh, D.S.Q., Kolahi, A.A., Kompani, F., Kong, J., Koren, G., Korja, M., Korshunov, V.A., Korzh, O., Kosen, S., Kothari, N., Koul, P.A., Laxminarayana, S.L.K., Krishan, K., Krishnamoorthy, V., Krishnamoorthy, Y., Krishnan, B., Krohn, K.J., Defo, B.K., Bicer, B.K., Kuddus, M.A., Kuddus, M., Kugbey, N., Kuitunen, I., Kulimbet, M., Kulkarni, V., Kumar, A., Kumar, N., Kumar, V., Kundu, S., Kurmi, O.P., Kusnali, A., Kusuma, D., Kutluk, T., Vecchia, C.L., Ladan, M.A., Laflamme, L., Lahariya, C., Lai, D.T.C., Lal, D.K., Lallukka, T., Lám, J., Lan, Q., Lan, T., Landires, I., Lanfranchi, F., Langguth, B., Lansingh, V.C., Laplante-Lévesque, A., Larijani, B., Larsson, A.O., Lasrado, S., Lauriola, P., Le, H.H., Le, L.K.D., Le, N.H.H., Le, T.T.T., Leasher, J.L., Ledda, C., Lee, M., Lee, P.H., Lee, S.W., Lee, S.W.H., Lee, Y.H., LeGrand, K.E., Leigh, J., Leong, E., Lerango, T.L., Lescinsky, H., Leung, J., Li, M.C., Li, W.Z., Li, W., Li, Y., Li, Z., Ligade, V.S., Lim, L.L., Lim, S.S., Lin, R.T., Lin, S., Liu, C., Liu, G., Liu, Jinli, Liu, Jue, Liu, R.T., Liu, S., Liu, W., Liu, Xiaofeng, Liu, Xuefeng, Livingstone, K.M., Llanaj, E., Lohiya, A., López-Bueno, R., Lopukhov, P.D., Lorkowski, S., Lotufo, P.A., Lozano, R., Lubinda, J., Lucchetti, G., Luo, L., Lv, H., Amin, H.I.M., Ma, Z.F., Maass, K.L., Mabrok, M., Machairas, N., Machoy, M., Mafhoumi, A., El Razek, M.M.A., Maghazachi, A.A., Prasad, D.R.M., Maharaj, S.B., Mahmoud, M.A., Mahmoudi, E., Majeed, A., Makram, O.M., Makris, K.C., Malasala, S., Maled, V., Malhotra, K., Malik, A.A., Malik, I., Malinga, L.A., Malta, D.C., Mamun, A.A., Manda, A.L., Manla, Y., Mansour, A., Mansouri, B., Mansouri, P., Mansourian, M., Mansournia, M.A., Mantovani, L.G., Manu, E., Marateb, H.R., Maravilla, J.C., Marsh, E., Martinez, G., Martinez-Piedra, R., Martini, S., Martins-Melo, F.R., Martorell, M., Marx, W., Maryam, S., Mathangasinghe, Y., Mathioudakis, A.G., Matozinhos, F.P., Mattumpuram, J., Maugeri, A., Maulik, P.K., Mayeli, M., Mazidi, M., Mazzotti, A., McGrath, J.J., McKee, M.,

McKowen, A.L.W., McLaughlin, S.A., McPhail, M.A., McPhail, S.M., Mechili, E.A., Mehmood, A., Mehmood, K., Mehrabani-Zeinabad, K., Nasab, E.M., Meier, T., Mejia-Rodriguez, F., Meto, T.M., Mekonnen, B.D., Menezes, R.G., Mengist, B., Mensah, G.A., Mensah, L.G., Mentis, A.F.A., Meo, S.A., Meretoja, A., Meretoja, T.J., Mersha, A.M., Mesfin, B.A., Mestrovic, T., Mettananda, K.C.D., Mettananda, S., Miazgowski, T., Micha, G., Michalek, I.M., de Sá, A.C.M.G.N., Miller, T.R., Mirarefin, M., Mirghafourvand, M., Mirica, A., Mirijello, A., Mirrakhimov, E.M., Mirshahi, A., Mirzaei, M., Mishra, A.K., Mishra, V., Mitchell, P.B., Mithra, P., Mittal, C., Moazen, B., Moberg, M.E., Mocciaro, G., Mohamadkhani, A., Mohamed, A.Z., Mohamed, A.I., Mohamed, J., Mohamed, M.F.H., Mohamed, N.S., Mohammadi, E., Mohammadi, S., Mohammadian-Hafshejani, A., Mohammadifard, N., Mohammed, H., Mohammed, M., Mohammed, Salahuddin, Mohammed, Shafiu, Mokdad, A.H., Monasta, L., Mondello, S., Moni, M.A., Ghalibaf, A.A.M., Moore, C.E., Moradi, M., Moradi, Y., Moraga, P., Morawska, L., Moreira, R.S., Morovatdar, N., Morrison, S.D., Morze, J., Heris, R.M., Mossialos, E., Motappa, R., Mougin, V., Mousavi, P., Msherghi, A., Mubarik, S., Muccioli, L., Mueller, U.O., Mulita, F., Mullany, E.C., Munjal, K., Murillo-Zamora, E., Murlimanju, B.V., Musina, A.M., Mustafa, G., Muthu, S., Muthupandian, S., Muthusamy, R., Muzaffar, M., Myung, W., Nafei, A., Nagarajan, A.J., Nagaraju, S.P., Nagel, G., Naghavi, M., Naghavi, P., Naik, G.R., Naik, G., Nainu, F., Nair, T.S., Najdaghi, S., Ansari, N.N., Nanavaty, D.P., Nangia, V., Swamy, S.N., Davani, D.N., Nascimento, B.R., Nascimento, G.G., Nashwan, A.J., Natto, Z.S., Nauman, J., Navaratna, S.N.K., Naveed, M., Nayak, B.P., Nayak, V.C., Ndejjo, R., Nduaguba, S.O., Negash, H., Nego, I., Nego, R.I., Nejadghaderi, S.A., Nejjari, C., Nematollahi, M.H., Nepal, S., Neupane, S., Ng, M., Nguefack-Tsague, G., Ngunjiri, J.W., Nguyen, D.H., Nguyen, N.N.Y., Nguyen, Phat Tuan, Nguyen, Phuong The, Nguyen, V.T., Minh, D.N.T., Niazi, R.K., Nicholson, S.I., Nie, J., Nikoobar, A., Nikpoor, A.R., Ningrum, D.N.A., Nnaji, C.A., Noman, E.A., Nomura, S., Noroozi, N., Norrving, B., Noubiap, J.J., Nri-Ezedi, C.A., Ntaios, G., Ntsekhe, M., Nunemo, M.H., Nurrika, D., Tutor, J.J., Oancea, B., O'Connell, E.M., Odetokun, I.A., O'Donnell, M.J., Oduro, M.S., Ogunfowokan, A.A., Ogunkoya, A., Oh, I.H., Okati-Aliabad, H., Okeke, S.R., Okekunle, A.P., Okonji, O.C., Olagunju, A.T., Olasupo, O.O., Olatubi, M.I., Oliveira, A.B., Oliveira, G.M.M., Olorukooba, A.A., Olufadewa, I.I., Olusanya, B.O., Olusanya, J.O., Oluwafemi, Y.D., Omar, H.A., Bali, A.O., Omer, G.L., Ong, K.L., Ong, S., Onwujekwe, O.E., Onyedibe, K.I., Oppong, A.F., Ordak, M., Orish, V.N., Ornello, R., Orpana, H.M., Ortiz, A., Ortiz-Prado, E., Osman, W.M.S., Ostroff, S.M., Osuagwu, U.L., Otoiu, A., Otstavnov, N., Otstavnov, S.S., Ouyahia, A., Owolabi, M.O., Oyeyemi, I.T., Oyeyemi, O.T., Padukudru, M.P.A., Pacheco-Barrios, K., Padron-Monedero, A., Padubidri, J.R., Pal, P.K., Palicz, T., Pan, F., Pan, H.F., Pana, A., Panda, S.K., Panda-Jonas, S., Pandey, A., Pandi-Perumal, S.R., Pangaribuan, H.U., Pantazopoulos, I., Stoian, A.M.P., Papadopoulou, P., Parent, M.C., Parija, P.P., Parikh, R.R., Park, Seoyeon, Park, Sungchul, Parsons, N., Pashaei, A., Pasovic, M., Passera, R., Patil, S., Patoulias, D., Patthipati, V.S., Paudel, U., Pawar, S., Toroudi, H.P., Peden, A.E., Pedersini, P., Peng, M., Pensato, U., Pepito, V.C.F., Peprah, E.K., Peprah, P., Peres, M.F.P., Perianayagam, A., Perico, N., Perna, S., Pesudovs, K., Petcu, I.R., Petermann-Rocha, F.E., Pham, H.T., Philip, A.K., Phillips, M.R., Pickering, B.V., Pierannunzio, D., Pigeolet, M., Pigott, D.M., Piracha, Z.Z., Piradov, M.A., Pisoni, E., Piyasena, M.P., Plass, D., Plotnikov, E., Poddighe, D., Polkinghorne, K.R., Poluru, R., Pond, C.D., Popovic, D.S., Porru, F., Postma, M.J., Poudel, G.R., Pour-Rashidi, A., Pourshams, A., Pourtaheri, N., Prabhu, D., Prada, S.I., Pradhan, J., Pradhan, P.M.S., Prasad, M., Prates, E.J.S., Purnobasuki, H., Purohit, B.M., Puvvula, J., Qasim, N.H., Qattea, I., Qazi, A.S., Qian, G., Qiu, S., Rad, M.R., Radfar, A., Radhakrishnan, R.A., Radhakrishnan, V., Shahraki, H.R., Rafferty, Q., Rafiei, A., Raggi, A., Raghav, P.R., Raheem, N., Rahim, F., Rahim, M.J., Rahimifard, M., Rahimi-Movaghar, V., Rahman, M.O., Rahman, M.A., Rahmani, A.M., Rahmani, B., Rahmanian, M., Rahmanian, N., Rahmanian, V., Rahmati, M., Rahmawaty, S., Raimondo, D., Rajaa, S., Rajendran, V., Rajput, P., Ramadan, M.M.,

Ramasamy, S.K., Ramasubramani, P., Ramazanu, S., Ramteke, P.W., Rana, J., Rana, K., Ranabhat, C.L., Rane, A., Rani, U., Ranta, A., Rao, C.R., Rao, M., Rao, P.C., Rao, S.J., Rasella, D., Rashedi, S., Rashedi, V., Rashidi, M., Rashidi, M.M., Rasouli-Saravani, A., Ratan, Z.A., Babu, G.R., Rauniyar, S.K., Rautalin, I., Rawaf, D.L., Rawaf, S., Rawassizadeh, R., Razo, C., Reda, Z.F.F., Reddy, M.M.R.K., Redwan, E.M.M., Reifels, L., Reitsma, M.B., Remuzzi, G., Reshmi, B., Resnikoff, S., Restaino, S., Reyes, L.F., Rezaei, M., Rezaei, Nazila, Rezaei, Negar, Rezaeian, M., Rhee, T.G., Riaz, M.A., Ribeiro, A.L.P., Rickard, J., Robinson-Oden, H.E., Rodrigues, C.F., Rodrigues, M., Rodriguez, J.A.B., Roeber, L., Romadlon, D.S., Ronfani, L., Rosauer, J.J., Roshandel, G., Rostamian, M., Rotimi, K., Rout, H.S., Roy, B., Roy, N., Rubagotti, E., de Andrade Ruela, G., Rumisha, S.F., Runghien, T., Russo, M., Ruzzante, S.W., Chandan, S.N., Saad, A.M.A., Saber, K., Saber-Ayad, M.M., Sabour, S., Sacco, S., Sachdev, P.S., Sachdeva, R., Saddik, B., Saddler, A., Sadee, B.A., Sadeghi, E., Sadeghi, M., Majd, E.S., Saeb, M.R., Saeed, U., Safari, M., Safi, S., Safi, S.Z., Sagar, R., Sagoe, D., Sharif-Askari, F.S., Sharif-Askari, N.S., Sahebkar, A., Sahoo, S.S., Sahu, M., Saif, Z., Sajid, M.R., Sakshaug, J.W., Salam, N., Salamati, P., Salami, A.A., Salaroli, L.B., Salehi, L., Salehi, S., Salem, M.R., Salem, M.Z.Y., Salihu, D., Salimi, S., Salum, G.A., Kafil, H.S., Samadzadeh, S., Samodra, Y.L., Samuel, V.P., Samy, A.M., Sanabria, J., Sanjeev, R.K., Sanna, F., Santomauro, D.F., Santric-Milicevic, M.M., Sarasmita, M.A., Saraswathy, S.Y.I., Saravanan, A., Saravi, B., Sarikhani, Y., Sarmiento-Suárez, R., Sarode, G.S., Sarode, S.C., Sartorius, B., Sarvezad, A., Sathian, B., Sattin, D., Sawhney, M., Saya, G.K., Sayeed, A., Sayeed, M.A., Sayyah, M., Schinckus, C., Schmidt, M.I., Schuermans, A., Schumacher, A.E., Schutte, A.E., Schwarzinger, M., Schwebel, D.C., Schwendicke, F., Selvaraj, S., Semreen, M.H., Senthilkumaran, S., Serban, D., Serre, M.L., Sethi, Y., Shafie, M., Shah, H., Shah, N.S., Shah, P.A., Shah, S.M., Shahbandi, A., Shaheen, A.A., Shahid, S., Shahid, W., Shahsavari, H.R., Shahwan, M.J., Shaikh, M.A., Shaikh, S.Z., Shalash, A.S., Sham, S., Shamim, M.A., Shams-Beyranvand, M., Shamshirgaran, M.A., Shamsi, M.A., Shanawaz, M., Shankar, A., Sharfaei, S., Sharifan, A., Sharifi-Rad, J., Sharma, M., Sharma, U., Sharma, V., Shastry, R.P., Shavandi, A., Shehabeldine, A.M.E., Shehzadi, S., Sheikh, A., Shen, J., Shetty, A., Shetty, B.S.K., Shetty, P.H., Shiani, A., Shiferaw, D., Shigematsu, M., Shin, M.J., Shiri, R., Shittu, A., Shiue, I., Shivakumar, K.M., Shivarov, V., Shool, S., Shorofi, S.A., Shrestha, R., Shrestha, S., Shuja, K.H., Shuval, K., Si, Y., Siddig, E.E., Silva, D.A.S., Silva, L.M.L.R., Silva, S., Silva, T.P.R., Simpson, C.R., Singh, A., Singh, B.B., Singh, B., Singh, G., Singh, H., Singh, J.A., Singh, M., Singh, N.P., Singh, P., Singh, S., Sinto, R., Sivakumar, S., Siwal, S.S., Skhvitardze, N., Skou, S.T., Sleet, D.A., Sobia, F., Soboka, M., Socea, B., Solaimanian, S., Solanki, R., Solanki, S., Soliman, S.S.M., Somayaji, R., Song, Y., Sorensen, R.J.D., Soriano, J.B., Soyiri, I.N., Spartalis, M., Spearman, S., Spencer, C.N., Sreeramareddy, C.T., Stachteas, P., Stafford, L.K., Stanaway, J.D., Stanikzai, M.H., Stein, C., Stein, D.J., Steinbeis, F., Steiner, C., Steinke, S., Steiropoulos, P., Stockfelt, L., Stokes, M.A., Straif, K., Stranges, S., Subedi, N., Subramaniyan, V., Suleman, M., Abdulkader, R.S., Sundström, J., Sunkersing, D., Sunnerhagen, K.S., Suresh, V., Swain, C.K., Szarpak, L., Szeto, M.D., Damavandi, P.T., Tabarés-Seisdedos, R., Tabatabaei, S.M., Malazy, O.T., Tabatabaeizadeh, S.A., Tabatabai, S., Tabche, C., Tabish, M., Tadakamadla, S.K., Abkenar, Y.T., Soodejani, M.T., Taherkhani, A., Taiba, J., Takahashi, K., Talaat, I.M., Tamuzi, J.L., Tan, K.K., Tang, H., Tat, N.Y., Taveira, N., Tefera, Y.M., Tehrani-Banihashemi, A., Temesgen, W.A., Temsah, M.H., Teramoto, M., Terefa, D.R., Teye-Kwadjo, E., Thakur, R., Thangaraju, P., Thankappan, K.R., Thapar, R., Thayakaran, R., Thirunavukkarasu, S., Thomas, N., Thomas, N.K., Tian, J., Tichopad, A., Ticoalu, J.H.V., Tiruye, T.Y., Tobe-Gai, R., Tolani, M.A., Tolossa, T., Tonelli, M., Topor-Madry, R., Topouzis, F., Touvier, M., Tovani-Palone, M.R., Trabelsi, K., Tran, J.T., Tran, M.T.N., Tran, N.M., Trico, D., Trihandini, I., Troeger, C.E., Tromans, S.J., Truyen, T.T.T.T., Tsatsakis, A., Tsermpini, E.E., Tumurkhuu, M., Udoakang, A.J., Udoh, A., Ullah, A., Ullah, Saeed, Ullah, Sana, Umair, M., Umakanthan, S., Unim, B., Unnikrishnan, B., Upadhyay, E., Urso, D., Usman, J.S., Vaithinathan, A.G., Vakili, O., Valenti, M., Valizadeh, R., Van den Eynde, J., van Donkelaar, A.,

- Varga, O., Vart, P., Varthya, S.B., Vasankari, T.J., Vasic, M., Vaziri, S., Venketasubramanian, N., Verghese, N.A., Verma, M., Veroux, M., Verras, G.I., Vervoort, D., Villafañe, J.H., Villalobos-Daniel, V.E., Villani, L., Villanueva, G.I., Vinayak, M., Violante, F.S., Vlassov, V., Vo, B., Vollset, S.E., Volovat, S.R., Vos, T., Vujcic, I.S., Waheed, Y., Wang, C., Wang, F., Wang, S., Wang, Y., Wang, Y.P., Wanjau, M.N., Waqas, M., Ward, P., Waris, A., Wassie, E.G., Weerakoon, K.G., Weintraub, R.G., Weiss, D.J., Weiss, E.J., Weldetinsaa, H.L.L., Wells, K.M., Wen, Y.F., Wiangkhom, T., Wickramasinghe, N.D., Wilkerson, C., Willeit, P., Wilson, S., Wong, Y.J., Wongsin, U., Wozniak, S., Wu, C., Wu, D., Wu, F., Wu, Z., Xia, J., Xiao, H., Xu, S., Xu, X., Xu, Y.Y., Yadav, M.K., Yaghoubi, S., Yamagishi, K., Yang, L., Yano, Y., Yaribeygi, H., Yasufuku, Y., Ye, P., Yesodharan, R., Yesuf, S.A., Yezli, S., Yi, S., Yiğit, A., Yigzaw, Z.A., Yin, D., Yip, P., Yismaw, M.B., Yon, D.K., Yonemoto, N., You, Y., Younis, M.Z., Yousefi, Z., Yu, C., Yu, Y., Zadey, S., Zadnik, V., Zakham, F., Zaki, N., Zakzuk, J., Zamagni, G., Zaman, S.B., Zandieh, G.G.Z., Zanghi, A., Zar, H.J., Zare, I., Zarimeidani, F., Zastrozhin, M.S., Zeng, Y., Zhai, C., Zhang, A.L., Zhang, H., Zhang, L., Zhang, M., Zhang, Y., Zhang, Z., Zhang, Z.J., Zhao, H., Zhao, J.T., Zhao, X.J.G., Zhao, Yang, Zhao, Yong, Zhong, C., Zhou, Jingjing, Zhou, Juexiao, Zhou, S., Zhu, B., Zhu, L., Zhu, Z., Ziaeian, B., Ziafati, M., Zielińska, M., Zimsen, S.R.M., Zoghi, G., Zoller, T., Zumla, A., Zyoud, Saed H., Zyoud, Samer H., Murray, C.J.L., and Gakidou, E., 2024: Global burden and strength of evidence for 88 risk factors in 204 countries and 811 subnational locations, 1990–2021: a systematic analysis for the Global Burden of Disease Study 2021. *The Lancet*, 403, 2162–2203. doi:10.1016/S0140-6736(24)00933-4
- Breiman, L., Friedman, J.H., Olshen, R.A., and Stone, C.J., 1984: Classification and regression trees. Monterey, CA: Wadsworth and Brooks.
- Breiman, L., 2001: Random Forests. *Machine Learning*, 45, 5–32. doi:https://doi.org/10.1023/A:1010933404324
- Cadar, R.D., Boitor, M.R., and Dumitrescu, M., 2017: Effects of traffic volumes on accidents: The case study of Romania's national roads. *Geographia Technica*, 12, 20–29. doi:10.21163/GT
- Cerri, J., Stendardi, L., Bužan, E., and Pokorný, B., 2023: Accounting for cloud cover and circannual variation puts the effect of lunar phase on deer–vehicle collisions into perspective. *Journal of Applied Ecology*, 60, 1698–1707. doi:https://doi.org/10.1111/1365-2664.14432
- Chang, I., and Kim, S.W., 2012: Modelling for identifying accident-prone spots: Bayesian approach with a Poisson mixture model. *KSCIE Journal of Civil Engineering*, 16, 441–449. doi:10.1007/s12205-012-1513-9
- Charm, T., Wang, H., Zuniga-Garcia, N., Ahmed, M., and Kockelman, K.M., 2024: Predicting crash occurrence at intersections in Texas: an opportunity for machine learning. *Transportation Planning and Technology*, 47, 1184–1204. doi:https://doi.org/10.1080/03081060.2023.2177651
- Chen, C., and Xie, Y., 2016: Modeling the effects of AADT on predicting multiple-vehicle crashes at urban and suburban signalized intersections. *Accident Analysis and Prevention*, 91, 72–83. doi:10.1016/j.aap.2016.02.016
- Chen, T., and Guestrin, C., 2016: XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13-17-Aug, 785–794*. doi:10.1145/2939672.2939785
- Chinmayi, H.K., Flynn, K.C., Baath, G.S., Gowda, P., Northup, B., and Ashworth, A., 2025: Monitoring legume nutrition with machine learning : The impact of splits in training and testing data. *Applied Soft Computing*, 176, 113186. doi:10.1016/j.asoc.2025.113186
- Choi, J.G., Kong, C.W., Kim, G., and Lim, S., 2021: Car crash detection using ensemble deep learning and multimodal data from dashboard cameras. *Expert Systems with Applications*, 183, 115400. doi:10.1016/j.eswa.2021.115400
- Chong, M., Abraham, A., and Paprzycki, M., 2004: Traffic accident analysis using Decision Trees and Neural Networks. *arXiv*, 2, 4. doi:10.48550/arXiv.cs/0405050

- Choudhary, A., Garg, R.D., and Jain, S.S., 2024: Estimating impact of pavement surface condition and geometrics design on two-wheeler run-off road crashes on horizontal curves. *IATSS Research*, 48, 108–119. doi:10.1016/j.iatsr.2024.02.001
- Colino-Rabanal, V.J., Langen, T.A., Peris, S.J., and Lizana, M., 2018: Ungulate: vehicle collision rates are associated with the phase of the moon. *Biodiversity and Conservation*, 27, 681–694. doi:10.1007/s10531-017-1458-x
- Creech, T.G., Fairbank, E.R., Clevenger, A.P., Callahan, A.R., and Ament, R.J., 2019: Differences in Spatiotemporal Patterns of Vehicle Collisions with Wildlife and Livestock. *Environmental Management*, 64, 736–745. doi:10.1007/s00267-019-01221-3
- Čubranić-Dobrodolac, M., Lipovac, K., Čičević, S., and Antić, B., 2017: A model for traffic accidents prediction based on driver personality traits assessment. *Promet - Traffic and Transportation*, 29, 631–642. doi:10.7307/ptt.v29i6.2495
- Cui, H., Dong, J., Zhu, M., Li, X., and Wang, Q., 2022: Identifying accident black spots based on the accident spacing distribution. *Journal of Traffic and Transportation Engineering (English Edition)*, 9, 1017–1026. doi:10.1016/j.jtte.2021.02.006
- Das, S., Sun, X., and Sun, M., 2021: Rule-based safety prediction models for rural two-lane run-off-road crashes. *International Journal of Transportation Science and Technology*, 10, 235–244. doi:10.1016/j.ijst.2020.08.001
- Dávila-Cervantes, C.A., 2021: Road injury burden in Mexico 1990 to 2019: Secondary data analysis from the Global Burden of Disease Study. *Accident Analysis and Prevention*, 160, 106316. doi:10.1016/j.aap.2021.106316
- Debrabant, B., Halekoh, U., Bonat, W.H., Hansen, D.L., Hjelmberg, J., and Lauritsen, J., 2018: Identifying traffic accident black spots with Poisson-Tweedie models. *Accident Analysis and Prevention*, 111, 147–154. doi:10.1016/j.aap.2017.11.021
- Delisle, Z.J., Reeling, C.J., Caudell, J.N., McCallen, E.B., and Swihart, R.K., 2024: Targeted recreational hunting can reduce animal-vehicle collisions and generate substantial revenue for wildlife management agencies. *Science of the Total Environment*, 935, 173460. doi:10.1016/j.scitotenv.2024.173460
- Dereli, M.A., and Erdogan, S., 2017: A new model for determining the traffic accident black spots using GIS-aided spatial statistical methods. *Transportation Research Part A: Policy and Practice*, 103, 106–117. doi:10.1016/j.tra.2017.05.031
- Deretić, N., Stanimirović, D., Al Awadh, M., Vujanović, N., and Djukić, A., 2022: SARIMA Modelling Approach for Forecasting of Traffic Accidents. *Sustainability (Switzerland)*, 14, 4403. doi:10.3390/su14084403
- Dong, S., Khattak, A., Ullah, I., Zhou, J., and Hussain, A., 2022: Predicting and Analyzing Road Traffic Injury Severity Using Boosting-Based Ensemble Learning Models with SHAPley Additive exPlanations. *International Journal of Environmental Research and Public Health*, 19, 23. doi:10.3390/ijerph19052925
- Dutta, N., and Fontaine, M.D., 2019: Improving freeway segment crash prediction models by including disaggregate speed data from different sources. *Accident Analysis and Prevention*, 132, 105253. doi:10.1016/j.aap.2019.07.029
- Ebrahim Shaik, M., and Ahmed, S., 2022: An overview of the impact of COVID-19 on road traffic safety and travel behavior. *Transportation Engineering*, 9, 100119. doi:10.1016/j.treng.2022.100119
- Elghriany, A., Yi, P., Liu, P., and Yu, Q., 2016: Investigation of the effect of pavement roughness on crash rates for rigid pavement. *Journal of Transportation Safety and Security*, 8, 164–176. doi:10.1080/19439962.2015.1025458
- Elvik, R., Christensen, P., and Helene Amundsen, A., 2004: Speed and road accidents - an evaluation of the power model.

- Elvik, R., 2007: State-of-the-art approaches to road accidents black spot management and safety analysis of road networks.
- Elvik, R., 2008: A survey of operational definitions of hazardous road locations in some European countries. *Accident Analysis and Prevention*, 40, 1830–1835. doi:10.1016/j.aap.2008.08.001
- Elyasi, M.R., Saffarzade, M., and Boroujerdian, A.M., 2016: A novel dynamic segmentation model for identification and prioritization of black spots based on the pattern of potential for safety improvement. *Transportation Research Part A: Policy and Practice*, 91, 346–357. doi:10.1016/j.tra.2016.06.020
- Elyassami, S., Hamid, Y., and Habuza, T., 2021: Road Crashes Analysis and Prediction using Gradient Boosted and Random Forest Trees, In: 2020 6th IEEE Congress on Information Science and Technology (CiSt). 7. doi:10.1109/CiSt49399.2021.9357298
- European Commission, 2024: 20,400 lives lost in EU road crashes last year. URL [https://transport.ec.europa.eu/news-events/news/20400-lives-lost-eu-road-crashes-last-year-2024-10-10\\_en](https://transport.ec.europa.eu/news-events/news/20400-lives-lost-eu-road-crashes-last-year-2024-10-10_en) (accessed 4.17.25).
- Eurostat, 2025: EU-DEM. URL <https://ec.europa.eu/eurostat/web/gisco/geodata/digital-elevation-model/eu-dem>
- Faizi, N., 2025: The burden and trends of road injuries in Afghanistan (1990–2021): A joinpoint analysis of data from the global burden of diseases, 2021 study. *Preventive Medicine Reports*, 54, 103061. doi:10.1016/j.pmedr.2025.103061
- Fan, Z., Liu, C., Cai, D., and Yue, S., 2019: Research on black spot identification of safety in urban traffic accidents based on machine learning method. *Safety Science*, 118, 607–616. doi:10.1016/j.ssci.2019.05.039
- Ferrari, A.J., Santomauro, D.F., Aali, A., Abate, Y.H., Abbafati, C., Abastabar, H., Abd ElHafeez, S., Abdelmasseh, M., Abd-El salam, S., Abdollahi, A., Abdullahi, A., Abegaz, K.H., Zuñiga, R.A.A., Aboagye, R.G., Abolhassani, H., Abreu, L.G., Abualruz, H., Abu-Gharbieh, E., Abu-Rmeileh, N.M.E., Ackerman, I.N., Addo, I.Y., Addolorato, G., Adebijiyi, A.O., Adepoju, A.V., Adewuyi, H.O., Afyouni, S., Afzal, Saira, Afzal, Sina, Agodi, A., Ahmad, A., Ahmad, D., Ahmad, F., Ahmad, S., Ahmed, A., Ahmed, L.A., Ahmed, M.B., Ajami, M., Akinosoglou, K., Akkaif, M.A., Al Hasan, S.M., Alalalmeh, S.O., Al-Aly, Z., Albashtawy, M., Aldridge, R.W., Alemu, M.D., Alemu, Y.M., Alene, K.A., Ali Saeed, A., Al-Gheethi, Alharrasi, M., Alhassan, R.K., Ali, M.U., Ali, R., Ali, S.S.S., Alif, S.M., Aljunid, S.M., Al-Marwani, S., Almazan, J.U., Alomari, M.A., Al-Omari, B., Altaany, Z., Alvis-Guzman, N., Alvis-Zakzuk, N.J., Alwafi, H., Al-Wardat, M.S., Al-Worafi, Y.M., Aly, S., Alzoubi, K.H., Amare, A.T., Amegbor, P.M., Ameyaw, E.K., Amin, T.T., Amindarolzarbi, A., Amiri, S., Amugsi, D.A., Ancuceanu, R., Anderlini, D., Anderson, D.B., Andrade, P.P., Andrei, C.L., Ansari, H., Antony, C.M., Anwar, S., Anwar, S.L., Anwer, R., Anyanwu, P.E., Arab, J.P., Arabloo, J., Arafat, M., Araki, D.T., Aravkin, A.Y., Arkew, M., Armocida, B., Arndt, M.B., Arooj, M., Artamonov, A.A., Aruleba, R.T., Arumugam, A., Ashbaugh, C., Ashemo, M.Y., Ashraf, M., Asika, M.O., Askari, E., Astell-Burt, T., Athari, S.S., Atorkey, P., Atout, M.M. d.Wahbi, Atreya, A., Aujayeb, A., Ausloos, M., Avan, A., Awotidebe, A.W., Awuviry-Newton, K., Quintanilla, B.P.A., Ayuso-Mateos, J.L., Azadnajafabad, S., Azevedo, R.M.S., Babu, A.S., Badar, M., Badiye, A.D., Baghdadadi, S., Bagheri, N., Bah, S., Bai, R., Baker, J.L., Bakkannavar, S.M., Bako, A.T., Balakrishnan, S., Bam, K., Banik, P.C., Barchitta, M., Bardhan, M., Bardideh, E., Barker-Collo, S.L., Barqawi, H.J., Barrow, A., Barteit, S., Barua, L., Aliabadi, S.B., Basiru, A., Basu, Sanjay, Basu, Saurav, Bathini, P.P., Batra, K., Baune, B.T., Bayileyegn, N.S., Behnam, B., Behnoush, A.H., Beiranvand, M., Ramirez, D.F.B., Bell, M.L., Bello, O.O., Beloukas, A., Bensenor, I.M., Berezvai, Z., Bernabe, E., Bernstein, R.S., Bettencourt, P.J.G., Bhagavathula, A.S., Bhala, N., Bhandari, D., Bhargava, A., Bhaskar, S., Bhat, V., Bhatti, G.K., Bhatti, J.S., Bhatti, M.S., Bhatti, R., Bhutta, Z.A., Bikbov, B., Bishai, J.D., Bisignano, C., Bitra, V.R., Bjørge, T., Bodolica, V., Bodunrin, A.O., Bogale, E.K., Hashemi, M.B., Bonny, A., Basara, B.B., Borhany, H., Boxe, C., Brady,

O.J., Bragazzi, N.L., Braithwaite, D., Brant, L.C., Brauer, M., Breitner, S., Brenner, H., Brown, J., Brugha, T., Bulamu, N.B., Buonsenso, D., Burkart, K., Burns, R.A., Busse, R., Bustanji, Y., Butt, Z.A., Byun, J., dos Santos, F.L.C., Calina, D., Cámera, L.A., Campos-Nonato, I.R., Cao, C., Capodici, A., Carr, S., Carreras, G., Carugno, A., Carvalho, M., Castaldelli-Maia, J.M., Castañeda-Orjuela, C.A., Castelpietra, G., Catapano, A.L., Cattaruzza, M.S., Caye, A., Cegolon, L., Cembranel, F., Cenderadewi, M., Cerin, E., Chakraborty, P.A., Chan, J.S.K., Chan, R.N.C., Chandika, R.M., Chandrasekar, E.K., Charalampous, P., Chattu, V.K., Chatzimavridou-Grigoriadou, V., Chen, A.W., Chen, A.T., Chen, C.S., Chen, H., Chen, N.M., Cheng, E.T.W., Chimed-Ochir, O., Chimoriya, R., Ching, P.R., Cho, W.C.S., Choi, S., Chong, B., Chong, Y.Y., Choudhari, S.G., Chowdhury, R., Christensen, S.W.M.P., Chu, D.T., Chukwu, I.S., Chung, Eric, Chung, Eunice, Chutiyami, M., Claassens, M.M., Cogen, R.M., Columbus, A., Conde, J., Cortesi, P.A., Cousin, E., Criqui, M.H., Cruz-Martins, N., Dadras, O., Dai, S., Dai, X., Dai, Z., Dalaba, M.A., Damiani, G., Das, J.K., Das, S., Dashti, M., Dávila-Cervantes, C.A., Davletov, K., De Leo, D., Debele, A.T., Debopadhaya, S., DeCleene, N.K., Deeba, F., Degenhardt, L., Bo, C.D., Delgado-Enciso, I., Demetriades, A.K., Denova-Gutiérrez, E., Dervenis, N., Desai, H.D., Desai, R., Deuba, K., Dhama, K., Dharmaratne, S.D., Dhingra, S., da Silva, D.D., Diaz, D., Diaz, L.A., Diaz, M.J., Dima, A., Ding, D.D., Dirac, M.A., Do, T.H.P., do Prado, C.B., Dohare, S., Dominguez, R.M.V., Dong, W., Dongarwar, D., D’Oria, M., Dorsey, E.R., Doshmangir, L., Dowou, R.K., Driscoll, T.R., Dsouza, H.L., Dsouza, V., Dube, J., Dumith, S.C., Duncan, B.B., Duraes, A.R., Duraisamy, S., Durojaiye, O.C., Dzianach, P.A., Dziedzic, A.M., Eboreime, E., Ebrahimi, A., Edinur, H.A., Edvardsson, D., Eikemo, T.A., Eini, E., Ekholuenetale, M., Ekundayo, T.C., Sayed, I.E., Tantawi, M.E., Elbarazi, I., Elemam, N.M., ElGohary, G.M.T., Elhadi, M., Elmeligy, O.A.A., ELNahas, G., Elshaer, M., Elshohaby, I., Bain, L.E., Erkhembayar, R., Eshrati, B., Estep, K., Fabin, N., Fagbamigbe, A.F., Falzone, L., Fareed, M., e Sá Farinha, C.S., Faris, M.A.I.E.M., Faro, A., Farrokhi, P., Fatehizadeh, A., Fauk, N.K., Feigin, V.L., Feng, X., Fereshtehnejad, S.M., Feroze, A.H., Ferreira, N., Ferreira, P.H., Fischer, F., Flavel, J., Flood, D., Flor, L.S., Foigt, N.A., Folayan, M.O., Force, L.M., Fortuna, D., Foschi, M., Franklin, R.C., Freitas, A., Fukumoto, T., Furtado, J.M., Gaal, P.A., Gadanya, M.A., Gaidhane, A.M., Gaihre, S., Galali, Y., Ganbat, M., Gandhi, A.P., Ganesan, B., Ganie, M.A., Ganiyani, M.A., Gardner, W.M., Gebi, T.G., Gebregergis, M.W., Gebrehiwot, M., Gebremariam, T.B.B., Gebremeskel, T.G., Gela, Y.Y., Georgescu, S.R., Obsa, A.G., Gething, P.W., Getie, M., Ghadiri, K., Ghadirian, F., Ghailan, K.Y., Ghajar, A., Ghasemi, M.R., Dabaghi, G.G., Ghasemzadeh, A., Ghazy, R.M., Gholamrezanezhad, A., Ghorbani, M., Ghotbi, E., Gibson, R.M., Gill, T.K., Ginindza, T.G., Girmay, A., Glasbey, J.C., Göbölös, L., Godinho, M.A., Goharinezhad, S., Goldust, M., Golechha, M., Goleij, P., Gona, P.N., Gorini, G., Goulart, A.C., Grada, A., Grivna, M., Guan, S.Y., Guarducci, G., Gubari, M.I.M., Gudeta, M.D., Guha, A., Guicciardi, S., Gulati, S., Gulisashvili, D., Gunawardane, D.A., Guo, C., Gupta, A.K., Gupta, B., Gupta, I., Gupta, M., Gupta, R., Gupta, V.B., Gupta, Vijai Kumar, Gupta, Vivek Kumar, Gutiérrez, R.A., Habibzadeh, F., Habibzadeh, P., Haddadi, R., Hadi, N.R., Haep, N., Hafezi-Nejad, N., Hafiz, A., Hagins, H., Halboub, E.S., Halimi, A., Haller, S., Halwani, R., Hamilton, E.B., Hankey, G.J., Hannan, M.A., Haque, M.N., Harapan, H., Haro, J.M., Hartvigsen, J., Hasaballah, A.I., Hasan, I., Hasanian, M., Hasnain, M.S., Hassan, A., Haubold, J., Havmoeller, R.J., Hay, S.I., Hayat, K., Hebert, J.J., Hegazi, O.E., Heidari, G., Helfer, B., Hemmati, M., Hendrie, D., Henson, C.A., Hezam, K., Hiraike, Y., Hoan, N.Q., Holla, R., Hon, J., Hossain, M.M., Hosseinzadeh, H., Hosseinzadeh, M., Hostiuc, M., Hostiuc, S., Hsu, J.M., Huang, J., Hugo, F.N., Hushmandi, K., Hussain, J., Hussein, N.R., Huynh, C.K., Huynh, H.H., Hwang, B.F., Iannucci, V.C., Ihler, A.L., Ikiroma, A.I., Ikuta, K.S., Ilesanmi, O.S., Ilic, I.M., Ilic, M.D., Imam, M.T., Immurana, M., Irham, L.M., Islam, M.R., Islam, S.M.S., Islami, F., Ismail, F., Ismail, N.E., Isola, G., Iwagami, M., Iwu, C.C.D., Iyer, M., Jaafari, J., Jacobsen, K.H., Jadidi-Niaragh, F., Jafarinia, M., Jaggi, K., Jahankhani, K., Jahanmehr, N., Jahrami, H., Jain, A., Jain, N., Jairoun, A.A., Jaiswal, A., Jakovljevic, M., Jatau, A.I., Javadov, S., Javaheri, T., Jayapal,

S.K., Jayaram, S., Jee, S.H., Jeganathan, J., Jeyakumar, A., Jha, A.K., Jiang, H., Jin, Y., Jonas, J.B., Joo, T., Joseph, A., Joseph, N., Joshua, C.E., Jozwiak, J.J., Jürisson, M., Vaishali, K., Kaambwa, B., Kabir, A., Kabir, Z., Kadashetti, V., Kalani, R., Kalankesh, L.R., Kaliyadan, F., Kalra, S., Kamenov, K., Kamyari, N., Kanagasabai, T., Kandel, H., Kanmanthareddy, A.R., Kanmodi, K.K., Kantar, R.S., Karaye, I.M., Karim, A., Karimi, S.E., Karimi, Y., Kasraei, H., Kassel, M.B., Kauppila, J.H., Kawakami, N., Kayode, G.A., Kazemi, F., Kazemian, S., Keikavoosi-Arani, L., Keller, C., Kempen, J.H., Kerr, J.A., Keshtkar, K., Kesse-Guyot, E., Keykhaei, M., Khajuria, H., Khalaji, A., Khalid, A., Khalid, N., Khalilian, A., Khamesipour, F., Khan, A., Khan, I., Khan, M., Khan, M.A.B., Khanmohammadi, S., Khatab, K., Khatami, F., Khatatbeh, M.M., Khater, A.M., Kashani, H.R.K., Khidri, F.F., Khodadoust, E., Khormali, M., Khorrami, Z., Kifle, Z.D., Kim, M.S., Kimokoti, R.W., Kisa, A., Kisa, S., Knudsen, A.K.S., Kocarnik, J.M., Kochhar, S., Koh, H.Y., Kolahi, A.A., Kompani, F., Koren, G., Korzh, O., Kosen, S., Laxminarayana, S.L.K., Krishan, K., Krishna, V., Krishnamoorthy, V., Defo, B.K., Kuddus, M.A., Kuddus, M., Kuitunen, I., Kulkarni, V., Kumar, M., Kumar, N., Kumar, R., Kurmi, O.P., Kusuma, D., Kyu, H.H., Vecchia, C.L., Lacey, B., Ladan, M.A., Laflamme, L., Lafranconi, A., Lahariya, C., Lai, D.T.C., Lal, D.K., Laloo, R., Lallukka, T., Lám, J., Lan, Q., Lan, T., Landires, I., Lanfranchi, F., Langguth, B., Laplante-Lévesque, A., Larijani, B., Larsson, A.O., Lasrado, S., Lauriola, P., Le, H.H., Dao Le, L.K., Le, N.H.H., Le, T.D.T., Leasher, J.L., Ledda, C., Lee, M., Lee, P.H., Lee, Sang Woong, Lee, Seung Won, Lee, W.C., Lee, Y.H., LeGrand, K.E., Lenzi, J., Leong, E., Leung, J., Li, M.C., Li, W., Li, X., Li, Yichong, Li, Yongze, Lim, L.L., Lim, S.S., Lindstrom, M., Linn, S., Liu, G., Liu, R., Liu, S., Liu, W., Liu, Xiaofeng, Liu, Xuefeng, Llanaj, E., Lo, C.H., López-Bueno, R., Loreche, A.M., Lorenzovici, L., Lozano, R., Lubinda, J., Lucchetti, G., Lunevicius, R., Lusk, J.B., Lv, H., Ma, Z.F., Machairas, N., Madureira-Carvalho, Á.M., Magaña Gómez, J.A., Maghazachi, A.A., Maharjan, P., Mahasha, P.W., Maheri, M., Mahjoub, S., Mahmoud, M.A., Mahmoudi, E., Majeed, A., Makris, K.C., Rad, E.M., Malhotra, K., Malik, A.A., Malik, I., Malta, D.C., Manla, Y., Mansour, A., Mansouri, P., Mansournia, M.A., Mantilla Herrera, A.M., Mantovani, L.G., Manu, E., Marateb, H.R., Mardi, P., Martinez, G., Martinez-Piedra, R., Martini, D., Martins-Melo, F.R., Martorell, M., Marx, W., Maryam, S., Marzo, R.R., Mathangasinghe, Y., Mathieson, S., Mathioudakis, A.G., Mattumpuram, J., Maugeri, A., Mayeli, M., Mazidi, M., Mazzotti, A., McGrath, J.J., McKee, M., McKowen, A.L.W., McPhail, M.A., Mehrabani-Zeinabad, K., Nasab, E.M., Meto, T.M., Mendoza, W., Menezes, R.G., Mensah, G.A., Mentis, A.F.A., Meo, S.A., Meresa, H.A., Meretoja, A., Meretoja, T.J., Mersha, A.M., Mestrovic, T., Mettananda, K.C.D., Mettananda, S., Michalek, I.M., Miller, P.A., Miller, T.R., Mills, E.J., Minh, L.H.N., Mirijello, A., Mirrakhimov, E.M., Mirutse, M.K., Mirza-Aghazadeh-Attari, M., Mirzaei, M., Mirzaei, R., Misganaw, A., Mishra, A.K., Mitchell, P.B., Mittal, C., Moazen, B., Moberg, M.E., Mohamed, J., Mohamed, M.F.H., Mohamed, N.S., Mohammadi, E., Mohammadi, S., Mohammed, H., Mohammed, Salahuddin, Mohammed, Shafiu, Mohr, R.M., Mokdad, A.H., Molinaro, S., Momtazmanesh, S., Monasta, L., Mondello, S., Ghalibaf, A.A.M., Moradi, M., Moradi, Y., Moradi-Lakeh, M., Moraga, P., Morawska, L., Moreira, R.S., Morovatdar, N., Morrison, S.D., Morze, J., Mosapour, A., Mosser, J.F., Mossialos, E., Motappa, R., Mougín, V., Mouodi, S., Mrejen, M., Msherghi, A., Mubarik, S., Mueller, U.O., Mulita, F., Munjal, K., Murillo-Zamora, E., Murlimanju, B.V., Mustafa, G., Muthu, S., Muzaffar, M., Myung, W., Nagarajan, A.J., Naghavi, P., Naik, G.R., Nainu, F., Nair, S., Najmuldeen, H.H.R., Nangia, V., Naqvi, A.A., Narayana, A.I., Nargus, S., Nascimento, G.G., Nashwan, A.J., Nasrollahzadeh, Ali, Nasrollahzadeh, Amir, Natto, Z.S., Nayak, B.P., Nayak, V.C., Nduaguba, S.O., Negash, H., Negoj, I., Negoj, R.I., Nejadghaderi, S.A., Nesbit, O.D., Netsere, H.B., Ng, M., Nguefack-Tsague, G., Ngunjiri, J.W., Nguyen, D.H., Nguyen, H.Q., Niazi, R.K., Nikolouzakis, T.K., Nikoobar, A., Nikoomanesh, F., Nikpoor, A.R., Nnaji, C.A., Nnyanzi, L.A., Noman, E.A., Nomura, S., Norrving, B., Nri-Ezedi, C.A., Ntaios, G., Ntsekhe, M., Nurrika, D., Nzopotam, C.I., Nzopotam, O.J., Oancea, B., Odetokun, I.A., O'Donnell, M.J., Oguntade, A.S., Oguta, J.O., Okati-Aliabad, H., Okeke, S.R., Okeunle, A.P.,

Okonji, O.C., Olagunju, A.T., Olasupo, O.O., Olatubi, M.I., Oliveira, G.M.M., Olufadewa, I.I., Olusanya, B.O., Olusanya, J.O., Omar, H.A., Omer, G.L., Emmanuel Omonisi, A.E., Onie, S., Onwujekwe, O.E., Ordak, M., Orish, V.N., Ortega-Altamirano, D.V., Ortiz, A., Ortiz-Brizuela, E., Osman, W.M.S., Ostroff, S.M., Osuagwu, U.L., Otoiu, A., Otstavnov, N., Otstavnov, S.S., Ouyahia, A., Ouyang, G., Owolabi, M.O., Padukudru, M.P.A., Padron-Monedero, A., Padubidri, J.R., Palicz, T., Palladino, C., Pan, F., Pandi-Perumal, S.R., Pangaribuan, H.U., Panos, G.D., Panos, L.D., Stoian, A.M.P., Pardhan, S., Parikh, R.R., Pashaei, A., Pasovic, M., Passera, R., Patel, J., Patel, S.K., Patil, S., Patoulis, D., Patthipati, V.S., Pawar, S., Toroudi, H.P., Pease, S.A., Peden, A.E., Pedersini, P., Peng, M., Pensato, U., Pepito, V.C.F., Peprah, E.K., Peprah, P., Perdigão, J., Pereira, M.O., Perianayagam, A., Perico, N., Pesudovs, K., Petermann-Rocha, F.E., Petri, W.A., Pham, H.T., Philip, A.K., Phillips, M.R., Pigeolet, M., Pigott, D.M., Pillay, J.D., Piracha, Z.Z., Pirouzpanah, S., Plass, D., Plotnikov, E., Poddighe, D., Polinder, S., Postma, M.J., Pourtaheri, N., Prada, S.I., Pradhan, P.M.S., Prakash, V., Prasad, M., Prates, E.J.S., Priscilla, T., Pritchett, N., Puri, P., Puvvula, J., Qasim, N.H., Qattea, I., Qazi, A.S., Qian, G., Rad, M.R., Radhakrishnan, R.A., Radhakrishnan, V., Shahraki, H.R., Rafferty, Q., Raggi, A., Raghav, P.R., Rahim, M.J., Rahman, M.M., Ur Rahman, M.H., Rahman, M., Rahman, M.A., Rahmani, S., Rahmanian, M., Rahmawaty, S., Rajaa, S., Ramadan, M.M., Ramasamy, S.K., Ramasubramani, P., Ramazanu, S., Rana, K., Ranabhat, C.L., Rancic, N., Rane, A., Rao, C.R., Rao, K., Rao, M., Rao, S.J., Rashidi, M.M., Babu, G.R., Rauniyar, S.K., Rawaf, D.L., Rawaf, S., Razo, C., Reddy, M.M.R.K., Redwan, E.M.M., Reifels, L., Reiner, R.C., Remuzzi, G., Renzaho, A.M.N., Reshmi, B., Reyes, L.F., Rezaei, Nazila, Rezaei, Negar, Rezaei, Nima, Hachesu, P.R., Rezaeian, M., Rickard, J., Rodrigues, C.F., Rodriguez, J.A.B., Roeber, L., Ronfani, L., Roshandel, G., Rotimi, K., Rout, H.S., Roy, B., Roy, N., Roy, P., Rubagotti, E., Chandan, S.N., Saad, A.M.A., Saber-Ayad, M.M., Sabour, S., Sacco, S., Sachdev, P.S., Saddik, B., Saddler, A., Sadee, B.A., Sadeghi, E., Sadeghi, M., Saeb, M.R., Saeed, U., Safi, S.Z., Sagar, R., Sagoe, D., Saif, Z., Sajid, M.R., Sakshaug, J.W., Salam, N., Salami, A.A., Salaroli, L.B., Saleh, M.A., Salem, M.R., Salem, M.Z.Y., Sallam, M., Samadzadeh, S., Samargandy, S., Samodra, Y.L., Samy, A.M., Sanabria, J., Sanna, F., Santos, I.S., Santric-Milicevic, M.M., Sarasmita, M.A., Sarikhani, Y., Sarmiento-Suárez, R., Sarode, G.S., Sarode, S.C., Sarveazad, A., Sathian, B., Sathyanarayan, A., Satpathy, M., Sawhney, M., Scarmeas, N., Schaarschmidt, B.M., Schmidt, M.I., Schneider, I.J.C., Schumacher, A.E., Schwebel, D.C., Schwendicke, F., Sedighi, M., Senapati, S., Senthilkumaran, S., Sepanlou, S.G., Sethi, Y., Setoguchi, S., Seylani, A., Shadid, J., Shafie, M., Shah, H., Shah, N.S., Shah, P.A., Shahbandi, A., Shahid, S., Shahid, W., Shahwan, M.J., Shaikh, M.A., Shakeri, A., Shalash, A.S., Sham, S., Shamim, M.A., Shamshirgaran, M.A., Shamsi, M.A., Shanawaz, M., Shankar, A., Shannawaz, M., Sharath, M., Sharifan, A., Sharifi-Rad, J., Sharma, M., Sharma, R., Sharma, S., Sharma, U., Sharma, V., Shastry, R.P., Shavandi, A., Shayan, A.M., Shayan, M., Shehabeldine, A.M.E., Shetty, P.H., Shibuya, K., Shifa, J.E., Shiferaw, D., Shiferaw, W.S., Shigematsu, M., Shiri, R., Shitaye, N.A., Shittu, A., Shivakumar, K.M., Shivarov, V., Eshkiki, Z.S., Shool, S., Shrestha, S., Shuval, K., Sibhat, M.M., Siddig, E.E., Sigfusdottir, I.D., Silva, D.A.S., Silva, J.P., Silva, L.M.L.R., Silva, S., Simpson, C.R., Singal, A., Singh, A., Singh, B.B., Singh, H., Singh, J.A., Singh, M., Singh, P., Skou, S.T., Sleet, D.A., Slepak, E.L.N., Solanki, R., Soliman, S.S.M., Song, S., Song, Y., Sorensen, R.J.D., Soriano, J.B., Soyiri, I.N., Spartalis, M., Sreeramareddy, C.T., Stark, B.A., Starodubova, A.V., Stein, C., Stein, D.J., Steiner, C., Steiner, T.J., Steinmetz, J.D., Steiropoulos, P., Stockfelt, L., Stokes, M.A., Subedi, N.S., Subramaniyan, V., Suemoto, C.K., Suleman, M., Abdulkader, R.S., Sultana, A., Sundström, J., Swain, C.K., Szarpak, L., Damavandi, P.T., Tabarés-Seisdedos, R., Malazy, O.T., Tabatabaeizadeh, S.A., Tabatabai, S., Tabche, C., Tabish, M., Tadakamadla, S.K., Abkenar, Y.T., Soodejani, M.T., Taherkhani, A., Taiba, J., Talaat, I.M., Talukder, A., Tampa, M., Tamuzi, J.L., Tan, K.K., Tandukar, S., Tang, H., Olliaee, R.T., Tavangar, S.M., Teimoori, M., Temsah, M.H., Teramoto, M., Thangaraju, P., Thankappan, K.R., Thapar, R., Thayakaran, R., Thirunavukkarasu, S., Thomas, N., Thomas, N.K.,

- Thum, C.C.C., Tichopad, A., Vera Ticoalu, J.H., Tillawi, T., Tiruye, T.Y., Tobe-Gai, R., Tonelli, M., Topor-Madry, R., Torre, A.E., Touvier, M., Tovani-Palone, M.R., Tran, J.T., Tran, M.T.N., Tran, N.M., Tran, N.H., Trico, D., Tromans, S.J., Truyen, T.T.T.T., Tsatsakis, A., Tsegay, G.M., Tsermpini, E.E., Tumurkhuu, M., Tyrovolas, S., Udoh, A., Umair, M., Umakanthan, S., Umar, T.P., Undurraga, E.A., Unim, B., Unnikrishnan, B., Unsworth, C.A., Upadhyay, E., Urso, D., Usman, J.S., Vahabi, S.M., Vaithinathan, A.G., Van den Eynde, J., Varga, O., Varma, R.P., Vart, P., Vasankari, T.J., Vasic, M., Vaziri, S., Vellingiri, B., Venketasubramanian, N., Veroux, M., Verras, G.I., Vervoort, D., Villafañe, J.H., Violante, F.S., Vlassov, V., Vollset, S.E., Volovat, S.R., Vongpradith, A., Waheed, Y., Wang, C., Wang, F., Wang, N., Wang, S., Wang, Y., Wang, Y.P., Ward, P., Wassie, E.G., Weaver, M.R., Weerakoon, K.G., Weintraub, R.G., Weiss, D.J., Weldemariam, A.H., Wells, K.M., Wen, Y.F., Whisnant, J.L., Whiteford, H.A., Wiangkham, T., Wickramasinghe, D.P., Wickramasinghe, N.D., Wilandika, A., Wilkerson, C., Willeit, P., Wimo, A., Woldegebreal, D.H., Wolf, A.W., Wong, Y.J., Woolf, A.D., Wu, C., Wu, F., Wu, X., Wu, Z., Hanson, S.W., Xia, Y., Xiao, H., Xu, X., Xu, Y.Y., Yadav, L., Yadollahpour, A., Yaghoubi, S., Yamagishi, K., Yang, L., Yano, Y., Yao, Y., Yaribeygi, H., Yazdanpanah, M.H., Ye, P., Yehualashet, S.S., Yesuf, S.A., Yezli, S., Yiğit, A., Yiğit, V., Yigzaw, Z.A., Yismaw, Y., Yon, D.K., Yonemoto, N., Younis, M.Z., Yu, C., Yu, Y., Yusuf, H., Zahid, M.H., Zakhm, F., Zaki, L., Zaki, N., Zaman, B.A., Zamora, N., Zand, R., Zandieh, G.G.Z., Zar, H.J., Zarrintan, A., Zastrozhin, M.S., Zhang, H., Zhang, N., Zhang, Y., Zhao, H., Zhong, C., Zhong, P., Zhou, J., Zhu, Z., Ziafati, M., Zielińska, M., Zimsen, S.R.M., Zoladl, M., Zumla, A., Zyoud, S.H., Vos, T., and Murray, C.J.L., 2024: Global incidence, prevalence, years lived with disability (YLDs), disability-adjusted life-years (DALYs), and healthy life expectancy (HALE) for 371 diseases and injuries in 204 countries and territories and 811 subnational locations, 1990–2021: a systema. *The Lancet*, 403, 2133–2161. doi:10.1016/S0140-6736(24)00757-8
- Flahaut, B., Mouchart, M., Martin, E.S., and Thomas, I., 2003: The local spatial autocorrelation and the kernel method for identifying black zones: A comparative approach. *Accident Analysis and Prevention*, 35, 991–1004. doi:10.1016/S0001-4575(02)00107-0
- Freund, Y., and Schapire, R.E., 1997: A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 55, 119–139. doi:10.1006/jcss.1997.1504
- Friedman, J.H., 2001: Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29, 1189–1232. doi:10.1214/aos/1013203451
- Gatarić, D., Ruškić, N., Aleksić, B., Đurić, T., Pezo, L., Lončar, B., and Pezo, M., 2023: Predicting Road Traffic Accidents—Artificial Neural Network Approach. *Algorithms*, 16. doi:10.3390/a16050257
- GBD 2021 US Burden of Disease and Forecasting Collaborators, 2024: Burden of disease scenarios by state in the USA, 2022–50: a forecasting analysis for the Global Burden of Disease Study 2021. *The Lancet*, 404, 2341–2370.
- Geurts, K., Wets, G., Brijs, T., and Vanhoof, K., 2004: Identification and ranking of black spots: Sensitivity analysis. *Transportation Research Record*, 34–42. doi:10.3141/1897-05
- Geyik, B., and Kara, M., 2020: Severity Prediction with Machine Learning Methods, In: HORA 2020 - 2nd International Congress on Human-Computer Interaction, Optimization and Robotic Applications, Proceedings. 7. doi:10.1109/HORA49412.2020.9152601
- Ghadi, M., and Török, Á., 2017a: Comparison Different Black Spot Identification Methods. *Transportation Research Procedia*, 27, 1105–1112. doi:10.1016/j.trpro.2017.12.104
- Ghadi, M., and Török, Á., 2017b: Comparison Different Black Spot Identification Methods. *Transportation Research Procedia*, 27, 1105–1112. doi:10.1016/j.trpro.2017.12.104
- Ghadi, M., and Török, Á., 2019: A comparative analysis of black spot identification methods and road accident segmentation methods. *Accident Analysis and Prevention*, 128, 1–7. doi:10.1016/j.aap.2019.03.002

- Ghanim, M.S., Muley, D., and Kharbeche, M., 2022: ANN-Based traffic volume prediction models in response to COVID-19 imposed measures. *Sustainable Cities and Society*, 81, 103830. doi:10.1016/j.scs.2022.103830
- Glavić, D., Mladenović, M., Stevanovic, A., Tubić, V., Milenković, M., and Vidas, M., 2016: Contribution to Accident Prediction Models Development for Rural Two-Lane Roads in Serbia Mark as interesting Comment. *Promet-Traffic & Transportation*, 28, 415–424. doi:10.7307/ptt.v28i4.1908
- Goh, K., Currie, G., Sarvi, M., and Logan, D., 2014: Factors affecting the probability of bus drivers being at-fault in bus-involved accidents. *Accident Analysis and Prevention*, 66, 20–26. doi:10.1016/j.aap.2013.12.022
- Gonçalves, L.O., Alvares, D.J., Teixeira, F.Z., Schuck, G., Coelho, I.P., Esperandio, I.B., Anza, J., Beduschi, J., Bastazini, V.A.G., and Kindel, A., 2018: Reptile road-kills in Southern Brazil: Composition, hot moments and hotspots. *Science of the Total Environment*, 615, 1438–1445. doi:10.1016/j.scitotenv.2017.09.053
- González-Vélez, J.C., Torres-Madronero, M.C., Murillo-Escobar, J., and Jaramillo-Fayad, J.C., 2021: An artificial intelligent framework for prediction of wildlife vehicle collision hotspots based on geographic information systems and multispectral imagery. *Ecological Informatics*, 63. doi:10.1016/j.ecoinf.2021.101291
- Gopalakrishnan, S., 2012: A Public Health Perspective of Road Traffic Accidents. *Journal of Family Medicine and Primary Care*, 1, 144. doi:10.4103/2249-4863.104987
- Grdinić-Rakonjac, M., Antić, B., Pešić, D., and Pajković, V., 2021: Construction of Road Safety Composite Indicator Using Grey Relational Analysis. *Promet - Traffic&Transportation*, 33, 103–116. doi:10.7307/ptt.v33i1.3587
- Gregoriades, A., and Mouskos, K.C., 2013: Black spots identification through a Bayesian Networks quantification of accident risk index. *Transportation Research Part C: Emerging Technologies*, 28, 28–43. doi:10.1016/j.trc.2012.12.008
- Gu, D., Ou, S., and Liu, G., 2025: Global burden of road injuries and their attributable risk factors from 1990 to 2021: A systematic analysis for the global burden of disease study 2021. *Preventive Medicine Reports*, 53, 103051. doi:10.1016/j.pmedr.2025.103051
- Ha, H., and Shilling, F., 2018: Modelling potential wildlife-vehicle collisions (WVC) locations using environmental factors and human population density: A case-study from 3 state highways in Central California. *Ecological Informatics*, 43, 212–221. doi:10.1016/j.ecoinf.2017.10.005
- He, M., Meng, G., Wu, X., Han, X., and Fan, J., 2025: Road Traffic Accident Prediction Based on Multi-Source Data – A Systematic Review. *Promet - Traffic and Transportation*, 37, 499–522. doi:10.7307/ptt.v37i2.763
- Hou, X., 2023: Urban Traffic Accident Factor Analysis, Risk Prediction and Early Warning Based on Big Data Technology, In: ICCAI '23: Proceedings of the 2023 9th International Conference on Computing and Artificial Intelligence. 691–696. doi:https://doi.org/10.1145/3594315.3594392
- Hsu, C.K., 2024: Reconsidering Seasonality, Weather, and Road Safety in Non-temperate Areas: the Case of Kaohsiung, Taiwan. *Travel Behaviour and Society*, 34, 100710. doi:10.1016/j.tbs.2023.100710
- Hu, G., and Mamady, K., 2013: Alcohol-related road traffic injury and Global Burden of Disease 2010. *The Lancet*, 382, 1092–1093. doi:10.1016/S0140-6736(13)62014-0
- Huang, H., Chin, H.C., and Haque, M., 2009: Empirical evaluation of alternative approaches in identifying crash hot spots. *Transportation Research Record*, 32–41. doi:10.3141/2103-05
- Hussain, S.F., and Ashraf, M.M., 2023: A novel one-vs-rest consensus learning method for crash severity prediction. *Expert Systems with Applications*, 228, 120443. doi:10.1016/j.eswa.2023.120443
- Hyodo, S., and Hasegawa, K., 2021: Factors Affecting Analysis of the Severity of Accidents in Cold and Snowy Areas Using the Ordered Probit Model. *Asian Transport Studies*, 7, 100035. doi:10.1016/j.eastsj.2021.100035

- Ignatavičius, G., Ulevičius, A., Valskys, V., Galinskaitė, L., Busher, P.E., and Trakimas, G., 2021: Lunar phases and wildlife–vehicle collisions: Application of the lunar disk percentage method. *Animals*, 11, 1–10. doi:10.3390/ani11030908
- lio, K., and Lord, D., 2024: Does wildlife–vehicle collision frequency increase on full moon nights? A case-crossover analysis. *Transportation Research Part D: Transport and Environment*, 135, 104386. doi:https://doi.org/10.1016/j.trd.2024.104386
- Inada, H., Li, Q., Bachani, A., and Hyder, A.A., 2020: Forecasting global road traffic injury mortality for 2030. *Injury Prevention*, 26, 339–343. doi:10.1136/injuryprev-2019-043336
- Institute for Health Metrics and Evaluation (IHME), 2022: GBD Compare. URL <https://vizhub.healthdata.org/gbd-compare/> (accessed 5.4.25).
- Institute for Health Metrics and Evaluation (IHME), 2025: Global Burden of Disease (GBD). URL <https://www.healthdata.org/research-analysis/gbd> (accessed 5.7.25).
- Institute of Public Health of Serbia ‘Dr Milan Jovanović Batut’, 2009: Health of Population of Serbia: Analytical Study 1997–2007. doi:978-86-7358-048-7
- Jaafari, A., Zenner, E.K., Panahi, M., and Shahabi, H., 2019: Hybrid artificial intelligence models based on a neuro-fuzzy system and metaheuristic optimization algorithms for spatial prediction of wildfire probability. *Agricultural and Forest Meteorology*, 266–267, 198–207. doi:10.1016/j.agrformet.2018.12.015
- Jakubas, D., Ryś, M., and Lazarus, M., 2018: Factors affecting wildlife–vehicle collision on the expressway in a suburban area in northern Poland. *North-Western Journal of Zoology*, 14, 107–116.
- James, S.L., Lucchesi, L.R., Bisignano, C., Castle, C.D., Dingels, Z.V., Fox, J.T., Hamilton, E.B., Liu, Z., McCracken, D., Nixon, M.R., Sylte, D.O., Roberts, N.L.S., Adebayo, O.M., Aghamolaei, T., Alghnam, S.A., Aljunid, S.M., Almasi-Hashiani, A., Badawi, A., Behzadifar, Masoud, Behzadifar, Meysam, Bekru, E.T., Bennett, D.A., Chapman, J.R., Deribe, K., Adema, B.D., Fatahi, Y., Gelaw, B.K., Getahun, E.A., Hendrie, D., Henok, A., de Hidru, H., Hosseinzadeh, M., Hu, G., Jahani, M.A., Jakovljevic, M., Jalilian, F., Joseph, N., Karami, M., Kelbore, A.G., Khan, M.N., Kim, Y.J., Koul, P.A., La Vecchia, C., Linn, S., Majdzadeh, R., Mehndiratta, M.M., Memiah, P.T.N., Mengesha, M.M., Merie, H.E., Miller, T.R., Mirzaei-Alavijeh, M., Darwesh, A.M., Mezerji, N.M.G., Mohammadibakhsh, R., Moodley, Y., Moradi-Lakeh, M., Musa, K.I., Nascimento, B.R., Nikbakhsh, R., Nyasulu, P.S., Bali, A.O., Onwujekwe, O.E., Pati, S., Kalhori, R.P., Salehi, F., Shahabi, S., Shallo, S.A., Shamsizadeh, M., Sharafi, Z., Shukla, S.R., Sobhiyeh, M.R., Soriano, J.B., Sykes, B.L., Tabarés-Seisdedos, R., Tadesse, D.B.B., Tefera, Y.M., Tehrani-Banihashemi, A., Tlou, B., Topor-Madry, R., Wiangkham, T., Yaseri, M., Yaya, S., Yenesew, M.A., Younis, M.Z., Ziapour, A., Zodpey, S., Pigott, D.M., Reiner, R.C., Hay, S.I., Lopez, A.D., and Mokdad, A.H., 2020: Morbidity and mortality from road injuries: results from the Global Burden of Disease Study 2017. *Injury Prevention*, 26, 146–156. doi:10.1136/injuryprev-2019-043302
- Janković, S., Vlajinac, H., Bjegović, V., Marinković, J., Šipetić-Grujičić, S., Marković-Denić, L., Kocev, N., Šantrić-Milićević, M., Terzić-Šupić, Z., Maksimović, N., and Laaser, U., 2007: The burden of disease and injury in Serbia. *European Journal of Public Health*, 17, 80–85. doi:10.1093/eurpub/ckl072
- Jevremović, S., Tubić, V., Arnaut, F., Kolarski, A., and Srećković, V.A., 2025a: Moonlit Roads — Spatial and Temporal Patterns of Wildlife – Vehicle Collisions in Serbia. *Sustainability (Switzerland)*, 17, 1–17. doi:https://doi.org/10.3390/su17146443
- Jevremović, S., Arnaut, F., Kolarski, A., and Srećković, V.A., 2025b: ncPick: A Lightweight Toolkit for Extracting, Analyzing, and Visualizing ECMWF ERA5 NetCDF Data. *Data*, 10, 178. doi:10.3390/data10110178
- Jevremović, S., and Medarević, A., 2026: Burden of mobility: a 20-year review of road traffic injuries in Serbia (2002–2022). *Injury Prevention*, ip–2025–045923. doi:10.1136/ip-2025-045923

- Jevremović, S., and Šelmić, M., 2026: Prediction models for understanding traffic safety risk on rural roads in Serbia. *Computational Urban Science*, 6, 20. doi:10.1007/s43762-025-00215-8
- Karacasu, M., Ergül, B., and Yavuz, A.A., 2014: Estimating the causes of traffic accidents using logistic regression and discriminant analysis. *International Journal of Injury Control and Safety Promotion*, 21, 305–313. doi:10.1080/17457300.2013.815632
- Karamanlis, I., Nikiforiadis, A., Botzoris, G., Kokkalis, A., and Basbas, S., 2023: Towards Sustainable Transportation: The Role of Black Spot Analysis in Improving Road Safety. *Sustainability (Switzerland)*, 15, 1–12. doi:10.3390/su151914478
- Karami, P., and Tavakoli, S., 2022: Identification and analysis of areas prone to conflict with wild boar (*Sus scrofa*) in the vineyards of Malayer County, western Iran. *Ecological Modelling*, 471, 110039. doi:https://doi.org/10.1016/j.ecolmodel.2022.110039
- Kaunitz, L., 2022: Severity Prediction and Time-Series Analysis of Vehicle Accidents Using Statistical Models. 48 p.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T.Y., 2017: LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 2017-Decem, 3147–3155.
- Keken, Z., Sedoník, J., Kušta, T., Andrášik, R., and Bíl, M., 2019: Roadside vegetation influences clustering of ungulate vehicle collisions. *Transportation Research Part D: Transport and Environment*, 73, 381–390. doi:10.1016/j.trd.2019.07.013
- Khalaf, M.K., Rosen, H.E., Mitra, S., Neki, K., Mbugua, L.W., Hyder, A.A., and Paichadze, N., 2023: Estimating the Burden of Disability From Road Traffic Injuries in 5 Low- and Middle-Income Countries: Protocol for a Prospective Observational Study., *JMIR Research Protocols*. doi:10.2196/40985
- Khattak, A.J., Liu, J., Wali, B., Li, X., and Ng, M.W., 2016: Modeling traffic incident duration using quantile regression. *Transportation Research Record*, 2554, 139–148. doi:10.3141/2554-15
- Khatun, M.S., Hossain, M.A., Kabir, M.A., and Rahman, M.A., 2024: Identification and analysis of accident black spots using Geographic Information System (GIS): A study on Kushtia-Jhenaidah national highway (N704), Bangladesh. *Heliyon*, 10, e25952. doi:10.1016/j.heliyon.2024.e25952
- Koenker, R., and Bassett, G., 1978: Regression Quantiles. *Econometrica*, 46, 33–50. doi:https://doi.org/10.2307/1913643
- Kučas, A., and Balčiauskas, L., 2021: Impact of road fencing on ungulate–vehicle collisions and hotspot patterns. *Land*, 10, 16. doi:10.3390/land10040338
- Labib, F., Rifat, A.S., Hossain, M., Das, A.K., and Nawrine, F., 2019: 2019 7th International Conference on Smart Computing and Communications, ICSCC 2019, In: 2019 7th International Conference on Smart Computing and Communications, ICSCC 2019. IEEE, 1–5.
- Laflamme, E.M., Villamagna, A., and Kim, H.J., 2024: Predicting Severe Wildlife Vehicle Crashes (Wvcs) on New Hampshire Roads Using a Hybrid Generalized Additive Model. *Archives of Transport*, 69, 39–57. doi:10.61089/aot2024.15w9vq26
- Laliberté, J., and St-Laurent, M.H., 2020: In the wrong place at the wrong time: Moose and deer movement patterns influence wildlife-vehicle collision risk. *Accident Analysis and Prevention*, 135, 105365. doi:10.1016/j.aap.2019.105365
- Laverty, W.H., Kelly, I.W., Flynn, M., and Rotton, J., 1992: Geophysical variables and behavior: LXVIII. distal and lunar variables and traffic accidents in Saskatchewan 1984 to 1989. *Perceptual and Motor Skills*, 74, 483–488. doi:10.2466/pms.1992.74.2.483
- Li, G., Wu, Y., Bai, Y., and Zhang, W., 2023: ReMAHA–CatBoost: Addressing Imbalanced Data in Traffic Accident Prediction Tasks. *Applied Sciences (Switzerland)*, 13, 22. doi:10.3390/app132413123

- Li, J., Guo, F., Zhou, Y., Yang, W., and Ni, D., 2023: Predicting the severity of traffic accidents on mountain freeways with dynamic traffic and weather data. *Transportation Safety and Environment*, 5, 14. doi:10.1093/tse/tdad001
- Li, Y., Liu, C., and Ding, L., 2013: Impact of pavement conditions on crash severity. *Accident Analysis and Prevention*, 59, 399–406. doi:10.1016/j.aap.2013.06.028
- Lin, Y.C., 2016: The global distribution of the burden of road traffic injuries: Evolution and intra-distribution mobility. *Journal of Transport Geography*, 56, 77–91. doi:10.1016/j.jtrangeo.2016.09.002
- Lipovac, K., 2008: *Bezbednost saobraćaja [Road traffic safety]*. Public enterprise Official Gazette of the Republic of Serbia, 422 p.
- Llagostera, P., Comas, C., and López, N., 2022: Modeling road traffic safety based on point patterns of wildlife-vehicle collisions. *Science of the Total Environment*, 846, 157237. doi:10.1016/j.scitotenv.2022.157237
- Ma, Z., Mei, G., and Cuomo, S., 2021: An analytic framework using deep learning for prediction of traffic accident injury severity based on contributing factors. *Accident Analysis & Prevention*, 160, 106322. doi:https://doi.org/10.1016/j.aap.2021.106322
- Meteogram, 2024: Moon phase and times of moonrise and moonset.
- Mićić, S., Vujadinović, R., Amidžić, G., Damjanović, M., and Matović, B., 2022: Accident Frequency Prediction Model for Flat Rural Roads in Serbia. *Sustainability (Switzerland)*, 14, 7704. doi:10.3390/su14137704
- Milicevic, M.S., Bjegovic, V., Terzic, Z., Vukovic, D., Kocev, N., Marinkovic, J., and Vasic, V., 2009: Serbia within the European context: An analysis of premature mortality. *Population Health Metrics*, 7, 1–10. doi:10.1186/1478-7954-7-12
- Ministry of Interior of the Republic of Serbia, 2026: Data on traffic accidents by municipalities in Serbia. URL <https://data.gov.rs/sr/datasets/podatsi-o-saobratshajnim-nezgodama-po-politsijskim-upravama-i-opshtinama/> (accessed 2.2.26).
- Ministry of Internal Affairs of the Republic of Serbia, 2024: Data on traffic accidents by police departments and municipalities.
- Montella, A., 2010: A comparative analysis of hotspot identification methods. *Accident Analysis and Prevention*, 42, 571–581. doi:10.1016/j.aap.2009.09.025
- Mujalli, R.O., Al-Masaeid, H., and Alamoush, S., 2023: Modeling Traffic Crashes on Rural and Suburban Highways Using Ensemble Machine Learning Methods. *KSCE Journal of Civil Engineering*, 27, 814–825. doi:10.1007/s12205-022-0658-4
- Murat, Y.S., 2011: An entropy (Shannon) based traffic safety level determination approach for black spots. *Procedia - Social and Behavioral Sciences*, 20, 786–795. doi:10.1016/j.sbspro.2011.08.087
- Murphy, F. & M., 2021: Car Accidents & Animals: What You Need to Know. URL <https://www.murphyfalcon.com/news/car-accidents-animals-what-you-need-to-know/>
- Naghavi, M., Zamagni, G., Abbafati, C., Armocida, B., Agodi, A., Alicandro, G., Barbic, F., Barchitta, M., Bauckneht, M., Beghi, M., Bugiardini, R., Capodici, A., Carletti, C., Carreras, G., Carugno, A., Cattaruzza, M.S., Cenko, E., Cerrai, S., Cioffi, I., Conti, S., Cortesi, P.A., Damiani, G., Davis Weaver, N., Del Bo', C., Fabin, N., Falzone, L., Fasina, F.O., Ferrara, P., Ferraro, O.E., Fonzo, M., Fornari, C., Fortuna, D., Foschi, M., Gemmi, F., Glenn, S.D., Golinelli, D., Gorini, G., Guarducci, G., Guicciardi, S., Jakovljevic, M., La Vecchia, C., Lanfranchi, F., Lauriola, P., Ledda, C., Leonardi, M., Logroscino, G., Lugo, A., Mantovani, L.G., Martini, D., Minelli, G., Mirijello, A., Mokdad, A.H., Molinaro, S., Muccioli, L., Naldi, L., Nieddu, L., Palladino, R., Pani, P., Pasovic, M., Passera, R., Pedersini, P., Pensato, U., Perico, N., Pierannunzio, D., Raggi, A., Remuzzi, G., Romozzi, M., Russo, M., Sacco, S., Trico, D., Valenti, M., Violante, F.S., Månsson, J., Naghavi, M., Ronfani, L., and Monasta, L., 2025: State of health and inequalities among Italian regions from 2000 to 2021: a systematic analysis

- based on the Global Burden of Disease Study 2021. *The Lancet Public Health*, 10, e309–e320. doi:10.1016/S2468-2667(25)00045-3
- Nasri, M., and Aghabayk, K., 2021: Assessing risk factors associated with urban transit bus involved accident severity: a case study of a Middle East country. *International Journal of Crashworthiness*, 26, 413–423. doi:10.1080/13588265.2020.1718465
- OECD, 2008: Towards Zero - Ambitious Road Safety Targets and the Safe System Approach.
- Onozuka, D., Nishimura, K., and Hagihara, A., 2018: Full moon and traffic accident-related emergency ambulance transport: A nationwide case-crossover study. *Science of the Total Environment*, 644, 801–805. doi:10.1016/j.scitotenv.2018.07.053
- Pagany, R., 2020: Wildlife-vehicle collisions - Influencing factors, data collection and research methods. *Biological Conservation*, 251, 108758. doi:10.1016/j.biocon.2020.108758
- Pagany, R., 2022: A spatiotemporal risk prediction of wildlife-vehicle collisions using machine learning for dynamic warnings. *Journal of Safety Research*, 83, 269–281. doi:https://doi.org/10.1016/j.jsr.2022.09.001
- Pajković, V., Grdinić-Rakonjac, M., and Antić, B., 2022: Application of Fuzzy Linguistic Rating and Entropy-Based GRA to Address Uncertainty in Safety Performance Index Construction. *Journal of Advanced Transportation*, 2022, 1–13. doi:10.1155/2022/5025768
- Parra, C., Ponce, C., and Rodrigo, S.F., 2020: Evaluating the Performance of Explainable Machine Learning Models in Traffic Accidents Prediction in California. *Proceedings - International Conference of the Chilean Computer Science Society, SCCS, 2020-Novem*, 2–9. doi:10.1109/SCCS51225.2020.9281196
- Pavlou, D., Christodoulou, G., and Yannic, G., 2023: The impact of weather conditions and driver characteristics on road safety on rural roads. *Transportation Research Procedia*, 72, 4081–4088. doi:10.1016/j.trpro.2023.11.369
- Perez-Guerra, J., Gonzalez-Velez, J., Murillo-Escobar, J., and Jaramillo-Fayad, J.C., 2024: Prediction of areas with high risk of roadkill wildlife applying maximum entropy approach and environmental features: East Antioquia, Colombia. *Landscape and Ecological Engineering*, 20, 75–88. doi:10.1007/s11355-023-00581-7
- Pešić, D., Vujanić, M., Lipovac, K., and Antić, B., 2012: An integrated method of identifying and ranking danger spots for pedestrians on microlocation. *Transport*, 27, 49–59. doi:10.3846/16484142.2012.664826
- Pitarque, A., and Guillen, M., 2022: Interpolation of Quantile Regression to Estimate Driver's Risk of Traffic Accident Based on Excess Speed. *Risks*, 10, 13. doi:10.3390/RISKS10010019
- Pljakić, M., Jovanović, D., Matović, B., and Mičić, S., 2019: Macro-level accident modeling in Novi Sad: A spatial regression approach. *Accident Analysis and Prevention*, 132, 105259. doi:10.1016/j.aap.2019.105259
- Pljakić, M., Stanojević, P., and Jovanović, D., 2021: Prediction of accident using time series methods and models in Serbia, In: VIII International Symposium 'New Horizons 2021'. 11.
- Pljakić, M., Dragan, J., Predrag, S., Svetlana, B., and Boško, M., 2022: Forecasting Fatalities and Injuries of Accidents Using the Arima, In: 17. International Conference 'Road Safety in Local Community'. 10. doi:https://www.researchgate.net/publication/361746255 FORECASTING
- Pljakić, M., Lindov, O., Petrović, A., Stanojević, P., and Arsić, N., 2024: Application of machine learning for prediction of road accidents based on indicators: A random forest approach, In: International Conference on Advances in Traffic and Communication Technologies (ATCT). 70–76.
- Polinder, S., Haagsma, J., Bos, N., Panneman, M., Wolt, K.K., Brugmans, M., Weijermars, W., and Van Beeck, E., 2015: Burden of road traffic injuries: Disability-adjusted life years in relation to hospitalization and the maximum abbreviated injury scale. *Accident Analysis and Prevention*, 80, 193–200. doi:10.1016/j.aap.2015.04.013

- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A.V., and Gulin, A., 2018: Catboost: Unbiased boosting with categorical features. *Advances in Neural Information Processing Systems, 2018-Decem*, 6638–6648.
- Public enterprise Roads of Serbia, 2025: The total length of state road networks of Serbia.
- Quinlan, J.R., 1986: Induction of decision trees. *Machine Learning, 1*, 81–106.  
doi:<https://doi.org/10.1007/BF00116251>
- Rahman, M.A., Sun, X., Das, S., and Khanal, S., 2021: Exploring the influential factors of roadway departure crashes on rural two-lane highways with logit model and association rules mining. *International Journal of Transportation Science and Technology, 10*, 167–183.  
doi:10.1016/j.ijtst.2020.12.003
- Rajčević, S., Štrbac, M., Kukić, D., Marković, M., Ivanović, I., Petrović, R., and Radić, I., 2024: The epidemiology of road traffic injuries in the republic of Serbia: a study based on hospital data, 2015-2019. *Frontiers in Public Health, 12*, 1–12. doi:10.3389/fpubh.2024.1468505
- Ranković, V., Đonić, A., and Geroski, T., 2024: Road Traffic Accidents Prediction Using Machine Learning Methods, In: 10th International Congress - Motor Vehicles & Motors 2024. 409–415. doi:978-86-6335-120-2
- Redelmeier, D.A., and Shafir, E., 2017: The full moon and motorcycle related mortality: population based double control study. *BMJ (Clinical research ed.)*, 359, j5367. doi:10.1136/bmj.j5367
- Republički zavod za statistiku, 2025: Statistički kalendar Republike Srbije. doi:1820-6794
- Rithesh, R.N., Vignesh, R., and Anala, M.R., 2018: Autonomous traffic signal control using decision tree. *International Journal of Electrical and Computer Engineering, 8*, 1522–1529.  
doi:10.11591/ijece.v8i3.pp1522-1529
- Road Traffic Safety Agency, 2023: Statistical report on traffic safety in Serbia. doi:2334-9395
- Road Traffic Safety Agency, 2025: Integrated traffic accident database. URL <https://bazaabs.abs.gov.rs/absPortal/> (accessed 2.4.25).
- Rosenblatt, F., 1958: The Perceptron: a Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review, 65*, 386–408.
- Rúa, E., Arias, P., Saavedra, Á., and Martínez-Sánchez, J., 2024: Combination of macroscopic and microscopic crash prediction models with multiple modeling approaches: A highway case study. *Expert Systems with Applications, 258*, 125158. doi:10.1016/j.eswa.2024.125158
- Sadeghi, A., Ayati, E., and Neghab, M.P., 2013: Identification and prioritization of hazardous road locations by segmentation and data envelopment analysis approach. *Promet - Traffic and Transportation, 25*, 127–136. doi:10.7307/ptt.v25i2.1295
- Sadeghian Tafti, M.R., Ostovar, A., Saeedi Moghaddam, S., Shobeiri, P., Ehrampoush, M.H., Salmani, I., Khajeaminian, M.R., Fallahzadeh, H., and Dehghani Tafti, A., 2023: Burden of road traffic injuries in Iran: A national and subnational perspective, 1990-2019. *Injury Prevention, 29*, 101–110.  
doi:10.1136/ip-2022-044677
- Šarić, Ž., Zovak, G., Kunštek, A., and Kučinić, T., 2016: Metodologija za identifikaciju opasnih mjesta u cestovnoj prometnoj mreži. Zagreb.
- Shaffiee Haghshenas, Sina, Guido, G., Shaffiee Haghshenas, Sami, and Astarita, V., 2025: Predicting the level of road crash severity: A comparative analysis of logit model and machine learning models. *Transportation Engineering, 20*, 100323. doi:10.1016/j.treng.2025.100323
- Shaik, M.E., Islam, M.M., and Hossain, Q.S., 2021: A review on neural network techniques for the prediction of road traffic accident severity. *Asian Transport Studies, 7*, 100040.  
doi:10.1016/j.eastsj.2021.100040
- Silva, P.B., Andrade, M., and Ferreira, S., 2021: Influence of segment length on the fitness of multivariate crash prediction models applied to a Brazilian multilane highway. *IATSS Research, 45*, 493–502.  
doi:10.1016/j.iatssr.2021.05.001

- Šipetic, S., Bjegovic-Mikanovic, V., Vlajinac, H., Marinkovic, J., Jankovic, S., Terzic, Z., Atanackovic-Markovic, Z., Šaulic, A., and Laaser, U., 2013: The burden of disease preventable by risk factor reduction in Serbia. *Vojnosanitetski Pregled*, 70, 445–451. doi:10.2298/VSP111024049S
- Sitar, J., 1994: K semilunárnímu zvýšení dopravní nehodovosti [The effect of the semilunar phase on an increase in traffic accidents]. *Cas Lek Cesk*, 133, 596–598.
- Skroch, M., and Hilaire, T., 2021: Wildlife-Vehicle Collisions Are a Big and Costly Problem and Congress Can Help. *The Pew Charitable Trusts*,. URL <https://www.pewtrusts.org/en/research-and-analysis/articles/2021/05/10/wildlife-vehicle-collisions-are-a-big-and-costly-problem-and-congress-can-help>
- Službeni glasnik RS br. 30/18, 2018: Traffic safety strategy of the Republic of Serbia for the period 2023 to 2030.
- Statistical Office of the Republic of Serbia, 2014: Administrative division of the territory of Serbia. URL <https://www.stat.gov.rs/oblasti/registar-prostornih-jedinica-i-gis/administrativno-teritorijalna-podela-i-nstj-nivoi-1-2-3/upravni-okruzi/> (accessed 5.12.25).
- Statistical Office of the Republic of Serbia, 2024a: Administrative categorization of the Republic of Serbia. URL <https://www.stat.gov.rs/en-US/oblasti/registar-prostornih-jedinica-i-gis/administrativno-teritorijalna-podela-i-nstj-nivoi-1-2-3/nstj-3>
- Statistical Office of the Republic of Serbia, 2024b: Municipalities and regions in the Republic of Serbia. doi:2217-7981
- Steiner, W., Scholl, E.M., Leisch, F., and Hacklander, K., 2021: Temporal patterns of roe deer traffic accidents: Effects of season, daytime and lunar phase. *PLoS ONE*, 16, 16–19. doi:10.1371/journal.pone.0249082
- Stepanović, N., Tubić, V., Milenković, M., and Halaj, K., 2025: The impact of basic traffic flow characteristics on traffic accident occurrence on 2-lane rural roads in Serbia. *Transport*, 40, 64–73. doi:10.3846/transport.2025.20543
- Su, H., Wang, Y., Yang, Y., Tao, S., and Kong, Y., 2023: An Analytical Framework of the Factors Affecting Wildlife–Vehicle Collisions and Barriers to Movement. *Sustainability (Switzerland)*, 15. doi:10.3390/su151411181
- Sullivan, J.M., 2011: Trends and characteristics of animal-vehicle collisions in the United States. *Journal of Safety Research*, 42, 9–16. doi:10.1016/j.jsr.2010.11.002
- Sun, Jie, and Sun, Jian, 2015: A dynamic Bayesian network model for real-time crash prediction using traffic speed conditions data. *Transportation Research Part C: Emerging Technologies*, 54, 176–186. doi:10.1016/j.trc.2015.03.006
- Tamim Kashifi, M., and Ahmad, I., 2022: Efficient Histogram-Based Gradient Boosting Approach for Accident Severity Prediction With Multisource Data. *Transportation Research Record*, 2676, 236–258. doi:<https://doi.org/10.1177/03611981221074370>
- Taylor, S.J., and Letham, B., 2018: Forecasting at Scale. *American Statistician*, 72, 37–45. doi:10.1080/00031305.2017.1380080
- Téllez, A., García, C.H., and Corral-Verdugo, V., 2015: Effect size, confidence intervals and statistical power in psychological research. *Psychology in Russia: State of the Art*, 8, 27–47. doi:10.11621/pir.2015.0303
- Templer, D.I., Veleber, D.M., and Brooner, R.K., 1982: Geophysical Variables and Behavior: VI. Lunar Phase and Accident Injuries: A Difference between Night and Day. *Perceptual and Motor Skills*, 55, 280–282. doi:<https://doi.org/10.2466/pms.1982.55.1.280>
- Teodorović, D., and Šelmić, M., 2019: *Računarska inteligencija u saobraćaju*. Univerzitet u Beogradu - Saobraćajni fakultet, 210 p.
- Transport Community, 2023: Road safety statistics - number of fatalities in the Western Balkans in 2023.

- Venkat, A., Vijey, G.K., and Susan Thomas, I., 2020: Machine Learning Based Analysis for Road Accident Prediction. *International Journal of Emerging Technology and Innovative Engineering*, 6, 2394–6598.
- Vlajinac, H., Marinkovic, J., Kocev, N., Sipetic, S., Bjegovic, V., Jankovic, S., Stanisavljevic, D., Markovic-Denic, L., and Maksimovic, J., 2008: Years of life lost due to premature death in Serbia (excluding Kosovo and Metohia). *Public Health*, 122, 277–284. doi:10.1016/j.puhe.2007.06.010
- Vorko-Jović, A., and Jović, F., 1992: Macro model prediction of elderly people's injury and death in road traffic accidents in Croatia. *Accident Analysis and Prevention*, 24, 667–672. doi:10.1016/0001-4575(92)90019-F
- Vrkljan, J., Hozjan, D., Barić, D., Ugarković, D., and Krapinec, K., 2017: Temporal Patterns of Vehicle Collisions with Roe Deer and Wild Boar in the Dinaric Area. *Croatian Journal of Forest Engineering*, 41, 13. doi:https://doi.org/10.5552/crojfe.2020.789
- Vutukuri, K., 2025: Model Evaluation Basics: Train, Validation, and Test Splits. *Medium*, URL <https://medium.com/@kiranvutukuri/19-model-evaluation-basics-train-validation-and-test-splits-ed5bb26b088d> (accessed 11.25.25).
- Wang, K., and Li, Z., 2025: Global, regional, and national burdens of road injuries from 1990 to 2021: Findings from the 2021 Global Burden of Disease Study. *Injury*, 56, 112221. doi:https://doi.org/10.1016/j.injury.2025.112221
- Wang, L., Abdel-Aty, M., Shi, Q., and Park, J., 2015: Real-time crash prediction for expressway weaving segments. *Transportation Research Part C: Emerging Technologies*, 61, 1–10. doi:10.1016/j.trc.2015.10.008
- Washington, S., Haque, M.M., Oh, J., and Lee, D., 2014: Applying quantile regression for modeling equivalent property damage only crashes to identify accident blackspots. *Accident Analysis and Prevention*, 66, 136–146. doi:10.1016/j.aap.2014.01.007
- Wen, T., Yuan, C., Chai, P., Zhang, B., Zhai, T., Li, Y., and Liu, Y., 2024: The burden of injury among elderly individuals in China from 1990 to 2019: An analysis of data from the global burden of disease study 2019. *Preventive Medicine Reports*, 44, 102815. doi:10.1016/j.pmedr.2024.102815
- Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L., François, R., Grolemund, G., Hayes, A., Henry, L., Hester, J., Kuhn, M., Pedersen, T., Miller, E., Bache, S., Müller, K., Ooms, J., Robinson, D., Seidel, D., Spinu, V., Takahashi, K., Vaughan, D., Wilke, C., Woo, K., and Yutani, H., 2019: Welcome to the Tidyverse. *Journal of Open Source Software*, 4, 1686. doi:10.21105/joss.01686
- Wilkins, D.C., Kockelman, K.M., and Jiang, N., 2019: Animal-vehicle collisions in Texas: How to protect travelers and animals on roadways. *Accident Analysis and Prevention*, 131, 157–170. doi:10.1016/j.aap.2019.05.030
- World Health Organization (WHO) and United Nations Regional Commission, 2021: Global plan - Decade of action for road safety 2021 - 2030.
- World Health Organization (WHO), 2023a: Global status report on road safety 2023.
- World Health Organization (WHO), 2023b: Road traffic injuries. URL <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>
- Xiao, D., Ding, H., Sze, N.N., and Zheng, N., 2024: Investigating built environment and traffic flow impact on crash frequency in urban road networks. *Accident Analysis and Prevention*, 201, 107561. doi:10.1016/j.aap.2024.107561
- Xie, Y., Zhao, K., and Huynh, N., 2012: Analysis of driver injury severity in rural single-vehicle crashes. *Accident Analysis and Prevention*, 47, 36–44. doi:10.1016/j.aap.2011.12.012
- Xu, X., and Duan, L., 2017: Xu, X., Duan, L., 2017. Predicting Crash Rate Using Logistic Quantile Regression with Bounded Outcomes. *IEEE Access* 5 January , 27036–27042. doi:10.1109/ACCESS.2017.2773612 Predicting Crash Rate Using Logistic Quantile Regression with Bounded Outcomes. *IEEE Access*, 5, 27036–27042. doi:10.1109/ACCESS.2017.2773612

- Xu, Y., and Goodacre, R., 2018: On Splitting Training and Validation Set : A Comparative Study of Cross - Validation , Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning. *Journal of Analysis and Testing*, 2, 249–262. doi:10.1007/s41664-018-0068-2
- Yasin, Y.J., Grivna, M., and Abu-Zidan, F.M., 2021: Global impact of COVID-19 pandemic on road traffic collisions. *World Journal of Emergency Surgery*, 16, 1–14. doi:10.1186/s13017-021-00395-8
- Yocum, R.L., and Gayah, V.V., 2022: County-level crash prediction models for Pennsylvania accounting for income characteristics. *Transportation Research Interdisciplinary Perspectives*, 13, 100562. doi:10.1016/j.trip.2022.100562
- Yousefzadeh-Chabok, S., Ranjbar-Taklimie, F., Malekpouri, R., and Razzaghi, A., 2016: A Time Series Model for Assessing the Trend and Forecasting the Road Traffic Accident Mortality. *Archives of Trauma Research*, 5. doi:10.5812/atr.36570
- Zadeh, L., 1965: Fuzzy Sets. *Information and Control*, 8, 338–353. doi:https://doi.org/10.1016/S0019-9958(65)90241-X
- Zeng, L., Hu, Z., and Sayed, T., 2022: Traffic Conflict Prediction at Signal Cycle Level Using Bayesian Optimized Machine Learning Approaches. *Transportation Research Record*, 2677, 183–195. doi:https://doi.org/10.1177/03611981221128812
- Zhang, W., Liu, T., and Yi, J., 2022: Exploring the Spatiotemporal Characteristics and Causes of Rear-End Collisions on Urban Roadways. *Sustainability (Switzerland)*, 14, 23. doi:10.3390/su141811761
- Zhang, Z., Nie, Q., Liu, J., Hainen, A., Islam, N., and Yang, C., 2022: Machine learning based real-time prediction of freeway crash risk using crowdsourced probe vehicle data. *Journal of Intelligent Transportation Systems*, 28, 84–102. doi:https://doi.org/10.1080/15472450.2022.2106564
- Zhu, L., Lu, L., Zhang, W., Zhao, Y., and Song, M., 2019: Analysis of accident severity for curved roadways based on Bayesian networks. *Sustainability (Switzerland)*, 11, 17. doi:10.3390/su11082223
- Zou, X., Sun, L., Lan, T., Fan, C., Liu, S., Zhao, H., and Qiu, J., 2024: The effects of weather factors on road traffic casualties: Analysis on provincial panel data of China from 2006 to 2021. *Heliyon*, 10, e36788. doi:10.1016/j.heliyon.2024.e36788
- Zovak, G., Šarić, Ž., and Brčić, D., 2014: Analysis of Road Black Spots Identification Method in Republic of Croatia. *Proceedings of 9 th International Conference Road Safety in Local Communities*, 9–11.
- Агенција за безбедност саобраћаја, 2022: Статистички извештај о стању безбедности саобраћаја у Републици Србији у 2022. години.
- Кузовић, Љ., 1984: *Вредновање у оптимизирању планова и пројеката путева*. Савез инжењера и техничара саобраћаја и веза Југославије, Београд.
- Кузовић, Љ., 1994: *Вредновање у управљању развојем и експлоатацијом путне мреже*. Универзитет у Београду, Саобраћајни факултет, Београд.
- Кузовић, Љ., 1997: *Утврђивање потреба и оправданости издвајања транзитног саобраћаја са градских артерија изградњом обилазница*. Универзитет у Београду, Саобраћајни факултет, Београд.
- Миленковић, М., 2014: Модели предвиђања саобраћајних незгода за ванградске двотрачне путеве. Универзитет у Београду, Саобраћајни факултет, Београд, 128 р.
- Миленковић, М., Главић, Д., Коцић, А., and Петковић, М., 2017: Утицај путних и саобраћајних карактеристика на догађање саобраћајних незгода на аутопутевима 1, 5–12.
- Степановић, Н., 2023: Модел за анализу брзине слободног тока у функцији класе двотрачног пута. Универзитет у Београду, Саобраћајни факултет, Београд, 113 р.

## Биографија аутора

Сретен Јевремовић је рођен 18. маја 1994. године у Блацу, где је завршио основну и средњу школу – гимназију, општи смер. Као носилац Вукове дипломе, 2013. године уписује Основне академске студије на Саобраћајном факултету, Универзитета у Београду, на смеру Безбедност друмског саобраћаја. Основне академске студије је завршио 2017. године, са просеком 9,81, и тиме стекао звање *дипломирани инжењер саобраћаја*. У септембру 2017. године уписао је Мастер академске студије на Саобраћајном факултету, Универзитета у Београду, на студијском програму Саобраћајно инжењерство. Мастер академске студије завршио је 2019. године, са просеком 9,88, и тиме стекао звање *мастер инжењер саобраћаја*. Током основних студија био је добитник стипендије Доситеја, Министарства омладине и спорта Републике Србије.

Сретен Јевремовић је 2019. године уписао Докторске академске студије на Саобраћајном факултету, Универзитета у Београду, на студијском програму Саобраћај, где је све испите положио са просеком 9,87 и тиме испунио све обавезе предвиђене планом и програмом Докторских академских студија.

Од 2018. године Сретен Јевремовић је радио на Саобраћајном факултету као сарадник у настави, а од 2019. као асистент на Катедри за саобраћајно пројектовање у друмском саобраћају, где се бавио наставним и научним радом у области саобраћајног пројектовања путне и уличне мреже. Од 2025. године Сретен ради на Институту за Физику у Београду, у лабораторији за астрофизику и физику јоносфере. У свом досадашњем раду Сретен је био аутор односно коаутор 76 научно-стручних радова, од којих је 18 са SCI листе у категорији M20. Осим тога, Сретен је био члан комисије за одбрану и оцену 65 завршних радова на Саобраћајном факултету Универзитета у Београду. Као члан ауторског тима учествовао је у изради 13 студија из области саобраћајног пројектовања, организације саобраћајног система, управљања и планирања одрживог саобраћаја. Рецензент је у неколико истакнутих међународних часописа: *Engineering Applications of Artificial Intelligence*, *BMC Public Health*, *Discover Cities*, *Sustainability*.

Од 2018. до 2025. године Сретен је био члан организационог одбора саветовања са међународним учешћем ТЕСИ (Технике саобраћајног инжењерства), а од 2025. године члан је организационог одбора Међународне научне конференције „Building bridges between climate science and society through a transdisciplinary network”. Од 2026. године члан је стручног удружења „Центар за планирање саобраћаја – ЦЕПЛАС”. 2021. године Сретен је стекао звање *Тренера приступачности у саобраћају*, добијено у оквиру пројекта „Европске политике приступачности у Републици Србији”.

## Изјава о ауторству

Име и презиме аутора  
Број индекса

**Сретен Г. Јевремовић**  
**ДС19Д001**

### Изјављујем

Да је докторска дисертације под насловом

**МОДЕЛОВАЊЕ, ПРЕДИКЦИЈА И УПРАВЉАЊЕ РИЗИКОМ У ДРУМСКОМ  
САОБРАЋАЈУ ПРИМЕНОМ МЕТОДА РАЧУНАРСКЕ ИНТЕЛИГЕНЦИЈЕ**

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени;
- да нисам кршио ауторска права и користио интелектуалну својину других лица.

У Београду,

**Потпис аутора**

---

**Изјава о истоветности штампане и електронске верзије докторског рада**

Име и презиме аутора	<b>Сретен Јевремовић</b>
Број индекса	<b>ДС19Д001</b>
Студијски програм	<b>Саобраћај</b>
Наслов рада	<b>МОДЕЛОВАЊЕ, ПРЕДИКЦИЈА И УПРАВЉАЊЕ РИЗИКОМ У ДРУМСКОМ САОБРАЋАЈУ ПРИМЕНОМ МЕТОДА РАЧУНАРСКЕ ИНТЕЛИГЕНЦИЈЕ</b>
Ментор	<b>Др Милица Шелмић, редовни професор Универзитет у Београду – Саобраћајни факултет</b>

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао ради похрањивања у **Дигиталном репозиторијуму Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

У Београду,

---

**Потпис аутора**

---

## Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић” да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

### **МОДЕЛОВАЊЕ, ПРЕДИКЦИЈА И УПРАВЉАЊЕ РИЗИКОМ У ДРУМСКОМ САОБРАЋАЈУ ПРИМЕНОМ МЕТОДА РАЧУНАРСКЕ ИНТЕЛИГЕНЦИЈЕ**

Која је моје ауторско дело.

Дисертацију са свим прилозима предао сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио.

1. Ауторство (CC BY)

2. Ауторство – некомерцијално (CC BY-NC)

3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)

4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)

5. Ауторство – без прерада (CC BY-ND)

6. Ауторство – делити под истим условима (CC BY-SA)

(Молимо да заокружите само једну од шест понуђених лиценци.  
Кратак опис лиценци је саставни део ове изјаве).

У Београду,

Потпис аутора

1. **Ауторство.** Дозвољаваће умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.
2. **Ауторство – некомерцијално.** Дозвољаваће умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.
3. **Ауторство – некомерцијално – без прерада.** Дозвољаваће умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.
4. **Ауторство – некомерцијално – делити под истим условима.** Дозвољаваће умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.
5. **Ауторство – без прерада.** Дозвољаваће умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.
6. **Ауторство – делити под истим условима.** Дозвољаваће умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода