Model procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika

Hasani, Habib

Doctoral thesis / Disertacija

2023

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:598599

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







Sveučilište u Zagrebu

Fakultet prometnih znanosti

Habib Hasani

MODEL PROCJENE RIZIKA OD PROMETNIH NESREĆA MLADIH VOZAČA IDENTIFIKACIJOM SUBJEKTIVNIH I OBJEKTIVNIH ČIMBENIKA

DOKTORSKI RAD

Zagreb, 2023.



Sveučilište u Zagrebu

Fakultet prometnih znanosti

Habib Hasani

MODEL PROCJENE RIZIKA OD PROMETNIH NESREĆA MLADIH VOZAČA IDENTIFIKACIJOM SUBJEKTIVNIH I OBJEKTIVNIH ČIMBENIKA

DOKTORSKI RAD

Mentor: prof. dr. sc. Grgo Luburić

Zagreb, 2023.



University of Zagreb

Faculty of Transport and Traffic Sciences

Habib Hasani

A MODEL FOR ASSESSING THE RISK OF TRAFFIC ACCIDENTS AMONG YOUNG DRIVERS BY IDENTIFYING SUBJECTIVE AND OBJECTIVE FACTORS

DOCTORAL DISSERTATION

Supervisor: Grgo Luburić, Ph. D.

Zagreb, 2023

Informacija o mentoru

Prof. dr. sc. Grgo Luburić rođen je 1. siječnja 1958. u Malom Ograđeniku pokraj Čitluka u Bosni i Hercegovini. Srednju Strojarsku tehničku školu u Klaićevoj završava 1977. nakon čega upisuje Prirodoslovno-matematički fakultet gdje diplomira 1982. i stječe zvanje profesora.

Nakon diplomiranja neko vrijeme radi u dvjema zagrebačkim osnovnim školama, a od 1984. radi u sustavu srednjeg školstva kao srednjoškolski profesor. Godine 1988. završava Fakultet prometnih znanosti nakon čega predaje stručne predmete, a od 1996. izabran je za ravnatelja srednjoškolske ustanove. Nakon poslijediplomskog studija na Fakultetu prometnih znanosti koji upisuje 1977., završava i poslijediplomski doktorski studij 2005. obranom doktorske disertacije na temu „Model rješavanja problema parkiranja u gradskim središtima“ i stječe akademski stupanj doktora znanosti u području tehničkih znanosti, polju tehnologije prometa i transport.

Tijekom rada u sustavu srednjeg školstva, a nakon izbora u naslovno zvanje docenta na Fakultetu prometnih znanosti radi kao vanjski suradnik. Tijekom 2008. radi u gradskoj upravi Grada Zagreba kao pomoćnik pročelnika. Od 2014. radi na Fakultetu prometnih znanosti kao izvanredni te kasnije redoviti profesor. Nositelj je i predavač 7 kolegija na preddiplomskom i diplomskom studiju FPZ-a i na sveučilišnom odjelu Promet i logistika Sveučilišta u Mostaru na kojem je voditelj ispred FPZ-a. Također, sudjeluje kao jedan od nositelja na dvama kolegijima na poslijediplomskom doktorskom studiju FPZ-a te je nositelj jednog kolegija na poslijediplomskom doktorskom studiju pri Fakultetu građevinarstva, arhitekture i geodezije Sveučilišta u Mostaru.

Uz objavljene znanstvene i stručne radove u časopisima, zbornicima i na međunarodnim i domaćim znanstvenim konferencijama aktivno je uključen u izradu znanstvenih projekata kao voditelj i suradnik.

Obnašao je dužnost tajnika sekcije za promet Znanstvenog vijeća za promet Hrvatske akademije znanosti u umjetnosti za razdoblje 2018. – 2022., kao i članstva u upravnim i nadzornim odborima i vijećima u nekoliko ustanova i udruga.

PODACI I INFORMACIJE O DOKTORANDU

1. Ime i prezime: **Habib Hasani, dipl. ing. prom.**
2. Datum i mjesto rođenja: **24. siječnja 1963., Kosovska Mitrovica, Kosovo**
3. Naziv završenog fakulteta i godina diplomiranja: **Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2005.**

INFORMACIJE O DOKTORSKOME RADU

1. Naziv doktorskog studija: **Tehnološki sustavi u prometu i transportu**
2. Naslov doktorskog rada: **Model procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika**
3. Fakultet na kojemu je doktorski rad branjen: **Fakultet prometnih znanosti Sveučilišta u Zagrebu**

POVJERENSTVA, OCJENA I OBRANA DOKTORSKOGA RADA

1. Datum prijave teme doktorskog rada: **10. svibnja 2018.**
2. Prvi mentor: **prof. dr. sc. Grgo Luburić**
3. Povjerenstvo za ocjenu i obranu doktorskoga rada:
    1. izv. prof. dr. sc. Željko Šarić, predsjednik
    2. prof. dr. sc. Grgo Luburić, mentor, član
    3. prof. dr. sc. Marinko Jurčević, član
    4. prof. dr. sc. Eduard Missoni, član
    5. doc. dr. sc. Petrana Brečić, vanjski član (Klinika za psihijatriju "Vrapče")
4. Datum obrane doktorskoga rada: **13. siječnja 2023.**
5. Lektor: **Silvija Jurić, prof. hrvatskog jezika i književnosti**

SAŽETAK

Uzimajući u obzir vozače svih dobnih skupina, mladi vozači najviše su izloženi riziku sudjelovanja u prometnim nesrećama. U okviru ovoga doktorskog rada izrađen je model za procjenu rizika od prometne nesreće identifikacijom subjektivnih i objektivnih čimbenika koji će doprinijeti većoj sigurnosti mladih vozača u prometu tijekom procesa osposobljavanja te u stvarnim prometnim situacijama. Istraživanje je provedeno u fazama, uključujući i proces terenskog istraživanja radi prikupljanja potrebnih podataka o stavovima mladih vozača te kandidata u autoškolama vezano uz nastanak prometnih nesreća. Osim toga, u sklopu istraživanja prikupljeni su podaci o prometnim nesrećama iz dostupnih baza podataka relevantnih za sigurnost cestovnog prometa. Obradom i analizom prikupljanih podataka definirana su obilježja cesta koja su uzrokovala najveći broj prometnih nesreća u kojima su sudjelovali mladi vozači te subjektivni i objektivni čimbenici koji su u najvećem postotku imali utjecaj na nastanak prometnih nesreća. U završnoj fazi istraživanja definirana je korelacija između objektivnih i subjektivnih čimbenika koji povećavaju rizik nastanka prometnih nesreća te učestalosti pojedinih čimbenika sigurnosti (čovjek, vozilo, cesta i okolina) u prometnim nesrećama u kojima su sudjelovali mladi vozači. Na temelju provedenog istraživanja i dobivenih rezultata predložen je model procjene rizika od prometnih nesreća mladih vozača. Uspostavom modela za procjenu rizika od prometne nesreće i njegovom implementacijom u program osposobljavanja vozača za samostalno sudjelovanje u cestovnom prometu, povećat će se sigurnost mladih vozača u prometu.

Ključne riječi: sigurnost prometa, prometne nesreće, mladi vozači, procjena rizika.

SUMMARY

Taking into account drivers of all age groups, young drivers are the most endangered participator involved in road accidents. Within this PhD, models are developed to assess the risk of road accidents identifying subjective and objective factors that are contribute to increasing the safety of young drivers in traffic during the training process and in real traffic situations when the drivers themselves assess the risk and make decisions. The research is done in five phases including also the field research to collect needed data on young drivers and driving school candidates attitude about the causation of traffic accidents. Furthermore, data have been collected on road accidents, databases available important for road traffic safety. The processing and analysis of the collected data have determined the characteristics

of the roads that have caused the largest number of road accidents involving young drivers, as well as the objective and cause-and-effect objectives that have greatly affected (occur) road accidents. At the end of the research phase, a link was established between objectives and entities that increase the risk of traffic accidents and the frequency of certain safety factors (man, vehicle and road) in road traffic accident involving drivers of young. Based on the research conducted and the results obtained, a model of risk assessment of the cause of road accidents with young drivers will be proposed. By using a traffic accident assessment model and implementing it in the driver training program for self-participation in road traffic, the safety of young drivers will be increased.

Key words: traffic safety, traffic accidents, young drivers, risk assessment

SADRŽAJ

SAŽETAK VI
SUMMARY VI
1. UVOD 1
1.1 CILJ I HIPOTEZE ISTRAŽIVANJA 1
1.2 OČEKIVANI ZNANSTVENI DOPRINOS PREDLOŽENOG ISTRAŽIVANJA 2
1.3 PREGLED DOSADAŠNJIH ISTRAŽIVANJA 2
1.4 METODE ISTRAŽIVANJA 4
1.5 STRUKTURA DOKTORSKOG RADA 5
2. ČIMBENICI SIGURNOSTI PROMETA 8
2.1 UZROCI PROMETNIH NESREĆA 9
2.1.1 Subjektivni čimbenici 9
2.1.2 Objektivni čimbenici 10
2.2 RIZIK U CESTOVNOM PROMETU 12
2.2.1 Međuovisnost uzroka i pogrešaka u nastanku prometnih nesreća 15
2.2.2 Sigurnost mladih vozača 15
2.2.3 Razina stupnja rizika u prometu 19
2.2.4 Sigurnosne granice vozača 20
2.2.5 Percepcija i procjena rizika 20
2.2.6 Ponašanja vozača u prometu 21
3. MODELI OSPOSOBLJAVANJA VOZAČA I VOZAČKE DOZVOLE 28
3.1 FORMALNO OSPOSOBLJAVANJE VOZAČA 29
3.2 NEFORMALNO OSPOSOBLJAVANJE VOZAČA 29
3.3 GDE MATRICE 30
3.4 NAPREDNO OSPOSOBLJAVANJE VOZAČA 31

3.5 POVEZANOST KOMPONENTI OSPOSOBLJAVANJA 31
3.6 MODELI VOZAČKE DOZVOLE 34
3.6.1 Klasični model 34
3.6.2 Dvofazni model 34
3.6.3 Višefazni model (VMD) 35
3.7 POSTOJEĆI PROBLEMI SUSTAVA OSPOSOBLJAVANJA VOZAČA I VOZAČKOG ISPITA U REPUBLICI KOSOVU 36
3.8 EDUKACIJA INSTRUKTORA VOŽNJE 39
3.9 KOMPARATIVNA ANALIZA OSPOSOBLJAVANJA KANDIDATA ZA VOZAČA I VOZAČKOG ISPITA 39
4. ANALIZA PROMETNIH NESREĆA U KOJIMA SUDJELUJU MLADI VOZAČI 44
4.1 AKTUALNI PROBLEM SIGURNOSTI MLADIH VOZAČA 44
4.2 KOMPARATIVNA ANALIZA PROMETNIH NESREĆA REPUBLIKE KOSOVA SA ZEMLJAMA REGIJE 45
4.2.1 Analiza prometnih nesreća s nastradalim osobama 2014. – 2018. godine 45
4.2.2 Analiza poginulih osoba u prometnim nesrećama u periodu 2014. – 2018. godine 47
4.2.3 Prometne nesreće prema kategorijama cesta 49
4.2.4 Broj poginulih vozača prema elementima ceste 53
4.2.5 Uzroci prometnih nesreća 54
4.2.6 Broj poginulih vozača prema uvjetima i stanju površine kolnika 56
4.2.7 Broj poginulih vozača prema satu u danu 57
4.2.8 Broj poginulih vozača prema danu u tjednu 58
4.2.9 Broj poginulih vozača prema tipu nesreće 59
5. ISTRAŽIVANJE STAVOVA MLADIH VOZAČA KOD NASTANKA PROMETNIH NESREĆA 60
5.1 ISTRAŽIVANJE I PROCEDURE ANKETIRANJA 60

5.2 OPĆE ZNAČAJKE I STAVOVI MLADIH VOZAČA 61
5.2.1 Spol ispitanika 61
5.2.2 Dob ispitanika 62
5.2.3 Vrijeme posjedovanja vozačke dozvole (vozački staž) 62
5.2.4 Sudjelovanje u prometnim nesrećama 63
5.2.5 Uzroci prometnih nesreća u kojima su sudjelovali mladi vozači 63
5.2.6 Prebivalište ispitanika 64
5.2.7 Socioekonomski status ispitanika 65
5.2.8 Frekvencije korištenja automobila 65
5.2.9 Poštovanje ograničenja brzine vožnje 66
5.2.10 Samoprocjena brzine vožnje 67
5.2.11 Procjena tehnike vožnje 67
5.2.12 Procjena promjene vlastitog ponašanje u prometu 68
5.3 PROCES OSPOSOBLJAVANJA KANDIDATA ZA VOZAČA 68
5.3.1 Stupanj edukacije predavača u autoškoli 70
5.3.2 Predznanja o ponašanju u cestovnom prometu 70
5.3.3 Satovi nastave za procjenu rizika nastanka prometnih nesreća 71
5.3.4 Videozapis (snimanje) za identifikaciju rizika u prometu 72
5.3.5 Organiziranje praktične nastave u skupinama s kandidatima za vozače 73
5.3.6 Prosječni broj kilometara iz praktične nastave 73
5.3.7 Dopunski teorijski satovi 74
5.3.8 Dopunski satovi vožnje 75
6. REZULTATI ANALIZE STATISTIČKE ZNAČAJNOSTI PROMETNIH NESREĆA 76
6.1 REZULATI ANALIZE HI-KVADRAT TESTA STATISTIČKE ZNAČAJNOSTI PROMETNIH NESREĆA 77
6.1.1 Rezultati analiza prometnih nesreća prema spolu 77

6.1.2 Rezultati analiza prometnih nesreća prema uzrastu 78
6.1.3 Rezultati analiza prometnih nesreća prema frekvenciji vožnje 79
6.1.4 Rezultati analiza prometnih nesreća s obzirom na ograničenje brzine 80
6.1.5 Rezultati analiza prometnih nesreća s obzirom na procjene tehnika vožnje 81
6.1.6 Rezultati analiza prometnih nesreća s obzirom na psihosocijalne komponente 82
6.1.7 Rezultati analiza prometnih nesreća s obzirom na promjene ponašanja u prometu 83
6.1.8 Rezultati analize prometnih nesreća s obzirom na elemente osposobljavanja 84
6.1.9 Rezultati analize prometnih nesreća i radnji s vozilom 89
6.1.10 Rezultati analize prometnih nesreća i vožnje 92
6.2 KORELACIJSKA ANALIZA 101
6.2.1 Korelacija: prometne nesreće – osnovne značajke mladih vozača 102
6.2.2 Korelacija: prometne nesreće – ostale promjenjive varijable 103
6.2.3 Korelacija: prometne nesreće − vožnja u različitim uvjetima i okolnostima u prometu 104
6.2.4 Korelacija prometne nesreće – tehnika vožnje – radnje vozilom na cesti 106
6.2.5 Korelacija: prometne nesreće – signalizacija – vozilo 108
7. IZRADA MODELA PROCJENE RIZIKA OD PROMETNIH NESREĆA MLADIH VOZAČA 121
8. EVALUACIJA MODELA PROCJENE RIZIKA OD PROMETNIH NESREĆA MLADIH VOZAČA 126
8.1 PRIJEDLOG MJERA ZA POBOLJŠANJE SIGURNOSTI PROMETA 128
8.2 DISKUSIJA 131
9. ZAKLJUČAK 136
LITERATURA 138
POPIS SLIKA 149
POPIS DIJAGRAMA 150
POPIS TABLICA 152

POPIS PRILOGA 157
ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA 162

1. UVOD

Sigurnost cestovnog prometa moguće je definirati kao stanje društveno prihvatljivog rizika u kojem se čovjek kao sudionik u prometu na cestama sa svojim osobnim značajkama, psihofizičkim osobinama, obrazovanjem i kulturom, uz vozilo i cestu, navodi kao uzročnik prometnih nesreća.

Sustav upravljanja sigurnošću predstavlja interdisciplinarni i sveobuhvatni model smanjenja rizika od nastanka prometnih nesreća. Metode procjene rizika od prometnih nesreća zahtijevaju dugotrajna mjerenja i analizu različitih čimbenika radi određivanja ispravnih koraka usmjerenih k povećanju sigurnosti u prometu.

U temeljne čimbenike sigurnosti cestovnog prometa ubrajaju se čovjek, vozilo i cesta zato što imaju najveći utjecaj na promet kao sustav i vožnju kao osnovnu aktivnost čovjeka unutar prometnog sustava. Vožnja je funkcionalna prostorno-vremenska aktivnost vozača, koja uključuje određeni rizik. Na osnovi percepcije rizika, a u skladu s motivacijskim čimbenicima (namjere, ciljevi, potrebe) i sposobnostima, donosi se odluka u određenoj prometnoj situaciji. Prepoznavanje opasnosti, opasnih mjesta i situacija u prometu te vožnja koja je prilagođena prometnoj situaciji, temelj su sigurnog ponašanja vozača u prometu.

Subjektivni i objektivni čimbenici mogu dovesti do rizika od prometnih nesreća. Identifikacija i procjena rizika i opasnosti stvarne prometne situacije na cesti od strane vozača ubrajaju se u subjektivne čimbenike (smanjenje brzine, povećan oprez u vožnji i sl.). Objektivni čimbenici su neželjeni događaji na promatranoj cesti ili njezinom segmentu na koje vozač ne može utjecati (odron kamenja, divljač na cesti, magla i sl.)

Rizik za pojavu nesreća povećava se ako identifikacija čimbenika (subjektivnih ili objektivnih) uključuje mlade vozače. Pri procjeni potencijalno rizičnih situacija u prometu mladi vozači uočavaju manji broj opasnosti na cesti, uočavaju ih sporije te podcjenjuju razinu njihove opasnosti. Za procjenu rizika i njegovo smanjenje, identifikacija subjektivnih i objektivnih čimbenika te njihova analiza jest primarna aktivnost.

1.1 CILJ I HIPOTEZE ISTRAŽIVANJA

Osnovni cilj istraživanja jest predložiti model procjene rizika koji će se temeljiti na pojedinim identificiranim subjektivnim i objektivnim čimbenicima koji utječu na rizik od prometnih nesreća. Primjena modela očekuje se tijekom procesa osposobljavanja.

Hipoteze istraživanja:

- Moguće je identificirati subjektivne i objektivne čimbenike koji utječu na procjenu rizika od prometnih nesreća mladih vozača.
- Moguće je odrediti korelaciju između temeljnih čimbenika sigurnosti u koje se ubrajaju čovjek, vozilo i cesta te identificiranih subjektivnih i objektivnih čimbenika kod mladih vozača.

1.2 OČEKIVANI ZNANSTVENI DOPRINOS PREDLOŽENOG ISTRAŽIVANJA

Metodologija identifikacije subjektivnih i objektivnih čimbenika kojima se može unaprijediti sigurnost cestovnog prometa.

Korelacija subjektivnih i objektivnih čimbenika s temeljnim čimbenicima sigurnosti.

Razvoj modela procjene rizika od prometnih nesreća identifikacijom subjektivnih i objektivnih čimbenika kod mladih vozača.

1.3 PREGLED DOSADAŠNJIH ISTRAŽIVANJA

U Republici Kosovu nema detaljnog istraživanja koje obavljaju institucije ili autori, koje se odnosi na procjenu od prometnih nesreća mladih vozača. U nastavku je dan primjer istraživanja stranih institucija i autora u vezi s tom problematikom.

Prema [1] dob vozača te tjelesni i duševni uvjeti povezuju različite razine individualnog rizika. Poznavanje uzroka i procjena rizika od prometnih nesreća doprinosi povećanju sigurnosti cestovnog prometa. U matrici GADGET (engl. *Guarding Automobile Drivers through Guidance, Education and Technology*) navedene su sposobnosti upravljanja vozilom, gdje osim svladavanja znanja i vještine upravljanja vozilom, vozači znaju prepoznati rizike vezane uz prometnu situaciju. Iz [2] se može zaključiti da problematika prepoznavanja rizika nije istražena do kraja, a odnosi se na elemente procesa osposobljavanja vozača koji će biti istraženi u okviru ovoga doktorskog rada. Ulleberg provodi istraživanje [3] na 2524 mlada vozača te navodi osobine povezane s rizičnim ponašanjem koje podrazumijeva nisku razinu altruizma, anksioznost, visoku razinu potrebe za uzbuđenjem, neodgovornost i agresiju. Prema [4] kompetencija vožnje uključuje motorne, kognitivne i motivacijske sposobnosti koje su potrebne za samostalno upravljanje vozilom. Istraživanje provedeno u [5] pokazuje četiri postupka koja imaju važnu ulogu u percepciji opasnosti: otkrivanje neposredne opasnosti,

procjena rizika, odabir radnje kako bi se izbjegla opasnost te provođenje odabrane radnje. Odnosi između karakteristika osobnosti mladih vozača, percepcije rizika i ponašanja u vožnji prikazani su u [6]. Rafaely i ostali u [7] su razmatrali percepciju rizika stradanja u prometu za mlađe osobe (do 24 godine) koji sudjeluju u prometu u svojstvu vozača motornih vozila. Istraživanja [8] se odnose na proučavanje percepcije rizika i donošenje odluke kod mladih vozača i iskusnih vozača pri identificiranju čimbenika (senzorni, psihomotorni, mentalni, psihološki itd.) koji su važni u procesu percepcije rizika te njegova prihvaćanja. Percepcija opasnosti se neposredno odnosi na prepoznavanje i identifikaciju opasnosti na cesti (trasa i stanje ceste, poprečni profil, raskrižje, klimatski uvjeti itd.), a percepcija rizika obuhvaća i procjenu vlastite sposobnosti. Višefazni model stjecanja vozačke dozvole (engl. *Graduated Driver Licensing – GDL*) definiran u [9] omogućuje da novi vozači postupno izgrade svoje vozačke vještine i iskustvo te pomaže u percepciji rizika na cesti tijekom vožnje. Istraživanje [10] se odnosi na model koji kombinira indikatore kao što su: alkohol i droge, brzina, sustav zaštite, vozilo, prometnica itd. s izlaznim pokazateljima kao što su broj poginulih i ozlijeđenih osoba u prometnim nesrećama. U Europi se tradicionalno provodi istraživanje društvenih stavova o rizicima u prometu u okviru projekta SARTRE (engl. *Social Attitudes to Road Traffic Risk in Europe*) [11], a odnosi se na istraživanje stavova vozača putničkih automobila, stavova vozača motocikala i stavova nemotoriziranih sudionika u prometu. Istraživanja [12] tvrde da je agresivna vožnja povezana s načinom ponašanja bez obzira na to je li namjerno počinjena ili nije. Rezultati istraživanja iz [13] mogu se upotrijebiti za razvoj obrazovanja, obuke i tehnologije usmjerenih na poboljšanje sigurnosti mladih vozača.

Prema istraživanju [14] rizik od prometne nesreće procjenjuje se na temelju ukupnog broja podataka koji proizlaze iz analiza opasnosti, analiza osjetljivosti i analiza ranjivosti (engl. *hazard, susceptibility and vulnerability analysis*). Wagner i Richter predlažu procedure koje se zasnivaju na videoprocjeni, međutim ova problematika prepoznavanja rizika nije istražena do kraja. Opasne situacije na cesti mogu nastati zbog iznenadnih okolnosti na cesti (zavoj, raskrižje, udarne rupe, suženje ceste itd.) ili vremenskih prilika (kiša, snijeg, led, magla itd.). Kako bi se što potpunije sagledala međuovisnost uzroka i pogrešaka u nastanku nesreća, potrebno je detaljnije analizirati realnu prometnu situaciju uz prisutnost konkretne opasnosti u prometu. Istraživanje [15] se odnosi na ljudske greške u vožnji u odnosu na okolnosti na cesti, trasu ceste, kategoriju ceste, elemente ceste itd. te stvara dodatan prostor za daljnje proučavanje i analiziranje. Model ljudskog djelovanja predstavlja model za klasifikaciju pogrešaka čiji je cilj identificirati korak između primanja informacija i izvršenja radnje. Studije [16] i [17] su pokazale da je distrakcija u vožnji (odvlačenje pažnje) glavni

čimbenik uzroka prometnih nesreća s rizikom na razini pojedinačnog vozača. Procjena analize pogrešaka [18] ukazala je da je većina prometnih nesreća (76,9 %) uzrokovana pogrešnim informacijama. Velik broj istraživanja bavio se utjecajem meteoroloških uvjeta na nastanak prometnih nesreća [18], [20]. Kao daljnje istraživanje potrebno je analizirati prometne nesreće uključujući njihova obilježja [21]. Na temelju analize navedene literature uočen je nedostatak sustavnog istraživanja korelacije između subjektivnih i objektivnih čimbenika koji utječu na procjenu rizika od prometnih nesreća u kojima sudjeluju mladi vozači kao posebna kategorija korisnika ceste. To je polazna osnova za realizaciju istraživanja i pristupanje razvoju modela koji će biti definiran unutar doktorskoga rada.

1.4 METODE ISTRAŽIVANJA

U pripremi i tijekom izrade doktorskoga rada upotrebljavane su različite znanstvene metode radi dobivanja kvalitetnih podataka, a najvažnije od njih prikazane su u nastavku:

Metoda analize i sinteze – analizom prikupljenih podataka o prometnim nesrećama, njihovim uzrocima, vrstama i posljedicama, kao i sudionicima prometnih nesreća doneseni su zaključci iskorišteni pri definiranju čimbenika sigurnosti koji utječu na rizik od prometnih nesreća kod mladih vozača te izvođenje zaključaka o modelima osposobljavanja vozača.

Metoda klasifikacije upotrijebljena je pri podjeli prometnih nesreća s obzirom na uzroke, vrste i posljedice.

Matematička i statistička metoda upotrijebljene su pri analizi podataka o prometnim nesrećama koji će se razvrstati prema dobnim skupinama te tabelarno i grafički prikazati što će omogućiti dobivanje određenih varijabli i parametara.

Komparativna metoda primijenjena je kod međusobnih odnosa svih bitnih elemenata koji imaju značajan utjecaj na nastanak prometnih nesreća, uključujući i osposobljavanje vozača u autoškolama te će im se dodijeliti težinski čimbenici.

Metoda anketiranja upotrebljavana je za istraživanje i prikupljanje podataka, stavova i mišljenja o podacima koji se odnose na osposobljavanje vozača u autoškolama, elemente osposobljavanja te procjenu rizika od prometnih nesreća.

Metodom sistematizacije na temelju utvrđenih činjenica, upotrebom dosad navedenih metoda, definirat će se nove zakonitosti i konkretni pojedinačni zaključci vezani uz čimbenike sigurnosti koji imaju utjecaj na rizik od prometne nesreće.

Metoda promatranja i deskripcije – prikupljanje podataka o modelima osposobljavanja vozača, sigurnosti mladih vozača u prometu te opisivanje činjenica i sustava osposobljavanja.

Metodom dokazivanja utvrdit će se točnost spoznaje, stavova mladih vozača u vezi prometnih nesreća te elementi osposobljavanja vozača.

1.5 STRUKTURA DOKTORSKOG RADA

U uvodu su prikazani osnovni cilj istraživanja rada, metode koje su upotrijebljene, postavljane su hipoteze te očekivani doprinos sigurnosti mladih vozača.

U drugom poglavlju objašnjeni su subjektivni i objektivni čimbenici koji imaju utjecaj na nastanak prometnih nesreća. Nadalje, dana je teorijska definicija te analiza subjektivnih i objektivnih čimbenika koji povećavaju rizik od prometnih nesreća te istovremeno utječu na sigurnost prometa s posebnim osvrtom na mlade vozače.

U trećem poglavlju analizirani su postojeći modeli osposobljavanja vozača motornih vozila koji uključuju programe osposobljavanja, fond sati teorijske i praktične nastave, educiranost predavača u autoškolama, kako bi se valorizirali osnovni elementi osposobljavanja mladih vozača, identificirali subjektivni i objektivni čimbenici koji mogu utjecati na procjenu rizika vožnje te modeli stjecanja vozačke dozvole.

Četvrto poglavlje odnosi se na provedenu analizu vrsta i uzroka prometnih nesreća s poginulim vozačima, s posebnim naglaskom na prometne nesreće u kojima su sudjelovali mladi vozači (od 16 do 24 godine) radi identificiranja subjektivnih i objektivnih čimbenika koji povećavaju rizik od prometnih nesreća. Nadalje, izvršena je komparativna analiza prometnih nesreća na području Republike Kosova s prometnim nesrećama na području zemalja regije te analiza prometnih nesreća s nastradalim osobama u razdoblju 2014. – 2018. godine.

Peto poglavlje donosi istraživanje stavova mladih vozača vezanih uz nastanak prometnih nesreća. Prikazan je proces provođenja terenskog istraživanja radi prikupljanja potrebnih podataka o stavovima mladih vozača vezanih uz nastanak prometnih nesreća, kao i rezultati istraživanja. Izrađen je plan aktivnosti terenskog istraživanja koji se odnosi na provedbu anketnog upitnika među kandidatima u ispitnim centrima i autoškolama te prikupljanje podataka o prometnim nesrećama iz dostupnih baza podataka relevantnih za sigurnost cestovnog prometa. Za obradu podataka iz anketnog upitnika (stavovi, stupanj obrazovanja, demografski i psihosocijalni čimbenici kod mladih vozača itd., elementi

osposobljavanja vozača motornih vozila, procjena rizika nastanka prometne nesreće na opasnim mjestima te procjena rizika od prometnih nesreća) upotrijebljen je odgovarajući računalni program za analizu najrelevantnijih subjektivnih i objektivnih čimbenika koji povećavaju rizik od prometnih nesreća mladih vozača.

U šestom poglavlju prikazani su rezultati analize statističke značajnosti prometnih nesreća. Analizirani su podaci o prometnim nesrećama za opasna mjesta na cesti ili cestovnom segmentu s najvećom frekvencijom nesreća mladih vozača. Na temelju zaključaka provedene analize te primjenom statističkih metoda i metoda promatranja utvrđena je povezanost procjene rizika u vožnji, stavova vozača, elemenata osposobljavanja mladih vozača s rizicima od prometnih nesreća. Na temelju toga identificirani su pojedini subjektivni i objektivni čimbenici koji utječu na procjenu rizika od prometnih nesreća. Zatim je neparametarskim metodama hi-kvadrat testa provjerena vjerojatnost slučajne pojave razlike između vrijednosti podataka iz provedenog istraživanja, tj. opaženih frekvencija i teorijskih frekvencija. Ispitana je korelacija (povezanost) između utvrđenih subjektivnih i objektivnih čimbenika prometnih nesreća iz podataka o svim prometnim nesrećama i nastanka prometnih nesreća kod mladih vozača te je utvrđeno da su rezultati statistički značajni. Dobiveni rezultati prikazani su preko koeficijenata korelacije te su analizirani i prikazani tablično s objašnjenjem (komentarom). Cilj ove faze jest određivanje korelacije između temeljnih čimbenika sigurnosti u koje se ubrajaju čovjek, vozilo i cesta te identificiranje subjektivnih i objektivnih čimbenika.

Sedmo poglavlje odnosi se na izradu modela procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika te se temelji na nalazima teorijskog i praktičnog istraživanja, kao i na osnovi obrade podataka – analize i nalaza kojima je utvrđeno da postoji povezanost između osnovnih čimbenika sigurnosti prometa na cestama: čovjek – vozilo – cesta – okoliš te subjektivnih i objektivnih uzroka nastanka prometnih nesreća.

U osmom poglavlju prikazani su evaluacija modela procjene rizika uz pomoć programa SPSS-26 korištenjem ANOVA testa te rezultati analize i evaluacija modela. Dan je prijedlog mjera za poboljšanje sigurnosti prometa na temelju nalaza iz teorijskog i praktičnog istraživanja i rezultata analize te su napravljene preporuke za povećanje prometne sigurnosti mladih vozača. Nadalje je prikazana diskusija s posebnim osvrtom na važne doprinose provedenog istraživanja, rezultate istraživanja te pregled dosadašnjeg istraživanja koje je značajno za usporedbu s rezultatima istraživanja za sigurnost prometa mladih vozača.

U zaključnom dijelu istraživanja sustavno su formulirani i prezentirani najvažniji rezultati znanstvenog istraživanja, a odnose se na identifikaciju subjektivnih i objektivnih čimbenika koji omogućuju procjenu rizika od prometnih nesreća i sastavni su dio predloženog modela za procjenu rizika od nesreća, kao i pravci daljeg istraživanja koji se odnose na razvoj modela procjene rizika od prometnih nesreća.

2. ČIMBENICI SIGURNOSTI PROMETA

U ovom poglavlju objašnjeni su osnovni čimbenici sigurnosti prometa koji imaju utjecaj na nastanak prometnih nesreća te je dano istraživanje ostalih čimbenika koji se odnose na mlade vozače.

Definicija prometne nesreće prema UN-u jest: Prometna nesreća je nesreća koja se dogodila na mjestu otvorenom za javni promet ili je započela na takvom mjestu u kojem je jedna ili više osoba poginula ili je ozlijeđena i u kojem je sudjelovalo najmanje jedno vozilo u pokretu. Temelj kvalitetnog preventivnog djelovanja u sprečavanju nastanka prometnih nesreća jest prepoznavanje utjecajnih subjektivnih i objektivnih čimbenika. U svijetu su razvijeni različiti modeli za utvrđivanje utjecajnih čimbenika u nastanku prometnih nesreća.

Prema podacima Svjetske zdravstvene organizacije u svijetu godišnje umre 1,35 milijun ljudi od posljedica nesreća u cestovnom prometu. Na svjetskim cestama svakodnevno umire gotovo 3700 ljudi. Svake se godine u prometnim nesrećama teško ozlijedi više od 50 milijuna ljudi. Prometne nesreće sada su osmi vodeći uzrok smrti na globalnoj razini [22].

Kako bi se povećala sigurnost prometa, potrebno je kontinuirano provoditi brojne mjere, čiji je cilj otklanjanje, odnosno smanjenje rizika.

Nastanak prometnih nesreća u funkciji je četiri osnovna čimbenika koji čine sustav [23]: korisnici cesta (čovjek) – vozilo – cesta – okolina (Slika 2-1).



Slika 2- 1 Čimbenici prometnih nesreća

Izvor: Izradio autor

Iz toga proizlazi da postoji biomehanički sustav koji se sastoji od veze „čovjek – vozilo“ i „čovjek – cesta“; mehanički sustav koji se sastoji od veze „vozilo – cesta“ te sustav okolina – korisnici – vozila – cesta.

Prema [24] glavni uzrok prometnih nesreća je čovjek (u 65 % prometnih nesreća); u 30 % prometnih nesreća uzročnik je kombinacija čimbenika ceste, čovjeka i vozila, a u 5 % prometnih nesreća čimbenici su cesta i vozila.

2.1 UZROCI PROMETNIH NESREĆA

2.1.1 Subjektivni čimbenici

Subjektivni čimbenici prometnih nesreća uključuju čovjeka koji izravno ili neizravno sudjeluje u cestovnom prometu (od 80 % do 95 % uzročnik prometnih nesreća) kao:

- vozač, upravlja vozilom na cesti
- suvozač i putnici koji putuju u vozilu
- pješak
- radnik koji radi na cesti (održavanje, sanacije, izgradnje, postavljanje signalizacije itd.)
- gonič stoke
- pružatelj osposobljavanja kandidata za vozače
- ispitivač na vozačkim ispitima
- konstruktor, proizvođač, onaj koji održava vozila
- projektant ceste
- operator
- upravitelj i kontrolor prometa te
- zakonodavac.

Radnje s vozilom kao uzroci prometnih nesreća

Prema podacima [25] velik broj prometnih nesreća uzrokovan je nepravilnim/nepropisnim radnjama s vozilom ili nepoštovanjem prometnih propisa i sigurnosnih ili prometnih pravila:

- nepropisna brzina
- brzina neprimjerena uvjetima
- vožnja s nedovoljnom udaljenošću među vozilima ili u koloni

- nepropisno pretjecanje
- nepropisno uključenje u promet
- nepropisno skretanje
- nepropisno prestrojavanje
- nepoštovanje cestovne signalizacije
- nepropisna ili nepravilna kretnja vozilom
- pogreške pješaka, biciklista itd.
- ostali uzroci.

Prema podacima glavni uzroci prometnih nesreća su [26]:

- nesigurna manipulacija vozilima
- neodržavanje dovoljnog razmaka između vozila
- brzina, neprilagođena brzina uvjetima na cesti i nepoštovanje ograničenja
- nepropisno uključenje u promet
- nepropisno prestrojavanje
- nepravilno skretanje, polukružno okretanje i vožnja unazad.

Čimbenici koji smanjuju psihofizičke sposobnosti vozača su:

- alkohol
- umor
- bolest
- lijekovi i narkotici
- stres
- tuga
- srdžba itd.

Alkohol povećava rizik od prometne nesreća za sve vozače, uključujući mlade vozače [27].

2.1.2 Objektivni čimbenici

Objektivni čimbenici uzročnici su u 5 % do 20 % prometnih nesreća.

Vozilo kao čimbenik sigurnosti prometa

Prema statističkim podacima nedostaci na vozilu uzročnici su u prosjeku 3 % − 5 % prometnih nesreća. Studije su otkrile da mladi vozači koji su sudjelovali u sudaru u pravilu upravljaju starijim vozilima [28], [29].

Cesta kao čimbenik sigurnosti prometa

Procjena rizika od prometnih nesreća na pojedinim dijelovima mreže – rangiranje, prioriteti (engl. *Road safety assesment*) – strateška je usporedna analiza utjecaja nove ceste, ili bitne promjene postojeće mreže, na sigurnost cestovne mreže. Upravljanje crnim točkama (engl. *Black Spot Management – BSM*) predstavlja postupak otkrivanja mjesta izrazito povećane ugroženosti u prometu i definiranje mjera radi saniranja tih mjesta.

Tehnički nedostaci ceste, stanje kolnika, raskrižja, bočne zapreke, signalizacija (objektivni čimbenici) često su uzrok nastanka prometnih nesreća, a mogu nastati pri projektiranju cesta i pri njihovoj izvedbi ili zbog neodržavanja ceste.

iRAP organizacija razvija specijalizirane aplikacije i alate za provođenje analize rizika te organizira obuku za njihovu upotrebu kako bi pomogla državama u procesu provođenja aktivnosti za podizanje razine sigurnosti na cestovnoj mreži. Europska unija je 2008. godine donijela *Direktivu o obaveznoj upotrebi suvremenih procedura unapređenja sigurnosti cesta.*

Prema istraživanjima [30] uočava se da je znak „Obilježeni pješački prijelaz“ koji prikazuje približavanje pješačkom prijelazu, postavljen neposredno ispred pješačkog prijelaza (Slika 2-2), što predstavlja potencijalni rizik od prometne nesreće.



Slika 2- 2 Prikaz nepravilnog postavljanja prometne signalizacije

Izvor: Izradio autor

Okolina

Okolina uključuje klimatske uvjete, kamenje na cesti, ulje i blato na kolovozu, urušavanje zemlje, urušavanje objekta ceste i druge elemente. Klimatski uvjeti imaju velik utjecaj na stope prometnih nesreća kod svih vozača, iako je utvrđeno da ti čimbenici imaju nerazmjeran utjecaj na mlade vozače [31]. Istraživanja [32] i [33] pokazuju kako mladi vozači vozeći iznad ograničenja brzine u nepovoljnim vremenskim uvjetima, najčešće stradavaju.

Razina urbanizacije još je jedan čimbenik koji utječe na stope prometnih nesreća. Istraživanje u Australiji [34] razmatralo je različite rizike prometnih nesreća kod mladih vozača koji su živjeli u urbanim, regionalnim i ruralnim sredinama.

Prema [35] uzorci vožnje koji utječu na rizike od prometnih nesreća odnose se na duljinu vremena provedenog na cesti, kao i na doba dana, dan u tjednu i sl.

2.2 RIZIK U CESTOVNOM PROMETU

Sigurnost cestovnog prometa jedna je od znanstvenih disciplina koja se primjenjuje u znanstvenoj metodologiji, prati, proučava i objašnjava uzroke, okolnosti i druge čimbenike u nastanku prometnih nesreća.

Rizik je povezan s opasnostima, odnosno postojanjem objektivnih i subjektivnih čimbenika u prometnom sustavu koji mogu dovesti do nastanka prometnih nesreća. Elementi sigurnosti cestovnog prometa jesu upravljanje prometnom sigurnošću i procjenom rizika. Upravljanje prometnom sigurnosti čini skup mjera za predviđanje i prevenciju prometnih nesreća. Rizik prometne sigurnosti definira se kao proizvod kombiniranih mjera vjerojatnosti nastanka prometne nesreće i utjecaja čimbenika sigurnosti u prometu.

U stručnoj literaturi objektivni rizik definira se kao mjerljiva vjerojatnost događanja prometne nesreće ili konkretne posljedice, dok je subjektivni rizik procijenjeni rizik od strane vozača na temelju percepcije okoline puta. Na osnovi toga te su situacije opasne onda kad je subjektivni rizik niži od objektivnog budući da vozači prilagođavaju svoje ponašanje prema subjektivnom, a ne prema objektivnom riziku.

Vožnja je funkcionalna prostorno-vremenska aktivnost vozača, koja nikad nije bez rizika. U vožnji vozač treba biti spreman za otkrivanje neposredne opasnosti na cesti, procijeniti rizik te prihvatiti rizik, odnosno odabrati aktivnosti – radnje – kako bi izbjegao prometne nesreće. Navedene komponente ponašanja u prometu vozač nauči tijekom procesa osposobljavanja za vozača, polaganja teorijskog ispita (test znanja) i praktičnog ispita (test vožnje) pri stjecanju vozačke dozvole.

Rizik od prometne nesreće uzrokovan je subjektivnim i objektivnim čimbenicima. Subjektivni čimbenici su: fiziološki, psihološki, socijalni itd., a imaju utjecaj na identifikaciju i procjenu rizika i opasnosti stvarne prometne situacije na cesti. Objektivni čimbenici ovise o stvarnim neželjenim događajima na promatranoj cesti ili njezinom segmentu.

Prepoznavanje i analiziranje subjektivnih i objektivnih uzroka koji povećavaju rizik od prometne nesreće predstavljaju važan alat za otkrivanje opasnosti tijekom vožnje te procjenu rizika od prometne nesreće. Za procjenu rizika i njegovo smanjenje, identifikacija subjektivnih i objektivnih čimbenika te njihova analiza primarna je aktivnost. Rizik od pojave nesreća povećava se ako analiza čimbenika (subjektivnih ili objektivnih) uključuje mlade vozače. Problem nastaje pri procjeni potencijalno rizičnih situacija u prometu, gdje mlađi vozači uočavaju manji broj opasnosti na cesti, uočavaju ih sporije te podcjenjuju razinu njihove opasnosti.

U vožnji vozač treba biti spreman za otkrivanje neposredne opasnosti na cesti, procjenu rizika te prihvaćanje rizika (razumijevanje psiholoških procesa, od opažanja prometne situacije, donošenja odluke, reakcije do poznavanja granica svojih mogućnosti),

odnosno odabir aktivnosti (kočenje, pomicanje vozila itd.) te ostale radnje kako bi izbjegao nastanak prometne nesreće.

Čimbenici rizika za sve vozače su:

- neiskustvo [36]
- mladi putnici [37]
- distrakcija (odvlačenje pažnje) tijekom vožnje, uključujući upotrebu mobitela i slanje poruka [38]
- vožnja s prekomjernom brzinom, blisko praćenje i druge rizične vožnje [39]
- vožnja pod utjecajem alkohola (pijano stanje) [40] [41]
- „biti muško“ – mladići, pogotovo oni s muškim putnicima, uključeni su u više prometnih nesreća nego mlade djevojke. Međutim, povećava se broj žena koje su sudjelovale u prometnim nesrećama [41].
- vožnja noću
- socijalne norme [12] [42].

Često su prisutni sljedeći rizici: mladi vozači koji pišu SMS tijekom vožnje, vjerojatnije će pribjeći i drugim rizičnim ponašanjima u vožnji za razliku od onih vozača koji ne pišu SMS tijekom vožnje. Ti dodatni čimbenici rizika uključuju slanje SMS-ova tijekom vožnje i druga rizična ponašanja [43]. Uz to, mladi vozači koji posjeduju svoje automobile mogu riskirati više. Pozitivan čimbenik za mlade vozače je prisutnost odraslog putnika tijekom vožnje. Istraživanje [39] je pokazalo da su stope prometnih nesreća kod mladih bile 75 % niže kad je odrasla osoba bila u automobilu.

Tri glavna elementa u prometnoj situaciji koje treba predvidjeti su [44]:

- radnje drugih korisnika ceste
- kontrola vlastitog vozila i posljedice vlastitih postupaka
- nakon što se identificirao mogući konflikt i predvidjelo gdje bi se mogao dogoditi, koja bi se odluka mogla donijeti.

2.2.1 Međuovisnost uzroka i pogrešaka u nastanku prometnih nesreća

Većina pogrešaka u vožnji uzrokovane su lošim navikama u načinu na koji se vozači koriste očima [45] IPDE (engl. *Identify, Predict, Decide and Execute*).

Četiri koraka IPDE postupka su:

I – Identificiranje – pronaći potencijalne opasnosti unutar potencijalne situacije u vožnji

P – Predviđanje – prosuditi gdje može doći do mogućih konflikata

D – Odlučivanje – odrediti koju akciju poduzeti, kada i gdje ju poduzeti

E – Izvršenje – upravljati automobilom kako bi se izbjegli konflikti.

U nastavku su dane specifične karakteristike mladih vozača zbog kojih su izloženi visokom riziku od prometne nesreće [46]:

- pretjerano samopouzdanje
- loša procjena opasnosti
- podcjenjivanje rizika u prometu
- vožnja velikom brzinom
- vožnja pod utjecajem alkohola
- nekorištenje sigurnosnog pojasa
- upotreba mobitela tijekom vožnje te
- drugi čimbenici rizika.

Funkciju upravljanja obavlja vozač, objekt upravljanja je vozilo, dok je okolina izvor informacija na osnovi koje se odvija vožnja.

2.2.2 Sigurnost mladih vozača

U Republici Kosovu i zemljama u regiji nema sustavnih istraživanja koja se odnose na sudjelovanje mladih vozača u prometnim nesrećama, dok u zemljama Europske unije u takvim istraživanjima dominiraju skandinavske države, posebno Švedska. U zapadnim razvijenim zemljama, kao što su SAD, Kanada i Australija, nadležne institucije i znanstvenici

koji se bave prometnom sigurnošću, istražuju prometne nesreće u kojima su sudjelovali mladi vozači.

Prema Izvješću Europske komisije [47] u razvijenim zemljama prometne nesreće su glavni uzrok smrti mladih u dobi od 15 do 24 godine. Stopa smrtnosti vozača u dobi od 15 do 24 godine dvostruko je veća nego u iskusnijih vozača. Nesreće u kojima su sudjelovali mladi vozači često su uzrokovane gubitkom kontrole ili prekoračenjem brzine i dogodile su se noću. Kako bi se smanjio rizik od prometnih nesreća, mladi vozači trebaju biti podvrgnuti strožoj kontroli od one koja se primjenjuje na iskusnim vozačima, npr. niže granice alkohola i ograničenja vožnje noću ili vožnja pod nadzorom iskusnog vozača.

Europski projekti za sigurnost mladih vozača nastoje povećati sigurnost mladih vozača preusmjeravajući fokus učenja o vožnji s kontrole vozila i percepcije prometa na prepoznavanje i izbjegavanje opasnosti na cesti. Primjerice, projekt HERMES koji financira EU, objavio je paket za poboljšanje obuke instruktora vožnje radi smanjenja broja prometnih nesreća. U sklopu projekta *Close* mladi koji uče voziti, izloženi su prikazima teških prometnih nesreća budući da je tada manja vjerojatnost da će se upustiti u rizičnu situaciju i biti nepažljivi u vožnji. Organizacija za ekonomsku suradnju i razvoj – OECD (engl. *Organisation for Economic Co-operation and Development)* i Europska konferencija ministara prometa – ECMT (engl. *European Conference of Ministers of Transport*) u svojem izvješću (OECD/ECMT) koji je realizirala skupina stručnjaka na području prometne sigurnosti identificirale su ključne elemente rizika mladih vozača (15 – 24 godine), čimbenike koji utječu na identificirani rizik i mjere koje se trebaju primijeniti. Prema tom izvještaju:

- U zemljama OECD-a oko 25 000 mladih (starosti 15 – 24 godine) pogine u prometnim nesrećama svake godine.
- U mnogim zemljama u 20 % − 30 % svih prometnih nesreća u kojima su sudjelovali mladi vozači, na svakih 10 poginulih mladih vozača u istim prometnim nesrećama pogine više od 13 drugih sudionika u prometu.
- Velik broj prometnih nesreća u kojima sudjeluju mladi vozači, događa se noću i/ili vikendom, kad mladi vozači za putnike imaju svoje vršnjake, i kad prekoračuju brzinu vožnje.

Ključni čimbenici sigurnosti mladih vozača su [46]:

- iskustvo

- starost
- spol.

Čimbenici prometnih nesreća mladih su [47]:

- Neiskustvo – vjerojatnije je da će mladi podcjenjivati opasne situacije ili ih neće moći prepoznati, za razliku od starijih vozača. Mladi imaju veću vjerojatnost donošenja kritičnih pogrešaka u odlučivanju koje dovode do ozbiljnih prometnih nesreća.
- Sigurnosni razmak – vjerojatnije je da će mladi voziti brzo i na manjem sigurnosnom razmaku nego što to čine stariji vozači.
- Upotreba sigurnosnog pojasa – u usporedbi s drugim dobnim skupinama, mladi i odrasli često imaju najmanju stopu korištenja sigurnosnih pojaseva. U 2017. godini samo je 58,8 % srednjoškolaca uvijek vezalo sigurnosne pojaseve dok su se vozili kao putnici.
- Upotreba alkohola – bilo koja količina alkohola kod mladih vozača povećava rizik od prometne nesreće u odnosu na starije vozače.

U anketi o riziku u ponašanju mladih za 2017. godinu, 16,5 % srednjoškolaca vozilo se s vozačem koji je konzumirao alkohol u prethodnom mjesecu. Konzumiranje alkohola je nezakonito za mlađe od 21 godine; ako konzumiraju alkohol, i upravljaju vozilom. Unatoč tome, u 2017. godini 15 % vozača u dobi od 16 do 20 godina koji su sudjelovali u prometnim nesrećama sa smrtnim posljedicama, imalo je razinu alkohola u krvi od 0,08 % ili veću.

U 2017. godini 58 % vozača u dobi od 15 do 20 godina koji su smrtno stradali u prometnim nesrećama nakon konzumiranja alkohola, nisu imali sigurnosni pojas (na temelju poznate uporabe sigurnosnih uređaja).

Muškarci u dobi od 15 do 20 godina sudjelovali su u 31 % prometnih nesreća sa smrtnim posljedicama u 2017. godini čiji je uzrok bila brzine, dok je za 20 % prometnih nesreća uzrok bila vožnja pod utjecajem alkohola

Noćna i vikend-vožnja: u 2017. godini 40 % smrtnih slučajeva u prometnim nesrećama među mladim vozačima i putnicima u dobi od 13 do 19 godina dogodilo se između 21:00 i 6:00, a 51 % u petak, subotu ili nedjelju.

Distrakcija tijekom vožnje posebno je izražena kad mladi vozači upravljaju vozilom s vršnjacima i ne koncentriraju se na vožnju, već njihovu pažnju odvraćaju druge stvari.

Prema [48] konzumiranje alkohola u visokim koncentracijama (ispijanje) može uzrokovati povraćanje, amneziju ili čak smrt. Kanada, SAD i Novi Zeland su tri vodeće zemlje u svijetu s najvišim postotkom smrtnih slučajeva povezanih s prometnim nesrećama (engl. *Road Traffic Accident* – RTA) zbog konzumacije alkohola [49]. U Europskoj uniji alkohol je jedan od triju glavnih čimbenika rizika za 40 % lošeg zdravlja i preranu smrt. Globalno gledano, ozljede povezane s RTA-om vodeći su uzrok smrtnosti među mladim i odraslim osobama (u dobi između 15 i 29 godina) [50]. Vožnja pod utjecajem alkohola glavni je čimbenik rizika za demografski i socioekonomski status svake zemlje [52].

Vožnja pod utjecajem droga također se smatra ozbiljnim problemom koji utječe na javno zdravlje. Isto tako u [51], [52], [53], [54], [55], [56], [57], [58], [59], [60] objašnjeno je kako je kombinacija konzumiranja alkohola i upotrebe psihoaktivnih tvari povezana s povećanim rizikom od prometnih nesreća sa smrtnim posljedicama. Osim toga, u trogodišnjoj studiji (2006. – 2008.) [61] u regiji Središnje Makedonije, uočeno je da je alkohol otkriven u 28 % vozača koji su sudjelovali u prometnim nesrećama sa smrtnim posljedicama. Vikende je karakterizirala veća prevencija vožnje pod utjecajem alkohola i/ili droge i prometnih nesreća sa smrtnim posljedicama povezanih s umorom vozača, kako su pokazala istraživanja u [62] i [63]. Prema statistikama EU-a o sigurnosti na cestama za 2017. godinu, doba godišnjih odmora (srpanj i kolovoz) povezana su s većom učestalošću prometnih nesreća sa smrtnim posljedicama od ostalih razdoblja u godini [64]. Postotak žrtava koje voze pod utjecajem alkohola u kombinaciji s drugim psihoaktivnim tvarima procijenjen je na 4,5 %. Ostale studije provedene u [53], [65] i [66] izvijestile su da vožnja pod utjecajem alkohola ili droga predstavlja značajan problem.

Kultura i edukacija – korisnici ceste također su sigurnosni element prometa koji utječe na ponašanje sudionika u prometu. Kultura je sama po sebi sigurnosni čimbenik i postala je ključ za razvoj sigurnosnih mjera i politika, posebno u SAD-u [67], [68], [69].

Kultura sigurnosti prometa privukla je nedavnu nacionalnu pažnju kao varijabla koja može objasniti rizično ponašanje vozača [70], čimbenik koji podržava prihvaćanje postojećih politika i program prometne sigurnosti [71], kontekstualno varijabla za definiranje visoko rizičnih skupina vozača i nova paradigma kao podrška viziji nula smrtnih slučajeva u prometu [72]. Istraživanje je osmišljeno oko definicije sigurnosne kulture kao „društvene norme,

vjerovanja i vrijednosti“ [73], [74]. Nedostatak edukacije o sigurnosti prometa na cestama može povećati vjerojatnost sudjelovanja u prometnoj nesreći [75], [76].

2.2.3 Razina stupnja rizika u prometu

Stupanj rizika koji prati odvijanje prometa ovisi o subjektivnim i objektivnim rizicima. Koliko će često rizik rezultirati prometnim nesrećama, pored stupnja rizika, ovisi i o izloženosti riziku (sudjelovanje u prometu) i brzini kretanja.

Sigurno sudjelovanje u prometu ovisi o:

- stupnju subjektivnog rizika, odnosi se na sposobnost vozača da prilagodi svoje ponašanje okruženju u prometu (objektivni rizik)
- stupnju objektivnog rizika
- stupnju izloženosti u prometu te
- brzini kretanja vozila.

Izloženost (sudjelovanje) u prometu može se definirati pomoću veličine populacije, prijeđenih kilometara vozila, dužine cestovne mreže, broja vozila, broja vozačkih dozvola itd.

Metoda za mjerenje stupnja smrtnosti u prometu upotrebljava broj poginulih na 100 000 vozila, a za mjerenje stupnja rizika broj poginulih na 100 000 stanovnika. Nesigurna ponašanja vozača u prometu dovode do stvaranja opasnih situacija koje mogu uzrokovati prometne nesreće.

Veoma je važno identificiranje određenih značajki osposobljavanja budućih vozača koji doprinose boljim sposobnostima procjene rizika, zatim čimbenika koji utječu na vještinu i percepciju rizika te spremnost na preuzimanje rizika u dinamičnim prometnim situacijama. Osnovne vozačke vještine, znanja o rizičnim čimbenicima i sposobnosti za samoprocjenu i edukacijske metode koje se opisuju, teže k povećanju vozačkih sposobnosti za procjenu rizika u dinamičnim situacijama na cesti. Takav korak zahtijevao bi od vozača samostalnu procjenu rizika od prometne nesreće, kao dio njegova osposobljavanja. Svrha takvog osposobljavanja jest kalibrirati samoprocjenu vozača i potaknuti ih da se voze u većim marginama sigurnosti (engl. *safety margin*).

Treba istražiti i razviti druge metode te usmjeriti istraživanja na pronalazak čimbenika koji statistički značajno utječu na rizik od prometne nesreće [77].

Subjektivni rizik [78] povezan je sa subjektivnim čimbenicima koji su već navedeni. Stupanj subjektivnog rizika ovisi o osobnim značajkama vozača, psihofizičkim svojstvima, edukaciji i kulturi itd. Za vozača je veoma važno da tijekom vožnje ima sposobnost

predvidjeti, uočiti, identificirati i procijeniti objektivni rizik i na njega odgovoriti adekvatno, radi eliminiranja rizika jer u suprotnom dolazi do nastanka prometne nesreće.

Veći utjecaj na subjektivni rizik ima niža razina sposobnosti, loše zdravstveno stanje, nedostatak motivacije, neadekvatne navike i shvaćanja, nedovoljno znanje i/ili nedovoljna vještina za upravljanje vozilom itd.

Rizik povećavaju oni čimbenici koji imaju negativan utjecaj na psihofizičke sposobnosti vozača (alkohol, droga, umor, nepažnja, distrakcija i dr.), motivi, navika, negativan stav o prometu itd.

Objektivni rizik [79] povezan je s objektivnim čimbenicima, tj. okruženjem i odnosi se na:

- cestovnu infrastrukturu
- vozila
- meteorološke uvjete
- prometni tok itd.

Okolina treba biti adaptirana i prilagođena jer je vozač u prometu izložen velikom objektivnom riziku, zbog toga može doći do nastanka prometne nesreće.

2.2.4 Sigurnosne granice vozača

Da bi se izbjegle prometne nesreće, vozač treba usvojiti i prilagoditi se optimalnim sigurnosnim granicama (engl. *safety margin*) [80]. To znači da vozač treba poznavati sigurnosna pravila i tehniku vožnje te ostaviti veće margine za sigurnost, tj. poduzeti odgovarajuće radnje vozilom kako bi se izbjegle prometne nesreće. Mladi vozači zadržavaju niže sigurnosne granice te tako podcjenjuju situaciju u prometu i nisu svjesni rizika. Prema istraživanju mladi vozači uzrokuju nastanak prometnih nesreća zbog nepoštovanja brzine, vožnje pod utjecajem alkohola, dokazivanja itd.

2.2.5 Percepcija i procjena rizika

Percepcija rizika ovisi o ravnoteži između složenosti zadatka i sposobnosti ili kapacitetu vozača da se suoči s objektivnim rizikom. Percepcija rizika, u skladu s motivacijskim čimbenicima (namjera, ciljevi, potrebe) i sposobnostima, donosi odluku u određenoj prometnoj situaciji.

Četiri postupka koja imaju važnu ulogu u percepciji opasnosti su: otkrivanje neposredne opasnosti, procjene rizika, odabir radnje kako bi se izbjegla opasnost te provođenje odabrane radnje [85].

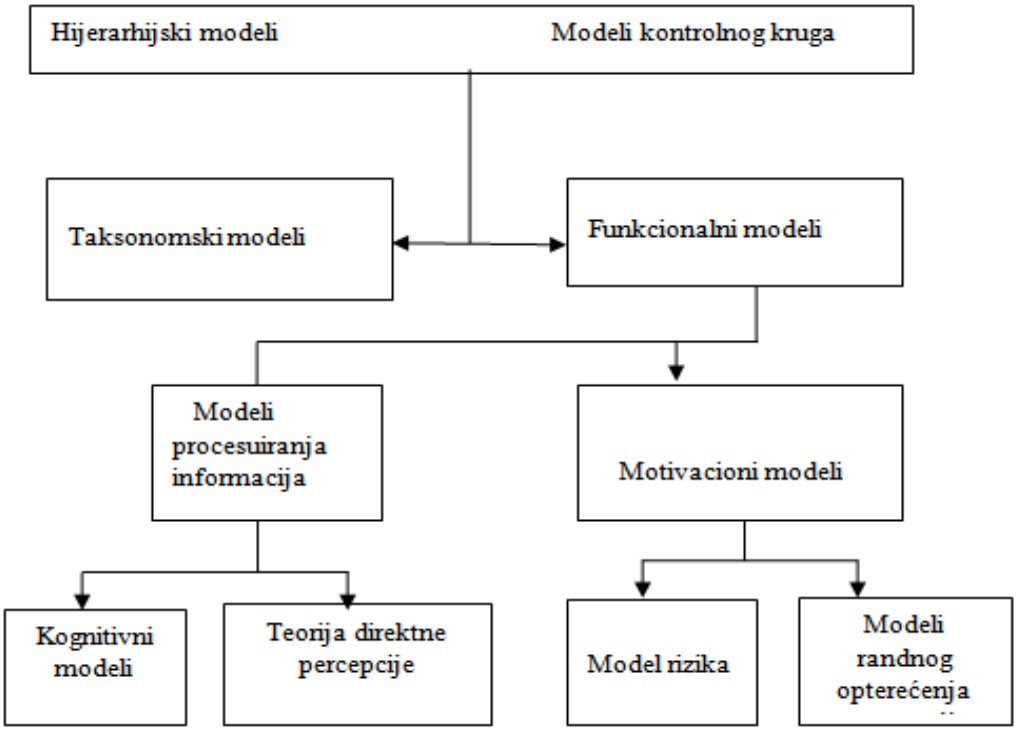
Proučavanje percepcije rizika i donošenje odluke te identificiranje čimbenika (senzorni, psihomotorni, mentalni, psihološki itd.) kod mladih su vozača važni u procesu percepcije rizika i njegova prihvaćanja.

Percepcija opasnosti neposredno se odnosi na prepoznavanje i identifikaciju opasnosti na cesti (trasa i stanje ceste, poprečni profil, raskrižje, klimatski uvjeti itd.), a percepcija rizika obuhvaća i procjenu vlastite sposobnosti [81].

Prepoznavanje i identifikacija opasnosti na cesti (objektivni čimbenici) i procjene rizika od prometne nesreće (subjektivni čimbenici) predstavljaju okosnicu i motiv za istraživanja koja su realizirana u okviru ovoga rada.

2.2.6 Ponašanja vozača u prometu

Od suštinskog je značaja pregled različitih ponašanja vozača u prometu, a najvažniji su hijerarhijski modeli i modeli kontrolnoga kruga koji služe kao polazište za ostale modele (slika 2-3).

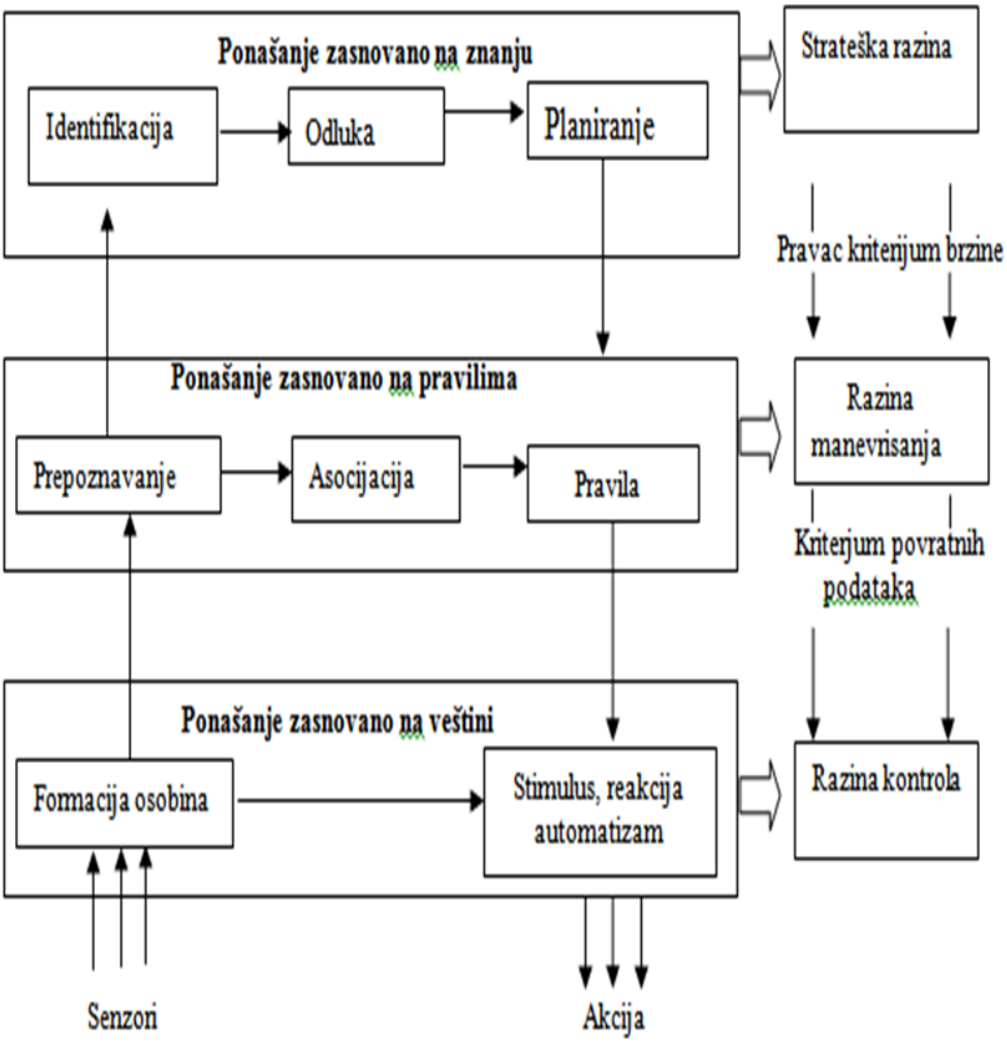


Slika 2- 3 Modeli ponašanja vozača

Izvor: [82]

Kognitivni modeli, teorija direktne percepcije, model rizika, modeli radnog opterećenja čine okvir vozačkog zadatka u koji se mogu integrirati ostale teorije. Taksonomski modeli naglašavaju pojedinačne razlike, dok funkcionalni modeli uzimaju u obzir kompliciranе interakcije u vožnji. U stvarnosti se najčešće upotrebljava kombinacija obaju modela [82]. Prikaz najčešće razmatranih modela ponašanja u vožnji koji se mogu naći u stručnoj literaturi, dat je na dijagramu 2-1.

Prema [83], [84] model vožnju vidi kao hijerarhijski problem koji rješava zadatak vožnje na tri različite razine. Michonov hijerarhijski model pronalazi ekvivalent u razlici između performansi ili razine ponašanja koje predlaže [85], koji pravi razliku između razina koje se temelje na znanju, pravilima i vještini u zadatku vožnje. Prema modelu kognitivne kontrole ljudske aktivnosti osnovne vrste pogrešaka kao rizičnog ponašanja vozača mogu se svrstati u tri kategorije: (1) neuspjeh u vještini – pad sustava i propusti, (2) pogreške na temelju pravila i (3) pogreške u znanju.



Dijagram 2- 1 Kombinacija razine učinka

Izvor: [85]

Prva razina odnosi se na strateške komponente koje sadrže sve procese koji se tiču odluke o putovanju, tj. odredišta putovanja, vremena putovanja, rute i modalitet prometa. Odluke na ovoj razini su rijetke i proces donošenja odluke traje dulje nego na ostalim razinama.

Na drugoj razini manevriranja odluke se donose brzo, u sekundi, jer kašnjenje u izvođenju manevra (radnje s vozilom), može dovesti do nastanka prometne nesreće. Tipični manevri s vozilom su pretjecanje, skretanje ili prihvaćanje prostornih i vremenskih intervala slijeđenja. Na ovoj razini na ponašanje vozača također utječe motivacija i situacija. Ostali izrazi koji se upotrebljavaju za opisivanje manevara su taktika i upute.

Na trećoj razini odluke kontrole donose se preko automatiziranih procesa. Tipični zadaci uključuju održavanje promjene trake ili brzine i izvode se bez svjesne obrade podataka. Za ovu razinu upotrebljavaju se izrazi stabilizacija i operacija. Je li zadatak na razini znanja, pravila ili vještina u velikoj mjeri ovisi o informacijama koje postoje u vezi sa zadatkom i okolinom. Kombinaciju obaju modela predložio je Donges (1982).

Motiv vožnje ima utjecaj na ponašanje vozača tijekom vožnje. Pravilno ponašanje vozača odnosi se na prilagodbu vožnje prema prometnim propisima i sigurnosnim pravilima. Stil vožnje ovisi o motivima. Postoje dva stila, i to: opći stilovi vožnje, npr. defanzivna vožnja, i specifični stil vožnje, npr. naglo ubrzanje. Opći stil uključuje pojedinačni stil vožnje [86], a u njega spadaju: 1. agresivna vožnja, 2. rizična vožnja 3. defanzivna vožnja i 4. koncentrirana vožnja.

Prema [87] rizična vožnja definirana je kao vožnja izvan okvira društveno prihvaćenih normi. Takva vožnja uključuje: 1) prebrzu vožnju, 2) vožnju pod utjecajem alkohola, 3) nekorištenje sigurnosnog pojasa, 4) vožnju u stanju povećanog umora, 5) nepoštovanje prometne signalizacije i 6) nedostatak koncentracije u vožnji.

Prema istraživanju [87] glavni motiv vozača jest stići na odredište, a dodatni motivi mogu biti: 1) povezani s obračunom (postizanje cilja što je brže moguće), 2) agresivnost (odmazda u slučaju ozljede drugog vozača), 3) nepridržavanje pravila ponašanja, 4) dokazivanje i 5) traženje senzacija.

Razlika između subjektivne procjene rizika i stvarnog rizika obično je uzrok pogrešaka u vožnji te ako se na vrijeme ne eliminiraju, dovode do situacije koja može uzrokovati prometnu nesreću [88].

Osnovne pogreške u vožnji kao oblik rizičnog ponašanja u skladu s razlogom uključuju propuste, lapsuse i pogreške. Neuspjesi su pogreške u implementaciji, kada dužna pažnja prati nepravilno izvršenje. Često se privlači pretjerana pažnja.

Prekršaji su nepoštovanje prometnih propisa koji su specifični u određenom kontekstu i dovode do sukoba s drugim sudionicima u prometu i s okolinom. Stoga su prekršaji sva ta ponašanja koja odstupaju od donesenih postupaka.

Prekršaji mogu biti rutinski, a to su ponašanja koju još uvijek tolerira većina vozača i općenito su uobičajena praksa. Posljednji oblik rizičnog ponašanja za volanom su takozvani izvanredni prekršaji kad se vozač pod vremenskim pritiskom nalazi u neočekivanim situacijama i kad nedostaje kontrola.

Kad su ekstremni prekršaji uzrokovani ljutnjom ili neprijateljstvom, govori se o agresivnoj vožnji ili bijesu na cestama.

Na temelju pravila, propusti i pogreške također se mogu smatrati prekršajima zbog svjesnog ponašanja vozača. Međutim, ta vrsta pogreške nije namjerni prekršaj pravila, već samo pogrešna odluka. Prekršaji su planirana nepoštovanja pravila i propisa, koji su specifični u određenom kontekstu i dovode do konfliktne situacije s drugim sudionicima u prometu i s okolinom.

Prema [89] rizično ponašanje karakterizira optimalna razina rizika određena sljedećim čimbenicima: 1) očekivane koristi od rizičnog ponašanja, 2) očekivani trošak pažljivog ponašanja, 3) očekivane koristi opreznog ponašanja i 4) očekivani troškovi rizičnog ponašanja, pri čemu prvi čimbenici povećavaju razinu rizika, a posljednja dva ga smanjuju.

Prema [90] dizajn modela za odnos između zahtjeva zadataka vožnje i sposobnosti vozača pokušaj je razumijevanja čimbenika, što utječe na donošenje odluke vozača, posebno one koje rezultiraju sigurnom vožnjom. Model pretpostavlja da je vozačeva sposobnost otkrivanja procesa i sigurnih aktivnosti ograničena. Zbog toga vozač mora uvijek stvarati i održavati uvjete vožnje unutar ovih ograničenja te zahtjev zadataka mora ostati u granicama njegovih sposobnosti. Gubitak kontrole nastaje kad vozač dopusti da zahtjevi zadataka vožnje premaše granice njegovih sposobnosti.

Model povezanosti između zahtjeva zadatka u vožnji i sposobnosti vozača oslanja se na teoriju upravljanja vozilom na temelju hipoteze ravnoteže težine zadatka. Naime, teorija

upravljanja vozilima pretpostavlja da vozač stalno donosi odluke što odražava složenost zadataka unutar upravljanih granica [91].

Vozači složenost svakog zadatka doživljavaju različito, od podcjenjivanja do precjenjivanja razine zahtjeva, što dovodi do odstupanja između subjektivne procjene i objektivne razine zahtjeva zadatka u vožnji. Precijenjena razina objektivne složenosti često može rezultirati gubitkom kontrole i posljedično, povećanim rizikom od nesreće. Prije zahtjeva pojedinog zadatka kod pojedinca se često javlja nezdrav negativan osjećaj bijesa koji može rezultirati agresivnim ponašanjem.

Prilagodba ponašanja

Prilagodba ponašanja odnosi se na karakteristiku ljudi da mijenjaju svoje ponašanje prema različitim situacijama. Mogućnosti smanjenja broja prometnih nesreća promjenom ponašanja vozača ovise o vrsti i uzroku prometne nesreće:

- prometne nesreće u kojima je uključeno samo jedno vozilo, tj. pri čemu je vozač u objektivnom konfliktu sa svojim neposrednim okruženjem (objektivnim čimbenicima)
- prometne nesreće u kojima sudjeluju dva ili više vozila ili vozila s korisnicima ceste ili životinje
- prometne nesreće zbog više sile (potres, poplava itd.) ili vanjskog događaja.

Razvoj cestovne infrastrukture (gradnja novih cesta, rekonstrukcija postojećih cesta, povećanje broja prometnih traka itd.) ponekad negativno utječe na prilagodbu ponašanju vozača tijekom vožnje.

Rizično ponašanje u prometu

Rizična vožnja može se tumačiti kao čitav niz pokazatelja, poput počinjenja prometnih prekršaja, vožnje pod utjecajem alkohola, prebrze vožnje, nekorištenja sigurnosnog pojasa, razgovora ili pisanja/čitanja poruka (SMS) na mobitelu te sudjelovanje u prometnim nesrećama.

Vozač je element koji pokreće sustav i koji ima zadatak regulirati njegovu aktivnost, kako bi se prilagodio problemima koji nastaju kao rezultat interakcije između različitih komponenti prometnog sustava.

Na sistemskoj razini države članice Europske unije ukazuju na rizična ponašanja u cestovnom prometu i preventivnim mjerama kojima se želi utjecati na izbor racionalnijeg ponašanja.

Distrakcija

Cestovna okolina pruža informacije vozaču tijekom vožnje, zahtijevajući od vozača maksimalnu koncentraciju i pozornost pri upravljanju vozilom. Međutim, vozači se često bave drugim zadacima koji smanjuju koncentraciju u vožnji (npr. pušenje, traženje postaje na radiju itd.). Distrakcija ili skretanje pažnje s vožnje predstavlja poremećaj kad se vozač usredotočuje na objekt, osobu ili događaj koji nije povezan s vožnjom.

Pojam distrakcije može se općenito prevesti kao nepažnja, a u prometnom smislu predstavlja skretanje pažnje s vožnje, uzrokovane nekim događajem, objektom (uređajem) ili osobom unutar ili izvan vozila, a odnosi se na sve sudionike u prometu. Oblici distrakcije su konzumiranje jela, pića, pušenje, razgovor s putnicima u vozilu, gledanje reklama uz cestu itd.

Istraživanja [92] razlikuje šest vrsta distrakcije: vidljive (vozač orijentira svoju vidljivu pozornost na situacije i stvari koje nisu povezane s upravljanjem vozilom), slušne (odnose se na razgovor vozača mobilnim telefonom ili razgovor s putnicima tijekom vožnje), olfaktorne (odnose se na prehranu tijekom vožnje), kinetske (pozornost vozača odvlače nagli i neočekivani fizički osjećaji, poput dodirivanja insekta po goloj koži) i kognitivne (vozač razmišlja za vrijeme vožnje).

Prema [93] stvarni utjecaj poremećaja pažnje u ponašanju u vožnji ovisi o četiri čimbenika: (1) vozačke karakteristike, (2) složenost vozačkih zadataka, (3) složenost paralelnih zadataka i (4) samoregulacija ponašanja vozača.

Poremećaji pozornosti ne mogu se u potpunosti eliminirati, ali se mogu u velikoj mjeri kontrolirati. Prema [94] u prosjeku se 55 % svih poremećaja pažnje (61 % u vozilu i 31 % u okolini) može izbjeći odgovarajućom samoregulacijom ponašanja. Na jačanje samoregulacije vozačkog ponašanja značajno utječe i edukacija svih sudionika prometa, a posebno vozača. Opisani čimbenici rizika najčešći su uzrok prometne nesreće u kontekstu ljudskog čimbenika, tj. subjektivni čimbenici.

3. MODELI OSPOSOBLJAVANJA VOZAČA I VOZAČKE DOZVOLE

U ovom poglavlju provedena je analiza postojećih modela osposobljavanja vozača motornih vozila koji uključuju programe osposobljavanja, fond sati teorijske i praktične nastave, educiranost predavača u autoškolama.

Obuka kandidata za vozače glavni je čimbenik koji povećava sigurnost u prometu jer kao takav predstavlja opći društveni interes. Tijekom procesa obuke kandidati za vozača uče prometna pravila, ponašanje u prometu i vještine za sigurnu vožnju. Postoje razni modeli osposobljavanja među državama Europske unije, ali i širom svijeta. Osim toga, kandidat za vozača tijekom obuke treba usvojiti pozitivne stavove o prometu, pravilno ponašanje u prometu, načelo odgovornosti, vijest o opasnostima, smisao socijalne odgovornosti, shvaćanje da sigurnost odvijanja prometa ovisi i o vremenskim uvjetima, stanju vozila, kvaliteti i kapacitetu prometnica te međusobnoj suradnji s ostalim sudionicima u prometu itd.

Plan i program osposobljavanja za vozače motornih vozila treba omogućiti kandidatu za vozača upravljati vozilom na takav način da može izbjeći eventualne greške drugih sudionika u prometu, da predvidi njihovo opasno ponašanje te procijeni rizik od prometnih nesreća u dinamičnoj situaciji u prometu. Danas se u svijetu upotrebljavaju modeli formalnog i neformalnog osposobljavanja vozača, a najpoznatiji modeli stjecanja vozačke dozvole su klasični, dvofazni i višefazni model (VMD) (engl. *Graduated Licensing System* (GLS)). Osposobljavanje vozača je proces gdje kandidati uče i usvajaju prometna pravila i etičke norme ponašanja u prometu te upravljanja vozilom. Statistika ukazuje da mladi vozači češće sudjeluju u prometnim nesrećama od starijih i iskusnijih vozača. U nastavku će biti prikazano istraživanje koje je obuhvatilo analizu kvalitete osposobljavanja mladih vozača, utvrditi i vrednovati ključne indikatore sigurnosti vezane za uključivanje mladih vozača u cestovni promet, uzimajući u obzir razinu obrazovanja, socioekonomske, psihosocijalne, kulturološke i druge čimbenike.

3.1 FORMALNO OSPOSOBLJAVANJE VOZAČA

Kod formalnog osposobljavanja kandidata za vozača praktični dio osposobljavanja obavlja se pod nadzorom ovlaštenog instruktora vožnje. Istraživana su različita mišljenja i analize o učinkovitosti osposobljavanja vozača prije vozačke dozvole te je iz [95] zaključeno da formalno osposobljavanje vozača nije dovoljno djelotvorno kad je riječ o sigurnosti mladih vozača jer se osposobljavanjem ne smanjuje broj prometnih nesreća kod mladih vozača. Analiza iz [96] pokazuje da u eksperimentalnom istraživanju u razdoblju od jedne do dvije godine, vozači s formalnim osposobljavanjem imaju 11 % više prometnih nesreća po kilometru od vozača s neformalnim osposobljavanjem. Trenutačno postoji malo jasnih sigurnosnih dokaza o prednosti koje proizlaze iz formalnog osposobljavanja vozača.

Na temelju prethodno navedenih istraživanja i činjenica koje iz toga proizlaze, potrebno je provesti daljnje znanstveno istraživanje, analizu troškova i koristi kako bi se bolje tumačile prednosti formalnog osposobljavanja i osmislio način za poboljšanje učinaka takvog osposobljavanja.

Europski projekti kao što je MERIT5 [97], imaju cilj poboljšanje kompetencije instruktora vožnje koje su iznimno važne za učinkovitost samog učenja. Osim didaktičnih vještina, kompetencije se odnose i na osobna uvjerenja i mišljenja instruktora vožnje o potrebama treninga mladog vozača. Projekt MERIT5 je prvi projekt koji financira Europska unija, a fokusiran je na vještine i kompetencije instruktora vožnje za pitanja sigurnosti na cestama.

3.2 NEFORMALNO OSPOSOBLJAVANJE VOZAČA

Neformalno (privatno) osposobljavanje vozača (poznato kao „vožnja pod pratnjom“) podrazumijeva da je kandidatu za vozača dopušteno da nauči voziti u posebnim uvjetima, pod nadzorom iskusnog vozača.

Prema istraživanju [98] u Ontariju (Kanada) mladi vozači koji su sudjelovali u formalnom osposobljavanju, a imali su certifikat autoškole, sudjelovali su u 44 % više prometnih nesreća od onih koji nisu imali certifikat autoškole. Iz istraživanja [99] je zaključeno da je potrebno odvoziti 5000 do 7000 kilometara prije dozvole kako bi se značajno smanjio broj prometnih nesreća nakon stjecanja dozvole.

U studiji istraživanja iz Švedske [100] pokazano je da je razina prakticiranja ostala približno ista u 2000. godini, kao što je bila u početnoj evaluaciji studije za razdoblje od 1991. do 1997.

3.3 GDE MATRICE

U okviru projekta EU-a GADGET (engl. *Guarding Automobile Drivers through Guidance, Education and Technology*) [101] razvijena je GDE matrica (engl.*Goals for Driver Education*). U procesu stjecanja vozačke dozvole treba promatrati ciljeve programa edukacije vozača kao što je prikazano na GDE matrici (tablica 3-1).

Tablica 3- 1 Prikaz GDE matrice

	Znanje i vještina	Aspekt povećanja rizika	Samoprocjena
Ciljevi za život Vještine za život	Razumijevanje važnosti stila života, dobne skupine, kultura, socijalne okolnosti itd.	Razumijevanje važnosti osjećaja za potrebe, prihvaćanje rizika, grupne norme, pritisak vršnjaka itd.	Razumijevanje važnosti samokritike, kompetencije, osobnih preduvjeta za sigurnu vožnju, poticanja kontrole itd.
Ciljevi u okruženju vožnje	Razumijevanje važnosti odabira vrste prijevoza, dnevno vrijeme, motiviranje za vožnju, planiranje rute itd.	Poznavanje utjecaja alkohola, umor, nizak stupanj koeficijenta trenja/prianjanja na kolniku, prometna gužva, putnici istih godina itd.	Poznavanje važnosti osobne motivacije, samokritična razmišljanja itd.
Vožnja u prometu	Svladavanje prometnih pravila, percepcija opasnosti itd. Automatizacija elemenata u procesu vožnje, suradnja s drugim vozačima itd.	Poznavanje rizika povezanih s nepoštovanjem pravila, vožnja s nedovoljnim sigurnosnim razmakom u odnosu na vozilo ispred, nizak stupanj koeficijenta trenja/prianjanja na kolniku, ugroženi sudionici u prometu itd.	Usmjeravanje vozačkih sposobnosti, razvoj osobnog stila vožnje itd.
Kontrola vozila	Svladavanje funkcioniranja vozila, sustavi zaštite, kontrola vozila, poznavanje utjecaja fizikalnih zakona itd.	Poznavanje rizika povezanog s nekorištenjem sigurnosnog pojasa, kvar vozila, istrošene gume itd.	Usmjeravanje vještina kontrole vozila

Izvor:[101]

GDE matrica pruža hijerarhijski shematski zadatak vozača, samoprocjenu situacije u kojoj se vozač nalazi tijekom vožnje, uključujući preduvjete, stavove, sposobnost, potrebe, odluke i ponašanje. Zadaci vozača definirani su u četiri razine, koje su opisali Keskinen u [102] i Hatakka u [103], koje se primjenjuju u projektu GADGET:

1) Razina 4 ciljevi za život i vještine za život: najviša razina odnosi se na osobnu motivaciju i nastojanja sa šireg stajališta.
2) Razina 3 ciljevi u okruženju vožnje: na trećoj razini usredotočenost je na ciljeve vožnje i uvjete u kojima se obavlja vožnja.
3) Razina 2 vožnja u prometnim situacijama: da te mogućnosti na trećoj razini imaju utjecaja na situacije koje će se dogoditi u stvarnom prometu, na razinu rizika te koliko će vozač biti u mogućnosti svladati određene prometne situacije.
4) Razina 1 kontrola vozila: najniža razina fokusirana na vozilo i na njegovo djelovanje.

3.4 NAPREDNO OSPOSOBLJAVANJE VOZAČA

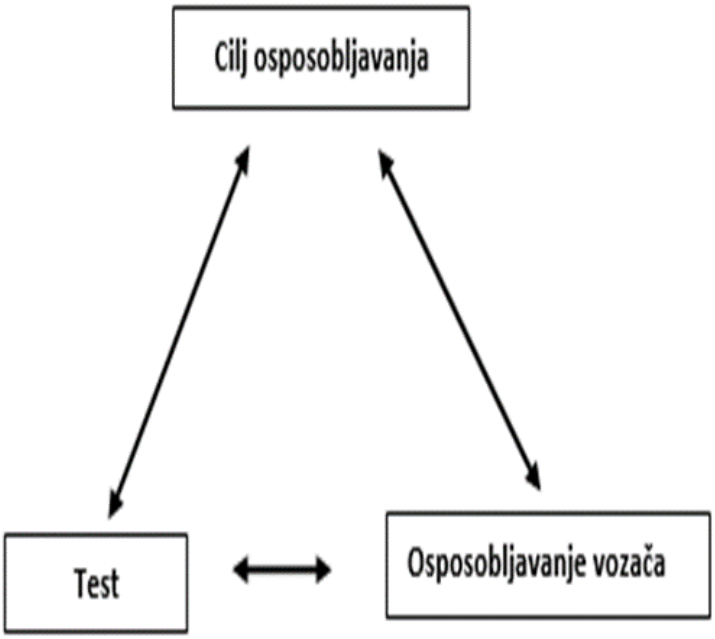
Početno osposobljavanje ne jamči mladom vozaču da će steći dovoljno iskustva u vožnji kako bi pravilno postupio u svakoj prometnoj situaciji. Na temelju naprednog osposobljavanja i provedenih istraživanja [104] zaključeno je da se kod osposobljavanja pažnja o rizicima ne treba usredotočiti na kontrolu vozila i manevriranje jer to dovodi do prekomjerne dekoncentracije, umjesto toga treba unaprijediti znanje, iskustvo i prepoznavanje opasnosti.

U projektu Europske unije ADVANCED [105] predstavljene su smjernice utemeljene na naprednom osposobljavanju nakon stjecanja vozačke dozvole. U okviru projekta provedena je obuka „nakon stjecanja vozačke dozvole“ (engl. *Post-licence training*) kojoj je cilj spriječiti vozače da postanu previše samouvjereni kad je u pitanju vožnja.

3.5 POVEZANOST KOMPONENTI OSPOSOBLJAVANJA

Na dijagramu 3-1 predstavljene su komponente osposobljavanja vozača, testiranja i ciljevi osposobljavanja kao zasebne komponente. Međutim, da bi osposobljavanje bilo učinkovito, te komponente trebaju biti usko povezane.

Prema [106] ciljevi osposobljavanja, koji su često prikazivani u službenom nastavnom planu i programu kod stjecanja vozačke dozvole, odnose se na ciljeve koji moraju biti ispunjeni da se postane siguran vozač, a to bi trebalo predstavljati temelj pri osposobljavanju vozača i polaganju vozačkog ispita.



Dijagram 3- 1 Trokut edukacije vozača

Izvor: [107]

Prema istraživanju iz [107] u slučaju neusklađenosti navedenih komponenti (dijagram 3-1) ispitivanje može negativno utjecati na sadržaj edukacije. U slučaju kad pojedine komponente osposobljavanja nisu kvalitetno testirane, posljedica je nedostatak pažnje kod vozača i instruktora vožnje tijekom osposobljavanja.

Modeli osposobljavanja vozača motornih vozila prikazani su u tablici 3-2.

Tablica 3- 2 Modeli osposobljavanja

PRVI MODEL	**DESKRIPCIJA**
OSPOSOBLJAVANJE KANDIDATA ZA VOZAČA OBAVLJA SE PO SLUŽBENOM PLANU I PROGRAMU	Po ovom modelu osposobljavanje uključuje obveznu teoriju i praktičnu nastavu u profesionalnoj autoškoli. Obvezno je pohađanje minimalnog broja sati iz teorijske i praktične nastave. Praktična nastava vrši se pod nadzorom ovlaštenog instruktora vožnje. Ovaj model upotrebljavaju u Austriji, Bugarskoj, Estoniji, Hrvatskoj, Češkoj, Danskoj, Francuskoj, Njemačkoj, Norveškoj, Švedskoj, Švicarskoj, Kosovu. Minimalni sati nastave kreću se od 10 do 40 sati teorijske nastave i od 12 do 35 sati praktičke nastave.
DRUGI MODEL	**DESKRIPCIJA**
OSPOSOBLJAVANJE KANDIDATA ZA VOZAČA, SAMO PRAKTIČNA NASTAVA JE OBVEZNA	Kod ovog modela osposobljavanja za vozača samo praktična nastava je obvezna dok teorijska nastava nije. Primjerice, u Litvi je obvezno pohađanje teorijskih predavanja samo ako kandidat nema barem srednju stručnu spremu. U Norveškoj ne postoji klasična teorijska nastava. Ovaj se model upotrebljava u Francuskoj, predviđeno je minimalno 20 sati.
TREĆI MODEL	**DESKRIPCIJA**
OSPOSOBLJAVANJE KANDIDATA ZA VOZAČA, NIJE PREDVIĐENA SATNICA IZ TEORIJSKE I PRAKTIČNE NASTAVE	Kod ovog modela osposobljavanja kandidata za vozača motornih vozila nije predviđen minimalni broj sati iz teorijske i praktične nastave. Prosječan broj sati prije praktičnog ispita kreće se od 22 do 50 sati. U Quebecu je umjesto sati vožnje prije vozačkog ispita, predviđeno 2522 km za vozače koji se osposobljavaju u autoškoli, dok je za ostale vozače to 3845 km. Ovaj se model upotrebljava u: Belgiji, Cipru, Velikoj Britaniji, Irskoj, Malti, Monaku, Nizozemskoj, Novom Zelandu, Sjevernoj Irskoj, Quebecu (Kanada), Španjolskoj, Švedskoj, Švicarskoj (uvjetno), Victoriji (Australija).
ČETVRTI MODEL	**DESKRIPCIJA**
OSPOSOBLJAVANJE UZ PRATNJU DRUGE OSOBE	Kod ovog modela osposobljavanje vozač obavlja pod nadzorom neke osobe. Postoje određeni uvjeti, ograničenja i zabrane za vožnju koja se odnosi i na vozača i na osobe iz pratnje. Isto tako, postoje ograničenja na vozilu koja se odnose na snagu, obujam itd. Ovaj model upotrebljava se na početku osposobljavanja vozača, u međufazama osposobljavanja vozača, prije polaganja vozačkog ispita ili nakon stjecanja vozačke dozvole, tzv. privremene dozvole. Ovaj se model upotrebljava u: Austriji, Belgiji, Češkoj, Danskoj, Estoniji, Finskoj, Francuskoj, Njemačkoj, Velikoj Britaniji, Islandu, Irskoj, Latviji, Litvi, Luksemburgu, Malti, Nizozemskoj, Novom Zelandu, Sjevernoj Irskoj, Norveškoj, Quebecu (Kanada), Sloveniji, Španjolskoj, Švedskoj, Švicarskoj, Victoriji (Australija).

Izvor: Izradio autor

3.6 MODELI VOZAČKE DOZVOLE

Najpoznatiji modeli vozačke dozvole za osobna vozila su:

- klasični model
- dvofazni model i
- višefazni model.

Tradicionalni klasični model stjecanja vozačke dozvole u najvećoj se mjeri upotrebljava u Europi, u većem dijelu zemalja zapadnog Balkana, uključujući i Republiku Kosovo. Dvofazni model vozačke dozvole upotrebljava se u nekoliko europskih zemalja, kao što su Austrija, Finska, Luksemburg itd. Višefazni model vozačke dozvole u velikoj se mjeri upotrebljava u Australiji, Kanadi, Novom Zelandu i SAD-u.

Osnovni oblici stjecanja vozačke dozvole po fazama prema [108] uvedeni su još 1960-ih i 1970-ih. Postoje različiti modeli VMD-a koji se upotrebljavaju u SAD-u, Novom Zelandu, Australiji, Kanadi. Isto se tako i u Europi upotrebljavaju neki elementi VMD-a (Finskoj, Sjevernoj Irskoj, Norveškoj, Švedskoj itd.) gdje se postižu dobri rezultati u smanjivanju prometnih nesreća.

3.6.1 Klasični model

U ovom modelu vozač početnik odmah dobije trajnu vozačku dozvolu nakon polaganja vozačkog ispita. Kao što je opisano u [109], ovaj sustav nema posebne uvjete i ograničenja. Klasični model vozačke dozvola često se naziva „jednofazni sustav vozačke dozvole“.

Preduvjet za ovaj sustav jest obvezno osposobljavanje vozača motornih vozila prije polaganja vozačkog ispita iz teorije i vožnje. Danas je većina zemalja koje upotrebljavaju klasični sustav vozačke dozvole, uvela probne dozvole. Dakle, vozač početnik dobije trajnu vozačku dozvolu nakon što istekne probno razdoblje koje traje dvije ili više godina, ovisno o zemljama koje upotrebljavaju ovaj sustav. Kod nekih zemalja probno razdoblje ima posebna ograničenja koja se odnose na obujam motora, brzinu, vožnju pod utjecajem alkohola itd.

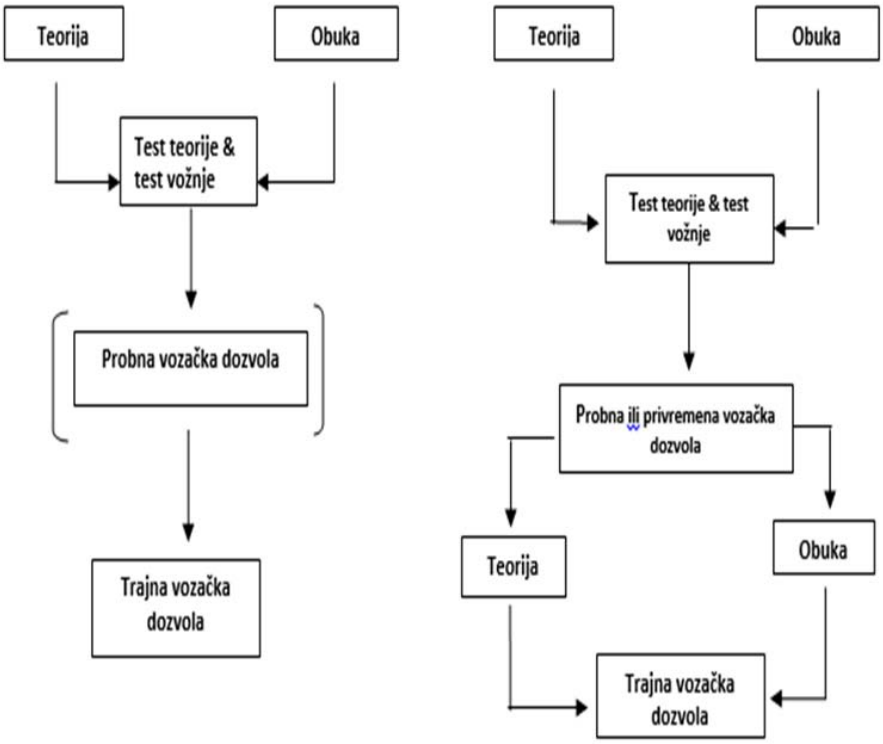
3.6.2 Dvofazni model

Glavna razlika ovog sustava u odnosu na klasični sustav vozačke dozvole jest taj što kandidati moraju proći dvije faze prije dobivanja trajne vozačke dozvole. Kod ovog sustava

prva faza podrazumijeva obvezno polaganje vozačkog ispita iz teorije i vožnje. Nakon polaganja ispita započinje druga faza gdje vozač dobiva probnu ili privremenu vozačku dozvolu. Ova vozačka dozvola omogućuje vozaču da se vozi samostalno, ali pod posebnim uvjetima vožnje.

Nakon završetka druge faze vozač stječe trajnu vozačku dozvolu pod dodatnim uvjetima, tj. osposobljavanje iz praktičnog dijela i polaganje vozačkog ispita iz teorijskog dijela.

Klasični i dvofazni sustav vozačke dozvole prikazani su na dijagramu 3-2.



Dijagram 3- 2 Struktura klasičnog (a) i dvofaznog sustava (b) vozačke dozvole

Izvor: [109]

3.6.3 Višefazni model (VMD)

Kod ovog modela vozač u fazama stječe trajnu vozačku dozvolu, i to obično u tri faze. Za pojedine faze postoje ograničenja koja se odnose na vožnju i koja će se postupno ukinuti kad vozač stekne određeno iskustvo u vožnji. Ta ograničenja su različita, ovisno o zemljama koje upotrebljavaju ovaj model stjecanja vozačke dozvole.

Prema [110] višefazni model prvenstveno je namijenjen rješavanju neiskustva kao komponente rizika kod mladih vozača, a sekundarno ublažavanju preuzetih rizika, što djelomično ovisi o dobi vozača. Osnovni je princip da novi vozači steknu iskustvo u vožnji pod uvjetima niskog rizika. Istraživanje u okviru studije [111], koja je provedena u vezi s modelom VMD, imalo je značajan doprinos smanjenju prometnih nesreća s poginulim osobama, ali uz velike promjene.

Neke studije pokazuju smanjenje prometnih nesreća do 4 %, dok druge donose čak i do 60 % manje prometnih nesreća. Istraživanje [112] koje se odnosi na uporabu modela VMD prikazuje da se broj prometnih nesreća s teškim ozljedama i tragičnim posljedicama u kojima su sudjelovali vozači od 15 do 24 godina gotovo prepolovio.

3.7 POSTOJEĆI PROBLEMI SUSTAVA OSPOSOBLJAVANJA VOZAČA I VOZAČKOG ISPITA U REPUBLICI KOSOVU

Zakonodavstvo Republike Kosova uređuje proces osposobljavanja vozača i dobivanja vozačke dozvole, koji nije u potpunosti usklađen s III. Direktivom Europske unije koja se odnosi na vozačke dozvole [113]. Kosovo je član CIECA od 2008. godine.

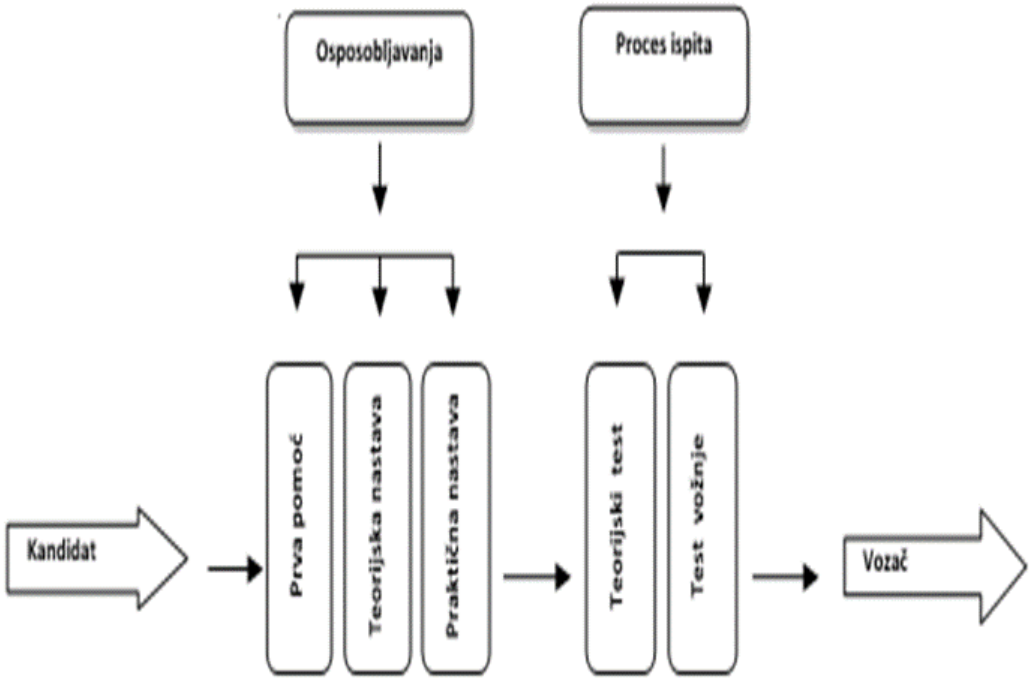
U postojećem sustavu osposobljavanja vozača postoje određeni problemi koji se odnose na:

- **velik broj autoškola,** koje rade po načelu slobodnog tržišta te ne postoji baza podataka koja će pratiti rad autoškole.
- **teorijsku i praktičnu nastavu** – vrlo je mali fond sati iz teorijske i praktične nastave, po 20 sati, a to je najmanji broj sati kad ga se usporedi sa zemljama regije. U okviru 20 sati nije moguće kvalitetno pratiti i savladati proces teorijske nastave, ne upotrebljava se suvremena tehnologija tijekom predavanja, ne upotrebljavaju se vježbe na autosimulatorima. Praktična nastava može početi bez polaganja testa iz teorije.
- **djelatnike autoškole** – stručni voditelj autoškole obavlja i administrativne poslove. Broj predavača je neograničen i svake se godine povećava. Na području Republike Kosova ima preko 337 predavača teorijskog dijela obuke. Za licenciranje instruktora vožnje kriteriji su veoma liberalni, s načelom slobodnog tržišta. Sa zanimanjem instruktora vožnje postoji oko 1344 osobe.

- **vozački ispit** – minimalni zahtjevi za vozački ispit nisu u potpunosti usklađeni s Prilogom III u [113]. Ispit za vozača organizira se i izvodi u sedam ispitnih centara čiji objekti ne ispunjavaju uvjete za rad. Većina centara nalazi se u objektima autobusnih kolodvora te ne postoje baze podataka o evidencijama kandidata koji polažu vozački ispit. Praktični se ispit polaže na poligonu i na javnoj cesti.
- **stručno usavršavanje predavača, instruktora vožnje i ovlaštenog ispitivača**

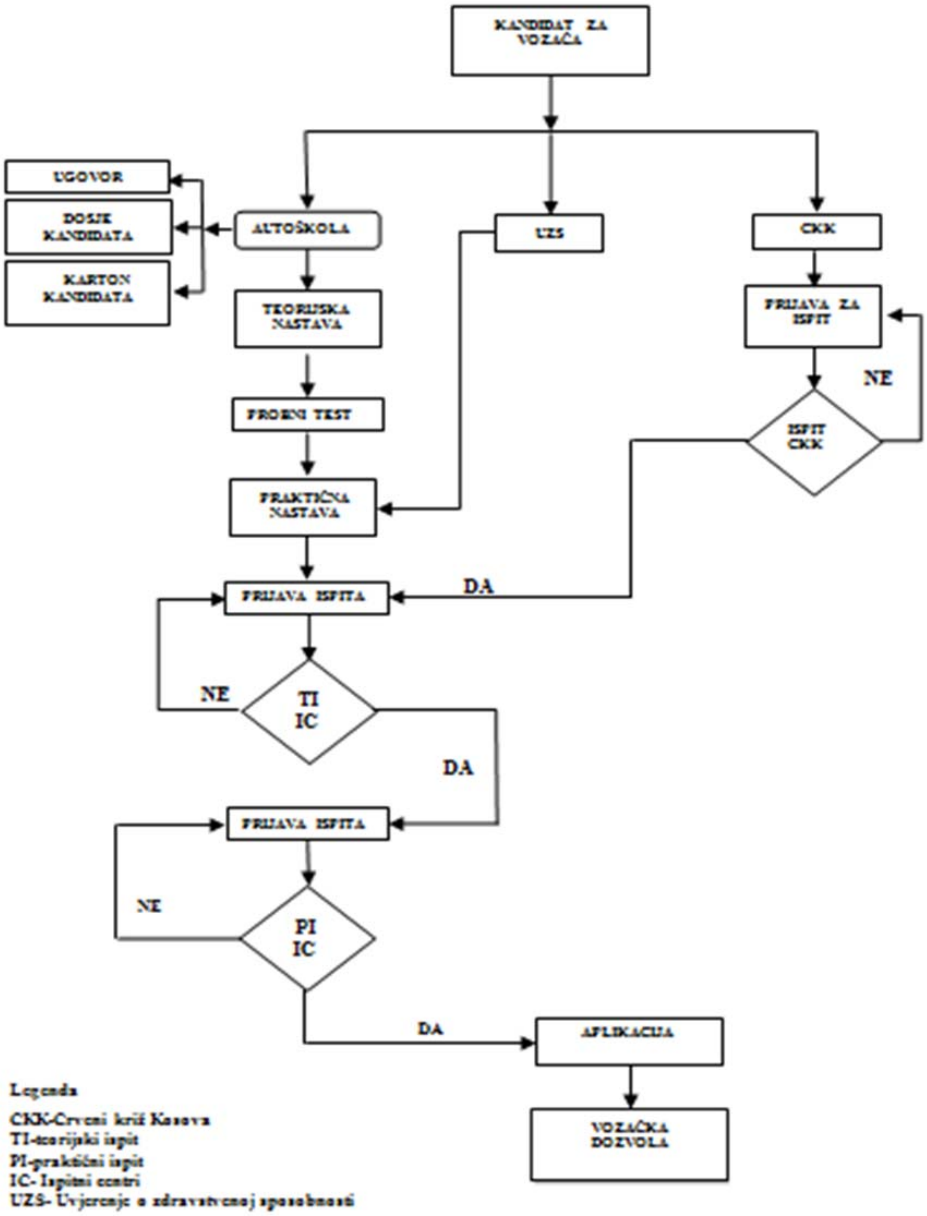
  S obzirom na to da do sada ne postoji baza podataka, otežano je praćenje i kontrola učinka instruktora vožnje i predavača. Licencirani ispitivači ne ispunjavaju minimalne standarde, utvrđene Prilogom IV u [113] .
- **stjecanje vozačke dozvole** – uvjeti i kriteriji su u suprotnosti sa [113]. Ne postoji stjecanje vozačke dozvole po fazama, niti vožnja pod pratnjom te nema obuke nakon stjecanja vozačke dozvole za vozače početnike.

Sustav osposobljavanja vozača prikazan je na dijagramu 3-3, a proces stjecanja vozačke dozvole na području Republike Kosova prikazan je na dijagramu 3-4.



Dijagram 3- 3 Sustav osposobljavanja vozača motornih vozila

Izvor: Izradio autor



Dijagram 3- 4 Postojeći proces stjecanja vozačke dozvole u Republici Kosovu

Izvor: Izradio autor

3.8 EDUKACIJA INSTRUKTORA VOŽNJE

U razdoblju 2004. – 2007. na području EU-a proveden je projekt MERIT (engl. *Minimum European Requirements for Driving Instructor Training*) kojim su postavljeni minimalni standardi za instruktore vožnje te njihove kompetencije (Preporuke o minimalnim zahtjevima za instruktore vožnje, Bruxelles, Belgija, 2007., str. 67 – 68).

U Danskoj, Estoniji, Velikoj Britaniji, Grčkoj, Sjevernoj Irskoj i Slovačkoj ne postoje zahtjevi koji se odnose na edukaciju instruktora vožnje**.** Za neke zemlje potrebna je edukacija nižeg srednjeg stupnja (do 16 godina) ili viša srednja škola (18 godina).

Uzimajući u obzir da neke od spomenutih država EU-a i neke razvijene zapadne zemlje nemaju obvezu osposobljavanja kandidata za vozača pod nadzorom instruktora vožnje te unatoč tomu imaju visoku razinu sigurnosti u prometu, svjesnost i stvaranje pozitivnog stava o prometu ima presudnu ulogu u sigurnosti mladih vozača i svih sudionika u prometu.

Razina edukacije instruktora vožnje u Republici Kosovu i u državama regije, uključujući Hrvatsku i Sloveniju kao članice EU-a, jest srednja škola i specijalni tečaj za stjecanje zvanja instruktora vožnje.

3.9 KOMPARATIVNA ANALIZA OSPOSOBLJAVANJA KANDIDATA ZA VOZAČA I VOZAČKOG ISPITA

Osposobljavanje kandidata za vozača ima presudnu ulogu u povećanju razine sigurnosti u prometu jer predstavlja preliminarnu fazu u kojoj kandidati za vozača stječu osnovno znanje o prometu prije polaganja teorijskog i praktičnog ispita.

U većini regionalnih zemalja osposobljavanje i polaganje vozačkog ispita uključeni su u zakon o sigurnosti prometa na cestama.

Kako bi se povećala kvaliteta osnovnih obuka za vozače, Europska unija financirala je projekt *New Models* koji osigurava smanjenje potencijalnog rizika u nastanku prometnih nesreća (*BASIC Basic Training Driving: New Models, 2001–2003*).

Europska Direktiva 2006/126 od 21. prosinca 2006. za vozačku dozvolu utvrđuje kriterije za dobivanje vozačke dozvole, psihofizičke kriterije za kandidata vozača, sadržaj teorijskih i praktičnih ispita, kriterije za vozila koja se rabe za praktični ispit, kriterije vozačkog ispita i druga pitanja [113].

U nastavku je dana komparativna analiza modela osposobljavanja vozača i polaganja vozačkih ispita u Republici Kosovu i zemljama regije: Albanija, Slovenija, Hrvatska, Bosna i Hercegovina, Crna Gora, Makedonija i Srbija.

- **Republika Kosovo**

  Osposobljavanje vozača realizira se u autoškolama koje imaju licencu izdanu od strane Ministarstva za infrastrukturu i transport na temelju plana i programa – kurikula [114]. Osposobljavanje je potrebno proći prije polaganja vozačkog ispita. Teorijsko i praktično osposobljavanje traje 20 sati. Kandidat može započeti praktičnu obuku i prije polaganja teorijskoga vozačkog ispita. Teorijski ispit se izvodi testom, a ove je godine započeo projekt *e-sustav* koji se odnosi na polaganje vozačkog ispita putem računala. Praktični i teorijski ispit drži ovlašteni ispitivač. Praktični ispit izvodi se na poligonu i na javnoj cesti. Ograničenja i zabrane predviđeni su za mlade vozače, koji, primjerice, smiju voziti na autocesti do 110 km/h [115].
- **Albanija**

  Osposobljavanje kandidata realizira se u autoškolama licenciranim od strane Ministarstva prometa na temelju plana i programa [116], [117]. Kandidat mora proći najmanje 56 sati teorijske i 36 sati praktične obuke prije polaganja vozačkog ispita. Nakon što kandidat završi obuku, može pristupiti polaganju teorijskog i praktičnog ispita. Ispit održava komisija koju je imenovalo nadležno tijelo. Teorijski ispit se provodi putem računala, dok se praktični ispit izvodi na poligonu, a potom na javnoj cesti.
- **Hrvatska**

  Osposobljavanje kandidata provode licencirane autoškole na temelju plana i programa [118], [119]. Teorijska obuka obuhvaća 30 sati predavanja, a praktična nastava 30 sati vožnje. Ispite drži licencirani ispitivač iz HAK-a (Hrvatski autoklub). Teorijski ispit se provodi putem računala. Praktični ispit se izvodi prvo na poligonu, a potom na javnim cestama. Postoji nekoliko ograničenja i zabrana za nove vozače.
- **Slovenija**

  Teorijski dio i praktični dio osposobljavanja kandidata za vozača sastoji se od najmanje 20 sati. Ispit za vozačku dozvolu održava se pred nadležnom komisijom Ministarstva. Teorijski ispit izvodi se na računalu. Praktični ispit održava se prvo na poligonu, a potom na javnoj cesti [120], [121].
- **Bosna i Hercegovina**

Osposobljavanje kandidata nadgleda nadležno Ministarstvo za promet. Teorijsko osposobljavanje vozača traje 30 sati i 8 sati vježbi, dok praktična nastava traje najmanje 30 sati. Ispit za vozačku dozvolu polaže se ispred povjerenstva koje imenuje Ministarstvo. Praktični ispit održava se na poligonu, a potom na javnoj cesti [122], [123].

- **Crna Gora**

  Osposobljavanje vozača obavlja se u autoškoli na temelju nastavnog plana vozačke obuke. Teorijski dio sastoji se od 40 sati, a praktični od 30 sati. Teorijski i praktični ispit polažu se pred povjerenstvom [124], [125].

- **Makedonija**

  Osposobljavanja kandidata za vozača nadgleda nadležno Ministarstvo. Teorijsko osposobljavanje traje 20 sati, dok praktično traje najmanje 36 sati. Praktični ispit održava se na poligonu, a potom na javnoj cesti [126], [127].

- **Srbija**

  Osposobljavanje vozača održava se u ovlaštenim autoškolama na temelju plana i programa. Teorijsko osposobljavanje traje 30 sati, a praktični se dio sastoji od 30 sati i 10 sati vježbi, ukupno 40 sati praktične nastave. Praktično osposobljavanje može započeti nakon što kandidat za vozača položi teorijski ispit pred povjerenstvom. Prvi dio praktičnog ispita održava se na poligonu, a drugi dio na javnoj cesti [128], [129].

Europska direktiva 2006/126 za vozačku dozvolu utvrđuje uvjete i kriterije za polaganje ispita. Praktični se ispit polaže pred ovlaštenim ispitivačem koji mora ispunjavati kriterije na temelju ove direktive.

Tablica 3- 3 Osposobljavanja kandidata za vozače u Republici Kosovu i zemljama regije

Zemlja	Osposobljavanja u autoškoli	Teorijski satovi osposobljavanja	Praktični satovi osposobljavanja	Uvjeti za početak praktičnog osposobljavanja vozača
Rep. Kosovo	DA	20	20	Probni test
Albanija	DA	56	30	Polaganje teorijskog ispita
Hrvatska	DA	30	30	Polaganje teorijskog ispita
Slovenija	DA	20	20	Polaganje teorijskog ispita
Crna Gora	DA	40	30	Polaganje teorijskog ispita
***BiH**	DA	30	30	Polaganje teorijskog ispita
Makedonija	DA	20	36	Polaganje teorijskog ispita
Srbija	DA	30	30+10	Polaganje teorijskog ispita

Izvor: [114], [116], [117], [118], [119], [120]. [121], [122]. [123], [124]. [125], [126]. [127], [128] i [129]

Iz tablice se uočava da se osposobljavanje kandidata za vozača održava u ovlaštenim autoškolama. Na Kosovu i u Sloveniji broj sati teorijske i praktične nastave je 20 sati, dok je u većini zemalja od 30 do 40 sati. Jedan je od glavnih kriterija za početak praktičnog osposobljavanja u svim zemljama regije polaganje teorijskog ispita, osim u Republici Kosovu.

Tablica 3- 4 Proces ispitivanja za vozačke dozvole

Zemlja	Institucija za organizaciju polaganja vozačkog ispita	Ispit	Ispit na poligon	Organičenje i zabrana za mlade vozača
Rep. Kosovo	Ministarstvo	Ispitivač	Da	Da
Albanija	Ministarstvo	Povjerenstvo	Da	Ne
Hrvatska	Agencija	Ispitivač	Da	Da
Slovenija	Ministarstvo	Povjerenstva	Da	/
Crna Gora	Ministarstvo	Povjerenstvo	Da	Ne
BiH	Ministarstvo	Povjerenstvo	Da	/
Makedonija	Agencija	Povjerenstvo	Da	/
Srbija	Agencija	Povjerenstvo	Da	Ne

Izvor: [114], [116], [117], [118], [119], [120]. [121], [122]. [123], [124]. [125], [126]. [127], [128] i [129]

To je važno jer kandidat za vozača polaganjem teorijskog ispita stječe teorijsko znanje o prometnim propisima i ponašanju u procesu ispitivanja za dobivanje vozačke dozvole, kako je prikazano u Tablici 3-4.

Iz tablice se uočava da na Kosovu, u Sloveniji, Crnoj Gori i BiH ispit za vozačku dozvolu organizira nadležno Ministarstvo, a u Hrvatskoj, Makedoniji i Srbiji organizira ga agencija.

Nakon proučavanja i analize procesa osposobljavanja kandidata za vozača i polaganja vozačkog ispita može se zaključiti:

- Kosovo i Hrvatska imaju ograničenja i zabrane radi zaštite mladih vozača.
- U svim zemalja regije osposobljavanje kandidata za vozača održava se u ovlaštenim autoškolama na temelju plana i programa odobrenog od nadležnog tijela.
- Na Kosovu teorijsko osposobljavanje traje 20 sati, kao i praktični dio, dok je u većini zemalja regije broj sati osposobljavanja vozača od 30 do 40 sati.
- Izuzev Kosova, kriterij za početak praktične obuke jest polaganje teorijskog ispita pred nadležnom komisijom/ispitivačima, dok se na Kosovu polaže probni test koji priprema autoškola u kojoj je kandidat završio osposobljavanje iz teorijskog dijela.
- Ispit za vozačku dozvolu organizira i održava nadležno ministarstvo na Kosovu, u Sloveniji, BiH, Crnoj Gori, dok u Makedoniji, Hrvatskoj i Srbiji ispit organizira agencija.
- Ispit se polaže pred povjerenstvom, primjerice u Albaniji, Srbiji, Crnoj Gori itd., dok se na Kosovu i u Hrvatskoj ispit polaže pod nadzorom ispitivača, kao i u većini zemalja EU-a.

Elementi osposobljavanja ukazuju na povezanost između znanja, vještina i procjene rizika od prometnih nesreća te predstavljaju okosnicu i motiv za istraživanja koja su realizirana u okviru ovoga rada.

4. ANALIZA PROMETNIH NESREĆA U KOJIMA SUDJELUJU MLADI VOZAČI

U ovom poglavlju provedena je analiza vrsta i uzroka prometnih nesreća s poginulim vozačima, s posebnim naglaskom na prometne nesreće u kojima su sudjelovali mladi vozači (od 16 do 24 godine) radi identificiranja subjektivnih i objektivnih čimbenika koji povećavaju rizik od prometnih nesreća.

4.1 AKTUALNI PROBLEM SIGURNOSTI MLADIH VOZAČA

Mladi vozači predstavljaju jednu od specifičnih rizičnih grupa kategorije sudionika u prometu. Na bazi statistike, prometne su nesreće jedan od vodećih čimbenika ozlijeđenih i smrtno stradalih među mladima do 24 godine [133]. Stopa prometnih nesreća kod mladih vozača najviša je tijekom prve godine nakon stjecanja vozačke dozvole, zatim postupno opada u periodu koji prosječno traje oko dvije godine. Zato su mnoge zemlje u Zakon o sigurnosti u cestovnom prometu uvele ograničenja i zabrane za vozače u razdoblju od dvije godine od dana izdavanja vozačke dozvole, među njima i Republika Kosovo.

Kako su vještine nužne za adekvatno uočavanje rizika u prometu, kod mladih vozača često nedostaje neophodna percepcija opasnosti i procjena rizika na cesti. Također, mladi vozači su više zastupljeni u rizičnim situacijama, kao što su velike brzine i vožnja s nedovoljnim razmakom.

Najznačajniji elementi rizičnih oblika ponašanja mladih vozača odnose se na vožnju pod utjecajem alkohola i uporabu mobilnih telefona tijekom vožnje (razgovor ili pisanje/čitanje poruka).

Kad je riječ o mladim vozačima, pokazalo se da su najefikasnije strategije u prevenciji prometnih nesreća programi poticanja i nagrada, pod uvjetom da se unaprijed temeljito planiraju i sustavno provedu. Svakako, trebalo bi uzeti u obzir da postoje i izvjesna ograničenja u općoj primjeni takvih mjera, u odnosu na različite socijalne, ekonomske, političke i administrativne razlike između različitih zemalja.

4.2 KOMPARATIVNA ANALIZA PROMETNIH NESREĆA REPUBLIKE KOSOVA SA ZEMLJAMA REGIJE

Analiza prometnih nesreća u Republici Kosovu u odnosu na zemlje u regiji obuhvaća razdoblje od 2014. do 2018. godine s posebnim naglaskom na poginule osobe u cestovnom prometu.

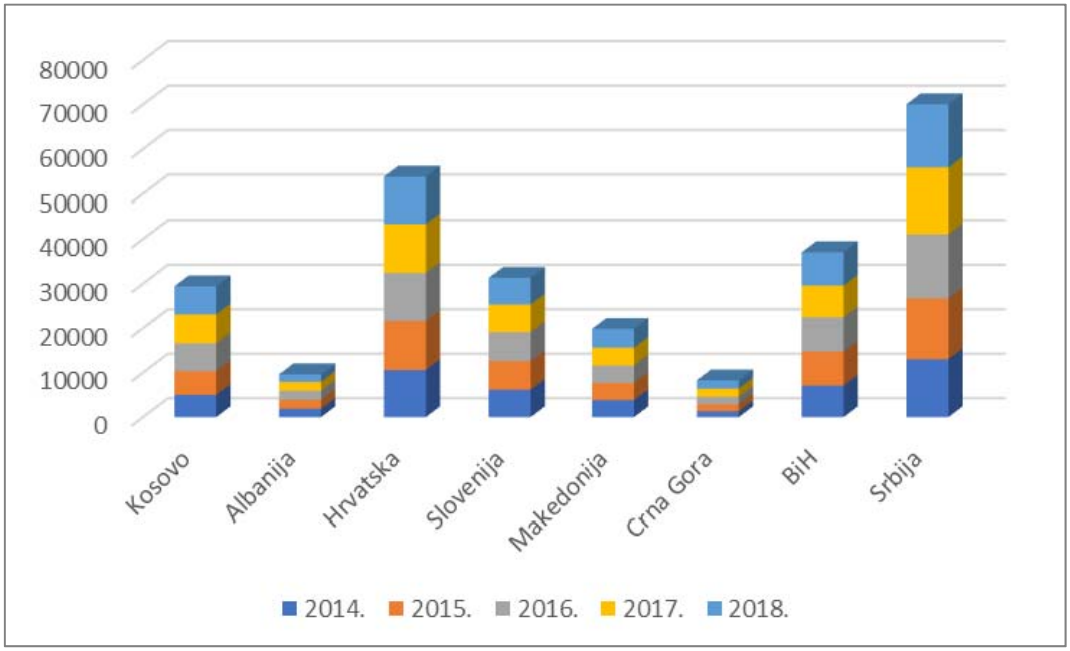
4.2.1 Analiza prometnih nesreća s nastradalim osobama 2014. – 2018. godine

U tablici 4-1 prikazan je broj nastradalih osoba u prometnim nesrećama na području Republike Kosova i zemalja u regiji [130], [131], [132], [133], [134], [135], [136], [137], [138].

Tablica 4- 1 Broj nastradalih osoba u prometnim nesrećama na području Rep. Kosova i zemalja u regiji

Zemlja	***Godina***					***UKUPNO***	***Prosjek***
	2014.	**2015.**	**2016.**	**2017.**	**2018.**		
Kosovo	4987	5390	6229	6512	6317	29 435	5887
Albanija	1914	1992	2033	1978	1718	9635	1927
Hrvatska	10 607	11 038	10 779	10 939	10 450	53 813	10 763
Slovenija	6167	6473	6495	6185	6014	31 334	6267
Makedonija	3853	3854	3904	4019	4223	19 853	3971
Crna Gora	1334	1555	1698	1831	1855	8273	1655
BiH	7106	7627	7716	7135	7494	37 078	7416
Srbija	13 044	13 656	14 397	14 756	14 223	70 076	14 015

Izvor: [130], [131], [132], [133], [134], [135], [136], [137], [138]



Dijagram 4- 1 Broj nastradalih osoba u prometnim nesrećama na području Rep. Kosova i zemalja u regiji

Izvor: [130], [131], [132], [133], [134], [135], [136], [137], [138]

Iz dijagrama 4-1 uočava se da je za analizirano razdoblje od pet godina na području osam zemalja broj nastradalih osoba u prometnih nesrećama najveći u Srbiji (70 076), slijedi ju Hrvatska s 53 813 nastradalih osoba. Republika Kosovo je na petom mjestu s 29 435 nastradalih osoba.

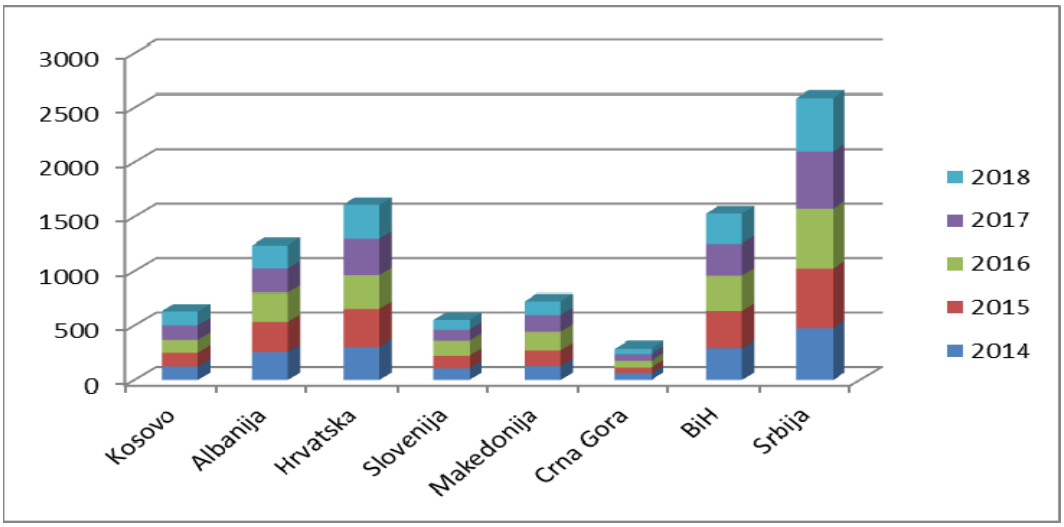
4.2.2 Analiza poginulih osoba u prometnim nesrećama u periodu 2014. – 2018. godine

U tablici 4-2 prikazan je broj poginulih osoba u prometnim nesrećama na području Republike Kosova i zemalja u regiji.

Tablica 4- 2 Broj poginulih osoba u prometnim nesrećama na području Rep. Kosova i zemalja u regiji

Zemlja	Godina					Ukupno	Prosjek
	2014.	2015.	2016.	2017.	2018.		
Kosovo	127	129	110	137	128	631	126
Albanija	264	270	269	222	213	1238	248
Hrvatska	308	348	307	331	317	1611	322
Slovenija	108	120	130	104	91	553	111
Makedonija	130	148	165	155	129	727	145
Crna Gora	65	51	65	63	48	292	58
BiH	297	341	321	295	277	1531	306
Srbija	476	548	551	525	489	2589	517,8

Izvor: [130], [131], [132], [133], [134], [135], [136], [137], [138].



Dijagram 4-2 Broj poginulih osoba u prometnim nesrećama na području Rep. Kosova i zemalja u regiji

Izvor: [130], [131], [132], [133], [134], [135], [136], [137], [138]

Iz Tablice 4-2 vidljivo je da je u Republici Kosovu najviše osoba u prometu poginulo u 2017. godini, ukupno 137 osoba, a najmanje je osoba poginulo u 2016. godini, 110 osoba. Iz podataka za razdoblje posljednjih pet godina ne postoji kontinuirani trend smanjenja broja poginulih osoba u prometnim nesrećama.

U Albaniji je najviše osoba u prometu poginulo u 2017., ukupno 270 osoba, a najmanje je osoba poginulo u 2018. godini, 213 osoba. Iz podataka kretanja prometnih nesreća vidljivo je da je u posljednje tri godine došlo je do smanjenja broja poginulih osoba u prometnim nesrećama.

U Hrvatskoj je najviše osoba u prometu poginulo u 2015., ukupno 348 osoba, a najmanje osoba u 2016. godini, 307 osoba. Iz podataka za promatrano razdoblje tijekom godina bilježi se i porast i smanjenje broja prometnih nesreća, međutim podrazumijeva se da nije smanjen broj poginulih osoba u prometnim nesrećama.

U Sloveniji je najviše osoba u prometu poginulo u 2016., ukupno 130 osoba, a najmanje osoba je poginulo u 2018. godini, 91 osoba. Iz podataka se uočava da je u posljednje dvije godine došlo do smanjenja broja poginulih osoba u prometnim nesrećama.

U Makedoniji je najviše osoba u prometu poginulo u 2016. godini, ukupno 165 osoba, a najmanje je osoba poginulo u 2018. godini, 129 osoba. Iz podataka se uočava da je u posljednje tri godine došlo do smanjenja broja poginulih osoba u prometnim nesrećama, u odnosu na 2016. godinu.

U Crnoj Gori najviše je osoba u prometu poginulo u 2014. i 2016. godini, ukupno 65 osoba, a najmanje je osoba poginulo u 2018. godini, 48 osoba. Iz podataka se uočava da je u posljednje dvije godine došlo do smanjenja broja poginulih osoba u prometnim nesrećama.

U BiH je najviše osoba u prometu poginulo u 2015. godini, ukupno 341 osoba, a najmanje je osoba poginulo u 2018. godini, 277 osoba. Iz podataka se uočava da je u posljednje tri godine došlo do smanjenja broja poginulih osoba u prometnim nesrećama.

U Srbiji je najviše osoba u prometu poginulo u 2016. godini, ukupno 551 osoba, a najmanje je osoba poginulo u 2018. godini, 481 osoba. Iz podataka se uočava da je u posljednje dvije godine i u prvoj godini za analizirano razdoblje došlo do smanjenja broja poginulih osoba u prometnim nesrećama.

Analizirajući i uspoređujući podatke u proteklih pet godina (2014. – 2018. god.), uočava se da je broj poginulih osoba u prometnim nesrećama u više navrata opadao i rastao,

ali da je trend smanjenja broja poginulih osoba u prometnim nesrećama započet tijekom 2017. godine, nastavljen i tijekom 2018. godine. Tako se u posljednje dvije godine broj poginulih osoba u prometnim nesrećama smanjio značajnije u većini zemalja regije, uključujući Republiku Kosovo.

4.2.3 Prometne nesreće prema kategorijama cesta

Osnovna mreža cesta na Kosovu projektirana je i izgrađena sredinom prošlog stoljeća s tehničkim parametrima koji su mogli zadovoljiti tadašnje skromne potrebe za prijevozom. Generalno, mreža cesta na Kosovu može se ocijeniti kao srednje razvijena (ispod europskih standarda), a osnovne tehničke karakteristike su niska projektna brzina, mali radijusi zavoja i veliki nagibi, česti priključci itd. Tek se posljednjih godina puno investiralo u cestovnu mrežu te su izgrađene nove ceste, autocesta, a postojeće nacionalne ceste rekonstruirane su s po dvije prometne trake za jedan smjer, i to s odvojenim kolničkim tracima.



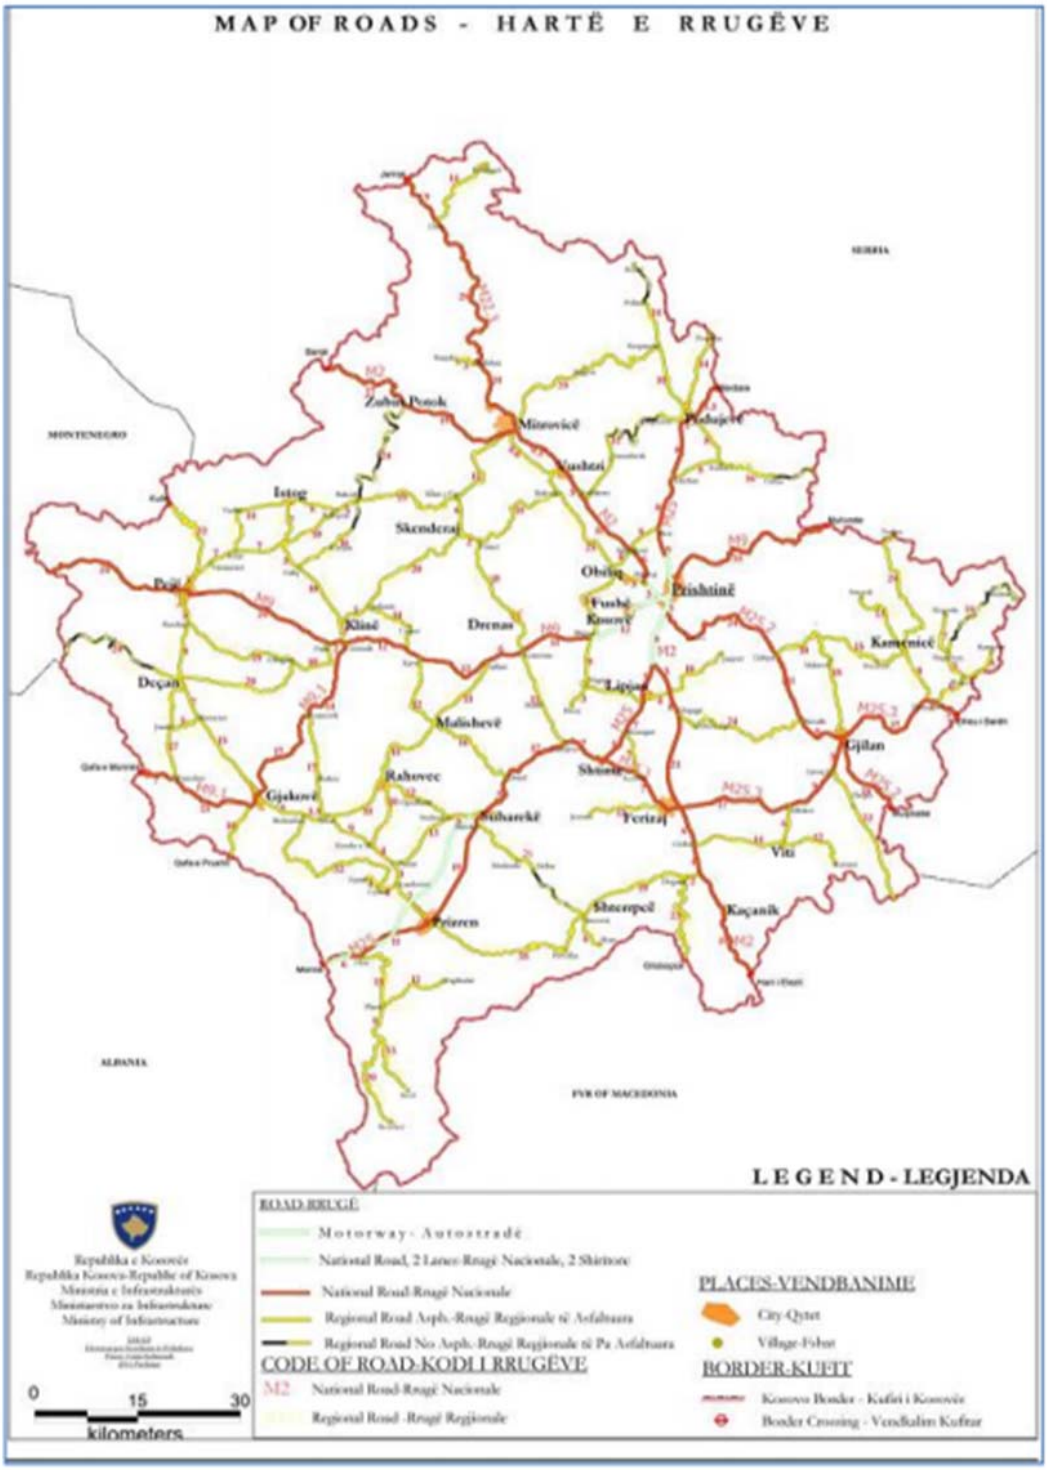

Slika 4- 1 Nacionalne ceste (N2) prije i nakon rekonstrukcije

Izvor: Izradio autor

Tablica 4- 3 Broj km prema kategorijama

Kategorija cesta	Godina							
	2011.	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**	**2017.**	**2018.**
Autocesta	38	60,4	78	78	78	98	108	119,1
Nacionalna	630,4	630,4	630,4	630,4	630,4	630,4	630,4	641,7
Regionalna	1294,7	1294,7	1294,7	1294,7	1305	1305	1305,4	1313,9
Lokalna								5034

Izvor: Ministarstvo infrastrukture



Slika 4- 2 Mreža cesta na Kosovu

Izvor: Ministarstvo infrastrukture

Prema podacima iz tablice 4-3 uočava se da 2018. godine na teritoriju Kosova ima 119,1 km autoceste, nacionalnih cesta je 641,7 km, regionalnih cesta 1313,9 km te lokalnih cesta 5034 km.

Kako bi se identificirale ceste i cestovni segmenti gdje su poginuli vozači, na temelju statističkih podataka kosovske policije provedena je detaljna analiza u svim regijama Kosova u razdoblju od 2014. do 2018. godine.

U tablici 4-4 prikazani su podaci o broju poginulih vozača prema kategorijama cesta.

Tablica 4- 4 Broj poginulih vozača prema kategorijama cesta

Kategorija ceste	2014.		2015.		2016.		2017.		2018.		Ukupno
	≤24	>24	≤24	>24	≤24	>24	≤24	>24	≤24	>24	
Autocesta		2		2		4		1	1	1	11
Nacionalna		12	2	9	3	12	3	18	4	10	73
Regionalna	2	2	4	13	2	14	4	12	3	10	66
Urban/gradska	2	8	2	5	1	5	2	6		7	38
Lokalna	1	2	1	3	1	3		2	2	7	22
Ukupno	5	31	9	32	7	35	9	39	10	31	216

Izvor: [130]

Iz tablice 4-4 uočava se da je broj poginulih vozača na području Republike Kosovo za promatrano razdoblje, posljednjih pet godina, 216. Što se tiče mladih vozača, najviše je poginulih u 2018. godini, 10 osoba ili 22,22 %, dok je najmanje poginulo u 2014. godini – pet osoba ili 13,89 %. Ako se uzmu u obzir ostali vozači, najviše ih je poginulo u 2017. godini, ukupno 39 ili 76,09 %, dok je najmanje vozača poginulo u 2014. godini, 39 ili 74,35 %.

Kad je riječ o cestama, najviše vozača poginulo je na nacionalnim cestama, ukupno 73 ili 33,80 %, zatim na regionalnim cestama, ukupno 66 ili 30,60 %, na urbanim cestama 38 ili 17,6 %, na lokalnim cestama 22 ili 10,18 % te najmanje na autocestama, 11 vozača ili 5,09 %.

Tablica 4- 5 Broj poginulih mladih vozača prema kategorijama cesta

Kategorija Ceste	2014.		2015.		2016.		2017.		2018.		Ukupno
	≤24	>24	≤24	>24	≤24	>24	≤24	>24	≤24	>24	
Autocesta		2		2		4		1	1	1	**11**
Nacionalna		13	2	9	3	12	3	18	4	10	**74**
Regionalna	2	5	4	13	2	15	4	12	3	10	**70**
Urban/gradska	2	9	2	5	1	5	2	6		7	**39**
Lokalna	1	2	1	3	1	3		2	2	7	**22**
Ukupno	5	31	9	32	7	39	9	39	10	35	**216**

Izvor: [130]

Mladih je vozača najviše poginulo na regionalnim cestima, ukupno 15 vozača ili 6,94 %, zatim na nacionalnim cestama 12 ili 5,56 %, na urbanim cestama 7 ili 3,24 %, na lokalnim cestama pet ili 2,31 % te na autocestama jedan mladi vozač ili 0,46 %.

Ostalih je vozača najviše poginulo na nacionalnim cestama, ukupno 62 vozača ili 28,70 %, zatim na regionalnim cestama 55 ili 25,46 %, urbanim cestama 32 ili 14,82 %, na lokalnim cestama 17 ili 7,87 % te na autocestama 10 ili 4,64 %. Sigurnost tih vozača na autocestama nije na visokoj razini jer su od tri prometne nesreće koje su se dogodile, u dvije uključeni vozači ove kategorije.

Iz toga se može zaključiti da su regionalne ceste opasnije za mlade vozače od ostalih cesta, dok na gradskim cestima u 2018. godini nema poginulih mladih vozača. Na autocesti u analiziranom razdoblju od tri nesreća koje su se dogodile, jedna je uključivala mlade vozače.

4.2.4 Broj poginulih vozača prema elementima ceste

U tablici 4-6- prikazani su elementi ceste na kojima su poginuli vozači.

Tablica 4- 6 Broj poginulih vozača prema elementima ceste s udjelom mladih vozača

Kategorija ceste	2014.		2015.		2016.		2017.		2018.		Ukupno
	≤24	>24	≤24	>24	≤24	>24	≤24	>24	≤24	>24	
Ravni cestovni segment	4	17	9	22	4	25	8	30	10	30	**158**
Zavoj	1	14		7	3	11	1	8		3	**48**
Raskrižje				3		3		1		2	**9**
Ukupno	5	31	9	32	7	39	9	39	10	35	**216**

Izvor: [130]

Iz tablice 4-6 uočava se da je najviše poginulih vozača na ravnom cestovnom segmentu (potezu). Od ukupno 216 poginulih vozača, čak 158 vozača poginulo je na ravnom cestovnom segmentu ili 73,14 %, dok je 48 vozača poginulo u zavojima ili 22,22 %. Na raskrižjima se dogodilo ukupno devet prometnih nesreća ili 4,64 %.

Mladi vozači najviše su poginuli na ravnom cestovnom segmentu (ukupno 35 vozača ili 16,20 %), zatim u zavoju (ukupno pet vozača ili 2,31 %), dok na raskrižjima nije bilo poginulih mladih vozača.

Ostali su vozači poginuli na ravnom cestovnom segmentu (ukupno 123 vozača ili 57,44 %), zatim u zavoju (ukupno 43 vozača ili 19,90 %) te na raskrižju (ukupno devet poginulih vozača ili 4,15 %).

Te su komponente uzete u obzir tijekom istraživanja i identificiranja čimbenika nastanka prometnih nesreća na ravnim dionicama ceste.

4.2.5 Uzroci prometnih nesreća

Tablica 4- 7 Uzroci prometnih nesreća s poginulim vozačima za razdoblje od 2014. do 2018. godine

Brzina	**5**	18	6	17	4	14	5	22	7	17	**116**

Pogreške	**2014.**		**2015.**		**2016.**		**2017.**		**2018.**		**Ukupno**
	≤24	**>24**	**≤24**	**>24**	**≤24**	**>24**	**≤24**	**>24**	**≤24**	**>24**	
Alkohol										1	**1**
Nepropisno prestrojavanje		1		1	1	3	2				**8**
Neoprezna vožnja		2	1	3		4		3	1	2	**16**
Nepropisno pretjecanje		5	1	3	1	2		3	1	8	**24**
Nepropisno skretanje				1		2	1	1	1	2	**8**
Nepropisno uključenje						2		2		3	**7**
Nepropisno obilaženje								1			**1**
Desna strana						2					**2**
Prometni znakovi				1	1	2		1			**5**
Nepoštovanje semafora				1						1	**2**
Nepropisno kretanje vozila		1		3		1				1	**6**
Vožnja na nedovoljnoj udaljenosti		1		1		3		1			**6**
Nepoštovanje prednosti		1	1	1		1					**3**
Motorna vozila		1				1					**2**
Gubitak kontrole nad vozilom						2	1	4			**7**
Slijetanje s ceste		1									**1**
Ostale pogreške vozača								1			**1**
Total	**5**	**31**	**9**	**32**	**7**	**39**	**9**	**39**	**10**	**35**	**216**

Izvor: [130]

Iz tablice 4-7 uočava se da je najveći uzrok prometnih nesreća bila brzina: nepoštovanje ograničenja brzine i neprilagođena brzina kretanja uvjetima i okolnostima na cesti što se odnosi na objektivne čimbenike. Od 216 poginulih vozača, 116 vozača ili 53,70 % poginulo je zbog brzine. Drugi uzrok prometnih nesreća je nepravilno pretjecanje vozila (24 ili 11,11 %), treći uzrok je nepažnja – neoprezna vožnja (16 ili 7,40 %) što je subjektivni čimbenik. Slijede nepropisno prestrojavanje (osam ili 3,70 %), nepropisno skretanje (osam ili 3,70 %), nepropisno uključenje (sedam ili 3,24 %), gubitak kontrole nad vozilom (sedam ili 3,2 %), vožnja na nedovoljnoj udaljenosti (šest ili 2,7 %), nepropisno kretanje vozila – vožnja

vozilom u zabranjenom smjeru (sedam ili 3,24 %), nepoštovanje prometnih znakova (pet ili 2,31 %) itd.

Iz podataka iz tablice 4-7 uočava se da se u analiziranom razdoblju dogodila samo jedna prometna nesreća s poginulim vozačima zbog utjecaja alkohola, dok se vozilo kao uzrok prometne nesreće pojavljuje dvaput.

Kod mladih se vozača, osim neprilagođene brzine kretanja uvjetima na cesti, kao uzroci ostalih nesreća javljaju: nepropisno pretjecanje vozila (nedostatak tehnike ili greška tijekom radnje), nepažnja (subjektivni čimbenici), greške pri promjeni trake (nedovoljno osposobljavanje), nepoštovanje prometnih znakova koji reguliraju prioritet prolaska (nepoznavanje ili ignoriranje prometnih pravila), gubitak kontrole nad vozilom (nedostatak vještine), vožnja na nedovoljnoj udaljenosti (nepažnja ili podcjenjivanje sigurnosne udaljenosti) te nepropisno skretanje (nedovoljno osposobljavanje).

Kod ostalih je vozača uznemirujuća činjenica vožnja u zabranjenom smjeru zbog nepoznavanja prometnih pravila (neznanje) ili zbog nepažnje. Podaci pokazuju da je jedna od radnji koja dominira kao uzrok nesreća s poginulima kod ove skupine vozača, pretjecanje vozila (uglavnom se radi o greškama). Uzrok je nesreće i vožnja s nedovoljnim razmakom (uglavnom se radi o greškama ili podcjenjivanju razmaka), dok kod mladih vozača nije bilo takvih nesreća. Među uzrocima prometnih nesreća su i nepropisno prestrojavanje (greška) i slijetanje s ceste (objektivni čimbenici). Prema podacima kao uzrok dviju prometnih nesreća je vozilo (objektivni čimbenik), gdje su uključeni ostali vozači.

Može se zaključiti da je glavni uzrok prometnih nesreća s poginulim osobama brzina, tj. nepoštovanje ograničenja brzine i neprilagođena brzina kretanja uvjetima i okolnostima na cesti (subjektivni čimbenici nisu prilagođeni objektivnim čimbenicima), zatim nepropisno pretjecanje vozila (uglavnom se radi o greškama), neodržavanje dovoljnog razmaka između vozila tijekom vožnje (uglavnom se radi o greškama ili podcjenjivanju razmaka – subjektivni čimbenici), nepažnja (subjektivni čimbenik), vožnja vozilom u zabranjenom smjeru (neznanje), nepropisno prestrojavanje (greška), slijetanje s ceste (objektivni čimbenici), vozilo (objektivni čimbenici) itd. Znatan broj uzroka navedenih prometnih nesreća može se otkloniti ako postoji kvalitetna obuka u autoškoli.

Na temelju analize rizika od prometnih nesreća nailazimo na veliki broj i međusobno kombiniranje objektivnih i subjektivnih čimbenika, koji su definirani unutar ovoga doktorskog rada.

4.2.6 Broj poginulih vozača prema uvjetima i stanju površine kolnika

Tablica 4- 8 Broj poginulih vozača prema uvjetima i stanju površine kolnika

Uvjeti i stanje zastora kolnika	2014.		2015.		2016.		2017.		2018.		Ukupno
	≤24	>24	≤24	>24	≤24	>24	≤24	>24	≤24	>24	
Suh/čist	5	27	6	29	6	37	7	29	9	28	**183**
Mokar		4	3	2	1	2	1	7	1	7	**28**
Prljav				1			1				**2**
Snijeg/led								3			**3**
Ukupno	**5**	**31**	**9**	**32**	**7**	**39**	**9**	**39**	**10**	**35**	**216**

Izvor: [130]

Prema stanju površine kolnika (objektivni čimbenici) najviše je poginulih vozača na suhoj i čistoj površini kolnika, ukupno 183 ili 84,72 %, zatim na mokrom kolniku 28 ili 12,96 % te na snijegu/ledu i prljavom kolniku pet ili 2,32 %.

Među poginulima najveći je broj mladih vozača poginuo na suhoj i čistoj površini kolnika, ukupno 33 poginula vozača ili 15,38 %, na mokrom kolniku ih je šest ili 3,78 %, dok na snijegu/ledu nije bilo poginulih mladih vozača.

I ostalih je vozača najveći broj poginuo na suhoj i čistoj površini kolnika, odnosno dobrim uvjetima kolnika, ukupno 150 poginulih vozača ili 69,44 %, na mokrom kolniku ih je poginulo 22 ili 10,47 %, dok su na snijegom prekrivenom kolniku poginula dva vozača ili 0,93 %.

Iz toga se može zaključiti da se najveći broj poginulih vozača prema stanju površine kolnika (objektivni čimbenici) dogodio po suhom i čistom kolniku kad su uvjeti za vožnju bili dobri. Sigurnost mladih vozača na visokoj je razini kad je posrijedi vožnja po snijegu/ledu jer nema poginulih u takvim uvjetima.

Može se zaključiti da vozači, kad su uvjeti na kolniku dobri (objektivni čimbenici), nisu toliko pažljivi (subjektivni čimbenici) tijekom vožnje jer su u takvim uvjetima najviše pogibali.

Te su komponente uzete u obzir tijekom istraživanja, kako bi se identificirali čimbenici rizika od prometnih nesreća koji su definirani unutar ovoga rada.

4.2.7 Broj poginulih vozača prema satu u danu

Tablica 4- 9 Broj poginulih vozača prema dobu dana za promatrano razdoblje 2014. – 2018.

Doba dana	2014.		2015.		2016.		2017.		2018.		Ukupno
	≤24	>24	≤24	>24	≤24	>24	≤24	>24	≤24	>24	
00 – 06	1	4	2	4	1	9	1	5	4	8	**39**
06 – 12	1	5	2	4	2	5	2	8		6	**35**
12 – 18	2	15	3	13	1	14	3	18	2	12	**83**
18 – 24	1	7	2	11	3	11	3	8	4	9	**59**
Ukupno	**5**	**31**	**9**	**32**	**7**	**39**	**9**	**39**	**10**	**35**	**216**

Izvor: [130]

Prema satu u danu najviše je poginulih vozača između 12 i 18 sati, ukupno 83 vozača ili 38,42 %, a najmanje između 6 i 12 sati, ukupno 35 vozača ili 16,21 %.

Prema satu u danu (subjektivni čimbenici) poginuli su:

- mladi vozači – najviše između 12 i 18 sati, ukupno 11 poginulih vozača ili 5,09 %, a najmanje između 6 i 12 sati, četiri poginula vozača ili 1,85 %. Između 00 i 6 sati poginulo je devet mladih vozača ili 4,17 %
- ostali vozači – najviše su poginuli između 12 i 18 sati, ukupno 72 ili 33,33 %, a najmanje između 18 i 24 sata, 46 ili 21,30 %.

Iz toga se može zaključiti da je najveći broj poginulih vozača prema satu u danu između 12 i 18 sati, dok ih je najmanje između 6 i 12 sati. Prema uzrastu vozača, mladi vozači najviše pogibaju između 12 i 18 sati, kao i ostali vozači. Ne postoji uzročna veza između vremena u kojima vozači pogibaju i njihova uzrasta.

Prema dobu dana, vozači najviše pogibaju tijekom dana (ukupno 133 poginula vozača ili 61,58 %), zatim noću (69 poginulih vozača ili 31,94 %), u sumrak (11 poginulih vozača ili 5,09 %) te u svitanje (tri poginula vozača ili 1,39 %).

Prema dobu dana poginuli su:

- mladi vozači – najviše tijekom dana (21 poginuli mladi vozač ili 9,72 %), zatim noću (ukupno 17 poginulih ili 7,87 %) te u svitanje (dva vozača ili 0,93 %), dok za vrijeme sumraka nije bilo poginulih

- ostali vozači – najviše tijekom dana (ukupno 112 ili 51,85 %), zatim noću (ukupno 52 ili 24,07 %), u sumrak 11 ili 5,10 % te u svitanje jedan ili 0,46 %.

Na temelju analize rizika od prometnih nesreća dovodi se velik broj istovremeno međusobno kombiniranih objektivnih i subjektivnih čimbenika koji su definirani unutar ovoga rada.

4.2.8 Broj poginulih vozača prema danu u tjednu

Tablica 4- 10 Broj poginulih vozača prema danu u tjednu

Dan u tjednu	2014.		2015.		2016.		2017.		2018.		Ukupno
	≤24	>24	≤24	>24	≤24	>24	≤24	>24	≤24	>24	
ponedjeljak		4	1	8	1	9		6	2	4	**36**
utorak	2	8		3	1	3	3	1	2	6	**29**
srijeda		3	1	5	1	5		7		2	**24**
četvrtak	1	3	3	4	3	5	1	4		4	**28**
petak		6	1	2		3		4	3	9	**28**
subota	1	3	2	3		8	4	8	1	5	**34**
nedjelja	1	4	1	7	1	6	1	9	2	5	**37**
ukupno	**5**	**31**	**9**	**32**	**7**	**33**	**9**	**39**	**10**	**35**	**216**

Izvor: [130]

Prema danu u tjednu, najviše vozača pogiba nedjeljom, ukupno 37 poginulih vozača ili 17,13 %, a najmanje srijedom, ukupno 24 ili 11,11 %.

Iz toga se može zaključiti da se najveći broj poginulih vozača prema danu u tjednu događa nedjeljom, a najmanje je poginulih srijedom. Te komponente uzete su u obzir tijekom istraživanja kako bi se utvrdila povezanost s rizikom od prometne nesreće.

4.2.9 Broj poginulih vozača prema tipu nesreće

Tablica 4- 11 Broj poginulih vozača prema tipu nesreće

Tip prometne nesreće	2016.		2017.		2018.		Ukupno
	≤24	>24	≤24	>24	≤24	>24	
Vozilo	2	15	6	15	5	12	**55**
Vozilo-vozilo	3	12		14	2	11	**42**
Vozilo-autobus			2			4	**6**
Vozilo-kamion		4	1	3		1	**9**
Vozilo-pješak		1					**1**
Vozilo-vlak		1		1			**2**
Vozilo-bicikl	1	3		1		1	**6**
Vozilo-motocikl		1	1	1		3	**6**
Ostalo	1	2	3	4	2		**12**
Total	**7**	**31**	**13**	**39**	**9**	**32**	**216**

Izvor: [130]

Prema tipu prometne nesreće s poginulim:

- mladim vozačima – dominira tip nesreća „ jedno vozilo“ gdje je uključeno samo jedno vozilo pri čemu je vozač u objektivnom konfliktu sa svojim neposrednim okruženjem, tj. s elementima ceste, stanjem kolnika, meteorološkim uvjetima (objektivnim čimbenicima). Kod ovog tipa prometne nesreće koji nastaje zbog propusta ili pogrešaka vozača koji su uključeni u prometne nesreće, rizik se može smanjiti promjenom ponašanja vozača. Drugi tip prometne nesreće je „motorno vozilo – motorno vozilo“ gdje sudjeluju najmanje dva vozila u pokretu.
- ostali vozači – situacija je ista kao i za mlade vozače, kako je gore opisano.

Taj pokazatelj je uzet u obzir tijekom praktičnog istraživanja i razrađen je u ovom radu. Te su komponente uzete u obzir tijekom istraživanja kako bi se utvrdila povezanost s rizikom od prometne nesreće.

5. ISTRAŽIVANJE STAVOVA MLADIH VOZAČA KOD NASTANKA PROMETNIH NESREĆA

Kako bi se istražili stavovi mladih vozača i njihova razmišljanja kod nastanka prometnih nesreća, u ovom poglavlju bit će prikazan proces prikupljanja podataka, koji će obuhvatiti i terenska istraživanja anketiranja, te rezultati provedenog istraživanja.

Na temelju podataka iz anketnog upitnika analizirat će se najrelevantniji subjektivni i objektivni uzroci koji povećavaju rizik od prometnih nesreća mladih vozača.

Analizirajući statističke pokazatelje, uočeno je da su mladi vozači najviše izloženi riziku sudjelovanja u prometnim nesrećama. Na temelju dosadašnjih istraživanja, uočava se potreba za izradom modela za procjenu rizika od prometnih nesreća identifikacijom subjektivnih i objektivnih čimbenika koji će doprinijeti većoj sigurnosti mladih vozača u prometu.

5.1 ISTRAŽIVANJE I PROCEDURE ANKETIRANJA

U sklopu provedenog istraživanja izvršeno je i anketiranje mladih vozača na terenu kako bi se prikupili potrebni podaci o stavovima mladih vozača kod nastanka prometnih nesreća. Na temelju dobivenih rezultata te upotrebom relevantnih metoda identificirat će se subjektivni i objektivni čimbenici koji imaju najveći utjecaj na nastanak prometnih nesreća.

Promatrani uzorak su mladih vozači (≥24 godine) u regiji Mitrovica, a kriterij odabira ispitanika je posjedovanje vozačke dozvole i prebivalište/boravište na području regije Mitrovica. Ukupan broj ispitanika je 371 mladi vozač. Za anketiranje su upotrijebljeni anketni obrasci u tiskanoj formi (olovka-papir-testiranje). Istraživanje je realizirano u regionalnom centru regije Mitrovica u Republici Kosovu. Upitnici su sadržavali pitanja s višestrukim izborom odgovora, pitanja zatvorenog tipa.

Na početku su ispitanici zamoljeni da iskreno i dobrovoljno pristupe anketiranju. Zajamčen im je anoniman karakter istraživanja i da će prikupljeni podaci služiti isključivo u znanstvene svrhe izrade doktorskog rada. Za ispunjavanje ankete ispitaniku je bilo potrebno između 25 i 30 minuta.

Terenska su istraživanja obavljena tijekom 2019. godine (u periodu siječanj – ožujak te listopad – prosinac), dok je analiza podataka o poginulim vozačima s posebnim osvrtom na mlade vozača provedena za petogodišnji period 2014. – 2018. Izvori podataka su osobni i iz drugih izvora koji su označeni posebnim indeksom.

Ispitivanje točnosti hipoteze radi identificiranja subjektivnih i objektivnih čimbenika koji utječu na procjenu rizika od prometnih nesreća mladih vozača, započeto je provođenjem terenskog istraživanja.

5.2 OPĆE ZNAČAJKE I STAVOVI MLADIH VOZAČA

5.2.1 Spol ispitanika

U istraživanje je uključeno ukupno 371 ispitanik, 225 ili 60,6 % muškaraca i 146 ili 39,4 % žena. Spolna struktura ispitanika prikazana je u tablici 5-1. Broj žena koje posjeduju vozačku dozvolu i dalje je nizak u usporedbi s muškarcima, iako se počeo znatno povećavati svake godine.

Tablica 5- 1 Prikaz ispitanika prema spolu

Spol

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	M	225	60,6	60,6	60,6
	Ž	146	39,4	39,4	100
	Total	371	100	100	

Izvor: Izradio autor

5.2.2 Dob ispitanika

Po dobi ispitanici su klasificirani u četiri skupine, kao što je prikazano u sljedećoj tablici:

Tablica 5- 2 Prikaz ispitanika prema dobi

Dob ispitanika

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	16 – 18	127	34,2	34,2	34,2
	19 – 20	129	34,8	34,8	69,0
	21 – 22	70	18,9	18,9	87,9
	23 – 24	45	12,1	12,1	100
	Total	371	100	100	

Izvor: Izradio autor

Iz tablice se uočava da je najviše ispitanika iz druge skupine, 129 ili 34,8 %, slijede prva skupina 127 ili 34,2 %, treća skupina 70 ili 18,9 % te četvrta skupina 45 ili 12,1 %.

5.2.3 Vrijeme posjedovanja vozačke dozvole (vozački staž)

Prema vozačkom stažu ispitanici su klasificirani u četiri skupine, kako je prikazano u tablici 5-3.

Tablica 5- 3 Prikaz ispitanika prema vozačkom stažu

Vozački staž

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	≥ 1	115	30,9	31,0	31,0
	< 1 ≥ 2	103	27,7	27,8	58,8
	< 2 ≥ 4	89	23,9	24,0	82,7
	< 4 i vše	64	17,2	17,3	100
	Total	371	99,7	100	
Missing	System	1	3		
Total		372	100		

Izvor: Izradio autor

Iz tablice se uočava da je najviše ispitanika iz prve skupine, 115 ili 30,9 %, slijedi druga skupina 103 ili 27,7 %, treća skupina 89 ili 23,9 % te četvrta skupina 64 ili 17,2 %.

5.2.4 Sudjelovanje u prometnim nesrećama

Tablica 5- 4 Prikaz ispitanika prema sudjelovanju u prometnim nesrećama

Nesreća					
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	273	73,6	73,6	73,6
	Da	98	26,4	26,4	100
	Total	371	100	100	

Izvor: Izradio autor

Od ukupnog broja ispitanika najviše ih se, 273 ili 73,6 %, izjasnilo da nisu bili uključeni u prometne nesreće, dok se 98 ispitanika ili 26,4 % izjasnilo da su bili uključeni u prometne nesreće (samo kao vozači, ovo je razjašnjeno ispitanicima tijekom praktičnog istraživanja), kako je prikazano na tablici 5-4.

5.2.5 Uzroci prometnih nesreća u kojima su sudjelovali mladi vozači

U tablici 5-5 prikazani su podaci glavnih uzroka prometnih nesreća čovjek – vozilo – cesta – okoliš. Tijekom anketiranja ispitanici su mogli odabrati više odgovora te je ovo pitanje razjašnjeno tijekom praktičnog istraživanja.

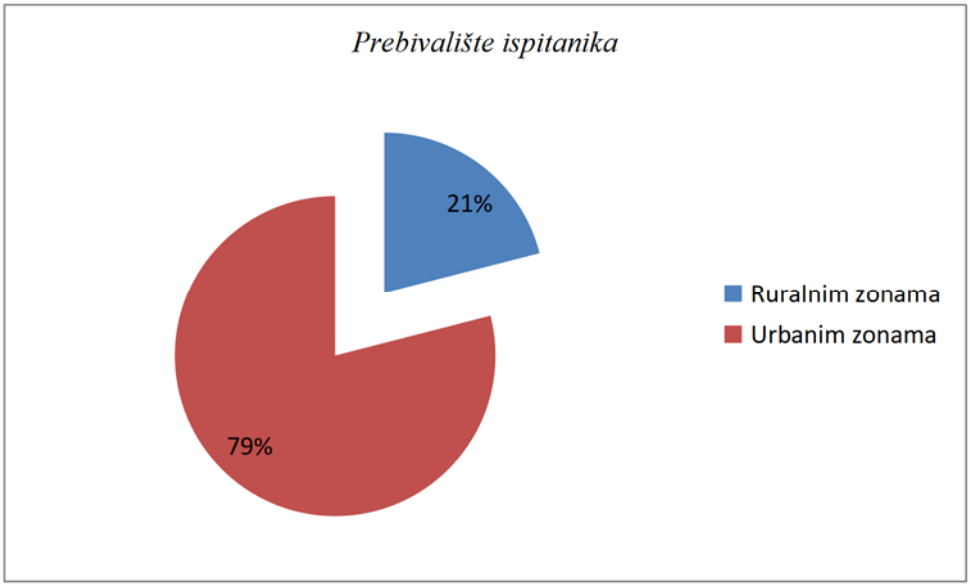
Tablica 5- 5 Prikaz uzroka prometnih nesreća u kojima su sudjelovali mladi vozači

Uzroci prometnih nesreća		**Prometne nesreće**	
		F	%
Čovjek (subjektivni čimbenik)	Nepoštovanje PSP	11	8,66
	Psihofizičko stanje	1	0,79
	Brzina vožnje	52	40,94
	Distrakcija u vožnji	15	11,81
	Alkohol	1	0,79
	Procjena rizika	8	6,30
	Radnje u prometu (tehnika vožnje, greške)	23	18,11
Vozilo (objektivni čimenik)	Sustav upravljanja i kočenja	0	0
	Gume		
	Svjetla i signali		
Cesta (objektivni čimbenik)	Cestovna signalizacija	2	1,57
	Kolnik (oštećen, sklizak, udarne rupe itd.)	9	7,16
Okolina (objektivni čimbenik)	Meteorološki uvjeti (kiša, snijeg, magla itd.)	7	5,51
	Doba dana	0	0
	Uvjeti prometa	0	0
Ostalo		2	1,57

Izvor: Izradio autor

Iz tablice 5-5 uočava se da je najveći broj prometnih nesreća povezan s ljudskim čimbenikom, ukupno 87,4 %, slijede cesta 8,73 % te okruženje 5,51 %. Glavni uzrok prometnih nesreća je brzina 40,94 %, slijede radnje u prometu 18,15 %, distrakcija 11,81 %, nepoštovanje prometnih pravila 8,61 % te procjena rizika 6,3 %.

5.2.6 Prebivalište ispitanika

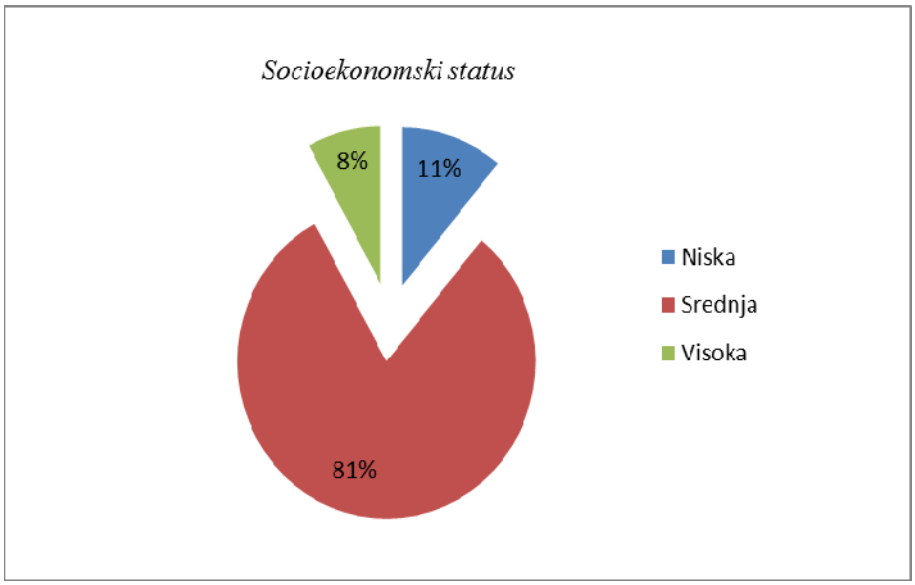


Dijagram 5- 1 Prikaz ispitanika prema mjestu prebivališta

Izvor: Izradio autor

Od ukupnog broja najveći broj ispitanika, njih 79 %, živi u urbanim zonama, dok 21 % ispitanika živi u ruralnim zonama, kako je prikazano na dijagramu 5-1.

5.2.7 Socioekonomski status ispitanika



Dijagram 5- 2 Prikaz ispitanika prema socioekonomskom statusu

Izvor: Izradio autor

Iz dijagrama se uočava da je najveći broj ispitanika, njih 81 %, srednjega socioekonomskog statusa, slijedi 11 % ispitanika niskoga socioekonomskog statusa te 8 % ispitanika visokoga socioekonomskog statusa.

5.2.8 Frekvencije korištenja automobila

Tablica 5- 6 Prikaz ispitanika prema učestalosti korištenja automobila

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Uvijek	42	11,3	11,3	11,3
	Često	48	12,9	12,9	24,3
	Ponekad	129	34,8	34,8	59,0
	Rijetko	103	27,8	27,8	86,8
	Vrlo rijetko	49	13,2	13,2	100,0
	Ukupno	371	100,0	100,0	

Izvor: Izradio autor

Iz tablice 5-6 uočava se da se najviše ispitanika, njih 129 ili 34,8 %, koristi automobilom ponekad (2 – 3 puta tjedno), slijedi 48 ispitanika ili 12,9 % ispitanika koji se automobilom koriste često (4 – 5 puta tjedno), 42 ispitanika ili 11,3 % uvijek (6 – 7 tjedno),

103 ispitanika ili 27,8 % rijetko (jednom tjedno), te 49 ili u 13,2 % vrlo rijetko (jednom mjesečno).

5.2.9 Poštovanje ograničenja brzine vožnje

Tablica 5- 7 Prikaz ispitanika prema poštovanju ograničenja brzineg

Poštujete li ograničenja brzine vožnje ?		*F*			*%*		
		M	***Ž***	***Σ***	***M***	***Ž***	***Σ***
Uvijek	zbog primjena pravila prometa	53	70	123	14	19	33
	zbog novčanih kazni	3	11	14	1	3	4
	zbog negativnih bodova	15	26	41	4	7	11
Često	osim kad kasnim da stignem na vrijeme; osim kad sam s vršnjacima u vozilu	12	3	15	3	1	4
	samo kad sam s roditeljem	48	7	55	13	2	15
Ponekad	kad sam s vršnjacima	23	4	27	7	1	8
Rijetko	samo kad znam za radarsku kontrolu	74	9	83	20	2	22
Nikad		9	4	13	2	1	3
Ukupno		**237**	**134**	**371**	**64**	**36**	**100**

Izvor: Izradio autor

Iz tablice se uočava da najveći broj ispitanika, 123 ili 33 %, poštuje ograničenje brzine uvijek zbog prometnih i sigurnosnih pravila, slijedi 14 ispitanika ili 4 % koji poštuju ograničenje brzine zbog novčanih kazni te 41 ispitanik ili 11 % ispitanika koji to čine zbog negativnih bodova. Slijedi skupina ispitanika koji poštuju ograničenje brzine u sljedećim okolnostima: 15 ispitanika ili 4 % zbog zakašnjenja, 55 ispitanika ili 15 % poštuje brzinu kad su s roditeljem, 83 ispitanika ili 22 % poštuje brzinu kad imaju saznanja o radarskoj kontroli, 27 ispitanika ili 8 % ne poštuje brzinu samo kad je s vršnjacima u vozilu te 13 ispitanika ili 3 % nikad ne poštuje ograničenje brzine.

Muškarci najviše poštuju ograničenje brzine na onom dijelu ceste na kojem se provode radarske kontrole (23 %), dok kod žena njihov veći postotak (19 %) poštuje ograničenje zbog prometnih pravila.

5.2.10 Samoprocjena brzine vožnje

Kao glavni parametar koji doprinosi nastanku prometnih nesreća je brzina (neprilagođena brzina, ograničenje brzine itd.). S tim u vezi za samoprocjenu svoje brzine vožnje u odnosu na ostale vozače istraživanje je pokazalo: najviše ispitanika, 178 ili 48 %, izjasnilo se da vozi brzo u odnosu na ostale vozače. Slijedi 105 ispitanika ili 28,3 % koji su svoju vožnju procijenili kao vrlo brzu u odnosu na brzine vožnje ostalih vozača, 81 ispitanik ili 21,8 % kao prosječnu u odnosu na ostale vozače, sedam ispitanika ili 1,9 % svoju brzinu smatra sporom, kako je prikazano u tablici 5-8.

Tablica 5- 8 Prikaz ispitanika prema samoprocjeni brzine vožnje

Brzina

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Sporo	7	1,9	1,9	1,9
	Prosječno	81	21,8	21,8	23,7
	Brzo	178	48,0	48,0	71,7
	Vrlo brzo	105	28,3	28,3	100,0
	Total	371	100,0	100,0	

Izvor: Izradio autor

5.2.11 Procjena tehnike vožnje

Na postavljeno pitanje: *Kako procjenjujete svoju tehniku vožnje u usporedbi s drugim vozačima*? ispitanici su odgovorili kako je prikazano u tablici 5-9.

Tablica 5- 9 Prikaz ispitanika prema procjeni tehnike vožnje

Tehnika

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Vrlo loša	10	2,7	2,7	2,7
	Lošija	85	22,9	22,9	25,6
	Jednaka	53	14,3	14,3	39,9
	Bolja	131	35,3	35,3	75,2
	Vrlo dobra	92	24,8	24,8	100,0
	Total	371	100,0	100,0	

Izvor: Izradio autor

Od ukupnog broja većina ispitanika, 131 ispitanik ili 35,3 % izjasnila se da ima bolju tehniku vožnje u usporedbi s drugim vozačima, slijedi 92 ispitanika ili 24,8 % koji imaju vrlo dobru tehniku vožnje, 85 ispitanika ili 22,9 % smatra da ima lošiju tehniku vožnje, 53 ispitanika ili

14,3 % jednaku te 10 ispitanika ili 27 % imaju vrlo lošu tehniku vožnje u usporedbi s drugim vozačima.

5.2.12 Procjena promjene vlastitog ponašanje u prometu

Ova se komponenta odnosi na pozitivne promjene ponašanja u prometu nakon vozačkog iskustva.

Tablica 5- 10 Prikaz ispitanika prema procjeni promjene vlastitog ponašanja u prometu

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Vrlo malo	167	45,0	45,0	45,0
	Malo	81	21,8	21,8	66,8
	Nepromijenjen	56	15,1	15,1	81,9
	Mnogo	42	11,3	11,3	93,3
	Vrlo mnogo	25	6,7	6,7	100,0
	Total	371	100,0	100,0	

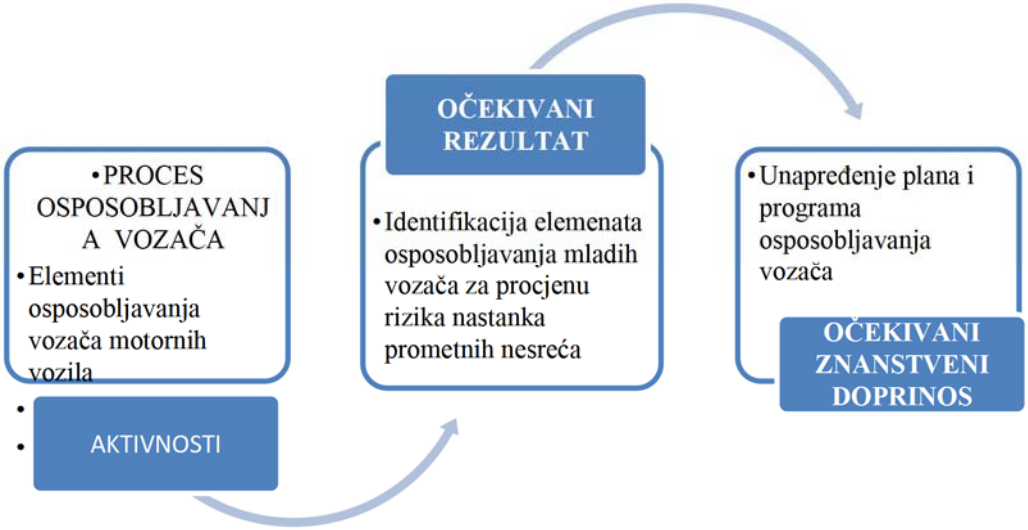
Izvor: Izradio autor

Prema podacima iz tablice najviše ispitanika, 167 ili 45 %, izjasnilo se da ima vrlo malo promjena ponašanja u prometu, slijedi 42 ispitanika ili 11,3 % s mnogo promjena ponašanja, 81 ispitanik ili 21,8 % s malo promjena ponašanja, 25 ispitanika ili 6,7 % s vrlo mnogo promjena ponašanja te 56 ispitanika ili 15,1 % s nepromijenjenim ponašanjem u prometu.

5.3 PROCES OSPOSOBLJAVANJA KANDIDATA ZA VOZAČA

Jedan od uzroka nastanka prometne nesreće je neadekvatno osposobljavanje vozača gdje kandidat za vozača stječe znanja i tehničke vještine vožnje kako bi samostalno sudjelovao u prometu.

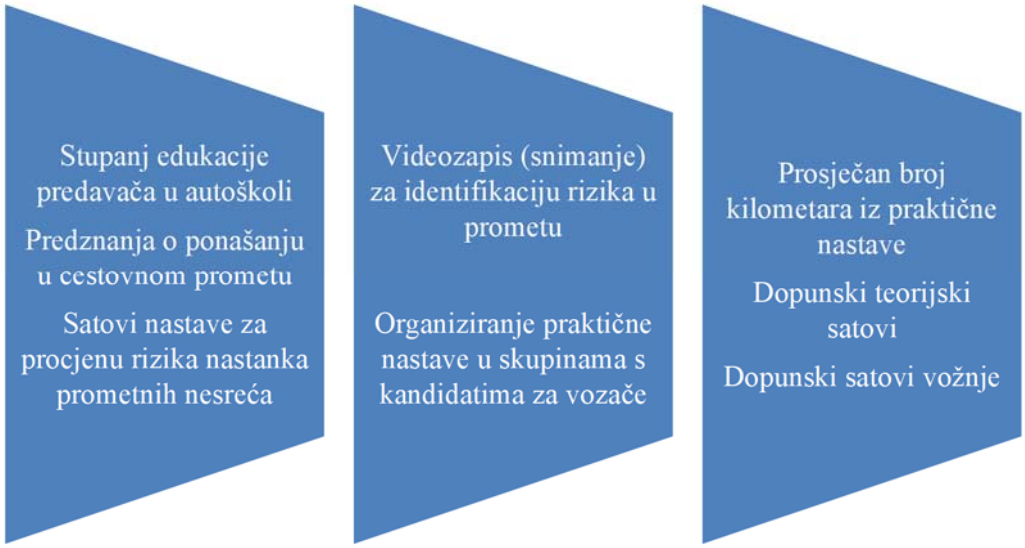
Na slici 5-1 prikazane su aktivnosti, očekivani rezultati te očekivani znanstveni doprinos u vezi elemenata procesa osposobljavanja kandidata za vozača.



Slika 5- 1 Proces osposobljavanja kandidata za vozača motornih vozila

Izvor: Izradio autor

Definirani ciljevi koji se odnose na elemente procesa osposobljavanja vozača radi ispitivanja subjektivnog stava mladih vozača o tim elementima prikazani su na slici 5-2:



Slika 5- 2 Elementi osposobljavanja kandidata za vozača

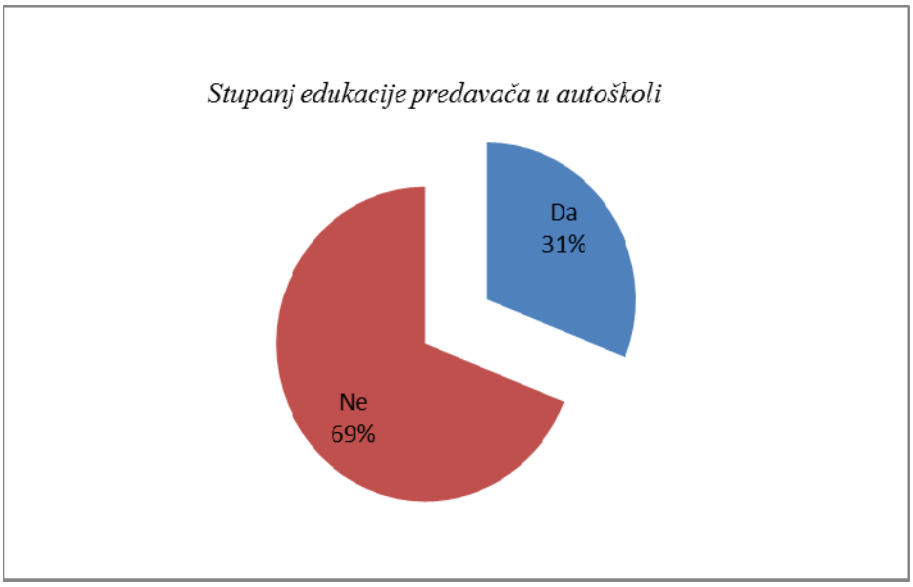
Izvor: Izradio autor

Elementi osposobljavanja kandidata za vozača međusobno su povezani, ali su različiti što znači da se ne mogu promatrati izolirani jedan od drugoga jer promjena jednog elementa izravno ima utjecaj na promjene ostalih elemenata.

Teorijsku nastavu realizira profesionalni predavač koja ima završen odgovarajući stupanj i smjer obrazovanja (prometni fakultet).

5.3.1 Stupanj edukacije predavača u autoškoli

Stav ispitanika na postavljeno pitanje: *Znate li stupanj edukacije predavača u autoškoli?* prikazan je na dijagramu 5-3.



Dijagram 5- 3 Stupanj edukacije predavača u autoškoli

Izvor: Izradio autor

Iz dijagrama se uočava da od ukupnog broj anketiranih 256 ili 69 % ne zna koju stručnu spremu ima predavač, dok se 115 ili 31 % izjasnilo da zna koju stručnu spremu ima predavač u autoškoli.

5.3.2 Predznanja o ponašanju u cestovnom prometu

Na pitanje: *Gdje ste prvi put naučili kako se treba ponašati u cestovnom prometu (osnovna pravila prometa)?* odgovori su prikazani u tablici 5-11.

Tablica 5- 11 Prikaz predznanja o ponašanju u prometu

		Predznanje			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Vrtić	37	10,0	10,0	10,0
	Osnovna škola	78	21,0	21,0	31,0
	Niža srednja škola	74	19,9	19,9	50,9
	Autoškola	151	40,7	40,7	91,6
	Ostalo	31	8,4	8,4	100,0
	Total	371	100,0	100,0	

Izvor: Izradio autor

Iz tablice se uočava da je 151 ispitanik ili 40,7 % naučio kako se treba ponašati u prometu u autoškoli, slijedi 78 ispitanika ili 21 % koji su predznanje stekli u osnovnoj školi, 37 ispitanika ili 10 % koji su predznanje stekli u vrtiću, 74 ispitanika ili 19 % koji su predznanje stekli u nižoj srednjoj školi te 31 ispitanik ili 8,4 % ostalih. Većina ispitanika je po prvi put o ponašanju u prometu učila u autoškoli i osnovnoj školi.

5.3.3 Satovi nastave za procjenu rizika nastanka prometnih nesreća

Tablica 5- 12 Prikaz broja satova nastave za procjenu rizika nastanka prometnih nesreća

Nastava

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	1 sat	118	31,8	31,8	31,8
	2 sata	96	25,9	25,9	57,7
	3 sata	48	12,9	12,9	70,6
	Ne	58	15,6	15,6	86,3
	Ne znam	51	13,7	13,7	100,0
	Total	371	100,0	100,0	

Izvor: Izradio autor

U tablici 5-12 prikazani su podaci o mišljenju ispitanika o uvođenju u teorijski dio nastavne jedinice procjenu rizika nastanka prometnih nesreća identifikacijom subjektivnih i objektivnih čimbenika. Od ukupnog broja ispitanika 118 ili 31,8 % izjasnilo se za jedan sat nastave za procjenu rizika nastanka prometnih nesreća, slijedi 96 ispitanika ili 25,9 % koji su se izjasnili za dva sata nastave, 48 ispitanika ili 12,9 % koji su se izjasnili za tri sata nastave, 58 ispitanika ili 15,6 % izjasnili su se da ne trebaju nastavni satovi za procjenu rizika te 51 ispitanik ili 13,7 % koji ne zna treba li ili ne treba takvih vrsta nastavnih jedinica tijekom učenja teorijskog dijela kod osposobljavanja vozača.

Kao što se može vidjeti, većina ispitanika smatra da bi se za procjenu prometnog rizika trebao održati jedan sat nastave.

5.3.4 Videozapis (snimanje) za identifikaciju rizika u prometu

Na pitanje: *Treba li videozapis postati obvezna nastava za procjenu rizika nastanka prometnih nesreća tijekom procesa osposobljavanja kandidata za vozače?* ispitanici su dali svoj stav kao što je prikazano u tablici 5-13.

Tablica 5- 13 Podaci o videozapisu kao dijelu nastave za procjenu rizika nastanka prometnih nesreća

		Videoprocjena			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	22	5,9	5,9	5,9
	1 sat	8	2,2	2,2	8,1
	2 sata	245	66,0	66,0	74,1
	3 sata	89	24,0	24,0	98,1
	Ne znam	7	1,9	1,9	100,0
	Total	371	100,0	100,0	

Izvor: Izradio autor

Iz tablice se uočava da se najviše ispitanika, 245 ili 66 %, izjasnilo za to da dva nastavna sata videosnimaka za procjenu rizika nastanka prometnih nesreća trebaju biti obvezna kao nastavna jedinica tijekom osposobljavanja kandidata za vozača, slijedi 89 ispitanika ili 24 % koji su se izjasnili za uvođenje tri nastavna sata te 22 ispitanika ili 5,9 % koji su protiv uvođenja takve nastavne jedinice. Za jedan sat izjasnilo se osam ispitanika ili 2,2 % te sa stavom „ne znam“ sedam ispitanika ili 1,9 %.

5.3.5 Organiziranje praktične nastave u skupinama s kandidatima za vozače

Stav ispitanika na postavljeno pitanje: *Ima li organizacija praktične nastave u skupinama s kandidatima za vozače pozitivan učinak na procjenu rizika?* dan je u tablici 5-14.

Tablica 5- 14 Praktična nastava u skupinama

Organiziranje praktične nastave u skupinama

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne znam	125	33,5	33,7	33,7
	2 kandidata	111	29,8	29,9	63,6
	3 kandidata	72	19,3	19,4	83,0
	Ne	63	16,9	17,0	100,0
	Total	371	99,5	100,0	
Missing	System	2	5		
	Total	373	100,0		

Izvor: Izradio autor

Iz tablice se uočava da se od ukupnog broja anketiranih 125 ili 33,5 % ispitanika izjasnilo da nema stav o tom pitanju, 111 ili 29,8 % ispitanika su za organiziranje praktične nastave u skupinama s dva kandidata za vozača, dok je najmanje 63 ili 16,9 % ispitanika protiv organiziranja nastave u skupinama.

5.3.6 Prosječni broj kilometara iz praktične nastave

Odgovori na postavljeno pitanje: *Koliko je prosječno kilometara potrebno odvoziti da bi kandidat uspješno završio proces osposobljavanja u autoškoli?* prikazani su u tablici 5-15.

Tablica 5- 15 Prosječni broj kilometara

Kilometraža

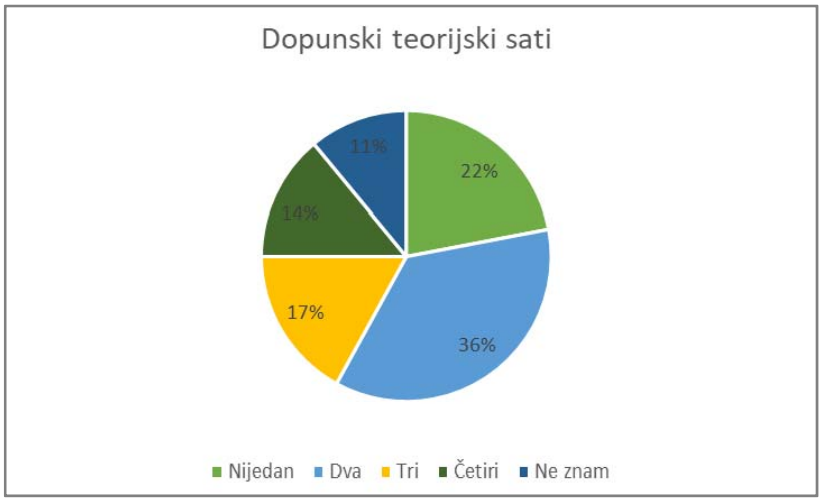
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	≥ 300	160	43,1	43,1	43,1
	> 300 ≥ 400	92	24,8	24,8	67,9
	> 400 ≥ 500	42	11,3	11,3	79,2
	> 500 i više	42	11,3	11,3	90,6
	Ne znam	35	9,4	9,4	100,0
	Total	371	100,0	100,0	

Izvor: Izradio autor

Iz tablice se uočava da se najviše ispitanika, 160 ili 43,1 % izjasnilo da je **≥ 300** prosječan broj kilometara potreban tijekom procesa osposobljavaja da bi kandidat za vozača uspješno završio proces osposobljavanja u autoškoli, slijede 92 ispitanika ili 24,8 % koji su se opredijelili za odgovor > 300 ≥ 400, 42 ispitanika ili 11,3 % smatra da je taj broj > 400 ≥ 500, 42 ili 11,3 %smatra da je potrebno 500 i više kilometara, a odgovor „Ne znam“ Odabralo je 35 ispitanika ili 9,4 %.

5.3.7 Dopunski teorijski satovi

Stav ispitanika na postavljeno pitanje: *Koliko je potrebno dopunskih sati iz teorijske nastave nakon neuspjeha u testu?* prikazan je na dijagramu 5-4.

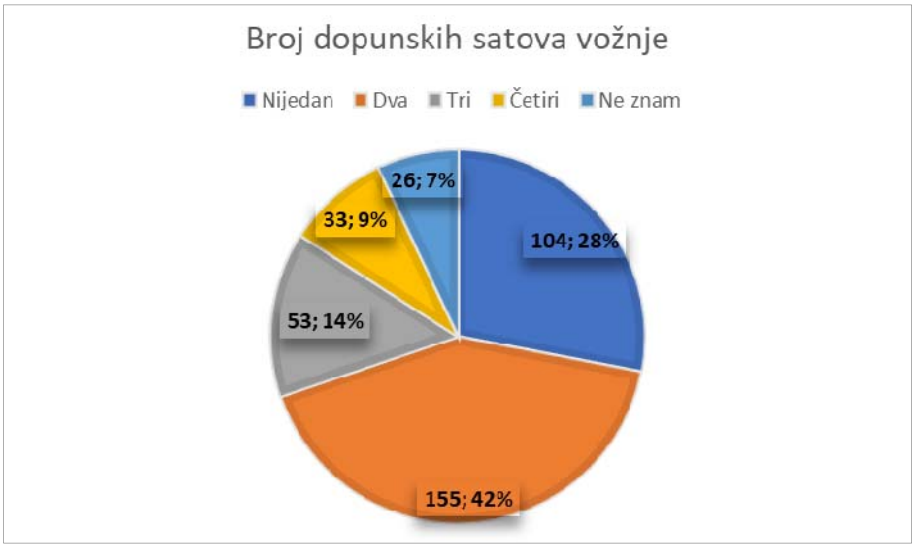


Dijagram 5- 4 Dopunski teorijski sati
Izvor: Izradio autor

Iz dijagrama se uočava da se najviše ispitanika, 36 %, izjasnilo za dva dopunska teorijska sata, slijedi 22 % ispitanika koji su protiv dopunskih teorijskih sati, 17 % ispitanika koji podržavaju tri sata, 14 % ispitanika četiri sata te 11 % ispitanika koji su se izjasnili da ne znaju koliko je dopunskih sati potrebno nakon neuspjeha u testu teorije.

5.3.8 Dopunski satovi vožnje

Na postavljeno pitanje: *Koliko je dopunskih sati vožnje potrebno nakon neuspjeha u testu vožnje?* odgovori su prikazani na dijagramu 5-5.



Dijagram 5- 5 Broj dopunskih satova vožnje

Izvor: Izradio autor

Iz tablice se uočava da se najviše ispitanika, 42 %, izjasnilo za dva dopunska sata vožnje nakon neuspjeha u testu vožnje, slijedi 28 % ispitanika za nijedan sat, 14 % ispitanika za tri sata, 9 % ispitanika za četiri sata te 7 % ispitanika koji ne znaju odgovor na postavljeno pitanje.

6. REZULTATI ANALIZE STATISTIČKE ZNAČAJNOSTI PROMETNIH NESREĆA

U prethodnom poglavlju prikazani su statistički podaci dobiveni praktičnim istraživanjima, u nastavku će biti predstavljene njihove analize s komentarima na glavne točke koje će se upotrijebiti za potvrdu prve hipoteze istraživanja: *Moguće je identificirati subjektivne i objektivne čimbenike koji utječu na procjenu rizika od prometnih nesreća mladih vozača.*

Program SPSS-26 korišten je za obradu podataka iz praktičnog ispitivanja koristeći neparametarski hi-kvadrat test.

Hi-kvadrat test ($\chi 2$ –test) se upotrebljava za ispitivanje nezavisnosti (engl. *indepedence*) dviju varijabli ili čimbenika, slučajnosti (engl. *randomness*) te dobrote prilagodbe (engl. *goodness-to-fit(xx)*). Hi-kvadrat test je vrlo praktičan test koji može osobito poslužiti onda kad se želi utvrditi odstupaju li neke dobivene (opažene) frekvencije od frekvencija koje se očekuju pod određenom hipotezom.

$$\sum_{i=1}^{k} p_i = 1$$

$$\sum_{i=1}^{k} m_i = n \sum_{i=1}^{k} p_i = \sum_{i=1}^{k} x_i$$

$$X^2 = \sum_{i=1}^{k} \frac{(x_i - m_i)^2}{m_i} = \sum_{i=1}^{k} \frac{x_i^2}{m^i} - n$$

$$X^2 - X'^2 = \sum_{i=1}^{k} \frac{x_i^2}{m^i} - \sum_{i=1}^{k} \frac{x_i^2}{m^i}_1$$

[1] https://en.wikipedia.org/wiki/Chi-squared_test

6.1 REZULATI ANALIZE HI-KVADRAT TESTA STATISTIČKE ZNAČAJNOSTI PROMETNIH NESREĆA

6.1.1 Rezultati analiza prometnih nesreća prema spolu

Rezultati analize prometnih nesreća prema spolu prikazani su u tablici 6-1.

Tablica 6- 1 Prikaz rezultata analize prometnih nesreća prema spolu

Crosstab

Count

		Spol		
		m	Ž	Total
Nesreća	Ne	148	125	273
	Da	77	21	98
Total		225	146	371

Izvor: Izradio autor

Tablica 6- 2 Rezultat hi-kvadrat testa prometnih nesreća prema spolu

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	17,929[a]	1	0,000		
Continuity Correction[b]	16,922	1	0,000		
Likelihood Ratio	19,008	1	0,000		
Fisher's Exact Test				0,000	0,000
Linear-by-Linear Association	17,880	1	0,000		
N of Valid Cases	371				

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 38,57.

b. Computed only for a 2x2 table

Izvor: Izradio autor

Iz Tablica 6-1 i 6-2 se uočava da su vozači više uključeni u prometne nesreće u odnosu na vozačice. Postoji statistički značajna razlika (x^2 = 17,929, p = 0,000) u broju frekvencija ispitanika koji nisu bili ili jesu bili uključeni u prometne nesreće s obzirom na spol.

6.1.2 Rezultati analiza prometnih nesreća prema uzrastu

Rezultati analize prometnih nesreća prema uzrastu prikazani su u tablici 6-3.

Tablica 6- 3 Prikaz rezultata analize prometnih nesreća prema uzrastu

Crosstab

Count

		Uzrast				
		16-18	19-20	21-22	23-24	Total
Nesreća	Ne	122	82	33	36	273
	Da	5	47	37	9	98
Total		127	129	70	45	371

Izvor: Izradio autor

Tablica 6- 4 Rezultat hi-kvadrat testa prometnih nesreća prema uzrastu

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	65,807[a]	3	0,000
Likelihood Ratio	75,185	3	0,000
Linear-by-Linear Association	23,377	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 11,89.

Izvor: Izradio autor

Postoji statistički značajna razlika (x^2 = 66,807, p = 0,000) u broju frekvencija ispitanika koji nisu bili ili jesu bili uključeni u prometne nesreće s obzirom na uzrast. Rezultati analize pokazuju da su vozači od 21 do 22 godine češće uključeni u prometne nesreće od ostalih skupina mladih vozača.

6.1.3 Rezultati analiza prometnih nesreća prema frekvenciji vožnje

Rezultati analize prometnih nesreća i frekvencije vožnje prikazani su u tablici 6-5.

Tablica 6- 5 Prikaz rezultata analize prometnih nesreća prema frekvenciji vožnje

Crosstab

Count

		Frekvencije					
		Uvijek	Često	Ponekad	Rijetko	Vrlo rijetko	Total
Nesreća	Ne	37	41	110	63	22	273
	Da	5	7	19	40	27	98
Total		42	48	129	103	49	371

Izvor: Izradio autor

Tablica 6- 6 Rezultat hi-kvadrat testa prometnih nesreća prema frekvenciji vožnje

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	45,990[a]	4	0,000
Likelihood Ratio	44,992	4	0,000
Linear-by-Linear Association	35,294	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0%) have expected count less than 5. The minimum expected count is 11,09.

Izvor: Izradio autor

Postoji statistički značajna razlika ($x^2 = 45,990$, $p = 0,000$) u broju ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na frekvenciju vožnje. Može se zaključiti da su vozači koji su izjavili da su vozili rijetko i vrlo rijetko češće uključeni u prometne nesreće od onih koji su vozili uvijek.

6.1.4 Rezultati analiza prometnih nesreća s obzirom na ograničenje brzine

Rezultati analize prometnih nesreća i ograničenja brzine prikazani su u tablici 6-7.

Tablica 6- 7 Prikaz rezultata analize prometnih nesreća i ograničenja brzine

Nesreća * ograničenje brzina Crosstabulation

Count

		Uvijek	Često	Ponekad	Rijetko	Nikad	Total
Nesreća	ne	138	57	12	62	4	273
	da	40	13	15	21	9	98
Total		178	70	27	83	13	371

Izvor: Izradio autor

Tablica 6- 8 Rezultat hi-kvadrat testa prometnih nesreća prema ograničenju brzine

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	27,748[a]	4	0,000
Likelihood Ratio	24,484	4	0,000
Linear-by-Linear Association	7,021	1	0,008
N of Valid Cases	371		

a. 1 cells (10,0 %) have expected count less than 5. The minimum expected count is 3,43.

Izvor: Izradio autor

Postoji statistički značajna razlika (x^2 = 27,748[a], p = 0,000) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na ograničenje brzine. Rezultati pokazuju da vozači koji su se izjasnili da poštuju brzinu samo zbog radara ili kad su s roditeljem i oni koji ne poštuju brzinu kad voze sa svojim vršnjacima u automobilu, češće su uključeni u prometne nesreće nego oni koji su se izjasnili da uvijek poštuju ograničenje brzine.

6.1.5 Rezultati analiza prometnih nesreća s obzirom na procjene tehnika vožnje

Prema rezultatima analize postoji statistički značajna razlika ($x^2 = 44,831$, $p = 0,000$) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na procjenu tehnike vožnje kao što je prikazano u tablici 6-9.

Tablica 6- 9 Prikaz rezultata analize prometnih nesreća s obzirom na procjenu tehnike vožnje

Crosstab

Count

		Tehnika					
		Vrlo loša	Lošija	Jednaka	Bolja	Najbolja	Total
Nesreća	Ne	7	81	40	98	47	273
	Da	3	4	13	33	45	98
Total		10	85	53	131	92	371

Izvor: Izradio autor

Tablica 6- 10 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na procjenu tehnike vožnje

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	44,831[a]	4	0,000
Likelihood Ratio	49,494	4	0,000
Linear-by-Linear Association	33,616	1	0,000
N of Valid Cases	371		

a. 1 cells (10,0 %) have expected count less than 5. The minimum expected count is 2,64.

Izvor: Izradio autor

Vozači koji su svoju tehniku vožnje procijenili boljom, odnosno najboljom u usporedbi s drugim vozačima, češće su uključeni u prometne nesreće od vozača koji su svoju tehniku procijenili jednakom u usporedbi s drugim vozačima. Vozačice su svoju tehniku vožnje procijenile slabijom od odnosu na ostale vozače.

6.1.6 Rezultati analiza prometnih nesreća s obzirom na psihosocijalne komponente

Prema analizi postoje statistički značajne razlike (x^2 = 112,314, p = 0,000) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na psihosocijalne komponente.

Tablica 6- 11 Prikaz rezultata analize prometnih nesreća s obzirom na psihosocijalne komponente

Crosstab

Count

		Psihosoc.					
		Uvijek	Često	Ponekad	Rijetko	Nikad	Total
Nesreća	Ne	8	18	140	65	42	273
	Da	0	2	12	83	1	98
Total		8	20	152	148	43	371

Izvor: Izradio autor

Tablica 6- 12 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na psihosocijalne komponente

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	112,314[a]	4	0,000
Likelihood Ratio	118,955	4	0,000
Linear-by-Linear Association	18,155	1	0,000
N of Valid Cases	371		

a. 1 cells (10,0 %) have expected count less than 5. The minimum expected count is 2,11.

Izvor: Izradio autor

Može se zaključiti da su vozači koji su se izjasnili da su rijetko imali psihosocijalni tretman ili konflikt, češće uključeni u prometne nesreće od onih koji nisu imali psihosocijalni tretman ili konflikt.

6.1.7 Rezultati analiza prometnih nesreća s obzirom na promjene ponašanja u prometu

Rezultati analize prometnih nesreća s obzirom na promjene ponašanja u prometu prikazani su u tablici 6-13.

Tablica 6- 13 Prikaz rezultata analize prometnih nesreća s obzirom na promjene ponašanja u prometu

Nesreća * Ponašanje Crosstabulation

		Ponašanje					
		Vrlo malo	Malo	Nepromijenjeno	Mnogo	Vrlo mnogo	Total
Nesreća	Ne	156	51	32	22	12	273
	Da	11	30	24	20	13	98
Total		167	81	56	42	25	371

Izvor: Izradio autor

Tablica 6- 14 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na promjene ponašanja u prometu

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	64,403[a]	4	0,000
Likelihood Ratio	71,281	4	0,000
Linear-by-Linear Association	52,940	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 6,60.

Izvor: Izradio autor

Prema analizi postoji statistički značajna razlika (x^2 = 64,403, p = 0,00) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na promjene ponašanja u prometu. Može se zaključiti da su vozači koji su se izjasnili da su promijenili ponašanje u prometu, češće uključeni u prometne nesreće od onih koji nisu promijenili svoje ponašanje u prometu.

6.1.8 Rezultati analize prometnih nesreća s obzirom na elemente osposobljavanja

6.1.8.1 Rezultati analize prometnih nesreća i predznanja o ponašanju u prometu

Rezultati analize prometnih nesreća i predznanja o ponašanju u prometu prikazani su u tablici 6-15.

Tablica 6- 15 Prikaz rezultata analize prometnih nesreća s obzirom na stečeno predznanje o ponašanju u prometu

Crosstab

Count

		Predznanje					
		Vrtić	Osnovna škola	Niža srednja škola	Autoškola	Ostalo	Total
Nesreća	Ne	35	75	64	84	15	273
	Da	2	3	10	67	16	98
Total		37	78	74	151	31	371

Izvor: Izradio autor

Tablica 6- 16 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na stečeno predznanje o prometnim nesrećama

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	70,352[a]	4	0,000
Likelihood Ratio	78,436	4	0,000
Linear-by-Linear Association	60,182	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 8,19.

Izvor: Izradio autor

Prema rezultatima analize postoji statistički značajna razlika (x^2 = 70,352, p = 0,00) u broju frekvencija ispitanika koji nisu bili ili jesu bili uključeni u prometne nesreće s obzirom na predznanje o ponašanju u prometu.

Vozači koji su se izjasnili da su ponašanje u prometu prvi put naučili u autoškoli, odnosno nižoj srednjoj školi, češće su bili uključeni u prometne nesreće od onih koji su pravila naučili u osnovnoj školi, odnosno u vrtiću.

6.1.8.2 Rezultati analize prometnih nesreća i pohađanja teorijske nastave

Rezultati analize prometnih nesreća i pohađanja teorijske nastave za procjene rizika od nastanka prometnih nesreća prikazani su u tablici 6-17.

Tablica 6- 17 Prikaz rezultata analize prometnih nesreća s obzirom na pohađanje teorijske nastave

Crosstab

Count

		Nastava					
		1 sat	2 sat	3 sata	Ne	Ne znam	Total
Nesreća	Ne	111	80	30	32	20	273
	Da	7	16	18	26	31	98
Total		118	96	48	58	51	371

Izvor: Izradio autor

Tablica 6- 18 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na pohađanje teorijske nastave

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	74,307[a]	4	0,000
Likelihood Ratio	77,163	4	0,000
Linear-by-Linear Association	73,165	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0b%) have expected count less than 5. The minimum expected count is 12,68.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 74,307, p = 0,00) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na pohađanje nastave.

Vozači koji su se izjasnili protiv pohađanja teorijske nastave o procjeni rizika nastanka prometnih nesreća i oni koji nisu iznijeli svoj stav o tom pitanju, češće su bili uključeni u prometne nesreće od onih koji su se izjasnili da bi pohađali nastavu dva, odnosno tri sata.

6.1.8.3 Rezultati analiza prometnih nesreća s obzirom na videoprocjene

Rezultati analize prometnih nesreća s obzirom na videoprocjene prikazani su u tablici 6-19.

Tablica 6- 19 Prikaz rezultata analize prometnih nesreća s obzirom na videoprocjene

Nesreća * Videoprocjena Crosstabulation

Count

		Videoprocjena					
		Ne	1 sat	2 sata	3 sata	Ne znam	Total
Nesreća	Ne	10	7	235	19	2	273
	Da	12	1	10	70	5	98
Total		22	8	245	89	7	371

Tablica 6- 20 Prikaz rezultata analize prometnih nesreća s obzirom na videoprocjene

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
PearsonChi-Square	204,859[a]	4	0,000
Likelihood Ratio	207,817	4	0,000
Linear-by-Linear Association	42,957	1	0,000
N of Valid Cases	371		

a. 2 cells (20,0 %) have expected count less than 5. The minimum expected count is 1,85.

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 204,859, p = 0,00) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na videoprocjene.

Rezultat analize pokazuje da su vozači koji su se izjasnili za tri sata i oni koji su protiv videozapisa u nastavi, češće uključeni u prometne nesreće od onih koji podržavaju videoprocjenu rizika od prometne nesreće.

6.1.8.4. Rezultati analize prometnih nesreća s obzirom na broj prijeđenih kilometara iz praktične nastave

Rezultati analize prometnih nesreća i broja prijeđenih kilometara iz praktične nastave prikazani su u tablici 6-21.

Tablica 6- 21 Prikaz rezultata analize prometnih nesreća s obzirom na broj prijeđenih kilometara iz praktične nastave

Crosstab

Count

		Kilometraža					
		≥ 300	> 300 ≥ 400	> 400 ≥ 500	> 500 i više	Ne znam	Total
Nesreća	Ne	103	76	38	30	26	273
	Da	57	16	4	12	9	98
Total		160	92	42	42	35	371

Izvor: Izradio autor

Tablica 6- 22 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na broj prijeđenih kilometara iz praktične nastave

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	17,111[a]	4	0,002
Likelihood Ratio	18,413	4	0,001
Linear-by-Linear Association	3,292	1	0,070
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 9,25.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 17,111, p = 0,002) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na broj prijeđenih kilometara iz praktične nastave.

Vozači koji su se izjasnili da je ≥ 300 i > 500 i više km potrebno da bi kandidat za vozača uspješno završio proces osposobljavanja u autoškoli, češće su bili uključeni u prometne nesreće od onih koji su se izjasnili za > 300 ≥ 400, odnosno za > 400 ≥ 500 kilometara.

6.1.8.5. Rezultati analize prometnih nesreća s obzirom na organiziranje praktične nastave

Rezultati analize prometnih nesreća i organiziranje praktične nastave po skupinama s kandidatima za vozače prikazani su u tablici 6-23.

Tablica 6- 23 Prikaz rezultata analize prometnih nesreća s obzirom na organiziranje praktične nastave

Crosstab

Count

		Organiziranje praktične nastave				
		Ne znam	2 kandidata	3 kandidata	Ne	Total
Nesreća	Ne	113	90	48	22	273
	Da	12	21	24	41	98
Total		125	111	72	63	371

Izvor: Izradio autor

Tablica 6- 24 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na organiziranje praktične nastave

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	71,618[a]	3	0,000
Likelihood Ratio	68,491	3	0,000
Linear-by-Linear Association	65,902	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 16,64.

Izvor: Izradio autor

Iz tablice 6-24 uočava se da postoji statistički značajna razlika ($x^2 = 71,618$, $p = 0,00$) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na organiziranje praktične nastave.

Vozači koji su se izjasnili protiv praktične nastave u skupinama, bili su češće uključeni u prometne nesreće od onih koji su se izjasnili za nastavu od dva, odnosno tri kandidata po skupinama iz praktičke nastave osposobljavanja kandidata za vozača.

6.1.9 Rezultati analize prometnih nesreća i radnji s vozilom

6.1.9.1 Rezultati analize prometnih nesreća s obzirom na manevriranja vozilom

Rezultati analize prometnih nesreća i manevriranja vozilom prikazani su u tablici 6-25.

Tablica 6- 25 Prikaz rezultata analize prometnih nesreća s obzirom na manevriranja vozilom

Crosstab

Count

		Manevriranja					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	23	33	68	88	61	273
	Da	0	0	22	18	58	98
Total		23	33	90	106	119	371

Izvor: Izradio autor

Tablica 6- 26 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na manevriranja vozilom

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	55,648[a]	4	0,000
Likelihood Ratio	66,812	4	0,000
Linear-by-Linear Association	40,594	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 6,08.

Izvor: Izradio autor

Prema analizi postoji statistički značajna razlika (x^2 = 55,648, p = 0,00) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na manevriranje vozilom. Vozači koji su procijenili manevar kao vrlo laku radnju, češće su uključeni u prometne nesreće od onih koji su manevar procijenili kao tešku radnju, odnosno vrlo tešku radnju.

6.1.9.2 Rezultati analize prometnih nesreća s obzirom na uključivanje u promet

Rezultati analize prometnih nesreća s obzirom na radnju uključivanja u promet prikazani su u tablici 6-27.

Tablica 6- 27 Prikaz rezultata analize prometnih nesreća s obzirom na uključivanje u promet

Crosstab

Count

		Uključivanje					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	20	62	40	119	32	273
	Da	0	21	22	37	18	98
Total		20	83	62	156	50	371

Izvor: Izradio autor

Tablica 6- 28 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na uključivanje u promet

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	12,803[a]	4	0,012
Likelihood Ratio	17,598	4	0,001
Linear-by-Linear Association	3,097	1	0,078
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 5,28.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 12,803, p = 0,000) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na uključivanje u promet. Vozači koji su procijenili manevar kao vrlo laku radnju, češće su uključeni u prometne nesreće od onih koji su manevar procijenili kao prosječno tešku, odnosno tešku radnju.

6.1.9.3 Rezultati analize prometnih nesreća s obzirom na promjene prometnih traka

Rezultati analize prometnih nesreća s obzirom na promjene prometnih traka prikazani su u tablici 6-29.

Tablica 6- 29 Prikaz rezultata analize prometnih nesreća s obzirom na promjene prometnih traka

Crosstab

Count

		Traka					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	1	35	44	161	32	273
	Da	2	1	17	62	16	98
Total		3	36	61	223	48	371

Izvor: Izradio autor

Tablica 6- 30 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na promjene prometnih traka

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	14,318[a]	4	0,006
Likelihood Ratio	18,523	4	0,001
Linear-by-Linear Association	5,019	1	0,025
N of Valid Cases	371		

a. 2 cells (20,0 %) have expected count less than 5. The minimum expected count is 0,79.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 14,318, p = 0,006) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na promjene prometnih traka. Vozači koji su procijenili promjene prometnih traka kao vrlo laku radnju, češće su uključeni u prometne nesreće od onih koji su promjene prometnih traka procijenili kao tešku radnju.

6.1.10 Rezultati analize prometnih nesreća i vožnje

6.1.10.1 Rezultati analize prometnih nesreća s obzirom na distrakcije tijekom vožnje

Tablica 6- 31 Prikaz rezultata analize prometnih nesreća s obzirom na distrakcije tijekom vožnje

Count

		Distrakcije					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	130	64	29	26	24	273
	Da	9	14	22	35	18	98
Total		139	78	51	61	42	371

Izvor: Izradio autor

Tablica 6- 32 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na distrakcije tijekom vožnje

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	74,573[a]	4	0,000
Likelihood Ratio	77,973	4	0,000
Linear-by-Linear Association	61,977	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 11,09.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 74,573, p = 0,00) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na distrakcije tijekom vožnje. Vozači koji su procijenili distrakciju kao prosječnu i laku smetnju, češće su uključeni u prometne nesreće od onih koji su distrakciju okarakterizirali kao tešku smetnju.

6.1.10.2 Rezultati analize prometnih nesreća s obzirom na noćne vožnje

Rezultati analize prometnih nesreća s obzirom na noćne vožnje prikazani su u tablici 6-33.

Tablica 6- 33 Prikaz rezultata analize prometnih nesreća s obzirom na vožnje noću

Crosstab

Count

		Noć					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	29	93	56	65	30	273
	Da	0	0	23	50	25	98
Total		29	93	79	115	55	371

Izvor: Izradio autor

Tablica 6- 34 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnje noću

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	71,574[a]	4	0,000
Likelihood Ratio	99,843	4	0,000
Linear-by-Linear Association	62,750	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 7,66.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 71,574, p = 0,000) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće tijekom vožnje noću. Vozači koji su procijenili noćne vožnje kao laku, odnosno vrlo laku smetnju, češće su uključeni u prometne nesreće od onih koji su noćnu vožnju procijenili kao prosječnu, odnosno tešku smetnju.

6.1.10.3 Rezultati analize prometnih nesreća s obzirom na vožnju izvan grada

Rezultati analize prometnih nesreće s obzirom na vožnju izvan grada prikazani su u tablici 6-35.

Tablica 6- 35 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju izvan grada

Crosstab

Count

		Izvan grada					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	23	40	106	74	30	273
	Da	0	0	36	41	21	98
Total		23	40	142	115	51	371

Izvor: Izradio autor

Tablica 6- 36 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju izvan grada

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	33,463[a]	4	0,001
Likelihood Ratio	48,680	4	0,000
Linear-by-Linear Association	29,691	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 6,08.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 33,463a, p = 0,001) u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na vožnju izvan grada. Vozači koji su procijenili vožnju izvan grada kao laku, odnosno kao vrlo laganu okolnost, češće su uključeni u prometne nesreće od onih koji su ju procijenili kao prosječnu okolnost.

6.1.10.4 Rezultati analize prometnih nesreća s obzirom na vožnju vikendom

Rezultati analize prometnih nesreća s obzirom na vožnje vikendom prikazani su u tablici 6-37.

Tablica 6- 37 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju vikendom

Crosstab

Count

		Vikend					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	19	103	56	65	30	273
	Da	0	9	29	34	26	98
Total		19	112	85	99	56	371

Izvor: Izradio autor

Tablica 6- 38 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju vikendom

Chi-Square Tests

	Value	Df	Asymptotic Significance (2-sided)
Pearson Chi-Square	43,620[a]	4	0,000
Likelihood Ratio	51,932	4	0,000
Linear-by-Linear Association	37,968	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 5,02.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 43,620, p = 0,000) u frekvenciji ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na vožnju vikendom. Vozači koji su procijenili vožnju vikendom kao prosječnu i vrlo laku okolnost, češće su uključeni u prometne nesreće od onih koji su vožnju vikendom procijenili kao tešku okolnost koja može dovesti do nastanka prometne nesreće.

6.1.10.5 Rezultati analize prometnih nesreća s obzirom na reagiranje u vožnji

Rezultati analize prometnih nesreća s obzirom na reagiranje u vožnji prikazani su u tablici 6-39.

Tablica 6- 39 Prikaz rezultata analize prometnih nesreća s obzirom na reagiranje u vožnji

Crosstab

Count

		Reagiranje					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	Ne	115	75	32	27	24	273
	Da	0	18	30	22	28	98
Total		115	93	62	49	52	371

Izvor: Izradio autor

Tablica 6- 40 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na reagiranje u vožnji

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	87,808[a]	4	0,000
Likelihood Ratio	111,927	4	0,000
Linear-by-Linear Association	77,128	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 12,94.

Izvor: Izradio autor

Iz tablice se uočava da postoji statistički značajna razlika (x^2 = 87,808, p = 0,000) u frekvenciji ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na reagiranje u vožnji. Vozači koji su procijenili reagiranje u vožnji kao prosječnu, odnosno vrlo laku okolnost, češće su uključeni u prometne nesreće od onih koji su reagiranje na iznenadne okolnosti na cesti procijenili kao teške okolnosti.

6.1.10.6 Rezultati analize prometnih nesreća s obzirom na signalizaciju

Rezultati analize prometnih nesreća s obzirom na signalizaciju, odnosno prometne znakove koji upozoravaju o rizicima na cesti, prikazani su u tablici 6-41.

Tablica 6- 41 Prikaz rezultata analize prometnih nesreća s obzirom na signalizaciju

Count

		Signalizacija					
		Vrlo loše	Loše	Prosječno	Dobro	Vrlo dobro	Total
Nesreća	Ne	26	121	44	50	32	273
	Da	0	21	22	26	29	98
Total		26	142	66	76	61	371

Izvor: Izradio autor

Tablica 6- 42 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na signalizaciju

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	37,216[a]	4	0,001
Likelihood Ratio	43,309	4	0,000
Linear-by-Linear Association	34,785	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 6,87.

Izvor: Izradio autor

Prema analizi postoji statistički značajna razlika ($x^2 = 37,216$, $p = 0,001$) u frekvenciji ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na signalizaciju. Vozači koji su ocijenili da je postavljanje signalizacije u odnosu na upozorenje rizika na cesti dobro, češće su uključeni u prometne nesreće od onih koji su postavljanje signalizacije procijenili kao loše.

6.1.10.7 Rezultati analize prometnih nesreća s obzirom na vozilo

Tablica 6- 43 Prikaz rezultata analize prometnih nesreća s obzirom na vozilo

Count

		Vozila					
		Vrlo loše	Loše	Prosječno	Dobro	Vrlo dobro	Total
Nesreća	Ne	9	32	159	50	23	273
	Da	0	0	72	26	0	98
Total		9	32	231	76	23	371

Izvor: Izradio autor

Tablica 6- 44 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vozilo

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	28,036[a]	4	0,001
Likelihood Ratio	44,103	4	0,000
Linear-by-Linear Association	1,126	1	0,289
N of Valid Cases	371		

a. 1 cells (10,0 %) have expected count less than 5. The minimum expected count is 2,38.

Izvor: Izradio autor

Prema analizi postoji statistički značajna razlika ($x^2 = 28,036$, $p = 0,001$) u frekvenciji ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na vozilo.

Vozači koji su osnovne elemente sigurnosti vozila procijenili dobrim, češće su uključeni u nesreće od onih koji su ih procijenili lošim.

6.1.10.8 Rezultati analize prometnih nesreća s obzirom na vožnju po suhoj i čistoj površini kolnika

Tablica 6- 45 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju po suhoj i čistoj površini kolnika

Nesreća * Suho Crosstabulation

Count

		Suho					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	ne	26	145	69	13	20	273
	da	0	1	2	43	52	98
Total		26	146	71	56	72	371

Izvor: Izradio autor

Tablica 6- 46 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju po suhoj i čistoj površini kolnika

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	230,224[a]	4	0,000
Likelihood Ratio	252,446	4	0,000
Linear-by-Linear Association	182,795	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 6,87.

Izvor: Izradio autor

Prema analizi postoji statistički značajna razlika (x^2 = 230,224, p = 0,000) u frekvenciji ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na vožnju po suhoj i čistoj površini kolnika. Vozači koji su procijenili vožnju po suhoj i čistoj površini kolnika vrlo lakom, odnosno lakom, češće su uključeni u prometne nesreće od onih koji su vožnju po suhoj i čistoj površini kolnika procijenili kao prosječno tešku, odnosno tešku.

6.1.10.9 Rezultati analize prometnih nesreća s obzirom na vožnju na ravnom cestovnom segmentu

Tablica 6- 47 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju na ravnom cestovnom segmentu

Nesreća * Ravnica Crosstabulation

Count

		Ravnica					
		Vrlo teško	Teško	Prosječno	Lako	Vrlo lako	Total
Nesreća	ne	26	144	70	13	20	273
	da	0	5	7	34	52	98
Total		26	149	77	47	72	371

Izvor: Izradio autor

Tablica 6- 48 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju na ravnom cestovnom segmentu

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	190,707[a]	4	0,000
Likelihood Ratio	197,193	4	0,000
Linear-by-Linear Association	160,618	1	0,000
N of Valid Cases	371		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 6,87.

Izvor: Izradio autor

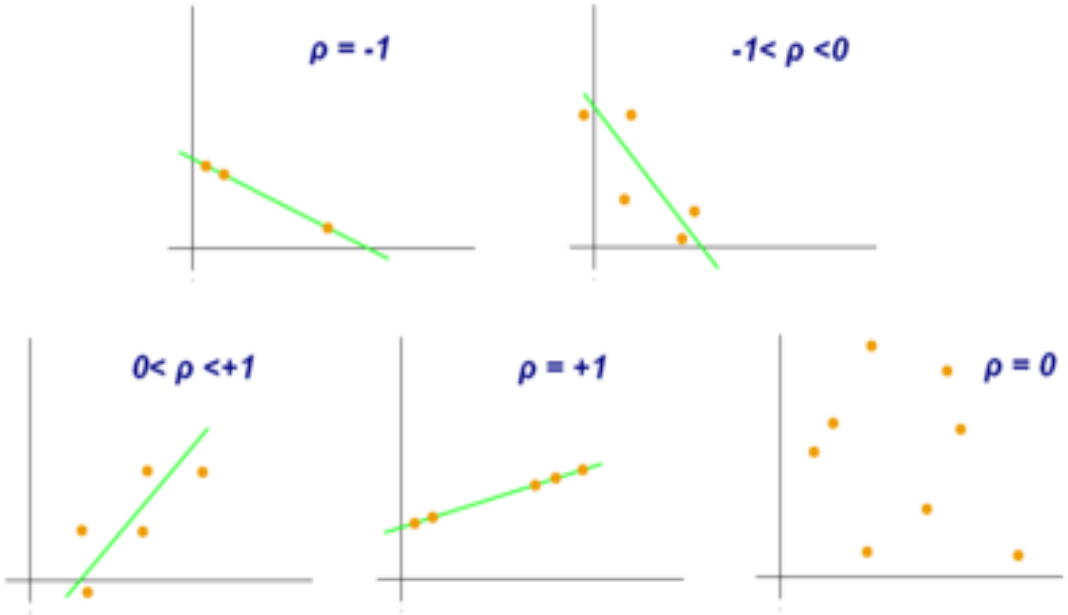
Prema analizi postoji statistički značajna razlika (x^2 = 190,707, p = 0,000) u frekvenciji ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na vožnju na ravnom cestovnom segmentu. Vozači koji su procijenili vožnju na ravnom cestovnom segmentu kao vrlo laku, odnosno laku, češće su uključeni u prometne nesreće od onih koji su vožnju na ravnom cestovnom segmentu procijenili kao prosječno tešku, odnosno tešku.

6.2 KORELACIJSKA ANALIZA

Da bi se potvrdila druga hipoteza: *moguće je odrediti korelaciju između temeljnih čimbenika sigurnosti u koje se ubrajaju čovjek, vozilo, cesta i okruženje te identificiranih subjektivnih i objektivnih čimbenika kod mladih vozača*, provedena je korelacijska analiza između ulaznih promjenjivih varijabli i izlazne nepromjenjive varijable – prometna nesreća.

Korelacijska analiza izvršena je korištenjem elektroničkog programa SPSS-verzije 26.0.

Pearsonov koeficijent korelacije mjeri linearnu korelaciju između dviju varijabli X i Y. Ona ima vrijednost između +1 i −1, gdje je 1 ukupna pozitivna linearna korelacija, 0 nije linearna korelacija, a −1 je ukupna negativna linearna korelacija. Pearsonov koeficijent korelacije kad se primjenjuje na populaciju, obično je predstavljen grčkim slovom ρ (rho) i može se nazvati koeficijentom korelacije stanovništva ili koeficijentom populacije Pearson.



Dijagram 6- 1 Rasipanja s različitim vrijednostima koeficijenta korelacije (ρ)

Izvor:[7]

Koeficijent korelacije kreće se od −1 do 1. Iz vrijednosti 1 podrazumijeva se da linearna jednadžba savršeno opisuje odnos između x i y, a sve podatkovne točke leže na liniji za koju y raste kako se x povećava. Vrijednost −1 podrazumijeva da sve podatkovne točke leže na liniji za koju se y smanjuje kako x raste. Vrijednost 0 implicira da ne postoji linearna povezanost među varijablama.

U nastavku su predstavljeni rezultati glavnih komponenti koji potvrđuju drugu hipotezu u ovom radu.

6.2.1 Korelacija: prometne nesreće – osnovne značajke mladih vozača

Rezultati korelacijske analize navedenih ulaznih promjenjivih varijabli (spol, uzrast, vozačko iskustvo) s ovisnom nepromjenjivom izlaznom varijablom − prometna nesreća − prikazani su u tablici 6-49.

Tablica 6- 49 Rezultat testa korelacije osnovnih značajki mladih vozača

Correlations

		Nesreća	Spol	Uzrast	Vozačko iskustvo
Nesreća	Pearson Correlation	1	−.220**	.251**	−.244**
	Sig. (2-tailed)		.000	.000	.000
	N	371	371	371	371
Spol	Pearson Correlation	−.220**	1	.220**	.335**
	Sig. (2-tailed)	.000		.000	.000
	N	371	371	371	371
Uzrast	Pearson Correlation	.251**	.220**	1	.724**
	Sig. (2-tailed)	.000	.000		.000
	N	371	371	371	371
Vozačko iskustvo	Pearson Correlation	−.244**	.335**	.724**	1
	Sig. (2-tailed)	.000	.000	.000	
	N	371	371	371	371

**. Correlation is significant at the 0.01 level (2-tailed).

Izvor: Izradio autor

Iz tablice se uočava da postoji statistička značajnost koeficijenta korelacije između navedenih varijabli. Najizraženija povezanost između prometnih nesreća i osnovnih značajki mladih vozača je uzrast (r` = .251, p = .000), dok je u odnosu na vozačko iskustvo (r` = −.244, p = .000) i na spol (r` = −.220, p = .000) korelacija negativna.

Dokazano je da postoji povezanost između ulaznih varijabli osnovnih značajki mladih vozača. Iz tablice se vidi da postoji negativna povezanost s vozačkim iskustvom i spolom, što znači da se s porastom dobi, odnosno vozačkog iskustva, vjerojatnost nastanka prometnih nesreća smanjuje.

6.2.2 Korelacija: prometne nesreće – ostale promjenjive varijable

Rezultati korelacijske analize ulaznih promjenjivih varijabli (reagiranje, prilagodba, psihosocijalna komponenta, videoprocjena, distrakcije) s ovisnom izlaznom nepromjenjivom varijablom − prometna nesreća − prikazani su u tablici 6-50.

Tablica 6- 50 Rezultat testa korelacije ostalih promjenjivih varijabli

Correlations

		Nesreća	Reagiranje	Prilagodba	Psihosoc.	Distrakcije	Video-procjena
Nesreća	Pearson Correlation	1	.457**	.380**	.222**	.409**	.406**
	Sig. (2tailed)		.000	.000	.000	.000	.000
	N	371	371	371	371	371	371
Reagiranje	Pearson Correlation	.457**	1	.951**	.151**	.901**	.184**
	Sig. (2-tailed)	.000		.000	.004	.000	.000
	N	371	371	371	371	371	371
Prilagodba	Pearson Correlation	.380**	.951**	1	.244**	.860**	.158**
	Sig. (2-tailed)	.000	.000		.000	.000	.002
	N	371	371	371	371	371	371
Psihosoc.	Pearson Correlation	.222**	.151**	.244**	1	.141**	.161**
	Sig. (2-tailed)	.000	.004	.000		.007	.002
	N	371	371	371	371	371	371
Distrakcije	Pearson Correlation	.409**	.901**	.860**	.141**	1	.171**
	Sig. (2-tailed)	.000	.000	.000	.007		.001
	N	371	371	371	371	371	371
Videoprocjena	Pearson Correlation	.406**	.184**	.158**	.161**	.171**	1
	Sig. (2-tailed)	.000	.000	.002	002	.001	
	N	371	371	371	371	371	371

**. Correlation is significant at the 0.01 level (2-tailed).

Izvor: Izradio autor

Iz tablice se uočava da prometne nesreće imaju najveću vrijednost korelacije s ulaznom varijablom reagiranje, slijede distrakcije, videoprocjena za identificiranje rizika u prometu i prilagodba (r` = .457, r` = .409, r` = .406 p = .000 i r` = .380 p =.000), dok su najniže vrijednosti korelacije s psihosocijalnom komponentom (`r` = .222 p = .000).

Korelacija s većim vrijednostima između ulaznih varijabli (neovisna) je kod reagiranja i prilagodbe (r` = .951, p < .000), dok je najmanja vrijednost kod psihosocijalne komponente i distrakcije (r` = .141, p < .007). Nema negativne korelacije između ulaznih varijabli.

Ostale vrijednosti korelacije između prometne nesreće i ulazne varijable, odnosno između neovisne varijable mogu se vidjeti u tablici 6-50.

Postoji jaka korelacija između distrakcija – reakcija – prilagodba – psihosocijalni utjecaj te videoprocjena, što znači da povećanje vrijednosti navedene varijable implicira porast rizika vjerojatnosti nastanka prometne nesreće.

Zaključak je da postoje korelacije između osnovnih čimbenika sigurnosti prometa na cestama i subjektivnih i objektivnih uzroka koji su identificirani i utječu na vjerojatnost nastanka prometnih nesreća.

6.2.3 Korelacija: prometne nesreće − vožnja u različitim uvjetima i okolnostima u prometu

Rezultati korelacijske analize između ulaznih promjenjivih varijabli (brzina, suho, vožnja izvan grada, ravnica, vikend te noć) s ovisnom izlaznom nepromjenjivom varijablom − prometne nesreće − prikazani su u tablici 6-51.

Tablica 6- 51 Rezultat testa korelacije prometne nesreće – vožnja

Correlations

		Nesreća	Brzina	Suho	Izvan grada	Vikend	Ravnica	Noć
Nesreća	Pearson Correlation	1	.744**	.703**	.283**	.320**	.659**	.412**
	Sig. (2-tailed)		.000	.000	.000	.000	.000	.000
	N	371	371	371	371	371	371	371
Brzina	Pearson Correlation	.744**	1	.598**	.399**	.456**	.565**	.547**
	Sig. (2-tailed)	.000		.000	.000	.000	.000	.000
	N	371	371	371	371	371	371	371
Suho	Pearson Correlation	.703**	.598**	1	.215**	.197**	.982**	.269**
	Sig. (2-tailed)	.000	.000		.000	.000	.000	.000
	N	371	371	371	371	371	371	371
izvan grada	Pearson Correlation	.283**	.399**	.215**	1	.681**	.225**	.693**
	Sig. (2-tailed)	.000	.000	.000		.000	.000	.000
	N	371	371	371	371	371	371	371
Vikend	Pearson Correlation	.320**	.456**	.197**	.681**	1	.200**	.895**
	Sig. (2-tailed)	.000	.000	.000	.000		.000	.000
	N	371	371	371	371	371	371	371
Ravnica	Pearson Correlation	.659**	.565**	.982**	.225**	.200**	1	.267**
	Sig. (2-tailed)	.000	.000	.000	.000	.000		.000
	N	371	371	371	371	371	371	371
Noć	Pearson Correlation	.412**	.547**	.269**	.693**	.895**	.267**	1
	Sig. (2-tailed)	.000	.000	.000	.000	.000	.000	
	N	371	371	371	371	371	371	371

**. Correlation is significant at the 0.01 level (2-tailed).

Izvor: Izradio autor

Iz tablice se uočava da prometne nesreće imaju najveću vrijednost korelacije s ulaznom varijablom brzinom (r` = .744, p = .000), dok su najniže vrijednosti korelacije s vožnjom izvan grada (r` = .283, p = .000).

Povezanost s većim vrijednostima između ulaznih varijabli (neovisna) je kod suho i ravnice (r` = .982, p = .000), dok je najmanja vrijednost kod suho i vožnja vikendom (r` = .197 p = .000). Ne postoje negativne korelacije među ulaznim varijablama.

Ostale vrijednosti korelacije između prometne nesreće i ulaznih varijabli, odnosno između neovisne varijable mogu se vidjeti u tablici 6-51.

Povećanjem brzine i podcjenjivanjem rizika (subjektivni čimbenici) tijekom vožnje po suhoj i čistoj prometnoj površini (objektivni čimbenik – cesta) / po vedrom vremenu (objektivni čimbenik – okruženje), na ravnom cestovnom segmentu (idealni uvjeti za brzu vožnju) i noću (objektivni čimbenik – okruženje) povećava se vjerojatnost nastanka prometnih nesreća.

Zaključujemo da postoji povezanost između glavnih čimbenika sigurnosti prometa na cestama čovjek – cesta – okolina i uzrocima prometnih nesreća koji su identificirani: reagiranje, prilagodba, brzina, precjenjivanje i podcjenjivanje rizika u prometu (subjektivni uzroci) elementi ceste – ravni cestovni segment (objektivni uzroci – cesta), suhi kolnik (objektivni uzroci – cesta), okolnosti (objektivni uzrok – okruženje).

6.2.4 Korelacija prometne nesreće – tehnika vožnje – radnje vozilom na cesti

Rezultati korelacijske analize između ulaznih promjenjivih varijabli (tehnika vožnje, manevra, uključivanje u promet i pretjecanje) s ovisnom izlaznom nepromjenjivom varijablom – prometna nesreća – prikazani su u tablici 6-52.

Tablica 6- 52 Rezultat testa korelacije prometne nesreće - radnje vozilom na cesti

Correlations

		Nesreća	Kilometraža	Tehnika	Manevriranja	Uključivanje	Traka	Pretjecanja
Nesreća	Pearson Correlation	1	−.094	.301**	.331**	.091	.116*	.689**
	Sig. (2-tailed)		.070	.000	.000	.078	.025	.000
	N	371	371	371	371	371	371	371
Kilometraža	Pearson Correlation	−.094	1	−.019	.304**	.380**	.309**	−.113*
	Sig. (2-tailed)	.070		.712	.000	.000	.000	.029
	N	371	371	371	371	371	371	371
Tehnika	Pearson Correlation	.301**	−.019	1	.268**	.374**	.312**	.165**
	Sig. (2-tailed)	.000	.712		.000	.000	.000	.001
	N	371	371	371	371	371	371	371
Manevriranja	Pearson Correlation	.331**	.304**	.268**	1	.490**	.187**	.227**
	Sig. (2-tailed)	.000	.000	.000		.000	.000	.000
	N	371	371	371	371	371	371	371
Uključivanje	Pearson Correlation	.091	.380**	.374**	.490**	1	.180**	−.012
	Sig. (2-tailed)	.078	.000	.000	.000		.000	.824
	N	371	371	371	371	371	371	371
Traka	Pearson Correlation	.116*	.309**	.312**	.187**	.180**	1	.244**
	Sig. (2-tailed)	.025	.000	.000	.000	.000		.000
	N	371	371	371	371	371	371	371
Pretjecanja	Pearson Correlation	.689**	−.113*	.165**	.227**	−.012	.244**	1
	Sig. (2-tailed)	.000	.029	.001	.000	.824	.000	
	N	371	371	371	371	371	371	371

**. Correlation is significant at the 0.01 level (2-tailed); *. Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izradio autor

Iz tablice se uočava da prometne nesreće imaju najveću vrijednost korelacije s ulaznom varijablom pretjecanje (r` = .689, p = .000), dok su najniže korelacije s promjenom prometne trake (r` = .091, p = .000).

Povezanost s većim vrijednostima između ulaznih varijabli (neovisna) je kod uključivanja u promet i manevriranja vozilom (r` = .490, p = .000), dok je najmanja vrijednost kod pretjecanja i tehnika (r` = .165, p = .000). Negativna korelacija je kod kilometraže (r` = .113, p = .000).

Ostale vrijednosti korelacije između prometne nesreće i ulaznih varijabli, odnosno između neovisne varijable mogu se vidjeti u tablici 6-52.

Podcjenjivanje rizika (subjektivni uzrok) koji u većini slučajeva izaziva pogreške novih vozača tijekom vožnje, povećava rizik vjerojatnosti nastanka prometne nesreće.

Povećavanjem vrijednosti pogrešaka (subjektivni uzrok) tijekom radnje s vozilom u prometu (skretanje, uključivanje, promjena prometne trake, gubitak kontrole nad vozilom) te pretjecanja kao glavnog uzroka prometnih nesreća, povećava se rizik vjerojatnosti nastanka prometnih nesreća. Te se pogreške uglavnom događaju zbog činjenice da mladi vozači nisu savladali tehniku vožnje dovoljno tijekom praktičnog osposobljavanja u autoškoli.

Postoje korelacije između osnovnih čimbenika sigurnosti prometa na cestama: čovjek okruženje i subjektivnih i objektivnih uzroka prometnih nesreća koji su identificirani s posebnim naglaskom na precjenjivanje tehnike vožnje i pogreške pri obavljanju manevara s vozilom.

6.2.5 Korelacija: prometne nesreće – signalizacija – vozilo

Rezultati korelacijske analize ulaznih promjenjivih varijabli (frekvencija, ponašanje, nastava, iskustvo, vozilo te signalizacija) s ovisnom izlaznom nepromjenjivom varijablom – prometna nesreća – prikazani su u tablici 6-53.

Tablica 6- 53 Rezultat testa korelacije prometne nesreće – vozilo

Correlations

		Nesreća	Frekvencije	Ponašanje	Nastava	Iskustvo	Vozila	Signalizacija
Nesreća	Pearson Correlation	1	.309**	.378**	.445**	.541**	.055	.307**
	Sig. (2-tailed)		.000	.000	.000	.000	.289	.000
	N	371	371	371	371	371	371	371
Frekvencije	Pearson Correlation	.309**	1	.172**	.151**	.198**	.017	.124*
	Sig. (2-tailed)	.000		.001	.003	.000	.747	.017
	N	371	371	371	371	371	371	371
Ponašanje	Pearson Correlation	.378**	.172**	1	.870**	.879**	.540**	.915**
	Sig. (2-tailed)	.000	.001		.000	.000	.000	.000
	N	371	371	371	371	371	371	371
Nastava	Pearson Correlation	.445**	.151**	.870**	1	.894**	.525**	.851**
	Sig. (2-tailed)	.000	.003	.000		.000	.000	.000
	N	371	371	371	371	371	371	371
Iskustvo	Pearson Correlation	.541**	.198**	.879**	.894**	1	.572**	.882**
	Sig. (2-tailed)	.000	.000	.000	.000		.000	.000
	N	371	371	371	371	371	371	371
Vozila	Pearson Correlation	.055	.017	.540**	.525**	.572**	1	.638**
	Sig. (2-tailed)	.289	.747	.000	.000	.000		.000
	N	371	371	371	371	371	371	371
Signalizacija	Pearson Correlation	.307**	.124*	.915**	.851**	.882**	.638**	1
	Sig. (2-tailed)	.000	.017	.000	.000	.000	.000	
	N	371	371	371	371	371	371	371

**. Correlation is significant at the 0.01 level (2-tailed) ; *. Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izradio autor

Iz tablice se uočava da prometne nesreće imaju najveću vrijednost korelacije s ulaznom varijablom iskustvom (r` = .541, p = .000). Ne postoji negativna korelacija kod prometne nesreće i ulaznih varijabli.

Korelacija s većim vrijednostima između ulaznih varijabli (neovisna) je kod ponašanja i signalizacije (r` = .915, p = .000). Ne postoji negativna korelacija između ulaznih varijabli.

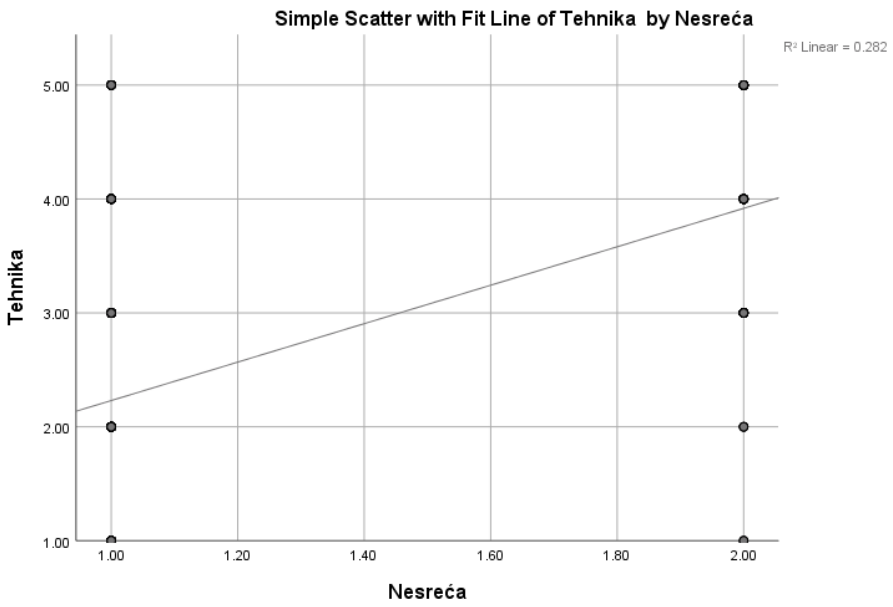
Ostale vrijednosti korelacije između prometne nesreće i ulaznih varijabli, odnosno između neovisne varijable mogu se vidjeti u tablici 6-51.

S povećanjem frekvencije vožnje povećava se iskustvo u vožnji što rezultira pozitivno na stav mladih vozača prema sigurnosti u prometu.

Postoje korelacije između osnovnih čimbenika sigurnosti prometa na cestama: čovjek – vozilo – cesta – okruženje i subjektivnih i objektivnih uzroka prometnih nesreća koji su identificirani s posebnim naglaskom na frekvenciju, satove procjene rizika te ponašanje.

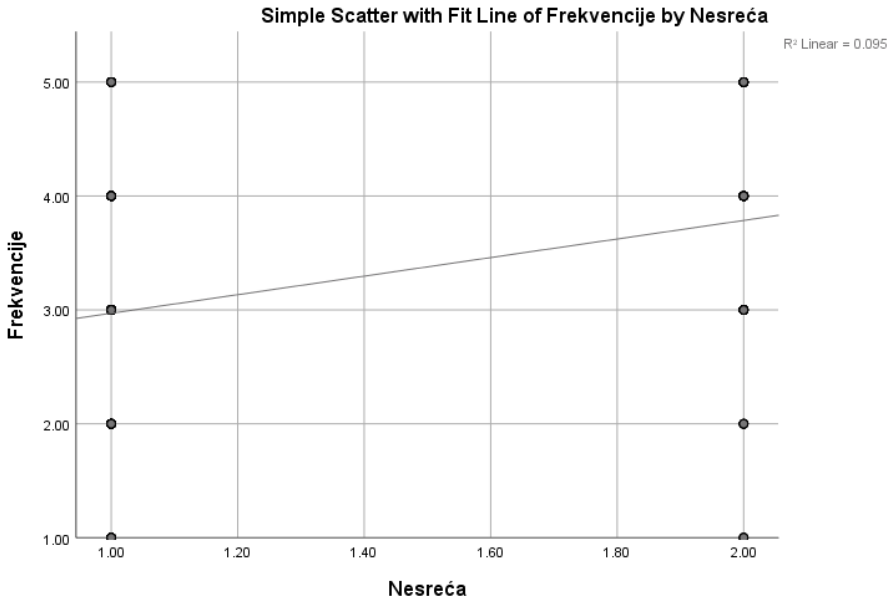
Zaključak: na temelju analize korelacije potvrđena je druga hipoteza da postoji mogućnost određivanja korelacije između temeljnih čimbenika sigurnosti u koje se ubrajaju čovjek, vozilo, cesta i okruženje te identificiranih subjektivnih i objektivnih čimbenika kod mladih vozača.

U nastavku su prikazani dijagrami između promjenjivih ulaznih varijabli s ovisnom nepromjenjivom izlaznom varijablom – prometna nesreća – koje su prethodno komentirane.



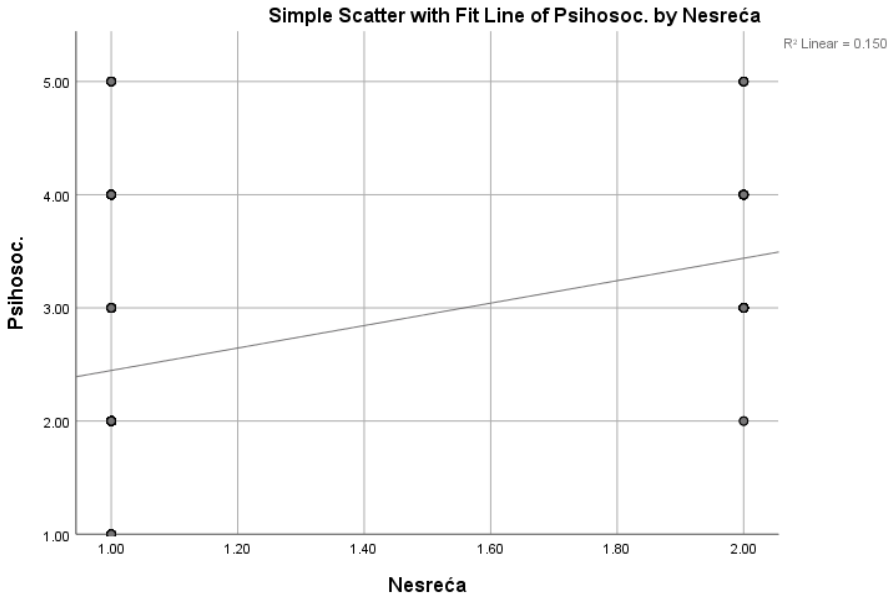
Dijagram 6- 2 Korelacije prometne nesreće – tehnika vožnje

Izvor: Izradio autor



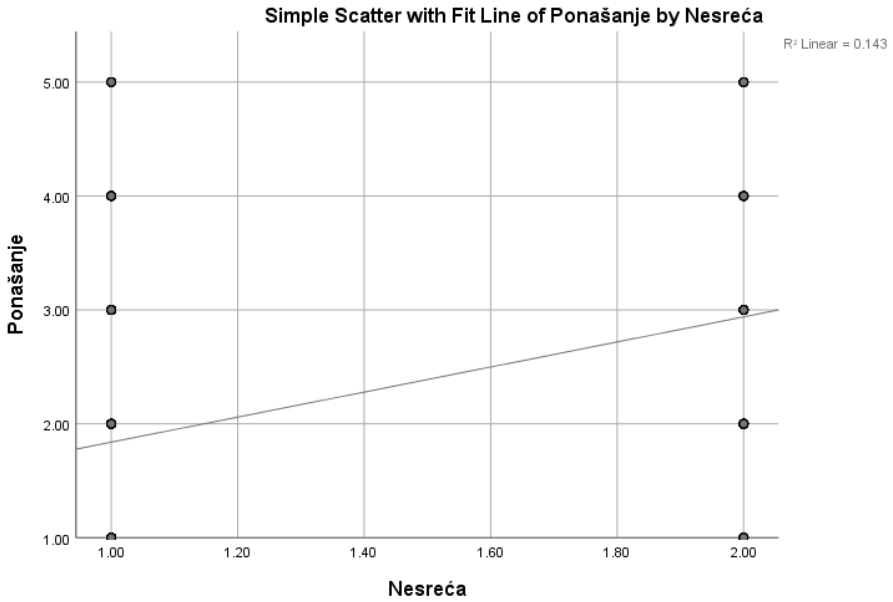
Dijagram 6- 3 Korelacije prometne nesreće – frekvencija vožnje

Izvor: Izradio autor



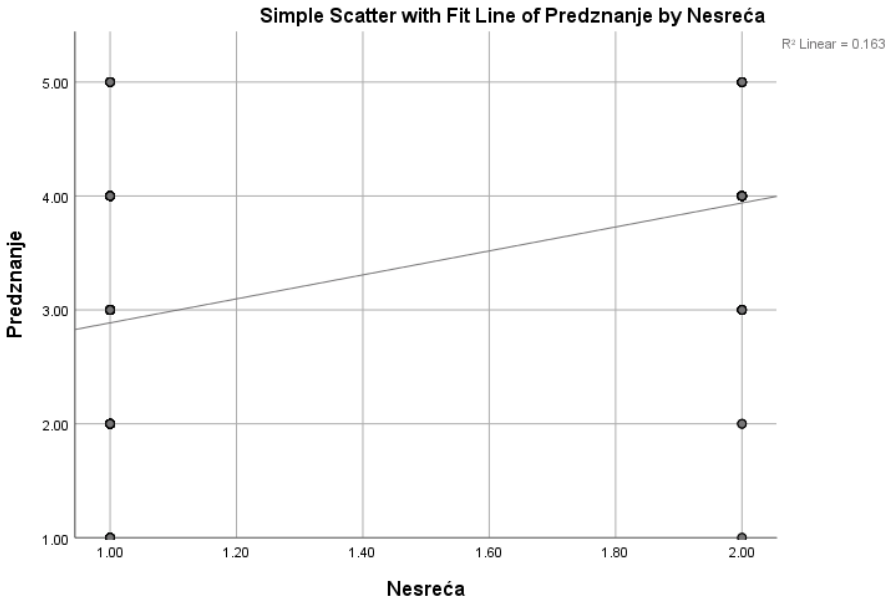
Dijagram 6- 4 Korelacije prometne nesreće – psihosocijalna komponenta

Izvor: Izradio autor



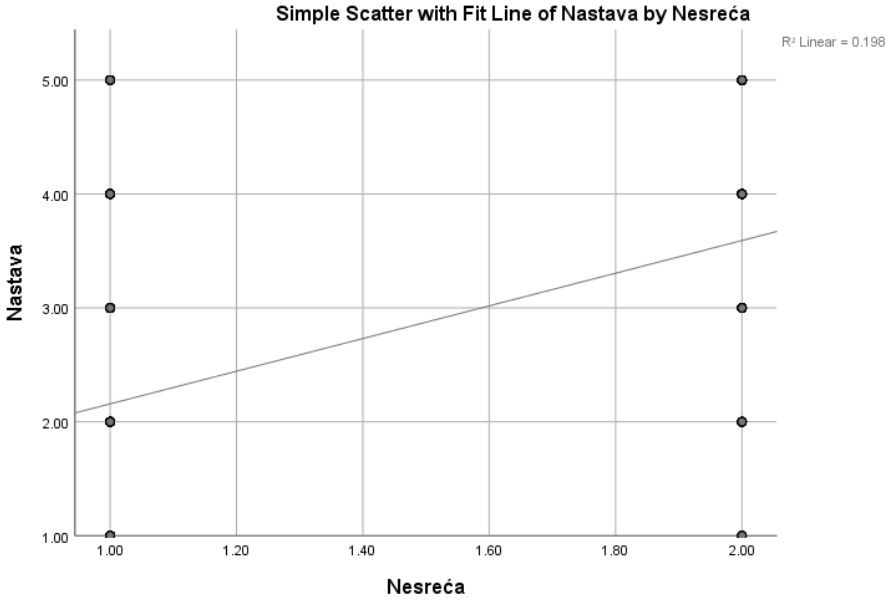
Dijagram 6- 5 Korelacije prometne nesreće – ponašanja

Izvor: Izradio autor



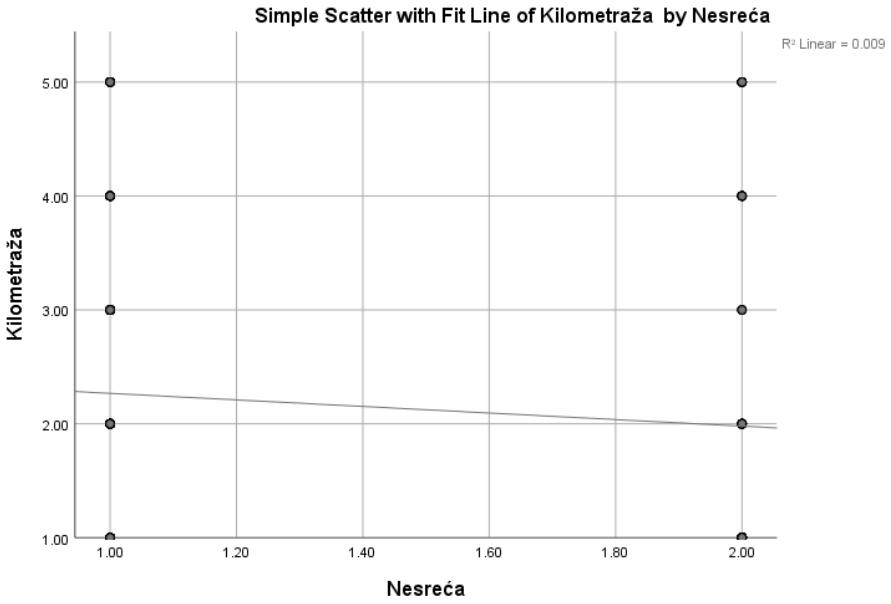
Dijagram 6- 6 Korelacije prometne nesreće – predznanja

Izvor: Izradio autor



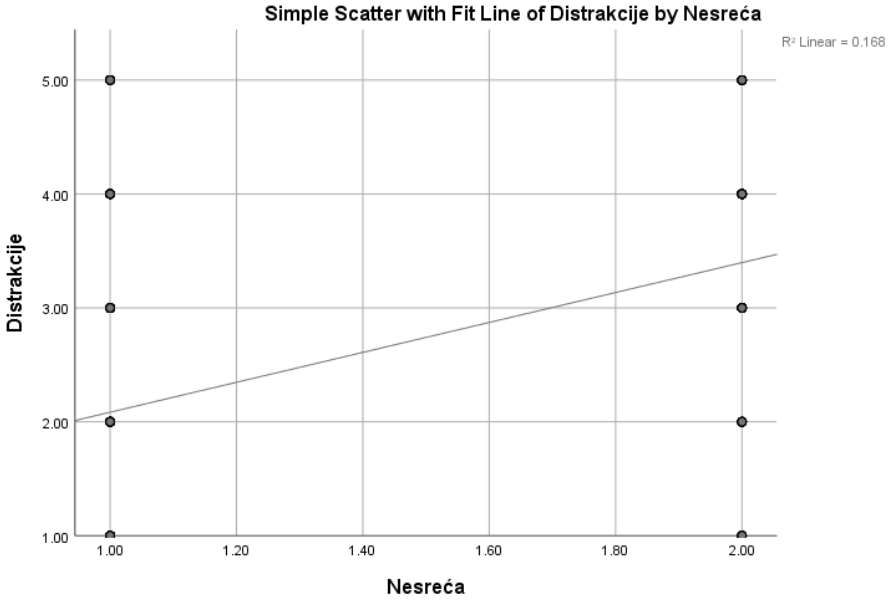
Dijagram 6- 7 Korelacije prometne nesreće – nastava

Izvor: Izradio autor



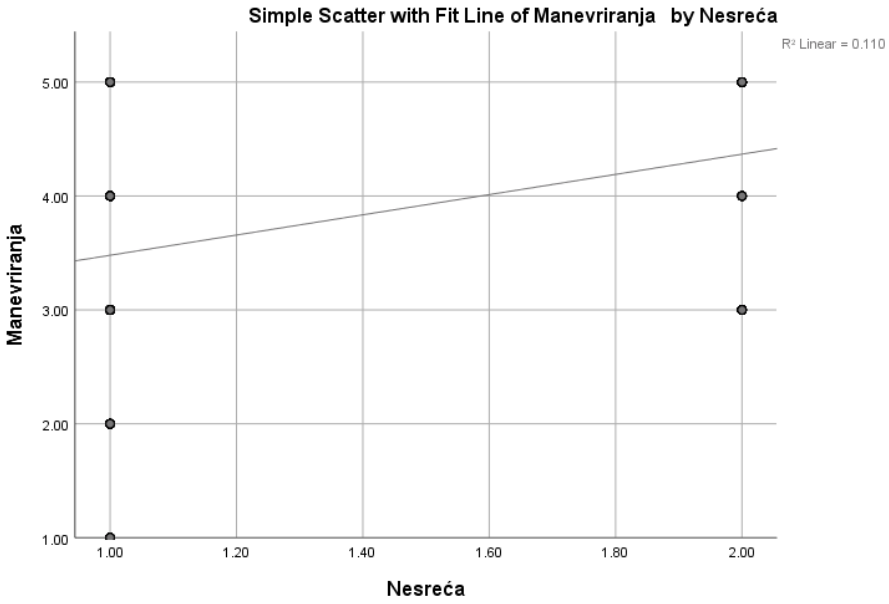
Dijagram 6- 8 Korelacije prometne nesreće – kilometraža

Izvor: Izradio autor



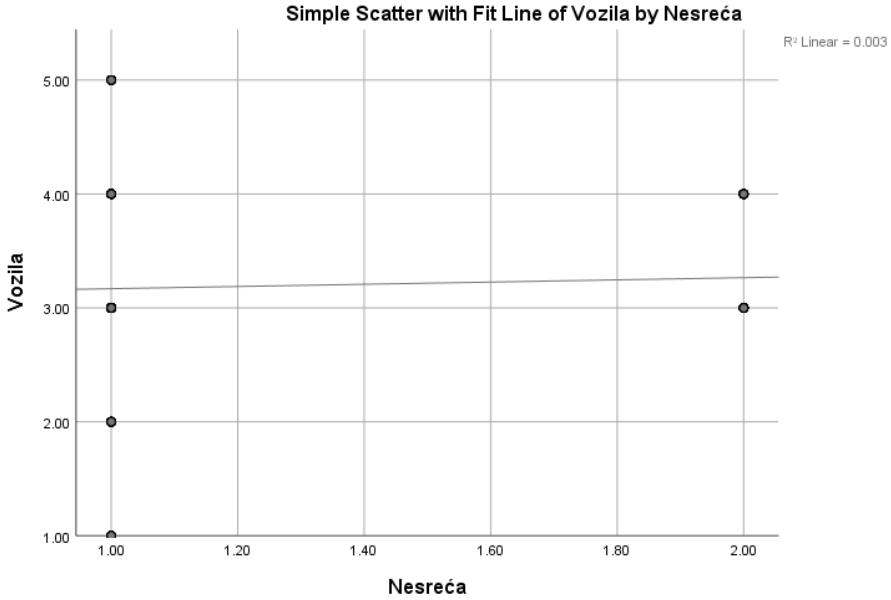
Dijagram 6- 9 Korelacije prometne nesreće – distrakcije

Izvor: Izradio autor



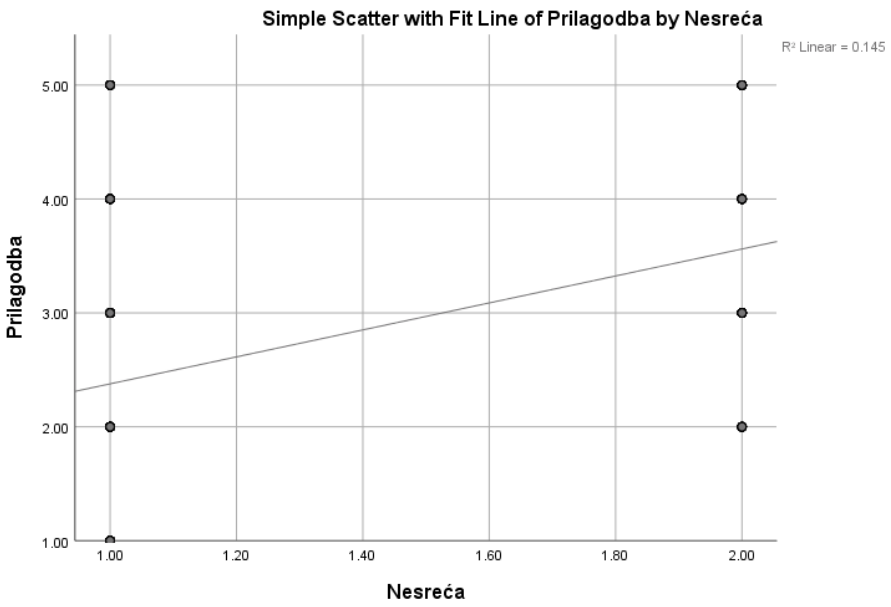
Dijagram 6- 10 Korelacije prometne nesreće – manevriranja

Izvor: Izradio autor



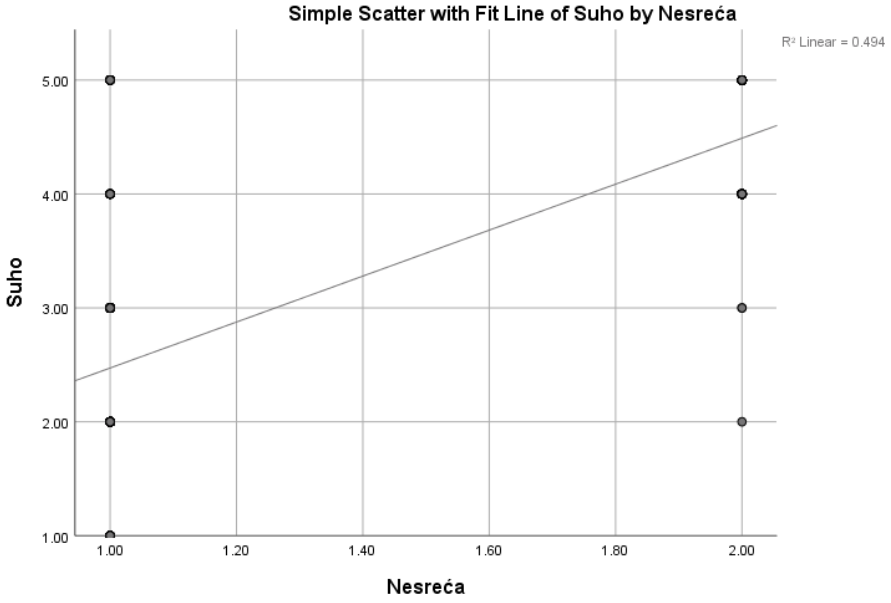
Dijagram 6- 11 Korelacije prometne nesreće – vozila

Izvor: Izradio autor



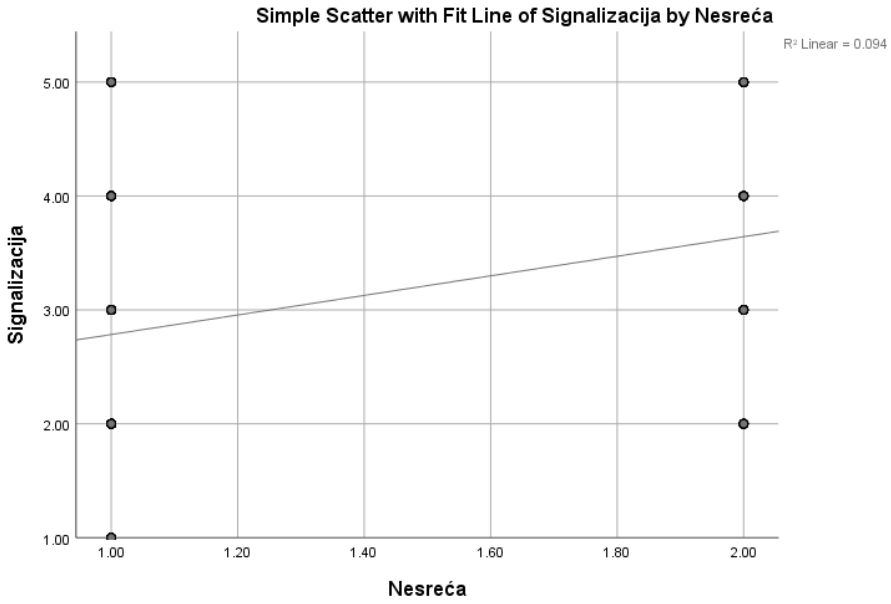
Dijagram 6- 12 Korelacije prometne nesreće – prilagodba

Izvor: Izradio autor



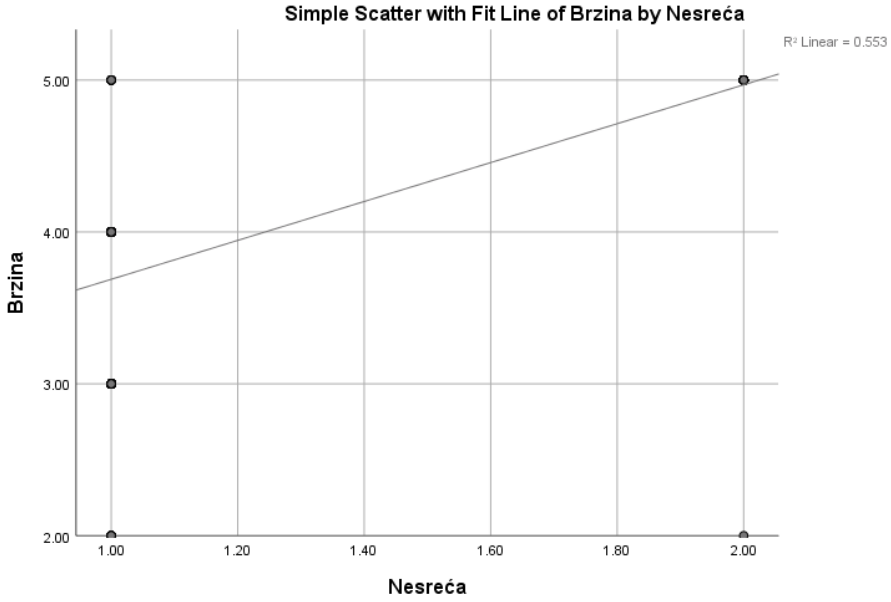
Dijagram 6- 13 Korelacije prometne nesreće – suho

Izvor: Izradio autor



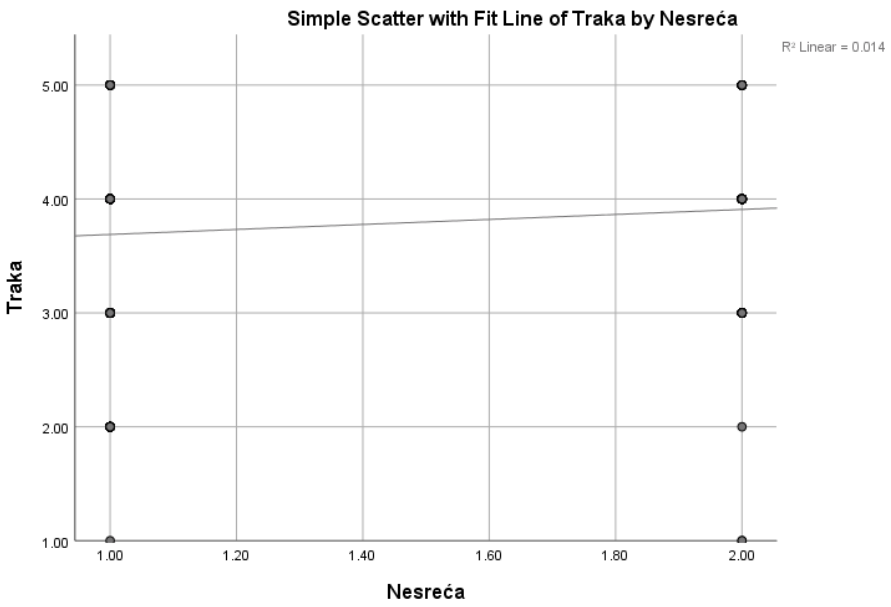
Dijagram 6- 14 Korelacije prometne nesreće – signalizacija

Izvor: Izradio autor



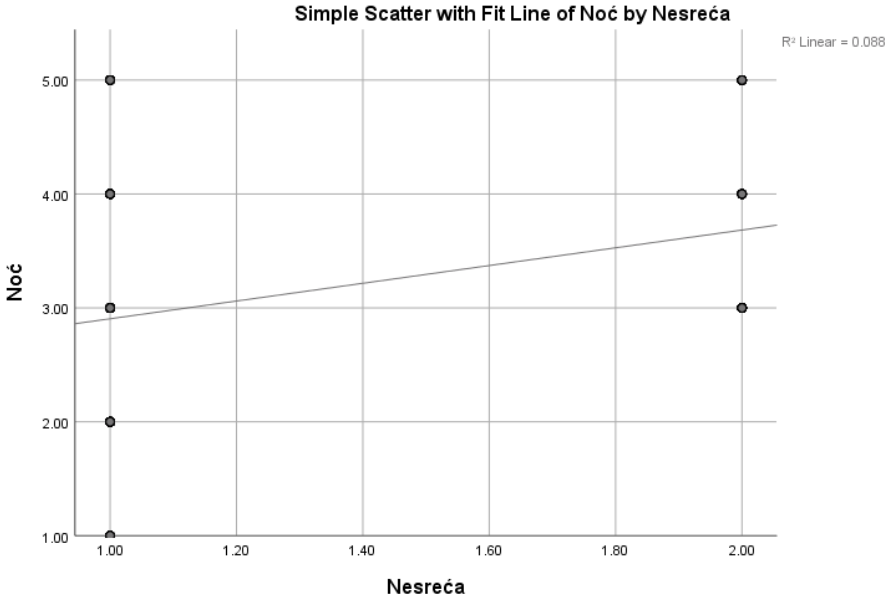
Dijagram 6- 15 Korelacije prometne nesreće – brzina

Izvor: Izradio autor



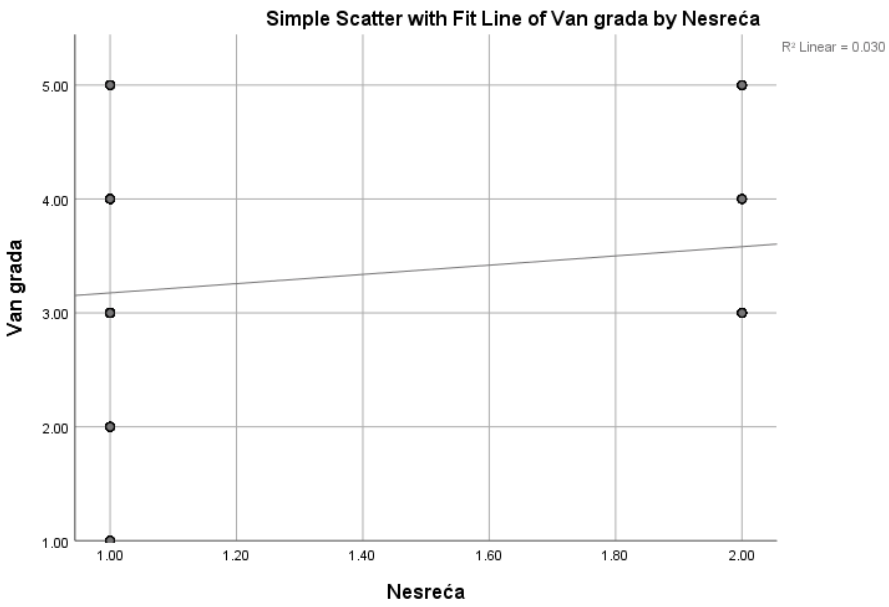
Dijagram 6- 16 Korelacije prometne nesreće – traka

Izvor: Izradio autor



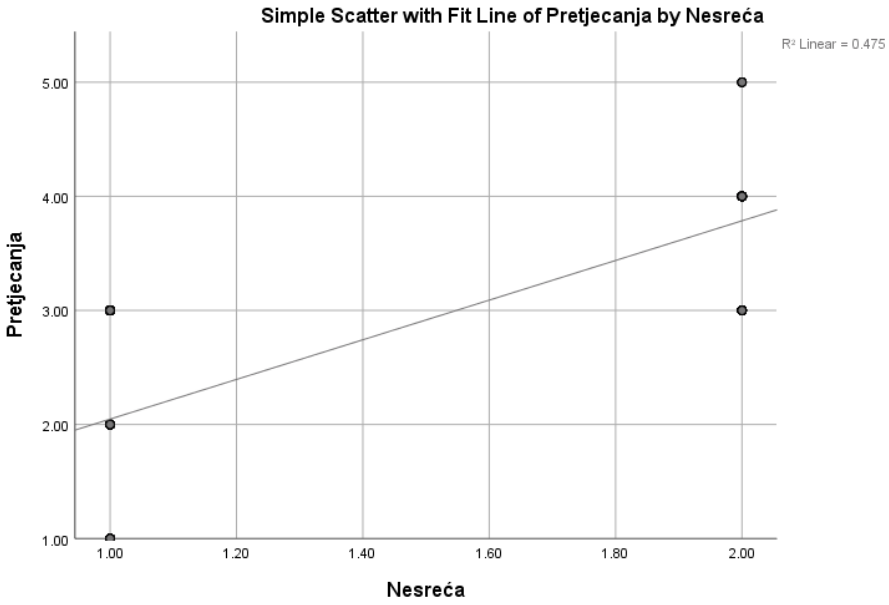
Dijagram 6- 17 Korelacije prometne nesreće – noć

Izvor: Izradio autor



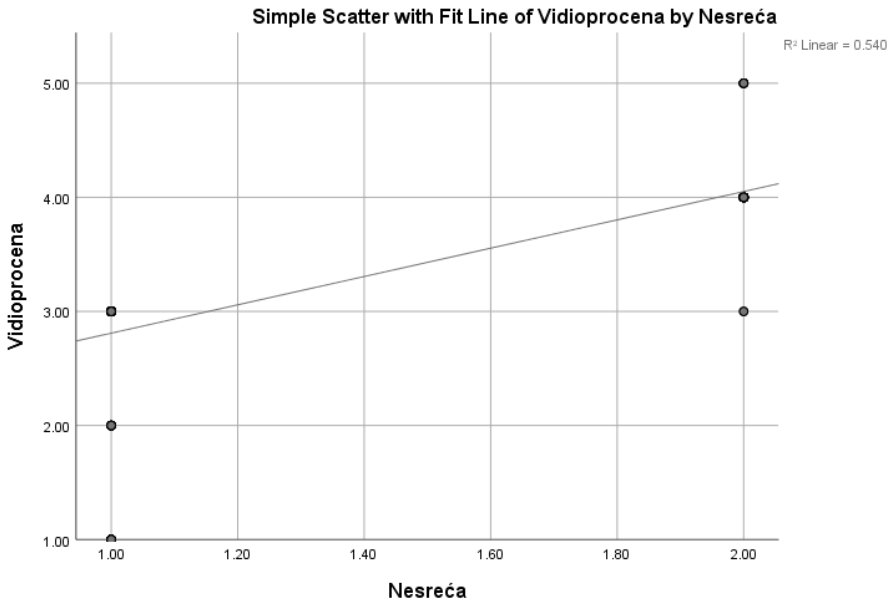
Dijagram 6- 18 Korelacije prometne nesreće – izvan grada

Izvor: Izradio autor



Dijagram 6- 19 Korelacije prometne nesreće – pretjecanje

Izvor: Izradio autor



Dijagram 6- 20 Korelacije prometne nesreće – videoprocjena

Izvor: Izradio autor

7. IZRADA MODELA PROCJENE RIZIKA OD PROMETNIH NESREĆA MLADIH VOZAČA

Izrada modela procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika temelji se na nalazima teorijskog i praktičnog istraživanja kao i na osnovi obrade podataka – analize i nalaza kojima je utvrđeno da postoji povezanost između osnovnih čimbenika sigurnosti prometa na cestama: čovjek – vozilo – cesta – okoliš te subjektivnih i objektivnih uzroka nastanka prometnih nesreća.

Prvi dio modela odnosi se na elemente procesa osposobljavanja kandidata za vozača u autoškoli, gdje kandidat tijekom teorijskog osposobljavanja uči o vještinama predviđanja i percepcije procjene rizika od prometnih nesreća, zatim praktičnim osposobljavanjem stječe vještine i tehniku vožnje kako treba reagirati u stvarnoj situaciji u prometu (ovisno o tome je li rizik unaprijed poznat, je li očekivan ili iznenadan).

Drugi dio modela (nakon stjecanja vozačke dozvole) odnosi se na elemente procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika koje je vozač (izlazna varijabla) naučio tijekom teorijskog i praktičnog osposobljavanja i vozačkog staža.

U nastavku je prikazana tablica korelacija osnovnih čimbenika sigurnosti prometa sa subjektivnim i objektivnim uzrocima koji su identificirani u kontekstu ovog rada.

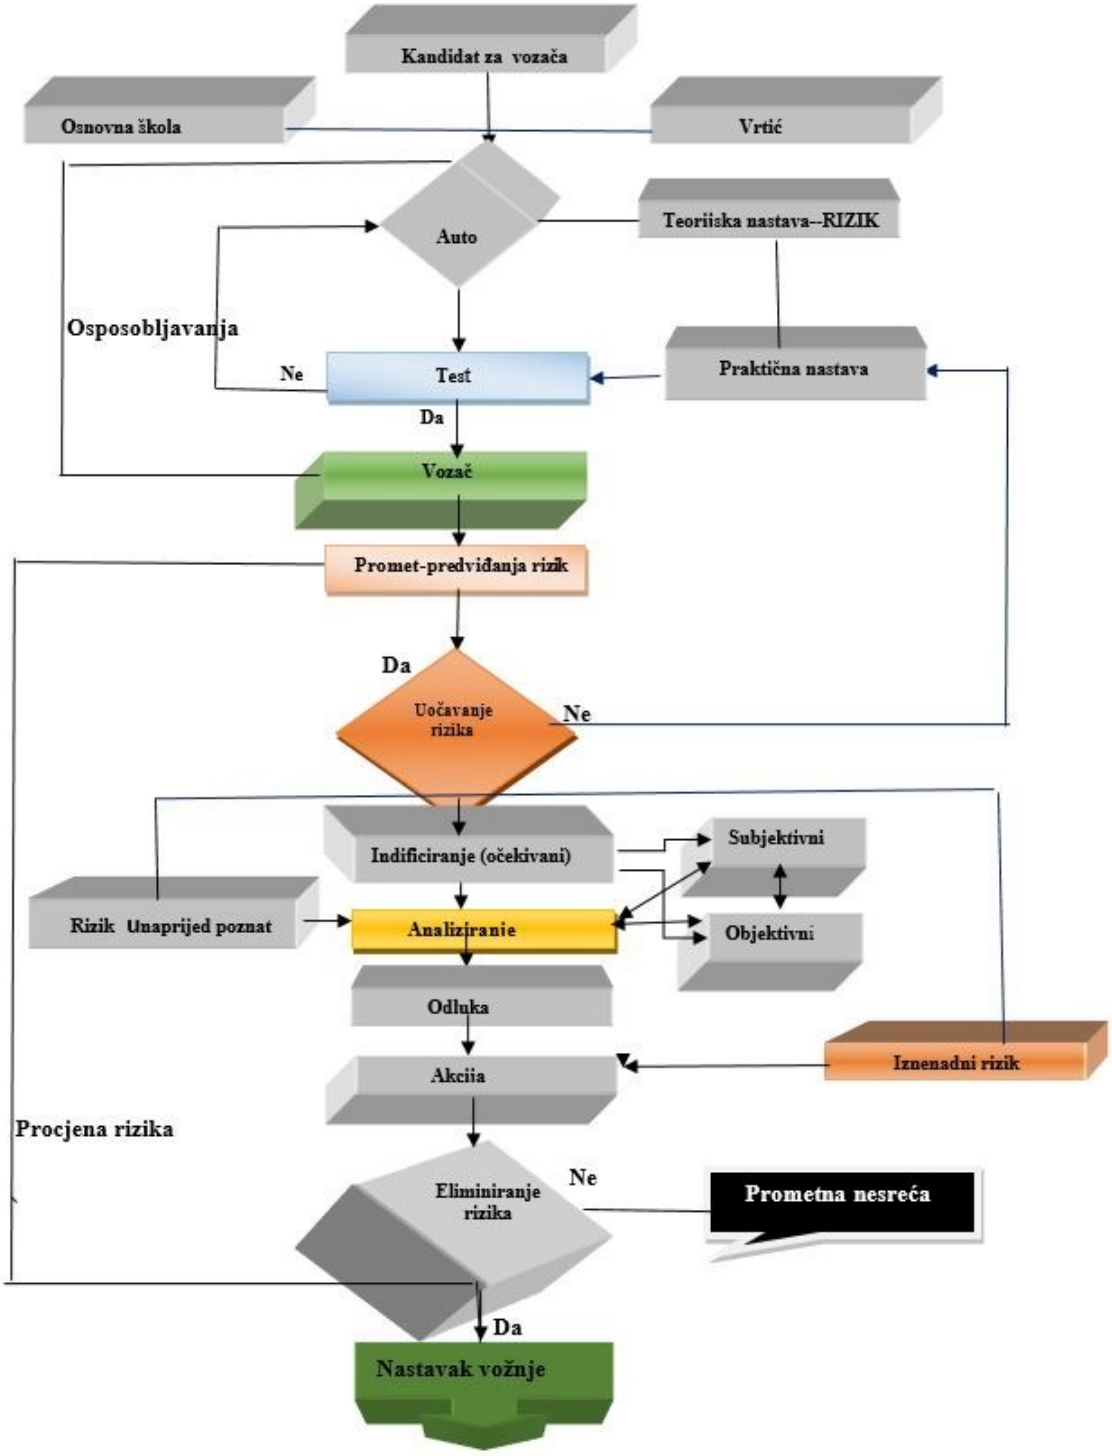
Tablica 7- 1 Uzroci prometnih nesreća

	KORELACIJA SUBJEKTIVNIH I OBJEKTIVNIH ČIMBENIKA				
	Elementi/komponente	Čovjek	Vozilo	Cesta	Okruženje
	Brzina	X			
	Frekvencije vožnje	X			
	Psihosocijalna komponenta	X			
	Samoprocjena brzine	X			
	Procjena tehnike vožnje	X			
	Procjena promjene vlastitog ponašanja	X			
	Predznanja o ponašanju u cestovnom prometu	X			x
	Satovi za procjenu rizika nastanka prometnih nesreća	X			x
	Videoprocjena za identificiranje rizika u prometu	X			x
	Iskustvo u vožnji prije upisa u autoškolu	X			
	Organiziranje praktične nastave u skupinama s kandidatima	X			x
	Prosječni broj kilometara iz praktične nastave	X			x
	Pogreške tijekom manevriranja vozilom	X			
	Pogreška pri uključivanju u promet	X			x
	Pogreška pri promjeni prometne trake	X		x	
	Distrakcija				
	Prilagodba ponašanja s kojim je vozač u objektivnom konfiktu sa svojim izravnim okruženjem	X			x
	Reagiranja na iznenadne okolnosti na cesti (udarne rupe, suženje ceste, kamenje na cesti, prljavština na cesti itd).	X		x	x
	Vožnja na nedovoljnoj udaljenosti	x			x
	Vožnja po kiši/snijegu i magli	x			x
	Vožnja po mokrom (prljavi/snijeg/led) kolniku	x		x	
	Vožnja po suhom i čistom kolniku / po vedrom vremenu	x		x	X
	Vožnja na ravnom cestovnom segmentu				
	Vožnja u sumrak/noću	x			x
	Procjena elemenata ceste i prepreke na njima (udarne rupe, kamenje i dr.) sa stajališta sigurnosti prometa	x	x	x	x
	Procjena cestovne signalizacije s gledišta postavljanja na odgovarajuća mjesta	x		x	x
	Vozilo				

Izvor: Izradio autor

Iz tablice se uočava da postoji korelacija osnovnih čimbenika sigurnosti cestovnog prometa, u koje se ubrajaju čovjek – vozilo – cesta – okoliš te subjektivnih i objektivnih uzročnih čimbenika koji su najviše utjecali na nastanak prometnih nesreća s poginulim osobama.

Model procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika prikazan na dijagramu 7-1.



Dijagram 7- 1 Model procjene rizika od prometnih nesreća

Izvor: Izradio autor

Interpretacija modela – na temelju nalaza iz praktičnog istraživanja svi elementi modela bit će opisani u nastavku:

- Kandidat za vozača – ulazna varijabla u ovom modelu. Znanje o ponašanju u prometu stečeno u osnovnoj školi ili vrtiću smatra se učinkovitijom metodom u odnosu na učenje o ponašanju u prometu koje se podučava tek u autoškoli.
- Autoškola – ovlašteni pravni subjekt za osposobljavanje kandidata za vozače iz teorijskog i praktičnog dijela.
- Teorijska nastava – u teorijskom nastavnom okviru predviđa se održavanje satova za procjenu rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika, također s videosnimkama.
- Praktična nastava – kandidat za vozača primjenjuje znanje koje je stekao na teorijskom dijelu procjene rizika tijekom vožnje u praktičnoj nastavi. Za ovaj dio obuke predviđena je organizacija praktične nastave u skupinama s kandidatima za vozača. Ova metoda će omogućiti kandidatima da bolje upoznaju rizik i steknu iskustvo tako što će biti promatrači dok drugi kandidati pod nadzorom i uz upute instruktora upravljaju vozilom.
- Test – nakon završetka procesa osposobljavanja kandidat za vozača polaže vozački ispit. Ako ne položi, omogućeni su mu dodatni satovi vožnje u autoškoli.
- Vozač – kandidat za vozača kao ulazna varijabla sa svojim značajkama nakon polaganja vozačkog ispita postaje vozač, tj. izlazna varijabla. Uz znanje stečeno iz procesa obuke i testiranja kao vozač može samostalno upravljati vozilom u prometu.
- Promet – predviđanje rizika – sudjelovanje u cestovnom prometu izloženo je riziku od prometne nesreće. Predviđanje rizika u prometu znanjem stečenim tijekom školovanja u autoškoli i vozačkim iskustvom ima ključnu ulogu u sigurnosti mladih vozača. Dakle, prvi element procjene rizika je predviđanje.
- Uočavanje rizika – drugi element rizika je uočiti (vidjeti – čuti). Ako vozač nije u stanju uočiti rizik, znači da nije stekao potrebna znanja u autoškoli.
- Identifikacija rizika (treći element) – nakon uočavanja rizika slijedi njegova identifikacija, točnije značajke rizika s kojim se vozač susreće u konkretnoj situaciji (ovaj se model bavi isključivo objektivnim čimbenicima, a ne situacijama s drugim sudionicima u prometu).
- Subjektivni i objektivni uzroci – identifikacija uključuje sve subjektivne i objektivne uzroke koji su prethodili nastanku rizika na cesti. Identifikacija uključuje sve subjektivne i objektivne čimbenike koji su uzrokovali rizik na cesti i koji su međusobno u interakciji.
- Rizik koji je unaprijed poznat – rizik se može očekivati jer je vozač unaprijed upozoren o riziku na cesti (prometnim znakovima ili iskustvom u vožnji kad poznaje cestu) i identifikacija rizika je jednostavna, jer vozač čeka rizik s kojim će se suočiti.

- Očekivani rizik – identifikacija ovog rizika odnosi se na uvjete i okolnosti koje se temelje na konfiguraciji terena i elementima ceste te okolnostima okruženja da se na cesti vozač možda suočava s rizikom.
- Iznenadni rizik (neočekivani rizik) – to se događa zbog iznenadnih uvjeta i okolnosti na cesti gdje je vozač izravno u konfliktu s okruženjem (u vezi s tim mladi su vozači dali svoje mišljenje na pitanje kako procjenjuju reagiranje na iznenadne okolnosti na cesti (udarne rupe, suženje ceste, kamenje na cesti, prljavština na cesti itd.)).
- Analiziranje rizika (četvrti element) – nakon identifikacije subjektivnih i objektivnih uzroka koji su doveli do nastanka rizika, započinje sljedeća faza analize svih uvjeta i okolnosti koje su dovele do rizika na cesti. Iz dijagrama se vidi da povezanost s analizom postoji samo s rizicima koji su unaprijed poznati i očekivani. Iznenadni rizik (neočekivan) nije povezan s analizom rizika zbog nedostatka vremena.
- Odluka (peti element) – nakon analiziranja svih subjektivnih i objektivnih čimbenika mora se donijeti odluka o reakciji u konkretnoj situaciji, to znači poduzimanje aktivnosti kako bi se izbjegao rizik. Prava odluka proizlazi iz vještine poznavanja rizika koju je vozač stekao tijekom osposobljavanja u autoškoli i kroz vozačko iskustvu. Niti odluka kao peti element nije povezana s iznenadnim rizikom jer odluka se ne donosi analizom, već u većini slučajeva na temelju instinkta, odnosno spontano.
- Akcija (šesti elementi) – na temelju odlučivanja započinje se s aktivnošću u vremenu i prostoru radi eliminiranja rizika s kojim je vozač suočen. Ako nakon akcije rizik ne može biti eliminiran, dogodit će se prometna nesreća.

Ovaj se model odnosi na procjenu rizika identificirajući subjektivne i objektivne uzroke, kad se vozač nalazi u konfliktu s okruženjem zbog okolnosti i uvjeta, ceste, odnosno okoline, kako bi se izbjegao rizik od prometne nesreće. Također, parametri i okolnosti analizirani kod procjene rizika podrazumijevaju prometnu nesreću u kojoj je sudjelovalo jedno vozilo (bez ostalih sudionika u prometu).

8. EVALUACIJA MODELA PROCJENE RIZIKA OD PROMETNIH NESREĆA MLADIH VOZAČA

U ovom poglavlju prikazana je evaluacija modela procjene rizika uz pomoć programa SPSS-26, korištenjem ANOVA testa. Rezultati analize i evaluacija modela pomoću ANOVA testa prikazani su u Prilogu B ovog rada.

U nastavku su dani rezultati ANOVA testa s najnižom i najvišom vrijednošću varijable kao što je prikazano u tablici 8-1. Ostali rezultati ANOVA testa nalaze se između ovih dviju vrijednosti.

Tablica 8- 1 ANOVA test

ANOVA

		Sum of Squares	df	Mean Square	F	Sig.
Traka	Between Groups	3.475	1	3.475	5.074	.025
	Within Groups	252.708	369	.685		
	Total	256.183	370			
Suho	Between Groups	293.455	1	293.455	360.309	.000
	Within Groups	300.534	369	.814		
	Total	593.989	370			

Izvor: Izradio autor

Iz tablice se uočava da su u ANOVA testu predstavljeni sljedeći podaci:

- zbroj kvadrata (engl. *Sum of Squares*)
- df (engl. *Degrees of Freedom*) – stupnjevi slobode
- srednji kvadrati (engl. *Mean Square*)
- F – koeficijent Anova
- Sig – vjerojatnost.

Najmanja vrijednost je u varijabli Traka s vrijednošću koeficijenta F – 5.074, a s najvećom vrijednošću varijabla koeficijenta F – 360.309.

U nastavku su zadane najznačajnije ulazne (neovisne) promjenjive varijable i ovisne ulazne nepromenjive varijable, tj. prometne nesreće s ANOVA testom:

Tablica 8- 2 ANOVA test

ANOVA

		Sum of Squares	df	Mean Square	F	Sig.
Reagiranje	Between Groups	152.610	1	152.610	97.177	.000
	Within Groups	579.492	369	1.570		
	Total	732.102	370			
Brzina	Between Groups	118.287	1	118.287	457.321	.000
	Within Groups	95.443	369	.259		
Skupina Videoprocjena Ravnica	Total	213.730	370			
Skupina	Between Groups	210.117	1	210.117	665.197	.000
	Within Groups	116.557	369	.316		
	Total	326.674	370			
Vidioprocena	Between Groups	111.149	1	111.149	432.454	.000
	Within Groups	94.840	369	.257		
	Total	205.989	370			
Ravnica	Between Groups	255.135	1	255.135	283.061	.000
	Within Groups	332.595	369	.901		
	Total	587.730	370			

Izvor: Izradio autor

uočava se da postoji međusobni utjecaj neovisnih varijabli (ulaznih) i ovisnih varijabli (prometne nesreće).

Na temelju analize s ANOVA testom (iz tablice prilog A), provjeren je međusobni utjecaj neovisnih varijabli (ulaznih) i ovisnih varijabli (prometne nesreće). Taj je utjecaj statistički značajan jer je vrijednost p = 0,00 u svim varijablama.

Na temelju analize ANOVA testa zaključuje se da postoji značajna statička razlika između skupina ulaznih varijabli (promjenjive varijable) s ovisnom izlaznom varijablom (nepromjenjiva varijabla) – prometne nesreće – što znači da je model prihvatljiv.

8.1 PRIJEDLOG MJERA ZA POBOLJŠANJE SIGURNOSTI PROMETA

Na temelju nalaza iz teorijskog i praktičnog istraživanja i rezultata analize, napravljene su preporuke za povećanje prometne sigurnosti mladih vozača koje uključuju:

1) Preporuke u procesu osposobljavanja kandidata za vozača:

   - Tijekom procesa osposobljavanja kandidata za vozače u fond nastavnih sati potrebno je uključiti i sadržaj procjene rizika (nastava i videoprocjena rizika), identificirati subjektivne i objektivne uzroke koji imaju najveći utjecaj na prometne nesreće.
   - Tijekom procesa osposobljavanja kandidata potrebno je prikazivati videosnimke sa sadržajem procjene rizika, uključujući mjere i aktivnosti za uklanjanje rizika, odnosno izbjegavanje prometne nesreće.
   - Sate iz praktičnog dijela nastave u autoškoli potrebno je mjeriti duljinom prijeđenih kilometara, a ne s vremenskim ograničenjima (minutama) kao što je to trenutačno.
   - Radnje s vozilom, posebno one radnje koje se odnose na gubitak kontrole nad vozilom, trebale bi biti prioriteti instruktora vožnje.
   - Potrebno je ukloniti loše navike, tj. promijeniti negativno ponašanje u prometu koje su kandidati prethodno stekli, što predstavlja poteškoće. Ovaj element instruktor vožnje mora uzeti u obzir na početku praktične nastave radeći s kandidatom više na planu pozitivne promjene ponašanja u prometu jer kandidati zbog vozačkog iskustva precjenjuju svoje sposobnosti.
   - Potrebno je organizirati praktičnu nastavu tijekom praktične obuke koja će se izvoditi u skupinama radi stjecanja iskustva u procjeni rizika identificiranjem subjektivnih i objektivnih uzroka nastanka prometnih nesreća.
   - Raditi na otklanjanju pogrešaka koje su najviše uočene kod mladih vozača tijekom pretjecanja, prometnih gužvi i gubitka kontrole nad vozilom, stoga instruktori vožnje takve elemente trebaju posebno proučiti i prolaziti situacije s kandidatima za vozače.

- Treba izvršiti promjene u programima obuke kandidata za vozače kako bi se povećala kvaliteta korištenjem najsavršenije tehničko-tehnološke opreme, posebno se usredotočujući na procjenu rizika i identifikaciju subjektivnih i objektivnih čimbenika koji utječu na nastanak prometnih nesreća.

2) Preporuke za mlade vozače:

- Potrebno je eliminiranti distrakcije tijekom vožnje. Distrakcije se kod mladih vozača očituju zbog unutarnjih i vanjskih uzroka i izravno utječu na procjenu rizika i eliminiranje, odnosno izbjegavanje nastanka prometne nesreće. Distrakcija je najizraženija kad mladi vozači voze s vršnjacima, kad su pod vremenskim pritiskom te zbog precijenjenosti njihovih vozačkih sposobnosti.
- Mladi vozači smatraju da je vožnja po suhim i čistim cestama najsigurnija. U stvarnosti u takvim je uvjetima većina mladih vozača uključena u prometne nesreće s poginulim osobama. Zbog toga rizik na takvim dijelovima cesta ne treba podcijeniti, pa bi instruktori vožnje tijekom praktične nastave trebali dati upute za procjenu rizika točno pod prethodno navedenim uvjetima.
- Stečeno vozačko iskustvo mladim vozačima treba biti u funkciji povećanja sigurnosti na cestama.
- Ne precjenjivati tehniku vožnje, što se posebno odnosi na mlade vozače.

3) Preporuke za poboljšanje cestovne prometne infrastrukture i njezine okoline te vozila:

- poduzimati administrativne i tehničke mjere na ravnim i dugim dionicama cesta koje će utjecati na smanjenje brzine vožnje,
- imati na umu da postavljanje prometne signalizacije koja se odnosi na upozorenja ne prekriva sva rizična mjesta na cestovnoj mreži i nije uvijek na odgovarajućim mjestima,
- povećati pažnju tijekom vožnje noću zbog male gustoće prometa, ne voziti brzo, naročito tijekom povratka iza ponoći iz zabavnih aktivnosti. U takvim se situacijama događa da vozači na cesti ne primijete rizik ili ga ne procijene ispravno, što povećava vjerojatnost nastanka prometne nesreće,
- iako je osnovni čimbenik sigurnosti na cestama vozilo, statistika pokazuje da nije uzrok prometnih nesreća u njihovu većem broju. Međutim, ne treba ga

zanemariti te je potrebno svaki put prije vožnje izvršiti vizualne i tehničke provjere osnovnog rada aktivnih elemenata u vozilu i kontinuiranog praćenja na instrumentnoj ploči koja signalizira kad su u kvaru sigurnosni elementi vozila.

4) Preporuke institucijama koje nadziru, kontroliraju i upravljaju cestovnom prometnom infrastrukturom:
   - subjekti za sigurnost cestovnog prometa trebali bi više pažnje posvetiti mjerama samosvijesti vozača nego administrativnim kaznama,
   - procjena rizika s teorijskog i praktičnog stajališta te identificiranje subjektivnih i objektivnih uzroka kao jedan od prioriteta institucija koje se bave prometnom sigurnošću,
   - prioritet institucija koje upravljaju prometom i kontroliraju ga ili imaju politički utjecaj na taj dio prometnog sustava, mora biti očuvanje sigurnosti na cestama mladih vozača koji su najrizičnija dobna skupina,
   - poduzimati administrativne i tehničko-tehnološke mjere radi discipliniranja neodgovornih vozača koji se ne pridržavaju prometnih i sigurnosnih pravila, posebno onih koja se odnose na brzinu i pretjecanje.

5) Preporuke roditeljima te odgojno obrazovnim ustanovama:
   - povećati utjecaj roditelja ili staratelja na samosvijest mladih vozača o riziku u prometu zbog brzine, vožnje noću i vikendom,
   - učenje ponašanja u cestovnom prometu u vrtićima, odnosno osnovnim školama.

6) Preporuke za korištenje predloženog modela procjene rizika:
   - model procjene rizika upotrebljavati tijekom procesa obuke kandidata za vozače (formalna i neformalna metoda) i pri procjeni stupnja rizika sve dok njegovo eliminiranje omogućava smanjenje vjerojatnosti nastanka prometnih nesreća,
   - model može poslužiti kao dodatak GDE matrici za procjenu i eliminiranje rizika uslijed okolnosti i uvjeta na cesti i njezinu okruženju,
   - stalno usavršavanje modela stvaranjem preduvjeta za ispravnu procjenu rizika u prometu u identifikaciji ostalih subjektivnih i objektivnih čimbenika koji

imaju najveći utjecaj na nastanak prometnih nesreća s posebnim osvrtom na mlade vozače.

8.2 DISKUSIJA

Analizirajući statističke pokazatelje (ulazne), uočeno je da su mladi vozači najviše izloženi riziku sudjelovanja u prometnim nesrećama. Na temelju dosadašnjih istraživanja uočava se potreba za izradom modela za procjenu rizika od prometnih nesreća identifikacijom subjektivnih i objektivnih čimbenika koji će doprinijeti većoj sigurnosti mladih vozača u prometu.

Na temelju teorijske analize nastanka prometnih nesreća nailazimo na velik broj međusobno kombiniranih objektivnih i subjektivnih čimbenika koji su objašnjeni u nalazima praktičnog istraživanja. Navedeni ulazni pokazatelji uzeti su u obzir za provedeno istraživanje u kontekstu ovog rada.

Praktična su istraživanja obuhvatila i proces terenskog istraživanja radi prikupljanja potrebnih podataka o stavovima mladih vozača kod nastanka prometnih nesreća. U istraživanje je uključeno ukupno 371 ispitanik, od njih je 225 ili 60,6 % muškaraca i 146 ili 39,4 % žena.

Prva hipoteza: Moguće je identificirati subjektivne i objektivne čimbenike koji utječu na procjenu rizika od prometnih nesreća mladih vozača.

U vezi postavljene hipoteze provedeno je istraživanje koje se temelji na pokaziteljima koji imaju statistički značajne razlike što znači povezanost u nastanku prometnih nesreća o čemu će biti diskusija u nastavku.

Kod edukacije, prebivališta i socioekonomskog statusa na temelju rezultata analize nema statistički značajne razlike, dakle pojava prometnih nesreća neovisna je o tim komponentama.

Kod frekvencije vožnje ($x^2 = 45,990$, $p = 0,000$), procjene tehnike vožnje ($x^2 = 44,831^a$, $p = 0,000$), procjene promjene vlastitog ponašanja u prometu ($x^2 = 64,403$, $p = 0,00$), ograničenja brzine ($x^2 = 27,748^a$, $p = 0,000$) te psihosocijalne komponente ($x^2 = 112,314^a$, $p = 0,000$) na temelju rezultata analize postoje statistički značajne razlike. Iz toga slijedi da je pojava prometnih nesreća ovisna o tim komponentama. Time su identificirani subjektivni i objektivni čimbenici koji utječu na procjenu rizika nastanka prometnih nesreća mladih vozača.

U nastavku su prikazani podaci iz analize i diskusija nalaza iz komponenti procesa osposobljavanja kandidata za vozače koji su korišteni tijekom izrade modela za procjenu rizika.

- Kod stupnja edukacije predavača u autoškoli, dopunski sati teorije i vožnje – ne postoje statističke značajne razlike.
- Kod stečenog predznanja o prometnim nesrećama (x^2 = 70,352, p = 0,00), teorijske nastave za procjene rizika nastanka prometnih nesreća (x^2 = 74,307, p = 0,00), videoprocjene za identifikaciju rizika (x^2 = 204,859, p = 0,00), broja prijeđenih kilometara iz praktične nastave (x^2 = 17,111, p = 0,002) te organiziranja praktične nastave po skupinama s kandidatima za vozače (x^2 = 71,618, p = 0,00), na temelju rezultata analize postoje statistički značajne razlike u broju frekvencija ispitanika koji nisu ili jesu bili uključeni u prometne nesreće s obzirom na navedene komponente. Iz toga slijedi da je pojava prometnih nesreća ovisna o tim komponentama.

Diskusija analize korelacije

U nastavku su predstavljeni rezultati glavnih komponenata koji potvrđuju drugu hipotezu u ovom radu.

- *Moguće je odrediti korelaciju između temeljnih čimbenika sigurnosti u koje se ubrajaju čovjek, vozilo i cesta te identificiranih subjektivnih i objektivnih čimbenika kod mladih vozača.*

Postoji korelacija ulaznih promjenjivih varijabli (spol, uzrast, vozačko iskustvo) s ovisnom izlaznom nepromjenjivom varijablom – prometna nesreća. Prema istraživanju [17] muškarci su češći sudionici prometnih nesreća u odnosu na žene, što se pokazalo i u ovom doktorskom radu.

Prometne nesreće imaju najveću vrijednost korelacije s ulaznom varijablom brzina (r` = .744, p = .000). Prema istraživanju [25] i [26] brzina, brzina neprilagođena uvjetima na cesti i nepoštovanje ograničenja brzine glavni je čimbenik nastanka prometnih nesreća kod mladih vozača. Slijedi korelacija (r` = .703, p = .000) prometne nesreće s ulaznom varijablom vožnja po suhoj i čistoj površini kolnika **(objektivni čimbenik)** te korelacija prometne nesreće (r` = .689, p = .000) s pretjecanjem **(subjektivni čimbenik)**. Prema [130] pretjecanje je drugi čimbenik nastanka prometnih nesreća kod mladih vozača. Prometne nesreće imaju korelacije (r` = .659, p = .000) s vožnjom na ravnom cestovnom segmentu – ravnica **(objektivni**

čimbenik – cesta kod modela). Prema [132] mladi su vozači najviše poginuli na ravnom cestovnom segmentu.

S povećanjem brzine i podcjenjivanjem rizika **(subjektivni čimbenici kod modela**) tijekom vožnje po suhoj i čistoj prometnoj površini **(objektivni čimbenik – cesta kod modela)** i na ravnom cestovnom segmentu **(objektivni čimbenik – cesta)** stvaraju se idealni uvjeti za brzu vožnju i pretjecanje, što povećava vjerojatnost nastanka prometnih nesreća, kao što je prikazano na dijagramima korelacijske analize 6-13 i 6-15.

Prometne nesreće imaju korelacije (r` = .457, p = .000) s reagiranjem na iznenadne okolnosti na cesti (udarne rupe, suženje ceste, kamenje na cesti, prljavština na cesti itd.), **ovaj element uzet je kod izrade modela, a odnosi se na iznenadni rizik (neočekivani rizik).** Iz ovog nalaza rizik ne treba podcjenjivati jer opasne situacije na cesti mogu nastati iznenadnim okolnostima na cesti ili vremenskim prilikama (kiša, snijeg, led, magla itd.). Istraživanje [15] se odnosi na ljudske greške u vožnji u odnosu na okolnosti na cesti, trasu ceste, kategoriju ceste, elemente ceste itd. Istraživanja [20] i [21] odnose se na utjecaj meteoroloških uvjeta na nastanak prometnih nesreća. Prema istraživanju [31] klimatski uvjeti imaju velik utjecaj na stope prometnih nesreća kod svih vozača, iako je utvrđeno da ovi čimbenici imaju nesrazmjeran utjecaj na mlade vozače.

Teorijska nastava (satovi za procjenu rizika) kao element osposobljavanja kandidata za vozače ima korelaciju (r` = .445, p = .000) s prometnim nesrećama. Taj je **element uzet pri izradi modela**, a korelacija je prikazana na dijagramu analize 6-7. Kod organiziranja praktične nastave po skupinama s kandidatima za vozače, prema analizama najviše se ispitanika izjasnilo za skupinu od dva kandidata. Taj je **element uzet pri izradi modela u procesu osposobljavanja praktične nastave.**

Prometne nesreće imaju korelaciju (r` = .409, p = .000) s distrakcijama **(subjektivni čimbenik)**. Prema studiji [16] distrakcija je glavni čimbenik uzroka prometnih nesreća s rizikom na razini pojedinačnog vozača. Korelacija (r` = .222, p = .000) ulazne promjenjive varijable psihosocijalna komponenta **(subjektivni čimbinik)** koja smanjuje psihofizičke sposobnosti vozača s ovisnom izlaznom varijablom prometna nesreća povećava vjerojatnost nastanka prometnih nesreća kao što je prikazano na dijagramu korelacijske analize 6-4.

Videoprocjena kao element osposobljavanja kandidata za vozača ima korelativniju povezanost s prometnim nesrećama (r`= .406, p = .000). Wagner i Richter predlažu procedure koje se zasnivaju na videoprocjeni rizika u prometu, dok je u kontekstu ovoga doktorskog

rada obavljeno istraživanje o stavovima mladih vozača o korištenju videosnimanja tijekom teorijske nastave o procjeni rizika od prometnih nesreća mladih vozača **(element pri izradi modela teorijska nastava)**, prikazano na dijagramu korelacijske analize 6-20.

Utvrđena je korelacija (r` = .380, p = .000) ulazne promjenjive varijable prilagodba ponašanja s ovisnom izlaznom nepromjenjivom varijablom prometna nesreća. Prilagodba ponašanja odnosi se na karakteristike vozača da mijenjaju svoje ponašanje prema različitim situacijama na cesti. Mogućnosti smanjenja broja prometnih nesreća promjenom ponašanja vozača ovise o vrsti i uzroku prometne nesreće, primjerice, nesreća kad je uključeno samo jedno vozilo gdje je vozač u objektivnom konfliktu sa svojim okruženjem (**objektivni čimbenik**), kod modela odnosi se na iznenadni rizik (neočekivani rizik).

Postoji korelacija prometne nesreće i manevriranje vozilom (r` = .331, p = .000) te tehnike vožnje (r` = .301, p = .000), a odnose se na tehniku i na pogreške tijekom vožnje jer se time povećava rizik vjerojatnosti nastanka prometne nesreće (kao što je prikazano na dijagramu korelacijske analize 6-2 i 6-10). Prema istraživanju [26] glavni su uzroci prometnih nesreća nesigurna manipulacija vozilima.

Pogreške (subjektivni uzrok kod modela) tijekom radnji s vozilom u prometu (skretanje, uključivanje, promjena prometne trake, gubitak kontrole nad vozilom) rezultiraju povećanjem rizika vjerojatnosti nastanka prometnih nesreća, kao što je prikazano na dijagramu korelacijske analize 6-16. Pogreške uglavnom nastaju zbog činjenice da mladi vozači nisu savladali tehniku vožnje tijekom praktičnog osposobljavanja u autoškoli **(element modela).** Prema istraživanju [9] višefazni model stjecanja vozačke dozvole (engl. *Graduated Driver Licensing – GnDL*) omogućuje da mladi vozači postupno izgrade svoje vozačke vještine i iskustvo. Ovaj element kod modela odnosi se na **očekivani rizik.**

Prometne nesreće imaju korelacije s ulaznom varijablom (r` = .307, p = .000) signalizacija, odnosno prometni znakovi koji upozoravaju o rizicima na cesti. Taj se element kod modela odnosi **na unaprijed poznate rizike**. Prema istraživanju [31] znak „Obilježeni pješački prijelaz“ koji prikazuje približavanje pješačkom prijelazu postavljen je neposredno ispred pješačkog prijelaza, što predstavlja potencijalni rizik za nastanak prometne nesreće.

Zaključujemo da postoji korelacija između glavnih čimbenika sigurnosti prometa na cestama čovjek – cesta – okolina i uzrocima prometnih nesreća koji su identificirani u kontekstu ovog rada.

Izrada modela procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika.

Diskusija – izrada modela – temelji se na nalazima teorijskih i praktičnih istraživanja kao i obradi podataka – analizi – i nalazima koji su utvrdili da postoji korelacija između osnovnih čimbenika sigurnosti prometa na cestama: čovjek – vozilo – cesta – okoliš te subjektivnih i objektivnih uzroka nastanka prometnih nesreća. Model se sastoji od dva dijela. Prvi dio modela odnosi se na elemente procesa osposobljavanja kandidata za vozača u autoškoli, dok se drugi dio modela (nakon stjecanja vozačke dozvole) odnosi na elemente procjene rizika od prometnih nesreća mladih vozača identifikacijom subjektivnih i objektivnih čimbenika, a prikazan je na dijagramu 7-1.

Za vozača je veoma važno da tijekom vožnje ima sposobnost: predvidjeti (**prvi element modela)**, uočiti **(drugi element modela),** identificirati **(treći element modela),** analizirati rizik **(četvrti element modela)** i na temelju analize donijeti odluku **(peti element modela)** te poduzeti aktivnosti **(šesti element modela)** radi eliminiranja rizika i nastavka vožnje, u suprotnom dolazi do nastanka prometne nesreće **(zadnji element modela).**

Ovaj se model odnosi na procjenu rizika identificirajući subjektivne i objektivne uzroke kad je vozač u konfliktu s okruženjem zbog okolnosti i uvjeta na cesti, odnosno okoline (objektivni uzroci) bez ostalih sudionika u prometu.

U istraživanju [5] pokazana su četiri postupka koja imaju važnu ulogu u percepciji opasnosti: otkrivanje neposredne opasnosti, procjena rizika, odabir radnje kako bi se izbjegla opasnost te provođenje odabrane radnje.

Predloženi model pruža hijerarhiju procjene rizika, počevši s predviđanjem rizika, zatim s uočavanjem, identifikacijom na tri razine (unaprijed poznata, očekivana i iznenađujuća), analizom rizika, donošenjem odluka, aktivnosti i eliminiranje rizika.

Evaluacija modela procjene rizika izvršena je uz pomoć programa SPSS-26 korištenjem ANOVA testa, kojim su hipoteze potvrđene i model je prihvatljiv.

9. ZAKLJUČAK

U okviru ovoga doktorskog rada izrađen je model procjene rizika identificiranjem subjektivnih i objektivnih uzroka koji imaju najveći utjecaj na nastanak prometnih nesreća s posebnim osvrtom na mlade vozače. Na temelju planiranja izrađen je postupak provođenja istraživanja, izveden u pet faza, koje su opsežno objašnjene u kontekstu ovoga doktorskog rada. Teoretska istraživanja najprije su provedena kao ulazni pokazatelji (izvor informacija o čimbenicima koji su prouzročili najviše prometnih nesreća s poginulim osobama u kojima su sudjelovali mladi vozači) koji su preuzeti iz policijskih podataka Republike Kosova. Praktična istraživanja provedena su na terenu prikupljanjem informacija o stavovima mladih vozača da identificiraju subjektivne i objektivne uzroke koji su imali velik utjecaj na izazivanje prometnih nesreća s poginulim osobama. Nakon prikupljanja podataka s terena putem upitnika o stavovima mladih vozača, izvršena je analiza podataka u SSPS programu koristeći hi-kvadrat test.

Statističkom analizom prikupljanih podataka uporabom hi-kvadrat testa pronađene su značajne statističke razlike između neovisnih ulaznih varijabli koje su, u ovom slučaju, subjektivni i objektivni uzroci koji su najviše utjecali na uzrok nastanka prometnih nesreća, i ovisne izlazne varijable prometne nesreće (prometne nesreće u kojima su sudjelovali mladi vozači). Time je potvrđena prva hipoteza koja se odnosi na identifikaciju subjektivnih i objektivnih uzroka nastanka prometnih nesreća s posebnim naglaskom na mlade vozače.

Nakon identificiranja subjektivnih i objektivnih čimbenika znanstvenim metodama za provjeru druge hipoteze korištena je korelacijska analiza osnovnih čimbenika sigurnosti cestovnog prometa, u koje se ubrajaju čovjek – vozilo – cesta – okoliš te subjektivnih i objektivnih uzročnih čimbenika koji su najviše utjecali na nastanak prometnih nesreća s poginulim osobama. Koeficijentom korelacije utvrđeno je koje su neovisne promjenjive ulazne varijable u korelaciji s ovisnim nepromjenjivim izlaznim varijablama (prometne nesreće).

Nakon provjere obje hipoteze na temelju nalaza istraživanja, izrađen je model za procjenu rizika identificirajući subjektivne i objektivne čimbenike. Dana je interpretacija modela čija je primjena predviđena tijekom procesa osposobljavanja kandidata za vozače, ali može se upotrijebiti i u onim zemljama u kojima se upotrebljava neformalna metoda osposobljavanja kandidata za vozače (engl. *accompanied driving*).

Evaluacija modela obavljena je uz pomoć ANOVA testa, čime je utvrđeno da postoji značajna statička razlika, što znači da je model prihvatljiv.

Nakon provjere modela dane su preporuke za povećanje sigurnosti na cestama za nove vozače. Na temelju rezultata istraživanja, preporuke su posvećene nadležnim tijelima za sigurnost cestovnog prometa koja kreiraju politike i upravljaju cestovnim prometom te poduzimaju administrativne i tehničko-tehnološke mjere radi sprečavanja prometnih nesreća usredotočenjem na mlade vozače. Zatim je dan prioritet procjeni rizika u prometu uključujući ih u program osposobljavanja kandidata u autoškoli kako bi se smanjila vjerojatnost prometnih nesreća.

Preporuke su dane i za autoškole i za osobe izravno uključene u proces osposobljavanja vozača, odnosno predavače i instruktore vožnje, kako bi u budućnosti uzeli u obzir nalaze ovoga doktorskog rada i model koji će se primijeniti u području osposobljavanja kandidata za vozača. Mladim vozačima preporučuje se primjena modela rizika identificiranjem subjektivnih i objektivnih uzroka koji imaju najveći utjecaj na nastanak prometnih nesreća, u kojem se postiže najveća sigurnost u cestovnom prometu za mlade vozače.

Također, nalazi ovog rada, subjektivnih i objektivnih uzročnih čimbenika, mogu se istražiti i za druge dobne skupine, poput vozača starije životne dobi koji se smatraju rizičnim vozačima u cestovnom prometu.

Definiranjem osnovnih pravaca daljnjeg istraživanja koji se odnose na procjenu rizika od prometnih nesreća, predloženi model može poslužiti kao poticaj za njegovo ispunjenje i usavršavanje identificiranjem ostalih subjektivnih i objektivnih uzroka koji imaju najveći utjecaj na nastanak prometnih nesreća s posebnim naglaskom na mlade vozače.

Očekivani znanstveni doprinos predloženog istraživanja očituje se u:

- metodologiji identifikacije subjektivnih i objektivnih čimbenika kojima se može unaprijediti sigurnost cestovnog prometa
- korelaciji subjektivnih i objektivnih čimbenika s temeljnim čimbenicima sigurnosti
- razvoju modela procjene rizika od prometnih nesreća identifikacijom subjektivnih i objektivnih čimbenika kod mladih vozača.

LITERATURA

1) Antin, J. F., Lockhart, T. E., Stanley, L. M., Guo, F.: Comparing the impairment profiles of older drivers and non-drivers: Toward the development of a fitness-to-drive model. Safety Science 50, p. 333−341, 2012.
2) Hatakka, M. et al.: BASIC – Driver Training: New Models, Final Report, University of Turku, Finland, 2003.
3) Ulleberg, P.: Personality subtypes of young drivers. Relationship to risk-taking preferences, accident involvment, reponse to a traffic safety, 2001.
4) Charles, M.: Attitudes towards Vehicle Driving Behaviour: Categorising and Contextualising Risk, Accident Analysis and Prevention, 38, Great Britain, p. 324–334, 2005.
5) Horswill, M. S., McKenna, F. P.: Drivers' Hazard Perception Ability: Situation Awareness on the Road, In Banbury, S and S. Tremblay (eds.), A cognitive approach to situation awareness: Theory and application, Aldershot, England, p. 155–175, 2004.
6) Machin, M. A., Sankey, K. S.: Relationships between young drivers' personality characteristics, risk perceptions, and driving behaviour, Accident Analysis and Prevention, 40 (2), Australia, p. 541−547, 2008.
7) Rafaely, V. et al.: Perception of traffic risks for older and younger adults, Accident Analysis and Prevention, 38, p.1231−1236, 2006.
8) Brown, I. D., Grieger, J. A.: Risk Perception and DecisionTaking during theTransition between Novice and Experienced Driver Status. Ergonomics, 31, United States of America (USA), p. 585−597, 1988.
9) Foss, R. D.: Reducing Fatal Crash Risk among Teenage Drivers: Structuring an Effective Graduated Licensing System, Journal of American Medical Association, 283, United States of America (USA), p. 1617−1618, 2000.
10) Hermans, E. et al.: Road safety risk evaluation by means of ordered weighted averaging operators and expert knowledge, Knowledge-Based Systems 23, p. 48−52, 2010.
11) Social Attitudes to Road Traffic Risk in Europe (SARTRE) 4, 2012.
12) Deffenbacher, J. L., Richards T. L., Filetti, L. B., Lynch R. S.: Angry drivers: a test of state-trait theory Expression Inventory: A measure of how people express their anger on the road. Behaviour Research and Therapy, 40, p. 717–737, 2007.

13) Carney, C. et al.: Using Naturalistic Driving Data to Assess the Prevalence of Environmental Factors and Driver Behaviors in Teen Driver Crashes (AAA Foundation for Traffic Safety, Washington, DC), USA, 2015.

14) Kinga, I. et al.: Identification of Traffic Accident Risk-prone Areas under Low-light Conditions, Natural Hazards Earth System Sciences, Hungary, 2015.

15) Hale, A. R., Štoop, J.: Human error models as predictors of accident seenarios for designers in road transport systems, Ergonomics, 33(10−11), p. 1377−1387, 1990.

16) Olson, R. L. et al.: Driver Distraction in Commercial Vehicle Operations, Federal Motor Carrier Safety Administration, 2009.

17) Klauer G., S. et al.: An Analysis of Driver Inattention Using a Case-Crossover Approach on 100-Car Data: Final Report. DOT HS 811 334. Washington, DC: National HighwayTraffic Safety Administration, 2010.

18) Rasmussen, J.: Human Errors: A Taxonomy for Describing Human Malfunction in Industrial Installations, Journal of Occupational Accidents, 4, p. 311−333, 1982.

19) Andersson, A., Chapman, L.: The use of a temporal analogue to predict future traffic accidents and winter road conditions in Sweden, Meteorological applications Meteorol. Appl. 18, p. 125–136, 2011.

20) Brijs, T., Karlis, D., Wets, G.: Studying the effect of weather conditions on daily crash counts using a discrete time-series model. Accident Analysis and Prevention. 40 (3), p. 1180–1190, 2008.

21) Sangbok, L., Byung, Yong, J.: Comparisons of Traffic Collisions between Expressways and Rural Roads in Truck Drivers, Saf Health Work, United States of America (USA), p. 38–42, 2016.

22) WHO (World Health Organization), Road traffic injuries, Global status report on road safety 2016.

23) FHA (Federal Highway Administration), Safety, The Haddon Matrix, USA, 2011.

24) PIARC Road Accident Investigation Guidelines For Road Engineers, 2007.

25) Bilten o Sigurnosti Cestovnog Prometa 2018., XLV. godina, Zagreb, 2019.

26) Podaci iz Kosovske policije, glavni čimbenici prometnih nesreća za razdoblje (2014. – 2018.), 24.04.2019., Priština

27) What can we learn about North Dakota's youngest drivers from their crashes? Vachal, K., Research Faculty, Malchose, D., Accid Anal Prev. 2009.

28) CCIS final reports on crash analysis, Cooperative Crash Injury Study, 2008

29) How Vehicle Age and Model Year Relate to Driver Injury Severity in Fatal Crashes, National Highway Traffic Safety Administration, 2013.

30) Hasani, H.: Seminarski rad, PSD – Sveučilište u Zagrebu, Fakultet prometnih znanosti, str.19., Zagreb, 2012.

31) Nokhandan, M. H., Bazrafshan, J., Ghorbani, K.: A quantitative analysis of risk based on climatic factors on the roads in Iran, Meteorol Appl. 2008.

32) Andrey, J., Hambly, D., Mills, B., Afrin, S.: Insights into driver adaptation to inclement weather inCanada, JTranspGeogr. 2013.

33) A study on crashes related to visibility obstruction due to fog and smoke, Abdel-Aty, M., Ekram, A. A., Huang, H., Choi, K., Accid Anal Prev. 2011 Sep; 43(5):1730−7. [PubMed] [Ref list]

34) Risk and type of crash among young drivers by rurality of residence: findings from the DRIVE Study,Chen, H.Y., Ivers, R. Q., Martiniuk, A. L., Boufous, S., Senserrick, T., Woodward, M., Stevenson, M., Williamson, A., Norton, R., Accid Anal Prev. 2009 Jul; 41(4):676−82.

35) Williamson, A.: Young drivers and crashes: Why are young drivers over-represented in crashes? Summary of the issues, Sydney: University of New South Wales, 1999.

36) Insurance Institute for Highway Safety (IIHS), (2012), Fatality facts 2010: Teenagers. Retrieved September 19, 2013.
from http://www.iihs.org/iihs/topics/t/teenagers/topicoverview

37) Simons-Morton, B. G., Lerner, N., Singer, J.: The observed effects of teenage passengers on the risky driving behavior of teenage drivers, Accident Analysis and Prevention, 37(6), 973–982, 2005.

38) Klauer, S. G., Guo, F., Simons-Morton, B. G., Ouimet, M. C., Lee, S. E., Dingus, T. A. (in press): Distracted driving and crash risk among novice and experienced drivers, New England Journal of Medicine, 2014.

39) Simons-Morton, B. G., Quimet, M. C., Zhang, Z., Klauer, S. E., Lee, S. E., Wang, J. et al.: The effect of passengers and risk-taking friends on risky driving and crashes/near crashes among novice drivers, Journal of Adolescent Health, 49, 587–593, 2011.

40) National Highway Traffic Safety Administration, (2012), Alcohol-impaired driving. Traffic Safety Facts: 2010 Data, (NHTSA Publication No. DOT HS 811 606), Retrieved svibanj 2., 2016., from http://www-nrd.nhtsa.dot.gov/Pubs/811606.pdf (PDF - 792K)

41) Klauer, S. G., Simons-Morton, B., Lee, S. E., Quimet, M. C., Howard, E. H., Dingus, T. A.: Novice drivers' exposure to known risk factors during the first 18 months of licensure: The effect of vehicle ownership, Traffic Injury Prevention, 12, 159–168, 2011.

42) Simons-Morton, B. G., Bingham, C. R., Ouimet, M. C., Pradhan, A., Falk, E., Li, K. G. et al. (in press): The effect of teenage passengers on simulated risky driving among teenagers: A randomized trial, Health Psychology, 2019.

43) O'Malley Olsen, E., Shults, R. A., Eaton, D. K.: Texting while driving and other risky motor vehicle behaviors among US high school students, Pediatrics, 131, e1708–e1715, 2013.

44) Cioca, L. I., Ivascu, L.: *Risk Indicators and Road Accident Analysis for the Period 2012–2016*, Sustainability, Australia, 2017.

45) CDS (Centers for Disease Control and Prevention), Transport SafetyTeen Drivers: Risk Factor, USA, 2017.

46) Franesco, A. et.al.: *Handbook of Traininig Guidelines on Road Safety Awareness and Education for Young Drivers*, ICARUS Project-EU, 2008.

47) WHO (World Health Organization), Youth and Road Safety, Geneva, Switzerland, 2017.

48) NTHSA (National Highway Traffic Safety Administration), corp-author Drunk Driving, USA, 2019.

49) WHO (World Health Organization), Road traffic injuries, Global status report on road safety 2015.

50) Romano, E., Torres-Saavedra, P., Voas, R. B., Lacey, J. H.: Drugs and alcohol: Their relative crash risk, J Stud Alcohol Drugs, 2014.

51) Simonsen, K., Linnet, K., Rasmussen, B. S.: Driving under the influence of alcohol and drugs in the eastern part of Denmark in 2015 and 2016.

52) Al-Abdallat, I. M., Al Ali, R., Hudaib, A. A., Salameh, G. A., Salameh, R. J., Idhair, A. K.: The prevalence of alcohol and psychotropic drugs in fatalities of road-traffic accidents in Jordan during 2008–2014. J Forensic Leg Med. 2016.

53) Gadegbeku, B., Amoros, E., Laumon, B.: Responsibility study: Main illicit psychoactive substances among car drivers involved in fatal road crashes, Ann Adv Automot Med. 2011.

54) Martin, J. L., Gadegbeku, B., Wu, D., Viallon, V., Laumon, B.: Cannabis, alcohol and fatal road accidents, PLoS One 2017.

55) Veldstra, J. L., Brookhuis, K. A., de Waard, D., Molmans, B. H., Verstraete, A. G., Skopp, G., Jantos, R.: Effects of alcohol (BAC 0.5‰) and ecstasy (MDMA 100 mg) on simulated driving performance and traffic safety, Psychopharmacology (Berl) 2012.]

56) Brubacher, J. R., Chan, H., Martz, W., Schreiber, W., Asbridge, M., Eppler, J., Lund, A., MacDonald, S., Drummer, O., Purssell, R. et al.: Prevalence of alcohol and drug use in injured British Columbia drivers, BMJ Open, 2016.

57) Ampanozi, G., Kovatsi, L., Smyrnakis, E., Zaggelidou, E., Gavana, M., Papadakis, N., Benos, A.: Anlysis of fatal motor vehicle collisions: Evidence from Central Macedonia, Greece, Hippokratia, 2011.

58) Foster, S., Gmel, G., Estévez, N., Bähler, C., Mohler-Kuo, M.: Temporal patterns of alcohol consumption and alcohol-related road accidents in young swiss men: Seasonal, weekday and public holiday effects, Alcohol Alcohol, 2015.

59) Furr-Holden, C. D., Voas, R. B., Lacey, J., Romano, E., Jones, K.: The prevalence of alcohol use disorders among night-time weekend drivers, Addiction, 2011.

60) European Commission, corp-author. Road safety in the European Union Trends, statistics andmainchallenges, https://ec.europa.eu/transport/road_safety/sites/roadsafety/files/vademecum_2018.

61) Bogstrand, S. T., Larsson, M., Holtan, A., Staff, T., Vindenes, V., Gjerde, H.: *Associations between driving under the influence of alcohol or drugs, speeding and seatbelt use among fatally injured car drivers in Norway*, Accid Anal Prev. 2015.

62) European Comimission *Mobility And Transport, Road Safety,* Statistics – accidents, data Novice drivers, 2018.

63) AAA Foundation for Traffic Safety, *Improving traffic safety culture in the United States*: the journey forward., Washington, DC, 2007.

64) Ward, N. J., Linkenbach, J., Keller, S. N., Otto, J. (2010) White Paper on Traffic Safety Culture, White Paper No. 2. Western Transportation Institute, College of Engineering Montana State University, BozemanGoogle Scholar.

65) USDOT (2011) Safety culture: A significant driver for safety in transportation. Research paper prepared for the US DOT Safety Council. USDOT, Washington, DCGoogle Scholar.

66) Conner, M., Lawton, R., Parker, D., Chorlton, K., Manstead, A. S. R., Stradling, S. (2007). Application of the theory of planned behaviour to the prediction of objectively assessed breaking of posted speed limits, British Journal of Psychology, 98, 429−453.

67) Rakauskas, Ward, Gerberich: Identification of differences between rural and urban safety cultures Article (PDF Available) in Accident; analysis and prevention 41(5):931−7 October 2009.

68) Ward, N. J., Otto, J., Linkenbach, J.: A Primer for Traffic-safety culture, ITE Journal, May Edition, 41–47, 2014.

69) Myers, D. J., Nyce, J. M., Dekker, S. W. A.: Setting culture apart: Distinguishing culture from behavior and social structure in safety and injury research, Accident Analysis and Prevention, 68, 25–29. p. 26, 2014.

70) Reiman, T., Rollenhagen, C.: Does the concept of safety culture help of hinder systems thinking in safety?, Accident Analysis and Prevention, 68, 5–15, 2014.

71) Markl, M., Effectiveness of Road Safety Educational Program for Pre-drivers about DUI: Practical Implication of the TPB in Developing New Preventive Program in Slovenia, Transportation Research Procedia, 14, pp. 3829−3838, 2016.

72) Meyer, S., Sagberg, F., Torquato, R.: Traffic hazard perception among children, Transportation Research Part F: Traffic Psychology and Behaviour, 26, Part A, pp. 190−198, 2014.

73) Innamaa, S. et al.: Develop the Method Further, and Find Factors that Statistically Significantly Affect Traffic Incident Risk, Finland, 2013.

74) Donges, E.: Aspects of active safety when driving passenger cars. Automobil-Industrie 27, pp. 183−190, 1982.

75) Michon, J. A.: A critical view of driver behavior models: what do we know what should we do? in Evanas, I. and Schawing, R. (Eds.) Human behavior and traffic safety.New York, Plenum Press, 1985.

76) Janssen, W. H.: Routeplaning en gelelding: Een Literatuarstudie. Report IFZ 1979 V. 13 Soesteburg (The Netherslands): Institute for Perception TNO, 1979.

77) https://www.google.com/search?q=objective+risks+in+traffic&oq=objective+risks+in+traffic&aqs=chrome..69i57j33.1570j0j7&sourceid=chrome&ie=UTF-8

78) https://www.diva-portal.org/smash/get/diva2:161097/fulltext01

79) Hermitte, T. et al.: *Identification of Vehicle Related Risk Factors*, Deliverable 6.1 of the H2020 project Safety Cube, U.K, 2016.

80) Nilsson, R.: *Safety Margins in the Driver*, Acta Universitatis Upsaliensis Uppsala, Sweden 2001.

81) Janssen, W. H.: *Routeplaning en gelelding*: *Een Literatuarstudie.* Report IFZ 1979 V. 13 Soesteburg (The Netherslands): Institute for Perception TNO, 1979.

82) Rasmussen, J.: Cognitive control and human error mechanisms, V New technology and human error, ur. Jens Rasmussen, Keith Duncan in Jacques Leplat, 53−61. New York: John Wiley & Sons, 1987.

83) Michon, J. A: A critical view of driver behavior models: what do we know what should we do? in Evanas, I. and Schawing, R. (Eds.) *Human behavior and traffic safety*, New York, Plenum Press, 1985.

84) Sagberg, F., Selpi, S., Piccinini, G. F. B., in Engström, J.: A Review of Research on Driving Styles and Road Safety, Human Factors 57 (7): 1248–1275, 2015.

85) Dula, C. S. in Ballard, M. E.: Development and Evaluation of a Measure of Dangerous, Aggressive, Negative Emotional, and Risky Driving. Journal of Applied Social Psychology 33: 263–282, 2003.

86) Shinar, D.: Traffic Safety and Human Behavior, London: Elsevier Inc., 2007.

87) Delhomme, P., De Dobbelleer, W., Forward, S. in Simoes, A.: Manual for Designing, Implementing, and Evaluating Road Safety Communication Campaigns, Brussels: Belgium Road Safety Institute, 2009.

88) Fuller, R.: Driver Control Theory, V Handbook of Traffic Psychology, ur. Bryan E. Porter, 13–26. London: Elsevier Inc., 2011.

89) Fuller, R.: Towards a general theory of driver behaviour, Accident Analysis and Prevention 37: 461−472, 2005.

90) Regan, M. A.: Driven by distraction, Vision Zero International 2 (1): 4−12, 2010.

91) Regan, M. A., Hallett, C.: Driver Distraction, V Handbook of Traffic Psychology, ur. Bryan E. Porter, 275–286. London: Elsevier Inc., 2011.

92) Regan, M. A., Lee, J. D. in Young, K. L.: Driver Distraction Injury Prevention Countermeasures – Part 2: Education and Training. V Driver Distraction: Theory, Effects and Mitigation, ur. Regan, M. A., Lee, J. D. in Young, K. L., 559−578. Boca Raton: CRC Press, 2008.

93) Elvik, R. et al.: Trafikksikkerhetshåndbok: Oversikt over virkninger, kostnader og offentlige ansvarsforhold for 124 trafikksikkerhetstiltak, Transportøkonomisk institutt, Oslo, Norway, 1977.

94) Elvik, R., Vaa, T.: The Handbook of Road Safety Measures, Elsevier, Amsterdam, Netherlands, 2004.

95) Minimum European Requirements for Driving Instructor Training-EU MERIT Project, Recommendations Regarding Minimum Requirements for Driving Instructors, 2004 – 2007, Brussels, Belgium, 2007.

96) Mayhew, D. R., Simpson, H. M., Singhal, D., Desmond, K.: Reducing the Crash Risk for Young Drivers, Foundation for Traffic Safety, Washington DC, USA, 2006.

97) Sagberg, F.: Summary: Driver Training, Driving Experience, and Crash Risk (English summary of report in Norwegian), Transportøkonomisk institutt (TØI), Oslo, Norway, 2002.

98) Gregersen, N. P., Nyberg, A.: Lay Instruction During Driver Training; A Study on How it is Carried Out and its Impact on Road Safety (in Swedish with English summary), VTI report 481,VTI (Swedish National Road and Transport Research Institute), Linköping, Sweden, 2002.

99) Siegrist, S.: Driver Training, Testing and Licensing – Towards Theory-based Management of Young Drivers' Injury Risk in Road Traffic, Results of EU-Project GADGET (Guarding Automobile Drivers through Guidance, Education and Technology), Work Package 3, Report 40, Schweizerische Beratungsstelle Fuer Unfallverhuetung, Berne, Switzerland, 1999.

100) Keskinen, E.: Why Do Young Drivers Have More Accidents? Bundesanstalt für Strassenwesen (Bast), Berisch Bladbach, Germany, 1996.

101) Hatakka, M., Keskinen, E., Baughan, C., Goldenbeld, C., Gregersen, N. P., Groot, H., Siegrist, S., Willmes-Lenz, G., Winkelbauer, M.: BASIC – Driver Training: New Models, Final Report, University of Turku, Finland, 2003.

102) Engström, I., Gregersen, N. P., Hernetkoski, K., Keskinen, E., Nyberg, A.: Young Novice Driver Education and Training, Literature Review, VTI Report 491A., Swedish National Road and Transport Research Institute (VTI), Linköping, Sweden, 2003.

103) ADVANCED Study of post-licence driver and rider training, 2002−2003, Brussels, Belgium, 2003.

104) Johnson, H., Sundström, A., Henriksson, W.: Curriculum, Driver Education and Driver Testing, Sweden, 1992 A Comparative Study of the Driver Education Systems in Some European Countries (Educational Measurement No. 44), Umeå University (EM) Department of Educational Measurement, Umeå, Sweden, 2003.

105) Messick, S., „Validity“ in Linn, R. L. (Ed.): Educational Measurement, American Council on Education and Macmillan, New York, USA, 1989.

106) Jonahtan, P. E.: The Effect of Graduated Driver Licensing on Teen Driver Crash Involvement, doctoral dissertation, The University of Michigan, USA, 2012.

107) Young Drivers − The Road to Safety, Organisation for Economic Co-operation and Development (OECD), European Conference of Ministers of Transport (ECMT), Paris, France, 2006.

108) Simons-Morton, B. G., Hartos, J. L.: How Well do Parents Manage Young Driver Crash Risk? in Journal of Safety Research, Vol. 34, No.1, pp. 91−97. Sweden, 2003.

109) Hedlund, J., Shults, R. A. and Compton, R.: What We Know, What We Don’t Know and What We Need to Know about Graduated Driver Licensing, Journal of Safety Research, Vol. 34, pp. 107−115., 2003.

110) Senserrick, T., Whelan, M.: Graduated Driver Licensing: Effectiveness of Systems and Individual Components, Monash University, Accident Research Centre, Clayton, Australia, 2003.

111) Službeni list Europske unije, Direktiva 2006/126/EC Europskog Parlamenta i Vijeća, Brussels, Belgium, 2006.

112) Udhezimi Administrativ për plan programin e kandidatit për shofer, Prishtinë, 2017.

113) Udhezimi Administrativ për dhënien e provimit për patentë shofer, Prishtinë, 2017.

114) Kodi për Qarkullimin rrugor, Tiranë, 2017.

115) Qarkuimi rrrugor dhe automjeti, Tiranë, 2009.

116) Zakon o sigurnosti prometa na cestama (pročišćeni tekst zakona NN 67/08, 48/10, 74/11, 80/13, 158/13, 92/14, 64/15, 108/17, 70/19) na snazi od 01.08.2019.

117) Pravilnik o osposobljavanju kandidata za vozače (Broj: 511-01-152-66867/6-2011), Zagreb, 6. studenoga 2012.

118) Zakon o voznikih (Uradni list RS, št. 85/16, 67/17, 21/18 – ZNOrg in 43/19).

119) Pravilnik o vozniškem izpitu (Uradni list RS, št. 38/13 z dne 3. 5. 2013).

120) Pravilnik o osposobljavanju za vozača motornih vozila br.46, Godina XVI, utorak, lipnja, 2012 godine http://cms.monkshnk.gov.ba/Upload/Dokumenti/12)-825f871.pdf

121) Službeni glasnik BiH, broj 12/18, Pravilnik o izmjenama i dopunama Pravilnika o osposobljavanju za vozača motornih vozila

122) Pravilnik o osposobljavanju za vozača motornih vozila, Službeni glasnik, br. 46, BiH, 2012.

123) Pravilnik o načinu i uvjetima organiziranja ispita za vozača motornih vozila, Službeni glasnik, br. 46, BiH, 2012.

124) Pravilnik za približne kriterije, način rada autoškole, nastavni plan i program za obuku stručnog kadra, oprema koja se treba imati, evidencija i sve što treba za vođenje autoškole za osposobljavanje kandidata za vozača. Službeni list RM, br. 30 od 9.3.2017. https://mvr.gov.mk/Upload/Documents/34.pdf

125) Pravilnik o izmjeni i dopuni pravilnika o načinu provođenja vozačkog ispita i kriteriji koji se odnose na prostorne, tehničke, materijalne uvjete i informacijska oprema ispitnih centara, vođenje evidencije u vezi provedbe vozačkog ispita te obliku i sadržaja dozvole za ispitni centar. Službeni list RM, br. 19 od 29.01.2014. https://mvr.gov.mk/Upload/Documents/12(2).pdf

126) Pravilnik za približne kriterije, način rada autoškole, nastavni plan i program za obuku stručnog kadra, oprema koja se treba imati, evidencija i sve što treba za vođenje autoškole za osposobljavanje kandidata za vozača. Službeni list RM, br. 30, 2017.

127) Pravilnik o izmjeni i dopuni pravilnika o načinu provođenja vozačkog ispita i kriteriji koji se odnose na prostorne, tehničke, materijalne uvjete i informacijska oprema ispitnih centara, vođenje evidencije u vezi provedbe vozačkog ispita te obliku i sadržaja dozvole za ispitni centar. Službeni list RM, br. 9, 2014.

128) Pravilnik o teorijskoj i praktičnoj obuci kandidata za vozače, Sl. glasnik RS, br. 93/2013, 116/2013, 108/2014, 36/2015, 51/2015, 86/2015, 104/2015, 77/2016 i 63/2017, Srbija, 2017.

129) Instat, Aksidentet rrugore, Shqipëri, Tiranë, 2019.

130) Republika Hrvatska, Ministarstvo unutarnjih poslova, Bilten o sigurnosti cestovnog prometa 2018. XLV. godina, Zagreb, 2019.

131) Prometne nesreče in posledice v zadnjih petih letih (2013 – 2018) prikazuje število umrlih udeležencev v obdobju 2014 – 2018 po mesecih

132) Analiza in pregled stanja varnosti v cestnem prometu za letohttps://www.avp-rs.si › wp-content › uploads › 2019/01.

133) BIHAMK-Bosanskohercegovački auto-moto klub sektor za informisanje i dokumentaciju (sid) informacija o saobraćajnim/prometnim nezgodama, njihovim uzrocima i posljedicama u Bosni i Hercegovini u 2017. godini, 2018.

134) BIHAMK-Bosanskohercegovački auto-moto klub sektor za informisanje i dokumentaciju (sid) informacija o saobraćajnim/prometnim nezgodama, njihovim uzrocima i posljedicama u Bosni i Hercegovini u 2018. godini, 2019.

135) Statističko izvješće o stanju sigurnosti u prometu u Republici Srbiji u 2018. godini, Beograd, 2019.

136) Crna Gora-Vlada Crne Gore/Ministarstvo unutrašnjih poslova „Program poboljšanja bezbjednosti u drumskom saobraćaju 2020. – 2022. godina s akcionim planom 2020. – 2022.godina“, Podgorica, 2019.

POPIS SLIKA

Slika 2- 1 Čimbenici prometnih nesreća 8

Slika 2- 2 Prikaz nepravilnog postavljanja prometne signalizacije 12

Slika 2- 3 Modeli ponašanja vozača 22

Slika 4- 1 Nacionalne ceste (N2) prije i nakon rekonstrukcije 49

Slika 4- 2 Mreža cesta na Kosovu 50

Slika 5- 1 Proces osposobljavanja kandidata za vozača motornih vozila 69

Slika 5- 2 Elementi osposobljavanja kandidata za vozača 69

POPIS DIJAGRAMA

Dijagram 2- 1 Kombinacija razine učinka 23

Dijagram 3- 1 Trokut edukacije vozača 32

Dijagram 3- 2 Struktura klasičnog (a) i dvofaznog sustava (b) vozačke dozvole 35

Dijagram 3- 3 Sustav osposobljavanja vozača motornih vozila 37

Dijagram 3- 4 Postojeći proces stjecanja vozačke dozvole u Republici Kosovu 38

Dijagram 4- 1 Broj nastradalih osoba u prometnim nesrećama na području Rep. Kosova izemalja u regiji 46

Dijagram 5- 1 Prikaz ispitanika prema mjestu prebivališta 64

Dijagram 5- 2 Prikaz ispitanika prema socioekonomskom statusu 65

Dijagram 5- 3 Stupanj edukacije predavača u autoškoli 70

Dijagram 5- 4 Dopunski teorijski sati 74

Dijagram 5- 5 Broj dopunskih satova vožnje 75

Dijagram 6- 1 Rasipanja s različitim vrijednostima koeficijenta korelacije (ρ) 101

Dijagram 6- 2 Korelacije prometne nesreće – tehnika vožnje 111

Dijagram 6- 3 Korelacije prometne nesreće – frekvencija vožnje 111

Dijagram 6- 4 Korelacije prometne nesreće – psihosocijalna komponenta 112

Dijagram 6- 5 Korelacije prometne nesreće – ponašanja 112

Dijagram 6- 6 Korelacije prometne nesreće – predznanja 113

Dijagram 6- 7 Korelacije prometne nesreće – nastava 113

Dijagram 6- 8 Korelacije prometne nesreće – kilometraža 114

Dijagram 6- 9 Korelacije prometne nesreće – distrakcije 114

Dijagram 6- 10 Korelacije prometne nesreće – manevriranja 115

Dijagram 6- 11 Korelacije prometne nesreće – vozila 115

Dijagram 6- 12 Korelacije prometne nesreće – prilagodba 116

Dijagram 6- 13 Korelacije prometne nesreće – suho 116

Dijagram 6- 14 Korelacije prometne nesreće – signalizacija 117

Dijagram 6- 15 Korelacije prometne nesreće – brzina 117

Dijagram 6- 16 Korelacije prometne nesreće – traka 118

Dijagram 6- 17 Korelacije prometne nesreće – noć 118

Dijagram 6- 18 Korelacije prometne nesreće – izvan grada 119

Dijagram 6- 19 Korelacije prometne nesreće – pretjecanje 119

Dijagram 6- 20 Korelacije prometne nesreće – videoprocjena 120

Dijagram 7- 1 Model procjene rizika od prometnih nesreća 123

POPIS TABLICA

Tablica 3- 1 Prikaz GDE matrice 30

Tablica 3- 2 Modeli osposobljavanja 33

Tablica 3- 3 Osposobljavanja kandidata za vozače u Republici Kosovu i zemljama regije 42

Tablica 3- 4 Proces ispitivanja za vozačke dozvole 42

Tablica 4- 1 Broj nastradalih osoba u prometnim nesrećama na području Rep. Kosova i zemalja u regiji 45

Tablica 4- 2 Broj poginulih osoba u prometnim nesrećama na području Rep. Kosova i zemalja u regiji 47

Tablica 4- 3 Broj km prema kategorijama 49

Tablica 4- 4 Broj poginulih vozača prema kategorijama cesta 51

Tablica 4- 5 Broj poginulih mladih vozača prema kategorijama cesta 52

Tablica 4- 6 Broj poginulih vozača prema elementima ceste s udjelom mladih vozača 53

Tablica 4- 7 Uzroci prometnih nesreća s poginulim vozačima za razdoblje od 2014. do 2018. godine 54

Tablica 4- 8 Broj poginulih vozača prema uvjetima i stanju površine kolnika 56

Tablica 4- 9 Broj poginulih vozača prema dobu dana za promatrano razdoblje 2014. – 2018. 57

Tablica 4- 10 Broj poginulih vozača prema danu u tjednu 58

Tablica 4- 11 Broj poginulih vozača prema tipu nesreće 59

Tablica 5- 1 Prikaz ispitanika prema spolu 61

Tablica 5- 2 Prikaz ispitanika prema dobi 62

Tablica 5- 3 Prikaz ispitanika prema vozačkom stažu 62

Tablica 5- 4 Prikaz ispitanika prema sudjelovanju u prometnim nesrećama 63

Tablica 5- 5 Prikaz uzroka prometnih nesreća u kojima su sudjelovali mladi vozači 63

Tablica 5- 6 Prikaz ispitanika prema učestalosti korištenja automobila 65

Tablica 5- 7 Prikaz ispitanika prema poštovanju ograničenja brzine 66

Tablica 5- 8 Prikaz ispitanika prema samoprocjeni brzine vožnje 67

Tablica 5- 9 Prikaz ispitanika prema procjeni tehnike vožnje 67

Tablica 5- 10 Prikaz ispitanika prema procjeni promjene vlastitog ponašanja u prometu 68

Tablica 5- 11 Prikaz predznanja o ponašanju u prometu 70

Tablica 5- 12 Prikaz broja satova nastave za procjenu rizika nastanka prometnih nesreća 71

Tablica 5- 13 Podaci o videozapisu kao dijelu nastave za procjenu rizika nastanka prometnih nesreća 72

Tablica 5- 14 Praktična nastava u skupinama 73

Tablica 5- 15 Prosječni broj kilometara 73

Tablica 6- 1 Prikaz rezultata analize prometnih nesreća prema spolu 77

Tablica 6- 2 Rezultat hi-kvadrat testa prometnih nesreća prema spolu 77

Tablica 6- 3 Prikaz rezultata analize prometnih nesreća prema uzrastu 78

Tablica 6- 4 Rezultat hi-kvadrat testa prometnih nesreća prema uzrastu 78

Tablica 6- 5 Prikaz rezultata analize prometnih nesreća prema frekvenciji vožnje 79

Tablica 6- 6 Rezultat hi-kvadrat testa prometnih nesreća prema frekvenciji vožnje 79

Tablica 6- 7 Prikaz rezultata analize prometnih nesreća i ograničenja brzine 80

Tablica 6- 8 Rezultat hi-kvadrat testa prometnih nesreća prema ograničenju brzine 80

Tablica 6- 9 Prikaz rezultata analize prometnih nesreća s obzirom na procjenu tehnike vožnje 81

Tablica 6- 10 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na procjenu tehnike vožnje 81

Tablica 6- 11 Prikaz rezultata analize prometnih nesreća s obzirom na psihosocijalne komponente 82

Tablica 6- 12 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na psihosocijalne komponente 82

Tablica 6- 13 Prikaz rezultata analize prometnih nesreća s obzirom na promjene ponašanja u prometu 83

Tablica 6- 14 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na promjene ponašanja u prometu 83

Tablica 6- 15 Prikaz rezultata analize prometnih nesreća s obzirom na stečeno predznanje o ponašanju u prometu 84

Tablica 6- 16 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na stečeno predznanje o prometnim nesrećama 84

Tablica 6- 17 Prikaz rezultata analize prometnih nesreća s obzirom na pohađanje teorijske nastave 85

Tablica 6- 18 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na pohađanje teorijske nastave 85

Tablica 6- 19 Prikaz rezultata analize prometnih nesreća s obzirom na videoprocjene 86

Tablica 6- 20 Prikaz rezultata analize prometnih nesreća s obzirom na videoprocjene 86

Tablica 6- 21 Prikaz rezultata analize prometnih nesreća s obzirom na broj prijeđenih kilometara iz praktične nastave 87

Tablica 6- 22 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na broj prijeđenih kilometara iz praktične nastave 87

Tablica 6- 23 Prikaz rezultata analize prometnih nesreća s obzirom na organiziranje praktične nastave 88

Tablica 6- 24 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na organiziranje praktične nastave 88

Tablica 6- 25 Prikaz rezultata analize prometnih nesreća s obzirom na manevriranja vozilom 89

Tablica 6- 26 Rezultat hi-kvadrat testa prometnih nesreća s obzirom na manevriranja vozilom 89

Tablica 6- 27 Prikaz rezultata analize prometnih nesreća s obzirom na uključivanje u promet 90

Tablica 6- 28 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na uključivanje u promet 90

Tablica 6- 29 Prikaz rezultata analize prometnih nesreća s obzirom na promjene prometnih traka 91

Tablica 6- 30 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na promjene prometnih traka 91

Tablica 6- 31 Prikaz rezultata analize prometnih nesreća s obzirom na distrakcije tijekom vožnje 92

Tablica 6- 32 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na distrakcije tijekom vožnje 92

Tablica 6- 33 Prikaz rezultata analize prometnih nesreća s obzirom na vožnje noću 93

Tablica 6- 34 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnje noću 93

Tablica 6- 35 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju izvan grada ... 94

Tablica 6- 36 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju izvan grada 94

Tablica 6- 37 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju vikendom 95

Tablica 6- 38 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju vikendom 95

Tablica 6- 39 Prikaz rezultata analize prometnih nesreća s obzirom na reagiranje u vožnji 96

Tablica 6- 40 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na reagiranje u vožnji 96

Tablica 6- 41 Prikaz rezultata analize prometnih nesreća s obzirom na signalizaciju 97

Tablica 6- 42 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na signalizaciju 97

Tablica 6- 43 Prikaz rezultata analize prometnih nesreća s obzirom na vozilo 98

Tablica 6- 44 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vozilo 98

Tablica 6- 45 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju po suhoj i čistoj površini kolnika 99

Tablica 6- 46 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju po suhoj i čistoj površini kolnika 99

Tablica 6- 47 Prikaz rezultata analize prometnih nesreća s obzirom na vožnju na ravnom cestovnom segmentu 100

Tablica 6- 48 Prikaz rezultata analize hi-kvadrat testa prometnih nesreća s obzirom na vožnju na ravnom cestovnom segmentu 100

Tablica 6- 49 Rezultat testa korelacije osnovnih značajki mladih vozača 102

Tablica 6- 50 Rezultat testa korelacije ostalih promjenjivih varijabli 103

Tablica 7- 1 Uzroci prometnih nesreća 122

Tablica 8- 1 ANOVA test 126

Tablica 8- 2 ANOVA test 127

POPIS PRILOGA

str.

Prilog A	157
Prilog B	160

Prilog A

ANOVA

		Sum of Squares	df	Mean Square	F	Sig.
Spol	Between Groups	4.279	1	4.279	18.737	.000
	Within Groups	84.266	369	.228		
	Total	88.544	370			
Uzrast	Between Groups	23.634	1	23.634	24.886	.000
	Within Groups	350.431	369	.950		
	Total	374.065	370			
Frekvencije	Between Groups	47.902	1	47.902	38.910	.000
	Within Groups	454.266	369	1.231		
	Total	502.167	370			
Tehnika	Between Groups	45.893	1	45.893	36.875	.000
	Within Groups	459.239	369	1.245		
	Total	505.132	370			
Psihosoc.	Between Groups	13.068	1	13.068	19.040	.000
	Within Groups	253.261	369	.686		
	Total	266.329	370			
Ponašanje	Between Groups	87.249	1	87.249	61.612	.000
	Within Groups	522.541	369	1.416		
	Total	609.790	370			
Predznanje	Between Groups	79.858	1	79.858	71.678	.000
	Within Groups	411.113	369	1.114		
	Total	490.970	370			
Iskustvo	Between Groups	227.332	1	227.332	152.701	.000
	Within Groups	549.347	369	1.489		
	Total	776.679	370			
Nastava	Between Groups	148.358	1	148.358	90.952	.000
	Within Groups	601.901	369	1.631		
	Total	750.259	370			
Kilometraža	Between Groups	5.973	1	5.973	3.312	.070
	Within Groups	665.439	369	1.803		
	Total	671.412	370			
Distrakcije	Between Groups	124.455	1	124.455	74.246	.000
	Within Groups	618.542	369	1.676		
	Total	742.997	370			
Manevriranja	Between Groups	56.800	1	56.800	45.473	.000
	Within Groups	460.915	369	1.249		
	Total	517.714	370			
Vozila	Between Groups	.676	1	.676	1.127	.289

	Within Groups	221.351	369	.600		
	Total	222.027	370			
Prilagodba	Between Groups	101.081	1	101.081	62.345	.000
	Within Groups	598.272	369	1.621		
	Total	699.353	370			
Suho	Between Groups	293.455	1	293.455	360.309	.000
	Within Groups	300.534	369	.814		
	Total	593.989	370			
Uključivanje	Between Groups	3.946	1	3.946	3.115	.078
	Within Groups	467.375	369	1.267		
	Total	471.321	370			
Signalizacija	Between Groups	53.208	1	53.208	38.291	.000
	Within Groups	512.749	369	1.390		
	Total	565.957	370			
Brzina	Between Groups	118.287	1	118.287	457.321	.000
	Within Groups	95.443	369	.259		
	Total	213.730	370			
Traka	Between Groups	3.475	1	3.475	5.074	.025
	Within Groups	252.708	369	.685		
	Total	256.183	370			
Noć	Between Groups	89.757	1	89.757	75.362	.000
	Within Groups	439.483	369	1.191		
	Total	529.240	370			
Izvan grada	Between Groups	32.479	1	32.479	32.195	.000
	Within Groups	372.265	369	1.009		
	Total	404.744	370			
Reagiranje	Between Groups	152.610	1	152.610	97.177	.000
	Within Groups	579.492	369	1.570		
	Total	732.102	370			
Pretjecanja	Between Groups	217.852	1	217.852	333.723	.000
	Within Groups	240.881	369	.653		
	Total	458.733	370			
Skupina	Between Groups	210.117	1	210.117	665.197	.000
	Within Groups	116.557	369	.316		
	Total	326.674	370			
Vikend	Between Groups	51.408	1	51.408	42.196	.000
	Within Groups	449.562	369	1.218		
	Total	500.970	370			
Videoprocjena	Between Groups	111.149	1	111.149	432.454	.000
	Within Groups	94.840	369	.257		
	Total	205.989	370			

Organizranje	Between Groups	77.415	1	77.415	79.967	.000
	Within Groups	357.221	369	.968		
	Total	434.636	370			
Ravnica	Between Groups	255.135	1	255.135	283.061	.000
	Within Groups	332.595	369	.901		
	Total	587.730	370			
Vozačko isk.	Between Groups	17.097	1	17.097	23.279	.000
	Within Groups	271.016	369	.734		
	Total	288.113	370			

Izvor: Izradio autor

PRILOG B

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
Spol	371	1.00	2.00	1.3935	.48919
Uzrast	371	1.00	4.00	2.0889	1.00548
Frekvencije	371	1.00	5.00	3.1860	1.16499
Tehnika	371	1.00	5.00	3.5660	1.16843
Psihosoc.	371	1.00	5.00	3.5337	.84841
Ponašanje	371	1.00	5.00	2.1294	1.28378
Predznanje	371	1.00	5.00	3.1644	1.15193
Iskustvo	371	1.00	5.00	2.7547	1.44884
Nastava	371	1.00	5.00	2.5364	1.42398
Kilometraža	371	1.00	5.00	2.1914	1.34708
Distrakcije	371	1.00	5.00	2.4313	1.41707
Manevriranja	371	1.00	5.00	3.7143	1.18289
Vozila	371	1.00	5.00	3.1941	.77464
Prilagodba	371	1.00	5.00	2.6900	1.37482
Suho	371	1.00	5.00	3.0054	1.26703
Uključivanje	371	1.00	5.00	3.3585	1.12865
Signalizacija	371	1.00	5.00	3.0108	1.23678
Brzina	371	2.00	5.00	4.0270	.76003
Traka	371	1.00	5.00	3.7466	.83210
Noć	371	1.00	5.00	3.1995	1.19598
Izvan grada	371	1.00	5.00	3.3531	1.04590
Reagiranje	371	1.00	5.00	2.5418	1.40665
Nesreća	371	1.00	2.00	1.2642	.44148
Pretjecanja	371	1.00	5.00	2.5067	1.11347
Skupina	371	1.00	4.00	2.7439	.93963
Vikend	371	1.00	5.00	3.1644	1.16360
Videoprocjena	371	1.00	5.00	3.1375	.74614
Organizranje	371	1.00	4.00	2.1968	1.08383
Ravnica	371	1.00	5.00	2.9730	1.26034
Vozačko isk.	371	1.00	4.00	1.7358	.88243
Ngasja	371	1.00	4.00	1.9757	.97368
Valid N (listwise)	371				

Izvor: Izradio autor

ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA

Životopis

Habib Hasani rođen je 24. siječnja 1963. godine u Mitrovici, Republika Kosovo gdje je završio osnovnu i srednju školu. Višu prometnu školu u Zagrebu završio je 1986. godine, a Fakultet prometnih znanosti 2005. godine i stekao akademski naziv diplomirani inženjer cestovnog prometa. Na Sveučilištu u Prištini nastavio je poslijediplomski studij koji je uspješno završio 2009. godine i stekao akademski naziv magistar prometnih znanosti.

Od 2001. godine zaposlen je u Ministarstvu infrastrukture u Prištini u sektoru za vozačke dozvole na radnom mjestu rukovoditelja za regiju Mitrovica. Radio je i kao prometni stručnjak na analizi prometnih nesreća te je kao koautor sudjelovao u objavi dviju knjiga pod nazivom *Prometna i sigurnosna pravila* izdane 2011. i 2013. godine.

U znanstvenom radu bavi se područjem poboljšanja osposobljavanja vozača motornih vozila i provedbe vozačkih ispita. U dosadašnjem radu bio je član niza povjerenstava i radnih timova koji se bave područjem vozačkih dozvola te je sudjelovao na domaćim i međunarodnim znanstveno-stručnim skupovima.

Popis javno objavljenih radova

Znanstveni radovi u drugim časopisima

1. Luburić, G., **Hasani, H.**: *Comparative Analysis of Trainings for Driver Candidates among Republic of Kosovo and Regional Countries*, Balkan Journal of Interdisciplinary research, IPPCL, Publishing, 21st January, 2016, Tirana, Albania, p. 374−379

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

1. Luburić, G., **Hasani, H.**, Dedaj, N.: *The Effect of the Training Process on Young Drivers*, The Tenth International Annual Meeting of Alb-Science Institute Skopje, 28 − 29 August 2015, Skopje, Macedonia, p. 227−231
2. Missoni, E., Luburić, G., **Hasani, H.**: *Preschool Children Traffic Casualties and Drivers' Behaviour*, International Conference on Innovative Technologies, IN-TECH 2015, 9 – 11 September 2015, Dubrovnik, Croatia, p. 77−79

3. Luburić, G., **Hasani, H.**, Dedaj, N.: *The Link Between the Social-Economic Indicator and Traffic Accidents by Young Drivers*, Second International Conference on Interdisciplinary Studies − Global Challenge 2015, 19th December 2015, Tirana, Albania, p. 252−256
4. Luburić, G., **Hasani, H.**, Bagarić, A.: *Relationship Between Education Instructor Driver with Road Accidents to Young Drivers*, International Conference on Interdisciplinary Studies, 5 March 2016, Tirana, Albania, p. 266−271