Komparativna analiza metoda segmentiranja cestovnih dionica pri identifikaciji opasnih mjesta

Merkaš, Mario

Master's thesis / Diplomski rad

2020

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:119:495227

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







FAKULTET PROMETNIH ZNANOSTI

SVEUČILIŠTE U ZAGREBU

MARIO MERKAŠ

KOMPARATIVNA ANALIZA METODA SEGMENTIRANJA CESTOVNIH DIONICA PRI IDENTIFIKACIJI OPASNIH MJESTA

DIPLOMSKI RAD

Zagreb, 2020.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 27. ožujka 2020.

Zavod: **Zavod za prometno-tehnička vještačenja**
Predmet: **Prometno tehničke ekspertize i sigurnost**

DIPLOMSKI ZADATAK br. 5981

Pristupnik: **Mario Merkaš (0135243717)**
Studij: Promet
Smjer: Cestovni promet

Zadatak: **Komparativna analiza metoda segmentiranja cestovnih dionica pri identifikaciji opasnih mjesta**

Opis zadatka:

U Diplomskom radu je potrebno objasniti opasna mjesta u cestovnoj prometnoj mreži te njihov utjecaj na sigurnost cestovnog prometa. Analizirati parametre identifikacije opasnih mjesta te prikazati metode koje se koriste pri segmentiranju ceste u funkciji identifikacije opasnih mjesta. Provesti statističko ispitivanje opasnosti lokacija prometnih nesreća te usporediti dobivene rezultate i predložiti vrste segmentiranja ceste ovisno o značajkama ceste.

Mentor:

doc. dr. sc. Željko Šarić

Predsjednik povjerenstva za diplomski ispit:

Sveučilište u Zagrebu

Fakultet prometnih znanosti

Diplomski rad

KOMPARATIVNA ANALIZA METODA SEGMENTIRANJA CESTOVNIH DIONICA PRI IDENTIFIKACIJI OPASNIH MJESTA

COMPARATIVE ANALYSIS OF ROAD SEGMENT METHODS FOR IDENTIFICATION BLACK SPOT

Mentor: doc. dr. sc. Željko Šarić

Student: Mario Merkaš

JMBAG:0135243717

Zagreb, rujan 2020.

Sažetak

U cilju povećanja sigurnosti u cestovnom prometu potrebno je smanjiti broj prometnih nesreća. Lokacije na kojima se događa veći broj prometnih nesreća nazivaju se opasna mjesta ili „crne točke“. Postupak identifikacije opasnih mjesta jedan je od najučinkovitijih u procesu smanjenja broja prometnih nesreća. Prilikom identifikacije opasnih mjesta potrebno je koristiti neku od metoda segmentiranja ceste na manje dijelove unutar kojih se promatraju nastale promete nesreće te određuje je li određeni segment identificiran kao opasno mjesto ili nije. U tu svrhu postoji nekoliko metoda segmentacije, a u ovom radu napravljena je komparativna analiza dvije segmentacijske metode: metoda podjele prometnice na fiksne dijelove i *Sliding window* metoda.

KLJUČNE RIJEČI: opasna mjesta, prometne nesreće, *Sliding window*, podjela na fiksne dijelove

Summary

In order to increase road safety, it is necessary to reduce the number of traffic accidents. Locations where a large number of traffic accidents occur are called hazardous locations or „black spots“. The process of identification hazardous locations is one of the most effective in the process of reducing the number of traffic accidents. During the identification of hazardous locations, it is necessary to use one of the methods of segmenting the road into smaller parts within which the occurred traffic accidents are observed, and determine whether a certain segment is identified as a dangerous place or not. For this purpose, there are several methods of segmentation, and in this work a comparative analysis of two segmentation methods is made, the method of distribution the road into fixed parts and the Sliding window method.

KEYWORDS: hazardous locations, traffic accident, Sliding window, constant length

Sadržaj

1. Uvod 1
2. Opasna mjesta u cestovnom prometu 3
2.1. Metode identifikacije opasnih mjesta u cestovnoj prometnoj mreži 3
2.1.1. Brojčane definicije opasnih mjesta 4
2.1.2. Statističke definicije opasnih mjesta 5
2.1.2.1. Metoda učestalosti prometnih nesreća 5
2.1.2.2. Metoda stope prometnih nesreća 6
2.1.2.3. Metoda Rate Quality Control 8
2.1.3. Metode na temelju predviđanja 9
2.2. Metodologija identifikacije opasnih mjesta 10
2.2.1. Prikupljanje podataka o prometnim nesrećama 11
2.2.2. Identifikacija opasnih mjesta 12
2.2.3. Analiza i rangiranje opasnih mjesta 14
2.2.4. Pregled identificiranih potencijalno opasnih mjesta na terenu 14
2.2.5. Potvrđivanje opasnog mjesta 15
2.2.6. Ostali postupci u procesu identifikacije opasnih mjesta 15
2.3. Sustavi upravljanja opasnim mjestima 16
2.4. Vrste pristupa identificiranju opasnih mjesta 18
2.5. Učinkovitost saniranja opasnih mjesta 20
3. Parametri kod identifikacije opasnih mjesta 22
3.1. Vremenski period promatranja 23
3.2. Broj prometnih nesreća 24
3.3. Duljina promatrane dionice 25
3.4. Broj vozila 26
3.5. Težine (ozbiljnost) prometnih nesreća 27
4. Metode segmentiranja ceste pri identifikaciji opasnih mjesta 29

4.1. Segmentiranje dionice na fiksne dijelove 29
4.2. Segmentiranje dionice metodom *Sliding window* 31
4.3. Segmentacija cestovne mreže temeljena na grupiranja prometnih nesreća .. 32
4.4. Usporedba metoda segmentiranja ceste pri identifikaciji opasnih mjesta 34
5. Statističko ispitivanje opasnosti lokacija prometnih nesreća 38
5.1. Definiranje parametara 38
5.2. Geoprometni položaj državne ceste D7 41
5.3. Analiza stanja sigurnosti na državnoj cesti D7 41
5.4. Proces identifikacije opasnih mjesta 44
5.4.1. Identifikacija potencijalno opasnih mjesta metodom podjele na fiksne dijelove 45
5.4.2. Identifikacija potencijalno opasnih mjesta metodom *Sliding window* 47
6. Komparativna analiza dobivenih rezultata 52
7. Zaključak 59
Literatura 62
Popis grafikona 64
Popis slika 64
Popis tablica 65

1. Uvod

Sigurnost u prometu je jedan od vodećih svjetskih problema, a predviđa se i pogoršanje ukoliko se problemu ne pristupi na pravilan način. Prema podacima Svjetske zdravstvene organizacije (WHO) 1,35 milijuna ljudi umre svake godine od posljedica prometnih nesreća, a ozljede u cestovnom prometu vodeći su uzrok smrti djece i mladih u dobi od 5-29 godina. Također prometne nesreće predstavljaju i financijski trošak za svaku zemlju. Procjenjuje se da prometne nesreće svaku zemlju koštaju oko 3% vlastitog BDP-a.

Poboljšanje sigurnosti na cestama kao prvi korak podrazumijeva identifikaciju i saniranje opasni mjesta. Identifikacija opasnih mjesta važna je za pronalazak mjesta na kojima se događa iznad prosječni broj prometnih nesreća te mjesta na kojima se sigurnost u cestovnoj mreži može poboljšati. Pogreške u prepoznavanju opasnih mjesta mogu rezultirati neučinkovitom uporabom resursa za poboljšanje sigurnosti te smanjenje učinkovitosti upravljanja procesom sigurnosti. Da bih se izbjegle takve pogreške postoje brojne metode i modeli kojima se provodi identifikacija opasnih mjesta.

Sastavni dio svake metode su parametri i kriteriji koje je potrebno odrediti prije same identifikacije opasnog mjesta. Najvažniji kriteriji koji se koriste u gotovo svim metodama su: vremenski period promatranja nastanka prometnih nesreća, broj prometnih nesreća i duljina promatrane dionice.

Tema ovog diplomskog rada je „Komparativna analiza metoda segmentiranja cestovnih dionica pri identifikaciji opasnih mjesta“. Svrha rada je napraviti komparativnu analizu između metode podjele dionice na fiksne dijelove i *Sliding window* metode prilikom identifikacije opasnih mjesta na državnoj cesti D7.

Diplomski rad sastoji se od 7 radnih teza:

1. Uvod

2. Opasna mjesta u cestovnom prometu

3. Parametri kod identifikacije opasnih mjesta

4. Metode segmentiranja ceste pri identifikaciji opasnih mjesta

5. Statističko ispitivanje opasnosti lokacija prometnih nesreća

6. Komparativna analiza dobivenih rezultata

7. Zaključak

U drugom poglavlju je definirano što je opasno mjesto te su navedene i objašnjene neke od metoda identifikacije opasnih mjesta. Nadalje, objašnjena je metodologija identifikacije opasnih mjesta i njezine faze. Navedeni su i ukratko objašnjeni sustavi upravljanja opasnim mjestima te su spomenute i opisane tri vrste pristupa identifikaciji opasnih mjesta.

U trećem poglavlju opisani su parametri potrebni za postupak identifikacije opasnih mjesta. Najvažniji parametri su: vremenski period promatranja, duljina promatrane dionice i broj prometnih nesreća. Neizostavan kriterij svake složenije metode identifikacije je kriterij broj vozila koji se odnosi na prometno opterećenje (PGDP). Također neke metode u obzir uzimaju i parametar ozbiljnosti prometnih nesreća.

U četvrtom poglavlju detaljno su opisane metode segmentiranja ceste pri identifikaciji opasnih mjesta. Dvije metode koje su službeno propisane za korištenje kod identifikacije opasnih mjesta u Republici Hrvatskoj su: metoda podjele dionice na fiksne dijelove i *Sliding window* metoda. U ovom poglavlju opisana je i metoda grupiranja prometnih nesreća.

U petom poglavlju definirani su parametri potrebni u postupku identifikacije opasnih mjesta, odabrana je i opisana državna prometnica D7 na kojoj je obavljen postupak identifikacije te su navedeni dobiveni podaci.

Šestom poglavlju napravljena je komparativna analiza dobivenih podataka. Analiza je napravljena na temelju dobivenih podataka o identifikaciji potencijalno opasnih mjesta te korištenjem slikovnog prikaza na dof (digitalnoj ortofoto) karti.

2. Opasna mjesta u cestovnom prometu

Opasno mjesto u cestovnom prometu predstavlja mjesto na cesti ili dijelu ceste na kojoj se događa natprosječan broj prometnih nesreća. Budući da pojam opasno mjesto nije zakonski reguliran pojam, kao u pojedinim zemljama, postoji i više različitih izvedenica tog pojma. U domaćoj literaturi takva mjesta nazivaju se i opasna cestovna lokacija ili „crne točke“ cestovnog prometa. Domaći autori različito interpretiraju pojam opasnih mjesta pa tako pojedini autori definiraju opasno mjesto kao dijelove ceste na kojima se događa veći broj prometnih nesreća, s ljudskim žrtvama i većom materijalnom štetom, dok drugi autori navode da su opasne cestovne lokacije ili „crne točke“ mjesta na cesti na kojima je rizik od prometnih nesreća (statistički) značajno veći nego na drugim cestovnim lokacijama. [1]

2.1. Metode identifikacije opasnih mjesta u cestovnoj prometnoj mreži

Način identificiranja opasnih mjesta u međunarodnom smislu nije standardiziran. Svaka država može odrediti neku svoju metodu odnosno model ili prihvatiti neke opće prihvaćene međunarodne metode. U međunarodnoj znanstveno – stručnoj literaturi opće su prihvaćene tri vrste definicija opasnih mjesta, a koje se mogu poistovjetiti i sa metodologijama identifikacije opasnih mjesta [2]:

- brojčane definicije;
- statističke definicije i
- definicije temeljene na predviđanju prometnih nesreća.

Sve tri definicije prikazuju načine identifikacije opasnih mjesta koje se mogu promatrati kronološki kao stupnjevi identifikacije opasnih mjesta jer su većine drugih zemalja kretala od najjednostavnije brojčane definicije/metode da bi nakon provedene sanacije većine identificiranih opasnih mjesta prešle na statističke definicije/metode te u konačnici implementirale određene metode predviđanja opasnih mjesta. [2]

Jednostavnije metode se baziraju na statističkim podacima o gomilanju prometnih nesreća u određenom vremenskom periodu, dok one kompleksnije uzimaju u obzir podatke o prometnom opterećenju, vrsti prometnih nesreća, njihovim posljedicama i sl.[2]

Svaka metoda identifikacije podrazumijeva i definirane kriterije na temelju kojih će se određena lokacija klasificirati kao opasna lokacija. Osnovni kriteriji koji se uzimaju u obzir su [2]:

- kritična razina broja prometnih nesreća koja određenu lokaciju definira kao opasnu;
- vremenski period u kojem se promatra nastanak prometnih nesreća i
- duljina dionice u kojoj se promatra nastanak prometnih nesreća.

Navedeni kriteriji se uzimaju u obzir kod jednostavnijih metoda identifikacije dok one složenije metode koriste i druge podatke poput prosječnog godišnjeg dnevnog prometa (PGDP), širine kolnika, broja prometnih traka i sl. [2]

Kriteriji određuju osjetljivost metode na identifikaciju opasnog mjesta pa će tako u slučaju postavljanja niže vrijednosti kritične razine broja prometnih nesreća, identifikacija rezultirati većim brojem opasnih mjesta. Ista stvar je i u obrnutom procesu, ako se postavi viša vrijednost kritične razine, broj opasnih mjesta će biti manji. Upravo iz tog razloga je nužno definirati metodu koja će djelovati dinamički na način da opasna mjesta identificira isključivo na temelju broja prometnih nesreća i prometnog opterećenja promatrane ceste neovisno o drugim prometnicama i njihovim karakteristikama. Takvim pristupom omogućuje se individualna identifikacija dijelova prometne mreže na temelju koje kritična razina broja prometnih nesreća nije ista za sve prometnice, već se ona mijenja ovisno o broju prometnih nesreća i prometnom opterećenju. [2]

2.1.1. Brojčane definicije opasnih mjesta

Brojčane definicije predstavljaju najjednostavniji oblik identifikacije opasnih mjesta u kojem se definira fiksni kriterij broja prometnih nesreća koji, ukoliko se premaši, identificira određenu lokaciju kao opasno mjesto. Primjer takve definicije je nekadašnja Norveška metodologija koja glasi: Opasno mjesto je bilo koja lokacija maksimalne dužine od 100 metara na kojoj su zabilježene barem četiri nesreće s ozlijeđenim osobama u periodu od pet godina. Ovakva jednostavna definicija ne uzima u obzir prometno opterećenje niti specificira tip same lokacije. Primjer definicije prema stopi prometnih nesreća jest: „Opasno mjesto je bilo koja lokacija, raskrižje, dionica ili zavoj, gdje broj nesreća s ozlijeđenima, na milijun vozila ili kilometar vozila, u periodu od četiri godine, prelazi vrijednost od primjerice 1.5“. Nedostatak ove

metode/definicije je što, osim u slučajevima izračuna stope prometnih nesreća, ne uzima u obzir prometno opterećenje lokacije te statistički kroz kritičnu razinu nastanka broja prometnih nesreća ne uspoređuje promatranu lokaciju sa drugim lokacijama istih prometno – tehničkih karakteristika. Također, nedostatak ove metode prilikom izračuna stope prometnih nesreća je što pretpostavlja linearan odnos između prometnog opterećenja i broja prometnih nesreća, iako je odnos nelinearan te što je pristrana prema dionicama manje duljine i s manjim prometnim opterećenjem. [2]

2.1.2. Statističke definicije opasnih mjesta

Statistička definicija opasnih mjesta oslanja se na usporedbu registriranog i uobičajenog broja nesreća. Na primjer, određena lokacija će biti klasificirana kao opasno mjesto ako je registrirani broj prometnih nesreća veći od kritične razine broja prometnih nesreća. Kritična vrijednost nastanka prometnih nesreća dobiva se statističkim ispitivanjem svake lokacije u usporedbi s drugom lokacijom sličnih karakteristika, a opasno mjesto se identificira ukoliko stopa prometnih nesreća, koja uzima u obzir prometno opterećenje, duljinu lokacije i vremenski period, prelazi definiranu kritičnu razinu. [2]

Statistički podaci o prometnim nesrećama osnovni su parametar bez kojeg nije moguće provesti ni najjednostavniju metodu identifikacije opasnih mjesta. Prema istraživanjima uspostavljeno je da se prometne nesreće u prometnoj mreži događaju prema Poissonovoj distribuciji. Upravo na toj distribuciji temelji se i većina statističkih metoda identifikacije opasnih mjesta. [2]

U svrhu povećanja sigurnosti i smanjenja broja prometnih nesreća Republika Hrvatska je zamijenila prijašnju brojčanu metodu identifikacije opasnih mjesta i prihvatila metodologiju identifikacije koja se temelji na statističkoj metodi. Nova metoda omogućuje efikasniju provedbu identifikacije opasnih mjesta, koja će uvelike pomoći u otkrivanju odnosno identificiranju novih opasnih mjesta.

2.1.2.1. Metoda učestalosti prometnih nesreća

Metoda učestalosti prometnih nesreća predstavlja najjednostavniji oblik identifikacije opasnih mjesta. Na temelju broja prometnih nesreća na određenoj lokaciji ili dionici određuje se parametar učestalosti prometnih nesreća u određenom vremenskom periodu. Učestalost prometnih nesreća izračunava se prema izrazu (1):

$$C_f = \frac{N_c}{t} \quad (1)$$

Gdje je:

C_f – Učestalost prometnih nesreća

N_c – ukupan broj prometnih nesreća

t – vremenski period u godinama

Rezultati dobiveni na temelju izraza (1) se rangiraju po svojim vrijednostima, te se lokacija s najvišom vrijednosti identificira kao najopasnije mjesto. Prednost ove metode je njena jednostavnost izračuna te vrlo mali broj podataka potreban za njenu provedbu. Nedostaci ove metode su što se ne uzima u obzir težina nesreća, duljina promatrane dionice te prometno opterećenje na promatranoj lokaciji. Zbog navedenih nedostataka, metoda je pristrana prema lokacijama s većim prometnim opterećenjem i većom duljinom jer ih u slučaju istog broja prometnih nesreća u odnosu na manju dionicu ili dionicu s manjim prometnim opterećenjem, identificira kao jednako opasne. Zbog bitnih nedostataka metoda ne prikazuje dobre rezultate, već može dati samo orijentacijske podatke koje je potrebno dodatno analizirati primjenom drugih podataka poput prometnog opterećenja i sl. [2]

Metoda se preporuča za korištenja na dionicama ili raskrižjima gdje su slični uvjeti i promet je manjeg kapaciteta. [3]

2.1.2.2. Metoda stope prometnih nesreća

Metoda stope prometnih nesreća predstavlja unaprjeđenu metodu učestalosti prometnih nesreća jer u svom izračunu uzima u obzir prometno opterećenje te duljinu promatrane dionice. Za uspješnu provedbu identifikacije opasnih mjesta pomoću ove metode, potrebni su podaci o [2]:

- broju prometnih nesreća;
- duljini promatrane dionice;
- prometnom opterećenju i
- vremenskom periodu.

Stopa prometnih nesreća može se definirati kao omjer između broja prometnih nesreća i mjere izloženosti na promatranom području. U analizama razine sigurnosti i rizika, kao mjera izloženosti, najčešće se primjenjuje prometno opterećenje pri čemu se na raskrižjima razmatra zbroj vozila koja ulaze na križanje, dok se na ostalim dijelovima ceste (dionicama) razmatra zbroj vozila koja prolaze kroz promatrani poprečni presjek u oba smjera u promatranom razdoblju pri čemu je potrebno uzeti u obzir i duljinu promatrane dionice ceste. [1]

Stopa prometnih nesreća računa se pomoću izraza (2):

$$C_r = \frac{N_C}{Q_L} \tag{2}$$

Gdje je:

C_R – stopa prometnih nesreća

N_C - ukupan broj prometnih nesreća

Q_L – prometno opterećenje na promatranoj lokaciji/dionici

Prometno opterećenje na promatranoj dionici/lokaciji računa se prema izrazu (3):

$$Q_L = \frac{Q \cdot t \cdot 365 \cdot l}{1.000000} \tag{3}$$

Gdje je:

Q – PGDP

t – vremenski period u godinama

L – duljina promatrane dionice [km]

Ukoliko se stopa prometnih nesreća računa za raskrižja, onda se pri izračunu prosječne količine prometa u jednoj godini na promatranoj lokaciji, koristi formula (4):

$$Q_L = \frac{Q \cdot t \cdot 365}{1.000000} \tag{4}$$

Stope prometnih nesreća definirane na ovaj način izražavaju se u milijun vozilo-km.

Prednosti ove metode su, kao i kod metode učestalosti prometnih nesreća, jednostavnost i mali broj potrebnih podataka, ali i uzimanje u obzir prometnog opterećenja promatrane lokacije. Nedostaci su što pretpostavlja linearan odnos između prometnog opterećenja i broja prometnih nesreća, iako je odnos nelinearan, te što je pristrana prema dionicama manje duljine i s manjim prometnim opterećenjem. [2] Također još jedan od nedostataka je što ne uzima u obzir slučajne fluktuacije (zanemaruje slučajnost nastanka) broja prometnih nesreća prilikom izračuna stope prometnih nesreća. [4]

Ova metoda koristila se u velikom broju prometnih agencija, istraživača i tvrtki zaduženih za analiziranje prometne sigurnosti. Ishod ove metode još se uvijek odnosi na povijesne podatke, pa je korištenje ove metode u budućnosti često osporavano. [16]

U provedenom međunarodnom istraživanju [16] gdje su uspoređene neke od identifikacijskih metoda (metoda učestalosti prometnih nesreća, stope prometnih nesreća i Empirijska Bayes metoda), metoda stope prometnih nesreća daje najlošije rezultate u usporedbi s ostale dvije metode. Autor navodi da je to zabrinjavajuće jer mnoge institucije i istraživači koriste ovu metodu u identifikaciji opasnih mjesta.

2.1.2.3. Metoda Rate Quality Control

Rate Quality Control (RQC) jedna je od pouzdanijih metoda identifikacije opasnih mjesta koju koriste mnoge institucije u svijetu koje se bave problematikom opasnih mjesta. Pokazuje visoku točnost jer je bazirana direktno na statističkom testiranju opasnosti svake lokacije u usporedbi s drugom lokacijom sličnih karakteristika. Statističko ispitivanje svake lokacije temelji se na pretpostavci da su prometne nesreće rijetki događaji čija se vjerojatnost pojavljivanja može aproksimirati prema Poissonovoj distribuciji.

Identifikacija opasnih mjesta pomoću *Rate Quality Control* metode provodi se na način da se na temelju broja prometnih nesreća te prometnog opterećenja na promatranoj lokaciji odredi kritična razina nastanka prometnih nesreća. Ukoliko stopa prometnih nesreća prelazi kritičnu razinu definiranu ovom metodom, smatra se da se prometne nesreće, statistički, ne događaju slučajno, već se radi o identificiranom opasnom mjestu [2].

Kritična razina broja prometnih nesreća računa se prema izrazu (5):

$$C_{CR} = C_{RA} + k \cdot \sqrt{\frac{C_{RA}}{Q_L}} + \frac{1}{2 \cdot Q_L} \quad (5)$$

Gdje je:

C_{CR} – kritična razina prometnih nesreća

C_{RA} – prosječna vrijednost stope prometnih nesreća

k – koeficijent razine povjerenja

Q_L – prometno opterećenje na promatranoj lokaciji/dionici

Tablica 1. Razine povjerenja k

Razina povjerenja	k
90%	1,282
95%	1,645
99%	2,323

Koeficijent razine povjerenja se u većini slučajeva uzima 1,96 što odgovara 95% razini povjerenja. Prednosti ove metode su to što uzima najvažnije podatke potrebne za identifikaciju opasnih mjesta, smanjuje eventualni veliki utjecaj lokacija s malim prometnim opterećenjem, uzima u obzir odstupanja u statističkim podacima te prikazuje jasnu usporedbu između identificiranih i neidentificiranih lokacija. Također, prednost metode je i to što uzima u obzir duljinu lokacije na kojoj se događaju prometne nesreće pa se može koristiti i za identifikaciju opasnih dionica. Nedostatak metode je taj što ne prikazuje utjecaj lokacije na opće stanje sigurnosti, ali to je ionako zaseban dio drugih sustava upravljanja opasnim mjestima koji se mogu nadomjestiti drugim procesima. [2]

2.1.3. Metode na temelju predviđanja

Definicije na temelju predviđanja obuhvaćaju razne modele predviđanja nastanka prometnih nesreća. Ovakvi modeli zahtijevaju velike količine podataka o karakteristikama lokacija koje se promatraju te se na temelju očekivanog broja nesreća pokušavaju identificirati opasna mjesta. Trenutno najpouzdanija metoda

predviđanja opasnih mjesta je Empirijska Bayes metoda, koja zahtjeva veliku količinu podataka koje moraju biti u potpunosti točni jer jedino na taj način omogućavaju zadovoljavajuću točnost predviđanja opasnih mjesta. [2]

Prema istraživanjima [4], [5] i [6] gdje je napravljena komparativna analiza različitih metoda identifikacije rezultati ispitivanja ističu da je Empirijska Bayes metoda najdosljednija i najpouzdanija metoda za identificiranje prioritetnih opasnih mjesta koje je potrebno istražiti kroz dodatnu analizu.

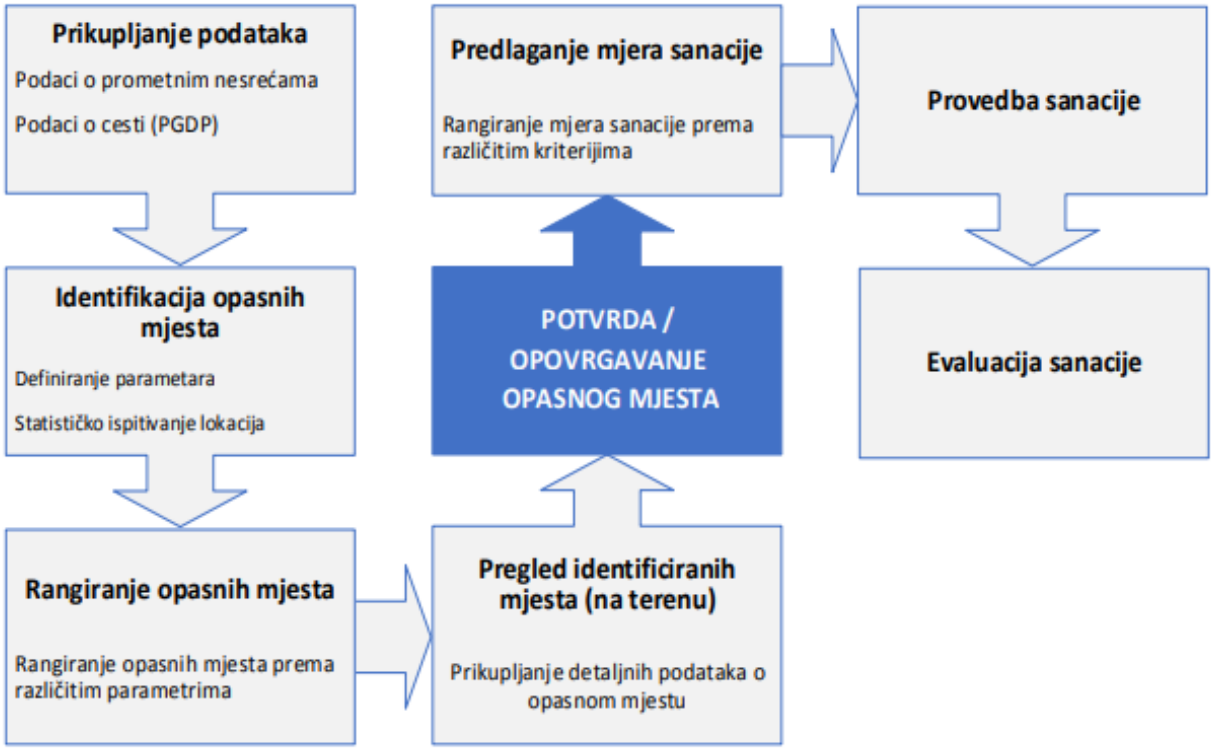
Empirijska Bayes metoda se u novijim istraživanjima [18] koja su usmjerena u smjeru pronalaska novih metoda i modela identifikacije opasnih mjesta koristi kao relevantna metoda za ocjenjivanje učinkovitosti eksperimentalne metode.

2.2. Metodologija identifikacije opasnih mjesta

Identifikacija i sanacija opasnih mjesta predstavlja jedan od najučinkovitijih načina povećanja sigurnosti cestovnog prometa. U Republici Hrvatskoj (RH) trenutno se primjenjuje metodologija koja je usklađena sa zakonskim regulativama, smjernicama i preporukama Europske unije. Cilj metodologije je prije svega identificirati opasna mjesta na kojima je uzrok nastanka prometnih nesreća bio nedostatak na prometno – tehničkim karakteristikama ceste. Da bi se obavila identifikacija opasnih mjesta u RH službena metoda koja se koristi je *Rate Quality Control* (RQC) metoda. Detaljno je opisana u poglavlju 2.1.2.

Metodologija za identifikaciju opasnih mjesta u cestovnoj prometnoj mreži omogućuje identifikaciju i rangiranje opasnih mjesta na način da ima dinamički postavljene kriterije koji djeluju ovisno o stanju sigurnosti i opterećenosti promatrane ceste. Time je omogućeno statističko ispitivanje svake lokacije na kojoj se dogodila bar jedna prometna nesreća u odnosu na duljinu ceste, ukupan broj prometnih nesreća i prometno opterećenje. Ovakvim procesom opasna mjesta se rangiraju s obzirom na kritičnu razinu nastanka prometnih nesreće čime se omogućuje bolji uvid u stanje na terenu te se lakše donosi odluka o prioritetima pri pregledu opasnih mjesta. Učinci nove metodologije, između ostalog, trebaju otkloniti dvojbe, prije svega utječe li cesta na nastale prometne nesreće i trebamo i/ili možemo li to mjesto smatrati opasnim te na njemu provesti mjere sanacije. [15]

Proces identifikacije opasnih mjesta obavlja se u više faza. Budući da ne postoje standardne metode identifikacije primjenjive za sve zemlje, svaka država može preraspodijeliti proces identifikacije i razviti svoj model uvažavajući prikazane korake identifikacije.



Slika 1. Proces upravljanja opasnim mjestima

Izvor: [1]

2.2.1. Prikupljanje podataka o prometnim nesrećama

Prva faza upravljanja opasnim mjestima započinje sustavnim prikupljanjem podataka na temelju kojih se mogu identificirati lokacije opasnih mjesta. Prometne nesreće koje su se dogodile na određenoj lokaciji analiziraju se kako bi se utvrdili uzroci prometnih nesreća, isto kao i čimbenici koji su pridonijeli nastanku prometne nesreće.

Cilj detaljne analize prometnih nesreća je identificirati uzroke koji su pridonijeli nastanku prometne nesreće i spriječiti da se takve prometne nesreće ne događaju u budućnosti. U slučaju da se ne provodi detaljna analiza prometne nesreće, neće se moći utvrditi opasno mjesto na dionici ceste, a samim time se ne će moći provesti sanacije toga dijela dionice ceste.

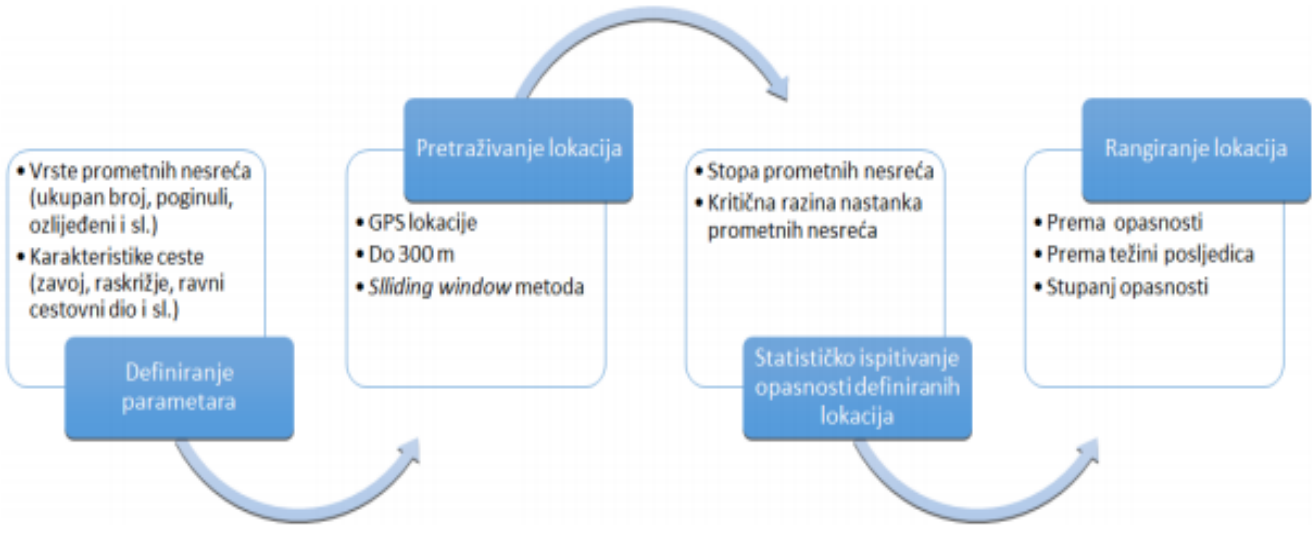
Osim podataka o prometnim nesrećama, za uspješnu identifikaciju opasnih mjesta nužno je poznavati i podatke o prosječnom godišnjem dnevnom prometu na promatranoj lokaciji (PGDP), a u slučaju identifikacije opasnih mjesta samo u ljetnim periodima potrebno je poznavati i podatak o prosječnom ljetnom dnevnom prometu (PLDP). Nadalje, za detaljnu analizu opasnih mjesta potrebno je prikupljati i ostale podatke o karakteristikama cesta, ali i ostalih čimbenika sigurnosti prometa na cestama (sudionici, vozilo).

U Republici Hrvatskoj podatke o prometnim nesrećama prikuplja Ministarstvo unutarnjih poslova koje ih onda ustupa drugim institucijama pa tako i upraviteljima cesta na njihov zahtjev u svrhu identifikacije opasnih mjesta. [1]

2.2.2. Identifikacija opasnih mjesta

Druga faza predstavlja identifikaciju opasnih mjesta. Ova faza sastoji se od definiranja parametara potrebnih za obavljanje procesa identifikacije opasnih mjesta (navedeni i detaljno objašnjeni u 3. poglavlju) i statističkog ispitivanja lokacije objašnjenog u poglavlju 2.1.2.

Identifikacija opasnih mjesta u cestovnom prometu započinje sa određivanjem lokacije sa natprosječnim brojem prometnih nesreća. Proces i način ovog izračuna prikazani su kroz pet koraka (slika 2).



Slika 2. Proces provedbe identifikacije opasnog mjesta

Izvor: [1]

U prvom koraku potrebno je definirati na temelju kojih parametara će se identificirati opasna mjesta (objašnjeno u poglavlju 3.).

. U drugom koraku sukladno definiranim parametrima, izdvoje se tražene lokacije prometnih nesreća. Ukoliko se koristi metoda segmentiranja dionice na fiksne dijelove, potrebno je dodatno analizirati svaku granicu između dva susjedna segmenta te u slučaju postojanja lokacija prometnih nesreća ispred ili iza pojedinog segmenta potrebno ih je također pridružiti primarnom segmentu, ali opet do maksimalnih 1000 m. Ukoliko se identifikacija vrši na raskrižjima, u obzir se uzima i zona oko raskrižja/križanja. Zona raskrižja/križanja je određena na osnovi prometne signalizacije koja upozorava na raskrižje/križanje, a ako nema signalizacije onda se koristi vrijednost do 20 m od sljedeće točke sjecišta rubova cesta koje se međusobno križaju. Isto se odnosi i na druge elemente ceste poput tunela, zavoja i sl.

Treći korak odnosi se na statističko ispitivanje opasnosti svake lokacije na kojoj su se događale prometne nesreće prema zadanim parametrima. Statističko ispitivanje podrazumijeva definiranje stope prometnih nesreća na svakoj lokaciji promatrane ceste gdje su se dogodile prometne nesreće. Stopa prometnih nesreća izračunava se prema jednadžbi 2.

Slijedeći korak statističkog ispitivanja podrazumijeva izračun kritične razine nastanka prometnih nesreća za svaku lokaciju na temelju prosječne stope prometnih nesreća svih lokacija. Izračunava se prema izrazu 5. Ukoliko stopa prometnih nesreća prelazi kritičnu razinu definiranu ovom metodom, smatra se da se prometne nesreće, statistički, ne događaju slučajno, već se radi o potencijalnom opasnom mjestu. U slučaju da stopa prometnih nesreća ne prelazi kritičnu razinu, lokacija statistički nije potencijalno opasno mjesto.

U petom koraku identificirana potencijalna opasna mjesta se rangiraju prema omjeru između stope prometnih nesreća i kritične razine nastanka prometne nesreće. Potencijalna opasna mjesta se rangiraju od najveće razlike omjera prema najmanjoj pa će tako lokacija s najvećim omjerom razlike identificirati kao potencijalno najopasnije mjesto dok će se lokacija s najmanjim omjerom razlike identificirati kao najmanje opasno u odnosu na druga opasna mjesta.[1]

2.2.3. Analiza i rangiranje opasnih mjesta

Analiza prometnih nesreća te identificiranih lokacija potencijalno opasnih mjesta mora omogućiti rangiranje, ali i provjeru lokacije na način da se utvrdi je li identificirano opasno mjesto uistinu opasno ili se radi o tzv. lažnom opasnom mjestu. Stoga se analiza lokacija opasnih mjesta provodi u dvije faze.

Prva faza sastoji se od detaljnih statističkih procjena, po potrebi izrada kolizijskih dijagrama te sveobuhvatnih dubinskih analiza na temelju kojih se provodi rangiranje lokacija. Osnovna značajka ove analize je da se ne provodi na terenu već se sukladno definiranim parametrima rangiraju opasna mjesta. Neke vrste rangiranja su [1]:

- Rangiranje prema broju prometnih nesreća,
- Rangiranje prema posljedicama prometnih nesreća,
- Rangiranje prema učestalost prometnih nesreća,
- Rangiranje prema gustoći prometnih nesreća,
- Rangiranje prema stopi prometnih nesreća na križanjima,
- Rangiranje prema stopi prometnih nesreća na ravnim dionicama ceste,
- Rangiranje prema relativnom stupnju opasnosti i
- Rangiranje prema troškovima prometnih nesreća

U drugoj fazi se identificirana i prioritetna opasna mjesta analiziraju na terenu, tj. na samoj lokaciji opasnog mjesta. Ova vrsta analize, uključuje provjeru svih elemenata ceste sukladno donesenim zaključcima u prvoj fazi analize te se na licu mjesta razmatraju mogući pravci sanacije opasnog mjesta.

2.2.4. Pregled identificiranih potencijalno opasnih mjesta na terenu

Nakon procesa provođenja identifikacije opasnih mjesta, lokacije prometnih nesreća se na temelju rangiranja analiziraju na samom terenu. Osnovni cilj ovog pregleda je utvrditi jesu li prometne nesreće na promatranoj lokaciji uzrokovane prometno – tehničkim nedostacima ceste te koje prometno - tehničke zahvate poduzeti da bi se otklonile opasnosti koje uzrokuju nastanak prometnih nesreća. U tu svrhu potrebno je prikupiti informacije o [1]:

- kvaliteti prometnih znakova, opravdanost postavljanja i njihovoj vidljivosti;

- kvaliteti oznaka na cesti te njihovoj korelaciji sa prometnim znakovima;
- kvaliteti kolničkog zastora i vrijednosti koeficijenta trenja;
- preglednosti ceste te utjecaju eventualnih prepreka na vozača;
- utjecaj okolne infrastrukture i okoliša na vidljivost vozača i
- adekvatnosti ograničenja brzine u odnosu na mogućnosti ceste.

Opis cestovne dionice mora sadržavati detaljne informacije o lokaciji od kojih se manji dio prikuplja iz izvještaja o registriranim nesrećama a drugi dio na temelju pregleda lokacije. Osnovni podaci o lokaciji stoga moraju omogućiti potvrđivanje ili opovrgavanje teze da je promatrana lokacija uistinu opasno mjesto. Neke od informacija koje moraju sadržavati su: osnovni podaci o lokaciji (pozicioniranje lokacije, vrsta regulacije prometa, ograničenje, struktura prometa, prosječna brzina, prometno opterećenje), geometrijske karakteristike ceste (vrsta raskrižja, radijus zavoja, duljina preglednosti, poprečni i uzdužni nagib, širina ceste i broj traka), prometna signalizacija (stanje vertikalne i horizontalne signalizacije, vrsta regulacije prometa), površina kolnika (koeficijent trenja, stanje i vrsta kolničkog zastora), rasvjeta (osvjetljenje ceste) i fotografska te video dokumentacija. [1]

2.2.5. Potvrđivanje opasnog mjesta

Na temelju provedenog statističkog ispitivanja, identifikacije i pregleda opasnog mjesta, donosi se konačna odluka je li potencijalno mjesto uistinu opasno ili se radi o tzv. lažnom opasnom mjestu. Ukoliko je utvrđen određeni nedostatak ceste ili njene infrastrukture koji je uzrokovao nastanak prometnih nesreća ili je doprinio težim posljedicama prometnih nesreća, identificirano opasno mjesto se potvrđuje kao stvarno opasno mjesto te se pristupa slijedećoj fazi upravljanja opasnim mjestima.

Ako se prilikom pregleda lokacija prometnih nesreća sa sigurnošću utvrdi da nema prometno – tehničkih nedostataka na cesti koji uzrokuju nastanak prometnih nesreća smatra se da to, sa stajališta upravitelja ceste, nije opasno mjesto već se uzroci nastanka prometnih nesreća moraju otklanjati preventivno – represivnim metodama drugih nadležnih institucija. [1]

2.2.6. Ostali postupci u procesu identifikacije opasnih mjesta

Predlaganje mjera za sanaciju identificiranog opasnog mjesta podrazumijeva skup aktivnosti, zadataka i mjera koje se moraju poduzeti da bi se saniralo opasno mjesto. S obzirom na identificiran uzrok nastanka nesreća predlažu se odgovarajuće

mjere za sanaciju. Na primjer u slučaju skliskog kolnika mogu se predložiti mjere ohrapljivanja površinskog sloja, nanošenje novog kolničkog zastora. U slučaju prekomjernog izlijetanja iz zavoja provjera poprečnog nagiba kolnika, postavljanja zaštitnih ograda, postavljanje svjetlosnih znakova itd.

Poslije sanacije opasnog mjesta potrebno je provesti analizu koliko je sanacija opasnog mjesta utjecala na smanjenje broja prometnih nesreća. Osnovni indikator uspješnosti provedene sanacije je promjena učestalosti nastanka prometnih nesreća, tj. usporedba broja prometnih nesreća prije i poslije sanacije. Praćenje učinkovitosti mjera za smanjivanje broja prometnih nesreća može se provoditi na dva načina [1]:

- za šire područje gdje se poduzima više različitih mjera (npr. više lokacija unutar jedne županije) i
- za pojedinu poduzetu mjeru na jednoj lokaciji.

Praćenje učinka sanacije važnoj je iz tri osnovna razloga [1]:

1. Osiguranje brze i efikasne izmjene sanacije ukoliko je izvedena sanacija pogoršala stanje sigurnosti u prometu.
2. Utvrđivanje broja izbjegnutih prometnih nesreća i učinkovitost provedene sanacije.
3. Ekonomski izračun postignutih ušteda s sanacijom opasnog mjesta te usporedba istih s troškom sanacije.

2.3. Sustavi upravljanja opasnim mjestima

Sustavi upravljanja i određivanja opasnih mjesta obuhvaćaju detaljnu analizu svakog identificiranog opasnog mjesta kao i njegov utjecaj na sigurnost cestovnog prometa na tom području. Najpoznatiji sustavi upravljanja opasnim mjestima su *Black spot management* (BSM) ili *Network safety management* (NSM) koji objedinjuju proces identifikacije i upravljanja opasnim mjestima na cestovnim prometnicama. Navedeni nazivi imaju isti cilj, identificirati i upravljati opasnim mjestima u cestovnom prometu, no unatoč istom cilju različiti je pristup. [2]

Cilj *Network safety management* sustava je identificirati duže dionice ceste na kojima se događaju prometne nesreće dok *Black spot sustav* identificira samo konkretne lokacije učestalih prometnih nesreća, poput raskrižja. Također, *Network safety management* sustav obuhvaća dublju analizu ozbiljnosti prometnih nesreća na

promatranoj dionici te posebno analizira posljedice tih prometnih nesreća i dovodi ih u korelaciju s uzrokom prometnih nesreća. Također ovi sustavi imaju mogućnost međusobnog kombiniranja u radu, čime se omogućuje prikaz relevantnog stanja na određenoj dionici promatrane ceste. [2]

Obje metode prate isti princip. Prvo se cestovna mreža segmentira na dijelove. Glavni razdjelnici su cestovna čvorišta odnosno raskrižja, ali na većoj cestovnoj mreži to bi predstavljalo prilično duge dionice, pa se često koristi najveća dopuštena udaljenost za segmentaciju. Neke zemlje koriste *Sliding window* metodu koja je složenija, ali daje bolje rezultate. Duljina promatranog dijela odnosno segmenta kod BSM metode je oko 500 metara, dok se kod NSM metode ta udaljenost kreće i do 10 kilometara. [7]

NSM se može smatrati kao izvedenica iz BSM. Često se koristi u Francuskoj i Njemačkoj kod autocesta i ostalih brzi cesta. Razlika NSM od BSM je u tome što NSM u proračun uzima prosječan ili očekivani broj prometnih nesreća i prilikom rangiranja uspoređuje dionice (segmentirane dijelove) međusobno i pronalazi one s najvećom razlikom te označava tu dionicu kao opasnu odnosno kao veliki potencijal za poboljšanje sigurnosti na promatranoj mreži. [7]

Autor u radu [2] navodi tri moguće kombinacije *Black spot management* (BSM) i *Network safety management* (NSM) sustava:

- nezavisni – sustavi su međusobno nezavisni te se rezultati jednog sustava ne uzimaju u obzir kod drugog sustava;
- djelomično zavisni – sustavi se uspoređuju jedino kada se njihovi rezultati preklapaju na određenoj dionici ceste i
- potpuno zavisni – analizira se koliko rezultati jednog sustava utječu na drugi sustav.

Najjednostavniji oblik je proces nezavisne identifikacije gdje se zasebno identificiraju opasna mjesta i opasne dionice ceste. Međutim, na taj način postoji problem da se na identificiranoj lokaciji opasnog mjesta automatski identificira cijela dionica ceste kao opasna, što ne mora nužno biti točno. U takvim slučajevima potrebno je provesti djelomičnu ili potpuno zavisnu identifikaciju da bi se izbjegle takve mogućnosti. Prema tome potrebno je da se utvrđena opasna mjesta, koja su

identificirana na raskrižjima ili križanjima izdvojeno promatraju u odnosu na dionicu ceste gdje se nalaze jer se na taj način dobivaju relevantniji rezultati. [2]

Prilikom implementacije sustava upravljanja opasnim mjestom preporučljivo je prvo implementirati BSM sustav koji je jednostavniji te da se nakon nekoliko godina i uspješnog saniranja svih opasnih mjesta primijeni NSM sustav samo za održavanje potrebne sigurnosti. Također moguće je umjesto primjene NSM sustava nadograditi odnosno nadopuniti postojeći sustav BSM sustavom NSM.

2.4. Vrste pristupa identificiranju opasnih mjesta

Postoje tri vrste pristup identifikaciji opasnih mjesta, a to su [8]:

1. Tradicionalni pristup koji se temelji samo na prometnim nesreća, što rezultira identifikacijom opasnih mjesta,
2. Empirijska Bayesova metoda predviđanja nesreća na temelju koje se identificiraju opasna mjesta, tj. realne i potencijalne opasne lokacije i
3. Proaktivna „preliminarna“ inspekcija sigurnosti cestovnog prometa uz prepoznavanje čimbenika rizika koji mogu potencijalno povećati broj nesreća i njihovu ozbiljnost.

Tradicionalni pristup predstavlja metode identifikacije opasnih mjesta koje uzimaju u obzir samo nastale prometne nesreće. *Black spot management* sustav pripada tradicionalnom načinu identifikacije opasnih mjesta. U ovakav pristup pripadaju sve brojčane metode identifikacije, statističke metode (*Metoda učestalosti, Metoda stope* i *Rate Quality Control*) te metode koje uzimaju u obzir broj nastalih nesreća i težine prometnih nesreća. Tradicionalnim pristupom se utvrđuju opasna mjesta tek nakon što se prometne nesreće dogode na određenoj lokaciji ili dionici ceste. Prednost takvog pristupa je jednostavnost procesa identifikacije te manji broj potrebnih podataka kod određivanja opasnog mjesta. Nedostatak je što se nesreće moraju dogoditi da bi se odredila opasna mjesta i analizirale određene lokacije kao opasne te u konačnici pristupilo saniranju opasnog mjesta.

Podaci o nastalim prometnim nesrećama, koje ne uzimaju u obzir slučajnost nastanka prometnih nesreća, mogu dovesti do pogrešnih identifikacija. Identificirana te sanirana mjesta možda nisu najopasnija, a istinske opasne lokacije mogu dalje ostati neidentificirane. Stoga je poželjno pokušati koristiti pristupe koji su statistički

pouzdaniji i omogućuju izradu liste prioriteta cestovnih dionica na kojima se očekuje vrlo učinkovito poboljšanje infrastrukture u svrhu poboljšanja sigurnosti prometa. Za ispunjavanje ovih zahtjeva Empirijski Bayesov pristup preporučeni je modele predviđanja nesreća. Procjene Empirijskog Bayesovog pristupa kombiniraju povijesne podatke o nesrećama s predviđanim nesrećama i na taj način su u stanju identificirati potencijalne opasne lokacije na cestama, gdje se još nije dogodila prometna nesreća. Takav proces omogućava kombinaciju proaktivnog i reaktivnog pristupa.

Inspekcije za provjeru sigurnosti na cestama definirane su kao „uobičajena periodična provjera značajki i nedostataka na cesti koji zahtijevaju poduzimanje radnji vezanih uz održavanje radi povećanja sigurnosti“. Ovakav pristup predstavlja preventivni (proaktivni) alat koji se temelji na subjektivnoj procjeni relevantnih stručnjaka za sigurnost. [8]

Proaktivni pristup temelji se na podacima prikupljenim vozilom koji je opremljen raznim uređajima za prikupljanje podataka i kamerama za snimanje cestovne dionice koja je predviđena za analizu. Tijekom vožnje kroz proučenu mrežu, revizor sigurnosti prometa evidentira prisutnost čimbenika rizika koji mogu potencijalno povećati broj nesreća i njihovu ozbiljnost. Na temelju tih procjena, prema stupnju ozbiljnosti rizika dodjeljuju se bodovi svakom faktoru rizika. Za svaki segment, faktori ozbiljnosti rizika zbrajaju se i množe s PGDP (prosječni godišnji dnevni promet). Ukoliko svaki segment nije jednake duljine rezultat se dijeli s duljinom segmenta. Za učinkovito korištenje indeksa rizika postupak mora zadovoljiti dva cilja [8]:

- mora dati sigurnosnu procjenu povezano s nastalim nesrećama
- mora rangirati dionice ili segmente ceste prema veličini opasnosti nastanka prometne nesreće.

Glavna prednost proaktivnog pristupa je vršenje analize dionice i otkrivanje opasnih elemenata na prometnicama koji mogu dovesti do prometnih nesreća ili povećanja ozbiljnosti nesreće. Omogućava saniranje opasnog mjesta i prije nego što je opasno mjesto evidentirano od strane tradicionalnog pristupa identifikacije opasnih mjesta. Nedostatak ovakvog pristupa je subjektivni pristup relevantnih stručnjaka u

određivanju opasnosti pojedinih elemenata koji utječu na smanjenje sigurnosti prometa i povećavaju vjerojatnost (rizik) nastanka prometnih nesreća.

U međunarodnom istraživanju [8] napravljena je komparativna analiza sve tri vrste pristupa. Primijenjena je metoda učestalosti prometnih nesreće kao tradicionalni pristupu identifikaciji opasnih mjesta te su dobiveni rezultati prikazali da takav pristup nije pogodan za ceste s malim količinama prometa na kojem je veća disperzija nesreća, dok postupak proaktivnog pristupa na koji ne utječu slučajne varijacije prometnih nesreća i u takvim uvjetima daje dobre rezultate.

Preporuča se postepeni prelazak s tradicionalnog pristupa upravljanja opasnim mjestima na proaktivni pristup upravljanja sigurnosti na cijeloj mreži u većinu europskih zemalja. Primjena Empirijske Bayes metode i indeksa rizika za identificiranje opasnih lokacija može biti prikladna zamjena za tradicionalno upravljanje opasnim mjestima i korak naprijed prema proaktivnom upravljanju sigurnosti na cestovnoj mreži.

2.5. Učinkovitost saniranja opasnih mjesta

Saniranje identificiranih opasnih mjesta glavni je korak u povećanju sigurnosti prometa na cestama. U RH Hrvatske ceste d.o.o. redovito prikupljaju podatke vezane za sigurnost prometa te na temelju stručnih analiza i odgovarajuće metodologije utvrđuju lokacije i/ili dionice državnih cesta s povećanim brojem prometnih nesreća i stradalih osoba.

Prema podacima Hrvatskih cesta u proteklom je razdoblju izvršena sanacija 284 opasna mjesta odnosno izvedeni su građevinski zahvati s novim prometno – tehničkim rješenjima, a za što je utrošeno preko 269 milijuna kuna, uključivši i sredstva osigurana Nacionalnim programom sigurnosti cestovnog prometa Republike Hrvatske. [15]

Najčešće mjere koje su poduzete u sanaciji opasnih mjesta su: izgradnja kružnih tokova, izgradnja dodatnih traka za skretanje, izmjene i dopune prometnih znakova, signalizacije i opreme ceste i poboljšanje karakteristika površine kolnika i geometrijskih karakteristika ceste

Na temelju saniranih opasnih mjesta napravljena je usporedba broja i posljedica prometnih nesreća na saniranim opasnim mjestima tri godine prije i tri

godine nakon sanacije. Uspješnost provedene sanacije pokazuje sljedeće rezultate [15]:

- 75,2% manje prometnih nesreća
- 90,8% manje poginulih osoba
- 74,2% manje teško ozlijeđenih
- 71,9% manje lako povrijeđenih

Navedeni rezultati ukazuju na uspješnost i važnost provedbe identifikacije opasnih mjesta i njihove sanacije u cilju većeg povećanja sigurnosti prometa na cestovnoj prometnoj mreži.

3. Parametri kod identifikacije opasnih mjesta

Prilikom identifikacije opasnih mjesta mogu se koristiti različite metode kao što su: brojčane metoda, metoda učestalosti prometnih nesreća, metoda stope prometnih nesreća, *Rate Quality Control* metoda, Empirijska Bayes metoda ili neke druge metode. Sve prethodno navedene metode koriste određene parametre u procesu identifikacije opasnih mjesta. Stoga je potrebno prije same identifikacije odrediti parametre i kriterije prema kojima će određena lokacija biti identificirana kao opasno mjesto.

Sukladno metodama koje se koriste za identifikaciju i provedenih međunarodnih istraživanja uočeno je da su osnovni kriteriji koje je potrebno definirati prije identifikacije opasnih lokacije sljedeći [2]:

- vremenski period promatranja,
- broj prometnih nesreća i
- duljina promatrane dionice.

Navedeni kriteriji zajednički su za sve metode identifikacije opasnih mjesta, ali se mogu koristiti na različite načine i primjenom različitih postupaka. Osim njih, moguće je uvoditi i druge kriterije ili definirati određene koeficijente kao pokazatelje prometne sigurnosti. [2]

Jednostavnije metode identifikacije opasnih mjesta ne uzimaju u obzir prometno opterećenje odnosno količinu prometa (PGDP) na promatranoj dionici, dok gotovo sve složenije i pouzdanije metode ističu taj parametar kao jedan od ključnih u identifikaciji opasnih mjesta.

Također jedan od važnih parametara u pojedinim metodama je težina (ozbiljnost) prometnih nesreća. Svaka prometna nesreća nema jednake posljedice te se uzimanjem ovog parametra u obzir različite posljedice prometnih nesreća (nesreće s lako ozlijeđenim, teško ozlijeđenim i smrtnim posljedicama) svode na nesreće ekvivalentne samo materijalnoj šteti.

Da bih se uspješno proveo proces identifikacije opasnih mjesta odnosno utvrdila mjesta s natprosječnim brojem nesreća potrebo je da lokacije budu tehnički usporedive to jest da se uspoređuju lokacije sličnih obilježja (homogeni

segmenti/lokacije). To znači da se ceste trebaju razvrstati u skladu s klasifikacijom cesta u RH (autoceste, državne ceste, županijske ceste, lokalne ceste i nerazvrstane ceste). Također potrebno je, ako je to moguće, podijeliti cestu na segmente sličnih karakteristika i uspoređivati međusobno elemente samo istih karakteristika npr. zavoje sa zavojima, raskrižja sa raskrižjima, ravne dijelove sa ravnim dijelovima itd.

3.1. Vremenski period promatranja

Vremenski period promatranja vrlo je važan kriterij koji je potrebno odrediti prije početka procesa identifikacije opasnih mjesta. Sukladno statističkom pravilu koji nalaže da što je veći broj uzoraka u pokusu rezultat je precizniji. Vođeni tim pravilom odnosno prikupljanjem (gomilanjem) velikog broja podataka potrebnih za postupak identifikacije opasnog mjesta podaci bih se prikupljali veliki vremenski period. S ciljem brzog djelovanja, smanjenja broja i vjerojatnosti nastanka prometnih nesreća period promatranja i prikupljanja podataka je značajno smanjen. Zbog toga je bitno kod identifikacije opasnih mjesta odrediti minimalno dovoljno vrijeme promatranja za utvrđivanje i identifikaciju stvarnih opasnih mjesta. U većini strane literature u istraživanjima [5], [9], [10], [11] i [12] vremenski period promatranja kreće se od 3 do 5 godina.

Važan kriterij za stvaranje pouzdane identifikacije cestovne dionice, koja ima statistički značajan stupanj nesreća, je utvrđivanje vremenskog razdoblja u kojem su analize provedene. Pri bilo kojem pokušaju identificiranja, trebalo bi uzeti u obzir sljedeće [2]:

- da bi se izbjegle neravnomjernosti izazvane sezonskim promjenama, važno je da se promatranja vrše nekoliko godina;
- na mjestima gdje su se dogodile iznenadne promjene u stopama nesreća, korisno je analizirati kraći vremenski period u trajanju od jedne godine ili manje, da bi se utvrdili specifični razlozi i mehanizmi koji uzrokuju prometne nesreće;
- razdoblje analize bi trebalo biti dovoljno dugo da bi se utvrdili čimbenici nesreća. Pretpostavlja se da je u većini slučajeva prihvatljiv period od 3-5 godina i
- nakon četiri ili pet godina promatranja broja prometnih nesreća, mogu se dogoditi promjene u karakteristikama opasnih mjesta

(nova infrastruktura, promjene okoliša i sl.) pa je zbog toga, ukoliko je moguće, važno koristiti dva razdoblja analize. Prvi period u trajanju od tri do pet godina, kojim se osigurava pouzdanost uzorka, i drugi period u trajanju od jedne godine, koji omogućuje otkrivanje promjena u broju nesreća izazvanih novim čimbenicima. Takav način koristi autor [10] u svojem istraživanju.

3.2. Broj prometnih nesreća

Broj prometnih nesreća je kriterij koji najviše varira te je usko povezan s parametrom duljine dionice te vremenskim periodom promatranja. Osnovni uvjet kod ovog kriterija je utemeljenost na statističkim podacima te, po mogućnosti, korištenje neke od statističkih metoda da bi kriterij bio relevantan i znanstveno utemeljen. [1]

Preporučljivo je da se broj minimalnih prometnih nesreća za identifikaciju opasnih mjesta definira na temelju očekivanog broja prometnih nesreća, a ne na temelju registriranog broja prometnih nesreća. Kao najuspješniju empirijsku metodu za određivanje očekivanog broja prometnih nesreća navedena je Bayesova metodu. [2]

Postupak identifikacije opasnih mjesta nije standardiziran već svaka zemlja zasebno odlučuje o metodi ili modelu koju će primijeniti u svrhu otklanjanja opasnih mjesta. Stoga su neke zemlje prihvatile prethodno navedenu Bayesovu metodu primjene za određivanje očekivanog broja prometnih nesreća, dok pojedine zemlje su kao minimalan broj prometnih nesreća odredile jednu ili više fiksnih vrijednosti koje se uspoređuju s drugim parametrima poput vremenskog perioda, duljine dionice i sl.

Primjer tako fiksno određenih vrijednosti je prepoznavanje opasnih lokacija koje uzimaju u obzir cestovni segment s produženjem do 200 metara, u kojem je u godini koja se analizira dogodilo najmanje pet prometnih nesreća s ljudskim posljedicama (lakše ozljede, teške ozljede ili smrtno stradale) i gdje je zbroj pokazatelja težine prometnih nesreća jednak ili veći od 20. Također ovi kriteriji se mogu međusobno mijenjati, na primjer uzimanjem manjeg broja nesreća s ljudskim posljedicama ili produljenje cestovnog segmenta promatranja.

Prema međunarodnom istraživanju [9] kod kojeg je korištena *Sliding window* metoda s dužinom pomičnog prozora od 200 metara i fiksno određenim minimalnim

brojem nesreća, kada se minimalni broj nesreća kao kriterij smanjio sa 5 na 4, broj crnih točaka se povećao za 82%. Time se može vidjeti koliko je prepoznavanje opasnih lokacija osjetljivo na promjenu kriterija minimalnog broja prometnih nesreća.

Prema istom istraživanju [9] vidljivo je da se minimalan broj prometnih nesreća ne može standardizirati te da je on ovisan o drugim elementima poput duljine dionice, vremenskog perioda (promjenom bilo kojeg kriterija mijenja se i konačni rezultat). Minimalan broj prometnih nesreća potrebno je promatrati u kontekstu općeg stanja sigurnosti te u komparaciji prometnih nesreća na sličnim lokacijama. [2]

3.3. Duljina promatrane dionice

Osnovni uvjet za analizu kriterija „duljina dionice“ jesu iste značajke cesta koje se uspoređuju. Na primjeru Republike Hrvatske to bi značilo da se ceste prije svega trebaju klasificirati u skladu s razvrstavanjem cesta u RH na: autoceste, državne ceste, županijske ceste, lokalne ceste te nerazvrstane ceste unutar gradova i naselja.[1]

Ceste se mogu promatrati kao cjelokupne dionice ili kao odvojeni segmenti ceste. Predloženo je odvajanje prometnih raskrižja i križanja sličnih karakteristika, ravnih odsječaka cesta, kružnih tokova te ostalih specifičnih dijelova prometne mreže u urbanim sredinama da bi u budućim analizama mogli biti usporedivi sa sličnim lokacijama. [2] U urbanim sredinama, ceste je potrebno dijeliti i prema broju prometnih trakova, također predlaže se i podjela cesta prema srednjim brzinama kretanja vozila. [13]

Kod ruralnih područja, također je potrebno podijeliti cestovne pravce koji se razvrstavaju na ravne dijelove, zavoje sličnih polumjera, mostove, tunele i sl. U ruralnim područjima, podatke o lokaciji nesreće potrebno je bilježiti putem adresa, stacionaža te koordinata u odgovarajućim prozorima za pretraživanje duljina od 50 do 300 m. [1]

U naseljenim sredinama, potrebno je podijeliti cestovne pravce na raskrižja i ravne poteze ceste te, osim podataka o svim karakteristikama ceste, zabilježiti podatke o lokaciji prometnih nesreća putem podataka o adresi ulica (ukoliko je nesreća bila na raskrižju više ulica), ali i koordinatama. [1]

Spajanje s poljskim putovima ili cestama od manjeg značaja mogu se pronaći putem podataka o kilometrima i/ili koordinatama. U naseljenim mjestima točkama raskrižja/križanja pridružuju se one nesreće koje se događaju do 20 m prije raskrižja. Na otvorenoj cesti važno je provjeriti nije li područje utjecaja raskrižja veće. Na raskrižjima izvan razine (RiR) uzimaju se u obzir sve prometne nesreće koje su se dogodile i na ulaznim/izlaznim rampama. [1]

Prema provedenom istraživanju [9] provedena je identifikacija opasnih mjesta gdje je uzeta u obzir parametrizacija (promjena dužine segmenata) u svrhu ustanovljenja razlike u broju identificiranih crnih točaka. Kada se dužina segmenta povećala s 200 na 300 metara broj crnih točaka povećao se za 55%, a kada se duljina poveća sa 200 na 400 metara broj crnih točaka se udvostruči (104%). Kada se duljina segmenta povećala sa 300 na 400 metara broj crnih točaka povećao se za 32%. Čime se zaključuje da je identifikacija opasnih mjesta veoma osjetljiva na promjenu duljine segmenata u procesu identifikacije.

Koncentraciju prometnih nesreća te identifikaciju opasnih mjesta na određenoj duljini promatrane dionice moguće je promatrati na tri načina:

a) segmentiranjem dionice na fiksne dijelove određene dužine, unutar kojih se identificiraju opasna mjesta,
b) segmentiranje dionice metodom „*Sliding window*“ i
c) segmentiranje dionice ili cestovne mreže na temeljem grupiranja prometnih nesreća.

Metode segmentiranja, njihove karakteristike i načini korištenja detaljno su opisani u poglavlju 4.

3.4. Broj vozila

Razvojem metoda za identificiranje opasnih mjesta od prvotnih brojčanih metoda te metoda učestalosti prometnih nesreća ustanovljeno je da određene lokacije odnosno dionice ceste sa sličnim karakteristikama koje se međusobnu uspoređuju imaju jednak broj nastalih prometnih nesreća kod različite količine prometa te su obje lokacije identificirane kao opasno mjesto ne uzimajući u obzir različitu izloženost prometnom opterećenju. Tom spoznajom zaključeno je da je

potrebno prilikom identifikacije opasnih mjesta uzeti u obzir i količinu prometa na promatranom odsječku ceste, dionici ili pojedinom segmentu.

Danas gotovo sve razvijenije zemlje (Danska, Norveška, Švicarska, Portugal, Italija, Mađarska) koriste modele identifikacije opasnih mjesta koje u svojoj formuli uzimaju u obzir količinu prometa odnosno prometno opterećenje na promatranoj dionici. Prometno opterećenje jedan je od najvažnijih kriterija ukoliko se želi koristiti napredniji sustav određivanja opasnih mjesta poput BSM ili NSM sustava identifikacije opasnih lokacija. [2]

U Republici Hrvatskoj se prometno opterećenje na cestama prikuplja pomoću tri načina, a to je [14]:

- neprekidno automatsko brojenje brojilima instaliranim na državnim, županijskim i lokalnim cestama (putem kamera ili induktivnih petlji)
- povremeno automatsko brojenje brojilima u pravilu na državnim cestama (prijenosna brojila)
- naplatno brojenje na autocestama, drugim cestovnim građevinama s naplatom prolaska vozila.

Podatke o prometnom opterećenju prikuplja, obrađuje i javno objavljuju *Hrvatske ceste d.o.o.* koje su zadužene za upravljanje, građenje i održavanje državnih cesta. Podaci su objavljeni u obliku tablica za svaki pojedini brojač i u obliku grafičkog prikaza na karti za pojedinu dionicu državne ceste. Obrađeni podaci se definiraju u obliku „Prosječnog godišnjeg dnevnog prometa“ (PGDP) prema izrazu (6).

$$PGDP = \frac{Q_{god}}{365}\left(\frac{voz}{danu}\right) \tag{6}$$

3.5. Težine (ozbiljnost) prometnih nesreća

Budući da sve prometne nesreće nisu jednake, nesreće s teškim ozljedama i smrtno stradalim osobama za društvo puno su skuplje nego nesreće sa samo materijalnom štetom. Troškovi prometnih nesreća u društvu uključuju medicinsku skrb, hitne službe, produktivnost tržišta, produktivnost domaćinstava, osiguranja,

troškove radnog mjesta, pravne troškove i imovinsku štetu, sve to predstavlja kumulativne troškove koje društvo snosi kada je osoba ozlijeđena ili poginula u prometnoj nesreći.

Postoje metode koje kao jedan od glavnih parametra kod identifikacije opasnog mjesta koriste težine prometnih nesreća koje su se dogodile. Prema težini prometnih nesreća, nesreće se dijele na:

- nesreće s materijalnom štetom,
- nesreće s lako ozlijeđenima,
- nesreće s teško ozlijeđenima i
- nesreće sa smrtno stradalim osobama.

Primjer takve metode može biti: „Opasno mjesto je bilo koja lokacija odnosno cestovni segment dužine do 200 metara, u kojem se u godini (koja se analizira) dogodilo najmanje pet prometnih nesreća s ljudskim posljedicama (lakše ozljede, teške ozljede ili smrtno stradale) i gdje ponderirani broj težine nesreća jednak je ili veći od 20“. U ovoj metodi parametar težine prometne nesreće jedan je od tri ključna u identifikaciji opasnog mjesta, a dobije se ponderiranjem prometnih nesreća različitih posljedica, tako da se sve nesreće svedu na nesreće s materijalnom štetom. Jednadžba (7) je primjer takvog ponderiranja.

$$PBTN = 3 \cdot Lo + 10 \cdot To + Po \cdot 100 \quad (7)$$

gdje je:

PBTN – ponderirani broj težine prometnih nesreća

Lo – broj prometnih nesreća s lakše ozlijeđenima

To – broj prometnih nesreća s teže ozlijeđenima

Po - broj prometnih nesreća s poginulim osobama

4. Metode segmentiranja ceste pri identifikaciji opasnih mjesta

Proces identifikacije opasnih lokacija na cestovnoj prometnoj mreži podrazumijeva podjelu određene promatrane prometnice na manje dijelove unutar kojih se zatim promatraju nastale nesreće. Kao što je prethodno već opisano minimalni broj nesreća, potrebnih da bi se lokacija označila kao „crna točka“, može se odrediti na više načina te se na temelju definiranih granica određuje je li određeno mjesto (lokacija) opasna ili nije. Takvo dijeljenje određene promatrane prometnice ili dionice ceste na manje dijelove naziva se segmentiranje.

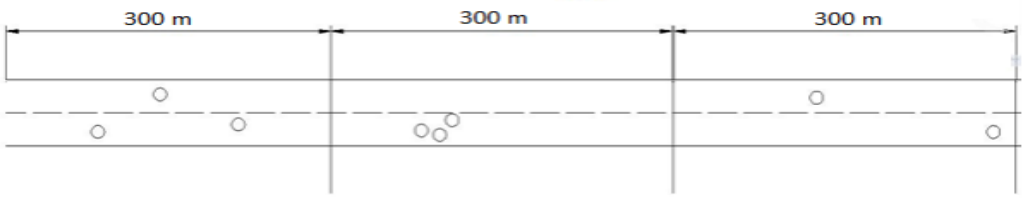
Dvije najpoznatije metode segmentiranja koje propisuje *„Metodologiji za identifikaciju opasnih mjesta u cestovnoj prometnoj mreži“* kao službeni dokument na temelju kojeg se određuju „crne točke“ u Republici Hrvatskoj su [1]:

1) segmentiranje dionice na fiksne dijelove određene dužine, unutar kojih se identificiraju opasna mjesta i
2) segmentiranje dionice metodom „*Sliding window*“.

Osim navedene dvije službene metode koje se koriste za identifikaciju opasnih mjesta u RH postoji i metoda koja se temelji na grupiranju prometnih nesreća na promatranoj prometnici ili cestovnoj mreži.

4.1. Segmentiranje dionice na fiksne dijelove

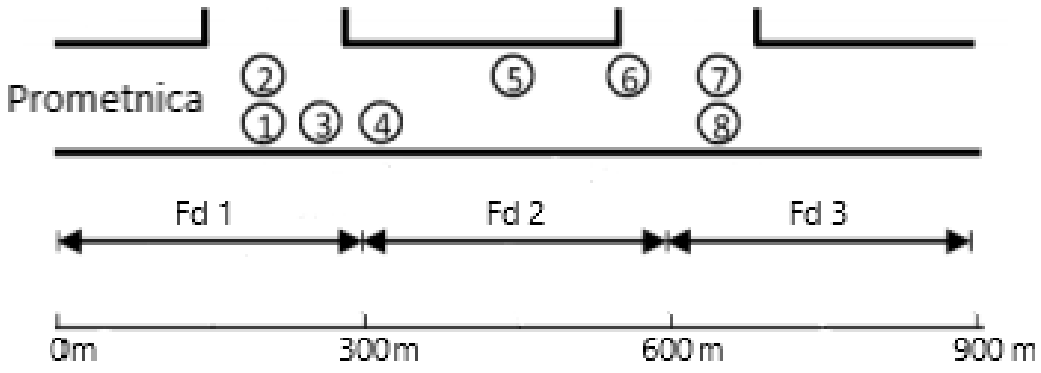
Segmentiranje dionice na fiksne dijelove određene dužine podrazumijeva dijeljenje promatrane dionice na fiksne dijelove, dužine, npr., 1 [km], koji su postavljeni jedan iza drugog. Na taj će način, npr. dionica od 10 [km], biti podijeljena u 10 dionica od jednog kilometra dužine. [2] Primjer podjele dionice na fiksne dijelove prikazan je na slici 3.



Slika 3. Prikaz segmentacije dionice na fiksne dijelove

Izvor: [1]

Na slici 4. prikazan je nedostatak prilikom identifikacije opasnih mjesta korištenjem metode podjele dionice na fiksne dijelove. Dijeljenjem određene dionice ceste na fiksne dijelove dolazi do problema kada je u blizini raskrižje iz razloga što je moguće da unaprijed definirana fiksna duljina ne može obuhvatiti cijelo područje raskrižja te samim time ne omogućava kvalitetnu identifikaciju opasnog mjesta. Na primjer da je određeno da za identifikaciju opasnog mjesta potrebno identificirati 3 nesreće u promatranom okviru. Podjelom na fiksne dijelove mogu se otkriti dva opasna mjesta: prvo, prozor (Fd 1) detektira opasno mjesto, ali ne uzimajući u obzir nesreću br. 4 koja se dogodila na istom križanju. Da je kojim slučajem za identifikaciju bilo potrebno 4 prometne nesreće u jednom okviru, ovo mjesto (križanje) ne bih bilo identificirano kao opasno mjesto (a trebalo bih biti). Prateći posljednji fiksni prozor (Fd 3) na istoj dionici ceste može se otkriti još jedan nedostatak što fiksni prozor nije uspio otkriti drugo stvarno opasno mjesto (nesreće br. 6,7,8), fiksni prozor započinje od kraja drugog kritičnog prozora gdje identificira samo dvije nesreće (7,8) koje ne zadovoljavaju kriterij identifikacije opasnog mjesta. Iz tog razloga je prilikom identifikacije opasnih mjesta koristeći metodu podjele na fiksne dijelove potrebno područja raskrižja promatrati zasebno i međusobno ih uspoređivati sa drugim raskrižjima sličnih karakteristika.



Slika 4. Problem identifikacije opasnog mjesta koristeći metodu podjele na fiksne dijelove

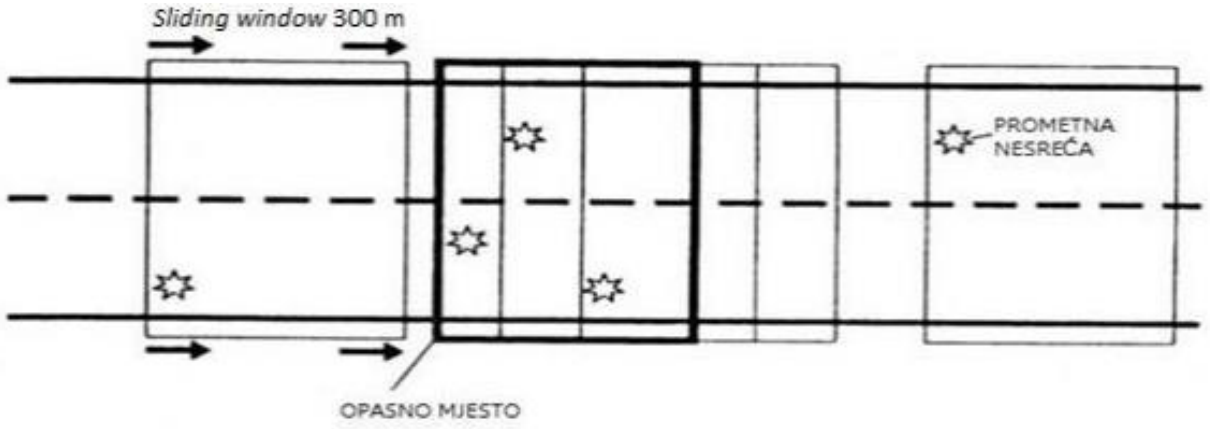
Izvor: [11]

Prema provedenom međunarodnom istraživanju [11] ova metoda je najučinkovitija na cestama velikih dopuštenih brzina kao što su brza cesta i autocesta, gdje je raspršenost prometnih nesreća velika. Tako se korištenjem fiksnih

prozora većih dužina (do 10 kilometara) mogu obuhvatiti dionice ceste s većim udjelom prometnih nesreća.

4.2. Segmentiranje dionice metodom *Sliding window*

Segmentiranje dionice metodom „*Sliding window*“ podrazumijeva da će se na promatranoj dionici odrediti okvir određene dužine koji će grupirati dionice, u rasponu svog okvira, na kojima postoji koncentracija prometnih nesreća. Važno je naglasiti da „*Sliding window*“ metoda ne uzima u obzir lokacije bez prometnih nesreća, već lokacije sa minimalno jednom prometnom nesrećom. [1]



Slika 5. Prikaz segmentiranja dionice metodom *Sliding window*

Izvor: [1]

Sliding window metoda koristi se u sljedećim europskim državama: Austrija, Danska, Portugal, Mađarska, Norveška, Slovenija te Belgija. U radovima [2] i [11] navodi se da ova metoda nije u potpunosti relevantna za korištenje budući da uvijek ima tendenciju grupiranja što većeg broja prometnih nesreća čime povećava broj opasnih mjesta zbog čega postoji opasnost od identificiranja tzv. lažnih opasnih mjesta.

U općoj metodologiji *Sliding window* metoda zahtijeva od korisnika da unese duljinu prozora i kritični broj nesreća po mjestu (tj. stopa učestalost nesreća itd.) zatim se klizni prozor pomiče po cijeloj cestovnoj mreži kako bi prepoznao segmente koji zadovoljavaju navedene kriterije. Kada se ispune kriteriji identificirano je opasno mjesto. Potraga za drugim opasnim mjestom nastavlja se sa sljedećeg segmenta bez preklapanja. [11]

Ako se u blizini identificiranih opasnih mjesta nalaze druga opasna mjesta u okviru definiranog prozora za promatranje, ona se uključuju u identifikaciju, što znači da se kod preklapanja prozora za promatranje čitavo područje smatra područjem jednog opasnog mjesta. [1]

Uvažavajući navedene preporuke te na temelju međunarodnih iskustava za identifikaciju opasnih mjesta u Republici Hrvatskoj potrebno je koristiti „Sliding window“ metodu na način da se oko svake lokacije prometne nesreće definira okvir u radijusu od 300 metara. Ako ispred ili iza okvira postoji još koja lokacija prometnih nesreća, okvir se može produžiti do maksimalnih 1000 m kako bi se i te lokacije pridodale primarno definiranom opasnom mjestu. [1]

4.3. Segmentacija cestovne mreže temeljena na grupiranja prometnih nesreća

Korištenjem prethodno navedenih metoda segmentiranja cestovne dionice koje se koriste kod identifikacije opasnih lokacija, duljina segmenata ima značajan utjecaj u određivanju stvarnih opasnih mjesta nesreće. Da bi se riješio problem identificiranja stvarne duljine opasnih mjesta razvijene su različite tehnike grupiranja.

Metoda grupiranja općenito je namijenjena organiziranju velikog skupa podataka (prometnih nesreća) u mali broj homogenih skupina u kojima je stupanj povezanosti između objekata (prometnih nesreća iste skupine maksimalan. [16]

Ova metoda segmentacije cestovne mreže temelji se na grupiranju prometnih nesreća. Ona omogućava klasifikaciju nesreća i drugih podatka vezanih uz cestu u homogene skupine na temelju prostorne međuovisnosti nesreća, prometnih karakteristika i geometrijskih atributa cestovne mreže. [10]

Ako se uzme u obzir osnovni cilj identificiranja opasnih mjesta prometnih nesreća, a to je pronaći točku ili dio na cesti gdje se događa veći broj prometnih nesreća, upotreba tehnika grupiranja (klastera) može biti korisnija za smanjenje duljine područja proučavanja opasnih mjesta otkrivanjem točnog mjesta prostorno locirani nesreća. [11]

Prema međunarodnim istraživanjima [3], [10] i [11] metode identificiranja opasnih mjesta koje se temelje na tehnici grupiranje najučinkovitije su na gradskim prometnicama, posebno na križanjima, gdje je mala raspršenost prometnih nesreća.

Takve metode mogu se koristiti pomoću GIS (Geografski informacijski sustav) alata koji omogućuje upravljanje prostornim podacima i pridruženim im osobinama (atributima). GIS može precizno izdvojiti udaljenost između točaka nesreće pomoću funkcije prostorne analize, nadmašujući time nedostatak podataka o nesreći.

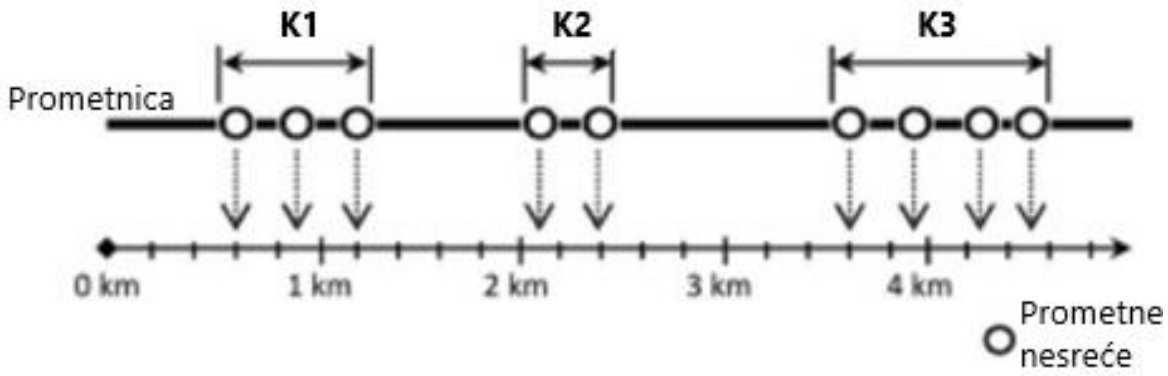
Također primjenom metode grupiranja potrebno je postaviti parametre za duljinu, broj prometnih nesreća te period za koji će se uzeti u obzir nastale nesreće. Nakon toga se postavljaju vrijednosti navedenih parametra u algoritam klasteriranja koji se obično koristi kod identifikacije crnih točaka tj. opasnih mjesta.

Postupak segmentacije nesreća na manje grupe (klastere) opisan je u šest koraka [16]:

1. Lokalizacija prometnih nesreća na temelju GIS koordinata.
2. Pretvaranje geografski označenih cesta u linearno usmjerene jednodimenzionalne linije.
3. Lociranje prometnih nesreća duž označene jednodimenzionalne linije koja predstavlja prometnicu u cestovnoj mreži.
4. Mjerenje i bilježenje udaljenosti prometnih nesreća koristeći određeni algoritam (najčešće korišteni „*K-means* algoritam“).
5. Identificiranje optimalnog broja klastera.
6. Primjena algoritma za definiranje skupina nesreća.

Na duljinu svakog klastera može utjecati broj prometnih nesreća koje klaster sadrži i njihova prostorna raspodjela.

U cilju pojednostavljenja korištenja ove metode moguće je položaj nesreća u algoritmu grupiranja prikazati kao linearni referentni model. Linearno referenciranje koristi se u pronalaženju prometnih nesreća na cijeloj dužini krivulje gledano od počete referentne točke. Na takvom modelu cesta je predstavljena kao jednodimenzionalna linija s nultom početnom točkom. Na ovaj način se omogućava izbjegavanje klasificiranja nesreća u isti klaster koje su blizu smještene, ali su se dogodile na različitim cestama. [16]



Slika 6. Prikaz pojednostavljene metode grupiranja

Izvor: [16]

4.4. Usporedba metoda segmentiranja ceste pri identifikaciji opasnih mjesta

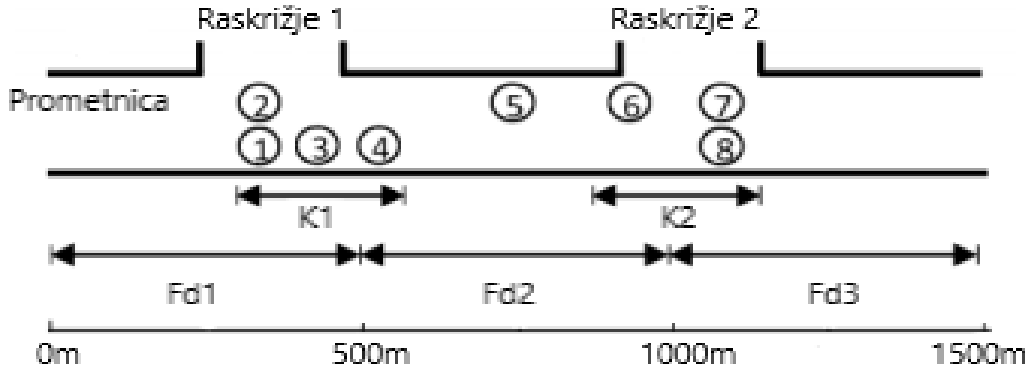
Napretkom i razvojem metoda za identifikaciju opasnih mjesta razvijale su se i metode segmentiranja ceste, a sve u svrhu preciznijeg pronalazaka lokacija na kojima se događa iznad prosječni broj nesreća. Najjednostavnija metoda je podjela dionice promatrane prometnice na fiksne dijelove, zatim dolazi složenija, popularna i dokazana *Sliding window* metoda. Naposljetku je razvijena nova metoda grupiranja prometnih nesreća u grupe odnosno klastere na promatranoj prometnoj mreži. Zajedničko je svim metoda da se koriste za promatranje nastalih prometnih nesreća prilikom identifikacije opasnih mjesta na određenoj prostornoj udaljenosti. No sve tri navedene metode se uvelike razlikuju. U tablici 1. su navedene prednosti i nedostaci pojedine metode te područje na kojem je njihova primjena najučinkovitija.

Tablica 2. Prednosti i nedostaci pojedine metode segmentiranja ceste pri identifikaciji opasnih mjesta

Metode segmentiranja	Prednosti	Nedostaci	Područje primjene
Podjela dionice na fiksne dijelove	-mogućnost korištenja duljina do 10 km -mogućnost pokrivanja raspršenih prometnih nesreća -jednostavnost korištenja	- uzima u obzir sve segmente dionice - raskrižja na dionici potrebno je promatrati zasebno - opasnim mjestom je označen cijeli segment	- metoda je najprikladnija za korištenje na cestama velikih brzina (brza cesta i autocesta)
***Sliding window* metoda**	-uzima u obzir samo segmente na kojima se dogodila jedna ili više prometnih nesreća - preciznija od metode podjele na fiksne dijelove - mogućnost obuhvaćanja cijelog područja raskrižja na dionici	- tendencija grupiranja što većeg broja prom. nesreća (opasnost od identificiranja lažnih opasnih mjesta) - cijelo područje promatranog prozora smatra se opasnim - složenija od metode podjele na fiksne dijelove	- najprikladnija za primjenu u urbanim sredinama (zbog preporučene male duljine prozora)
Metoda grupiranja	-minimiziranje lažnih negativnih i lažnih pozitivnih opasnih mjesta - ne uzima u obzir mjesta bez prometnih nesreća - duljina klastera jednaka je duljini stvarnog opasnog mjesta - raskrižja i ostale dijelove prometnice nije potrebno promatrati zasebno	- korištenje geografskih koordinata ponekad predstavlja problem (nesreća koje se nisu dogodile na istoj prometnici stavlja u isti klaster) - potrebno unaprijed odrediti broj klastera - složenija primjena (provodi se pomoću algoritma)	- metoda je najučinkovitija na gradskim prometnicama (gdje je mala raspršenost nesreća), posebno na raskrižjima

Prema provedenom međunarodnom istraživanju [16] gdje su uspoređene dvije od tri ovdje navedene metode segmentacije korištenjem više identifikacijskih metoda, metoda grupiranja se pokazala kao bolja metoda u identifikaciji opasnih mjesta za razliku od metode podjele na fiksne dijelove.

Slika 7 prikazuje razliku između metode podjele na fiksne dijelove i metode grupiranja (klasteriranja) prometnih nesreća prilikom identifikacije opasnih mjesta. Prikazana je dionica urbane prometnice, gdje su brojevima označene prometne nesreće, K1 i K2 označavaj dva klastera koja identificiraju opasna mjesta, a Fd1, Fd2 i Fd3 označavaju fiksne dijelove promatrane dionice. Na slici se može primijetiti kako je za određivanje opasnog mjesta korištenjem metode grupiranja nesreća potrebna manja duljina čime se postiže veća preciznost prilikom identifikacije mjesta, a time i smanjuje prostor za daljnju detaljnu analizu identificiranog opasnog mjesta. Metoda grupiranja nesreća omogućava identificiranje svih nesreća koje se nalaze u međusobnoj blizini te na taj način omogućuje identifikaciju opasnog mjesta kada se uspostavi da broj nesreća u klasteru prelazi prethodno definirani prag za identifikaciju opasnog mjesta definiran u algoritmu. Na slici se može vidjeti kako je metoda grupiranja precizno označila opasno mjesto na raskrižju 1 (K1) dok metoda podjele na fiksne dijelove (Fd1) nije obuhvatila nesreću broj 4 koja se nalazi u istom raskrižju te je također i razlika u duljini identificiranog opasnog mjesta velika. Također vidljivo je da je metoda grupiranja na raskrižju 2 (K2) prepoznala opasno mjesto, dok podjelom na fiksne dijelove opasno mjesto nije identificirano.



Slika 7. Usporedba metode grupiranja i metode podjele na fiksne dijelove

Izvor: [11]

S obzirom na prethodnu usporedbu može se vidjeti kako je metoda grupiranja prometnih nesreća znatno prikladnija za korištenje u urbanoj prometnoj mreži od metode podjele na fiksne dijelove.

U istraživanju [17] autori su usporedili također dvije segmentacijske metode, a to su *Sliding window* metoda i metoda grupiranja. Navode kako su obje metode visoko učinkovite u otkrivanju opasnih mjesta te kao zajedničku prednost ističu mogućnost korištenja jednodimenzionalnog i dvodimenzionalnog modela u procesu identifikacije. Jednodimenzionalni model predstavlja jednostavniji model u kojem je prometnica definirana kao jednodimenzionalna linija, a prometne nesreće kao točke na toj liniji. Ističu kako je takav model primjenjiv u slučaju kadu su prometne nesreće zadane stacionažom ceste ili nazivima ulica i kućnim brojevima. Dvodimenzionalni model predstavlja složeniji i napredniji model u kojem je potrebno definirati širinu i dužinu okvira kod korištenja *Sliding window* metode. Ovakav model zahtijeva korištenje GPS koordinata što povećava točnost i preciznost prilikom identifikacije opasnih mjesta. Primjena takvog modela naročito je bitna u urbanim sredinama sa velikim brojem raskrižja.

Također u istom istraživanju [17] autori navode i razlike između ove dvije metode. Ističu kako Sliding widnow metoda može identificirati opasno mjesto samo u obliku linije (korištenjem jednodimenzionalnog modela) ili pravokutnika (korištenjem dvodimenzionalnog model), dok kod metode grupiranja oblik identificiranog mjesta nije određen već se on formira prilikom procesa identifikacije ovisno o prostornim lokacijama prometnih nesreća, tj. omogućena je identifikacija s nepravilnim oblicima. Nadalje autori navode prednost *Sliding window* metode u odnosu na metodu grupiranja u manjem broju parametara i lakšoj interpretaciji gotovih rezultata.

5. Statističko ispitivanje opasnosti lokacija prometnih nesreća

Statističko ispitivanje opasnih lokacija izvršeno je u skladu sa službenom metodologijom u Republici Hrvatskoj. Identifikacija je provedena koristeći metodu *Rate Quality Control* (RQC). Prema dosadašnjim istraživanjima ova metoda prikazuje iznimno dobre rezultate u otkrivanju opasnih mjesta. RQC metoda detaljnije je opisana u poglavlju 2.1.2.3.

Kao što je ranije u radu navedeno prema službenoj metodologiji za identifikaciju opasnih mjesta u RH mogu se koristiti dvije metode segmentiranja odabrane prometnice na manje dijelove, a to su: metoda podjele dionice na fiksne dijelove i *Sliding window* metoda te je stoga u ovom radu identifikacija provedena koristeći obje službene metode u svrhu analize i komparacije dobivenih rezultata, dok metoda grupiranja nije provedena i korištena u analizi iz razloga što nije adekvatna za primjenu na cestama izvan naselja već je prikladnija za korištenje u urbanim područjima gdje je raspršenost prometnih nesreća manja.

5.1. Definiranje parametara

Za potrebe identifikacije opasnih mjesta potrebno je odrediti određene parametre i kriterije koji su opisani u 3. poglavlju. Svakako najvažniji parametri bez koji se ne može obaviti identifikacija opasnih mjesta su: broj prometnih nesreća, duljina promatrane dionice, vremenski period promatranja i broj vozila.

Podacima o broju prometnih nesreća i broju vozila (PGDP) na prometnicama u Republici Hrvatskoj raspolaže tvrtka Hrvatske ceste d.o.o. Podaci o broju prometnih nesreća, karakteristikama te točnim lokacijama nisu javno dostupni.

Dobiveni službeni podaci o prometnim nesrećama na državnoj cesti D7 sadrže sljedeće podatke:

- regija u kojoj se cesta nalazi,
- naziv ceste i oznaka,
- dionica ceste,
- stacionaža prometne nesreće na dionici,
- stacionaža prometne nesreće na cesti,
- datum nesreća,

- vrsta nesreća,
- posljedice prometnih nesreća,
- karakteristika dijela ceste na kojem se nesreća dogodila,
- stanje površine kolnika,
- okolnosti pod kojima se nesreća dogodila,
- broj vozila koja su sudjelovala u prometnoj nesreći,
- ukupan broj sudionika koji su sudjelovali u prometnoj nesreći,
- broj sudionika poginulih u nesreći,
- broj sudionika teško ozlijeđenih u nesreći,
- broj sudionika lako ozlijeđenih u nesreći i
- broj sudionika bez ozljeda.

Prilikom obavljanja procesa identifikacije opasnih mjesta koristeći obje metode segmentacije ceste nisu korišteni svi prethodno navedeni podaci o pojedinoj nesreći, već su korišteni podaci o točnoj lokaciji prometnih nesreća, tj. stacionaži prometnih nesreća na pojedinoj dionici i stacionaži prometnih nesreća na ukupnoj duljini prometnice.

Za razliku od podataka o prometnim nesrećama koji nisu javno objavljeni i dostupni, podaci o broju vozila odnosno prometnom opterećenju (PGDP) svake se godine objavljuju i javno su dostupni pod naslovom „Brojenje prometa na cestama Republike Hrvatske“. Sukladno prethodno navedenom podaci o broju vozila (PGDP) za određene dijelove cestovne prometnice su preuzeti iz prethodno navedene publikacije o brojanju prometa za 2018. godinu.

Korištenjem prethodno navedenih javno objavljenih podataka o broju prometa državnoj cesti D7 evidentirano je sedam neprekidnih automatskih brojača prometa i jedan povremeni automatski brojač prometa. U tablici 3 prikazi su brojevi brojačkih mjesta, prometno opterećenje i stacionaža ceste za koju vrijedi prikazano prometno opterećenje.

Tablica 3. Tablični prikaz prometnog opterećenja na državnoj cesti D7

Broj brojačkog mjesta	PGDP	Stacionaža ceste (km)
2501	1445	0 -16,2
2503	6369	16,2 - 21,9
2505	4983	21,9 - 32,8
2513	9525	32,8 - 44,4
2512	7153	44,4 - 56,4
3705	4796	56,4 - 82,9
3606	3701	82,9 - 100,65
3615	2623	100,65 - 115,2

U skladu s objašnjenim periodom promatranja u poglavlju 3.1., preporučeni periodi promatranja kreću se od 3-5 godina. Period od tri godine može se koristiti kao relevantan u identifikaciji opasnih mjesta te je taj period ujedno i najčešće korišteni u međunarodnim istraživanjima na slične teme radova. Sukladno prethodno navedenom u ovom diplomskom radu koristit će se period promatranja od tri uzastopne godine od 2016. do 2018. U navedenom razdoblju analizirane su sve prometne nesreće za koje su poznati potrebni podaci.

U ovom diplomskom radu posebnu pozornost potrebno je obratiti na parametar duljine promatrane dionice odnosno načini segmentiranja promatrane prometnice. S obzirom na svrhu rada, a koja je komparativna analiza rezultata segmentacijskih metoda. U ovom radu prilikom identifikacije opasnih mjesta koristit će se dvije segmentacijske metode: metoda podjele dionice na fiksne dijelove i *Sliding window* metoda. Spomenute metode navedene su kao službene metode u metodologiji za identifikaciju opasnih mjesta koja se primjenjuje u Republici Hrvatskoj (RH).

Metoda podjele dionice na fiksne dijelove primijenit će se na prometnici D7 koristeći konstantne duljine od 500 m. U istraživačkom radu [11] je spomenuto da preporučena duljina prema HSM (engl. Highway Safety Manual) 0,3 milje što je ekvivalentno 483 metara.

Sliding window metoda primijenit će se sukladno metodologiji za identifikaciju opasnih mjesta koja se primjenjuje u RH. Preporučena duljina okvira prozora je 300

m. Duljina pomicanja okvira po prometnici određena je individualno od strane istraživača i iznosit će jednu trećinu okvira odnosno 100 metara.

5.2. Geoprometni položaj državne ceste D7

D7 je državna cesta koja se nalazi na istoku Republike Hrvatske. Pruža se od graničnog prijelaza (GP) Duboševica kod Mađarske, preko Belog Manastira, Osijeka i Đakova do graničnog prijelaza Slavonski Šamac gdje se prometnica dalje nastavlja u Bosnu i Hercegovinu. Ukupna duljina prometnice je 115,2 km. Na slici 7 sivom bojom prikazan je položaj i pružanje državne ceste D7.



Slika 8. Prikaz državne ceste D7

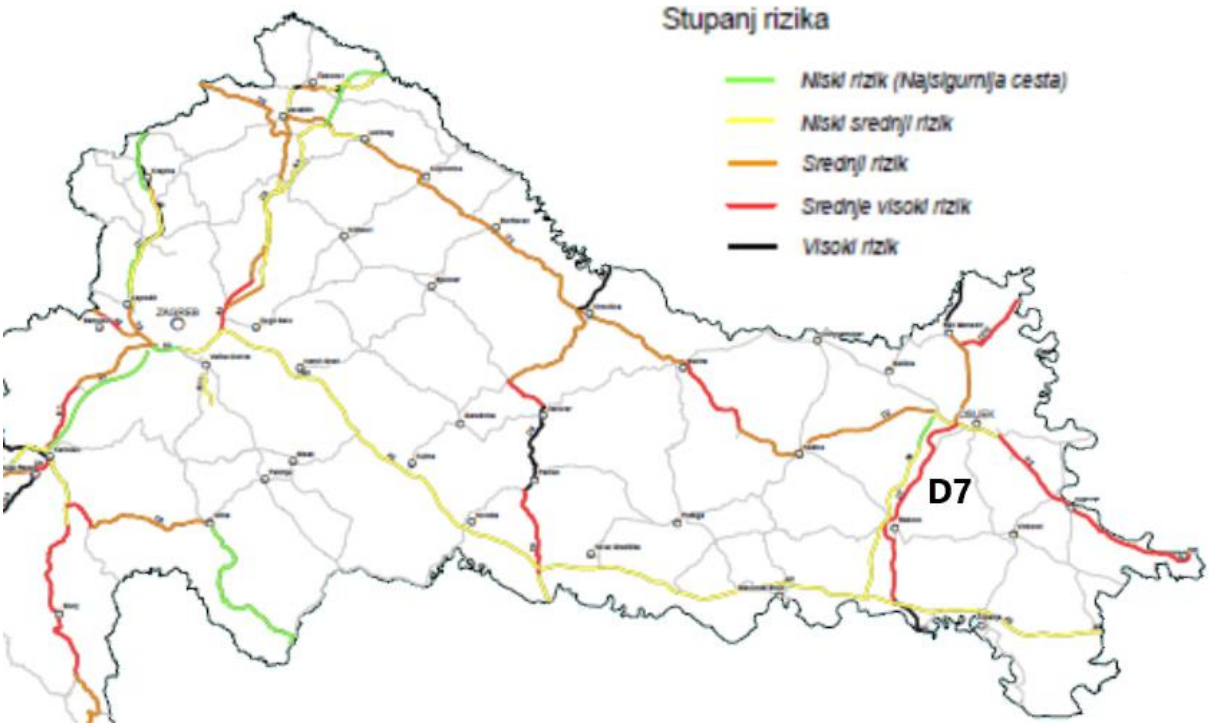
Izvor: [19]

Državna cesta D7 od iznimne je prometne i gospodarske važnosti za istočni dio Republike Hrvatske (RH). Ova prometnica povezuje istočnu Hrvatsku s Mađarskom na sjeveru te Bosnom i Hercegovinom na jugu. Prolazi pokraj nekoliko velikih Hrvatskih gradova od kojih je najznačajniji Osijek zatim Đakovo, Beli Manastir i Vrpolje. Prometnica je od velike važnosti za razvoj istočnog područja RH.

5.3. Analiza stanja sigurnosti na državnoj cesti D7

U Republici Hrvatskoj je na svim važnijim državnim pravcima proveden projekt EuroRAP koji procjenjuje rizik (opasnost) od nastanka prometne nesreće i procjenjuje opasna mjesta na kojima može doći do prometnih nesreća, a sve u svrhu otklanjanja prepoznatih potencijalno opasnih mjesta i ublažavanja posljedica ukoliko dođe do

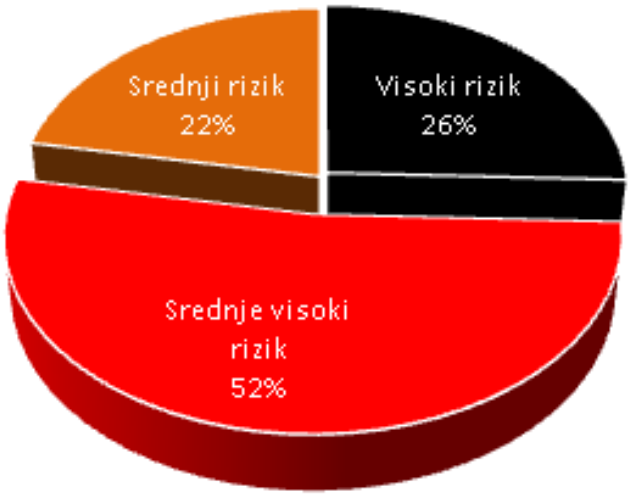
prometnih nesreća. Ovisno o veličini rizika na karti su dijelovi prometnica označeni različitim bojama od zelene koja predstavlja nizak rizik (najsigurnije ceste) do crne koja predstavlja visok rizik. Prema karti rizika koja je prikazana na slici 9, državna cesta D7 pripada među najopasnije prometnice u cestovnoj mreži RH. Najvećim svojim dijelom, oko 60,3 km, označena je crvenom bojom koja označava srednje visoki rizik od nastanka nesreća s poginulim ili ozlijeđenim osobama. Na krajnjem sjevernom i krajnjem južnom potezu označena je kao prometnica visokog rizika (oko 29,5 km), dok je na potezu od Osijeka do Belog Manastira (oko 25,4 km) označena kao srednje rizična prometnica.



Slika 9. Prikaz D7 na karti rizika

Izvor: [20]

Na grafikonu 1 prikazan je rizik od nastanka prometne nesreće u postocima na državnoj cesti D7. Može se vidjeti da najvećim dijelom s udjelom od 52% promatrana prometnica je procijenjena kao srednje visoko rizična. 26% od ukupne duljine prometnice predstavlja najrizičniji dio, dok je 22% prometnice procijenjeno srednjim rizikom.



Grafikon 1. Prikaz procjene rizika od nastanka prometnih nesreća na D7 u postocima

Sliku 9 i grafikon 1 potvrđuju podaci prema kojima je na promatranoj državnoj cesti D7 od 2014. do 2016. godine evidentirano 345 prometnih nesreća od čega 8 nesreća s poginulim osobama te 137 nesreća s ozlijeđenim osobama. Prema službenim podacima u periodu od 2016. do 2018. godine broj evidentirani prometnih nesreća na istoj prometnici se povećao na 431. Broj poginulih osoba u tom periodu je 9, dok je broj ozlijeđenih osoba 265 od čega je 49 teško ozlijeđenih, a 216 lakše ozlijeđenih osoba.

U tablici 4 prikazani su podaci o broju prometnih nesreća s obzirom na posljedice za svaku godinu zasebno te ukupni zbroj u promatranom periodu od 2016. do 2018. godine. Prema prikazanoj tablici može se vidjeti da se ukupan broj prometnih nesreća u 2017. godini naglo povećao u odnosu na 2016. godinu. U 2018. godini dogodila se jedna nesreća više u odnosu na 2017. godinu. Najviše prometnih nesreća s poginulim osobama dogodilo se u 2017. godini, dok 2018. bilježi dvostruko manji broj. Također u istoj godini zabilježen je i najveći broj nesreća s teško ozlijeđenim osobama i nesreća u kojima je došlo samo do materijalne štete. U 2018. godini zabilježen je najveći broj nesreća s lako ozlijeđenim osobama.

Tablica 4. Broj prometnih nesreća prema posljedicama u promatranom periodu

Godina	Nesreće s materijalnom štetom	Nesreće s lakše ozlijeđenim osobama	Nesreće s teže ozlijeđenim osobama	Nesreće s poginulim osobama	Prometne nesreće ukupno
2016.	67	37	9	3	116
2017.	102	33	18	4	157
2018.	96	49	11	2	158
Ukupno:	265	119	38	9	**431**

Upravo iz prethodno navedenog i prikazanog, državna cesta D7 odabrana je za provedbu identifikacije opasnih mjesta korištenjem obje službene metode segmentiranja ceste u svrhu analize i komparacije međusobnih rezultata.

5.4. Proces identifikacije opasnih mjesta

Nakon definiranja parametra potrebnih u postupku identifikacije opasnih mjesta potrebno je pristupiti izračunavanju stopa prometnih nesreća za svaku lokaciju. Stopa prometnih nesreća proporcionalna je broju prometnih nesreća, a obrnuto proporcionalna mjeri izloženosti na danom području. Stopa prometnih nesreća opisana je u poglavlju 2.1.2.2.

U sljedećem koraku se izračunavaju kritične razine nastanka prometnih nesreća za svaku lokaciju na temelju prosječne stope prometnih nesreća svih lokacija. Izračunavanje kritične razine nastanka prometnih nesreća objašnjeno je u poglavlju 2.1.2.3. te prikazano izrazom (5).

Prilikom računanja kritične razine prometnih nesreća kako je navedeno i objašnjeno u poglavlju 2.1.2.3. kao razina povjerenja u proračunu uzeto je 95% te stoga koeficijent k iznosi 1,645.

Nakon obavljenih izračuna kao potencijalno opasna mjesta identificirana su ona mjesta čija stopa prometnih nesreća prelazi kritičnu razinu prometnih nesreća.

Detaljni proces i svi koraci u obavljanja identifikacije opasnih mjesta opisan je u poglavlju 2.2.

5.4.1. Identifikacija potencijalno opasnih mjesta metodom podjele na fiksne dijelove

Na državnoj cesti D7 primijenjena je metoda podjele na fiksne dijelove u postupku identifikacije potencijalno opasnih mjesta. Kao što je prethodno spomenuto fiksna udaljenost uzeta je 500 m. Na slici 10 koristeći digitalnu ortofoto kartu (dof) prikazana je podjela državne ceste D7 na fiksne dijelove. Crvene linije na slici prikazuju prometnicu, žutom bojom su označene prometne nesreće na prometnici, kratke okomite zelene linije na os ceste predstavljaju odsječke od 500 metara, dok zeleni okvir prikazuje identificirano potencijalno opasno mjesto.



Slika 10. Prikaz podjele državne ceste D7 na fiksne dijelove

Ukupna duljina prometnice od 115,2 km podijeljena je na 230 dijelova jednakih dijelova te jedan posljednji dio duljine od 200 metara. Nakon provedenog procesa identifikacije opasnog mjesta s segmentacijskom metodom podjele na fiksne dijelove, utvrđeno je 15 potencijalno opasnih mjesta. U dva se slučaja događa da se identificirana potencijalno opasna mjesta nalaze jedno do drugog. U prvom slučaju povezana su tri odsječka i to od stacionaže ceste 0 metara do 1500 metara, što

zapravo ukazuje na to da se radi o potencijalno opasnoj dionici ceste u ukupnoj dužini od 1500 metara. U drugom slučaju povezana su isto tri potencijalno opasna mjesta i to u ukupnoj dužini od 1500 metara, tj. od stacionaže ceste 15000 metara do 16500 metara.

U slučaju da se prethodno navedena spojena identificirana opasna mjesta promatraju kao opasne dionice ceste, sukladno tome može se zaključiti da je na promatranoj prometnici korištenjem segmentacijske metode podjele na fiksne dijelove identificirano ukupno devet opasnih mjesta i dvije opasne dionice.

U svakom segmentu prebrojene su nastale prometne nesreće. Tako je na ukupnom broju od 231 segmenta, 64 segmenata bez prometnih nesreća. Najveći broj segmenata je onih u kojima se dogodila samo jedna nesreća dok se najveći broj nesreća, 16, dogodio u 2 segmenta. Detaljan prikaz broja nesreća u određenom broju segmenata prikazan je u tablici 5.

Tablica 5. Lokacije prometnih nesreća na državnoj cesti D7 od 2016. do 2018. godine definirane pomoću metode "Segmentiranje dionice na fiksne dijelove"

Broj nesreća	Broj lokacija
0	64
1	73
2	43
3	16
4	14
5	5
6	6
7	2
9	1
10	3
11	2
16	2

U tablici 6 prikazana su potencijalno identificirana opasna mjesta te podaci potrebni u postupku identifikacije, a to su: dionica, stacionaža ceste od – do (duljina segmenta odnosno duljina identificiranog potencijalno opasnog mjesta), broj nesreća u promatranom segmentu, prosječni godišnji dnevni promet (PGDP), prometno opterećenje na promatranoj dionici/segmentu (Q_L), stopa prometnih nesreća (C_R), kritična razina broja prometni nesreća (C_{CR}), odnos C_R/C_{CR} i podatak je li određeno mjesto identificirano kao potencijalno opasnom mjesto.

Tablica 6. Identificirana opasna mjesta segmentacijskom metodom podjele na fiksne dijelove

Rb	Dionica	Stacionaža od (m)	Stacionaža do (m)	Broj nesreća	PGDP	Q_L	C_R	C_{CR}	C_R/C_{CR}	Opasno mjesto
1.	001 - GP Duboševica - Vrpolje (g.ž.)	0	500	10	1445	0,79	12,64	3,14	4,026	DA
2.	001 - GP Duboševica - Vrpolje (g.ž.)	500	1000	3	1445	0,79	3,79	3,14	1,208	DA
3.	001 - GP Duboševica - Vrpolje (g.ž.)	1000	1500	3	1445	0,79	3,79	3,14	1,208	DA
4.	001 - GP Duboševica - Vrpolje (g.ž.)	9000	9500	5	1445	0,79	6,32	3,14	2,013	DA
5.	001 - GP Duboševica - Vrpolje (g.ž.)	12500	13000	5	1445	0,79	6,32	3,14	2,013	DA
6.	001 - GP Duboševica - Vrpolje (g.ž.)	15000	15500	6	1445	0,79	7,58	3,14	2,415	DA
7.	001 - GP Duboševica - Vrpolje (g.ž.)	15500	16000	5	1445	0,79	6,32	3,14	2,013	DA
8.	002 - GP Duboševica - Vrpolje (g.ž.)	16000	16500	7	1445	0,79	8,85	3,14	2,818	DA
9.	003 - GP Duboševica - Vrpolje (g.ž.)	22000	22500	9	4983	2,73	3,30	3,28	1,006	DA
10.	005 - GP Duboševica - Vrpolje (g.ž.)	74500	75000	11	4796	2,63	4,19	3,25	1,291	DA
11.	005 - GP Duboševica - Vrpolje (g.ž.)	77500	78000	16	4796	2,63	6,09	3,25	1,877	DA
12.	005 - GP Duboševica - Vrpolje (g.ž.)	78000	78500	10	4796	2,63	3,81	3,25	1,173	DA
13.	005 - GP Duboševica - Vrpolje (g.ž.)/ 006 - GP Duboševica - Vrpolje	80000	80500	10	4796	2,63	3,81	3,25	1,173	DA
14.	006 - GP Duboševica - Vrpolje (g.ž.)	88000	88500	11	3701	2,03	5,43	3,08	1,761	DA
15.	008 - Vrpolje (g.ž.) - GP Slavonski Šamac	114500	115000	5	2623	1,44	3,48	3,00	1,161	DA

Najveći broj potencijalno opasnih mjesta identificiran je na prvoj dionici ceste. Od ukupnog broja identificiranih opasnih mjesta skoro polovica ih se nalazi na prvoj dionici. Jedan od glavnih razloga tome je primjene RQC statističke metode identifikacije opasnih mjesta koja u obzir uzima prometno opterećenje (PGDP). Na prvoj dionici prosječni godišnji dnevni promet je znatno manji u usporedbi s ostalim dionicama na promatranoj prometnici, što u konačnici rezultira većim brojem identificiranih opasnih mjesta.

Kada bi se sva potencijalno opasna mjesta koja se nalaze jedna do drugog odnosno označena su istom bojom promatrala kao jedno opasno mjesto, u tom slučaj je metodom podjele dionice na fiksne dijelove identificirano 10 potencijalno opasnih mjesta.

5.4.2. Identifikacija potencijalno opasnih mjesta metodom *Sliding window*

Kod identifikacije opasnih mjesta korištenjem segmentacijske metode *Sliding window* korišten je okvir radijusa 300 metara sa pomakom od 100 metara. U obzir su uzeti okviri u kojima se nalazi najmanje jedna prometna nesreća. Slikovni prikaz postupka identifikacije opasnih mjesta segmentacijskom metodom *Sliding window* prikazan je na slici 11. Žutom bojom je prikazan osnovni okvir u definiranoj duljini. Žute zvjezdice prikazuju promete nesreće, a zelenom bojom su prikazani okviri koji

predstavljaju identificirano potencijalno opasnom mjesto primjenom navedene metode.



Slika 11. Prikaz segmentacijske metode *Sliding window*

U tablici 7 prikazano je u koliko se segmenata ponovio isti broj prometnih nesreća. S obzirom da metoda *Sliding window* ne uzima u obzir segmente bez prometnih nesreća, podatak o broju segmenata u kojima se nije dogodila prometna nesreća ne postoji. Nadalje u 325 segmenta se dogodila samo jedna, što ujedno predstavlja i najveći broj. Zatim se se u 160 segmenata dogodile dvije prometne nesreće. Najveći broj nesreća (18) dogodio se u jednom segmentu dok je vrijedno spomenuti da su evidentirana i dva segmenta sa 16 prometnih nesreća.

Tablica 7. Lokacije prometnih nesreća na državnoj cesti D7 od 2016. do 2018. godine definirane pomoću metode "*Sliding window*"

Broj nesreća	Broj lokacija
1	325
2	160
3	56
4	24
5	12
6	9
7	5
8	5
9	4
10	5
11	1
13	1
15	1
16	2
18	1

Provedbom postupka identifikacije opasnih mjesta na državnoj cesti D7 segmentacijskom metodom *Sliding window* identificirana su 43 segmentacijska okvira kao potencijalno opasna mjesta. U više slučaja su evidentirana potencijalno opasna mjesta čiji se okviri djelomično preklapaju. U dva se slučaja samo pojavljuje da je opasno mjesto identificirano samo jednim okvirom. Također u dva je slučaja identificirano potencijalno opasno mjesto s 6 i 8 okvira i to u prvom slučaju od stacionaže ceste od 15200 metara do 16400 metara što predstavlja potencijalno opasno mjesto u dužini od 1200 metara te se može također promatrati i kao potencijalna opasna dionica. U drugom slučaju potencijalno opasno mjesto je identificirana u dužini od 800 metara, tj. od stacionaže ceste od 77600 metara do 78400. Primjer identificiranog potencijalno opasnog mjesta u ukupnoj dužini od 800 metara prikazan je na slici 12. Zelenom bojom prikazani su okviri radijusa 300 metara koji su identificirani kao potencijalna opasna mjesta.



Slika 12. Prikaz identificirane opasne dionice pomoću segmentacijske metode *Sliding window*

U takvim slučajevima potrebno je kao potencijalno opasno mjesto promatrati sva identificirana opasna mjesta odnosno okvire koji se preklapaju od početne stacionaže prvog identificiranog opasnog mjesta u nizu pa do stacionaže posljednjeg identificiranog opasnog mjesta u nizu. Na takav način moguće je pomoću metode *Sliding window* otkriti potencijalno opasnu dionicu koja je duža od definiranog osnovnog okvira navedene metode.

U tablici 6 su prikazana identificirana potencijalno opasna mjesta segmentacijskom metodom *Sliding window* te podaci potrebni u identifikacijskom postupku. Istom bojama prikazana su identificirana potencijalno opasna mjesta čiji se okviri preklapaju. Kada bih se kao potencijalno opasno mjesto promatrale segmenti

koji su označeni istom bojom u tablici, može se reći da je metodom *Sliding window* identificirano 14 potencijalno opasnih mjesta.

Tablica 8. Tablični prikaz identificiranih potencijalno opasnih mjesta segmentacijskom metodom *Sliding window*

Rb	Dionica	Stacionaža od (m)	Stacionaža do (m)	Broj nesreća	PGDP	Q_L	C_R	C_{CR}	C_R/C_{CR}	Opasno mjesto
1.	001 - GP Duboševica - Vrpolje (g.ž.)	0	300	10	1445	0,47	21,07	5,86	3,597	DA
2.	001 - GP Duboševica - Vrpolje (g.ž.)	100	400	3	1445	0,47	6,32	5,86	1,079	DA
3.	001 - GP Duboševica - Vrpolje (g.ž.)	800	1100	4	1445	0,47	8,43	5,86	1,439	DA
4.	001 - GP Duboševica - Vrpolje (g.ž.)	900	1200	5	1445	0,47	10,53	5,86	1,799	DA
5.	001 - GP Duboševica - Vrpolje (g.ž.)	1000	1300	3	1445	0,47	6,32	5,86	1,079	DA
6.	001 - GP Duboševica - Vrpolje (g.ž.)	8900	9200	3	1445	0,47	6,32	5,86	1,079	DA
7.	001 - GP Duboševica - Vrpolje (g.ž.)	9000	9300	4	1445	0,47	8,43	5,86	1,439	DA
8.	001 - GP Duboševica - Vrpolje (g.ž.)	9100	9400	3	1445	0,47	6,32	5,86	1,079	DA
9.	001 - GP Duboševica - Vrpolje (g.ž.)	12600	12900	4	1445	0,47	8,43	5,86	1,439	DA
10.	001 - GP Duboševica - Vrpolje (g.ž.)	12700	13000	4	1445	0,47	8,43	5,86	1,439	DA
11.	001 - GP Duboševica - Vrpolje (g.ž.)	12800	13100	5	1445	0,47	10,53	5,86	1,799	DA
12.	001 - GP Duboševica - Vrpolje (g.ž.)	13300	13600	3	1445	0,47	6,32	5,86	1,079	DA
13.	001 - GP Duboševica - Vrpolje (g.ž.)	15200	15500	6	1445	0,47	12,64	5,86	2,158	DA
14.	001 - GP Duboševica - Vrpolje (g.ž.)	15300	15600	8	1445	0,47	16,85	5,86	2,878	DA
15.	001 - GP Duboševica - Vrpolje (g.ž.)	15400	15700	9	1445	0,47	18,96	5,86	3,238	DA
16.	001 - GP Duboševica - Vrpolje (g.ž.)	15500	15800	5	1445	0,47	10,53	5,86	1,799	DA
17.	001 - GP Duboševica - Vrpolje (g.ž.)	15600	15900	3	1445	0,47	6,32	5,86	1,079	DA
18.	002 - GP Duboševica - Vrpolje (g.ž.)	15900	16200	4	1445	0,47	8,43	5,86	1,439	DA
19.	002 - GP Duboševica - Vrpolje (g.ž.)	16000	16300	5	1445	0,47	10,53	5,86	1,799	DA
20.	002 - GP Duboševica - Vrpolje (g.ž.)	16100	16400	6	1445	0,47	12,64	5,86	2,158	DA
21.	003 - GP Duboševica - Vrpolje (g.ž.)	22100	22400	7	4983	1,64	4,28	3,67	1,164	DA
22.	003 - GP Duboševica - Vrpolje (g.ž.)	22200	22500	9	4983	1,64	5,50	3,67	1,496	DA
23.	003 - GP Duboševica - Vrpolje (g.ž.)	22300	22600	8	4983	1,64	4,89	3,67	1,330	DA
24.	004 - GP Duboševica - Vrpolje (g.ž.)	42100	42400	15	9525	3,13	4,79	3,07	1,564	DA
25.	004 - GP Duboševica - Vrpolje (g.ž.)	42200	42500	16	9525	3,13	5,11	3,07	1,668	DA
26.	005 - GP Duboševica - Vrpolje (g.ž.)	74400	74700	7	4796	1,58	4,44	3,72	1,195	DA
27.	005 - GP Duboševica - Vrpolje (g.ž.)	74500	74800	7	4796	1,58	4,44	3,72	1,195	DA
28.	005 - GP Duboševica - Vrpolje (g.ž.)	74600	74900	9	4796	1,58	5,71	3,72	1,536	DA
29.	005 - GP Duboševica - Vrpolje (g.ž.)	77600	77900	13	4796	1,58	8,25	3,72	2,219	DA
30.	005 - GP Duboševica - Vrpolje (g.ž.)	77700	78000	16	4796	1,58	10,16	3,72	2,731	DA
31.	005 - GP Duboševica - Vrpolje (g.ž.)	77800	78100	18	4796	1,58	11,43	3,72	3,073	DA
32.	005 - GP Duboševica - Vrpolje (g.ž.)	77900	78200	10	4796	1,58	6,35	3,72	1,707	DA
33.	005 - GP Duboševica - Vrpolje (g.ž.)	78000	78300	8	4796	1,58	5,08	3,72	1,366	DA
34.	005 - GP Duboševica - Vrpolje (g.ž.)	78100	78400	8	4796	1,58	5,08	3,72	1,366	DA
35.	006 - GP Duboševica - Vrpolje (g.ž.)	80100	80400	10	4796	1,58	6,35	3,72	1,707	DA
36.	006 - GP Duboševica - Vrpolje (g.ž.)	80200	80500	10	4796	1,58	6,35	3,72	1,707	DA
37.	006 - GP Duboševica - Vrpolje (g.ž.)	80300	80600	8	4796	1,58	5,08	3,72	1,366	DA
38.	006 - GP Duboševica - Vrpolje (g.ž.)	87900	88200	10	3701	1,22	8,23	4,05	2,032	DA
39.	006 - GP Duboševica - Vrpolje (g.ž.)	88000	88300	11	3701	1,22	9,05	4,05	2,235	DA
40.	007 - Vrpolje (g.ž.) - GP Slavonski Šamac	111700	112000	4	2623	0,86	4,64	4,58	1,013	DA
41.	008 - Vrpolje (g.ž.) - GP Slavonski Šamac	114300	114600	6	2623	0,86	6,96	4,58	1,520	DA
42.	008 - Vrpolje (g.ž.) - GP Slavonski Šamac	114400	114700	7	2623	0,86	8,12	4,58	1,773	DA
43.	008 - Vrpolje (g.ž.) - GP Slavonski Šamac	114500	114800	5	2623	0,86	5,80	4,58	1,266	DA

6. Komparativna analiza dobivenih rezultata

Mnogo istraživanja napravljeno je kako bi se kvalitativno usporedile metode identifikacije opasnih mjesta radi utvrđivanja najbolje metode kojom se postižu točni rezultati s minimalnim odstupanjem i pogreškama, no malo je istraživanja provedeno kako bi se međusobno usporedile metode segmentacije ceste na manje dijelove. Takve metode su sastavni dio gotovo svakog identifikacijskog postupka koji se bavi otkrivanjem crnih točaka ili opasnih mjesta odnosno dionica na određenoj prometnici ili cestovnoj mreži. Da bih se identificiralo opasno mjesto, ponajprije se mora definirati određeni okvir ili radijus unutar kojeg će se promatrati nastale nesreće te provesti postupak izračuna za svaku metodu kako bi u konačnici utvrdilo je li promatrano mjesto unutar okvira ili radijusa opasno ili nije. Postoji više načina na koji se mogu odrediti i koristiti takvi definirani okviri određenih duljina. U ovom diplomskom radu napravljena je identifikacija opasnih mjesta na državnoj cesti D7 koristeći obje metode koje su službene u Republici Hrvatskoj za korištenje u procesu otkrivanja opasnih mjesta sukladno definiranoj metodologiji. U daljnjem dijelu rada međusobno će biti uspoređeni dobiveni podaci i druge karakteristike obje metode.

Uspoređujući obje metode; metodu podjele na fiksne dijelove i *Sliding window* metodu, prva najočitija razlika je kompleksnost odnosno složenost primjene pojedine metode. Metoda podjele na fiksne dijelove predstavlja jednostavniju metodu za primjenu u odnosu na *Sliding window* metodu. Primjenom metode podjele na fiksne dijelove ukupna duljina prometnice podjeli se na dijelove pri čemu je svaki dio jednake unaprijed određene duljine te se na temelju tako određenih dijelova promatraju nastale evidentirane prometne nesreće i obavlja se postupak identifikacije opasnih mjesta. Kod metode *Sliding window* postupak identifikacije je složeniji. Unaprijed definirani okvir pomiće se po ukupnoj duljini određene prometnice i pronalazi mjesta na kojima je stopa prometnih nesreća veća od definiranog praga. Takvo kretanje okvira po prometnici odvija se s određenim pomakom, u ovom diplomskom radu korištena je duljina okvira od 300 metara, a pomaka od 100 metara. Pri tome je važno napomenuti da metoda *Sliding window* ne uzima u obzir mjesta na kojima nije evidentirana niti jedna prometna nesreća za razliku od metode podjele na fiksne dijelove koja uzima u obzir i dijelove na kojima se nije dogodila prometna nesreća.

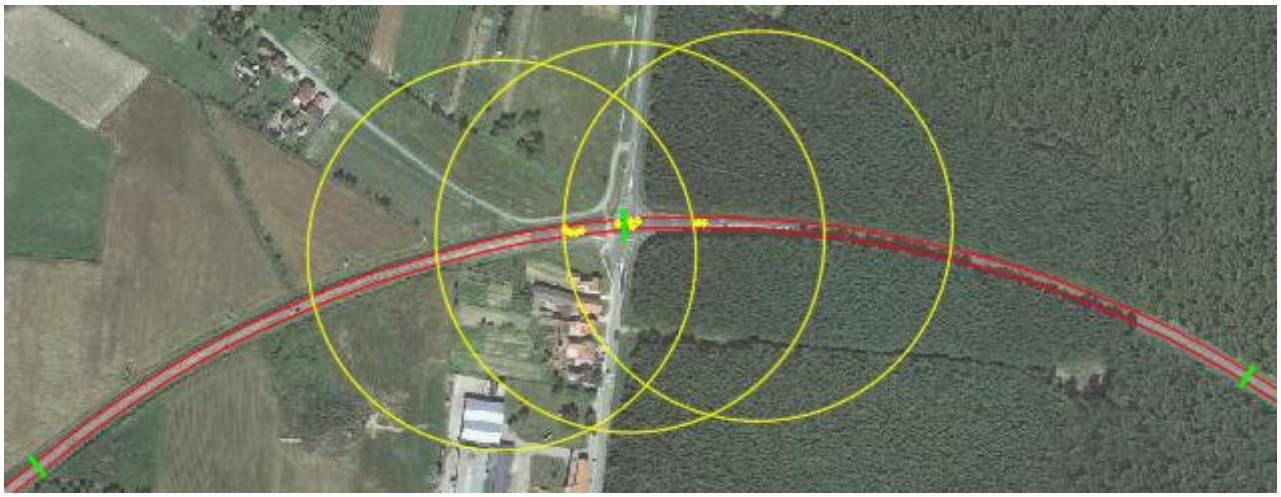
Sukladno tome kako je prethodno navedeno mogu se međusobno usporediti ukupni broj segmenata, za obje metode, unutar kojih se određivalo je li određeno mjesto potencijalno opasno ili nije. Broj takvih segmenata u slučaju metode podjele na fiksnih dijelova je 231, od čega je 230 jednakih dijelova dužine 500 metara i posljednji dio 200 metara. Kod metode *Sliding window* broj pokretnih prozora ili okvira unutar kojih je evidentirana jedna ili više prometnih nesreća je 611. Evidentirani broj okvira je više nego dvostruko veći korištenjem metode *Sliding window*. Takav omjer ne predstavlja veliki problem prilikom jednostavnije identifikacije opasnih mjesta na jednoj prometnici i primjenom jednodimenzionalnog modela identifikacije. Autor [17] u svojem istraživanju ističe kako primjenom navedene metode na cijeloj cestovnoj mreži te korištenjem dvodimenzionalnog modela (za identifikaciju koristi koordinate prometnih nesreća) na kojoj se evidentira velik broj okvira predstavlja značajan problem. Velika količina podataka zahtjevnija je za obradu kao i sama potreba za većim kapacitetom memorije.

Kod identifikacije opasnih mjesta jedna od vrlo važnih karakteristika je preciznost u određivanju točne lokacije stvarnog opasnog mjesta. Često u praksi opasno mjesto ne predstavlja jednu točku manjeg radijusa (npr. raskrižja), već su nesreće u većoj mjeri raspršene pa je identificirano opasno mjesto veće dužine ili se govori o opasnoj dionici. Korištenjem različitih metoda moguće je točnije odnosno preciznije odrediti i definirati položaj identificiranog opasnog mjesta. Primjenom metode podjele na fiksne dijelove identificirano opasno mjesto predstavlja jedan ili više segmenata jednakih dijelova na koje je prometnica podijeljena. Segment ukupne duljine od 500 metara u ovom slučaju predstavlja potencijalno opasno mjesto, ne uzimajući u obzir raspršenost nesreća dužinom cijelog segmenta ili koncentraciju više nesreća oko jedne točke. S druge strane *Sliding window* metoda je u tom smislu značajno preciznija. Manji radijus okvira i mogućnost pomicanja po prometnici omogućuje joj preciznije definiranje lokacije stvarnog opasnog mjesta. Na slici 13 prikazana je usporedba utjecaja duljine segmenta na preciznost identifikacije opasnog mjesta. Na temelju obje metode identificirano je opasno mjesto, ali korištenjem *Sliding window* metode koja je označena kružnicom identificirano potencijalno opasno mjesto je znatno preciznije locirano, odnosno označeno područje je manje nego u slučaju kada je primijenjena metoda podjele na fiksne dijelove koja je označena zelenim okvirom.



Slika 13. Usporedba utjecaja duljine segmenta na preciznost identifikacije opasnog mjesta

Nadalje uspoređujući ove dvije metode prilikom identifikacije potencijalno opasnih mjesta na ukupnoj duljini prometnice u jednom slučaju se dogodilo da stvarno opasno mjesto na raskrižju nije identificirano korištenjem metode podjele na fiksne dijelove, dok je korištenjem metode *Sliding window* opasno mjesto uspješno identificirano. Ovime se ukazuje na nedostatak prilikom korištenja metode podjele na fiksne dijelove. Prilikom korištenja ove metode na određenoj prometnici raskrižja, zavoje, tunele, mostove ili vijadukte je potrebno promatrati i analizirati zasebno u postupku identifikacije opasnih mjesta. Navedeni primjer prikazan je na slici 14. Kratke okomite zelene linije prikazuju podjelu na fiksne dijelove. Na slici se može vidjeti kako se podjela dogodila u središtu raskrižja te se dio prometnih nesreća našao u jednom segmentu, a drugi dio nesreća u drugom, time se opasno mjesto nije identificiralo kao stvarno opasno korištenjem navedene metode. Žute kružnice označavaju okvire *Sliding window* metode te prikazuju kako je opasno mjesto identificirano od strane sve tri kružnice. U ovom slučaju metoda *Sliding window* se pokazala kao efikasnija i pouzdanija metoda.



Slika 14. Usporedba metode podjele na fiksne dijelove i *Sliding window* metode na raskrižju

Na slici 12 i 14 može se vidjeti tendencija metode *Sliding window* za grupiranjem prometnih nesreća, a time i gomilanjem identificiranih opasnih mjesta. Naime na prikazanoj slici 12 i 14 sva tri kružna okvira identificirala su potencijalno opasno mjesto, no zapravo riječ je o jednom potencijalno opasnom mjestu iako se u tablici 6 (pod rednim brojem 36.,37. i 38.) svaki od okvira prikazuje identificirano potencijalno opasno mjesto. Pojednostavljeno, potencijalno opasno mjesto na slici 14 može se identificirati samo jednim okvirom, nije potrebno da svaki okvir prikazuje identificirano opasno mjesto zasebno. No kao što je već ranije spomenuto nije nužno da se ovakav princip „gomilanja“ opasnih mjesta gleda s negativne strane, jer na ovakav princip *Sliding window* metoda ima mogućnost prepoznati odnosno identificirati opasnu dionicu ukoliko je više okvira koji se preklapaju označeno kao opasno mjesto.

Također prethodno spomenuto može se potkrijepiti i razlikom u broju identificiranih potencijalno opasnih mjesta. Ako uzmemo u obzir podatke iz tablice 5 i 6. Metodom podjele na fiksne dijelove identificirano je 15 opasnih mjesta, dok je metodom *Sliding window* identificirano skoro trostruko više, 43 opasna mjesta (tablica 9). Pri tome je važna istaknuti da su u većini slučajeva i s jednom i drugom metodom identificirana ista opasna mjesta. Velika razlika u broju identificiranih opasnih mjesta stvorena je upravo iz razloga gomilanja opasnih mjesta korištenjem metode *Sliding window*, gdje je jedno opasno mjesto identificirano od strane više okvira koji se pomiću.

Tablica 9. Usporedba broja identificiranih potencijalno opasnih mjesta

Naziv metode	Broj identificiranih potencijalno opasnih mjesta
Podjela na fiksne dijelove	15
Sliding window	43

Usporedbom broja prometnih nesreća koji se ponavljaju u određenom broju segmenata može se vidjeti značajna razlika u broju identificirani lokacija sa jednom prometnom nesrećom (tablica 10). Uzrok velike razlike je u samom principu primjene *Sliding window* metode. Naime ukoliko se određena nesreća nalazi na prometnici pomični okvir dolazi do prometne nesreće te ju identificira prilikom prvog zahvaćanja, zatim se okvir pomiče za određeni pomak te ukoliko je nesreća i dalje unutar okvira ponovno evidentira segment s jednom nesrećom i tako sve dok se okvir ne pomakne te se nesreća više ne nalazi u radijus pomičnog okvira. U ovom slučaju kada je radijus okvira 300 metara, a pomak 100 metara, evidentirana prometna nesreća se identificira tri puta, tj. u tri segmenta za redom.

Tablica 10. Usporedni prikaz lokacija prometnih nesreća od 2016. do 2018. pomoću obje metode

	Podjela dionice na fiksne dijelove	*Sliding window*
Broj nesreća	Broj lokacija	Broj lokacija
0	64	-
1	73	325
2	43	160
3	16	56
4	14	24
5	5	12
6	6	9
7	2	5
8	-	5
9	1	4
10	3	5
11	2	1
13	-	1
15	-	1
16	2	2
18	-	1
Ukupno:	231	611

Nadalje, u tablici 10 može se vidjeti kako je korištenjem metode *Sliding window* u jednom segmentu identificirano 18 prometnih nesreća, dok druga metoda nije identificirala toliki broj prometnih nesreća. Time se može vidjeti tendencija *Sliding window* metode za grupiranjem što većeg broja prometnih nesreća, ali time se postiže i veća efikasnost i preciznost ove metode u definiranju točne lokacije opasnih mjesta.

Kada bi se kao jedno opasno mjesto promatralo više identificiranih opasnih segmenata koji su osjenčani istom bojom (tablice 6 i 8) tj. njihovi okviri ili granice se preklapaju ili dodiruju, tada bi se moglo utvrditi da je metodom podjele na fiksne dijelove identificirano 10 potencijalno opasnih mjesta, dok je *Sliding window* metodom identificirano 14 potencijalno opasnih mjesta, pri čemu je u jednom slučaju korištenjem Sliding window metode sa dva identificirana okvira kao opasna označeno mjesto koje je metodom podjele na fiksne dijelove identificirano jednim okvirom. S obzirom na prethodno navedeno metodom *Sliding window* identificirana su tri potencijalno opasna mjesta više nego metodom podjele na fiksne dijelove. Takav rezultat čini razliku od 23,08% više identificiranih opasnih mjesta metodom *Sliding window*. Veći broj identificiranih opasnih mjesta od strane metode *Sliding window* bio je i očekivan s obzirom na karakteristike i dinamički način primjene ove metode te tendenciju metode da grupira nastale prometne nesreće.

Sliding window metoda je identificirala sva potencijalno opasna mjesta kao i metoda podjele na fiksne dijelove te još tri mjesta koja nisu identificirana korištenjem metode podjele dionice na fiksne dijelove. Jedan od razloga većeg broja identificiranih potencijalno opasnih mjesta može se naći u proračunu gdje se kod izračuna prometnog opterećenja (Q_L) uzima u obzir duljina promatrane dionice te je kod veće udaljenosti i opterećenje veće, a time i stopa prometnih nesreća (C_R) manja kao i kritična razina broja prometnih nesreća (C_{CR}). Drugi razlog je objašnjen i prikazan na slici 14. Gdje potencijalno opasno mjesto nije identificirano od strane metode podjele na fiksne dijelove, jer se podjela dogodila u središtu potencijalnog opasnog mjesta.

U tablici 11 za pojedinu metodu prikazane su prednosti i nedostaci uočeni prilikom izrade ovog diplomskog rada, a posebno kroz obavljanje procesa odnosno postupka identifikacije potencijalno opasnih mjesta.

Tablica 11. Prednosti i nedostaci segmentacijskih metoda podjele na fiksne dijelove i *Sliding window* metode

Metode	Prednosti	Nedostaci
Podjela na fiksne dijelove	- jednostavnost primjene - mogućnost korištenja podjele većih dužina - dobra identifikacija u slučaju raspršenosti prometnih nesreća	- ne prepoznavanje stvarno opasnog mjesta - raskrižja, zavoje, tunele, mostove itd. potrebno promatrati zasebno - cijeli segment označen kao opasno mjesto (loša preciznost označavanja opasne lokacije)
Sliding window	- mogućnost malim radijusom okvira identificirati opasnu dionicu - dinamička primjena pomičnog okvira - identificiranje opasnih mjesta na području raskrižja, zavoja, tunela i mostova bez zasebne analize - preciznije označavanje opasnog područja	- gomilanje opasnih mjesta (isto opasno mjesto identificirano s više okvira) - složeniji postupak primjene (najprikladnije korištenjem algoritma) - velik broj identificiranih segmenata u kojim se dogodila jedna nesreća

7. Zaključak

Sigurnost u prometu zasigurno je jedan od najvažnijih problema današnjice kojemu se posvećuje velika pažnja kako na međunarodnoj tako i na nacionalnoj razini. Problem sigurnosti u prometu je kompleksan problem u kojemu je teško odrediti jedinstveno rješenje, no kontinuirani rad, analize te donošenje i provođenje određenih odluka i mjera doprinose poboljšanju sigurnosti u prometu. Kada govorimo o povećanju sigurnosti u prometu najčešće se misli što napraviti da bih se broj prometnih nesreća smanjio odnosno kako otkloniti uzrok zbog kojeg dolazi do prometnih nesreća. Kako bih se smanjio broj prometnih nesreća a time i povećala sigurnost u prometu potrebno je identificirati mjesta na kojima se događa iznad prosječni broj prometnih nesreća odnosno identificirati opasna mjesta ili „crne točke“. Da bih se otkrila opasna mjesta potrebno je obaviti proces identifikacije.

Identifikacija potencijalno opasnih mjesta napravljena prema službenoj metodologiji za identifikaciju opasnih mjesta u Republici Hrvatskoj, što podrazumijeva korištenje *Rate Quality Control* (RQC) metode koja uzima u obzir duljinu promatrane dionice, prometno opterećenje na dionici, stopu prometnih nesreća i kritičnu razinu prometnih nesreća.

Prilikom provedbe procesa identifikacije potencijalno opasnih mjesta definirani su parametri (vremenski period promatranja, duljina promatrane dionice, prometno opterećenje i broj prometnih nesreća) potrebni u samom postupku identifikacije. Jedan od najvažnijih parametara je duljina promatrane dionice čime se podrazumijeva odabir neke segmentacijske metode. Najpoznatije segmentacijske metode su: metoda podjele na fiksne dijelove, *Sliding window* metoda i metoda grupiranja.

U ovom radu napravljena je komparacija dviju segmentacijskih metoda koje su navedene u službenoj metodologiji za identifikaciju opasnih mjesta u Republici Hrvatskoj, a to su: metoda podjele dionice na fiksne dijelove i *Sliding window* metoda. Metoda grupiranja nije obuhvaćena u analizu iz razloga što nije službena metoda za identifikaciju opasnih mjesta u Republici Hrvatskoj te nije adekvatna za primjenu na cestama izvan naselja, već je najprikladnija za primjenu u gradskom području.

Usporedba je napravljena na temelju identifikacije potencijalno opasnih mjesta na državnoj cesti D7. Da bi se lokacije utvrdile kao stvarno opasno mjesto bilo bi potrebno pregledati ih sve na terenu što nije bio cilj ovog rada, stoga ovdje govorimo o potencijalno opasnim mjestima.

Prema dobivenim podacima i obavljenoj komparacijskoj analizi ne može se reći kako je određena metoda pogrešna, obje metode uspješno su identificirale potencijalno opasna mjesta, no određene razlike u rezultatima postoje. Tako je na primjer *Sliding window* metoda identificirala tri potencijalno opasnih mjesta više od metode podjele na fiksne dijelove, čime se pokazala kao efektivnija i pouzdanija metoda. Nadalje metoda *Sliding window* omogućava precizniju identifikaciju područja opasnog mjesta, dok metoda podjele na fiksne dijelove kao opasno mjesto identificira cijelo područje okvira bez obzira na raspršenost prometnih nesreća. S druge strane jedan od glavnih nedostataka *Sliding window* metode je tako zvano gomilanje opasnih mjesta gdje je jedno opasno mjesto identificirano od strane više pomičnih okvira uzastopno, no na takav način moguće je pomoću ove metode identificirati potencijalno opasno mjesto ukoliko se identificira više okvira koji se dodiruju ili preklapaju uzastopno.

Kao bitno razliku odnosno prednost fiksne podjele dionice na manje dijelove nad metodom *Sliding window* važno je izdvojiti jednostavniju primjenu, mogućnost podjele na veće dijelove (do 10 km), višestruko manji broj segmenata na koje je prometnica podijeljene (231 u odnosu na 611 segmenata *Sliding window* metode) i uspješna identifikacija opasnih mjesta u slučajevima veće raspršenosti prometnih nesreća. Jedan od glavnih nedostataka podjele dionice na fiksne dijelove je „krutost“ metode u pogledu definiranih granica podjele, gdje se u nekim slučajevima događa podjela u središtu stvarno opasnog mjesta te to mjesto ostane neidentificirano odnosno lažno negativno opasno mjesto. S druge strane metoda *Sliding winodw* sa prozorom (okvirom) koji se pomiće duž prometnice omogućava identifikaciju svih potencijalno opasnih mjesta.

Uzimanjem u obzir svega što je prethodno navedeno, dobivenih podataka i napravljene komparativne analize može se zaključiti kako je metoda *Sliding window* u odnosu na metodu podjele na fiksne dijelove točnija, preciznija, pouzdanija i efektivnija te se s razlogom preporuča za korištenje u službenom dokumentu

„Metodologija za identifikaciju opasnih mjesta u cestovnoj prometnoj mreži“ prilikom identifikacije opasnih mjesta u Republici Hrvatskoj.

Literatura

[1] Hrvatske ceste: Metodologija za identifikaciju opasnih mjesta u cestovnoj prometnoj mreži, Zagreb, 2016.

[2] Šarić, Ž.: Model identifikacije opasnih mjesta u cestovnoj prometnoj mreži, Doktorska disertacija, Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2014

[3] Yuan, T., Zeng, X., Shi, T.: Identifying Urban Road Black Spots with a Novel Method Based on the Firefly Clustering Algorithm and a Geographic Information System, College of Transportation Engineering, China, 2019.

[4] Maskooni E.K., Haghighi, F.: Evaluation and Statistical Validation of Black-Spots Identification Methods, International Journal of Transportation Engineering, 2018;6(1)

[5] Montella, A.: A comparative analysis of hotspot identification methods, Accident Analysis and Prevention, Elsevier, 2010;42(2): 571–581

[6] Borsos, A., Cafiso, S., D'Agostino, C., Miletics, D.: Comparison of Italian and Hungarian black spot ranking, Transportation Research Procedia, Elsevier, 2016.

[7] Campelo, C., Bertolotto, M., Corcoran, P.: Volunteered Geographic Information and the Future of Geospatial Dana, IGI Global, 2017.

[8] Ambros, J.,Havránek, P., Valentová, V., Krivankova, Z., Striegler, R.: Identification of hazardous locations in regional road network – comparison of reactive and proactive approaches, Transportation Research Procedia, Elsevier, 2016.

[9] Ramosa L., Silvab, L., , Santosa, M.Y., Piresb, J.M.: Detection of road accident accumulation zones with a visual analytics approach, Procedia Computer Science, Elsevier, 2015.

[10] Ghadi, M.Q., Török, Á.: Comparison of Different Road Segmentation Methods, Faculty of Transport Engineering and Vehicle Engineering Budapest University of Technology and Economics, Hungary, 2019.

[11] Ghadi, M., Török, Á.: Comparison Different Black Spot Identification Methods, Transportation Research Procedia, Elsevier, 2017.

[12] Nguyen, H.H., Taneerananon, P., Luathep, P.: Approach to Identifying Black Spots Based on Potential Saving in Accident Costs, Engineering journal, 2015.

[13] Masayoshi, T., Wee, B.: Impact of vehicle speeds and changes in mean speeds on per vehicle-kilometer traffic accident rates in Japan, Faculty of Science and Engineering, Chuo University, IATSS Research, 2016.

[14] Hrvatske ceste: Brojenje prometa na cestama Republike Hrvatske godine 2018., Zagreb, 2019.

[15] Hrvatske ceste. Preuzeto sa: https://hrvatske-ceste.hr/hr/stranice/promet-i-sigurnost/dokumenti/69-metodologi ja -za-identifikaciju-opasnih-mjesta-u-cestovnoj-prometnoj-mrezi (Pristupljeno: listopad 2020.)

[16] Ghadi, M., Török, Á.: A comparative analysis of black spot identification methods and road accident segmentation methods, Budapest University of Technology and Economics, Elsevier, 2019.

[17] Szenasi, S., Felde, I., Kertesz, G., Nadai, L.: Comparison of Road Accident Black Spot Searching Methods, John von Neumann Faculty of Informatics, Budapest, 2017.

[18] Ghadi, M., Török, Á., Tánczos, K.: Integration of Probability and Clustering Based Approaches in the Field of Black Spot Identification, Faculty of Transport Engineering and Vehicle Engineering, 2019;63(1): 46–52

[19] Google karte. Preuzeto sa: https://www.google.hr/maps (Pristupljeno: kolovoz 2020.)

[20] Hrvatski auto klub. Preuzeto sa: https://www.hak.hr/sigurnost-u-prometu/projekti/eurorap/karta-rizika-2010-2012 (Pristupljeno: kolovoz 2020.)

Popis grafikona

Grafikon 1. Prikaz procjene rizika od nastanka prometnih nesreća na D7 u postocima 43

Popis slika

Slika 1. Proces upravljanja opasnim mjestima 11
Slika 2. Proces provedbe identifikacije opasnog mjesta 12
Slika 3. Prikaz segmentacije dionice na fiksne dijelove 29
Slika 4. Problem identifikacije opasnog mjesta koristeći metodu podjele na fiksne dijelove 30
Slika 5. Prikaz segmentiranja dionice metodom *Sliding window* 31
Slika 6. Prikaz pojednostavljene metode grupiranja 34
Slika 7. Usporedba metode grupiranja i metode podjele na fiksne dijelove 36
Slika 8. Prikaz državne ceste D7 41
Slika 9. Prikaz D7 na karti rizika 42
Slika 10. Prikaz podjele državne ceste D7 na fiksne dijelove 45
Slika 11. Prikaz segmentacijske metode *Sliding window* 48
Slika 12. Prikaz identificirane opasne dionice pomoću segmentacijske metode *Sliding window* 50
Slika 13. Usporedba utjecaja duljine segmenta na preciznost identifikacije opasnog mjesta 54
Slika 14. Usporedba metode podjele na fiksne dijelove i *Sliding window* metode na raskrižju 55

Popis tablica

Tablica 1. Razine povjerenja k 9
Tablica 2. Prednosti i nedostaci pojedine metode segmentiranja ceste pri identifikaciji opasnih mjesta 35
Tablica 3. Tablični prikaz prometnog opterećenja na državnoj cesti D7 40
Tablica 4. Broj prometnih nesreća prema posljedicama u promatranom periodu 44
Tablica 5. Lokacije prometnih nesreća na državnoj cesti D7 od 2016. do 2018. godine definirane pomoću metode "Segmentiranje dionice na fiksne dijelove" 46
Tablica 6. Identificirana opasna mjesta segmentacijskom metodom podjele na fiksne dijelove 47
Tablica 7. Lokacije prometnih nesreća na državnoj cesti D7 od 2016. do 2018. godine definirane pomoću metode "*Sliding window*" 49
Tablica 8. Tablični prikaz identificiranih potencijalno opasnih mjesta segmentacijskom metodom *Sliding window* 51
Tablica 9. Usporedba broja identificiranih potencijalno opasnih mjesta 56
Tablica 10. Usporedni prikaz lokacija prometnih nesreća od 2016. do 2018. pomoću obje metode 56
Tablica 11. Prednosti i nedostaci segmentacijskih metoda podjele na fiksne dijelove i *Sliding window* metode 58

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu diplomskog rada pod naslovom **Komparativna analiza metoda segmentiranja cestovnih dionica pri identifikaciji opasnih mjesta** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 17.09.2020.

Student/ica:

(potpis)