Model prepoznavanja opasnih dionica na javnim cestama u područjima učestale pojave divljači

Vrkljan, Joso

Doctoral thesis / Disertacija

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:119:423440

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

JOSO VRKLJAN

MODEL PREPOZNAVANJA OPASNIH DIONICA NA JAVNIM CESTAMA U PODRUČJIMA UČESTALE POJAVE DIVLJAČI

DOKTORSKI RAD

Zagreb, 2020.



UNIVERSITY OF ZAGREB

FACULTY OF TRANSPORT AND TRAFFIC SCIENCES

JOSO VRKLJAN

MODEL FOR IDENTIFYING DANGEROUS SECTIONS ON PUBLIC ROADS IN AREAS OF FREQUENT APPEARANCE OF WILD

DOCTORAL DISSERTATION

Zagreb, 2020.

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

JOSO VRKLJAN

MODEL PREPOZNAVANJA OPASNIH DIONICA NA JAVNIM CESTAMA U PODRUČJIMA UČESTALE POJAVE DIVLJAČI

DOKTORSKI RAD

Mentori:

izv. prof. dr. sc. Dubravka Hozjan

prof. dr. sc. Krešimir Krapinec

Zagreb, 2020.

UNIVERSITY OF ZAGREB

FACULTY OF TRANSPORT AND TRAFFIC SCIENCES

JOSO VRKLJAN

MODEL FOR IDENTIFYING DANGEROUS SECTIONS ON PUBLIC ROADS IN AREAS OF FREQUENT APPEARANCE OF WILD

DOCTORAL DISSERTATION

Supervisors:

Assoc. Prof. Dubravka Hozjan, PH. D.

Prof. Krešimir Krapinec, PH. D.

Zagreb, 2020.

INFORMACIJE O MENTORIMA

Izv. prof. dr. sc. Dubravka Hozjan
Sveučilište u Zagrebu Fakultet prometnih znanosti

Izv. prof. dr. sc. Dubravka Hozjan, rođena je 1958. u Sisku. U Zagrebu je završila osnovnu školu i IX. gimnaziju. Godine 1976. upisala je Građevinski fakultet Sveučilišta u Zagrebu – prometno usmjerenje na studiju visoke stručne spreme. Godine 1983. završila je program studija i stekla stručni naziv diplomiranog inženjera građevinarstva.
Na Fakultetu prometnih znanosti Sveučilišta u Zagrebu radi od 1983. godine do danas.
Upisala je poslijediplomski znanstveni studij pri Građevinskom fakultetu Sveučilišta u Zagrebu na smjeru Prometnice s prometnom tehnikom i 1995. godine obranila znanstveni magistarski rad te stekla akademski naziv magistar znanosti iz područja građevinarstva.
Doktorski rad obranila je na Fakultetu prometnih znanosti 6. travnja 2007. i stekla akademski naziv doktora znanosti iz znanstvenog područja tehničke znanosti, znanstvenog polja tehnologija prometa i transport, znanstvena grana cestovni i željeznički promet.
Nositeljica je nekoliko kolegija na diplomskom studiju, te kolegija Prometnice velikih brzina na poslijediplomskom doktorskom studiju i Urbani tračnički sustavi na poslijediplomskom specijalističkom studiju. Bila je komentorica na jednom doktorskom radu.
Pročelnica je Odsjeka Promet. Članica je Hrvatskog znanstvenog društva za promet, a 2010. godine izabrana je za redovitog člana Znanstvenog vijeća za promet Hrvatske akademije znanosti i umjetnosti.
Do sada je objavila je preko dvadeset znanstvenih radova.
Služi se engleskim i njemačkim jezikom.

Prof. dr. sc. Krešimir Krapinec
Šumarski fakultet Sveučilišta u Zagrebu

Prof. dr. sc. Krešimir Krapinec rođen je 1973. u Zagrebu. U Koprivnici je završio osnovnu i srednju ekonomsku školu. Diplomirao je 1996., magistrirao je 2001., doktorirao je 2005. na Šumarskom fakultetu Sveučilišta u Zagrebu. Na Šumarskom fakultetu Sveučilišta u Zagrebu radi od 1997. godine do danas. U znanstveno-nastavno zvanje redoviti profesor/prvi izbor izabran je 2017. Znanstveno istraživačku djelatnost do sada je razvijao i razvija u sklopu 17 znanstvenih projekata. Do sada je samostalno ili u suautorstvu objavio preko 60 znanstvenih rada različitih kategorija, Kao mentor sudjelovao je u izradi dva doktorska rada, jednom stručnom magistarskom radu, 26 diplomskih i 10 završnih radova. Sudjelovao je na 36 međunarodnih znanstvenih skupova.

Član je strukovnih udruga te različitih stručnih povjerenstava, od čega dva nacionalna (Stalno nacionalno povjerenstvo za ocjenu trofeja i izložbe CIC—a pri HLS-u, Stručna komisija za ustanovljenje državnih lovišta, Zamjenik predsjednika ispitnog povjerenstva u području Lovstvo, Hrvatske komore inženjera šumarstva i drvne industrije) te tri županijska povjerenstva. Samostalno ili kao član stručnih komisija izradio je preko 80 elaborata s područja lovnog gospodarenja.

Aktivno se služi njemačkim i engleskim jezikom. Oženjen je i otac troje djece.

Doktorski rad s naslovom

Model prepoznavanja opasnih dionica na javnim cestama u područjima učestale pojave divljači

obranjen je dana 15.07.2020. godine na Fakultetu prometnih znanosti Sveučilišta u Zagrebu pred Povjerenstvom u sastavu:

1. izv. prof. dr. sc. Danijela Barić, predsjednica,
2. izv. prof. dr. sc. Dubravka Hozjan, mentorica,
3. prof. dr. sc. Krešimir Krapinec, mentor i vanjski član (Šumarski fakultet Sveučilišta u Zagrebu),
4. doc. dr. sc. Željko Šarić, član i
5. doc. dr. sc. Luka Novačko, član.

PODACI I INFORMACIJE O DOKTORANDU

1. **Ime i prezime** : mr. sc. Joso Vrkljan, dipl. ing.
2. **Datum, mjesto rođenja i OIB** : 24.05.1976., Gospić, 31446694479
3. **Naziv završenog fakulteta i godina diplomiranja** : Sveučilište u Zagrebu, Fakultet prometnih znanosti, 2002.
4. **Naziv završenog poslijediplomskog magistarskog studija i godina magistriranja** : Tehničko-tehnološki sustavi u prometu i transportu, 2010.
5. **Naziv poslijediplomskog doktorskog studija** : Tehnološki sustavi u prometu i transportu

INFORMACIJE O DOKTORSKOM RADU

1. **Naslov doktorskog rada** : Model prepoznavanja opasnih dionica na javnim cestama u područjima učestale pojave divljači
2. **Fakultet na kojem je rad objavljen** : Sveučilište u Zagrebu, Fakultet prometnih znanosti

POVJERENSTVA, OCJENA I OBRANA DOKTORSKOG RADA

1. **Datum prijave teme** : 22.10.2018.
2. **Datum prihvaćanja teme** : 30.10.2018.
3. **Javna obrana nacrta doktorskog rada** : 20.11.2018.
4. **Mentori** : izv. prof. dr. sc. Dubravka Hozjan (Fakultet prometnih znanosti) i prof. dr. sc. Krešimir Krapinec (Šumarski fakultet Sveučilišta u Zagrebu)
5. **Povjerenstvo za ocjenu doktorskog rada** :

- izv. prof. dr. sc. Danijela Barić, predsjednica,
- izv. prof. dr. sc. Dubravka Hozjan, mentorica,
- prof. dr. sc. Krešimir Krapinec, mentor i vanjski član (Šumarski fakultet Sveučilišta u Zagrebu),
- doc. dr. sc. Željko Šarić, član,
- doc. dr. sc. Luka Novačko, član i
- prof. dr. sc. Goran Zovak, zamjena.

6. **Povjerenstvo za obranu** :

- izv. prof. dr. sc. Danijela Barić, predsjednica,
- izv. prof. dr. sc. Dubravka Hozjan, mentorica,
- prof. dr. sc. Krešimir Krapinec, mentor i vanjski član (Šumarski fakultet Sveučilišta u Zagrebu),
- doc. dr. sc. Željko Šarić, član,
- doc. dr. sc. Luka Novačko, član i
- prof. dr. sc. Goran Zovak, zamjena.

7. **Lektor** : Anela Serdar Pašalić, prof.

8. **Datum obrane doktorskog rada** : 15.07.2020.

SAŽETAK

Uočen je trend povećanja prometnih nesreća naleta vozila na divljač koji zahtijeva prijedloge mjera kako bi se prevenirala pojava divljači na rizičnim dionicama cesta. Da bi se došlo do određenih mjera spriječavanja naleta vozila na divljač, potrebno je prepoznati rizične dionice cesta s obzirom na mogućnost pojave divljači. U tom smislu razvijen je model prepoznavanja opasnih dionica na javnim cestama i istražene su mjere učinkovitog gospodarenja cestovnom mrežom koje će doprinijeti smanjenju pojave divljači na cestama.

Zbog velikog raspona nadmorskih visina (0 – 1 011 m. n. v.) cestovne mreže, klimatskih razlika, različitosti konfiguracije terena te obitavanja svih vrsta divljači Republike Hrvatske, istraživanje doktorskog rada provedeno je na cestama Ličko-senjske županije.

U razdoblju istraživanja najveći broj nesreća naleta vozila na divljač dogodio se na državnim cestama i uzrok nesreća uglavnom je bila krupna divljač. Stoga su modeli napravljeni na državnim cestama za krupnu divljač, srnu običnu i divlju svinju te za krupnu divljač ukupno.

Posebna pažnja posvećena je vremenskim i prostornim obrascima naleta vozila na divljač koji su poslužili kao podloga razvoja modela prepoznavanja opasnih dionica od pojave divljači. Analiziranje prostornih obrazaca daleko je složenije od vremenskih obrazaca i zahtijevalo je upotrebu velikog broja nazavisnih varijabli, odnosno pretkazivača (pretkazivači ceste, krajobraza, reljefa, brojnosti divljači i broj naleta u ćeliji).

Kako bi se dobio što precizniji i pouzdaniji model prepoznavanja opasnih dionica od pojave divljači ceste su podijeljene na dionice te su oko središta dionica ucrtani krugovi/ćelije određenih polumjera. Za svaku ćeliju određene su nezavisne varijable odnosno (pretkazivači). Prostorni podaci su pripremljeni i obrađeni u programskom paketu ArcGIS 9.2.

U doktorskom radu predložene su dvije vrste modela prepoznavanja opasnih dionica od pojave divljači, i to model procjene vjerojatnosti naleta i model procjene broja naleta vozila na divljač. Za izbor najpouzdanijeg modela prepoznavanja opasnih dionica od pojave divljači korišten je Akaike Information Criterion (AIC). Izbor pouzdanog modela uslijedio je ukoliko je $\Delta AIC < 2$ jedinice. Isto tako je određena i Akaike-ova težina (w_i), koja predstavlja vjerojatnost da je model najbolji odnosno najpouzdaniji u usporedbi s ostalim modelima. Rizične dionice cesta od pojave divljači rangirane su višekriterijskom analizom primjenom analitičkog hijerarhijskog procesa (AHP metodom).

Na osnovi provedenog istraživanja definirani su modeli procjene vjerojatnosti naleta i modeli procjene broja naleta vozila na divljač koji se temelje na pouzdanim podacima naleta vozila na divljač u istraživanom razdoblju.

Svaki model za sebe relativno je manjkav. Prvi tip modela (model procjene vjerojatnosti naleta) dosta precizno procjenjuje vjerojatnost nastanka naleta. Ako se za procjenu vjerojatnosti naleta koristi i drugi model (model procjene broja naleta), tada kombinacija ova dva tipa modela daje dosta visoku točnost u procjeni opasnih dionica od naleta vozila na divljač.

Modeli će omogućiti pravnim osobama koje gospodare javnim cestama da dobiju prikaz opasnih dionica i djeluju preko mjera održavanja i opremanja cesta na sigurnost prometa.

Terenskim istraživanjem na kritičnim dionicama cesta ispitan je utjecaj pojedinih mjera održavanja na pojavu divljači na cestama. Predložen je novi postupak održavanja javnih cesta s kojim bi se smanjili prelasci divljači preko javnih cesta.

Predloženi model prepoznavanja opasnih dionica na javnim cestama i postupak održavanja funkcionalno su provjereni na mreži javnih cesta Ličko-senjske županije.

Ključne riječi: sigurnost prometa, nalet vozila na divljač, državne ceste, model prepoznavanja opasnih dionica

EXTENDED SUMMARY

Along with the increase in the number of road motor vehicles there is also an increase in the number of collisions of vehicles and wildlife (WVC) that for some reason come out onto the road. The consequences of such collisions are sometimes very severe. Apart from material damage on the vehicle, wild animals also get injured, and there is great danger for human lives as well. The observed trend of the increasing number of traffic accidents involving collisions between vehicles and wildlife (WVC) requires proposals of measures in order to prevent the appearance of game at risky road sections. In order to take certain measures of preventing vehicle collision with the game (WVC), it is necessary to identify the high-risk road sections regarding the possible appearance of game. Therefore, a model of identifying dangerous sections on public roads, and measures of efficient management of the road network have been studied, and this will contribute to reducing the occurrence of wildlife on the roads.

In practice, the question of liability for the damage caused by wildlife in collision with the vehicles or the vehicles colliding with wildlife (WVC) is often raised. The law stipulates that the game are the assets of interest for the Republic of Croatia and has its protection. The game lives in the hunting grounds with roads passing through. The hunting grounds are managed by the hunting licensees or hunting right owners, who are either legal or natural persons (craftsmen). The legislation in the Republic of Croatia, related to this issue is based on four laws of the Republic of Croatia. The area of compensation for the damage and liability caused by the vehicle colliding with the game is regulated by the Hunting Act, the Roads Act, the Road Traffic Safety Act, and the Obligations Act. The judicial practice of passing judgements lacks uniformity and there are different court judgements both in the first and the second court instances. According to the verdicts, sometimes the driver is to blame and sometimes the hunting licensee, and sometimes the legal entity that manages the road on which the vehicle collided with the game.

The purpose of this doctoral thesis is to produce a maximally reliable model of forecasting the collision of vehicle with the wildlife (game) based on relatively easily accessible data.

The objective of research is to propose measures that would significantly increase the traffic safety and reduce the number of vehicle-game collisions (WVC).

Research hypotheses have been set, i.e. by in-depth analysis of data on traffic accidents caused by vehicle colliding with the game, it is possible to determine the elements of road and environment that highlight the high-risk sections of public roads and it is possible to develop a model of identifying the dangerous sections of public roads regarding the occurrence of wild animals on them.

Lika-Senj County, selected as the research area, has central geographical position, and therefore an important connecting significance within the Republic of Croatia. Lika-Senj County occupies 9,46 % of the Croatian territory. Most of the County belongs to the mountainous area and includes the mountains of Velebit, Plješivica and Velika and Mala Kapela. The area of the County includes also the karst fields separated by the mountain ridges: fields of Lika, Gacka, Krbava, Drežnica, Korenica, Lapacand Gračac. The County also includes the Adriatic coast as well as a part of the island of Pag, i.e. a part of the territorial sea (596,63 km^2 or 1.9 % of the Croatian sea area) and 2,29 km^2 of the island area or 0,07 % of the area of all the islands of the Republic of Croatia. The mainland area of the Lika-Senja County covers an area of 535 113 ha, and stretches from 0 to 1 738 metres above sea level. Considering the division of climate according to Köppen, several different climate types change in the entire Lika-Senj County (climate type Cfb – 85,6 % of the area; climate type Cfa – 6,7 % of the area and climate type Df – 7,7 % of the Lika-Senj County area). The dominant type of the game habitat in Lika-Senj County are forests, which make up 65 % i.e. together with shrubs, brake-grown areas, and heaths the closed habitats make up almost 70 % of the observed area. Carbonate rocks make up 74 % of the researched area, which makes this part of the research area porous in terms of precipitation retention. Consequently, and due to a large range of the altitudes of the road network (0 – 1 011 metres a.s.l.), climatic differences, differences in terrain configuration and habitat of almost all species of game in the Republic of Croatia, the research of the doctoral dissertation was conducted on the roads of the Lika-Senj County.

A prerequisite for determining the dangerous road sections regarding the occurrence of wildlife are the collected relevant data about the vehicle collisions with wildlife. The data on traffic accidents of vehicle collisions with wildlife have been collected by the employees of the Ministry of the Interior of the Republic of Croatia through going to the scene of accident, and for the purposes of this thesis the data have been collected by the Lika-Senj Police Department, i.e. police stations Gospić, Otočac, Senj, Donji Lapac, Korenica, Karlobag and Novalja. The data about vehicle collisions with wildlife have been taken from the police

records on vehicle collisions with wildlife in the time period from 2012. to 2016.. There are 63 established hunting grounds in this area, which are managed by slightly fewer hunting licensees (some hunting licensees lease two or more hunting grounds). In order to verify the accuracy of the obtained data the hunting licensees of the hunting grounds in the Lika-Senj County have been surveyed, and because of the sensitivity of the data that impact the value of the hunting grounds, no newer relevant data could be obtained.

In the research period there were 548 accidents involving vehicles colliding with wildlife, and the largest number of accidents of vehicle and wildlife collisions occurred on state roads, as many as 441, mostly collisions with roe deer (*Capreolus capreolus*) and wild boar (*Sus scrofa*). Having in mind the frequency of traffic accidents and the possibility of fatal outcomes of the traffic accidents, the work started on developing a model for recognizing dangerous sections on state roads, for the cases of collisions with roe deer, wild boar and large game in total.

Special attention was paid to the temporal and spatial patterns of vehicle collisions with wildlife that served as the basis for developing the model of recognizing the dangerous sections regarding the appearance of wildlife.

In order to determine the relevant minimum section length for the calculation of the collision probability estimate, state roads were divided into sections of 200, 500, 1 000, 2 000 and 12 000 m. Circles (cells) of radii of 100, 250, 500, 1 000 and 6 000 m were drawn around the centres of the sections and for each circle (cell) independent variables, that is, predictors were determined.

In developing temporal patterns regarding the time of the occurrence of vehicle – wildlife collision, the 24-hour day was divided regarding the time of dawn and dusk into day, night and dusk. The time of sunrise and sunset was calculated by means of the algorithm provided by the Zagreb Observatory website for every day of the research period. When calculating the lunar phases, the international standard of the US Maritime Oceanographic Portal (lunar cycle of eight lunar months) was used.

Analysing spatial patterns is far more complex than the temporal patterns and required the use of a large number of independent variables, i.e. predictors (predictors of the road, landscape, relief, number of wildlife, and number of collisions in the cell). The observed characteristics of the road included: average annual daily traffic (AADT), average summer daily traffic (ASDT) and curves parameter. The habitat data that were used included: share of water, shores, bare grounds, heaths and brake-grown areas, thickets, forests, grasslands, built-up land, neglected agricultural land, arable land. The index of topographic position (TPI or

TOPEX) was used for the relief as a predictor of topographic characteristics of road. Regarding the index of topographic position and slope, the terrain has been classified into six categories: valleys, less steep terrains, medium steep terrains, extremely steep terrains, upper parts of the slopes and ridges. The data on the number of wildlife are relatively unreliable as predictor of population density, and therefore the data on game shooting in individual hunting grounds were used; however, they have been reduced to the unit of the hunting area.

In order to obtain a maximally precise model of identifying dangerous sections on state roads, spatial patterns of vehicle collisions with large game were used. The spatial data were prepared in the software package Arc GIS 9.2., and processed in the software package Statistica 13.4.014 TIBCO Software Inc., 2018.

The doctoral thesis proposes two types of patterns of recognizing dangerous sections regarding appearance of wildlife. These are: collision probability estimate model and vehicle-game collision number estimate. For the selection of the most reliable model of recognizing dangerous road sections regarding appearance of wildlife the software tools Akaike Information Criterion (AIC) was used. The selection of a reliable model followed if $\Delta AIC < 2$ units. Akaike weight (w_i) was also determined, and it represents the probability that the model is the best, that is, the most reliable compared to other models. Logistic regression was used to calculate the prediction of the probability of a vehicle colliding with wildlife. AIC analysis provided collision estimate models for every cell radius separately, and the logistic regression provided reliability of the results in estimation percentages.

For the estimate of the collision probability with roe deer the smallest road section would be 2 000 m (cell radius 1 000 m), and the prediction accuracy is 68,20 %. The used independent variables (predictors) are the number of roe deer, share of the neglected agricultural land and the shares of bare land and the sea. The number of collisions with roe deer increases with the population density of roe deerfor radiiof 500 and 1 000 m, roe deer and wild boarfor radius of 250 m and wild boarfor radii of 6 000 m; the share of neglected agricultural land for sections of 500, 1 000 and 2 000 m; share of heaths and brake-grown areas on road sections of 500 and 1 000 m; distances from possible watering places (fresh water) on road sections of 500 and 1 000 m; AADT on sections of 500 and 12 000 m and with lower TPI (TOPEX) value, i.e. in valleys and less steep terrain, but this applies only to road sections of 12 000 m. The number of collisions with roe deer gets reduced with the increase of curves on a section (sections of 1 000 m) or road share (sections of 2 000 m); share of bare

land (on all sections, except sections of 12 000 m); share of the sea (on all sections, except sections of 12 000 m) and built-up land on sections of 500 m.

In the wild boar collision estimation model, AIC analysis provided quite a lot of collision estimation models for each cell radius separately, and the logistic regression gave reliable results only for road sections of 12 000 m. The collision probability on the section can be estimated in 73,33 % of cases. In the wild boar collision estimation model the game population density proved to be the key independent variable (predictor). The number of wild boar collisions will be larger if the population density of roe deer, wild boar or large game in total is higher; higher share of neglected agricultural land and higher ASDT. The number of collisions will be smaller if the share of built-up land is higher; higher share of forests; higher share of roads; higher share of the sea (exceptions are cells of radius of 6 000 m) and higher AADT.

For the models estimating the probability of collision with large game in total, all the large game killed during the research period were included as well as grey wolf (legally grey wolf is not game, but is included in the model development due to similar consequences of the collision). For models of estimating the collision probability with large game in total the wildlife population density as independent variable comes in all cell radii. Respecting the results of the logistic regression, it may be said that the shortest section on which the probability of collision with large game in total may be reliably determined is a section of 2 000 m. On this section it is possible to predict the collision of vehicle on wildlife with a certainty of 70,11 %, based on the relative density of game, share of bare land, share of the sea, and the proximity to the nearest watering place. The number of collisions with large game in total will be greater if the population density of roe deer or large game is higher; higher share of neglected agricultural land; higher share of heaths and brake-grown areas; greater distance to the watering place; higher AADT. The number of collisions on large game in total will be smaller if the road features more curves or more intersections; higher share of bare land; higher share of built-up land; higher share of the sea and more indented relief (higher TPI value).

Although the collision or non-collision location model can be estimated with an accuracy of 70,11 %, there are also certain model errors. Three outcomes of the model operation can be expected, and these are: the model has estimated correctly that on a certain section there will not occur or there will come to a collision; there were no collisions on the section during the research period, but the model predicted that a collision might occur there

(collision overestimation error) and on the section collisions were recorded during the research period, but the model predicts that no collision can occur there (collision underestimation error)

Each model for itself is relatively deficient. The first type of model (collision probability estimation) estimates quite accurately the collision occurrence probability. If another model were used for the collision probability estimation (estimation of the number of collisions) then the combination gives quite high accuracy in estimating the danger of vehicle collision with wildlife.

The proposed models will enable the legal entities that manage public roads to get a view of dangerous sections and to act through measures of maintaining and equipping the roads for traffic safety.

The road sections at risk of the appearance of wildlife have been ranked by multi-criteria analysis by applying the Analytic Hierarchy Process (AHP method), using the software tools Expert Choice. Before using the software tools the objective was set, and it is to rank the dangerous road sections on state roads of the Lika-Senj County regarding the appearance of wildlife. The criteria that have been used are the number of collisions, section length, number of collisions per 100 km and number of collisions per 100 km annually. Appropriate matrices have been developed comparing the criteria with each other in relation to the set objective and based on these the values from the Saaty evaluation scale were added. The program requires also setting of variants, and they are several dangerous sections.

Field research on critical road sections examined the impact of certain maintenance measures on the appearance of wildlife on the roads. The tested maintenance measures include installation of protective wire fences along the road; thorough cleaning of the protective road belt; mounting of optical and sound sensors on signposts; installation of adequate traffic signs – game on the road; planting of plant species that repel game, and also the impact of the location of game feeding grounds on the wildlife population density along the road was investigated.

A new public road maintenance procedure has been proposed that would reduce wildlife crossing the public roads by increasing the patrol hours on high-risk sections; installation of protective fences to prevent the appearance of wild animals on the roads; cleaning the full profile of road protection zone in order to reduce the occurrence of wildlife on the roads; planting of game-repellent plant species along the road; installation of optical

and sound sensors on signposts that drive off the game, and amendments to the Ordinance on traffic signs, signalization and road equipment.

By proving the set objective and hypotheses, this doctoral dissertation opens up the possibilities of further research in preventing the wildlife to appear on the roads by developing a model with and without large predators; classification of killed game by gender and estimated age of the individual; unification of temporal and spatial patterns; separation of spatial patterns of collision according to the season, time of day and phases of the moon. Furthermore, in further research it is of extreme importance to separately study the killing on the roads of fallow deer, as a separate species. According to the conducted research in this doctoral thesis, this is the game which suffers major casualties in vehicle collisions, although they are small in number and living in a confined area.

Key words: traffic safety, collision of vehicle and wildlife, state roads, model of identifying dangerous sections

SADRŽAJ

1. UVOD 1
1.1. Problem istraživanja 2
1.2. Cilj i hipoteze istraživanja 3
1.3. Osvrt na dosadašnja istraživanja 4
1.4. Znanstvene metode 15
1.5. Struktura doktorskog rada 16
2. PODRUČJE I METODE ISTRAŽIVANJA 18
2.1. Područje istraživanja 18
2.2. Javne ceste Ličko-senjske županije 26
2.2.1. Autocesta A1 (tunel Mala Kapela – tunel Sveti Rok) 27
2.2.2. Državne ceste Ličko-senjske županije 28
2.2.3. Županijske i lokalne ceste Ličko-senjske županije 29
2.3. Baza podataka o naletima vozila na divljač 29
2.3.1. Učestalost naleta vozila na divljač po kategoriji ceste 30
2.3.2. Učestalost naleta vozila na divljač po vrsti divljači 32
2.4. Anketa lovozakupnika rizičnih područja 34
2.5. Metodologija izrade vremenskih i prostornih obrazaca naleta vozila na divljač 35
2.5.1. Dosadašnja iskustva izrade vremenskih obrazaca naleta vozila na divljač 35
2.5.1.1. Sezonska dinamika naleta vozila na divljač 35
2.5.1.2. Dnevna dinamika naleta vozila na divljač 37
2.5.2. Dosadašnja iskustva izrade prostornih obrazaca naleta vozila na divljač 40
2.5.3. Podaci za analizu vremenskih obrazaca naleta vozila na divljač 43
2.5.4. Podaci za analizu prostornih obrazaca naleta vozila na divljač 46
2.6. Rezultati obrade podataka 51
2.6.1. Prostorni obrasci naleta vozila na glavne vrste krupne divljači za definiranje modela na istraživanom području 51
2.6.2. Vremenski obrasci naleta vozila na glavne vrste krupne divljači za definiranje modela na istraživanom području 58
3. MODEL PREPOZNAVANJA OPASNIH DIONICA 65
3.1. Prostorni obrazci naleta vozila na divljač i procjena naleta po dionicama ceste 67
3.1.1. Prostorni obrasci naleta vozila na srnu običnu 67
3.1.2. Prostorni obrasci naleta vozila na divlju svinju 78
3.1.3. Prostorni obrasci naleta vozila na krupnu divljač ukupno 91
3.1.4. Testiranje modela procjene naleta vozila na krupnu divljač 102
3.2. Diskusija dobivenih rezultata 111
3.2.1. Povezanost vremenskih obrazaca naleta s ponašanjem divljači 112
3.2.2. Povezanost prostornih obrazaca naleta s ponašanjem divljači 118

3.3. Višekriterijsko vrednovanje - AHP metodom opasnih dionica državnih cesta Ličko-senjske županije od pojave divljači 133
4. MJERE SPRJEČAVANJA ILI UBLAŽAVANJA NALETA VOZILA NA DIVLJAČ 138
4.1. Praćenje frekvencije prelaza divljači pomoću kamera („foto zamki“)..... 140
4.2. Postavljanje zaštitnih žičanih ograda uz cestu 141
4.3. Detaljno čišćenje zaštitnog cestovnog pojasa 144
4.4. Postavljanje optičkih i zvučnih senzora na smjerokazne stupiće..... 146
4.5. Postavljanje adekvatnih prometnih znakova – divljač na cesti 150
4.6. Sadnja biljnih vrsta uz cestu koje odbijaju divljač..... 151
4.7. Utjecaj lokacije hranilišta divljači na gustoću populacije divljači uz cestu..... 152
5. POSTUPAK ODRŽAVANJA JAVNIH CESTA U PODRUČJU OPASNOSTI OD POJAVE DIVLJAČI..... 154
5.1. Prijedlog postupka održavanja javnih cesta u području opasnosti od pojave divljači 155
5.1.1. Povećanje sati ophodarske službe na rizičnim dionicama 156
5.1.2. Postavljanje zaštitnih ograda radi sprječavanja pojave divljači na cesti 157
5.1.3. Čišćenje punog profila cestovnog zaštitnog pojasa radi smanjenja pojave divljači na cestama 158
5.1.4. Sadnja biljnih vrsta uz cestu koje odbijaju divljač 159
5.1.5. Postavljanje na smjerokazne stupiće optičkih i zvučnih senzora koji tjeraju divljač 160
5.2. Izmjena Pravilnika o prometnim znakovima, signalizaciji i opremi na cesti..... 161
6. ZAKLJUČAK..... 163
LITERATURA 170
POPIS SLIKA..... 183
POPIS TABLICA..... 185
POPIS GRAFIKONA 188
POPIS AKRONIMA..... 190
PRILOZI 192
ŽIVOTOPIS..... 197
POPIS OBJAVLJENIH RADOVA I KNJIGA..... 199

1. UVOD

Usporedno s porastom broja cestovnih motornih vozila povećava se i nalet vozila na divljač koja je iz bilo kojega razloga izašla na cestu. Posljedice takvih naleta katkad su vrlo teške. Osim materijalne štete na vozilu, stradava i divljač, a prijeti velika opasnost i za ljudske živote.

Iz dostupnih pokazatelja 2012. godine, prema podacima Ministarstva unutarnjih poslova (MUP), dogodilo se 858 prometnih nesreća naleta vozila na životinju [1]. Godine 2014. zabilježeno je 2 969 naleta vozila na životinje od čega je 2 333 naleta vozila na divljač u Republici Hrvatskoj (RH). Od ukupnog broja naleta vozila na divljač 2014. godine, nalet na srneću divljač je bio čak 1 705 puta [2]. Prema podacima s kojima raspolaže Hrvatski lovački savez 2017. godine broj slučajeva naleta vozila na divljač zabilježen je čak 3 789 puta [3].

Uvidom u evidenciju službenih podataka Croatia osiguranja s kojim je Hrvatski lovački savez sklopio policu osiguranja za slučajeve naleta vozila na divljač, brojke stvarnog stanja naleta vozila na divljač su zabrinjavajuće. U samo prvih šest mjeseci 2019. godine na javnim cestama u RH zabilježena su 1 522 slučaja naleta vozila na divljač za koji je prijavljena šteta i traženo njeno namirenje kroz policu osiguranja. Odšteta vozačima za navedena 1 522 naleta vozila na divljač iznosi vrtoglavih 13 715 125 kuna [4].

Iz dostupnih statističkih pokazatelja uočen je trend povećanja prometnih nesreća naleta vozila na divljač koji zahtjeva prijedloge mjera kako bi se prevenirala pojava divljači na rizičnim dionicama cesta. Prema raspoloživim podacima, uočava se kako broj naleta vozila na divljač značajno raste iz godine u godinu. Šteta se mjeri u desecima milijuna kuna, jer se pri izračunu štete mora uzeti i tržišna vrijednost uginule divljači zbog naleta motornog vozila, šteta na motornom vozilu te šteta od ozljeda vozača i putnika u motornim vozilima.

U praksi se često postavlja pitanje odgovornosti za štetu koju prouzroči divljač naletom na vozila ili vozilom na divljač. Zakonom je normirano da je divljač dobro od interesa za Republiku Hrvatsku i ima njezinu zaštitu. Divljač obitava u lovištima kroz koja prolaze ceste. Lovištima upravljaju lovoovlaštenici ili ovlaštenici prava lova, koji su pravna ili fizička osoba (obrtnik). Zakonska regulativa u Republici Hrvatskoj, vezana za ovu problematiku, zasniva se na četiri Zakona Republike Hrvatske. Područje naknade štete i odgovornosti uzrokovanih naletom vozila na divljač regulirano je Zakonom o lovstvu, Zakonom o cestama, Zakonom o sigurnosti prometa na cestama i Zakonom o obaveznim

odnosima. Sudska praksa donošenja presuda je neujednačena. U praksi dolazi do različitih sudskih presuda i prvog i drugog stupnja suda. Po presudama, negdje je kriv vozač, negdje lovoovlaštenik, a negdje pravna osoba koja gospodari cestom na kojoj se desio nalet vozila na divljač. Osim zakonske regulative tu je i Nacionalni program sigurnosti cestovnog prometa RH kojega prioritetno treba poštivati.

Jedna od mjera sprječavanja naleta vozila na divljač je učinkovito gospodarenje cestovnom mrežom koje podrazumijeva ažuriranu informacijsku bazu podataka i određeni postupak održavanja cesta koji bi se osobito primjenjivao na cestovnim dionicama u području učestale pojave divljači. Točan, odnosno prihvatljiv model prepoznavanja opasnih dionica, kao i razvijeni postupak održavanja javnih cesta u smislu izbjegavanja naleta vozila na divljač danas gotovo da i ne postoji.

Upravo iz tog razloga, u ovom doktorskom radu predloženi su modeli prepoznavanja opasnih dionica koji uzimaju u obzir sve dostupne vremenske i prostorne podatke s ciljem izbora najpouzdanijeg modela.

1.1. Problem istraživanja

Nalet vozila na divlje životinje ili nalet vozila na divljač dosta je česta pojava u Republici Hrvatskoj. Nalet vozila na divljač pričinjava veliku štetu i povlači za sobom brojne posljedice. Najučinkovitiji način smanjenja broja prometnih nesreća naleta vozila na divljač je točna identifikacija opasnih dionica na kojima je moguća pojava divljači te saniranje istih kroz mjere održavanja cesta.

Preduvjet za određivanje opasnih dionica od pojave divljači su mjerodavni podaci. Podatke o prometnim nesrećama naleta vozila na divljač prikupljaju djelatnici Ministarstva unutarnjih poslova Republike Hrvatske kroz izlaske na mjesto nesreće. Određenu bazu podataka vodi i Hrvatski lovački savez, ali uglavnom je sastavljena od podataka MUP-a i od dostave šturih podataka svojih članica. Veliki broj slučajeva naleta vozila na divljač se i ne prijavi pa stoga nisu nigdje ni evidentirani. Iako postoji određen broj mjerodavnih podataka, podaci o naletima vozila na divljač teško su dostupni i vrlo malo izlaze u javnost, uglavnom iz razloga što lovišta na čijem se području događa veliki broj naleta vozila na divljač teško pronalaze lovozakupnika.

Informacijski sustav MUP-a omogućuje pregled podataka o naletima vozila na divljač po zasebnim rubrikama. Problem nastaje kada je potrebno s određenom sigurnošću prepoznati na određenoj cesti opasnu dionicu od pojave divljači, jer informacijski sustav nema takvu mogućnost.

Osim problema nemogućnosti prepoznavanja opasnih dionica od pojave divljači problem je i sanacija tih dionica kroz mjere održavanja cesta. Društva kapitala koja imaju ugovore za redovno održavanje javnih cesta u Republici Hrvatskoj i pravne osobe koje gospodare javnim cestama nemaju nikakav uvid u opasne dionice od pojave divljači. Trenutne jedine mjere sprječavanja naleta vozila na divljač, koje se provode kroz redovno održavanje cesta su minimalne i neplanske, a to su uglavnom postavljanje prometnih znakova i čišćenje cestovnog pojasa u vrlo maloj širini od ruba ceste.

Temeljem uočenog problema i nedostataka dosadašnjih istraživanja određen je predmet istraživanja te su postavljeni cilj i hipoteze istraživanja.

1.2. Cilj i hipoteze istraživanja

Poznato je da divljač slobodnim načinom života u prirodi dnevno i sezonski migrira iz različitih potreba. Te potrebe mogu biti zbog hrane, parenja, podizanja mladunčadi ili (jednostavno) radi mira i odmora. Sve veća prisutnost cestovnih motornih vozila i izgrađenost svih oblika cesta nužno dovodi do situacije da divljač na svojim migracijskim putovima prelazi ceste. U tim trenutcima često dolazi do naleta vozila na divljač, pri čemu nisu rijetke tjelesne ozljede vozača i drugih sudionika u prometu.

Činjenica je kako je promet jedan od odlučujućih čimbenika ugroženosti populacije pojedinih životinjskih vrsta te je zbog sigurnosti svih sudionika u prometu nužno razviti metodologiju predviđanja potencijalnih mjesta naleta. Iako je do sada načinjeno dosta istraživanja glede ovisnosti i procjene značajnosti čimbenika na vjerojatnost naleta vozila na divljač generalnog modela još uvijek nema. Razlog tomu je što su istraživanja uglavnom bazirana na lokalnim stanišnim značajkama, rađena su u različitim regijama i klimatskim (stanišnim) zonama, a mjesta naleta bilježena su različitom razinom preciznosti.

Svrha ovoga doktorskog rada je razvijanje točnijeg modela predviđanja naleta vozila na divlje životinje, ali na temelju relativno lako dostupnih podataka. Danas su ovakvi modeli sve traženiji jer je nužno pronaći dijelove ceste s visokim rizikom naleta vozila na divljač.

Cilj istraživanja je predložiti mjere kojima bi se značajno povećala sigurnost prometa i smanjio broj naleta vozila na divljač. U tome smislu odredit će se značajke opasnih mjesta na javnim cestama vezano uz pojavu divljači a zatim izraditi model prepoznavanja opasnih dionica javnih cesta. Istraživanjem učinaka pojedinih mjera održavanja i opremanja javnih cesta predložit će se postupak održavanja dionica javnih cesta koje su identificirane kao opasne u smislu pojave divljači. Predloženi model prepoznavanja opasnih dionica javnih cesta s obzirom na pojavu divljači i predloženi postupak održavanja javnih cesta u području učestale pojave divljači provjerit će se na kritičnim dionicama javnih cesta Ličko-senjske županije (LSŽ).

Uz zadani cilj, postavljene su hipoteze istraživanja, a one su:

- dubinskom analizom podataka o prometnim nesrećama uzrokovanih naletom vozila na divljač moguće je odrediti elemente ceste i okoline koji ističu rizične dionice javnih cesta
- moguće je razviti model prepoznavanja opasnih dionica javnih cesta s obzirom na pojavu divljači na njima.

1.3. Osvrt na dosadašnja istraživanja

Ceste prolaze kroz prirodna staništa divljači pa svakim kilometrom novoizgrađenih cesta i svakim novoregistriranim vozilom povećava se vjerojatnost naleta vozila na divljač. Problem povećanja broja naleta vozila na divljač izražen je kako na području Republike Hrvatske, tako i na svjetskoj razini. U svijetu se i kod nas, radi aktualnosti problema, provode istraživanja uz ovu aktualnu problematiku.

Širenje cestovne mreže, povećanje gustoće prometa te sve veće brzine kretanja vozila, osobito u razvijenim zemljama, dovele su do jedne od ključnih nuspojava u prometu – naleta vozila na ljude [5] ili divlje životinje (divljač), bez obzira o kojoj skupini kralježnjaka se radi [6]. Prema podacima Shad i Rahimi u [6] svaki dan na prometnicama pogine 3 400 ljudi, a godišnje se ozlijedi ili onesposobi 10×10^6 ljudi. Osim toga, godišnje na prometnicama pogine preko $1{,}2 \times 10^6$ ljudi, a prema sadašnjim projekcijama trenda smrtnosti ljudi na prometnicama do 2030. godine - promet će biti sedmi uzrok smrtnosti čovjeka.

Ljudi u prometu ne moraju isključivo smrtno stradati od vozila. Seiler i Folkeson u [7] navode kako je u do 5 % naleta vozila na divljač posljedica ozljeda ljudi, a 10 do 15 naleta

godišnje završe s fatalnim ishodom za čovjeka. Sullivan u [8] istražuje uzroke prometnih nesreća sa smrtnim slučajevima u cestovnom prometu Sjedinjenih Američkih Država i iznosi da je 1990. godine bilo 106 smrtnih slučajeva u cestovnom prometu, pri čemu je sudar sa životinjom bio prvi štetni događaj, a analizom je ustanovljen trend povećanja od sedam dodatnih smrtnih slučajeva na godišnjoj razini. Godine 2007. smrtno su stradale 223 osobe, što je povećanje od 110 % u odnosu na 1990. godinu.

Koliki su intenziteti naleta vozila na divljač, dobro govori podatak u [9] da je do konca 80-tih godina u SAD-u na prometnicama dnevno stradavalo 1 milijun jedinki životinja. U Europi je ta brojka daleko manja, a ovisno o autorima se godišnje dogodi od pola milijuna [10] do preko milijun naleta vozila na kralježnjake [11]. Pokorny u [12] iznosi podatak da u Sloveniji strada između 4 000 – 6 000 jelena ili srna godišnje i to od 1999., kada Slovenija počinje bilježiti kontakte cestovnih vozila s divljači.

Saenz-de-Santa-Maria i Telleria u [13] iznose podatak da u Španjolskoj nesreće uzrokovane naletom vozila na divljač čine čak 8,9 % ukupnog broja cestovnih prometnih nesreća u razdoblju od 2006. do 2012. godine. Šprem i ostali su u [14], zabilježili 7 495 nesreća naleta vozila na divljač tijekom razdoblja od 2009. - 2012. godine u Republici Hrvatskoj. Istraživanje je provedeno sukladno teritorijalnoj distribuciji u odnosu na obitavališta divljih životinja, frekventnost dnevnog i noćnog prometa, sezonskog i izvansezonskog prometa (turistička sezona), te prema tipu javne ceste.

Generalno, većina stručnjaka se slaže kako je rast broja stradalih životinja na kopnenim prometnicama (cestama i željezničkim prugama) posljedica sve veće gustoće prometnica, brzine vozila, ali i brojnosti pojedinih životinjskih vrsta, osobito parnoprstaša (divlja svinja, srna obična, jeleni, muflon, divokoza), npr. u [11] i [15], a smrtnost životinja na prometnicama čini 1 do 12 % procijenjene veličine populacije određene vrste, odnosno 10 do 100 % godišnje odstrelne kvote [11]. Vivoda i ostali u [16] zaključuju da je jedan od najvažnijih uzroka naleta divljači na vozilo brzina vozila. Stoga su i naleti vozila na divljač najučestaliji na brzim javnim cestama. Sullivan u [17] provodi analizu odnosa broja prometnih nesreća, rasvjete prometnica i ograničenja brzine. Ramp i Roger u [18], osim općeg povećanja razine sigurnosti cestovnog prometa, usmjeravaju cilj istraživanja i poduzetih mjera na učestalost i razumijevanje razloga naleta vozila na životinju. Poduzimanje odgovarajućih mjera za sprečavanje naleta divljači na vozila je prijeko potrebno za prometnu sigurnost i očuvanje divljači. U cilju boljeg razumijevanja samog naleta, razvijene su različite metode, koje uzimaju u obzir ljudski čimbenik i značajke divljači. Yunteng i ostali su u [19]

dokazali da ograničenje brzine, značajke područja i blizina staništa divljači neposredno utječu na rizik naleta vozila na divljač.

Nadzor divljači s aspekta brojanja populacije također je važan element u predviđanju kretanja životinja blizu prometnica. U radu [20] Fabijanić i ostali ustanovljuju brojnost pojedinih vrsta divljači koje obitavaju na promatranom području i gustoću populacije po km^2. Međutim, učestalost naleta ovisi i o načinu korištenja zemljišta, odnosno nagle promjene u strukturi krajobraza. One mogu nastati i kao promjene u agrarnoj politici. Primjerice u Danskoj su najučestaliji naleti vozila na srneću divljač bili u razdoblju 1975. - 1978. godine jer je u sklopu poljoprivredne prakse većina oranica od žetve do 1. listopada bila pod strništima, a nakon toga je počelo preoravanje. Oranja prisiljavaju srnu na promjenu životnog prostora jer na njima ne nalazi hranu, tako da se u potrazi za hranom intenzivnije kreće [21]. Nadalje, većina srnjaka strada na granicama njihova teritorija tijekom parenja jer ceste mogu biti i granice njihovih teritorija, odnosno životnih prostora [22].

Od krupnih vrsta divljači na prometnicama uglavnom strada srneća divljač (64,7 % svih naleta prema [23]; 75 % svih naleta prema [14]), a na drugom je mjestu divlja svinja (9 % svih naleta prema [14]; odnosno čak 29,5 % svih naleta prema [23]). Jelen obični i jelen lopatar stradavaju u svega 2 % slučajeva [14]. Budući da je ovo relativno velik raspon udjela stradavanja pojedinih vrsta očito je da se on razlikuje od regije do regije. Tako je prema [24] u području središnje Hrvatske (Karlovačko područje) u 85 % slučajeva žrtva stradanja na prometnicama bila srneća divljač.

Prema podacima Ministarstva unutarnjih poslova (MUP) u Hrvatskoj u prvih 10 godina 21. stoljeća, broj naleta vozila na životinje je porastao za više od 400 % (s 575 u 1997. na 2 764 u 2007.). Iako, su u ovu evidenciju uključeni i naleti vozila na domaće životinje taj porast je vrlo velik.

Generalno, pod pojmom „nalet vozila na divljač“ podrazumijeva se nalet na bilo koju divlju životinju. Štete na vozilima, ozljede i smrtni ishodi za ljude uglavnom nastaju pri naletu životinje mase preko 30 kg [25] i [26].

U Belgiji 87 % sudara vozila sa životinjama završava s materijalnom štetom [27], a u Francuskoj su štete na vozilima iznosile 200×10^6 eura. Belgija (a osobito Valonija) je jedna o zemalja u Europi s najgušćom cestovnom mrežom (4,8 km/km^2) i gustoćom naseljenosti (209 $stanovnika/km^2$). Tijekom zadnjih desetljeća gustoća cesta se u toj zemlji rapidno povećala, broj vozila se udvostručio (1977. godine je bilo 3 315 071 vozila, a 2011. –

6 861 777 vozila), a paralelno s tim promjenama se povisila i gustoća populacije krupne divljači. Međutim, ovo ne mora i biti generalan trend. Tako je u Mađarskoj broj sudara divljih životinja i vozila (WVC) signifikantno rastao i u prosjeku je iznosio 1 418 naleta/godišnje (1,4 jedinke/km godišnje), no nakon 2007. je broj naleta počeo opadati usprkos tome što se gustoća cestovne mreže povećavala (od 2006. do 2011. se duljina mreže autoceste s 811 km povećala na 1 290 km [28]). Autori su u radovima [29], [30], [31] i [32] provodili istraživanja o tome kolika je materijalna šteta uslijed naleta vozila na divljač. Najnovije procijene materijalnih šteta u sudarima vozila s jelenima i losovima u SAD-u su veće od 3,5 mlrd. dolara na godišnjoj razini.

Fuller i Gill u [33] navode 6 glavnih razloga zbog kojih se gustoća populacije divljih parnoprstaša u zapadnoj Europi tijekom zadnjih 100 godina rapidno povećala:

- povećanje ploštine šuma i šumskih područja
- povećanje udjela ozimih žitarica na oranicama
- pad broja stoke (kao trofičkog konkurenta)
- promjene u lovnom gospodarenju (provođenje niza uspješnih reintrodukcija divljih parnoprstaša na području zapadne Europe)
- globalno zatopljenje i
- nestanak ili pad brojnosti krupnih predatora.

Većina fatalnih ishoda na prometnicama se događa u zemljama s niskim do srednjim primanjima stanovništva te rapidnim rastom mreže prometnica i inteziteta prometa, nastalim kao posljedica naglog ekonomskog rasta. Stradali u prometu su uglavnom mlade osobe u dobi 15 do 25 godina. Stoga su prometne nesreće vodeći uzrok prerane smrtnosti. Crne točke se mogu otkrivati raznim metodama, no nema generalnog postupka. Stoga se nameće potreba razvoja standardizirane tehnike koja bi omogućila objektivniju usporedbu podataka [5].

Prema Shad i Rahimi [5] prometne nesreće s ozljedama javljaju se uglavnom na udaljenostima 20 do 25 km od gradova zbog koncentracije industrije i nekontroliranih križanja te izlaza/ulaza s autocesta. Broj nesreća raste u područjima oko gradova.

Razlozi su:

- nekontrolirani izlazi i ulazi na cestu
- nekontroliran pristup cesti
- nazočnost pješaka.

Nesreće s fatalnim ishodima se događaju na udaljenostima oko 30 km od gradova. Razlozi tome su:

- umor vozača
- veće brzine vozila
- blizina urbaniziranih područja
- nekontroliran izlazak na cestu s imanja.

Naleti na životinje ne događaju se samo na prometnicama izvan urbanih cjelina. Rončević i Pintur su u [34] istražili 201 nalet vozila na divljač na području Grada Zagreba od 2008. do 2013. godine. I u drugim urbanim sredinama su obavljena istraživanja pa Pintur i ostali u [24] navode da je na karlovačkom području tijekom 2006. i 2007. godine zabilježeno 117 naleta na divljač. Najveći udio u nesrećama imaju srne (86 %).

Brojni su radovi koji se, bez obzira na klimatsku zonu, bave naletima vozila na pojedine vrste divljači, od vodozemaca i gmazova [6] i [35] do ptica i sisavaca [36]. Ako se usporede radovi Hell i suradnici [36], Šprem i ostali [14] te Glavaš [37] udio pojedine vrste u stradavanju na prometnicama znatno varira što govori da svaka dionica prometnice pokazuje specifičan spektar stradavanja životinja.

Sveobuhvatan spektar stradalih vrsta divljači nije moguće ustanoviti iz policijskih, lovačkih ili vozačevih izvješća nego jedino sistematskim višegodišnjim praćenjem jer vozači ne prijavljuju većinu naleta vozila na divljač [12] i [38].

Prema Hell i ostali [36] od ptica na prometnicama najučestalije stradavaju vrapci (*Passer* spp., 23,1 %), fazan - gnjetao (*Phasianus colchicus*; 4,1 %) i sovke (*Strigiformes*; 2,9 %).

Prema Seiler i ostali [39] na cestama najčešće stradavaju zečevi (*Lepus*spp) - (učestalost 30 %; prosječna frekvencija sudara izražena kroz godišnji broj naleta na 100 km cesta – MCF = 1,11); srneća divljač (učestalost 21 %; MCF = 0,77); jazavac *(Meles meles)*- (učestalost 11 %; MCF = 0,42) i crvena vjeverica (*Sciurus vulgaris)* - (učestalost 10 %; MCF = 0,38), dok su naleti vozila na divlju svinju, vidru ili ježa vrlo rijetki. Kod sitnih sisavaca prema [37] glodavci stradavaju preko 30 % te ježevi čak do 45,8 %.

U suvremenom krajobrazu zeleni pojasevi uz ceste predstavljaju izvrsna staništa za gniježđenje fazana [40], [41], [42]. Takvi tereni predstavljaju tzv. „ekološke klopke“ za gnijezdeće ptice jer stradaju prilikom košnje. Stoga je u Južnoj Dakoti zakonski regulirana

dinamika njihove košnje (zeleni pojasevi se ne smiju kositi prije 15. lipnja, u okruzima zapadno od rijeke Missouri, odnosno prije 10. srpnja, u okruzima istočno od rijeke Missouri).

Razlog „privlačenja“ divljači prema prometnicama ne treba biti samo zaklon. Istraživanja u [43] su pokazala da frekvencija naleta može ovisiti i o dostupnosti hrane u nekom području. Prema njihovim istraživanjima losovi se općenito kreću bliže cestama tijekom noći, nadalje, kreću se bliže manjim cestama pri čemu se mužjaci u prosjeku kreću bliže cestama nego košute.

Iako su dobili relativno oprečne podatke u odnosu na druge autore, Eldegard i ostali u [43] ističu kako još uvijek u potpunosti nije poznat mehanizam rizika izloženosti divljači čovjeku (buka, izravan rizik mortaliteta itd.), no činjenica je kako postoji visoka unutarvrsna ili, bolje rečeno, individualna varijabilnost u udaljenosti jedinke od ceste, što ukazuje na temeljnu plastičnost u ponašanju.

Povećan intenzitet prometa na lokalnoj razini je doveo do pada brojnosti pojedinih vrsta životinja u mnogim dijelovima svijeta. Međutim, izloženost stradanjima u prometu ovisi o načinu života životinje te staništu u kojima stradaju. Primjerice ježevi se u urbanim područjima kreću uzduž linearnih elemenata krajobraza koji čine ježeve ekološke koridore (prometnice, ograde, nasipi, živice) te izbjegava otvorena područja (npr. polja), a od staništa preferira naseljena područja. Sezonski gledano, ježevi najčešće stradaju tijekom srpnja [44]. Pri tome je ta brojka izrazito visoka. Na prometnicama u Belgiji godišnje strada između 230 000 i 350 000 jedinki tamnoprsog ježa *(Erinaceus europaeus)* [45].

Slične obrasce stradavanja pokazuju i vodozemci. Smeđa krastača *(Bufo bufo)* najčešće stradava u suburbanim područjima, zelena žaba *(Rana arvalis)* i vodenjaci (*Triturus* sp.) u ruralnim područjima, dok gatalinka *(Hyla arborea)* vrlo rijetko strada usprkos njenom terestričkom i migratornom načinu života [6].

Jazavac *(Meles meles)* također pokazuje specifičan obrazac stradanja na cestama. U Engleskoj učestalije stradavaju tijekom razdoblja siječanj - ožujak, a najmanje tijekom razdoblja srpanj - rujan [46]. Međutim, naleti nisu povezani s gustoćom prometne mreže nego s gustoćom prometa na cesti. Pri tome postoji određeni prag gustoće prometa kod kojeg učestalost naleta počinje signifikantno rasti.

U procjeni rizika naleta vozila na kunu bjelicu *(Martes foina)* Grilo i ostali su u [47] koristili tehniku troška površina („Cost surface“ – CS). Pri tome razlikuju dvije vrste krajobrazne povezanosti:

- Strukturna povezanost – odnosi se na prostorne obrasce krajobraznih elemenata.
- Funkcionalna povezanost – odnosi se na interakciju između obrazaca i bioloških značajki vrsta, kao što su sposobnost korištenja i kretanja između različitih krajobraznih elemenata i njihova rizika mortaliteta.

Primjerice glodavci i parnoprstaši naseljavaju isto područje, ali će imati različitu funkcionalnu povezanost s obzirom na razlike u veličini tijela, brzini kretanja i životnim putevima. U svom istraživanju Grilo i ostali u [47] za procjenu gustoće populacije kune bjelice nisu koristili lovnu statistiku nego su ovaj parametar utvrđivali na 44 primjerne plohe tako da su na ploče od 1 m^2 (1 x 1 m) postavljali mramorni prah i dijelove pilića, a lokacije su pregledavane svaki drugi dan tijekom 6 dana.

Suprotno dosadašnjim rezultatima istraživanja naleta vozila na divljač koji ukazuju kako kretanja jedinki među krpama (fragmentima) mogu rasti zbog fragmentacije staništa, Grilo i ostali [47] su istraživanjem dokazali kako u slučaju naleta vozila na kunu bjelicu učestalije nastaju na prometnicama koje presijecaju šumska područja (niska fragmentiranost staništa). Nadalje, dionice cesta s većim indeksom sinusoidnosti (zakrivljenosti) imala su učestalije nalete. Pretpostavlja se kako je uzrok tome prekasno uočavanje opasnosti.

Jedna od čestih žrtva na cesti je i vidra *(Lutra lutra)*. Istraživanja u [48] PCA analizom (Principal component analysis), glavnih sastavnica, su dokazala kako postoje tri skupine značajki mjesta naleta vozila na vidru:

1. skupina – pozicije uz jezera, bez mostova, gdje je ograničenje brzine 100 km/h (44 % naleta)
2. skupina – područja do 200 m od ceste gdje nema vodenih površina, a ograničenje brzine je 100 km/h (35 % naleta) i
3. skupina – lokacije gdje vodotok presijeca cestu, dubina vodotoka je do 0,5 m, a nazočni su i propusti za vodu (20,5 % naleta).

Naleti vozila na vidru su, općenito, učestaliji na mjestima gdje vodotoci presijecaju cestu jer vidra izbjegava plivati vodotokom ispod ceste (mosta) nego napušta vodotok i prelazi ga preko ceste [49]. Postoje različita mišljenja o tome zašto pojedine jedinke vidre izbjegavaju preplivati kroz propuste ili ispod mostova, a mogući razlozi su:

- ispod mostova ili kroz propuste je brzina vode veća
- tzv. „učinak tunela“

- izostanak prirodnih obala ili kolnih platformi.

Izgradnja posebne infrastrukture koja služi isključivo prijelazu divljači važan je element kod projektiranja novih ili nadogradnje postojećih prometnica. Najčešće rješenje, a ujedno i najskuplje je izgradnja zelenih mostova na kojima se tada bilježe prijelazi životinja. Tako su Gužvica i Šver u [50] provjerili korištenje zelenog mosta Osmakovac i ustanovili da je od 16. rujna do 10. prosinca 2006. zabilježeno ukupno 8 404 prekida infracrvene zrake senzora za brojanje prijelaza preko mosta, od čega je 3 401 prijelaz (40,5 %) ostvaren tijekom noći. Prosječno je dnevno zabilježeno 99 prijelaza. Sudeći po trgovima najzastupljeniji su vukovi (26,9 %) i divlje svinje (22,1 %).

Iako pojedine populacije krupnih vrsta divljači (životinje veće od lisice – *Vulpes vulpes*) mogu biti izložene riziku naleta vozila na globalnoj razini to nije razlog da bi se promet smatrao značajnijom ugrozom za opstanak vrsta. Stoga su ciljevi smanjenja sudara vozila i divljači usmjereni ka podizanju sigurnosti u prometu, a ne na zaštitu vrsta. Stoga i provođenje mjera za ublažavanje posljedica naleta može dati nepredviđene ishode. Tako se ograđivanjem prometnica i izgradnjom prelaza za divljač (bez obzira jesu li ispod ili iznad ceste) broj naleta vozila na parnoprstaše može smanjiti za 80 %. No, kod krupnih zvijeri ograđivanje ne daje garanciju da će se naleti smanjiti jer se te vrste mogu penjati ili skakati preko ograde [51].

Prometnice su jedan od ključnih čimbenika smrtnosti velikih zvijeri. Razlog tome je specifičnost ponašanja ove skupine životinja koje se očituju kao mala veličina populacije, velik životni prostor te ponašanje, odnosno način života koji se kosi s interesima čovjeka. Stoga i ne čudi kako Colino-Rabanal i ostali u [52] primjenom logističke regresije i programskog alata Akaike Information Criterion (AIC) nisu uspjeli razviti precizniji matematički model za procjenu mjesta naleta vozila na vuka *(Canis lupus)*, no kao glavni čimbenici naleta mogu se izdvojiti brzina vožnje, gustoća prometa i blizina šume. S vremenskog gledišta vukovi na prometnicama učestalije stradavaju tijekom razdoblja studeni - travanj te od sumraka do zore.

Za razliku od vuka, smeđi medvjed *(Ursus arctos)* učestalije stradava na autocestama [53] te željezničkim prugama [54]. Te su prometnice uzrok 10 %-tne godišnje smrtnosti ove vrste. Štoviše, zbog već spomenutih specifičnosti u ponašanju velikih zvijeri prelazima na autocestama se ne može znatnije doprinijeti smanjenju vjerojatnosti naleta vozila na medvjeda [53] te prelazi uglavnom služe kao koridori u povezivanju populacija. U Hrvatskoj se broj

naleta vlaka na smeđeg medvjeda do sredine 90-tih godina 20. stoljeća utrostručio (s 0,78 grla/godišnje porastao je na 4,2 grla/godišnje), no usprkos tome teško je predvidjeti mjesta naleta jer topografske značajke nemaju značajan utjecaj na prelazak medvjeda preko pruga iako pri prelasku medvjed bira strmije terene. Vjerojatno je razlog veća udaljenost od ljudskih naselja [54].

Početak razvoja modela za prepoznavanje rizika naleta vozila na životinje u Europskim krugovima seže još na početak 60-tih godina 20. stoljeća kada su razni autori opisivali brojnost naleta po vrstama divljači. Tako su rađena istraživanja u srednjoj Europi, (Hartwig u [55], Ueckermann u [56]); zapadnoj Europi, (Clarke i ostali u [46], Jonkers i De Vries u [57], Van den Tempel u [58], Rodts i ostali u [59], Hansen u [60], Harris i ostali u [61], Van der Zee i ostali u [62]) i sjevernoj Europi (Bengtsson [63], Bolund [64], Göransson i ostali [65]). No, usprkos tome, vrlo je malo država počelo provoditi sustavno praćenje ovih stradanja, odnosno uglavnom su ograničena na policijska izvješća u kojima se bilježe naleti na krupnije vrste, naleti s materijalnom štetom ili ozljedama putnika [39]. Yunteng i ostali u radovima [66] i [67], razvijaju nove algoritme i metode obrade prikupljenih podataka, koristeći podatke agencije koja prati statistiku o vrstama životinja stradalih u prometu (domaća ili divlja) i vremenu naleta vozila na životinju i podatke službe koja je zadužena za uklanjanje lešina divljači sa ceste i sa pojasa ceste.

Tijekom razvoja istraživanja interakcije prometnica i divljači spoznaje o mehanizmima stradavanja životinja znatno su proširene tako da se danas može govoriti o novoj grani ekologije - ekologiji prometnica. Međutim, brojanje stradalih životinja pored ceste ili izmjera veličine ekološkog učinka ceste samo po sebi ne daje dovoljno podataka o tome koje ceste i koja vozila ugrožavaju određenu vrstu divlje životinje. Stoga temeljni parametar mora biti dugoročna životna aktivnost susjednih populacija što zahtjeva podatke o veličini populacije, stope vitalnosti i stupnja povezanosti između subpopulacija [68].

Generalno, prostorne zakonitosti naleta vozila na divljač je dosta teško procijeniti stoga je temeljni zadatak prevencije naleta procjena razdoblja naleta [35].

S obzirom na različite klimatske zone izloženost pojedinih taksonomskih skupina kralježnjaka naletima vozila se mijenja. Dok u umjerenim područjima uglavnom stradavaju sisavci (osobito parnoprstaši) u tropskom području učestalije stradavaju gmazovi i ptice i to tijekom kišnog razdoblja (parenje i migracija).

Moen u [69] istražuje novi sustav promatranja prometnica i područja prijelaza divljači. Razmatrani sustav omogućava identifikaciju vrsta divljači koje prelaze prometnice, učestalost prijelaza, ponašanje životinja na cesti i u blizini cesta i reakcije vozača na moguću opasnost od naleta životinje.

Interakcija prometnica (osobito cesta) i divljači može imati pozitivan i negativan predznak [68] i [70], a očituje se kroz niz promjena:

- u životnom prostoru
- u obrascima kretanja
- u reproduktivnom uspjehu
- u fiziološkom stanju.

Izraziti negativan utjecaj očituje se kroz :

- smanjenje propusnosti krajobraza [71]
- utjecaj na dinamiku migracije životinjskih populacija, čime nastaju male izolirane populacije što dovodi do pojave zamršene dinamike te povećanje vjerojatnosti nestanka pojedinih izoliranih populacija [71]
- ograničenje u isparavanju vode sa ceste

  U usporedbi sa golim tlom na tvrdoj površini ceste isparavanje vode je usporeno što ima za posljedicu podizanje temperature gornje površine ceste.

  Budući da se cesta preko noći sporije hladi u odnosu na lokalno područje ona predstavlja „tople otoke“ koji privlače hladnokrvne (najčešće gmazove) te sitne toplokrvne organizme koji se na takvim površinama dolaze grijati [72].
- kemijske promjene u okolišu – očituju se kao povišeni sadržaj teških metala (olovo, ali i aluminij, željezo, kadmij, bakar, mangan, titan, nikal, cink i bor), soli (NaCL, CaCl, KCl, $MgCl_2$) i ozona (čime se povisuje i sadržaj štetnih molekula u zraku [73] i
- izravno povećanje mortaliteta [74].

Kao pozitivni učinci cesta na divljač mogu se navesti:

- bolji trofički uvjeti – vegetacija uz cestu može biti dobar izvor krmiva [75] te izvor mineralnih krmiva, npr. soli [76] i

- olakšano kretanje – u slučajevima dubokog snijega, na očišćenoj cesti je dubina snijega niža od okoline te životinja gubi manje energije pri kretanju cestom [77].

Ukoliko je krajobraz za neku populaciju propustan tada je distribucija jedinki na njemu slobodna, a dinamika populacije jednostavna i panmiktična [78]. U populacijskoj genetici panmiksija predstavlja slučajno sparivanje unutar neke populacije, odnosno jedinke ne pokazuju sklonost izboru partnera s nekim posebnim značajkama. Kako raste fragmentacija staništa tako raste i utjecaj ruba staništa s kasnijim (subsekventnim) negativnim učincima na tzv. temeljne vrste. Temeljne vrste su sve vrste na koje antropogeno ugrožavanje ima značajan utjecaj.

Danas su sve veće intencije na omogućavanju propusnosti ceste, što podrazumijeva mogućnost kretanja životinje nekim krajobrazom bez signifikantnog utjecaja prometnice, odnosno mreže prometnica na kretanje jedinki [79].

Međutim, pozitivna strana cesta je da u intenzivnom poljoprivrednom krajobrazu uz cestu opstaju pojedine travnjačke biljne vrste koje su na poljima nepoželjne, a divljači služe za hranu [80].

Od početka 21. stoljeća broj publikacija koje se bave naletima vozila na divljač, bez obzira radi li se o izradi modela prostorno - vremenskih mehanizama naleta ili razvoju metoda njihova sprječavanja, je rapidno narastao [81].

Mammeri i ostali u [82] istražuju mogućnost uporabe robota i specijaliziranih vozila opremljenih ultrazvučnim senzorima i pametnim kamerama za detekciju divljači na i u blizini prometnica. U radovima [83], [84], [85] i [86] autori ispituju uređaje koji bilježe akustičnu jeku s ciljem određivanja pozicije i kretanja divljači, te bespilotne letjelice (dronove) opremljene naprednim uređajima za snimanje i nadzor kretanja divljači.

Upravljanje infrastrukturom na opasnim mjestima cestovne mreže istražuje Šimunović i ostali u radu [87]. Autori u radovima [88] i [89] nastoje statistički predvidjeti koje su lokacije najučestalijeg prelaska divljači. Istraživanja su pokazala da najveću učestalost naleta vozila na divljač imaju prometnice kroz šumska područja s relativno malo niskog raslinja, minimalnim brojem građevina blizu prometnica te na površinama s visokom razinom bioraznolikosti u okolišu. Istraživanja provedena u Kanadi (Ontario) [90] pokazala su da se 88,7 % naleta vozila na divljač događa na dvotračnim cestama. Nesreće su najbrojnije u mjesecu studenom i to najviše u ranim jutarnjim satima i pred zalazak sunca. Od 1994. do 2001. godine 42 osobe su smrtno stradale u naletima vozila na divljač na području države

Ontario. Zato je potrebno tražiti troškovno opravdane i učinkovite načine kako odrediti koje prometnice i dionice imaju prednost u pogledu provođenja mjera za smanjenje naleta na divljač, što proučavaju Ford i ostali autori u radu [91]. Složenu problematiku donošenja odluka o prometnoj infrastrukturi te analizu primjene metoda višekriterijske analize istražili su autori u radu [92].

1.4. Znanstvene metode

U doktorskom radu, na temelju postavljenog problema, cilja i hipoteze istraživanja, prezentiranim rezultatima istraživanja u odgovarajućoj mjeri su primjenjene slijedeće znanstvene metode:

- **povijesna metoda,** korištena je u vidu preuzimanja tuđih spoznaja, opažanja, razmišljanja;
- **metoda kompilacije,** korištena je na temelju rezultata prethodnih znanstveno istraživačkih radova na temu naleta vozila na divljač;
- **metoda anketnog upitnika,** korištena je prilikom ankentiranja lovozakupnika s rizičnih područja, iz razloga da se provjeri točnost podataka dobivenih iz javnih izvora;
- **metoda klasifikacije**, korištena je za izvršenje klasifikacije naleta vozila na divljač, po vrsti javne ceste i klasifikacije po vrsti divljači;
- **metoda deskripcije,** za opisivanje predmeta istraživanja i pojedinih postupaka u doktorskom radu, kao što je način izrade prostornih i vremenskih obrazaca naleta vozila na divljač;
- **metoda analize i sinteze,** kojima je predloženo više modela iz razloga da se dobije jedan pouzdan model prepoznavanja opasnih dionica cesta od pojave divljači;
- **matematička i statistička metoda,** omogućile su analizu pojedinih parametara na temelju prikupljenih vjerodostojnih podataka, kao i razvoj modela prepoznavanja opasnih dionica od pojave divljači;
- **metoda modeliranja,** kojom je razvijen model kao odgovor na istraživanje doktorskog rada;
- **AHP metoda,** kojom su višekriterijski vrednovane opasne dionice od pojave divljači;

- **metoda promatranja,** korištena je za prikupljanje informacija pomoću kamera o učincima pojedinih mjera održavanja na pojavu divljači na cestama;
- **metoda generalizacije,** za donošenje zaključaka.

1.5. Struktura doktorskog rada

Struktura doktorskog rada podijeljena je u šest poglavlja.

U **UVODU** opisan je problem istraživanja te su određeni svrha i ciljevi istraživanja. Prikazana su dosadašnja istraživanja. Definirane su znanstvene hipoteze. Na kraju poglavlja prikazana je struktura doktorskog rada.

U poglavlju **PODRUČJE I METODE ISTRAŽIVANJA** obrađeno je područje istraživanja, kao i mreža javnih cesta Ličko-senjske županije. Prikupljeni su mjerodavni podaci o naletima vozila na divljač te su zbog provjere dobivenih podataka iz javnih izvora anketirani lovozakupnici rizičnih područja. Provedeno je filtriranje i grupiranje podataka te objašnjena metodologija izrade prostornih i vremenskih obrazaca naleta vozila na divljač. Izneseni su obrađeni prostorni podaci o naletima vozila na divljač u istraživanom razdoblju po vrsti divlje životinje i vremenski obrasci naleta vozila na divljač s istraživanog područja.

U trećem poglavlju **MODEL PREPOZNAVANJA OPASNIH DIONICA** napravljeni su modeli procjene vjerojatnosti naleta i modeli procjene broja naleta vozila na divljač na istraživanom području. Modeli su napravljeni na primjeru dvije vrste krupne divljači, koja najviše stradava na javnim cestama Ličko-senjske županije (srna obična i divlja svinja), kao i na primjeru krupne divljači ukupno. Provjerom pouzdanosti razvijenih modela određen je najpouzdaniji model prepoznavanja opasnih dionica od pojave divljači. U nastavku poglavlja napravljeno je testiranje modela procjene naleta i provedena je diskusija o predloženom modelu prepoznavanja opasnih dionica od pojave divljači. Na kraju ovog poglavlja napravljeno je višekriterijsko vrednovanje opasnih dionica državnih cesta u Ličko-senjskoj županiji od pojave divljači, primjenom AHP metode.

Naslov četvrtog poglavlja je **MJERE SPRIJEČAVANJA ILI UBLAŽAVANJA NALETA VOZILA NA DIVLJAČ.** U ovome poglavlju ispitan je utjecaj mjera održavanja cesta na pojavljivanje divljači na cestama Ličko-senjske županije. Na pojedinim kritičnim dionicama javnih cesta provedene su sljedeće mjere: postavljanje žičane ograde uz cestu, detaljno čišćenje cestovnog pojasa, sadnja biljnih vrsta koje odbijaju divljač, postavljanje

optičkih i zvučnih senzora na smjerokazne stupiće, postavljanje adekvatnih prometnih znakova. Navedene mjere nadzirane su pomoću lovačkih nadzornih kamera, te je provjeren njihov učinak. Ispitan je i utjecaj lokacije hranilišta na gustoću populacije divljači uz cestu.

Peto poglavlje **POSTUPAK ODRŽAVANJA JAVNIH CESTA U PODRUČJU OPASNOSTI OD POJAVE DIVLJAČI** na temelju ispitanih mjera spriječavanja naleta vozila na divljač daje prijedlog postupka održavanja javnih cesta u području pojave divljači kroz povećanje sati ophodarske službe, postavljanje zaštitne ograde, čišćenje punog profila cestovnog zaštitnog pojasa, sadnju bilja koje odbija divljač, postavljanje optičkih i zvučnih senzora. Također se predlažu izmjene aktualnog Pravilnika o prometnim znakovima, signalizaciji i opremi na cesti.

U zadnjem, šestom poglavlju **ZAKLJUČAK** prikazani su najvažniji rezultati istraživanja te je istaknut znanstveni doprinos doktorskog rada.

Na kraju doktorskog rada nalazi se popis korištene literature, popis slika, tablica, grafikona, akronima i prilozi doktorskog rada.

2. PODRUČJE I METODE ISTRAŽIVANJA

Za istraživanje doktorskog rada potrebno je odabrati područje koje zadovoljava kriterije određenog broja naleta vozila na divljač i dostupnost tih podataka. Područje sa svojim značajkama razvedenosti terena, klimatskim čimbenicima i vrstama divljači koje obitavaju u njemu mora pokrivati i druga područja, te se mjerodavnim istaknuo prostor Ličko-senjske županije. U doktorskom radu istraženo je stradavanje divljači i ostalih životinjskih vrsta naletom vozila na javnim cestama Ličko-senjske županije tijekom razdoblja od 2012. godine do 2016. godine. Radi osjetljivosti podataka koji utječu na vrijednost lovišta nisu se mogli dobiti noviji mjerodavni podaci.

Osnovni preduvjet za provedbu istraživanja su podaci koji sadrže dovoljno informacija na temelju kojih bi se mogle definirati značajke prometnih nesreća uslijed naleta vozila na divljač. Iz tog su razloga u doktorskom radu prikupljeni mjerodavni podaci iz znanstveno - stručne literature i podaci iz javnih izvora o naletima vozila na divljač.

Uz pretpostavku da neki slučajevi naleta vozila na divljač nisu evidentirani u javnim izvorima (odlazak vozača sa mjesta nesreće), anketom lovozakupnika s rizičnih područja provjerena je vjerodostojnost podataka.

Tijekom navedenog razdoblja obrađeno je 548 prometnih nesreća u kojima je sudjelovala divljač na javnim cestama Ličko-senjske županije. Rezultati istraživanja poslužili su kao osnova za izradu modela prepoznavanja opasnih dionica od pojave divljači, kako za lovoovlaštenike (pravna ili fizička osoba koja je stekla pravo lova), tako i za vozače, odnosno za sigurnost prometa na cestama.

2.1. Područje istraživanja

Područje istraživanja doktorskog rada je područje Ličko-senjske županije. U ukupnom prostoru Republike Hrvatske Ličko-senjska županija ima izuzetno značenje. Ličko-senjska županija ima središnji geografski položaj, a samim time i važno spojno značenje unutar Republike Hrvatske. Ličko-senjska županija zauzima 9,46 % površine Republike Hrvatske. Teritorij Ličko-senjske županije je smješten između Karlovačke županije na sjeveru, Primorsko-goranske na sjeverozapadu, Jadranskog mora na zapadu, Zadarske županije na jugoistoku i jugu, a na istoku je Bosna i Hercegovina (*slika 1.*).



Slika 1. Položaj Ličko-senjske županije u Republici Hrvatskoj

Izvor: [93]

Veći dio županije pripada planinskom predjelu i obuhvaća planine Velebit, Plješivicu i Kapelu. Područje županije čine i kraška polja odijeljena planinskim grebenima, a to su: Ličko, Gacko, Krbavsko, Drežničko, Koreničko, Lapačko, Gračačko. Pod prostorom Županije je jadransko priobalje kao i dio otoka Paga. Ličko - senjskoj županiji pripada i dio teritorijalnog mora (596,63 km^2 ili 1.9 % hrvatskog morskog akvatorija), te joj pripada i 2,29 km^2 površine otoka ili 0,07 % površine svih otoka RH (*slika 2.*).



Slika 2. Pregledni prikaz Ličko-senjske županije s gradovima i općinama

Izvor: [93]

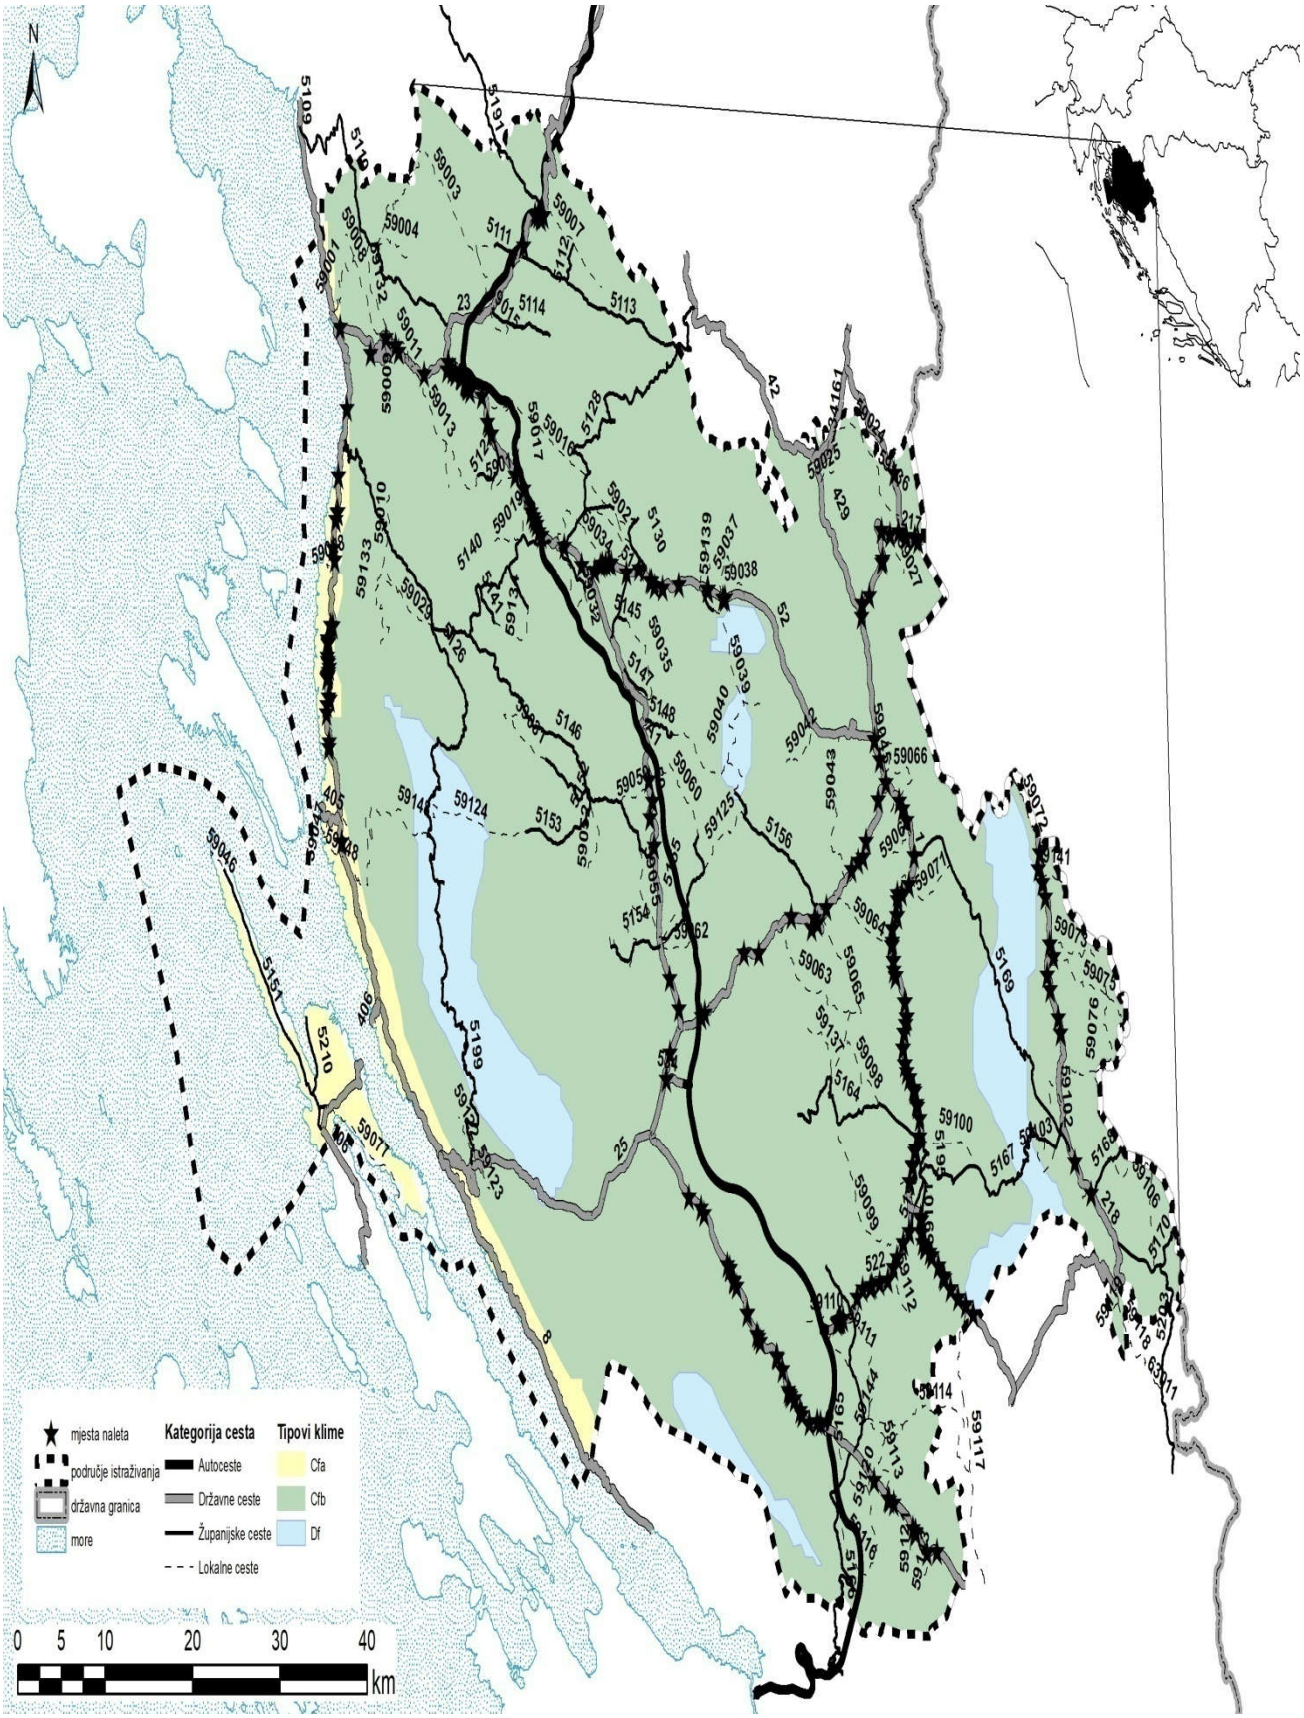
Kopneno područje Ličko-senjske županije ima ploštinu od 535,113 ha, a prostire se od 0 do 1 738 metara nadmorske visine. Može se generalno podijeliti na sredozemno i kontinentalno područje s time da se kontinentalni dio izdiže u gorski dio (prelazi 1 000 m nadmorske visine). Relativno velik raspon nadmorskih visina, odnosno izražen reljef te činjenica da se dio prostora nalazi i uz more definitivno ukazuje da postoje velike klimatske, odnosno stanišne razlike idući od mora prema sjeveru.

Upravo ovakav izražen reljef (tipičan za krška područja) uvjetovao je položaj glavnih cestovnih prometnica (autocesta i državnih cesta). Naime, cijelo područje je omeđeno s četiri dinarska masiva. Prvi je masiv Velebit, koji sa zapadne strane odjeljuje unutrašnje područje

od sredozemnog. Sa sjeverne strane masivi Velike i Male Kapele, a s istočne strane masiv Ličke Plješivice odjeljuju niži unutrašnji dio Županije od peripanonskog prostora.

Svi navedeni masivi imaju izražene grebene s visinom od preko 1 000 metara nad morem. Središnji dio istraživanog prostora čini (peti) kompleks Ličkog sredogorja, no on ne predstavlja masiv nego niz raštrkanih uzvisina od kojih neke premašuju nadmorsku visinu od 1 000 metara. Budući da je glavni smjer pružanja Dinarida sjeverozapad - jugoistok [94], smjer izmjene dinarskih lanaca ide okomito na njihovo pružanje. Upravo u tim udolinama smješten je veći dio državnih cesta (DC-8, DC-50 i DC-1), a već prema mogućnostima reljefa ove se ceste granaju te, zajedno sa županijskim i lokalnim cestama te autocestom čine mrežu prometnica od 4,13 km/1 000 ha (gustoća državnih cesta iznosi 1,23 km/1 000 ha).

S obzirom na podjelu klime prema Köppenu na cijelom se području Ličko-senjske županije izmjenjuje nekoliko različitih klimatskih tipova (*slika 3*.).



Slika 3. Karta tipova klime prema Köppenu na području Ličko-senjske županije

Prerađeno iz: [95] i [96]

Tipovi klime u Ličko-senjskoj županiji su:

- tip klime „Cfb“ - umjereno topla vlažna klima s toplim ljetom. Ovaj tip klime dolazi na 85,6 % područja
- tip klime „Cfa“ – sredozemna klima s vrućim ljetom vlada na području neposredno uz more. Prostorno gledano ovdje pripada područje otoka Paga te područje koje prati morsku obalu na kopnu, a kroz koje prolazi Jadranska magistrala, odnosno državna cesta DC-8. Ovo klimatsko područje rasprostire se na 6,7 % površine Županije
- tip klime „Df“ - vlažna borealna klima. Ovaj tip klime vlada na vršnim dijelovima Velebita i Ličke Plješivice, odnosno na 7,7 % površine Županije. Kroz ovo klimatsko područje ne prolazi niti jedna državna cesta nego samo lokalne i županijske.

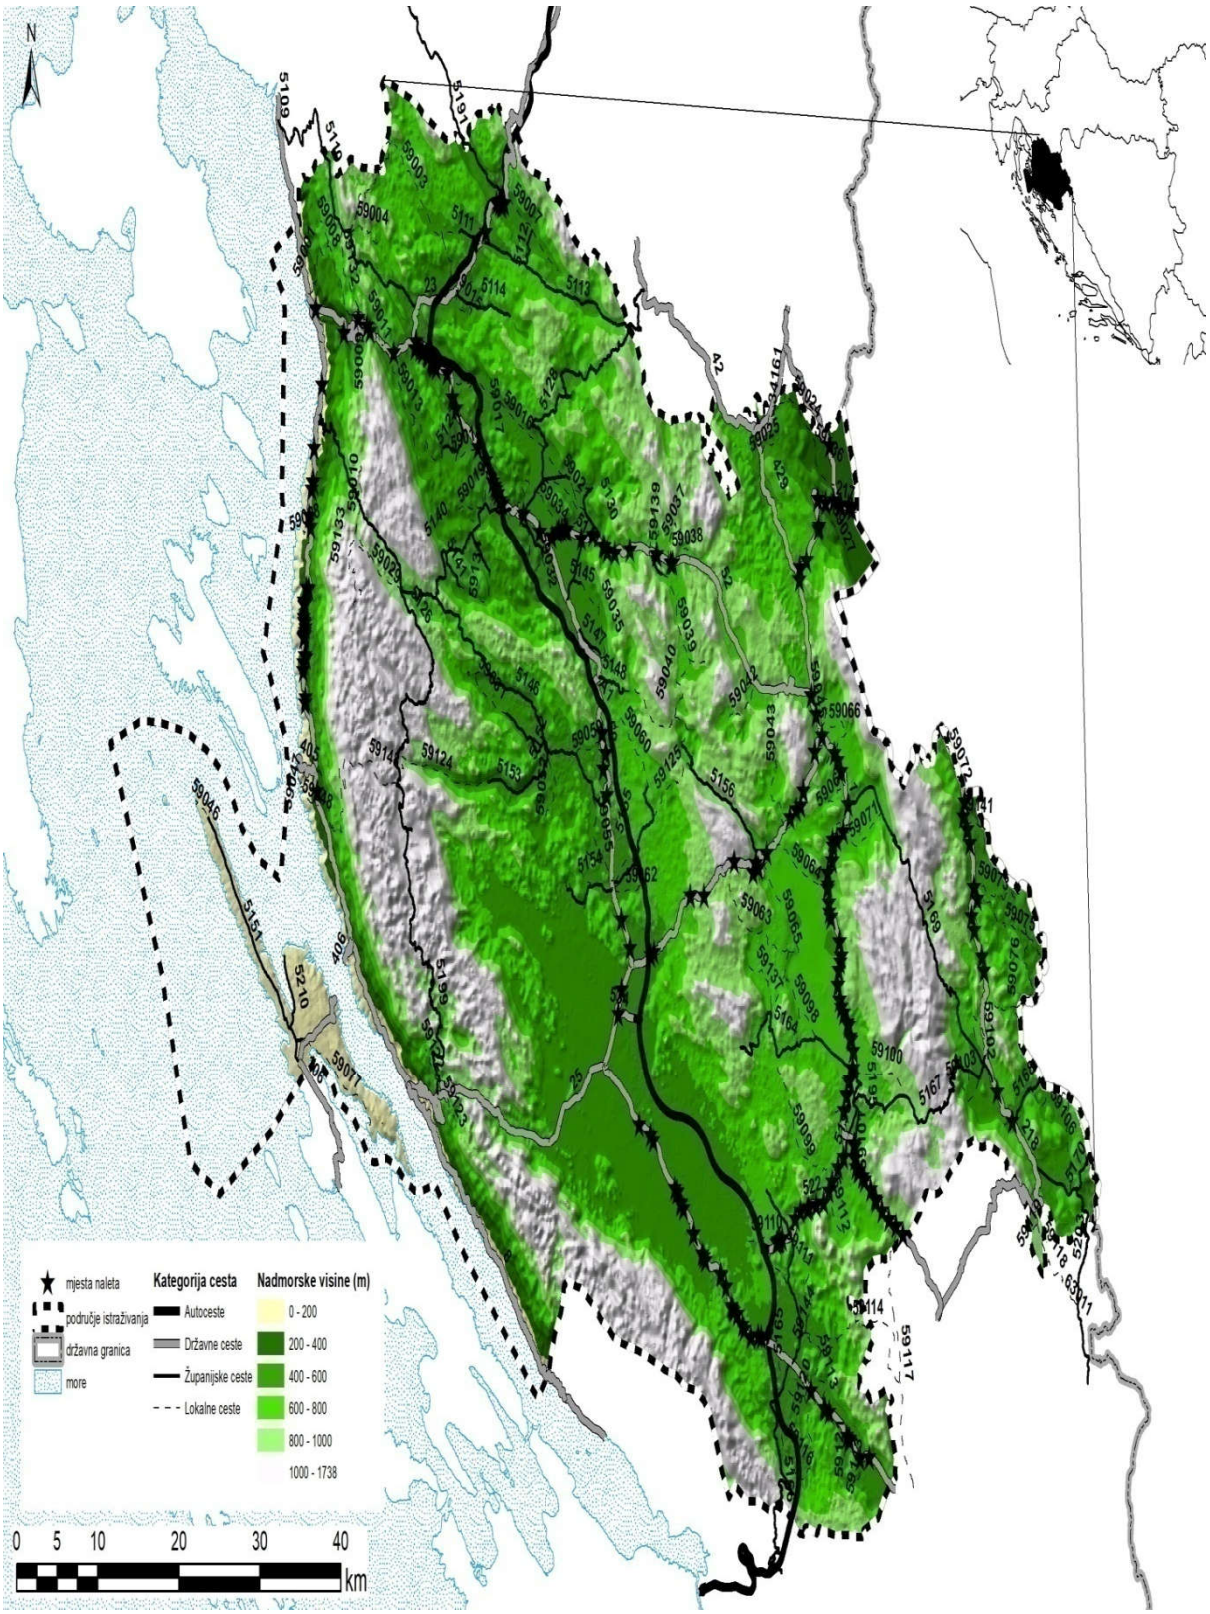
Prema podacima iz [97] (*tablica 1.*) dominantan tip staništa u Ličko-senjskoj županiji su šume, koje čine 65 %, odnosno zajedno sa šikarama, bujadnicama i vrištinama zatvorena staništa čine gotovo 70 % istraživanog područja.

Tablica 1. Struktura zemljišta u Ličko-senjskoj županiji

KORIŠTENJE ZEMLJIŠTA	PLOŠTINA (ha)	UDIO (%)
rijeke	986	0,18
povremene stajaćice	67	0,01
povremene tekućice	883	0,16
vode-ostalo	7	0,00
kanali	62	0,01
jezera	572	0,11
obale	128	0,02
tršćaci	1,156	0,22
goleti	16,819	3,14
travnjaci	109,447	20,45
bujadnice i vrištine	13,954	2,61
šikare	7,816	1,46
šume	347,892	65,01
zapušteno poljoprivredno zemljište	19,934	3,73
oranice	5,545	1,04
izgrađeno	2,147	0,40
ceste	3,685	0,69
voćnjaci	4,011	0,75
UKUPNO	**535,113**	**100,00**

Prema Velić i Vlahović u [98] karbonatne stijene čine 74 % istraživanog područja, što taj dio istraživanog područja čini poroznim u smislu zadržavanja oborina [94]. S obzirom da vode, bez obzira da li se radi o stalnim ili povremenim tekućicama ili stajaćicama, čine svega 0,5 % prostora (*tablica 1.)* glavnina istraživanog područja tijekom ljeta pokazuje oskudicu vode što divljač nedvojbeno tjera na veće ili manje migracije. Ovaj je čimbenik uzet u obzir prilikom istraživanja prostornih mehanizama naleta vozila na divljač te je kao jedan od pretkazivača naleta korištena „udaljenost od mjesta naleta do stalne vodene površine“, bilo da se radi o tekućici, stajačici ili lokvi, odnosno pojilištu.

Ličko - senjska županija ima važnost geoprometnog križišta između dva najveća grada u državi Zagreba i Splita i zbog svoje raznolikosti, različite nadmorske visine cestovne mreže (od 0 do 1 011 m.n.v.), izraženog reljefa, raznolikosti konfiguracije terena (planinski dio, ravničarski dio i primorski dio s otocima), izmjene nekoliko različitih tipova klime te prisutnosti svih vrsta divljači koje obitavaju u Republici Hrvatskoj, to je prostor županije mjerodavna osnova za provedbu istraživanja ovoga doktorskog rada. Stoga je u ovome doktorskom radu provedeno istraživanje naleta vozila na divljač na području javnih cesta Ličko-senjske županije (*slika 4.).*



Slika 4. Područje istraživanja

2.2. Javne ceste Ličko-senjske županije

Javne ceste su ceste razvrstane kao javne ceste sukladno Zakonu o cestama, koje svatko može slobodno koristiti na način i pod uvjetima određenim Zakonom o cestama i drugim važećim propisima [99]. Prethodnik Zakona o cestama [99] je Zakon o javnim cestama [100] koji također govori da su javne ceste javno dobro u općoj uporabi u vlasništvu Republike Hrvatske.

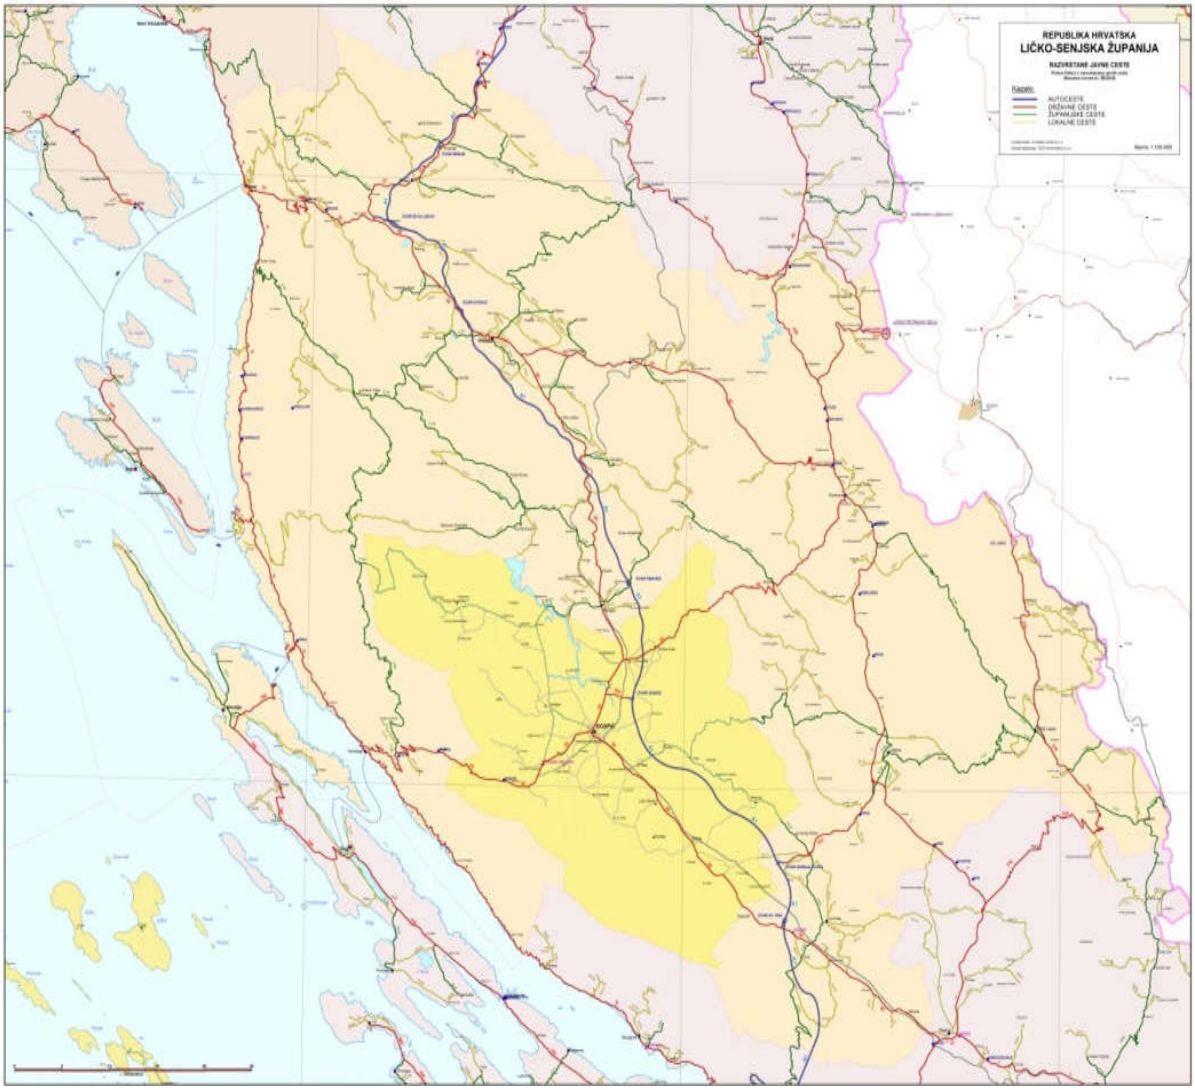
Javne ceste ovisno o svom značenju mogu biti razvrstane u četiri skupine, a to su:

- autoceste
- državne ceste
- županijske ceste
- lokalne ceste.

Ceste, kao osnova na kojoj se odvija promet moraju se projektirati, izgrađivati, opremati, održavati i štititi tako da odgovaraju svojoj namjeni i zahtjevima sigurnosti prometa [101].

Kroz Ličko-senjsku županiju prolazi 540,257 kilometara (km) državnih cesta, 479,970 km županijskih cesta, 651,330 km lokalnih cesta i dionica autoceste A1 od tunela Mala Kapela do tunela Sveti Rok u dužini od 112,80 km (*slika 5.*, plava boja - autocesta, crvena boja - državne ceste, zelena boja – županijske ceste i žuta boja – lokalne ceste).

Trasa autoceste uglavnom je postavljena za dugačka putovanja, a prema teoriji prometnog toka čak 80 % dnevnih putovanja odvija se unutar 50 kilometara [102]. Trasa autoceste od pojave divljači na autocesti zaštićena je žičanom ogradom i zelenim mostovima, od kojih lička dionica autoceste A1 ima izgrađena dva (Medina Gora i Varošina).



Slika 5. Karta javnih cesta Ličko-senjske županije

Izvor: [103]

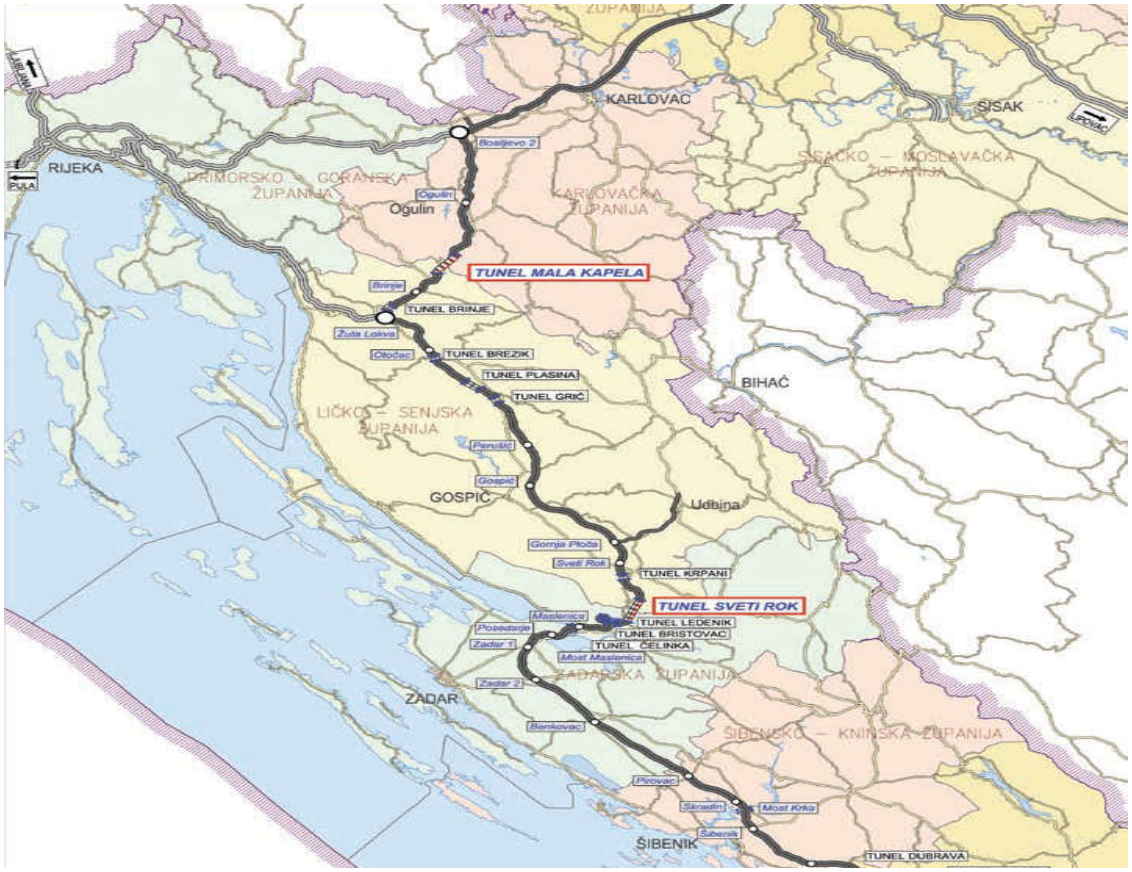
2.2.1. Autocesta A1 (tunel Mala Kapela - tunel Sveti Rok)

Autoceste (A) su javne ceste s tehničkim karakteristikama autoceste određenim propisima kojima se uređuje sigurnost prometa na cestama, koje imaju funkciju povezivanja Republike Hrvatske u europski prometni sustav, ostvarivanje kontinuiteta E-ceste (međunarodnim i međudržavnim sporazumima određena kao europska cesta), prometnog povezivanja regija Republike Hrvatske, omogućavanje tranzitnog prometa [99].

Autocesta Zagreb - Split - Dubrovnik sastavni je dio mreže međunarodnih E - cesta, i nosi domaću oznaku A1. Međutim dobiva i kombinirane oznake E65 i E71, jer nastavlja prometne tokove Sjeverne i Srednje Europe iz smjera Beča, Budimpešte i Bratislave.

Nacionalno autocesta A1 osnovna je infrastrukturna poveznica između sjevera i juga Republike Hrvatske, te je važna strateška pretpostavka za razvoj gospodarstva, privrede i turizma.

Kroz Ličko-senjsku županiju prolazi autocesta A1, a lička dionica počinje od tunela Mala Kapela do tunela Sveti Rok, u dužini od 112,80 km (*slika 6.*).



Slika 6. Trasa autoceste kroz Ličko-senjsku županiju

Izvor: [104]

2.2.2. Državne ceste Ličko-senjske županije

Državne ceste (DC) su javne ceste koje imaju funkciju povezivanja Republike Hrvatske u europski prometni sustav, ostvarivanje kontinuiteta E-ceste prometnog povezivanja regija Republike Hrvatske, prometnog povezivanja sjedišta županija međusobno, povezivanja sjedišta županija s većim regionalnim sjedištima susjednih država (gradovi veći od 100 000 stanovnika), omogućavanje tranzitnog prometa, koje čine cestovnu okosnicu velikih otoka i kojima se ostvaruje kontinuitet državnih cesta kroz gradove [99]. Na području Ličko - senjske županije ukupna dužina državnih cesta iznosi 540,257 km (*prilog 1.*) [105]. S državnim cestama upravljaju Hrvatske ceste d.o.o. društvo s ograničenom odgovornošću za upravljanje, građenje i održavanje državnih cesta.

2.2.3. Županijske i lokalne ceste Ličko-senjske županije

Županijske ceste (ŽC) su javne ceste koje povezuju sjedišta županija s gradovima i općinskim sjedištima, koje povezuju sjedišta gradova i općina međusobno, preko kojih se ostvaruje veza grada ili gradskih dijelova s državnim cestama [99].

Lokalne ceste (LC) su javne ceste koje povezuju sjedište grada, odnosno općine s naseljima s više od 50 stanovnika unutar grada ili općine, ceste u urbanom području koje povezuju gradske četvrti sa županijskim cestama, ceste koje povezuju susjedne gradske četvrti međusobno [99].

Na području Ličko - senjske županije ukupna dužina županijskih cesta je 479,97 km, a lokalnih cesta 651,33 km, što ukupno čini 1 131,30 km županijskih i lokalnih cesta (*prilog 2.*) [103], a s njima upravlja, gradi ih i održava Županijska uprava za ceste Ličko-senjske županije sa sjedištem u Gospiću.

2.3. Baza podataka o naletima vozila na divljač

Podaci o naletima na životinje prikupljeni su od Ministarstva unutarnjih poslova, Policijske uprave Ličko-senjske (PULS) [106], policijskih postaja Gospić, Otočac, Senj, Donji Lapac, Korenica, Karlobag i Novalja. Na navedenom području nalaze se 63 ustanovljena lovišta [107]. Podaci o naletima vozila na divljač uzeti su iz policijskih zapisnika o naletu vozila na divlje životinje (2012. – 2016.), a dogodili su se u razdoblju od 15. ožujka 2012. do 27. prosinca 2016. godine [106]. U zapisnik su tijekom izvida policijski djelatnici upisivali slijedeće podatke:

- datum naleta
- vrijeme naleta
- oznaka prometnice
- dionica
- stacionaža
- posljedica naleta
- vrsta životinje
- naziv nadležne policijske postaje.

Stradale životinje su razvrstavane na divljač i ostale životinjske vrste.

2.3.1. Učestalost naleta vozila na divljač po kategorizaciji ceste

Po kategorizaciji cesta na području Policijske postaje Gospić najveći broj naleta vozila na divljač dogodio se na državnim cestama i to 89 naleta vozila na divljač, (od čega se na DC-50, dionica 3 dogodilo 36 naleta vozila na divljač). Na autocesti A1 dogodilo se 32 naleta vozila na divljač, na gradskim cestama dogodilo se 5 naleta vozila na divljač, a na lokalnim cestama 1 nalet vozila na divljač.

Na području Policijske postaje Otočac najveći broj naleta vozila na divljač dogodio se na državnim cestama i to 74 naleta (od čega 25 naleta na DC-52). Na autocesti A1 dogodio se 23 naleta vozila na divljač, a na županijskim cestama 1 nalet vozila na divljač.

Na području Policijske postaje Senj najveći broj naleta vozila na divljač dogodio se na državnim cestama i to 42, (od toga 33 naleta na DC-8, dionica 7, a 9 naleta vozila na divljač na DC-23, dionica 4), i na lokalnim cestama 7 naleta vozila na divljač.

Na području Policijske postaje Korenica najveći broj naleta vozila na divljač dogodio se na državnim cestama i to 220 puta (na državnoj cesti DC-1 čak 168 puta), 29 naleta bilo je na županijskim cestama te na lokalnim cestama 4 puta.

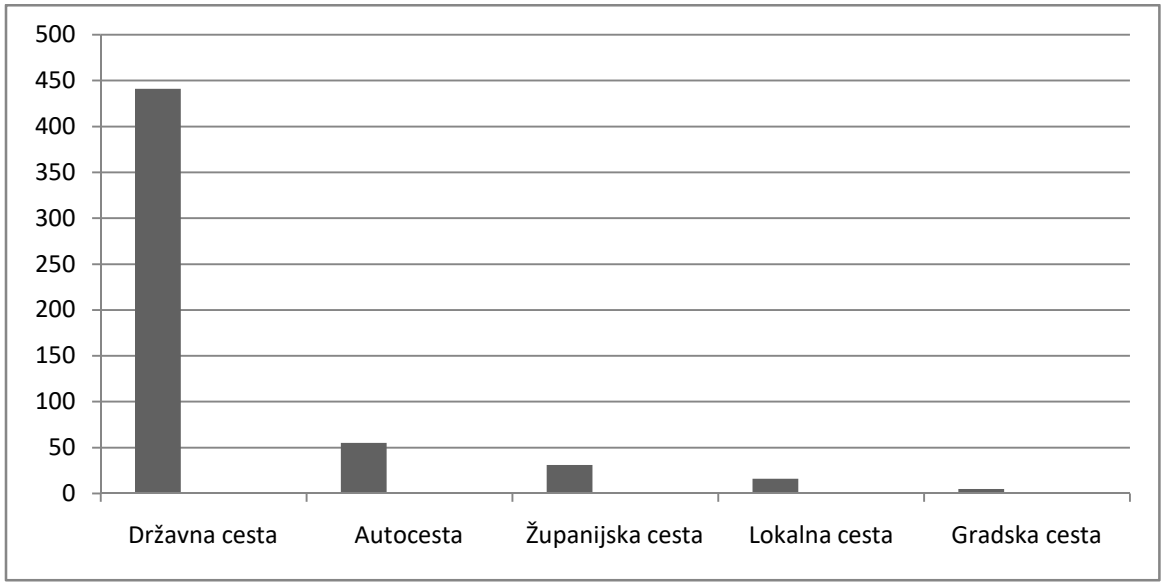
Na području Policijske postaje Donji Lapac najveći broj naleta vozila na divljač dogodio se na državnim cestama i to 16 naleta vozila na divljač (svi naleti desili su se na DC-218, 14 naleta na dionici -1 i 2 naleta na dionici -2), 1 nalet dogodio se na lokalnoj cesti i 1 nalet na županijskoj cesti.

Na javnim cestama Ličko-senjske županije u razdoblju od 2012. godine do 2016. godine najviše naleta vozila na divljač bilo je na državnim cestama (*tablica 2, grafikon 1.*). Na gradskim, lokalnim i županijskim cestama broj naleta vozila na divljač je vrlo mali, što potvrđuje tezu da je prevelika brzina jedan od uzroka prometnih nesreća koje su se dogodile zbog naleta vozila na divljač. Također je broj naleta vozila na divljač mali i na autocesti A1, koja prolazi kroz Ličko-senjsku županiju, a ovaj podatak potvrđuje tezu da se iako je velika dozvoljena brzina na autocesti, poboljšanim održavanjem cesta (postavljanje žičane ograde uz cestu) na kritičnim dionicama cesta može svakako smanjiti broj naleta vozila na divljač, a i divljač se već naviknula na nove koridore kretanja (zeleni most [50]). Utvrđeno je i par kritičnih dionica na području djelovanja svake policijske postaje. Tako npr. na području PP Gospić od ukupnog broja prometnih nesreća na državnim cestama čak se 40 % prometnih nesreća dogodio da državnoj cesti DC-50, dionica 3. Na području djelovanja PP Senj od

ukupnog broja prometnih nesreća na državnim cestama čak se 78 % prometnih nesreća dogodio na državnoj cesti DC-8, dionica 7.

Tablica 2. Vrste kategorizirane ceste na kojima se dogodio nalet vozila na divljač u Ličko-senjskoj županiji

Broj naleta vozila na divljač po kategorizaciji ceste (2012. - 2016.)	
Kategorizacija ceste	**Broj naleta**
Državne ceste	441
Autocesta	55
Županijske ceste	31
Lokalne ceste	16
Gradske ceste	5
Ukupno :	**548**



Grafikon 1. Nalet vozila na divljač po kategorizaciji ceste u Ličko – senjskoj županiji

Većina korisnika cestovnog prometa svoje putovanje obavlja prvo državnim, a onda županijskim i lokalnim cestama. Također, iz mjerodavnih dobivenih podataka, pokazalo se da se daleko najveći broj naleta vozila na divljač u istraživanom razdoblju i na istraživanom području dogodio upravo na državnim cestama, stoga je istraživanje ovog doktorskog rada dalje provedeno na državnim cestama Ličko - senjske županije.

2.3.2. Učestalost naleta vozila na divljač po vrsti divljači

Tijekom 5 - godišnjeg razdoblja praćenja naleta vozila na divljač zabilježeno je ukupno 548 naleta. Kod većine naleta su policijski službenici uspijeli procijeniti vrstu divljači tako da je samo u jednom slučaju u policijskom zapisniku pod rubrikom „vrsta životinje“ stajalo „nepoznata“.

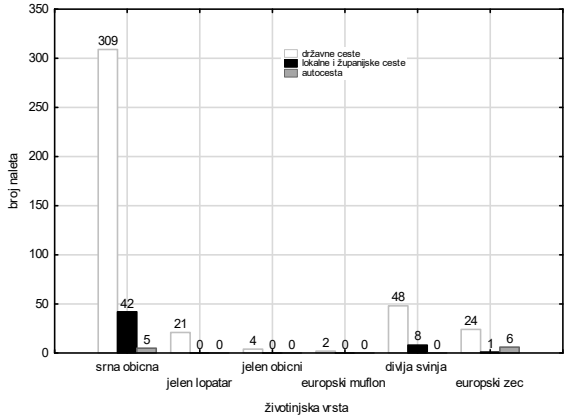
Radi usporedbe s podacima istraživanja ostalih znanstvenika i stručnjaka iz ove problematike podaci o stradaloj divljači su razvrstani na kategoriju ceste (državne ceste, lokalne i županijske ceste te autocesta – A1) i taksonomske skupine (parnoprstaši – *Artiodactyla*, dvojezupci – *Lagomorpha* te zvijeri –*Carnivora*).

U skupinu parnoprstaša spadaju srna obična, divlja svinja, porodice jelena, europski muflon i sjeverna divokoza. Dvojezupci su divlji zec i divlji kunić, dok su skupina zvjeri smeđi medvjed, sivi vuk, ris, čagalj, lisica, jazavac i divlja mačka.

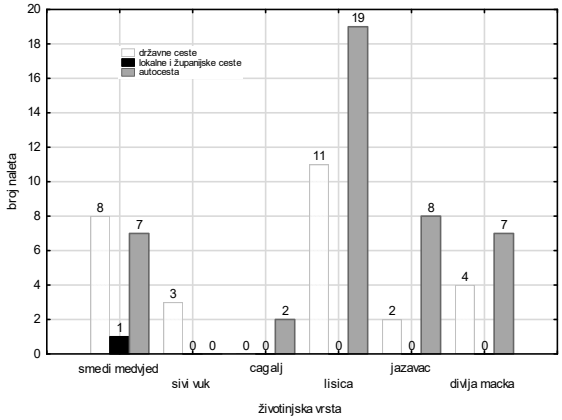
Ako se usporede podaci prikazani na *grafikonu 2.* i *grafikonu 3.* može se uočiti određena zakonitost stradavanja, vezana za taksonomsku pripadnost i kategoriju ceste. Naime, parnoprstaši i dvojezupci (europski zec) učestalije stradavaju na državnim cestama, dok pripadnici reda zvijeri učestalije stradavaju na autocestama.

Vrsta koja najučestalije stradava na cestama Ličko-senjske županije je srna obična. Tijekom 5 - godišnjeg razdoblja praćenja ukupno je stradalo 356 grla srneće divljači (71,2 grlo godišnje), od čega 309 grla na državnim cestama (61,8 grla godišnje), 42 grla na lokalnim i županijskim (8,4 grla godišnje) te 5 grla na autocesti A1 (1 grlo godišnje). Na drugom je mjestu po broju naleta vozila divlja svinja. Zanimljivo je kako nije zabilježen nalet vozila na divlju svinju na autocesti, ali je zabilježeno 48 slučajeva naleta vozila na državnim (9,6 grla godišnje) i 8 na lokalnim i županijskim cestama (1,6 grla godišnje), što ukupno čini broj od 56 stradalih grla (11,2 grla godišnje). Bez obzira radi li se o jelenu lopataru ili jelenu običnom, u odnosu na prethodne dvije vrste, jeleni stradavaju relativno rijetko i to gotovo isključivo na državnim cestama. Dvopapkar (parnoprstaš) koji najrjeđe stradava na prometnicama je europski muflon. Zapravo, na navedenom području obitava još jedna vrsta dvopapkara, a to je sjeverna divokoza *(Rupicapra rupicapra)*, no tijekom promatranog razdoblja nije zabilježen niti jedan nalet na ovu vrstu krupne divljači. Razlog vjerojatno leži u načinu njezina života, odnosno ona naseljava područja viših nadmorskih visina spomenutih gorskih masiva i relativno je malobrojna te je vjerojatnost naleta na nju izrazito niska.

Europski zec ne spada u razred parnoprstaša, no to je treća vrsta po učestalosti naleta kod pripadnika koji ne spadaju u zvijeri. Njega razmjerno malo stradava na lokalnim i županijskim cestama (zabilježena je samo 1 jedinka), na državnim cestama je zabilježeno 24 naleta vozila na zeca, te 6 naleta na autocesti. Ovo čini brojku od 31 stradalog zeca.



Grafikon 2. Broj stradalih parnoprstaša i dvojezubaca na cestama Ličko-senjske županije tijekom 5 godina praćenja, prema vrsti životinje i kategoriji ceste



Grafikon 3. Broj stradalih zvijeri na cestama Ličko-senjske županije tijekom 5 godina praćenja, prema vrsti životinje i kategoriji ceste

Od zvijeri na cestama najučestalije stradava lisica. Tijekom promatranog razdoblja policijski zapisnici bilježe 30 naleta vozila na lisicu, pri čemu je 11 naleta nastalo na državnim cestama, a čak 19 na autocesti. Na drugom mjestu je smeđi medvjed, sa 16 stradalih grla, od čega 8 na državnim cestama, 1 grlo na županijskim i lokalnim te 7 grla na autocesti.

Budući da po veličini tijela spada u krupne životinje, uz medvjeda je nužno spomenuti i sivog vuka. Tijekom promatranog razdoblja zabilježeni su naleti na svega 3 grla, pri čemu su se svi naleti dogodili na državnim cestama. Sitne zvijeri koje učestalije stradavaju na autocestama uz lisicu su divlja mačka i jazavac. Zabilježeni su naleti vozila na 11 divljih mačaka, od čega 7 na autocesti i 4 na državnoj cesti, dok je broj stradalih jazavaca 10 jedinki (čak 8 na autocesti i 2 na državnoj cesti). Nalet vozila na čaglja zabilježen je u svega 2 slučaja i to isključivo na autocesti.

Od ostalih skupina životinja zabilježeno je stradanje tri jedinke ptica (*Aves*), dvije jedinke iz reda sovki (*Strigiformes*) te jedna jedinka divljih pataka (*Anseridae*). Osim sovki, koje su stradale na državnim cestama, jedinke ostalih dviju skupina su stradale na autocesti.

2.4. Anketa lovozakupnika rizičnih područja

Navedeni slučajevi su službeno poznati i dobiveni su od nadležnih institucija, ali uvijek postoji i ona brojka naleta vozila na divljač za koju se službeno ne zna odnosno nije nikome prijavljen nalet vozila na divljač. Na području Ličko - senjske županije ustanovljena su 63 lovišta [107], kojima gospodari nešto manje lovoovlaštenika, iz razloga što pojedini lovoovlaštenici gospodare s dva i više lovišta.

Za potrebe izrade doktorskog rada odabranim lovoovlaštenicima s područja Ličko-senjske županije poslana je anketa (*prilog 3.*) vezana za nalet vozila na divljač za istraživano razdoblje. Upitnik ankete sastavljen je od 8 pitanja. Prvo pitanje lovoovlaštenika bio je je li se dogodio nalet vozila na divljač u lovištu s kojim gospodari lovoovlaštenik. Ukoliko je odgovor DA lovoovlaštenik je trebao odgovoriti na pitanja vezana za podatke koji su dobiveni i od Ministarstva unutarnjih poslova, a to su:

- mjesto događaja
- vrsta stradale divljači
- vrsta ceste
- datum prometne nesreće
- vrijeme nastanka prometne nesreće
- posljedica prometne nesreće.

U anketnom upitniku postavljeno je pitanje je li obavljen policijski očevid i pitanje da li je nalet uzrokovao smrt divljači? Na kraju ankete pitalo se lovoovlaštenike je li hitno potrebno riješiti problem naleta vozila na divljač.

Tijekom istraživanja, slučajnim odabirom, ukupno je ankentirano 20 lovoovlaštenika. Popunjenu anketu je vratilo 11, odnosno 55 % ankentiranih lovoovlaštenika. S lovoovlaštenicima koji nisu dostavili popunjenu anketu, napravljen je intervju s istim pitanjima. Nalet vozila na divljač u svojim lovištima imalo je 9 ankentiranih lovoovlaštenika, odnosno 45 % ankentiranih lovoovlaštenika.

Nakon prikupljanja popunjenih anketa i napravljenih intervjua utvrđeno je da lovoovlaštenici rijetko kronološki vode nalet vozila na divljač koji se dogodio na cestama koje prolaze kroz lovišta koja oni imaju u zakupu. Uglavnom podaci od lovoovlaštenika koji su vratili anketu ne prelaze brojku naleta vozila na divljač u njihovim lovištima u odnosu na podatke MUP-a. Isto tako lovoovlaštenici s kojima je napravljen intervju, potvrdili su kako

po njihovim saznanjima nema odstupanja od podataka MUP-a. To je pokazatelj kako su podaci Ministarstva unutarnjih poslova mjerodavni za istraživanje ovog doktorskog rada.

Jedino je odstupanje, u podacima lovoovlaštenika i MUP-a, u tome što djelatnici unutarnjih poslova vode podatke za divljač, npr. srneća divljač, a lovoovlaštenici rasčlanjuju srneću divljač na srnu, srnjaka ili lane. Isto tako kod divlje svinje lovoovlaštenici raščlanjuju stradalu divljač na lovačku stručnu terminologiju, odnosno na prasad, nazimad, krmače i veprove dok djelatnici MUP-a sve vode kao divlja svinja.

Svi lovoovlaštenici kroz ankete i intervjue potvrdno su odgovorili da je hitno potrebno rješiti problematiku naleta vozila na divljač.

2.5. Metodologija izrade vremenskih i prostornih obrazaca naleta vozila na divljač

U ovom radu, za potrebe istraživanja, bilo je potrebno obratiti posebnu pažnju na vremenske i prostorne obrasce naleta vozila na divljač. Vremenski i prostorni obrasci jedan su od važnijih čimbenika koji mogu utjecati na izradu i izbor najpovoljnijeg modela prepoznavanja opasnih dionica od pojave divljači. Međunarodna iskustva i istraživanja pokazuju da vremenski i prosorni obrasci nisu u potpunosti unificirani.

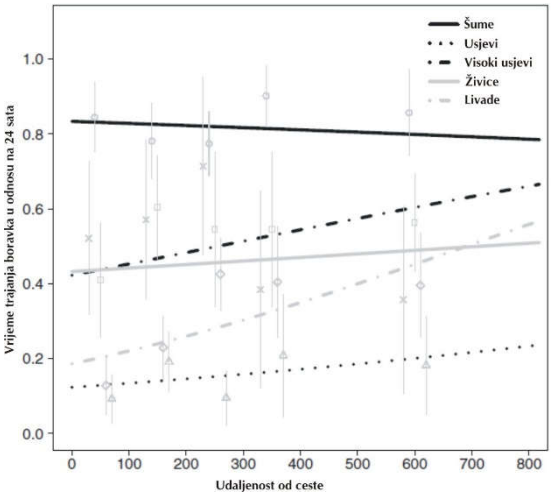
Analizirajući podatke dobivene iz Ministarstva unutarnjih poslova jasno je vidljivo da je na cestama Ličko - senjske županije u promatranom razdoblju daleko najviše stradavala krupna divljač pa je daljnja analiza (dinamika naleta, izrada modela predviđanja naleta) načinjena za temeljne vrste krupne divljači kojima se gospodari na ovome području: srna obična (*Capreolus capreolus*), divlja svinja (*Sus scrofa*) i jelene (ova kategorija obuhvaća dvije vrste jelena običnog – *Cervus elaphus*, i jelena lopatara – *Dama dama*).

2.5.1. Dosadašnja iskustva izrade vremenskih obrazaca naleta vozila na divljač

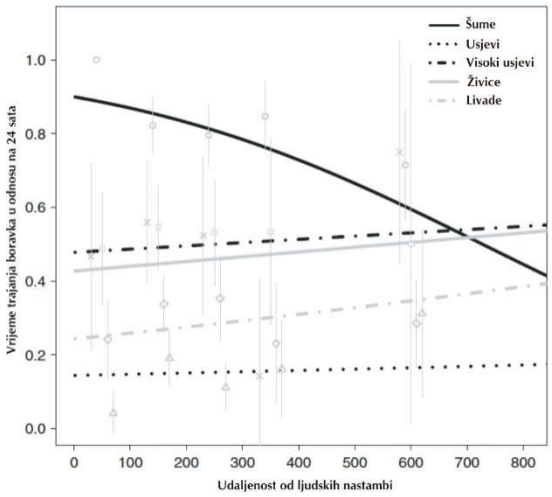
2.5.1.1. Sezonska dinamika naleta vozila na divljač

Razina povezanosti između broja naletana divljač i godišnjeg doba od istraživanja do istraživanja varira. Vincent u [108] nije našao signifikantnu (značajnu) povezanost između godišnjeg doba i učestalosti naleta. Bez obzira na spol naleti vozila na srneću divljač se najčešće događaju tijekom lipnja, srpnja, rujna i listopada. Srnjaci općenito učestalije stradavaju tijekom svibnja, kolovoza i prosinca, a srne tijekom ostalih mjeseci, međutim, srne (63,4 % slučajeva) učestalije stradavaju od srnjaka, a osobito odrasle, spolno zrele srne – 55,7 % slučajeva [21].

Generalno, divlja svinja se tijekom dana uglavnom zadržava u šumi, a tijekom noći na otvorenim površinama. Međutim, tijekom sezone lovidbe u visokim kulturama (zaklon i hrana) tijekom dana se zadržava kraće vrijeme. „Visokim kulturama“ se smatraju usjevi čija je visina sklopa tijekom razdoblja rujan - listopad viša od stojećeg grla srne (npr. stočni sirak – *Sorghumbicolor*, kukuruz i suncokret). Udaljenošću od cesta se učestalost korištenja šume i živica (zaklon) se ne mijenja (*grafikon 4.)* no što je veća udaljenost od ceste to ona tijekom dana učestalije boravi u visokim kulturama [109]. Jedan od ključnih čimbenika uznemiravanja srneće divljači jest čovjek. Naime, s udaljenošću od ljudskih nastambi boravak srne tijekom dana u šumskim staništima opada, dok raste učešće boravka ove divljači na poljoprivrednim kulturama livadama pa čak i u živicama (*grafikon 5.*).



Grafikon 4. Promjene učestalosti boravka srneće divljači u pojedinoj kulturi s obzirom na udaljenost od ceste. Izvor: [109], 191 p



Grafikon 5. Promjene učestalosti boravka srneće divljači u pojedinoj kulturi s obzirom na udaljenost od ljudskih nastambi. Izvor: [109], 190 p

Promjenjive obrasce ponašanja pokazuje i divlja svinja. Budući da srna obična i divlja svinja u naletima u sjeverozapadnoj Italiji sudjeluju s 92,7 %; autori su u [23] vremenske obrasce objedinili za obje vrste zajedno. Prema njihovim podacima naleti su najučestaliji od 19:00 do 23:00 sata (kada je najčešće noć), ali se kod srneće divljači javlja još jedan vrhunac naleta u zoru. S obzirom na godišnju dinamiku, najučestaliji naleti na srnu su od travnja do svibnja, a na divlju svinju od rujna do prosinca.

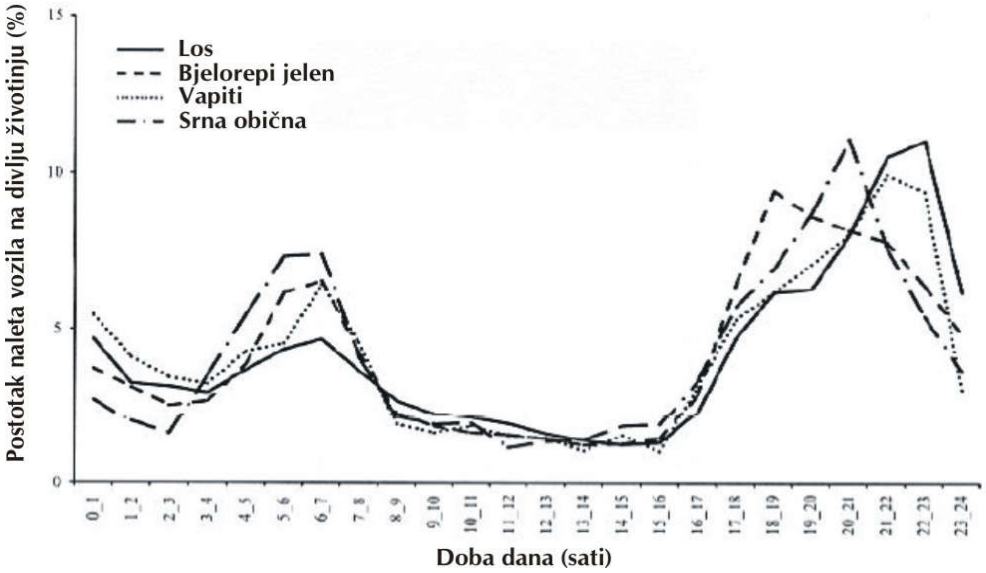
Kod divlje svinje su učestaliji naleti tijekom razdoblja studeni - siječanj i kolovoz - listopad [110]. Broj naleta vozila na srneću divljač je najviši tijekom jeseni, no on nije signifikantno povezan s gustoćom prometa ($R_S = 0,108$; $p = 0,63$; [21]).

Povezanost lunarnih faza s vjerojatnošću naleta vozila na pojedinu vrstu jelena je još uvijek nedovoljno istražena [111] i za sada su poznati jedino kod losa [112] i bjelorepog jelena (*Odocoileus virginianus*) [113]. U obje vrste vjerojatnost stradavanja u prometu je najviša u noćima punog mjeseca. Pri tome je vjerojatnost naleta vozila na bjelorepog jelena tijekom punog mjeseca viša ako su košute gravidne ili ako vode telad.

2.5.1.2. Dnevna dinamika naleta vozila na divljač

Iako se glavnina naleta na divlje životinje događa u sumrak ili noću [27] i smatra se kako je uzrok tome smanjena vidljivost, dnevna dinamika naleta dosta ovisi o vrsti životinje, ali i dinamici prometa. Naime, pretpostavlja se kako je aktivnost divljači u to doba povišena jer je u potrazi za hranom, no tada je i povišena gustoća prometa jer ljudi idu na posao ili se

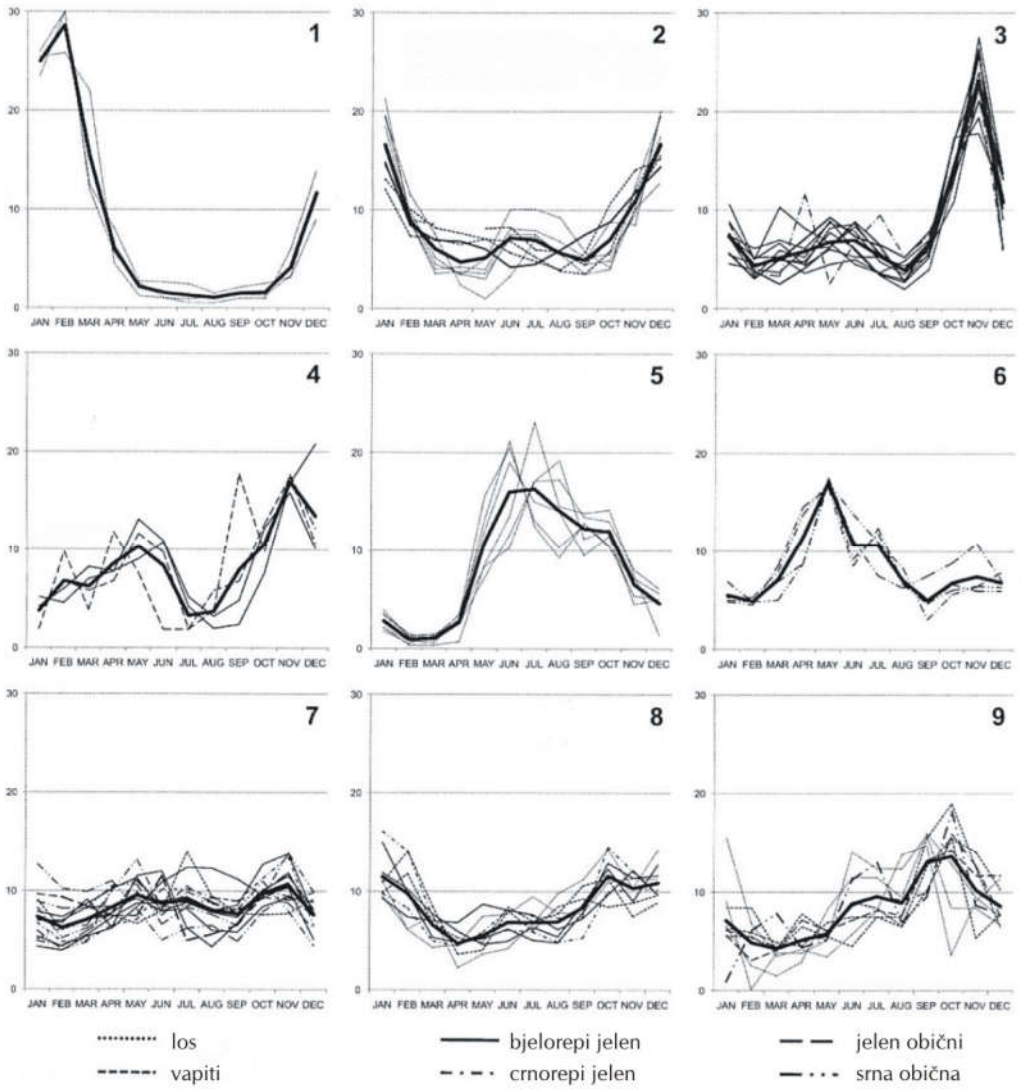
vraćaju s posla [27]. Dnevna dinamika naleta vozila na srneću divljač pokazuje bimodalnu distribuciju s maksimumom u zoru i sumrak [12], (*grafikon 6.*). Slično navodi i Mysterud u [114] za jelena običnog, dok su kod divlje svinje učestaliji tijekom večeri, a manje tijekom dana ili noći [110]. Međutim, dosta autora u izvješćima nije u obzir uzimalo godišnje promjene u izlascima i zalascima sunca. Iz radova u kojima je obrađena dnevna dinamika naleta srneće divljači i divlje svinje s obzirom na godišnji hod izlaska i zalaska sunca u [115] i [116] jasno se uočava kako su naleti povezani s izlascima i zalascima sunca te se može reći kako divlja svinja uglavnom stradava noću, dok srneća divljači stradava tijekom sumraka i tijekom dana.



Grafikon 6. Dnevni obrazac učestalosti naleta losa, bjelorepog jelena, vapitija i srne obične

Izvor: [111],175 p

Upravo je analiza koju su proveli Díaz-Varela i ostali u [116] pokazala kako divlja svinja uglavnom stradava tijekom subote, tijekom jeseni i zime te od 18:00 do 20:00 sati, što su autori uglavnom povezali sa sezonom lova. Dosta autora nastanak naleta vozila na divlje životinje pokušava povezati s lovnom aktivnosti čovjeka [27], [110], [116], [117], međutim, nema čvršće povezanosti između ove dvije pojave.



Grafikon 7. Devet različitih sezonskih obrazaca učestalosti naleta šest različitih vrsta divljih preživača.

Izvor: [111], 172 p

Budući da su do sada prostorno - vremenski obrasci naleta opsežno istraživani, čak i unutar iste vrste oni se, s obzirom na autora nešto razlikuju, što je potvrdila klasterska analiza iz rada [111]. Naime *grafikon 7.* predstavlja predviđanje naleta 6 vrsta divljih preživača u odnosu na jednog referalnog. U skladu s tim model broj 1 predstavlja prosječnu dinamiku naleta. Model 2 predstavlja sezonske obrasce naleta bazirane na istraživanjima u Sjevernoj Americi (i njihovim vrstama divljih preživača). Model broj 3 predstavlja obrazce naleta bazirane na bjelorepom jelenu. Model broj 4 predstavlja obrasce bazirane na bjelorepom jelenu i srni običnoj. Model broj 5 je baziran na obrascu naleta losa (vrlo je uočljiva kolmunacija naleta u lipnju i u srpnju). Model broj 6 bazira se na obrascu naleta srne obične s jasnom kulminacijom naleta tijekom razdoblja travanj – lipanj. Model broj 7 predstavlja

obrazac naleta svih divljih preživača, osim losa i on ne pokazuje velike godišnje fluktuacije, što će reći da je u Europi općenito cijele godine relativno ista vjerojatnost naleta. Model broj 8 predstavlja obrazac naleta baziran na svim divljim preživačima osim srne obične i jelena običnog što se i može uočiti iz krivulja jer je najniža vjerojatnost naleta upravo u razdoblju kada su naleti na srneću divljač najučestaliji. U konačnici model broj 9 predstavlja obrazac naleta računan za sve divlje preživače pri čemu su podaci za sjevernoameričkog jelena i losa bili najučestaliji. Očito je kako svaka vrsta divljeg preživača ima sebi svojstven obrazac naleta, a ako ih na pojedinoj dionici obitava više tada su modeli prepoznavanja naleta lošiji.

Povišen intenzitet prometa nije glavni razlog učestalijih naleta vozila na divljač, no uočava se da mjesta naleta pokazuju obrazac grupiranja. On može biti posljedica strukture staništa jer je jedna od „crnih točaka“ područje gdje cesta sječe poljoprivredne površine između dvije šume u duljini od 800 metara. Tih 800 metara predstavlja blagi zavoj, a sa svake strane su živice čime je vjerojatnost uočavanja srneće divljači mala [21]. Stoga se pri analizi naleta sve više proučavaju prostorni, odnosno okolišni obrasci naleta.

Općenito gledano, ako neka vrsta divljači na određenom lokalitetu pokazuje tjednu dinamiku naleta (stradavanja) na prometnicama to je gotovo isključivo povezano s tjednom dinamikom prometa, a teško s lovnom aktivnošću. S time u svezi većina divljih preživača, neovisno o geografskoj duljini pokazuje slične dnevne obrasce naleta (*grafikon 6.*), dok se na godišnjoj (sezonskoj), s obzirom na vrstu mogu uočiti određena odstupanja (*grafikon 7.*).

2.5.2. Dosadašnja iskustva izrade prostornih obrazaca naleta vozila na divljač

Činjenica je kako je promet jedan od odlučujućih čimbenika ugroženosti populacije pojedinih životinjskih vrsta te je kako radi zaštite životinjskih vrsta tako i radi podizanja razine sigurnosti prometa nužno razviti metodologiju predviđanja potencijalnih mjesta naleta.

Madsen i ostali su u [21] model procjene naleta vozila na srneću divljač radili na sekcijama ceste duljine 150 metara. Pokazalo se da su naleti grupirani, odnosno da se učestalije javljaju u područjima gdje su jedna ili obje strane ceste obrasle gušćim raslinjem (živice, grmlje ili branjevine), odnosno sijeku cestu pod kutom, što je bio prvi dokaz da se nesreće ne događaju slučajno.

Bez obzira na skupinu životinja veću vjerojatnost naleta imaju: ravan tren, gustoća prometa, brzina vozila, širina ceste i nazočnost vlažnih staništa. Manju vjerojatnost učestalosti

naleta imaju preglednost ceste i nazočnost graničnika (branika) i Jersey-evih barijera [118]. Dakle, brzinu vozila nekoliko autora [55], [119], i [120] spominju kao ključan čimbenik naleta vozila na divljač (WVC-a). Primjerice, Ng i ostali u [120] ukazuju kako je vjerojatnost naleta vozila na jelena dvostruko veća na dionicama cesta s dopuštenom brzinom vožnje od preko 80 km/h, ali i u područjima slabije razvijenom mrežom cesta (npr. 11,0 ± 7,4 km u prostoru od 800 m).

Gunson i ostali su u [118] načinili presjek metoda za izračun modela vjerojatnosti naleta i generalno počelo (slijed) izrade ovakvih modela bi bilo:

1. definiranje skupine organizama za koje se izrađuje model (npr. zvijeri, parnoprstaši, ptice, gmazovi, vodozemci itd.)
2. definiranje ključnih čimbenika naleta (pretkazivači), kao što su krajobrazna struktura, topografija itd i
3. definiranje signifikantnih pretkazivača prema tipu (nazočnost, indeks, veličina, područje, broj, udio ili udaljenost) te, ako postoje, kriterija (npr. polumjer bafera za izmjeru proporcija).

Rezultati prvih istraživanja naleta vozila na divljač su uglavnom bili deskriptivni, pojedini su spadali čak u kategoriju anegdotskih izvješća o tome koliko je životinja stradalo u prometu kumulativno, po dobi i spolu i po sezoni. Međutim, veći dio radova koji se bave ovom problematikom i danas sadrže spomenute podatke, iako im je težište na davanju matematičkog modela procjene vjerojatnosti naleta.

Dosadašnja istraživanja naleta vozila na divljač su pokazala kako mjesta naleta krupnih životinja pokazuju prostornu grupiranost [121], odnosno za životinje do veličine kojota (*Canis latrans*) prostori mogu biti veličine od 13 km kod sisavaca do 4 km kod ptica. Činjenica je da su divlje životinje povezane s određenim tipovima staništa te načinom korištenja zemljišta i da krajobrazne strukture igraju vrlo važnu ulogu glede izloženosti naleta pojedinog područja. Međutim, generalno točnost modela procjene vjerojatnosti naleta (odnosno određivanja opasnih mjesta ili „crnih točaka“) se od vrste do vrste životinje dosta razlikuju. Primjerice, modeli koje su razvili Clevenger i ostali u [121], primjenom K-statistike objašnjavali su svega 37 % varijabilnosti naleta vozila na američkog zeca (*Lepus americanus*), odnosno čak 87 % varijabilnosti naleta vozila na sivu vjevericu (*Sciurus carolinensis*). Osim toga, kod zeca su naleti najviše povezani s topografskim značajkama, odnosno oni najmanje stradavaju na dionicama cesta koje su smještene na nasipima i

usjecima, odnosno najviše stradavaju u blizini područja dobre pokrovnosti i daleko od uređenih prelaza preko ceste (tuneli ili raskrižja), što je i generalna, ali ne i isključiva značajka mjesta naleta vozila na sisavce. Stoga su ovi autori svoja daljnja istraživanja zakonitosti naleta vozila na sisavce usmjerili na topografiju ceste (usjek, zasjek, nasip ili u razini terena) za što je potrebna vrlo detaljna baza cesta.

Način dobivanja nezavisnih varijabli - pretkazivača naleta dosta se razlikuje među znanstvenicima. U oko 77 % istraživanja su ovi parametri dobiveni interpretacijom karata, dok su u 54 % studija podaci mjereni izravno s terena [122]. Prvi način dobivanja podataka ima prednost što se radi o relativno jeftinim metodama, no često puta su podaci nedovoljno točni zbog loše rezolucije snimaka ili topografskih podloga. U odnosu na stvarnu lokaciju naleta službena lokacija naleta može odstupati i do 516 m [122], no ako se nalet locira po stacionažama prometnice tada ta greška ne prelazi 100 m. Ukoliko se podaci o naletima (95 % žrtava su bili divlji preživači) bilježe na licu mjesta globalnim položajnim sustavom (GPS uređajem) tada je dobivenim algoritmom moguće objasniti do 39 % varijabilnosti naleta, dok algoritam dobiven korištenjem podataka o stacionažama i očitanjem s karata objašnjava svega 23 % varijabilnosti.

Isto tako podaci o naletima mogu biti sakupljeni od osiguravajućih kuća, lovačkih organizacija, cestovnih poduzeća ili njihovih podružnica koje se bave održavanjem cesta i praćenjem prometa te policije [27]. Danas većina baza naleta vozila na divljač (WVC-a) sadrži precizne lokacije mjesta naleta te više nije potrebno određivati opasne lokacije iz agregiranih podataka [123].

Do početka 20. stoljeća geografski informacijski sustavi (GIS modeli) u istraživanjima nisu bili dovoljno razvijeni, a baze za analizu podataka nisu bile dovoljno ažurirane, što je dovelo do podcjenjivanja utjecaja gustoće prometnica i fragmentacije staništa na divlje životinje. Razvoj GIS-a doveo je do novih problema u krajobraznoj ekologiji - koji izvor (izvore) podataka koristiti u istraživanjima?

Problematikom kvalitete izvora podataka te izbora i kreiranja parametara za potrebe izrade modela predviđanja naleta su se bavili Hawbeker i ostali u [124]. Oni navode kako bi veličina i oblik (fraktalna dimenzija) poligona koji su omeđeni cestama mogli biti presudni u definiranju uzroka povišene učestalosti naleta, a kao relevantan izvor podataka navode digitalne ortofoto snimke. Međutim do sada nema čvrstih dokaza koji bi išli u prilog ovoj tezi.

Jedan od ključnih parametara je gustoća populacije divljači. Naime, bez obzira na metodu koja se primjenjuje, samo prebrojavanje divljači je dosta skupa radnja, a podatke o brojnosti treba uvijek uzeti s pričuvom, osobito ako se radi o kratkim vremenskim nizovima [125]. Stoga dosta znanstvenika koristi podatke o odstrelu, odnosno relativnu odstrelnu kvotu, koja predstavlja broj odstreljenih grla na 100 ha (ili 1 km^2 lovne površine). Seiler [119] je u izradi modela procjene naleta vozila na losa koristio prostore polumjera 500 m oko mjesta naleta, a modeli su prihvaćeni kao adekvatni ako je faktor inflacije varijabilnosti (odnos pogodnosti uklapanja χ^2 i stupnja slobode) iznosio oko 1,0 [126].

Dosta autora navodi kako gustoća prometa nije odlučujući čimbenik u broju naleta [116], [119]. Primjerice, Seiler u [119] navodi kako je najviše naleta vozila na losa bilo na cestama s gustoćom prometa od 2 000 do 4 000 vozila dnevno, dok Díaz-Varela i ostali u [116] navode kako se 32 % naleta javlja na prometnicama s gustoćom prometa od 5 000 do 10 000 vozila/dan, a svega 4 % naleta na dionicama s izrazio visokom gustoćom prometa. Mužjaci losa prometnice s nižom gustoćom prometa radije prelaze noću, vjerojatno zato što na njima tijekom noći dolazi do značajnog smanjenja gustoće prometa [43].

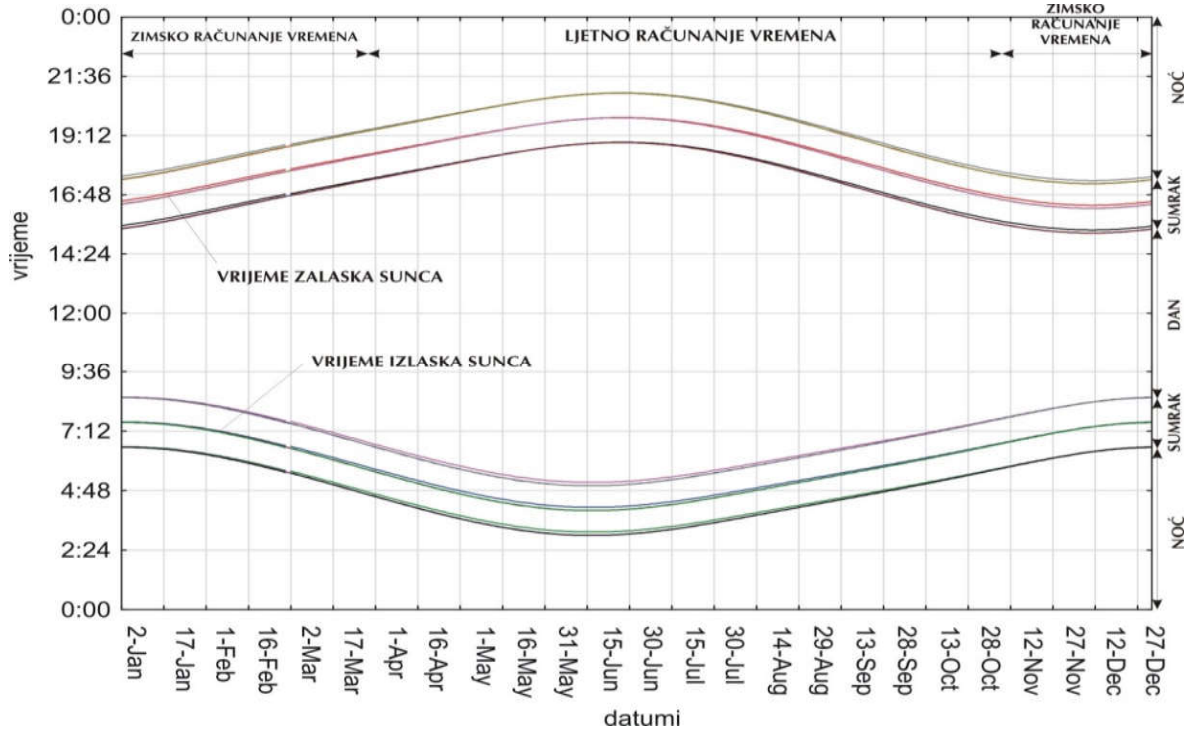
Razlog niže stope naleta vozila na divlje životinje na cestama s gustim prometom može biti povišena buka [46], [127] te degradacija okolnog staništa [128] što odbija životinje od prometnica. Mysterud je u [114] pokušao povezati broj naleta na jelena običnog s brojem registriranih vozila u pojedinoj regiji Norveške, no nije dobio nikakvu povezanost. Ovo ukazuje da je prometno opterećenje daleko bolji pokazatelj naleta jer broj vozila na nekom području može ovisiti o tome je li neka regija turistička, odnosno da li predstavlja tranzitno područje za turiste. Međutim, gustoća populacije divljači definitivno predstavlja jedan od čimbenika pozitivno povezan s vjerojatnosti naleta [114], [119].

2.5.3. Podaci za analizu vremenskih obrazaca naleta vozila na divljač

S obzirom na vrijeme nastanka naleta vozila na divljač 24 - satni dan je s obzirom na vrijeme svitanja i sutona *(grafikon 8.)* podijeljen na slijedeće dijelove [129]:

- dan – razdoblje koje počinje 1 sat nakon izlaska sunca, a završava 1 sat prije zalaska sunca
- noć – vremensko razdoblje koji počinje 1 sat nakon zalaska sunca, a završava 1 sat prije izlaska sunca

- sumrak – vremensko razdoblje koje dnevno traje ukupno četiri sata. Jutarnji sumrak počinje 1 sat prije izlaska sunca, a završava 1 sat nakon izlaska sunca. Večernji sumrak počinje 1 sat prije zalaska sunca, a završava 1 sat nakon zalaska sunca.



Grafikon 8. Godišnji hod trajanja dana i noći prema izlascima i zalascima sunca od 1. siječnja. do 31. prosinca za istraživani prostor.

Grafikon je izrađen prema podacima Zvjezdarnice Zagreb [130]

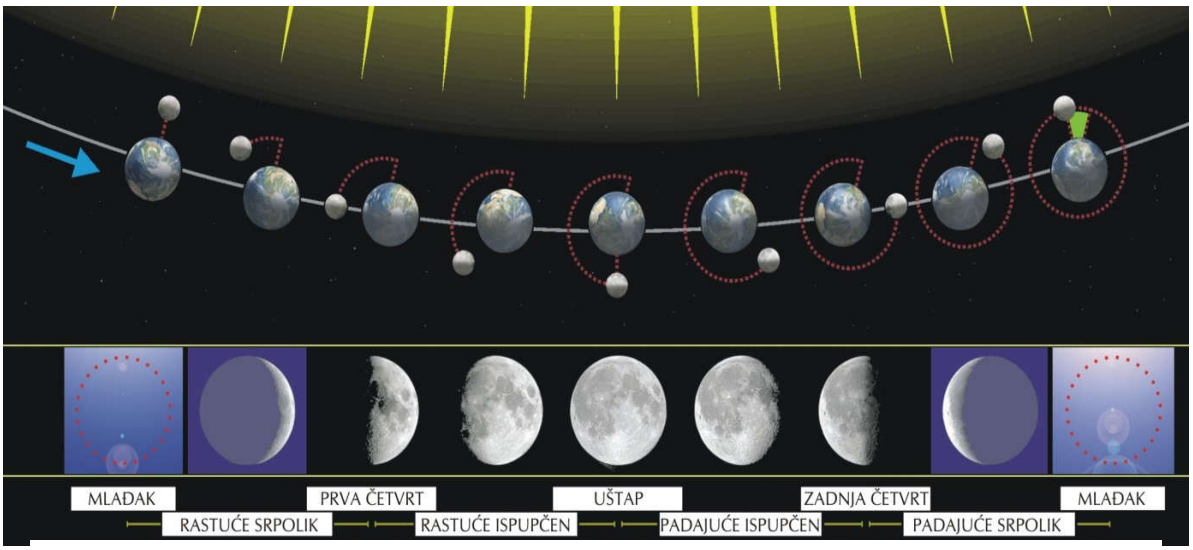
Vrijeme izlaska i zalaska sunca izračunato je pomoću algoritma danog na web stranicama [130], Zvjezdarnice Zagreb za svaki dan istraživanog razdoblja. Prilikom analize dnevne dinamike naleta pojavila su se tri problema:

- Računanje ljetnog i zimskog vremena. Temeljno vrijeme je zimsko, a ljetno vrijeme se u Republici Hrvatskoj (kao i u većem broju europskih zemalja) računa od zadnje nedjelje u ožujku do zadnje nedjelje u listopadu. Ono se računa na način da se zimskom vremenu dodaje jedan sat i obrnuto.
- Drugi je problem vezan uz aproksimaciju datuma prelaska sa zimskog na ljetno vrijeme, a važno je radi prikaza podataka na grafikonima. Naime, 2012. godine je datum prelaska na ljetno vrijeme bio 25. ožujka 2012, a već iduće godine 31. ožujka, što od godine do godine daje „pomak“ do 6 (7) dana. Ova je greška

aproksimirana na način da je kao datum prelaska sa zimskog na ljetno vrijeme uzet srednji datum između 25. i 31. ožujka, odnosno 27. ožujka.

- Treći problem je bio odabir koordinate mjesta izračuna izlaska i zalaska sunca. Ulazni podaci za izračun vremena izlaska i zalaska sunca su koordinate i nadmorska visina područja za koje se računa navedeno vrijeme. Budući da su podaci o naletima sakupljani na pet policijskih postaja (Senj, Otočac, Gospić, Donji Lapac i Korenica), to je za svaku postaju uzeta središnja točka obuhvata djelokruga postaje. Koordinata i nadmorska visina te točke bila je ulaz za izračun vremena izlaska i zalaska sunca. Vremenski parametri su uspoređeni i dobivena je maksimalna razlika od 5 minuta. Naime, koordinate za Senj nalaze se na zapadnom dijelu, a koordinate za Donji Lapac u istočnome dijelu istraživanog prostora. Navedena razlika se čini mala tako da je zanemarena te su podaci o izlasku i zalasku sunca ponovo izračunati za koordinate i nadmorsku visinu središta poligona istraživanog područja. Generalno, granične vrijednosti vremena naleta vozila na divljač (one koje se približavaju crti dana, noći, zore i sumraka) treba shvatiti okvirno jer su u uvjetima izražene orografije podaci dosta podložni pogrešci od nekoliko minuta. Osim toga, na slabiju vidljivost zbog smanjene količine sunčeva ili dnevnog svjetla, tijekom razdoblja kada nije noć, može utjecati i naoblaka.

Prilikom obračuna mjesečevih mijena koriste se dva međunarodna standarda. Prvi, jednostavniji način [131] lunarni ciklus razvrstavana 4 mijene (mlađak, prva četvrt, uštap i posljednja četvrt). Međutim, američki Pomorski oceanografski portal (Naval Oceano graphic Portal) [132] navodi 8 mjesečevih mijena *(slika 7.)*.



Slika 7. Mjesečeve mijene prema Pomorskom oceanografskom portalu.

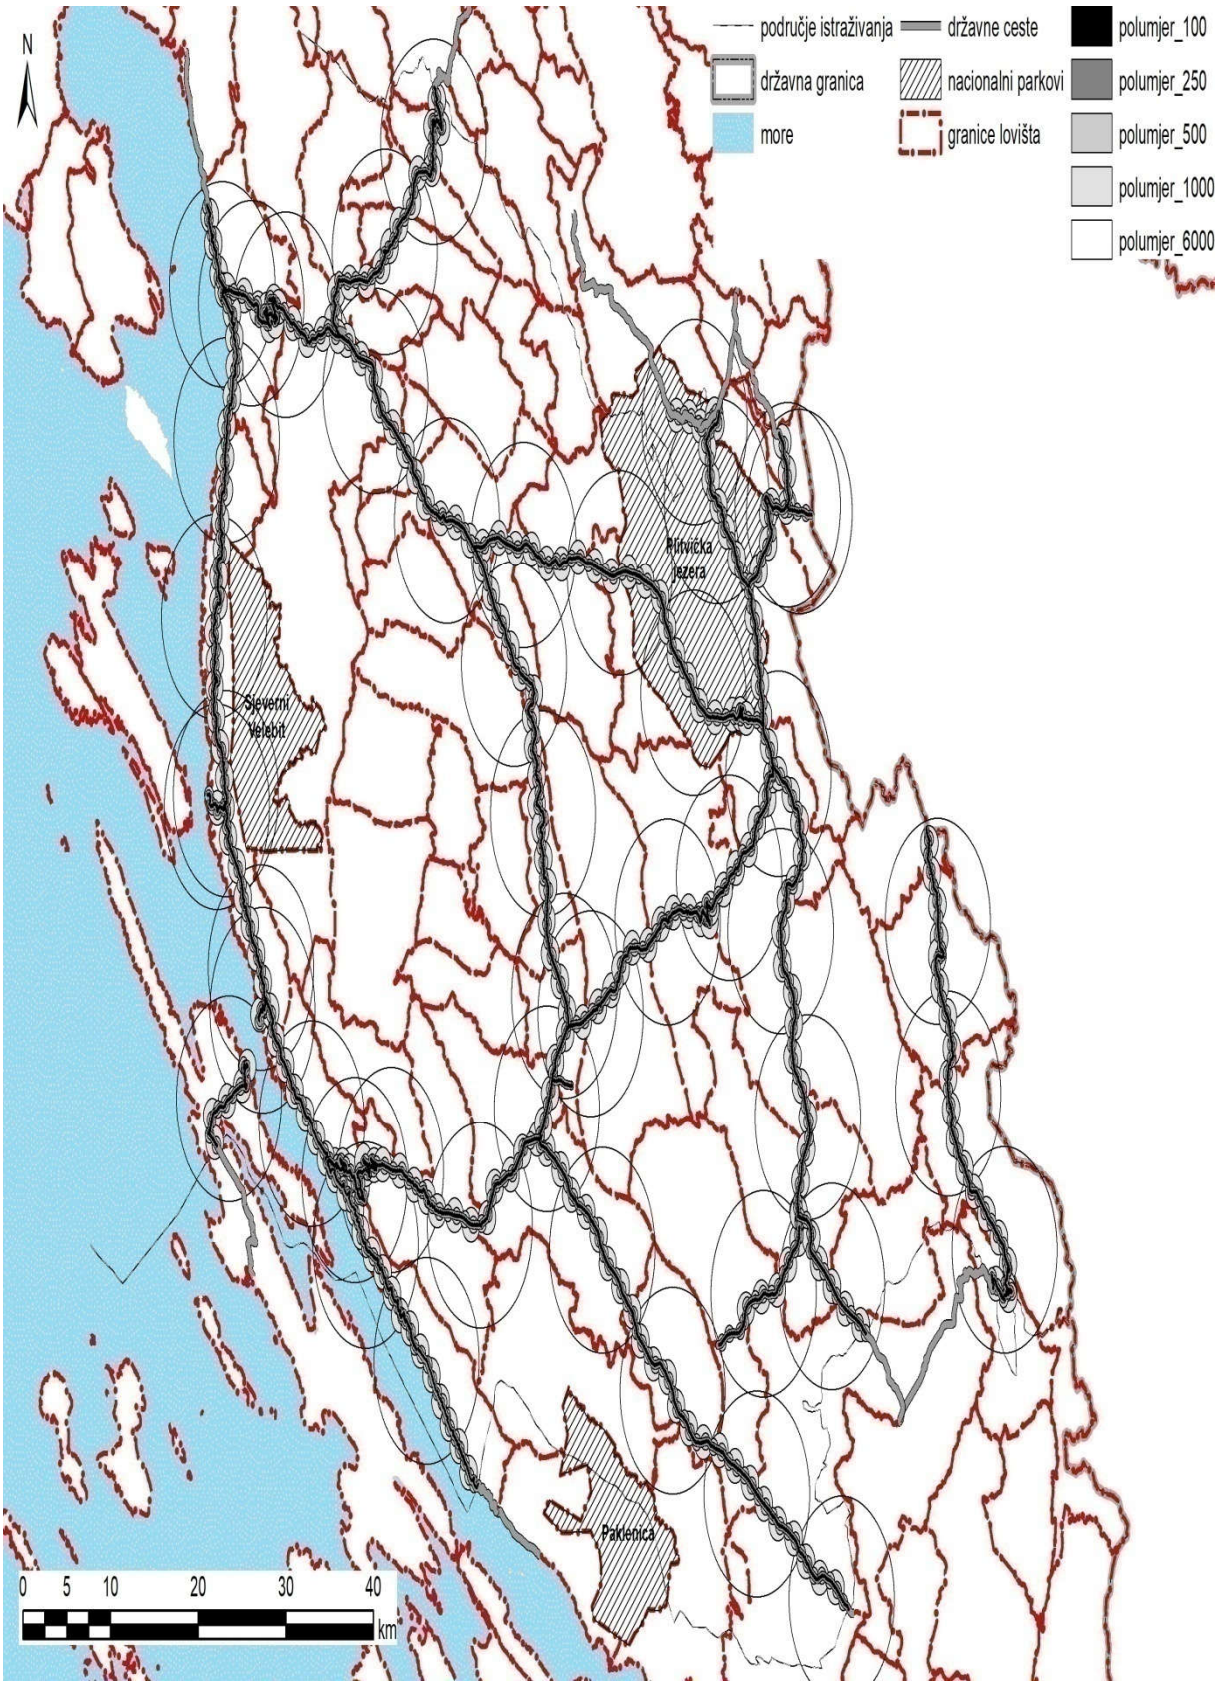
Prerađeno iz: [133]

Budući da su odnosi povezanosti mjesečevih mijena i aktivnosti životinja do danas još uvijek slabo poznati (osobito što se tiče naleta vozila na divlju životinju) u analizu je uzeta podjela lunarnog ciklusa od 8 mijena.

2.5.4. Podaci za analizu prostornih obrazaca naleta vozila na divljač

Svrha analize prostornih obrazaca naleta vozila na divljač bila je istražiti varijabilnost naleta vozila na divljač prema vrsti. Naime, usprkos generalnim obrascima ponašanja, na razini vrste postoje određene specifičnosti. Analiziranje okolišnih obrazaca naleta vozila na divljač (NVD-a) je daleko složenije od vremenskih. Ono zahtjeva upotrebu velikog broja nezavisnih varijabli (pretkazivača) koji uključuju: značajke prometnice, korištenja zemljišta, topografske varijable i značajke populacije.

Prilikom izračuna procjene vjerojatnosti naleta od osobitog je značaja podatak – koja je minimalna duljina dionice na kojoj se može procijeniti vjerojatnost naleta vozila na divljač, odnosno pojedinu vrstu divljač. Kako bi se odredila mjerodavna najmanja duljina dionice državne su ceste podijeljene na dionice od 200, 500, 1 000, 2 000 i 12 000 m. Oko središta dionica iscrtani su krugovi (ćelije) polumjera od 100, 250, 500, 1 000 i 6 000 m i za svaki krug (ćeliju) određene su nezavisne varijable, odnosno pretkazivači *(slika 8.)*. Ovaj potonji krug polumjera 6 000 m predstavlja i prosječan životni prostor divlje svinje.

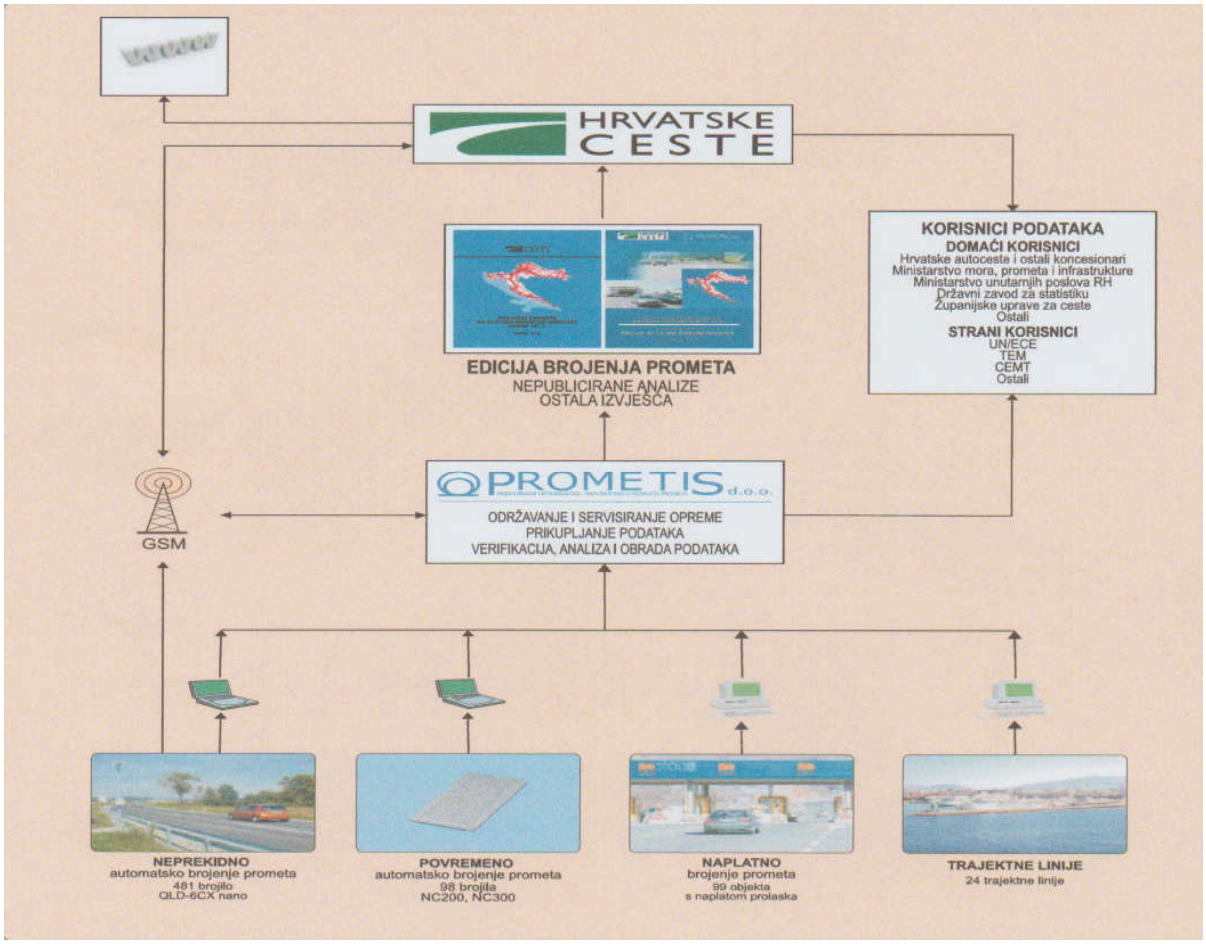


Slika 8. Položaj ćelija korišten za izračun modela predviđanja naleta vozila na divljač

Pod značajkama prometnice razmatrani su: prosječan godišnji dnevni promet (PGDP), prosječan ljetni dnevni promet (PLDP) i parametar zavoja.

Prosječni godišnji dnevni promet i prosječni ljetni dnevni promet izračunava se na osnovu brojenja prometa. *Slika 9.* predočava sastavnice informacijskog sustava brojenja prometa i osnovne podatkovne tokove. Kako je razvidno, riječ je o sustavu s brojnim sudionicima, u kojem se prikuplja, distribuira i obrađuje ogromna količina podataka, a obrade podataka obavljaju se kako na izvornim podacima svakog sudionika tako i na centralno prikupljenim podacima.

Metodologija obrade podataka obuhvaća sve postupke izrade i primjene cjelovite programsko - računalne podrške, koja se stalno unapređuje. PGDP i PLDP se izračunavaju kao artimetička sredina izbrojenog prometa u odnosnom razdoblju. Stoga su u ovom doktorskom radu podaci PGDP-u i PLDP-u preuzeti iz [134], [135], [136], [137] i [138].



Slika 9. Informacijski sustav brojenja prometa

Izvor: [134]

Pojedini autori, [139], [140] ukazuju na važnost zavoja na cesti, ali zavoji na cesti dvojako utječu na vjerojatnost naleta vozila na divljač. Naime, bez obzira na propis o ograničenju brzine vožnje, za očekivati je da će vozači prilagoditi brzinu u skladu s trasom ceste. Ukoliko je cesta u pravcu voziti će brže, a ukoliko je cesta u zavoju, odnosno što su zavoji izraženiji to će morati voziti sporije. Ovo ne znači nužno da će vozač zbog sporije vožnje na vrijeme izbjeći nalet na divljač. Naime, izraženi zavoji smanjuju preglednost ceste i potencijalno mogu povećati izglednost naleta.

Pošto se u ovom doktorskom radu nastoji izraditi dinamični model procjene, parametar zavoja ceste se morao računati. On je određen izrazom (1):

$$K = \frac{L}{R} \tag{1}$$

Gdje su:

- K = parametar zavojitosti
- L = duljina ceste koja prolazi ćelijom
- R = polumjer ćelije.

Ako je koeficijent 1, znači da je cesta u pravcu. Što je ovaj koeficijent viši od 1 to je cesta zavojitija.

Zbog kompleksnosti krajobraznih struktura u doktorskom radu korišteno je nekoliko tipova stanišnih podataka, i to:

- udio voda, obala, goleti, vriština i bujadnica, šikara, šuma, travnjaka, izgrađenog zemljišta, zapuštenog poljoprivrednog zemljišta, oranica. Načini korištenja zemljišta preuzeti su iz nacionalne baze, odnosno karte stanišnih tipova u Republici Hrvatskoj [97]. Nakon izračuna ploštine svake kategorije zemljišta u ćeliji izračunat je njihov udio (u relativnom broju, a ne u postotku, kako bi se mogli transformirati „arcsin“ transofrmacijom)
- udaljenost od stalnog vodotoka ili jezera te udaljenost od izvora ili lokve. Izvori i lokve su digitalizirani iz topografske karte Republike Hrvatske 1: 25 000
- ukupna duljina granica katastarskih kultura u ćeliji u odnosu na opseg ćelije.

Gunson i ostali [122] su kao topografske varijable koristili položaj ceste u odnosu na okolni teren, a što su kvantificirali kao 1 - cesta u razini s okolinom, 2 - nasip, zasjek ili usjek te 3 - djelomičan zasjek ili djelomičan usjek. Budući da su danas već razvijeni bolji modeli

prikaza reljefa kao pretkazivač topografskih značajki ceste je korišten indeks topografske pozicije (TPI) ili TOPEX. To je jedna od novijih topografskih varijabli, a detaljnije su je definirali Guisan i ostali u [141] te Weiss u [142].

Topografske varijable dobivene su iz digitaliziranih slojnica topografskih karata 1: 25 000, koje su pretvorene u digitalni elevacijski model (DEM). Pri tome je nužno objasniti varijablu „indeks topografske pozicije“ (TPI).

TPI se dobije usporedbom nadmorske visine svake ćelije nekog DEM-a s prosječnom nadmorskom visinom oko te ćelije. Kombinacijom TPI-a, pri različitim mjerilima, i nagibima terena može se neko područje razvrstati u nekoliko inklinacijskih razreda. Pozitivni TPI-i predstavljaju pozicije koje su više od okolnog terena (grebeni), dok negativni predstavljaju pozicije niže od okolnog terena (udoline). TPI vrijednosti blizu nule predstavljaju ravne terene (nagib je blizu nule), odnosno područja konstantnog nagiba (nagib te točke je signifikantno viši od nule). Teren je, s obzirom na TPI i nagib, razvrstan na šest kategorija: udoline, manje strmi tereni, srednje strmi tereni, izrazito strmi tereni, gornji dijelovi strmina i grebeni.

Podatke o brojnosti divljači u lovištu unose lovoovlaštenici u lovnogospodarske osnove, ali nisu u potpunosti točni iz razloga nemogućnosti prebrojavanja sve divljači u pojedinom lovištu. Budući da su podaci o brojnosti divljači relativno nepouzdani kao pokazatelj gustoće populacije korišteni su podaci o odstrelu divljači u pojedinom lovištu, ali svedeni na jedinicu lovne površine (relativna odstrelna kvota (ROK), broj grla/100 ha). Gustoća populacije ili odstrelna kvota se iskazuje u broju jedinki (grla, repova, kljunova) na jednoj lovnoj jedinici, koja iznosi 100 ha (1 km^2). Lovna površina dobije se tako ta se od ukupne površine lovišta oduzmu izgrađene i vodene površine. Budući da je istraživanje vršeno tijekom 5 lovnih godina u obračunu je korištena aritmetička sredina ROK-a za razdoblje 2012. - 2016.. U slučajevima kada je ćelija obuhvatila minimalno 2 lovišta tada je uzimana aritmetička sredina ROK-ova obuhvaćenih lovišta. Budući da dio prometnica prolazi kroz ili uz nacionalne parkove, a u njima nema odstrela, ROK je za ta područja iznosio nula. Naime, prema Adamiču u [143], zbog izostanka prihrane i drugih uzgojnih mjera brojno stanje krupne divljači na površinama izvan lovišta (npr. nacionalni parkovi i strogi rezervati) je signifikantno niže nego u lovištima. U slučaju da cesta prolazi između lovišta i nacionalnog parka, ROK je određena kao srednja vrijednost ROK-a lovišta i nule.

2.6. Rezultati obrade podataka

Podaci su pripremljeni u programskom paketu ArcGIS 9.2. Testiranje normaliteta distribucije izvršeno je Kolmogorov-Smirnov testom i, budući da je veličina uzorka ispod 50, Shapiro-Wilk testom. Prostorni podaci (udjeli pojedinih krajobraznih struktura u ćeliji) su transformirani arcsin transformacijom, a udaljenosti logaritamskom transformacijom.

Vrijednost povezanosti (korelacija) je izražena Pearsonovim (r) ili Spearmanovim (r_S) koeficijentima. Kako bi se smanjila greška parcijalne korelacije iz daljnje analize su izbačene one varijable s graničnom vrijednošću $r_s(r) > 0,75$ [144]. Podaci su obrađeni u programskom paketu Statistica 13.4.014 TIBCO Software Inc., 2018.

2.6.1. Prostorni obrasci naleta vozila na glavne vrste krupne divljači za definiranje modela na istraživanom području

Najvišu odstrelnu kvotu *(tablica 3.)* ima divlja svinja, a ovisno od godine do godine ona se (na razini cijele županije) kreće od 0,26 do 0,33 grla/100 ha. Nakon nje je po brojnosti odstrela srna obična. Njena se relativna odstrelna kvota (ROK) kreće od 0,13 do 0,16 grla/100 ha.

Najniže ROK imaju smeđi medvjed (od 0,003 do 0,007 grla/100 ha) i jelen lopatar (0,001 do 0,006 grla/100 ha). Međutim, kod svih vrsta krupne divljači, izuzev sjeverne divokoze, nema signifikantnog (značajnog) povećanja ROK-a, što ukazuje da im populacija ne raste.

Tablica 3. Relativna odstrelna kvota krupne divljači na području Ličko-senjske županije i njen trend tijekom istraživanog razdoblja

VRSTA DIVLJAČI	RELATIVNA ODSTRELNA KVOTA (grla/100 ha lovne površine)				
	2012./2013.	*2013./2014.*	*2014./2015.*	*2015./2016.*	*2016./2017.*
Jelen obični	0,02	0,02	0,02	0,02	0,01
Jelen lopatar	0,003	0,004	0,003	0,001	0,006
Srna obična	0,13	0,14	0,15	0,16	0,13
Europski muflon	0,04	0,03	0,03	0,03	0,03
Sjeverna divokoza	0,01	0,01	0,01	0,01	0,01
Divlja svinja	0,29	0,3	0,33	0,29	0,26
Smeđi medvjed	0,006	0,004	0,007	0,007	0,003
Ukupno	0,50	0,51	0,56	0,52	0,47

Osim što se populacija većine vrsta krupne divljači na istraživanom području nije statistički značajno povećala, statistički testovi su pokazali kako kod većine vrsta krupne divljači na državnim cestama nije došlo ni do statistički značajnog povećanja naleta vozila *(tablica 4.)*. Izuzetak je srna obična, kod koje je zabilježeno statistički značajno povećanje naleta vozila (R_s = 0,9; p < 0,05). Budući da se ovakav trend naleta vozila kod srneće divljači dogodio usprkos stagnaciji u brojnosti uzroke treba tražiti u drugim čimbenicima (promjena strukture staništa, neodržavanje područja uz ceste, povećanje cestovne mreže itd.).

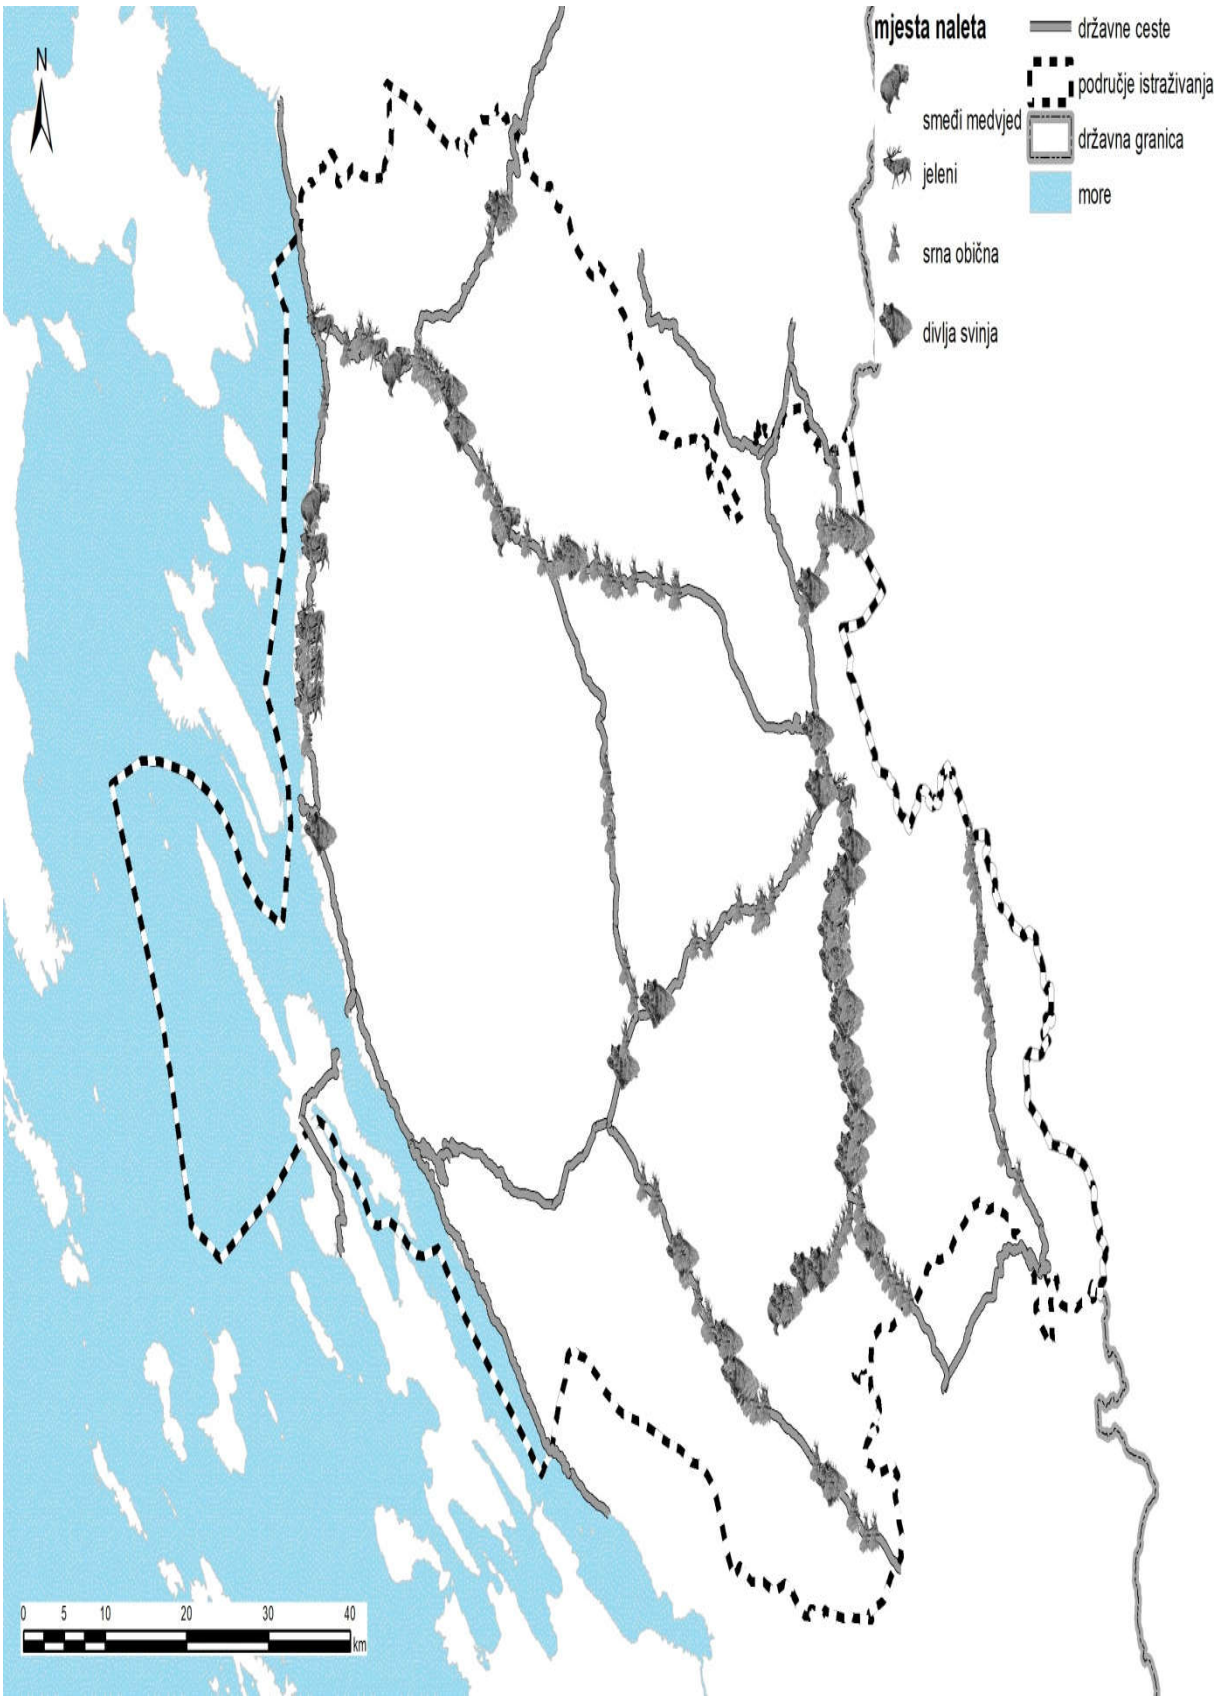
Tablica 4. Relativna odstrelna kvota krupne divljači na području državnih cesta Ličko-senjske županije i njen trend tijekom istraživanog razdoblja

VRSTA DIVLJAČI	KOEFICIJENT KORELACIJE (R_s)	
	TRENDOVI BROJNOSTI	***TRENDOVI NALETA***
Jelen obični	-0,200000	-0,579751
Jelen lopatar	0,300000	0,400000
Srna obična	0,000000	0,900000
Europski muflon	-0,800000	-
Sjeverna divokoza	-0,900000	-
Divlja svinja	-0,300000	0,666886
Smeđi medvjed	-0,100000	-0,670820
UKUPNO	-0,300000	0,800000

Brojevi označeni crvenom bojom u tablici ukazuju na statistički značajnu povezanost uz prag signifikantnosti p<0,05.

Osim što se razlikuju po brojnosti, vjerojatnosti naleta, vrste krupne divljači pokazuju i određene specifičnosti u prostornoj distribuciji naleta *(slika 10.)*. Naime, srneća i crna divljač (divlje svinje) su bile žrtve naleta na gotovo svim dionicama državnih cesta. Jelenska je divljač, bez obzira na vrstu uglavnom stradavala u zapadnom dijelu (sredozemno područje), na državnoj cesti DC-8, u sjevernom dijelu (državna cesta DC-23) te u istočnom dijelu (državna cesta DC-1).

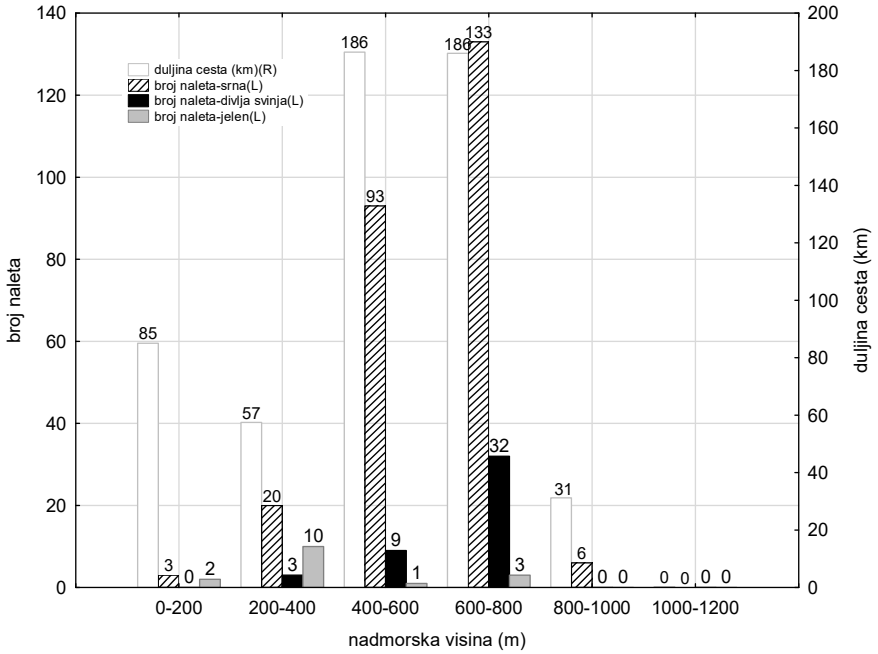
Za razliku od jelenske divljači smeđi medvjed pokazuje relativno dobru disperziranost. Bez obzira što se radi o samo 8 naleta na državnim cestama oni su se dogodili u sjevernom (DC-8/2 naleta, DC-23/1 nalet), središnjem (DC-50/1 nalet), istočnom (DC-1/3 naleta) i južnom (DC-522/1 nalet) dijelu istraživanog područja. Međutim, kako se radi o malom uzorku, ne mogu se načiniti detaljnije analize, pogotovo ako se uzme u obzir relativno velik životni prostor ove životinjske vrste koji može iznositi i do 128 km^2 [145].



Slika 10. Prostorni razmještaj mjesta naleta vozila na krupnu divljač tijekom istraživanog razdoblja (2012. - 2016.) na području Ličko-senjske županije

S obzirom na nadmorsku visinu državne se ceste u Ličko-senjskoj županiji rasprostiru od 0 do 1 011 m nadmorske visine. Ova potonja kategorija predstavlja prijevoj preko Mazinske planine, (DC-218) u predjelu Uvale, s dionicom od 200 m. Međutim, u ukupnoj duljini cesta (konfiguracijska, odnosno 3D duljina) dominiraju ceste na nadmorskim visinama od 400 do 600 te od 600 do 800 m i čine udio od 68 % cesta. Točke naleta vozila na divlju svinju i jelensku divljač javljale su se do 800 m nadmorske visine, dok se kod srneće divljači naleti javljaju i na većim nadmorskim visinama (najviša nadmorska visina s naletom vozila na srnu je bila 970 m, DC-25 – predjel Kneževići), (*grafikon 9.).*

Regresijska analiza nije polučila signifikantnu ovisnost između nadmorskih visina i broja naleta na običnog jelena (R^2 = 0,113; F = 0,745; p = 0,546) te povezanost između duljine ceste po nadmorskoj visini i broja naleta kod srne (R_s = 0,771; ns), divlje svinje (R_s = 0,759; ns) i jelenske divljači (R_s = 0,464; ns). Stoga se nameće pitanje što je uvjetovalo ovakvu pojavu. Nije isključena i gustoća populacije, kao uzrok naleta.

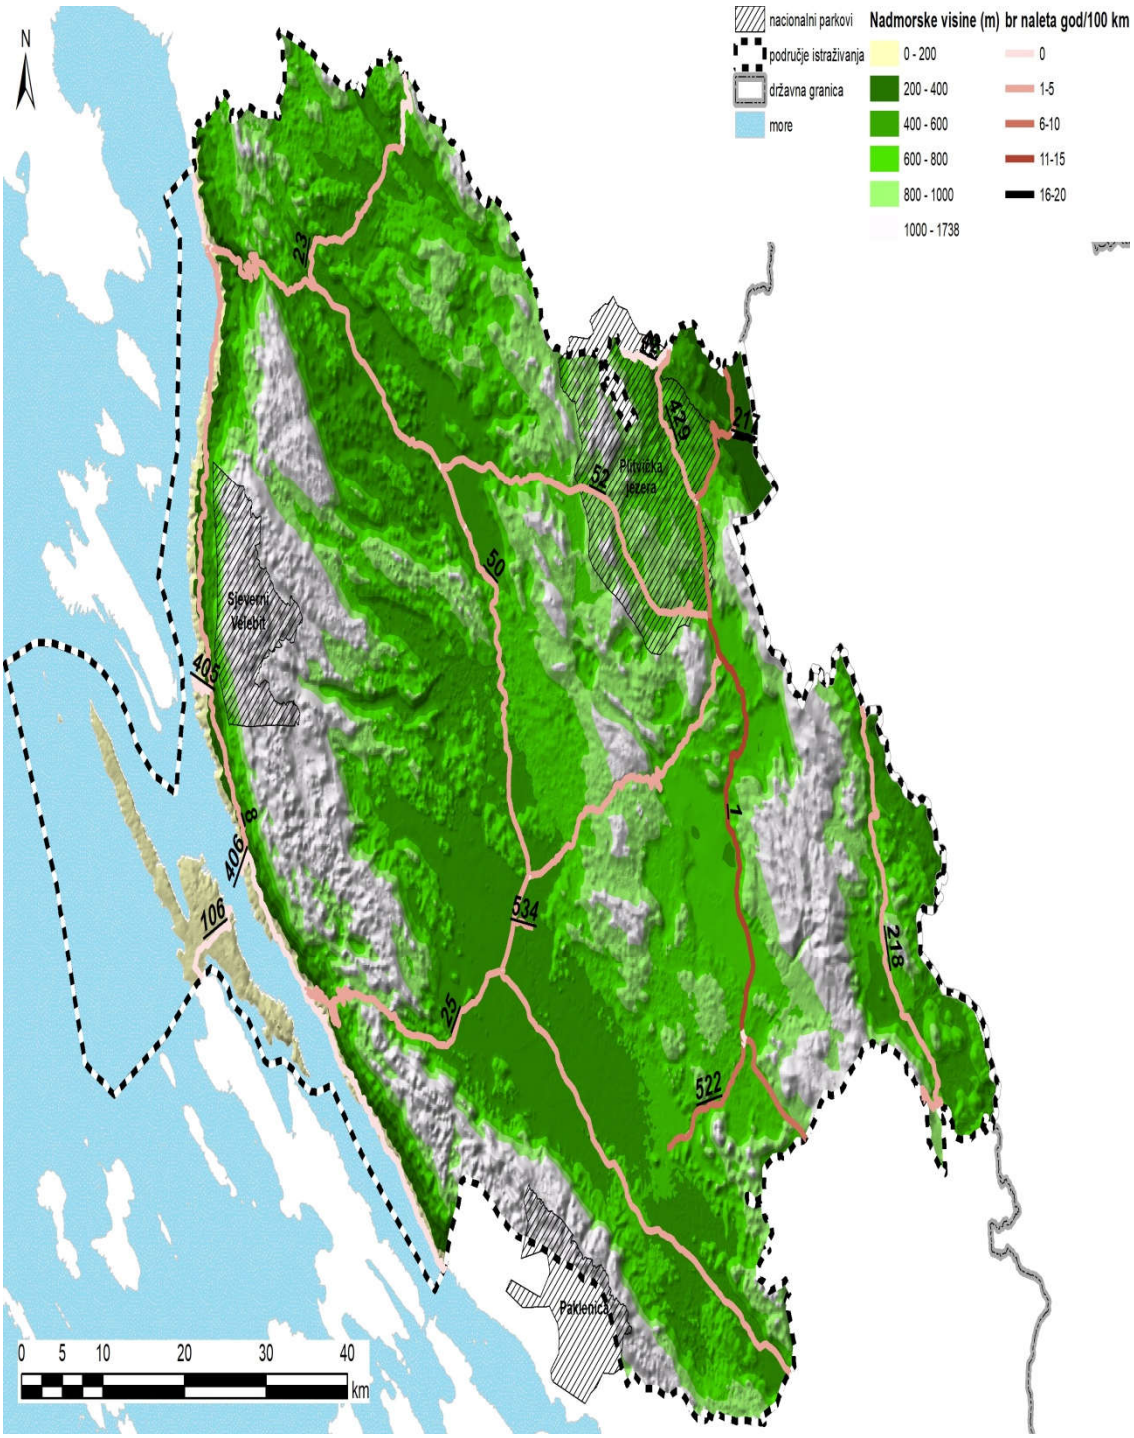


Grafikon 9. Duljina cesta i brojevi naleta na jelene, srnu običnu i divlju svinju po nadmorskim visinama

Iz podataka o broju naleta na svakoj dionici, duljine dionice i broja godina praćenja izračunati su godišnji naleti vozila na krupnu divljač (krupna divljač i sivi vuk) na 100 km ceste (*tablica 5.*, *slika 11.*). Naime, naleti su najučestaliji u području između Ličkog sredogorja i Ličke Plješivice, na DC-217 (ova je cesta ujedno i najopasnija što se tiče naleta

jer se godišnje na 100 km ceste dogodi 19 naleta na krupne vrste) i DC-1. Unutar DC-1 postoji razlika u učestalosti naleta, koja može biti uvjetovana i činjenicom da dio državnih cesta prolazi uz ili kroz Nacionalni park „Plitvička jezera“. Ostala dva nacionalna parka („Sjeverni Velebit“ i „Paklenica“) nisu u izravnom doticaju s državnim cestama nego samo s lokalnim i županijskim cestama. Do sada su na cestama koje prolaze kroz ili uz NP „Plitvička jezera“ (DC-1, DC-42, DC-52 i DC-429) bilježeni naleti vozila na krupnu divljač, no činjenica je da su manje učestali jer je na dionici 12 državne ceste DC-1 (dionica predstavlja granicu između NP „Plitvička jezera“ i susjednog lovišta) zabilježena manja učestalost naleta nego na dionicama 13 i 14 iste ceste, koje se nastavljaju prema jugu. To ukazuje i da je gustoća populacije divljih parnoprstaša u nacionalnom parku niža nego u lovištima, što se poklapa s istraživanjima Adamiča [143].

Kao hipotetski razlozi izrazite učestalosti naleta na DC-217, mogu se izdvojiti visoka gustoća populacije krupne divljači (uvjetovana niskom nadmorskom visinom i dostupnosti vode tijekom cijele godine, što povećava koncentraciju divljači), mala zavojitost traste ceste te mali nagib, odnosno u konačnici – visoka gustoća populacije u kombinaciji s uvjetima povoljnim za brzu vožnju vozila. Višekriterijska analiza, koja je obrađena u trećem poglavlju doktorskog rada treba dati odgovor na pitanje koja je najopasnija dionica državnih cesta u Ličko-senjskoj županiji od pojave krupne divljači.



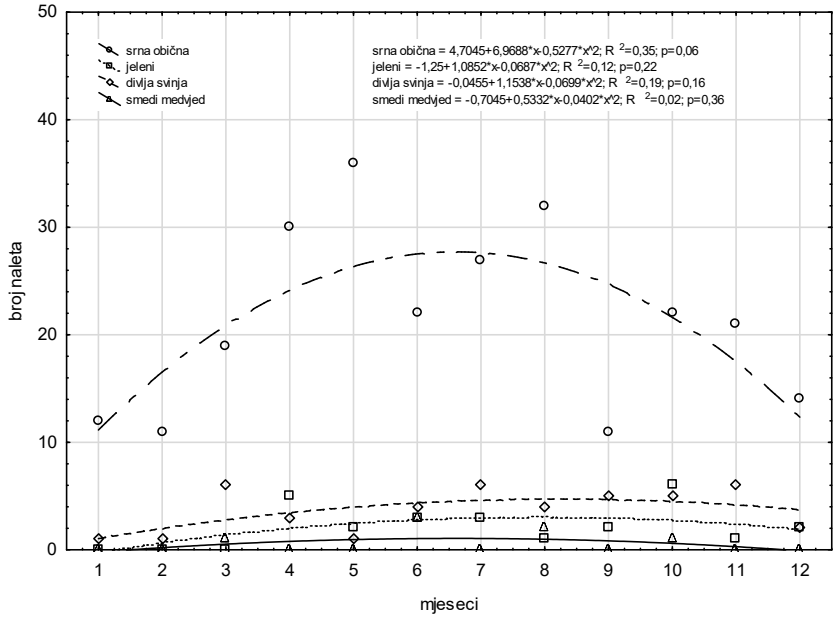
Slika 11. Učestalost naleta po dionicama državnih cesta Ličko-senjske županije na krupnu divljač tijekom promatranog razdoblja (2012. - 2016.)

Tablica 5. Broj naleta vozila krupne divljači i sivog vuka na državnim cestama Ličko-senjske županije po dionicama tijekom razdoblja 2012. - 2016. te gustoća naleta

CESTA	DIONICA	NAZIV	BROJ NALETA	DULJINA DIONICE (km)	BROJ NALETA NA 100 km	BROJ NALETA NA 100 km GODIŠNJE
DC-1	12	Grabovac (DC-42) – Vrelo Koreničko (DC-52)	39	23,00	33,91	6,78
DC-1	13	Vrelo Koreničko (DC-52) – Mutilić: čvorište Udbina (DC-522)	91	33,17	54,87	10,97
DC-1	14	Mutilić: čvorište Udbina (DC-522) – Gračac (DC-27)	26	11,58	44,91	8,98
DC-8	7	Senj (DC-23) – Stinica (DC-405/LC-59148)	32	36,67	17,45	3,49
DC-8	8	Jablanac (DC-405) – Prizna (DC-406)	2	13,00	3,08	0,62
DC-23	3	Jezerane (ŽC-5191) – Žuta Lokva (DC-50)	9	19,19	9,38	1,88
DC-23	4	Žuta Lokva (DC-50) –Senj (DC-8)	8	22,26	7,19	1,44
DC-25	1	Korenica (DC-1) – Lički Osik (DC-50)	9	36,57	4,92	0,98
DC-25	2	Lički Osik (DC-50) – Karlobag (DC-8)	7	47,26	2,96	0,59
DC-50	1	Žuta Lokva (DC-23) – Špilnik (DC-52)	27	21,47	25,15	5,03
DC-50	2	Špilnik (DC-52) – Lički Osik (DC-25)	8	34,37	4,66	0,93
DC-50	3	Gospić (DC-25) – Lovinac (ŽC-5165)	27	31,99	16,88	3,38
DC-50	4	Lovinac (ŽC-5165) – Gračac (DC-27)	12	15,19	15,80	3,16
DC-52	1	Špilnik (DC-50) - Korenica (DC-1)	31	41,11	15,08	3,02
DC-217	1	Ličko Petrovo Selo (DC-1) – Novo Selo Koreničko: GP Ličko Petrovo Selo (granica RH/BIH)	14	2,97	94,28	18,86
DC-218	1	Nebljusi: GP Užljebić (Granica RH/BIH) –Dobroselo (ŽC-5203)	14	30,08	9,31	1,86
DC-218	2	Dobroselo (ŽC-5203) – Bruvno (DC-1)	1	8,70	2,30	0,46
DC-429	1	Selište Drežničko (DC-42) – Prijeboj (DC-1)	12	14,1	17,02	3,4
DC-522	1	Mutilić (DC-1) – Gornja Ploča: čvor Gornja Ploča (A1)	21	13,19	31,84	6,37
DC-534	1	Gospić (DC-25) –Lički Osik: čvorište Gospić (A1)	1	2,45	8,16	1,63

2.6.2. Vremenski obrasci naleta vozila na glavne vrste krupne divljači za definiranje modela na istraživanom području

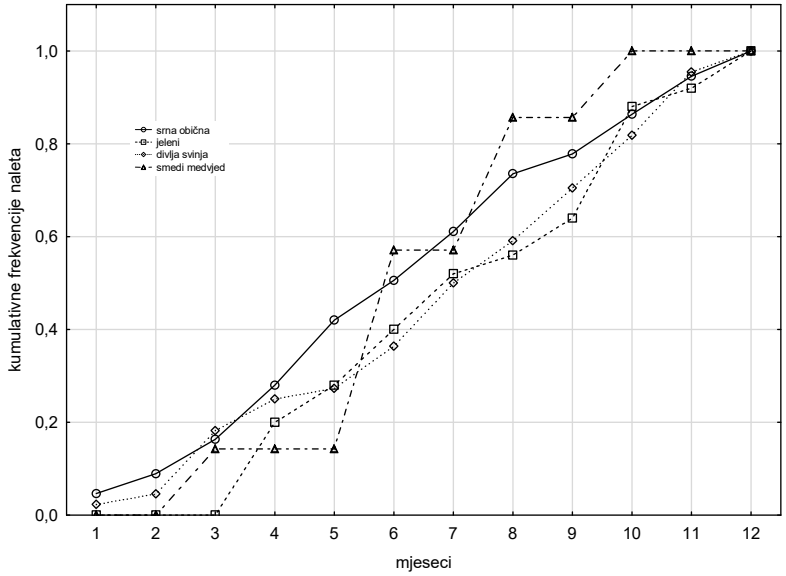
Mjesečna dinamika naleta vozila na glavne vrste krupne divljači (srna obična, jeleni, divlja svinja i smeđi medvjed) pokazuju izvjesnu sinusoidu (*grafikon 10.)* pri čemu je najizraženija ona u srne obične, odnosno ona je na samome pragu signifikantnosti ($R^2 = 0,35$; $p = 0,06$). Osim srne, određenu pravilnost (ali ne i statistički pouzdanu) pokazuje divlja svinja ($R^2 = 0,19$; $p = 0,16$). Pri tome se može uočiti kako je kulminacija naleta vozila na srneću divljač tijekom razdoblja (travanj) svibanj - kolovoz, dok kod divlje svinje ona nastupa kasnije (kraj ljeta - početak jeseni), slično kao i kod jelena. Generalno, jelen obični i jelen lopatar imaju relativno sličnu godišnju fenologiju parenja te ciklusa rasta i razvoja rogovlja s time da kod jelena lopatara fenološke mijene kasne mjesec dana [146], [147], s toga je to još jedan razlog objedinjavanja ove dvije vrste prilikom obrade podataka o naletima.



Grafikon 10. Mjesečna dinamika naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije tijekom razdoblja (2012. - 2016.)

Za razliku od prethodnih vrsta smeđi medvjed pokazuje izvjesnu specifičnost u životnom ciklusu. Njegovo razdoblje parenja slično je kao i kod srneće divljači (ljetno razdoblje, točnije lipanj - kolovoz), no tijekom zime se brloži, odnosno uglavnom miruje. Pri tome bira relativno mirna i teško dostupna mjesta. Razdoblje brloženja, tijekom toplog

zimskog vremena može i prekinuti [146]. Stoga je i teško za očekivati da će za vrijeme zima bogatih snijegom poduzimati bilo kakve aktivnosti, što je potpuno suprotno s obzirom na jelene, a osobito s divljom svinjom.



Grafikon 11. Kumulativna frekvencija mjesečne dinamike naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije tijekom razdoblja (2012.-2016.)

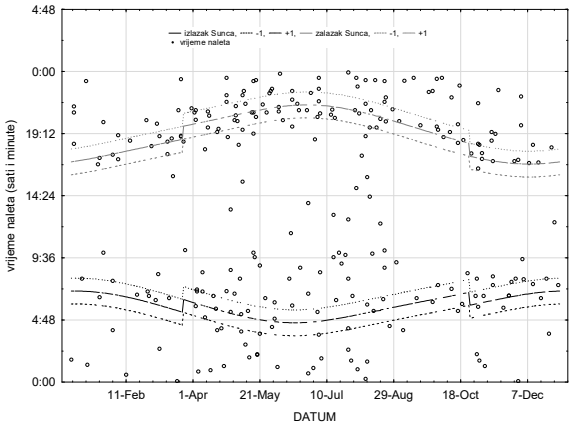
Iako je kod srne obične ustanovljena određena godišnja pravilnost u dinamici naleta, same kumulativne frekvencije dinamike naleta među vrstama ne pokazuju razlike *(grafikon 11.)*, što je potvrđeno Kolmogorov-Smirnov testom *(tablica 6.)*. Međutim, iz *grafikona 10.* i *11.* se može uočiti kako kod srneće divljači postoje dvije kulminacije naleta. Prva je, već spomenuta, u razdoblju travanj - kolovoz, dok je druga u razdoblju listopad - studeni. Stoga i ne čudi kako na razini kumulativnih frekvencija nisu nađene razlike između dinamika naleta na srne i ostale vrste krupne divljači.

Tablica 6. Rezultati analize Kolmogorov-Smirnov testa za kumulativne frekvencije mjesečnih naleta krupne divljači na državnim cestama Ličko-senjske županije za razdoblje 2012. - 2016.

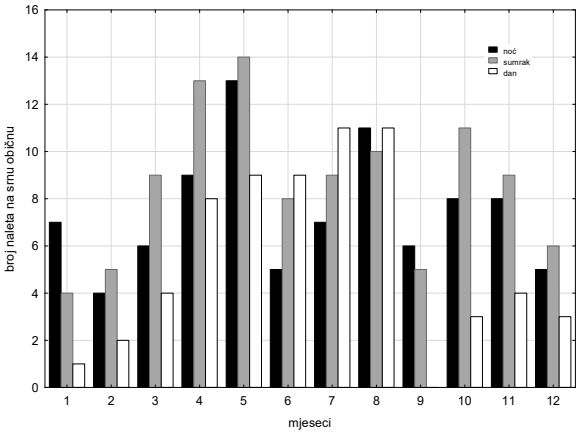
Skupina 1	Skupina 2	$\overline{X}_1$	$\overline{X}_2$	St. Dev.$_1$	St. Dev.$_2$
Srna obična	Jeleni	0,536641	0,450000	0,337352	0,364667
Srna obična	Divlja svinja	0,536641	0,475379	0,337352	0,339661
Srna obična	Smeđi medvjed	0,536641	0,523810	0,337352	0,414636
Jeleni	Divlja svinja	0,450000	0,475379	0,364667	0,339661
Jeleni	Smeđi medvjed	0,450000	0,523810	0,364667	0,414636
Divlja svinja	Smeđi medvjed	0,475379	0,523810	0,339661	0,414636

Na razini godine tijekom dana se događa signifikantno najmanje naleta (22 %) nego tijekom noći (37 %) i sumraka (41 %, $F = 11{,}3819$; $p < 0{,}001$). Naleti tijekom noći („noćni naleti“) na srneću divljač mogu se dogoditi u bilo koje doba godine. Isto vrijedi i za nalete koji se događaju od izlaska do zalaska sunca (naleti tijekom dana), ali u samo specifični dio godine. Naleti tijekom dana pretežno su vezani za određeno razdoblje u godini (travanj – kolovoz).

Naime, tijekom najučestalijeg razdoblja naleta (travanj - kolovoz), naleti tijekom dana mogu se doslovno dogoditi u bilo koje vrijeme *(grafikon 12.)*. Međutim, učestalost naleta s obzirom na količinu dnevnog svjetla, odnosno doba dana mijenja se tijekom godine. Tijekom siječnja naleti su najučestaliji tijekom noći, a tek onda tijekom sumraka *(grafikon 13.)*. Međutim, već tijekom ožujka slika naleta se značajno mijenja, odnosno naleti na srnu više nisu najučestaliji tijekom noći nego tijekom izlaska (zora) i zalaska (suton) sunca. Doduše, to se može već primijetiti i u veljači, ali još uvijek nije tako izraženo. Već je rečeno kako od početka travnja naleti pokazuju izrazitu učestalost, no sada se već može primijetiti kako se izjednačavaju učestalosti naleta na srnu tijekom noći i tijekom dana. Tijekom svibnja noćni i sumračni naleti ponovo postaju dominantni, no tijekom lipnja i srpnja danji naleti imaju dominaciju, a zanimljivo je kako u kolovozu dolazi do određenog izjednačavanja u frekvenciji naleta tijekom sva tri doba dana (dan, noć i sumrak), te u rujnu noćni naleti postaju ponovo najučestaliji (iako je razlika s naletima u sumrak gotovo zanemariva). Nakon toga, do kraja godine, ponovo počinju dominirati naleti koji se dogode tijekom sumraka, a nakon njih slijede naleti tijekom noći. Generalno, naleti tijekom dana se mogu dogoditi tijekom cijele godine (izuzetak je rujan kada tijekom dana nije zabilježen niti jedan nalet), ali dominiraju svega dva mjeseca (lipanj i srpanj).

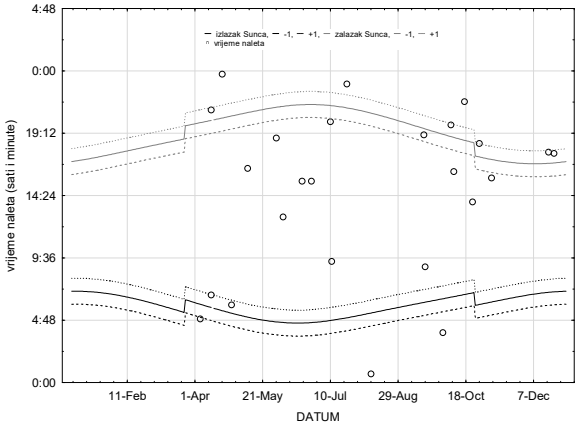


Grafikon 12. Dnevne fluktuacije naleta vozila na srnu običnu tijekom godine

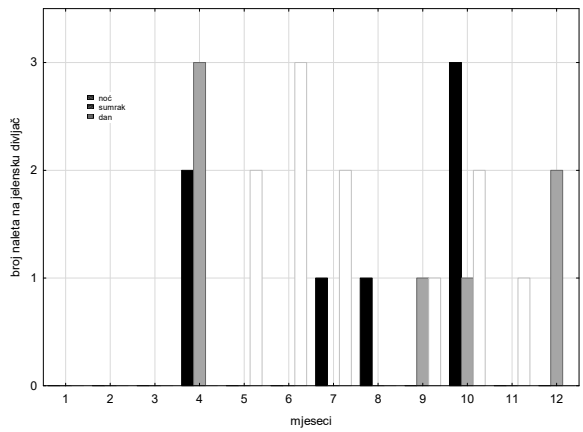


Grafikon 13. Godišnje fluktuacije u učestalosti naleta vozila na srnu običnu s obzirom na doba dana

Iako je broj naleta na jelene predstavljen relativno malim brojem uzoraka, mogu se povući određene zakonitosti. Naime, osim što tijekom zimskih mjeseci nije bilo naleta, oni koji su se dogodili tijekom ljetnih mjeseci dogodili su se tijekom svih dijelova dana *(grafikon 14.)*. Udio naleta tijekom noći i sumraka bio je 25 %, a tijekom dana se dogodilo 50 % naleta. Usprkos tome nema statistički značajne razlike učestalosti naleta tijekom spomenutih dijelova dana (F = 1,254; p = 0,303). Moguć uzrok tome je i izvjesna nepravilnost u dinamici naleta s obzirom na dio dana *(grafikon 15.)*. Tijekom travnja naleti su se događali tijekom sumraka i noći, a tijekom ljetnih mjeseci glavnina naleta je bila tijekom dana. Krajem jeseni i zime naleti su ponovo počeli biti učestaliji tijekom sumraka i noći. Pri tome je izuzetak mjesec studeni, kada se dogodio samo jedan nalet i to tijekom dana. Međutim, ako se pogleda *grafikon 14.*, tada se može uočiti kako je taj nalet bio na prijelazu iz dana u suton.



Grafikon 14. Dnevne fluktuacije naleta vozila na jelena običnog tijekom godine

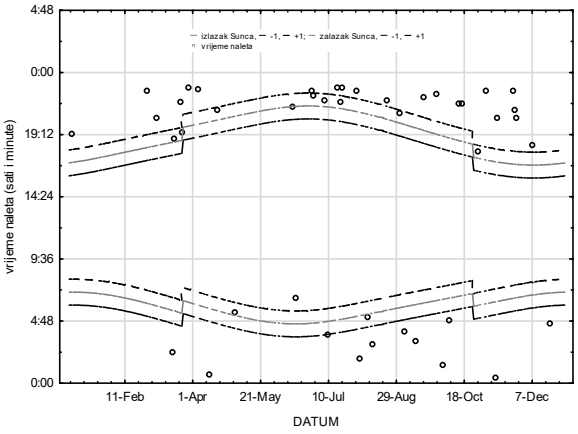


Grafikon 15. Godišnje fluktuacije u učestalosti naleta vozila na jelena običnog s obzirom na doba dana

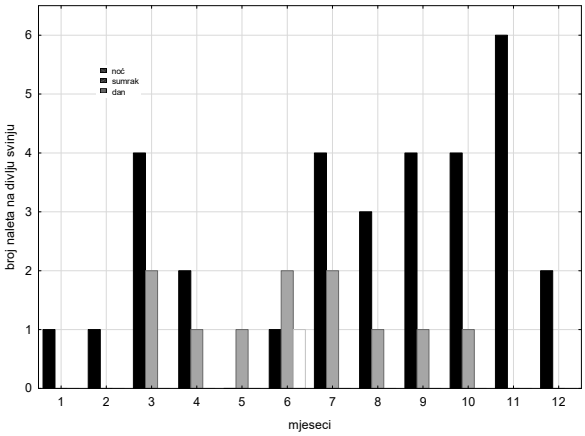
Za razliku od prethodne dvije skupine divljači, divlja svinja pokazuje tendenciju stradavanja na prometnicama gotovo isključivo tijekom noći i sumraka. Iako je udio stradalih

grla tijekom noći 72 %, a tijekom sumraka 26 % nije nađena statistički značajna razlika između ova dva doba dana (χ^2 = 20,403; p < 0,05). Isto tako nije nađena ni signifikantna razlika između učestalosti naleta tijekom sumraka i dana usprkos tome što je udio naleta vozila na divlju svinju za vrijeme dana svega 2 %. Jedina statistički značajna razlika je da divlja svinja stradava učestalije tijekom noći nego tijekom dana.

Osim toga na *grafikonu 16.* se jasno može uočiti kako je samo vrijeme stradavanja divlje svinje tijekom noći relativno postojano, dok je stradavanje u sumrak učestalije u suton nego u zoru. Štoviše, vremena naleta vozila na divlju svinju tijekom sumraka se nalaze gotovo na prijelazu sutona u noć. Nalet vozila na divlju svinju tijekom dana se dogodio samo jednom u promatranom razdoblju i to u jutro samog početka lipnja. Generalno, na razini godine tijekom svih mjeseci dominiraju „noćni naleti". Sumračni naleti se javljaju od ožujka do listopada i ne dosežu ni polovicu noćnih naleta *(grafikon 17.)*.



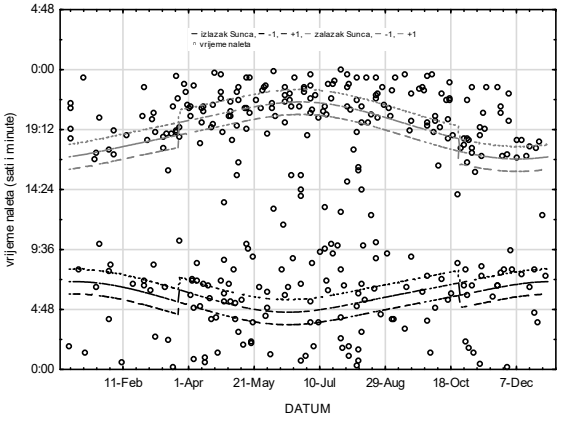
Grafikon 16. Dnevne fluktuacije naleta vozila na divlju svinju tijekom godine



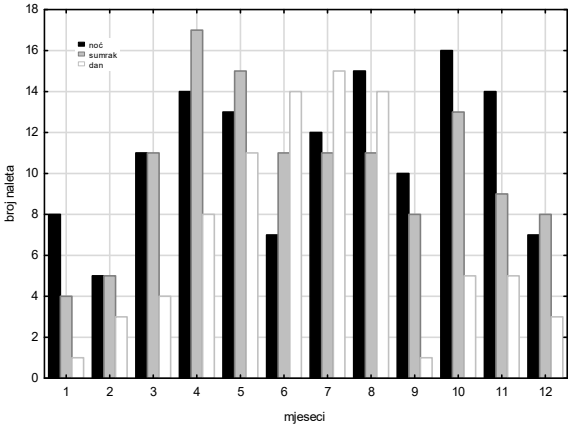
Grafikon 17. Godišnje fluktuacije u učestalosti naleta vozila na divlju svinju s obzirom na doba dana

Budući da su pri naletu vozila na krupnu vrstu divljači rizici od velike materijalne štete ili fatalnog ishoda visoki u konačnoj analizi vremenskih obrazaca naleta objedinjene su sve vrste krupne divljači. U analizu su osim srne obične, jelena i divlje svinje uključeni i podaci o naletima na 8 grla medvjeda, 2 grla muflona i 3 grla vuka. Ovih 12 novo pridodanih grla nisu znatnije utjecali na ukupnu sliku vremenskih obrazaca naleta. Uzrok tome je velik udio srnećih grla u ukupnom uzorku naleta. I dalje se vidi kako tijekom ljeta dolazi do povišenog rizika naleta *(grafikon 18.)*, a noćni naleti se javljaju tijekom cijele noći, bez izrazitije tendencije prema sumracima. Generalno, na godišnjoj razini najučestaliji naleti su tijekom noći (41 %) i sumraka (37 %), dok su preko dana nešto rjeđi (22 %). Pri tome su noćni naleti signifikantno učestaliji od jutarnjih (F = 11,7; p < 0,05).

Ukupna slika naleta s obzirom na doba dana je učinila distribuciju naleta na razini vrste nešto preciznijom. Naime, zbog jelena, divlje svinje, ali i novih vrsta (europski muflon, smeđi medvjed i vuk), nešto je porastao udio dnevnih naleta tijekom jeseni *(grafikon 19.)*, ali se dosta izmijenila slika naleta tijekom kolovoza. Naime, tijekom lipnja i srpnja i dalje dominiraju dnevni naleti, dok već u kolovozu dolazi do dominacije noćnih naleta, koji (izuzev prosinca) čine najučestaliju skupinu sve do siječnja.



Grafikon 18. Dnevne fluktuacije naleta vozila na krupne divlje životinje tijekom godine



Grafikon 19. Godišnje fluktuacije u učestalosti naleta vozila na krupne divlje životinje s obzirom na doba dana

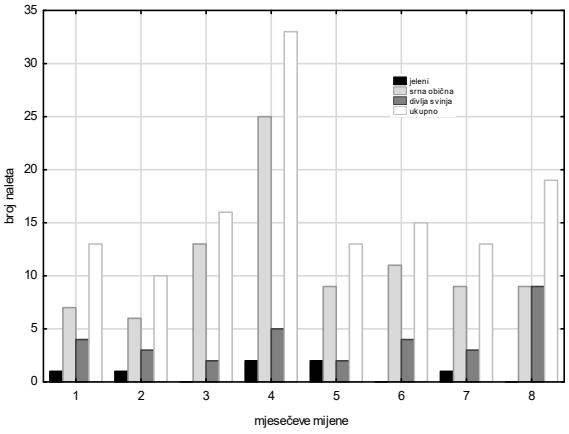
Zbog pretpostavke da mjesečeve mijene uzrokuju promjene u aktivnosti divljači tijekom noći i sumraka (uobičajene smanjene vidljivosti) načinjena je regresijska analiza dinamike naleta tijekom tih razdoblja. Treba istaknuti kako tijekom lunarnog ciklusa mjesec tijekom noći nije jednako osvijetljen. Razina osvjetljenja mijenja se u skladu sa slijedećim Mjesečevim mijenama (*slika 7.*) :

- noć tijekom mlađaka (oznaka 1) nije osvijetljena mjesečinom
- tijekom razdoblja 2 (rastuće srpolik) i 8 (padajuće srpolik) osvijetljena je ¼ Mjeseca
- tijekom razdoblja 3 (prva četvrt) i 7 (zadnja četvrt) osvijetljena je ½ Mjeseca
- tijekom razdoblja 4 (rastuće ispupčen) i 6 (padajuće ispupčen) osvijetljeno je ¾ Mjeseca i
- tijekom razdoblja uštapa (punog mjeseca, oznaka 5) osvijetljen je cijeli Mjesec.

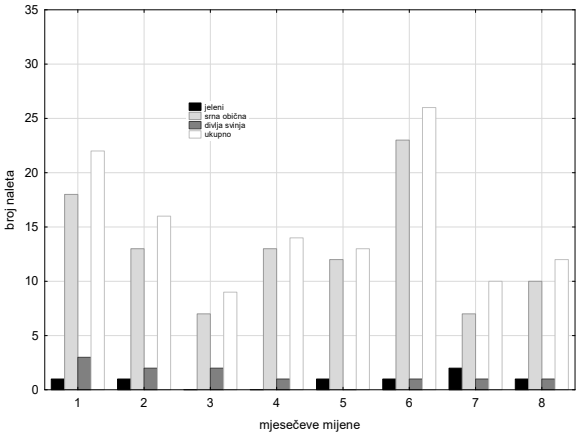
Na ukupnoj razini naleta na razmatrane vrste (jeleni, srna obična, divlja svinja, europski muflon, smeđi medvjed i vuk), tijekom noći, postoji izvjesna sinusoida naleta *(grafikon 20.)* te se čini kako s povećanjem razine osvijetljenosti Mjeseca raste i broj naleta. Pri tome je najviše naleta tijekom noći bilo za vrijeme faze rastuće ispupčenog Mjeseca (faza

4). Ovisno o vrsti ta se distribucija mijenja. Jeleni ne pokazuju neku ovisnost o mjesečevim mijenama. Srna obična pokazuje tendenciju povećanja naleta s povišenim osvjetljenjem (faze 3 i 4). Kod divlje svinje se može uočiti određena negativna ovisnost o osvijetljenosti Mjeseca. Naime, čini se da ova vrsta izbjegava noćne aktivnosti tijekom punog Mjeseca, odnosno čak i tijekom faza kada je osvijetljenost Mjeseca viša (faze 4 i 6).

Regresijska analiza je pokazala kako nema signifikantne povezanosti između lunarnih faza i intenziteta naleta tijekom noći (jeleni: R^2 = -0,109; p = 0,56; srna obična: R^2 = 0,037; p = 0,39; divlja svinja: R^2 = 0,38; p = 0,12; sveukupno: R^2 = -0,240; p = 0,74).



Grafikon 20. Distribucija naleta krupnih divljih životinja tijekom noći u ovisnosti o mjesečevim mijenama



Grafikon 21. Distribucija naleta krupnih divljih životinja tijekom sumraka u ovisnosti o mjesečevim mijenama

Tijekom sumraka su hodovi nešto nepravilniji *(grafikon 21.)*. Na ukupnoj razini (sve vrste zajedno) može se uočiti pad naleta od faze 1 do faze 3, a nakon toga povećanje do faze 6 i opet nagli pad, no od faze 7 do faze 1 ponovo dolazi do povećanja frekvencije naleta. Gledano na razini vrste ovakav hod upravo pokazuje srna obična, no ta ovisnost nije statistički značajna (R^2 = -0,34; p = 0,89), kao što nije značajna ni na ukupnoj razini (R^2 = -0,290; p = 0,82). Kod jelena se ponovo ne može uočiti nekakva povezanost, što je potvrđeno i statistički (R^2 = 0,07; p = 0,36), no za divlju svinju se može reći kako postoji povezanost (R^2 = 0,76; p < 0,05). Prema *grafikonu 21.* naleti na divlju svinju su najučestaliji tijekom onih sumraka kod kojih je Mjesec najmanje osvijetljen (faze 1, 6, 7 i 8), dok tijekom punog Mjeseca uopće nije bilo naleta.

3. MODEL PREPOZNAVANJA OPASNIH DIONICA

U analizi i izboru modela korišten je programski alat Akaike Information Criterion (AIC), [126]. Programski alat Akaike Information Criterion uspoređuje kvalitetu skupa statističkih modela i procjenjuje kvalitetu svakog modela u odnosu na svaki drugi model. Temeljna postavka AIC analize jest da se neka pojava (zavisna varijabla) treba opisati sa što manje nezavisnih varijabli (pretkazivača). Pri tome je najpovoljniji model onaj s najnižom AIC vrijednosti. Izbor modela je uslijedio ukoliko je $\Delta AIC < 2$ jedinice. Isto tako je računana i Akaike-ova težina (w_i), koja predstavlja vjerojatnost da je model najbolji među ostalim uspoređivanim modelima.

Za izračun pretkazivanja vjerojatnosti naleta vozila na divlju životinju (0 = nema naleta u ćeliji ili 1 = u ćeliji se dogodio nalet) korištena je logistička stepenasta regresija unaprijed [148]. Za određivanje signifikantnosti svakog modela, korišten je log - lokelihood ratio test, odnosno test omjera vjerojatnosti koji procjenjuje dobru usklađenost dva konkuretna statistička modela. Signifikantnost koeficijenata zavisnih varijabli (pretkazivača) je bazirana na χ^2 Wald statistici (Wald-ov χ^2). Relativna važnost nezavisnih varijabli (pretkazivača) unutar svakog modela, je dobivena množenjem višestrukih koeficijenata logističke regresije (β) sa standardnom devijacijom svake varijable. Za procjenu doprinosa rasta jedinice nezavisnih varijabli (pretkazivača) na vjerojatnost WVC-a, korišten je omjer izgleda [149].

Za izračun pretkazivanja broja naleta po ćeliji korištena je klasična višestruka regresija [150]. Pri tome se broj naleta po ćeliji, kao zavisna varijabla kreće od 1 do n (ovisno o veličini ćelije), a u analizi su, isto kao i pri logističkoj regresiji korišteni pretkazivači koje je kao značajne za određeni model izdvojila AIC analiza.

Zaključno, AIC analiza daje modele procjene vjerojatnosti naleta i modele procjene broja naleta vozila na divljač za svaki polumjer ćelije posebno, a logistička regresija daje pouzdanost rezultata u postotcima procjene.

Opasne dionice državnih cesta, od pojave divljači u Ličko-senjskoj županiji, rangirane su višekriterijskom analizom primjenom analitičkog hijerarhijskog procesa (AHP metodom). Višekriterijsko odlučivanje je skup metoda koje omogućuju istovremeno korištenje više različitih kriterija kako bi se iz skupa varijanti odabrala optimalna s obzirom na zadanu funkciju cilja [151]. Usporedba kriterija izvedena je prema opisu odnosa kriterija iz tzv.

Saaty - jeve skale [152]. Za AHP metodu višekriterijskog vrednovanja korišten je programski alat Expert Choice [153].

Kako bi se dobio što precizniji model prepoznavanja opasnih dionica od pojave divljači korišteni su prostorni obrasci naleta vozila na krupnu divljač te su napravljene i dvije vrste modela prepoznavanja opasnih dionica i to model procjene vjerojatnosti naleta i model procjene broja naleta vozila na divljač. Da bi se od svih ponuđenih modela definirao što točniji i što pouzdaniji model jasno su definirane nezavisne varijable ili pretkazivači.

U modele su uvrštene nezavisne varijable ili pretkazivači ceste (PGDP, PLDP, koeficijent zavojitosti ceste, udio cesta); broj naleta u ćeliji; pretkazivači krajobraza (udio ploština voda, mora, obala, goleti, vriština i bujadnica, šikara, šuma, voćnjaka, travnjaka, izgrađenog zemljišta, zapuštenog poljoprivrednog zemljišta, oranica, udaljenost od stalnog vodotoka ili jezera te udaljenost od izvora ili lokve); pretkazivač granice i pretkazivač brojnosti divljači (odstrelna kvota divljači). Oznake korištene u modelima svake navedene nazavisne varijable ili pretkazivača su:

- SO – Srna obična
- DS – Divlja svinja
- TPI ili TOPEX – Indeks topografske pozicije
- N_{uk} – događaj naleta u ćeliji na krupnu životinjsku vrstu
- BN_{uk} – ukupan broj naleta u ćeliji na krupnu životinju
- N_{SO} – događaj naleta u ćeliji na srnu običnu
- BN_{SO} – ukupan broj naleta u ćeliji na srnu običnu
- N_{DS} – događaj naleta u ćeliji na divlju svinju
- BN_{DS} – ukupan broj naleta u ćeliji na divlju svinju
- ROK_{uk} – relativna odstrelna kvota (grla/100 ha) krupne divljači
- ROK_{DS} – relativna odstrelna kvota (grla/100 ha) divlje svinje
- ROK_{SO} – relativna odstrelna kvota (grla/100 ha) srne obične
- CZ – koeficijent zavojitosti ceste u ćeliji
- $Ceste_{\%}$ – udio cesta
- $ZPZ_{\%}$ – udio zapuštenog poljoprivrednog zemljišta
- $Golet_{\%}$ – udio goleti
- $Izgrađeno_{\%}$ – udio izgrađnog zemljišta
- $Šume_{\%}$ – udio šuma
- $VB_{\%}$ – udio vriština i bujadnica
- $Voćnjaci_{\%}$ – udio voćnjaka
- $More_{\%}$ – udio mora
- $Izvor_{m}$ – udaljenost do izvora
- ST_{m} – udaljenost do stajaćice ili tekućice
- $Granice_{km}$ – duljina ekotona na 100 ha ćelije

- PGDP – prosječni godišnji dnevni promet
- PLDP – prosječni ljetni dnevni promet.

3.1. Prostorni obrasci naleta vozila na divljač i procjena naleta po dionicama ceste

3.1.1. Prostorni obrasci naleta vozila na srnu običnu

U *tablici 7.* uočava se logična zakonitost rasta broja naleta po dionici s povećanjem njena polumjera. Udio takvih opasnih dionica kreće se od 9 % kod ćelija polumjera 100 m do 73 % kod ćelija polumjera 6 000 m, što ukazuje da je vrlo malen broj dijelova ceste na kojima je vjerojatnost naleta mala. Isto tako, s porastom polumjera ćelije raste i broj vjerojatnih naleta po ćeliji. Pri polumjeru od 100 m na dvije dionice je zabilježeno čak 6 naleta što je čini izrazito opasnom. Kod polumjera od 500 m na jednoj dionici je zabilježeno 7 naleta, kod polumjera 1 000 m na 2 dionice je zabilježeno 11 naleta, a kod polumjera 6 000 m su zabilježene po jedna dionica s 21, 24, 28 i čak 38 naleta u pet godina istraživanja. Ovo ukazuje kako u analizi prostornih obrazaca naleta nije važna samo vjerojatnost da će vozilo naletjeti na srnu nego i razina opasnosti (broj naleta se, ovisno o duljini dionice, može kretati od jednog do čak 38).

Budući da korelacijska analiza nije pokazala ikakvu povezanost između nastanka naleta (0 = nema naleta, 1 = nalet) i svake pojedine potencijalne nezavisne varijable (pretkazivača) pri polumjeru ćelije od 100 m za istu duljinu dionice ceste nije bilo moguće načiniti AIC analizu. Rezultati AIC analize za vjerojatnost naleta vozila na srnu običnu prikazani su u *tablicama 8.*, *9.*, *10.* i *11.*.

Tablica 7. Broj dionica u kojima nije zabilježen nalet te dionica s određenim brojem naleta vozila na srnu običnu

BROJ NALETA	POLUMJER ĆELIJE (m)				
	100	**250**	**500**	**1 000**	**6 000**
0	2 367	891	382	157	12
1	173	118	90	39	3
2	37	34	25	25	2
3	17	12	18	15	6
4	5	5	5	7	3
5	11	5	4	9	0
6	2	2	4	3	4
7			1	3	1
8				1	0
9				0	1
10				0	1
11				2	0
12					3
13					1
14					1
15					1
18					2
21					1
24					1
28					1
38					1
BROJ DIONICA S NALETOM	**245**	**176**	**147**	**104**	**33**
UKUPNO	2 612	1 067	529	261	45
UDIO DIONICA S NALETOM (%)	9	16	28	40	73

Tablica 8. . Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 250 m

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{DS}+ ZPZ%+Golet%+VB%+Voćnjaci%+ ST_m+PGDP	7	899,05	0,00	0,06
2.	ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PGDP	8	899,38	0,33	0,05
3.	ROK_{SO}+ ZPZ%+Golet%+VB%+More%+ ST_m +PGDP	7	900,48	1,43	0,03
4.	ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+More%+ ST_m +PGDP	7	900,55	1,50	0,03
5.	ROK_{DS}+ ZPZ%+Golet%+More%+ ST_m +PGDP	6	900,61	1,56	0,03
6.	ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m +PGDP	8	900,72	1,67	0,03
7.	ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m +PLDP	7	900,91	1,86	0,02
8.	ROK_{DS}+ ZPZ%+Golet%+VB%+Voćnjaci%+More%+ ST_m +PGDP	8	901,03	1,98	0,02
9.	ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m +PGDP+PLDP	8	901,04	1,99	0,02

Tablica 9. Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 500 m

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{UK}+ CZ+ $ZPZ_{\%}$+$Golet_{\%}$+ $More_{\%}$+ST_m	6	607,96	0,00	0,03
2.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m	5	608,36	0,40	0,03
3.	ROK_{UK}+ROK_{SO}+ CZ+ $ZPZ_{\%}$+$Golet_{\%}$+ $More_{\%}$+ST_m	7	608,53	0,57	0,03
4.	ROK_{UK}+ CZ+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+ $More_{\%}$+ST_m	7	608,67	0,71	0,02
5.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m	6	608,80	0,84	0,02
6.	ROK_{UK}+ROK_{SO}+ CZ+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+ $More_{\%}$+ST_m	8	608,96	1,00	0,02
7.	ROK_{SO}+ CZ $ZPZ_{\%}$+$Golet_{\%}$+ +$More_{\%}$+ST_m	6	608,96	1,00	0,02
8.	ROK_{UK}+ ROKSO+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m	6	609,01	1,05	0,02
9.	ROK_{UK}+ ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m	7	609,13	1,17	0,02
10.	ROK_{SO}+ CZ+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+ $More_{\%}$+ST_m	7	609,64	1,68	0,01
11.	ROK_{UK}+ CZ+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ $More_{\%}$+ST_m	7	609,74	1,78	0,01
12.	ROK_{UK}+ CZ+ $ZPZ_{\%}$+$Golet_{\%}$+$Voćnjaci_{\%}$+ $More_{\%}$+ST_m	7	609,84	1,88	0,01
13.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$More_{\%}$+ST_m	6	609,84	1,88	0,01

Tablica 10. Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 1 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{DS}+$ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$	4	372,77	0,00	0,08
2.	ROK_{DS}+$ZPZ_{\%}$+$Golet_{\%}$+$Ceste_{\%}$+$More_{\%}$	5	374,01	1,24	0,04
3.	ROK_{DS}+$Golet_{\%}$+$More_{\%}$	3	374,07	1,30	0,04
4.	ROK_{DS}+$ZPZ_{\%}$+$Golet_{\%}$+$Voćnjaci_{\%}$+$More_{\%}$	5	374,38	1,61	0,04
5.	ROK_{DS}+$ZPZ_{\%}$+$Golet_{\%}$+$Travnjak_{\%}$+$More_{\%}$	5	374,52	1,75	0,03

Tablica 11. Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 6 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	CZ	1	88,69	0,00	0,07
2.	CZ+TOPEX	2	89,00	0,31	0,06
3.	$VB_{\%}$	1	89,03	0,33	0,06
4.	TOPEX	1	89,06	0,37	0,06
5.	PGDP	1	89,07	0,37	0,06
6.	Granice	1	89,17	0,47	0,06
7.	$VB_{\%}$+TOPEX	2	89,80	1,11	0,04
8.	CZ+PGDP	2	89,80	1,11	0,04
9.	CZ+$VB_{\%}$	2	89,80	1,11	0,04
10.	$VB_{\%}$+PGDP	2	89,86	1,16	0,04
11.	$VB_{\%}$+Granice	2	89,96	1,26	0,04
12.	PGDP+Granice	2	90,03	1,34	0,04
13.	PGDP+TOPEX	2	90,05	1,36	0,04
14.	CZ+Granice	2	90,11	1,42	0,04
15.	CZ+$VB_{\%}$+TOPEX	3	90,31	1,62	0,03
16.	CZ+PGDP+TOPEX	3	90,49	1,80	0,03
17.	Granice+TOPEX	2	90,63	1,94	0,03

Ovisno o promjeru ćelije, odnosno duljini dionice ceste broj tipova modela za procjenu vjerojatnosti naleta na srneću divljač dosta varira i kreće se od 5 (polumjer 1 000 m, *tablica 10.*) do čak 17 (polumjer 6 000 m, *tablica 11.*). Međutim, ako se usporede *tablice 8.* do *11.* jasno se može vidjeti kao kod ćelija polumjera 250 do 1 000 m u svakom od modela kao stalne nezavisne varijable (pretkazivači) dolaze brojnost divljači, udio zapuštenog zemljišta i udio mora. Osim spomenutih nezavisnih varijabli (pretkazivača), kod ćelija

polumjera 250 do 1 000 m, iako ne dolaze u svakom modelu, dosta su česti udjeli vriština i bujadnica, te nazočnost ili udaljenost do pojilišta (izvora, lokve ili vodotoka). Prometno opterećenje se kao statistički značajna nezavisna varijabla (pretkazivač) javlja samo pri procjeni naleta u ćelijama polumjera 250 i 6 000 m, a zavojitost prometnice unutar ćelije kod polumjera 500 i 6 000 m.

Usporedbom najpovoljnijih AIC modela s obzirom na polumjer ćelije mogu se uočiti dvije specifične zakonitosti. Prva se odnosi na ovisnost broja nezavisnih varijabli (pretkazivača) u prvom modelu u svakoj tablici i polumjera ćelije. Konkretno, što je polumjer ćelije veći to je broj nezavisnih varijabli (pretkazivača) vjerojatnosti naleta manji. On se kreće od K = 7 (polumjer 250 m) do K = 1 (polumjer 6 000 m). Druga pojava se odnosi na vrijednosti AIC, odnosno vrijednost najpovoljnijeg modela pada s porastom polumjera ćelije, što ukazuje da s porastom polumjera ćelije raste i vrijednost pretkazivanja naleta. Tako je AIC vrijednost modela procjene naleta na srnu običnu za polumjer ćelije 250 m = 899,05 *(tablica 8.)*, kod polumjera od 500 m je 608,36 *(tablica 9.)*, kod polumjera 1 000 m 372,77 *(tablica 10.)*, a kod polumjera od 6 000 m *(tablica 11.)* svega 88,69, što ukazuje i na najviši postotak procjene točnosti.

Čini se da je pri polumjeru od 6 000 m zahvaćen dovoljno veliki prostor pri kome su anulirani sinergijski utjecaji velikog broja nezavisnih varijabli *(tablica 11.)* te se kao ključne nezavisne varijable javljaju one iz skupine značajki ceste (zavojitost, reljef te PGDP), a samo iznimno nezavisne varijable (pretkazivači) iz skupine stanišnih značajki (udio vriština i bujadnica te raznolikost staništa izražena u duljini ekotona na 100 ha).

Logističkom regresijom nije bilo moguće procijeniti vjerojatnost naleta za ćelije polumjera 250 m, no s obzirom na veće ispitane polumjere *(tablica 12.)* točnost procjene naleta se kreće od 68,20 (polumjer 1 000 m) do čak 77,78 % (polumjer 6 000 m).

Iz spomenute analize svakako treba istaknuti kontradiktorne utjecaje (predznake) pojedinih nezavisnih varijabli (pretkazivača). Kod ćelija polumjera 500 m u predviđanju vjerojatnosti naleta proizlazi da su naleti u negativnoj ovisnosti s brojnošću krupne divljači i udjelu zapuštenog zemljišta te pozitivnoj ovisnosti s udjelom goleti i mora, što nije logično. Stoga procjenu vjerojatnosti naleta na dionici ceste od 1 km (polumjer 500 m) treba uzeti s pričuvom. Od operativne je važnosti vjerojatnost naleta predvidjeti na što kraćoj dionici ceste. Stoga bi za procjenu vjerojatnosti naleta srne obične najmanja dionica ceste bila 2 000 m (polumjer ćelije 1 000 m), a točnost predviđanja je 68,20 % pri čemu se kao nezavisne

varijable (pretkazivači) mogu koristiti brojnost srne obične (pozitivan, ali nelogičan procjenitelj), udio zapuštenog poljoprivrednog zemljišta (pozitivan i logičan procjenitelj) te udjeli goleti i mora koji pokazuju negativnu ovisnost s vjerojatnošću naleta).

Tablica 12. Vrijednost parametara za procjenu vjerojatnosti naleta vozila na srnu običnu dobivenih logističkom regresijom pri različitim polumjerima ćelija

NEZAVISNE VARIJABLE (PRETKAZIVAČI)	POLUMJER ĆELIJE (m)		
	500	**1 000**	**6 000**
konstanta	8,265	-0,87571	1,611033
ROK_{UK}	-1,16555	-	-
ROK_{DS}	-	1,878384	-
CZ	-	-	-0,79346
$ZPZ_{\%}$	-2,06415	3,575434	-
$Golet_{\%}$	8,224426	-4,33445	-
$More_{\%}$	7,506149	-4,63726	-
ST_m	-0,72593	-	-
Točnost predviđanja (%)	**73,72**	**68,20**	**77,78**

Ako se oko točaka naleta vozila na srnu običnu povuče krug polumjera 100 m tada se broj naleta na srnu običnu po ćeliji kretao od 0 do 5. U tom je slučaju za procjenu vjerojatnosti broja naleta moguće koristiti 7 relativno slabo pouzdanih modela, pri čemu je prvi najtočniji *(tablica 7.)*. U svih 7 modela kao ključan čimbenik broja naleta vozila na srnu običnu dolazi gustoća populacije srne (populacijska sastavnica modela), zavoji na cesti (izvedba ceste), udio zapuštenog poljoprivrednog zemljišta.

Osim vjerojatnosti naleta na pojedinu vrstu divljači, broj naleta godišnje po dionici je ključan čimbenik sigurnosti u prometu. Naime, vjerojatnost naleta samo ukazuje da li će se tijekom određenog vremena i pri istim (ovo je nužno naglasiti) vrijednostima nezavisnih varijabli (pretkazivača) tijekom godine ili više godina dogoditi nalet ili ne. Broj naleta, dodatno daje informaciju o razini opasnosti naleta jer nije svejedno da li se godišnje na određenoj dionici dogodi jedan ili više naleta. Drugim riječima vjerojatnost procjene broja naleta po dionici opasne dionice dijeli na manje opasne (manji broj naleta) i opasnije (veći broj naleta, odnosno učestaliji naleti).

Tablica 13. Izbor modela varijabilnosti broja naleta srne obične za ćelije polumjera 250 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ ST_m +PGDP	9	1 302,16	0,00	0,16
2.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ ST_m +PGDP	8	1 302,91	0,75	0,11
3.	ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ ST_m +PGDP	8	1 303,96	1,80	0,07
4.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ ST_m +PLDP	8	1 304,05	1,89	0,06
5.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ ST_m +PGDP+PLDP	10	1 304,11	1,94	0,06
6.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$Voćnjaci_{\%}$+$More_{\%}$+ ST_m +PGDP	10	1 304,12	1,96	0,06

Tablica 14. Izbor modela varijabilnosti broja naleta srne obične za ćelije polumjera 500 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	CZ+ROK_{SO}+ ZPZ%+Golet%+VB%+More% +ST_m	7	958,76	0,00	0,07
2.	CZ+ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+More% +ST_m	8	959,14	0,38	0,06
3.	CZ+ ROK_{UK}+ROK_{SO}+ ZPZ%+Golet%+VB%+More% +ST_m	8	959,40	0,64	0,05
4.	CZ+ ROK_{UK}+ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+More% +ST_m	9	959,66	0,90	0,05
5.	CZ+ROK_{SO}+ ZPZ%+Golet%+VB%+Voćnjaci%+More% +ST_m	8	960,09	1,33	0,04
6.	ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+More% +ST_m	7	960,32	1,56	0,03
7.	ROK_{UK}+ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+More% +ST_m	8	960,39	1,63	0,03
8.	CZ+ ROK_{UK}+ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+VB%+More% +ST_m	9	960,40	1,64	0,03
9.	CZ+ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+Voćnjaci%+More% +ST_m	9	960,64	1,88	0,03
10.	CZ+ ROK_{UK}+ROK_{SO}+ ZPZ%+Golet%+VB%+Voćnjaci%+More% +ST_m	9	960,72	1,96	0,03
11.	CZ+ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+VB%+More% +ST_m	8	960,75	1,99	0,03

Tablica 15. Izbor modela varijabilnosti broja naleta srne obične za ćelije polumjera 1 000 i 6 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
POLUMJER ĆELIJE 1 000 m					
1.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Ceste_{\%}$+$More_{\%}$	5	800,29	0,00	0,00
2.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Ceste_{\%}$+$More_{\%}$	6	801,24	0,95	0,00
3.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Voćnjaci_{\%}$+$Ceste_{\%}$+$More_{\%}$	6	802,15	1,86	0,00
POLUMJER ĆELIJE 6 000 m					
1.	PGDP+Granice+TOPEX+ ROK_{DS}	4	457,51	0,00	0,90

Glede broja naleta po dionici ovisno o duljini dionice broj modela, AIC vrijednosti te pouzdanost procjene dosta variraju (*tablice 13.*, *14*. i *15.*). Broj modela ne ovisi o polumjeru ćelije jer je najveći broj modela (11 modela) dobiven za ćelije polumjera 500 m, dok je kod ćelija polumjera 250 m broj pouzdanih modela 6. Za razliku od procjene vjerojatnosti naleta vozila na srnu običnu u slučaju procjene broja naleta po ćeliji za ćelije polumjera 6 000 m pouzdan je svega jedan model.

Za sve polumjere ćelija sastavni dio nezavisnih varijabli su gustoće populacija divljači, bez obzira da li se radi samo o srni, divljoj svinji ili svim vrstama zajedno. No, kod procjene broja naleta za dionice od 12 000 m *(tablica 15.)* kao nezavisne varijable (pretkazivači) nisu prepoznati pojedini stanišni elementi nego samo raznolikost staništa (duljina ekotona – km/100 ha).

Osim gustoće populacije kao ključne nezavisne varijable (pretkazivači) su pronađeni elementi prometa PGDP i TPI (TOPEX).

Udio zapuštenog zemljišta, udio goleti i udio mora su ključne stanišne nezavisne varijable (pretkazivači) broja naleta za dionice duljine 500, 1 000 i 2 000 m, dok je udio vriština i bujadnica ključna nezavisna varijabla (pretkazivač) broja naleta na srnu za dionice od 500 i 1 000 m. Još jedan važan stanišni pretkazivač broja naleta na srnu je svakako i udaljenost do pojilišta, a javlja se kod procjene naleta za dionice od 500 i 1 000 m.

Za razliku od procjene naleta na srnu običnu kod koje je zamijećena pojava kontradiktornih predznaka koeficijenata (utjecaja) varijabli, kod procjene broja naleta se ova pojava ne uočava, što se može vidjeti u *tablici 16*.

Tablica 16. Rezultati analize broja naleta vozila na srnu običnu po dionici državnih cesta s obzirom na različite polumjere ćelija primjenom višestruke regresije

NEZAVISNE VARIJABLE (PRETKAZIVAČI)	POLUMJER ĆELIJE (m)							
	250		500		1 000		6 000	
	b	β	b	β	b	β	b	β
konstanta	-1,061	-	-1,151	-	1,118	-	67,9607	-
ROK_{SO}	0,685	0,0797	2,207	0,173	2,690	0,192	-	-
ROK_{DS}	0,092	0,0206	-	-	-	-	10,0978	0,313
CZ	-	-	-0,089	-0,052	-	-	-	-
$Ceste_{\%}$	-	-			-60,008	-0,092	-	-
$ZPZ_{\%}$	0,43	0,0975	0,975	0,127	2,409	0,148	-	-
$Golet_{\%}$	-0,388	-0,1011	-0,746	-0,115	-1,155	-0,094	-	-
$Izgrađeno_{\%}$	-0,3	-0,0650	-	-	-	-	-	-
$VB_{\%}$	0,293	0,0474	0,493	0,048	-	-	-	-
$More_{\%}$	-0,644	-0,0939	-0,979	-0,117	-1,336	-0,098	-	-
ST_m	0,119	0,1264	0,163	0,157	-	-	-	-
PGDP	0,0001	0,1163	-	-	-	-	0,0013	0,195
ST_mGranice	-	-	-	-	-	-	-0,0008	-0,115
TOPEX	-	-	-	-	-	-	-17,5520	-0,255
R^2	0,071		0,110		0,119		0,121	
F	10,072		10,304		8,031		2,516	
p	0,0001		0,0001		0,0001		0,056	

Generalno, broj naleta na srnu raste s porastom:

- gustoće populacije srne obične za polumjere 500 i 1 000 m, srne obične i divlje svinje za polumjer od 250 m i divlje svinje za polumjere od 6 000 m
- udjela zapuštenog poljoprivrednog zemljišta za dionice od 500, 1 000 i 2 000 m;
- udjela vriština i bujadnica na dionicama cesta od 500 i 1 000 m
- udaljenosti do mogućeg pojilišta (slatka voda) na dionicama cesta od 500 i 1 000 m
- godišnje gustoće prometa na dionicama od 500 i 12 000 m
- s nižom TPI (TOPEX) vrijednošću, odnosno u udolinama i manje strmim terenima, ali ovo vrijedi samo na dulje dionice cesta (12 000 m).

Broj naleta na srnu se smanjuje s porastom:

- zavoja na dionici (dionice od 1 000 m) ili udjela cesta (dionice 2 000 m)
- udjela goleti (na svim dionicama, osim dionica od 12 000 m)
- udjela mora (na svim dionicama, osim dionica od 12 000 m)
- izgrađenog zemljišta na dionicama od 500 m.

Veličina pouzdanosti modela procjene broja naleta na srnu običnu raste s rastom polumjera ćelije *(tablica 16.)*. Ona je najniža, ali signifikantna za dionice od 500 m i iznosi 7,1 % ($R^2 = 0,071$; $p < 0,0001$), a najviša (ali nesignifikantna) za dionice od 12 000 m i iznosi 12,1 % ($R^2 = 0,121$; $p = 0,056$). Budući da se ova potonja procjena nalazi na rubu statističke značajnosti, a broj naleta vozila na srnu je na dionicama duljine 2 000 m moguće procijeniti s točnošću od 11,9 % ($R^2 = 0,119$; $p < 0,0001$), to se može zaključiti kako je to i gornja dovoljna granica za izračun vjerojatnosti procjene.

3.1.2. Prostorni obrasci naleta vozila na divlju svinju

Isto kao i kod srne, kod divlje svinje se s povećanjem polumjera ćelije povećava i udio dionica na kojima se dogodio nalet vozila na divlju svinju *(tablica 17.)*. Udio takvih opasnih dionica kreće se od 2 % kod ćelija polumjera 100 m do 40 % kod ćelija polumjera 6 000 m, što ukazuje da je vrlo malen broj dijelova ceste na kojima je vjerojatnost naleta mala, odnosno da je gotovo i nema. No, u usporedbi s podacima za srnu običnu broj naleta na divlju svinju po ćeliji je daleko manji. Pri polumjeru ćelije od 100 m na 9 lokacija su zabilježena 2 naleta, a na 51 lokaciji samo jedan. Nadalje, kod ćelija polumjera 250, 500 i 1 000 m najveći broj naleta po lokaciji je svega 3, dok je kod ćelija polumjera 6 000 m maksimalan broj naleta svega 11. Kod ovog polumjera ćelije treba istaknuti kako nisu zabilježene lokacije s brojem naleta na divlju svinju od 5 do 9 te se može zaključiti kako broj naleta na dionici od 12 000 m ide od 0 do 4, a dionice s 10 i 11 naleta su relativno rijetke. Ovo ukazuje da je općenito broj naleta na divlju svinju malen i sažet na relativno malo područje što bi trebalo u konačnici rezultirati relativno pouzdanijim modelima procjene naleta na ovu vrstu divljači.

Tablica 17. Broj dionica u kojima nije zabilježen nalet te dionica s određenim brojem naleta vozila na divlju svinju

BROJ NALETA	POLUMJER ĆELIJE (m)				
	100	**250**	**500**	**1 000**	**6 000**
0	2 552	1 030	503	228	27
1	51	32	20	24	8
2	9	4	5	7	1
3		1	1	2	5
4					2
5					0
6					0
7					0
8					0
9					0
10					1
11					1
BROJ DIONICA S NALETOM	60	37	26	33	18
UKUPNO	2 612	1 067	529	261	45
UDIO DIONICA S NALETOM (%)	2	3	5	13	40

U nastavku doktorskog rada prikazani su izbori najpouzdanijeg modela procjene vjerojatnosti naleta i izbori najpouzdanijeg modela procjene vjerojatnosti broja naleta za divlju svinju.

Tablica 18. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 250 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{DS}+ ZPZ%+Izgrađeno%+Šume%+Ceste%+More%	6	300,63	0,00	0,03
2.	ROK_{DS}+ Izgrađeno%+Šume%+Ceste%+More%	5	300,87	0,25	0,03
3.	ROK_{DS}+ Golet%+Izgrađeno%+Šume%+Ceste%+More%	6	301,69	1,07	0,02
4.	ROK_{SO}+ ROK_{DS}+ ZPZ%+Izgrađeno%+Šume%+Ceste%+More%	7	301,79	1,17	0,02
5.	ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+Šume%+Ceste%+More%	7	301,84	1,21	0,02
6.	ROK_{UK}+ ROK_{DS}+ ZPZ%+Izgrađeno%+Šume%+Ceste%+More%	7	301,88	1,26	0,02
7.	ROK_{SO}+ ROK_{DS}+ Izgrađeno%+Šume%+Ceste%+More%	6	301,91	1,28	0,02
8.	ROK_{UK}+ ROK_{DS}+ Izgrađeno%+Šume%+Ceste%+More%	6	301,93	1,31	0,02
9.	ROK_{DS}+ ZPZ%+Izgrađeno%+Šume%+More%	5	301,97	1,35	0,02
10.	ROK_{DS}+ Izgrađeno%+Šume%+More%	4	302,30	1,68	0,01
11.	ROK_{DS}+ ZPZ%+Izgrađeno%+Šume%+VB%+Ceste%+More%	7	302,32	1,69	0,01
12.	ROK_{DS}+ ZPZ%+Izgrađeno%+Šume%+Voćnjaci%+Ceste%+More%	7	302,46	1,83	0,01
13.	ROK_{DS}+ Izgrađeno%+Šume%+VB%+Ceste%+More%	6	302,62	1,99	0,01

Tablica 19. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 500 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ PGDP+PLDP	5	179,95	0,00	0,02
2.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ ST_m+PLDP	7	180,29	0,34	0,02
3.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$+ PGDP+PLDP	6	180,34	0,39	0,02
4.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ PGDP+PLDP	7	180,50	0,55	0,02
5.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ PGDP+PLDP	6	181,03	1,08	0,01
6.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ PGDP+PLDP	6	181,08	1,13	0,01
7.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ ST_m+PGDP	7	181,14	1,19	0,01
8.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ ST_m+PGDP+PLDP	6	181,18	1,23	0,01
9.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$+ PGDP+PLDP	7	181,38	1,43	0,01
10.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ ST_m+PLDP	5	181,41	1,46	0,01
11.	ROK_{SO}+ $Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ ST_m+PLDP	6	181,46	1,50	0,01
12.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$+ ST_m+PLDP	6	181,54	1,59	0,01
13.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ ST_m+PLDP	6	181,54	1,59	0,01
14.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$+ ST_m+PGDP+PLDP	7	181,58	1,62	0,01
15.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ ST_m+PGDP+PLDP	8	181,62	1,67	0,01

Broj modela	Model	K	AIC	ΔAIC	w_i
16.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ PGDP+PLDP	8	181,73	1,78	0,01
17.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ PLDP	6	181,75	1,80	0,01
18.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ ST_m+PLDP	8	181,79	1,84	0,01
19.	ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ ST_m+PLDP	8	181,90	1,94	0,01
20.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+ PGDP+PLDP	6	181,93	1,98	0,01
21.	$ZPZ_{\%}$+$Golet_{\%}$+ PGDP+PLDP	4	181,93	1,98	0,01

Tablica 20. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 1 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{DS}+ ZPZ%+Ceste%+More%+ PLDP	5	176,98	0,00	0,03
2.	ROK_{DS}+ ZPZ%+ Travnjak %+Ceste%+More%+ PLDP	6	177,45	0,47	0,03
3.	ROK_{DS}+ ZPZ%+Ceste%+More%+ PGDP+PLDP	6	178,26	1,29	0,02
4.	ROK_{DS}+ ZPZ%+Golet%+Ceste%+More%+ PLDP	6	178,41	1,44	0,02
5.	ROK_{DS}+ Ceste%+More%+ PLDP	4	178,45	1,47	0,02
6.	ROK_{DS}+ ZPZ%+Voćnjaci%+Ceste%+More%+ PLDP	6	178,49	1,51	0,02
7.	ROK_{DS}+ ZPZ%+Ceste%+More%+ PGDP	5	178,52	1,54	0,02
8.	ROK_{SO}+ ROK_{DS}+ ZPZ%+Ceste%+More%+ PLDP	6	178,59	1,61	0,01
9.	ROK_{DS}+ ZPZ%+ Travnjak %+Ceste%+More%+ PGDP+PLDP	7	178,68	1,70	0,01
10.	ROK_{UK}+ ROK_{DS}+ ZPZ%+Ceste%+More%+ PLDP	6	178,84	1,87	0,01
11.	ROK_{DS}+ ZPZ%+Golet%+Ceste%+More%+ PGDP+PLDP	7	178,89	1,91	0,01

Tablica 21. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 6 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	TOPEX	1	64,61	0,00	0,17
2.	PGDP+TOPEX	2	64,85	0,24	0,15
3.	More$_{\%}$+TOPEX	2	65,87	1,26	0,09
4.	Granice+TOPEX	2	66,59	1,98	0,06
5.	More$_{\%}$+PGDP+TOPEX	3	66,60	1,99	0,06

Gustoća populacije divljači jedan je od odlučujućih čimbenika pojave naleta na divlju svinju. Na dionicama od 500 m (polumjer 250 m) to je gustoća populacije divlje svinje, dok je na dionicama od 1 000 m to gustoća populacije srne obične, odnosno u modelu 19. u *tablici 19.* je, uz gustoću populacije srne obične, jedna od značajnih nezavisnih varijabli (pretkazivača) gustoća populacije krupne divljači, a u modelu 20. je to i gustoća populacije divlje svinje. Vjerojatno je uzrok tome što ćelije s naletom obuhvaćaju lovišta s visokom gustoćom populacije krupne divljači pa je relativno teško točno razlučiti koja vrsta krupne divljači ima odlučujuću ulogu u naletu vozila na divlju svinju. Nazočnost ili blizina pojilišta kao pouzdana nezavisna varijabla (pretkazivač) je jedino prepoznata za ćelije polumjera 500 m, a uvrštena je u 7 od 21 modela *(tablica 19.)*.

Kao i u primjeru srne obične kod ćelija polumjera 6 000 m rapidno se smanjio broj nezavisnih varijabli u modelu, AIC vrijednost (povećala se točnost predviđanja), a gustoća populacije divljači nema važnost u procjeni vjerojatnosti naleta (*tablici 21.*). Glavna nezavisna varijabla (pretkazivač) vjerojatnosti naleta na divlju svinju je topografija terena i ovaj se pretkazivač provlači kroz svih 5 predloženih modela pri čemu u prvome modelu dolazi u potpunosti sam.

Usprkos tome što je AIC analiza dala dosta modela procjene naleta za svaki polumjer ćelije posebno, logistička regresija je dala pouzdane rezultate jedino za dionice ceste od 12 000 m. Vjerojatnost naleta na dionici je moguće procijeniti u 73,33 % slučajeva, a sukladno modelu logističke regresije vjerojatnost naleta se može procijeniti prema izrazu (2):

$$P_{DS} = -47{,}254 + 13{,}057\, TOPEX \ (p < 0{,}0001) \qquad (2)$$

Tablica 22. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 250 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	7	340,70	0,00	0,03
2.	ROK_{SO}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	6	341,51	0,82	0,02
3.	ROK_{DS}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	6	341,54	0,85	0,02
4.	ROK_{SO}+ ROK_{DS}+ $Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	6	341,89	1,20	0,02
5.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Voćnjaci_{\%}$+$Ceste_{\%}$+$More_{\%}$	8	342,01	1,32	0,02
6.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$G_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	8	342,10	1,40	0,02
7.	ROK_{UK}+ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	8	342,19	1,50	0,02
8.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$More_{\%}$	6	342,25	1,55	0,02
9.	ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	7	342,30	1,60	0,02
10.	ROK_{DS}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$Voćnjaci_{\%}$+$Ceste_{\%}$+$More_{\%}$	7	342,42	1,73	0,01
11.	ROK_{SO}+ $Izgrađeno_{\%}$+$Šume_{\%}$+$Ceste_{\%}$+$More_{\%}$	5	342,55	1,86	0,01
12.	ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+$VB_{\%}$+$Ceste_{\%}$+$More_{\%}$	8	342,59	1,89	0,01

Tablica 23. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 500 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ PGDP+PLDP	5	202,30	0,00	0,03
2.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$+ PGDP+PLDP	6	202,69	0,40	0,02
3.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ PGDP+PLDP	6	203,08	0,78	0,02
4.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ PGDP+PLDP	7	203,33	1,03	0,02
5.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Šume_{\%}$+ ST_m+PLDP	7	203,37	1,07	0,02
6.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ ST_m+PGDP+PLDP	6	203,43	1,13	0,02
7.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$ +PGDP+PLDP	7	203,47	1,17	0,02
8.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Voćnjaci_{\%}$+ PGDP+PLDP	6	203,59	1,29	0,02
9.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ PGDP+PLDP	6	203,73	1,43	0,01
10.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$+ ST_m+PGDP+PLDP	7	203,83	1,53	0,01
11.	ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ST_m+PLDP	5	204,11	1,81	0,01
12.	ROK_{SO}+$ZPZ_{\%}$+$Golet_{\%}$+$Šume_{\%}$+ ST_m+PLDP	6	204,13	1,84	0,01
13.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ ST_m+PGDP+PLDP	7	204,19	1,89	0,01
14.	CZ+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Voćnjaci_{\%}$+ PGDP+PLDP	7	204,28	1,98	0,01
15.	ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+ PGDP+PLDP	6	204,29	1,99	0,01

Tablica 24. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 1 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{UK}+ ZPZ%+Golet%+Ceste%+More%+ PGDP+PLDP	7	200,11	0,00	0,03
2.	ROK_{SO}+ ROK_{DS}+ ZPZ%+Ceste%+More%+ PGDP+PLDP	7	201,00	0,89	0,02
3.	ROK_{UK}+ ZPZ%+Golet%+ Travnjak %+Ceste%+More%+ PGDP+PLDP	8	201,04	0,93	0,02
4.	ROK_{SO}+ ROK_{DS}+ ZPZ%+ Travnjak %+Ceste%+More%+ PGDP+PLDP	8	201,15	1,04	0,02
5.	ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+Ceste%+More%+ PGDP+PLDP	8	201,16	1,05	0,02
6.	ROK_{SO}+ ZPZ%+Ceste%+More%+ PGDP+PLDP	6	201,22	1,11	0,02
7.	ROK_{SO}+ ZPZ%+Golet%+Ceste%+More%+ PGDP+PLDP	7	201,22	1,11	0,02
8.	ROK_{UK}+ROK_{SO}+ ROK_{DS}+ ZPZ%+Ceste%+More%+ PGDP+PLDP	8	201,46	1,34	0,02
9.	ROK_{UK}+ROK_{SO}+ ZPZ%+Golet%+Ceste%+More%+ PGDP+PLDP	8	201,53	1,41	0,02
10.	ROK_{SO}+ ZPZ%+ Travnjak %+Ceste%+More%+ PGDP+PLDP	7	201,53	1,42	0,02
11.	ROK_{UK}+ ZPZ%+Golet%+Ceste%+More%+ PGDP+PLDP+TOPEX	8	201,74	1,62	0,02
12.	ROK_{UK}+ ZPZ%+Golet%+Voćnjaci%+Ceste%+More%+ PGDP+PLDP	8	201,83	1,72	0,01
13.	ROK_{uk}+ ROK_{DS}+ ZPZ%+Golet%+Ceste%+More%+ PGDP+PLDP	8	202,10	1,99	0,01

Tablica 25. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 6 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	$More_{\%}$+ PGDP+PLDP+TOPEX	4	113,77	0,00	0,08
2.	ROK_{DS}+ $More_{\%}$+ $IZVOR_m$+PGDP+PLDP+TOPEX	6	114,05	0,28	0,07
3.	ROK_{DS}+ $More_{\%}$+ PLDP+Granice+TOPEX	5	114,19	0,42	0,07
4.	$More_{\%}$+$IZVOR_m$+PGDP+PLDP+TOPEX	5	114,21	0,44	0,07
5.	ROK_{DS}+ $More_{\%}$+ $IZVOR_M$+PGDP+PLDP+Granice+TOPEX	7	114,49	0,72	0,06
6.	ROK_{DS}+ $More_{\%}$+ PGDP+PLDP+TOPEX	5	114,60	0,83	0,05
7.	ROK_{DS}+ $More_{\%}$+ PGDP+PLDP+Granice+TOPEX	6	114,85	1,08	0,05
8.	ROK_{DS}+ $More_{\%}$+ $IZVOR_m$+PLDP+Granice+TOPEX	6	114,87	1,10	0,05
9.	ROK_{DS}+ PLDP+TOPEX	3	114,87	1,11	0,05
10.	PLDP+TOPEX	2	115,10	1,33	0,04
11.	$More_{\%}$+ PGDP+PLDP+Granice+TOPEX	5	115,19	1,43	0,04
12.	ROK_{DS}+ $More_{\%}$+ PLDP+TOPEX	4	115,35	1,58	0,04
13.	ROK_{DS}+ PLDP+Granice+TOPEX	4	115,53	1,76	0,03

Kod procjene broja naleta vozila na divlju svinju po dionicama gustoća populacije divljači je jedna od ključnih nezavisnih varijabli, odnosno ključni pretkazivač za sve duljine dionica. Za pojedine duljine dionica, ovisno o modelu mogu se koristiti gustoće populacije čak dvije vrste krupne divljači (*tablica 22.*, *tablica 24.*). Čak i za ćelije polumjera 6 000 m gustoća populacije divlje svinje je kao nezavisna varijabla korištena u 9 od 13 modela *(tablica 25.)*, što ovu sastavnicu kod procjene broja naleta na crnu divljač čini neizostavnom. Osim gustoće populacije, ovdje se kao nezavisne varijable često javljaju i stanišni elementi pri čemu su udio zapuštenog zemljišta, izgrađenog zemljišta, cesta (uključujući zavojitost cesta) i mora

najčešće korištene nezavisne varijable. Međutim, za razliku od srne obične, TPI se za procjenu broja naleta na divlju svinju ne javlja samo za ćelije polumjera 6 000 m, nego i za dionice od 2 000 m (model 11., *tablica 24.*).

Iako se ne javljaju u modelima svih dionica, nego samo za dionice od 1 000 i 12 000 m i ne u svim modelima, pojilišta su opet prepoznata kao nezavisne varijable (pretkazivači) broj naleta na divlju svinju. No, ono što je svakako specifično, u odnosu na srneću divljač to je činjenica kako je gustoća prometa za sve dionice (osim za dionice od 500 m) ključna nezavisna varijabla (pretkazivač) broja naleta na divlju svinju. Bez obzira radi li se o godišnjoj, ljetnoj ili obje kategorije gustoće prometa zajedno, ove sastavnice čine većinu modela.

Tablica 26. Rezultati analize broja naleta vozila na divlju svinju po dionici državnih cesta s obzirom na različite polumjere ćelija primjenom višestruke regresije

NEZAVISNE VARIJABLE (PRETKAZIVAČI)	POLUMJER ĆELIJE (m)							
	250		500		1 000		6 000	
	b	β	b	β	b	β	b	β
konstanta	0,051	-	-	-0,072	0,156	-	32,407	-
ROK_{SO}	0,153	0,057	0,169	0,607	-	-	-	-
ROK_{DS}	0,085	0,061	-	-	-	-	-	-
ROK_{UK}	-	-	-	-	0,139	0,140	-	-
$ZPZ_{\%}$	0,127	0,092	0,232	0,499	1,023	0,236	-	-
$Golet_{\%}$	-	-	-0,071	-0,129	-0,771	-0,235	-	-
$Izgrađenost_{\%}$	-0,101	-0,070	-	-	-	-	-	-
$Šume_{\%}$	-0,036	-0,064	-	-	-	-	-	-
$VB_{\%}$	-	-	-	-	-	-	-	-
$Ceste_{\%}$	-1,094	-0,036	-	-	-20,751	-0,119	-	-
$More_{\%}$	-0,084	-0,039	-	-	-0,217	-0,060	2,552	0,130
PGDP	-	-	-0,388	0,0001	-0,0002	-0,443	-0,001	-0,291
PLDP	-	-	0,583	0,0001	0,0001	0,690	0,001	0,631
TOPEX	-	-	-	-	-	-	-8,789	-0,465
R^2		0,028		0,123		0,180		0,265
F		5,423		15,870		9,166		4,972
p		0,0001		0,0001		0,0001		0,002

Iako je kod dionica od 500 m pouzdanost modela procjene broja naleta vozila na divlju svinju manje pouzdana nego za srnu običnu (varijabilnost broja naleta je objašnjena samo s 3 %, *tablica 26.*), s porastom duljine dionice uvelike se povećava i pouzdanost procjene, koja za duljinu dionice od 12 000 m iznosi čak 26,5 % (R^2 = 0,265; p < 0,02) i statistički je pouzdana, u odnosu na sličan model za srnu običnu. Ako se usporede *tablica 16.* i *tablica 26.*, tada iste nezavisne varijable (pretkazivači) imaju iste predznake i za srnu i za divlju svinju. Generalno, neovisno o duljini dionice broj naleta na divlju svinju će biti veći ako je:

- veća gustoća populacije srne obične, divlje svinje ili krupne divljači ukupno
- viši udio zapuštenog poljoprivrednog zemljišta
- veći prosječni ljetni dnevni promet (PLDP).

Broj naleta će biti manji ako je:

- viši udio izgrađenog zemljišta
- viši udio šuma
- viši udio cesta
- viši udio mora (izuzetak su ćelije polumjera 6 000 m)
- veći prosječni godišnji dnevni promet (PGDP).

S obzirom na koeficijent β, koji govori koliki je utjecaj svakog čimbenika na zavisnu varijablu, ako se ostale varijable modela ne mijenjaju, iz *tablice 26.* može se vidjeti kako ovisno o polumjeru ćelije redoslijed važnosti pojedinih nezavisnih varijabli varira. Primjerice, za dionice od 500 m udio zapuštenog poljoprivrednog zemljišta ima najveći utjecaj na broj naleta (β = 0,092), za dionice od 1 000 m on je na drugome mjestu nakon gustoće populacije srne (β = 0,499), a za dionice od 2 000 m je na trećem mjestu, iza PGDP-a i PLDP-a (β = 0,236).

PLDP je najvažnija nezavisna varijabla (pretkazivač) broja naleta vozila na divlju svinju i za duljinu dionice od 12 000 m (β = 0,631), a odmah iza nje se nalazi TOPEX, ali s negativnim predznakom (β = -0,465).

Budući da razina varijabilnosti broja naleta na divlju svinju raste s porastom polumjera ćelije do 6 000 m, za razliku od srne, kod divlje svinje je za procjenu broja naleta moguće koristiti i modele polumjera 1 000 i 6 000 m.

3.1.3. Prostorni obrasci naleta vozila na krupnu divljač ukupno

Distribucija broja dionica državnih cesta na kojima se dogodio nalet na krupnu divljač pokazuje u potpunosti isti obrazac kao za srnu običnu i divlju svinju *(tablica 27.)*, odnosno čak su i postoci ćelija s naletom približno isti kao i kod srne obične. Udio opasnih dionica kreće se od 11 % kod ćelija polumjera 100 m do 73 % kod ćelija polumjera 6 000 m. Dakle, kada se objedine sve vrste krupne divljači ukupno ne dolazi do značajnijeg povećanja udjela „opasnih" dionica i on je isti kao i za srnu običnu. Ako se usporede *tablice 7.*, *17.* i *27.*, kumulativno gledano nije došlo do značajnijeg povećanja broja ćelija s naletom na divljač nego se povećao broj ćelija u kojima se dogodio nalet. To znači da su naleti grupirani unutar određenog područja, odnosno da postoje lokaliteti u kojima je generalna (neovisno o vrsti divljači) vjerojatnost naleta na divljač visoka. Tako je kod srne obične bilo najviše 38 naleta po ćeliji (polumjer 6 000 m), dok su kod svih vrsta krupne divljači u jednoj ćeliji zabilježena čak 52 naleta.

Tablica 27. Broj dionica u kojima nije zabilježen nalet te dionica s određenim brojem naleta vozila na krupne divlje životinje

BROJ NALETA	POLUMJER ĆELIJE (m)				
	100	**250**	**500**	**1 000**	**6 000**
0	2 318	857	363	140	12
1	200	138	89	48	2
2	49	41	32	19	1
3	22	14	25	22	2
4	6	4	5	10	4
5	6	6	5	4	0
6	3	2	2	6	5
7	6	3	4	4	2
8	2	1	3	3	2
9		1	1	0	1
10				1	0
11				2	1
12				1	1
13				0	1
14				1	1
17					1
18					1
19					1
21					2
24					2
29					1
34					1
52					1
BROJ ĆELIJE S NALETOM	294	210	166	121	33

UKUPNO	2 612	1 067	529	261	45
UDIO ĆELIJA S NALETOM (%)	11	20	31	46	73

Tablica 28. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 250 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m+PGDP	7	1 022,97	0,00	0,05
2.	ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PGDP	8	1 023,47	0,50	0,04
3.	CZ+ ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m +PGDP	8	1 023,84	0,87	0,03
4.	CZ+ ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PGDP	9	1 024,59	1,62	0,02
5.	ROK_{UK}+ ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m +PGDP	8	1 024,77	1,80	0,02
6.	ROK_{DS}+ ZPZ%+Golet%+VB%+Voćnjaci%+More%+ ST_m PGDP	8	1 024,85	1,88	0,02
7.	ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m +PGDP	8	1 024,95	1,97	0,02
8.	ROK_{DS}+ ZPZ%+Golet%+VB%+More%+ ST_m +PGDP+PLDP	8	1 024,95	1,98	0,02

Tablica 29. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 500 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	CZ+ ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PGDP	7	657,75	0,00	0,02
2.	CZ+ ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	9	657,97	0,21	0,01
3.	CZ+ ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	8	658,06	0,31	0,01
4.	CZ+ ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PGDP	8	658,07	0,32	0,01
5.	ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	8	658,41	0,66	0,01
6.	CZ+ ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PLDP	7	658,44	0,69	0,01
7.	CZ+ ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+Izgrađeno$_{\%}$+$More_{\%}$+ST_m+PGDP	8	658,48	0,73	0,01
8.	CZ+ ROK_{UK}+ROK_{SO}+ $Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	8	658,52	0,77	0,01
9.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PGDP	6	658,54	0,79	0,01
10.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	7	658,57	0,82	0,01
11.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+Izgrađeno$_{\%}$+$More_{\%}$+ST_m+PGDP	7	658,66	0,90	0,01
12.	CZ+ ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PLDP	8	658,77	1,02	0,01
13.	CZ+ ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PLDP	9	658,85	1,10	0,01
14.	ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PGDP	7	658,85	1,10	0,01
15.	CZ+ ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+Izgrađeno$_{\%}$+$More_{\%}$+ST_m+PGDP	9	658,89	1,14	0,01
16.	CZ+ ROK_{UK}+$ZPZ_{\%}$+ $Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PLDP	8	658,92	1,17	0,01
17.	ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+Izgrađeno$_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	9	658,93	1,18	0,01
18.	CZ+ ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PGDP	8	658,94	1,19	0,01
19.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+Izgrađeno$_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	8	658,96	1,21	0,01
20.	CZ+ ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	9	658,99	1,23	0,01
21.	CZ+ ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+Izgrađeno$_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	9	658,99	1,24	0,01
22.	CZ+ ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+Izgrađeno$_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	10	659,01	1,25	0,01
23.	ROK_{UK}+ROK_{SO}+	8	659,06	1,31	0,01

	$ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$More_{\%}$+ST_m+PGDP				
24.	CZ+ ROK_{UK}+ROK_{SO}+ $Golet_{\%}$+$More_{\%}$+ST_m+PGDP	7	659,07	1,32	0,01
25.	CZ+ ROK_{UK}+ $Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	7	659,14	1,38	0,01
26.	CZ+ ROK_{UK}+ $Golet_{\%}$+$More_{\%}$+ST_m+PGDP	6	659,18	1,42	0,01
27.	ROK_{UK}+$ZPZ_{\%}$+ $Golet_{\%}$+$More_{\%}$+ST_m+PLDP	6	659,18	1,43	0,01
28.	ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PLDP	8	659,25	1,50	0,01
29.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PLDP	7	659,38	1,63	0,01
30.	ROK_{UK}+ROK_{SO}+ $Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	7	659,39	1,64	0,01
31.	CZ+ ROK_{UK}+ROK_{SO}+ $Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PLDP	8	659,42	1,67	0,01
32.	CZ+ ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$More_{\%}$+ST_m+PGDP	9	659,47	1,71	0,01
33.	ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PLDP	7	659,50	1,74	0,01
34.	CZ+ ROK_{UK}+ROK_{SO}+ $Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	9	659,50	1,75	0,01
35.	CZ+ ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$Voćnjaci_{\%}$+$More_{\%}$+ST_m+PGDP	8	659,53	1,78	0,01
36.	CZ+ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PGDP+PLDP	8	659,57	1,82	0,01
37.	CZ+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PGDP	7	659,58	1,83	0,01
38.	CZ+ ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$More_{\%}$+ST_m+PLDP	8	659,60	1,85	0,01
39.	ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	8	659,60	1,85	0,01
40.	CZ+ ROK_{UK}+ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP+PLDP	10	659,65	1,90	0,01
41.	CZ+ ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$More_{\%}$+ST_m+PLDP	8	659,70	1,95	0,01
42.	CZ+ ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	10	659,71	1,96	0,01
43.	ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$More_{\%}$+ST_m+PGDP	8	659,72	1,97	0,01
44.	CZ+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	8	659,73	1,97	0,01
45.	ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$VB_{\%}$+$More_{\%}$+ST_m+PGDP	9	659,74	1,99	0,01
46.	CZ+ ROK_{UK}+ROK_{SO}+ $Golet_{\%}$+$More_{\%}$+ST_m+PLDP	7	659,74	1,99	0,01

Tablica 30. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 1 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{UK}+ Golet%+More%+ ST_m	4	400,44	0,00	0,10
2.	ROK_{UK}+ ZPZ%+Golet%+More%+ ST_m	5	401,03	0,59	0,07
3.	ROK_{UK}+MAX_ROK_{SO}+ Golet%+More%+ ST_m	5	401,63	1,20	0,05
4.	ROK_{UK}+MAX_ROK_{SO}+ ZPZ%+Golet%+More%+ ST_m	6	401,79	1,35	0,05
5.	ROK_{UK}+ ROK_{DS}+ Golet%+More%+ ST_m	5	401,84	1,40	0,05
6.	ROK_{UK}+ Golet%+Voćnjaci%+More%+ ST_m	5	402,35	1,91	0,04
7.	ROK_{UK}+ Golet%+ Travnjak %+More%+ ST_m	5	402,35	1,92	0,04

Tablica 31. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 6 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	ROK_{UK}+CZ	2	88,64	0,00	0,04
2.	CZ	1	88,69	0,06	0,04
3.	CZ+TOPEX	2	89,00	0,37	0,03
4.	$VB_{\%}$	1	89,03	0,39	0,03
5.	TOPEX	1	89,06	0,42	0,03
6.	PGDP	1	89,07	0,43	0,03
7.	ROK_{UK}+$VB_{\%}$	2	89,08	0,44	0,03
8.	ROK_{UK}	1	89,15	0,52	0,03
9.	Granice	1	89,17	0,53	0,03
10.	ROK_{UK}+CZ+$VB_{\%}$	3	89,31	0,68	0,03
11.	ROK_{UK}+CZ+TOPEX	3	89,53	0,90	0,03
12.	$VB_{\%}$+TOPEX	2	89,80	1,16	0,02
13.	CZ+PGDP	2	89,80	1,16	0,02
14.	CZ+$VB_{\%}$	2	89,80	1,17	0,02
15.	$VB_{\%}$+PGDP	2	89,86	1,22	0,02
16.	$VB_{\%}$+Granice	2	89,96	1,32	0,02
17.	PGDP+Granice	2	90,03	1,39	0,02
18.	PGDP+TOPEX	2	90,05	1,41	0,02
19.	ROK_{UK}+PGDP	2	90,10	1,46	0,02
20.	CZ+Granice	2	90,11	1,48	0,02
21.	ROK_{UK}+CZ+PGDP	3	90,16	1,53	0,02
22.	ROK_{UK}+TOPEX	2	90,22	1,58	0,02
23.	CZ+$VB_{\%}$+TOPEX	3	90,31	1,67	0,02
24.	ROK_{UK}+$VB_{\%}$+PGDP	3	90,31	1,67	0,02
25.	ROK_{UK}+$VB_{\%}$+TOPEX	3	90,37	1,73	0,02
26.	ROK_{UK}+Granice	2	90,37	1,73	0,02
27.	ROK_{UK}+CZ+$VB_{\%}$+TOPEX	4	90,40	1,76	0,02
28.	CZ+PGDP+TOPEX	3	90,49	1,85	0,02
29.	ROK_{UK}+CZ+Granice	3	90,52	1,88	0,02
30.	ROK_{UK}+$VB_{\%}$+Granice	3	90,55	1,92	0,02

Iako AIC vrijednosti s porastom polumjera ćelije padaju, za razliku od modela procjene vjerojatnosti naleta na srnu i divlju svinju, broj modela za krupnu divljač ne pokazuje pad nego je promjenjiv (*tablice 28*., *29.*, *30.* i *31.*). Broj modela je najmanji kod ćelija polumjera 1 000 m (7 modela; *tablica 30.*) te kod ćelija polumjera 250 m (8 modela, *tablica 28.*). Za dionice duljine 12 000 m pronađeno je 30 modela procjene naleta vozila na krupnu divljač *(tablica 31.)*, a za dionice duljine 1 000 m čak 46 modela *(tablica 29.)*. Usprkos tome, logističkom regresijom je jedino bilo moguće predvidjeti nalete za dionice ceste od 2 000 i 12 000 m *(tablica 32.)*. Kao i kod srneće divljači predznaci koeficijenata pojedinih nezavisnih varijabli (pretkazivača) su kontradiktorni. Tako je za dionice duljine 2 000 m vjerojatnost naleta u pozitivnom odnosu s gustoćom populacije, dok je za dionice od 12 000 m odnos suprotan. Bez obzira na ovakav ishod svakako je nužno primijetiti kako se gustoća populacije divljači (najčešće se radi o krupnoj divljači) proteže kroz sve polumjere ćelija. Dok se za dionice ceste od 2 000 m uz gustoću populacije krupne divljači, kao nezavisne varijable (pretkazivači) javljaju i stanišni elementi (udio goleti i mora te udaljenost do najbližeg pojilišta), kod dionica od 12 000 m se kao druga nezavisna varijabla (pretkazivač) javlja zavojitost ceste. Ona je u negativnom odnosu s vjerojatnošću naleta i predstavlja loginu interpretaciju koja će reći – što je više zavoja ili križanja na nekoj dionici cesta to će vjerojatnost naleta vozila na krupnu divljač biti manja.

Operativno gledano, potrebno je pronaći odgovor na pitanje koja je najkraća dionica ceste na kojoj se pouzdano može utvrditi vjerojatnost naleta na krupnu divljač ukupno? Respektirajući rezultate logističke regresije, sažete u *tablici 32.* može se reći kako je to dionica od 2 000 m. Naime, na toj je dionici sa sigurnošću od 70,11 %, a na temelju relativne odstrelne kvote krupne divljači, udjela goleti, udjela mora i blizine do najbližeg pojilišta moguće predvidjeti nastanak naleta. Pri tome treba naglasiti kako je u obračun uključen i sivi vuk. Iako nema egzaktnijih podataka o njegovoj brojnosti (osobito o odstrelu jer ne spada u kategoriju divljači i nije ga se odstreljivalo posljednjih 5 godina) zbog niske gustoće populacije i broja naleta (svega 3 u 5 godina istraživanja) on ne bi smio utjecati na točnost procjene.

Tablica 32. Vrijednost parametara za procjenu vjerojatnosti naleta vozila na krupnu divljač dobivenih logističkom regresijom pri različitim polumjerima ćelija

NEZAVISNE VARIJABLE (PRETKAZIVAČI)	POLUMJER ĆELIJE (m)	
	1 000	**6 000**
konstanta	-8,462766	3,010702
ROK_{UK}	1,368436	-7,150335
CZ		-0,9155893
$Golet_{\%}$	-6,994296	
$More_{\%}$	-5,17252	
ST_m	0,8366543	
Točnost predviđanja (%)	**70,11**	**77,78**

Kod procjene broja naleta vozila na krupnu divljač ukupno (*tablice 33*., *34*., *35.* i *36.*) također se uočava kako nema povezanosti između broja modela procjene i polumjera ćelije. Najmanji broj modela je zabilježen kod ćelija polumjera 500 m (5 modela, *tablica 34.*), a najveći kod ćelija polumjera 1 000 m (9 modela, *tablica 35.*).

I u modelima procjene broja naleta je gustoća populacije krupne divljači ključna nezavisna varijabla (pretkazivač) naleta. Međutim, za razliku od modela procjene vjerojatnosti naleta, kod modela procjene broja naleta se zavojitost cesta javlja u modelima za dionice od 500 i 1 000 m (*tablice 33.* i *34.*) i uključena je kao nezavisna varijabla u sve predložene modele. Nadalje, osim gustoće populacije divljači, kod krupne divljači najučestalije nezavisne varijable (pretkazivači) su udjeli zapuštenog poljoprivrednog zemljišta, goleti, izgrađenog zemljišta, vriština i mora te blizina pojilišta, ali i prosječan godišnji dnevni promet (PGDP). Izuzetak čini jedino procjena u ćelijama polumjera 6 000 m. Naime, na tim dionicama je predložen samo jedan model s tri nezavisne varijable (pretkazivača) – gustoćom populacije krupne divljači, prosječnim godišnjim dnevnim prometom i indeksom topografske pozicije *(tablica 35.)*.

Tablica 33. Izbor modela varijabilnosti broja naleta svih vrsta krupne divljači za ćelije polumjera 250 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	CZ+ROK_{UK}+ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m+PGDP	10	1 572,64	0,00	0,09
2.	CZ+ ROK_{UK} +ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PGDP	11	1 572,69	0,05	0,08
3.	CZ+ ROK_{UK} +ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PLDP	10	1 574,14	1,50	0,04
4.	CZ+ ROK_{UK} +ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+Voćnjaci%+ More%+ST_m +PGDP	11	1 574,32	1,68	0,04
5.	CZ+ ROK_{UK} +ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+VB%+Voćnjaci%+ More%+ST_m +PGDP	12	1 574,32	1,69	0,04
6.	CZ+ ROK_{UK} +ROK_{SO}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PGDP+PLDP	11	1 574,41	1,77	0,04
7.	CZ+ ROK_{UK} + ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PGDP	10	1 574,49	1,86	0,03
8.	CZ+ ROK_{UK} +ROK_{SO}+ ROK_{DS}+ ZPZ%+Golet%+Izgrađeno%+VB%+More%+ ST_m +PGDP+PLDP	12	1 574,53	1,90	0,03

Tablica 34. Izbor modela varijabilnosti broja naleta svih vrsta krupne divljači za ćelije polumjera 500 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
1.	CZ+ ROK_{UK}+ROK_{SO}+ ZPZ%+Izgrađeno%+Golet%+VB%+More%+ ST_m+PGDP	10	1 099,95	0,00	0,17
2.	ROK_{UK}+ROK_{SO}+ ZPZ%+Izgrađeno%+Golet%+VB%+More%+ ST_m+PGDP	9	1 101,22	1,27	0,09
3.	CZ+ ROK_{UK}+ROK_{SO}+ ROK_{DS} +ZPZ%+Izgrađeno%+Golet%+VB%+More%+ ST_m+PGDP	11	1 101,77	1,82	0,07
4.	CZ+ ROK_{UK}+ROK_{SO}+ ZPZ%+Izgrađeno%+Golet%+VB%+Voćnjaci%+ More%+ST_m+PGDP	11	1 101,79	1,85	0,07
5.	CZ+ ROK_{UK}+ROK_{SO}+ ZPZ%+Izgrađeno%+Golet%+VB%+More%+ ST_m+PLDP	10	1 101,81	1,86	0,07

Tablica 35. Izbor modela varijabilnosti broja naleta svih vrsta krupne divljači za ćelije polumjera 1 000 i 6 000 metara

Broj modela	Model	K	AIC	ΔAIC	w_i
POLUMJER 1 000 m					
1.	ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ ST_m+PGDP	7	883,81	0,00	0,13
2.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ ST_m+PGDP	6	883,82	0,01	0,13
3.	ROK_{UK}+MAX_ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ ST_m+PGDP	8	884,55	0,74	0,09
4.	ROK_{UK}+MAX_ROK_{SO}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ ST_m+PGDP	7	884,89	1,08	0,08
5.	ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ Travnjak $_{\%}$+ ST_m+PGDP	8	885,14	1,33	0,07
6.	ROK_{UK}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+ Travnjak $_{\%}$+ST_m+PGDP	7	885,28	1,47	0,06
7.	ROK_{UK}+$ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Voćnjaci_{\%}$+ ST_m+PGDP	7	885,37	1,56	0,06
8.	ROK_{UK}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Voćnjaci_{\%}$+ ST_m+PGDP	8	885,38	1,57	0,06
9.	ROK_{UK}+MAX_ROK_{SO}+ ROK_{DS}+ $ZPZ_{\%}$+$Golet_{\%}$+$Izgrađeno_{\%}$+$Voćnjaci_{\%}$+ ST_m+PGDP	9	885,45	1,64	0,06
POLUMJER 6 000 m					
1.	ROK_{DS}+PGDP+TOPEX	3	556,09	0,00	1,00

Kvaliteta modela broja naleta vozila na krupnu divljač ukupno po dionici raste s duljinom dionice *(tablica 36.)*, no kvaliteta modela svoj maksimum dosiže pri dionicama duljine 2 000 m. Naime, dani modeli ovisno o duljini dionice varijabilnost broja naleta procjenjuju s točnošću od 7 % (duljina dionice od 500 m; $R^2 = 0,071$; $p < 0,0001$) do 19 % (duljina dionice od 2 km; $R^2 = 0,192$; $p < 0,0001$), a kod duljine dionice od 12 000 m samo 13 % varijabilnosti broja naleta je objašnjeno danim modelom ($R^2 = 0,133$; $p < 0,031$). Uzrok tome vjerojatno leži u dominantnoj brojnosti srna u uzorku. Naime, kod divlje svinje najpouzdaniji model je upravo onaj dan za dionice od 12 000 m *(tablica 26.)*, dok kod srne obične *(tablica 16.)* jedva da postoji razlika u točnosti modela za dionice od 2 000 i 12 000 m (u oba slučaja ona približno iznosi 12 %).

Bez obzira na točnost modela, odnosno duljini dionica, bitno je istaknuti kako se predznaci koeficijenata nezavisnih varijabli (pretkazivača) poklapaju. Izuzetak čini brojnost divlje svinje kod ćelija od 1 000 m, koji je negativan *(tablica 36.)*.

Tablica 36. Rezultati analize broja naleta vozila na krupnu divljač po dionici državnih cesta s obzirom na različite polumjere ćelija primjenom višestruke regresije

NEZAVISNE VARIJABLE (PRETKAZIVAČI)	POLUMJER ĆELIJE (m)							
	250		500		1 000		6 000	
	b	β	b	β	b	β	b	β
konstanta	-1,393	-	-2,400	-	-3,927	-	47,128	-
ROK_{SO}	0,093	0,046	2,766	0,170	-	-	-	-
ROK_{DS}	-	-	-	-	-0,265	-0,025	-	-
ROK_{UK}	0,790	0,073	0,266	0,090	1,057	0,227	10,568	0,257
CZ	-0,087	-0,044	-0,121	-0,055	-	-	-	-
$ZPZ_{\%}$	0,538	0,097	1,448	0,149	3,956	0,194	-	-
$Golet_{\%}$	-0,451	-0,094	-1,071	-0,129	-4,583	-0,298	-	-
$Izgrađeno_{\%}$	-0,323	-0,056	-1,412	-0,115	-5,157	-0,161	-	-
$VB_{\%}$	0,300	0,039	0,946	0,072	-	-	-	-
$More_{\%}$	-0,880	-0,102	-1,254	-0,117	-	-	-	-
ST_m	0,167	0,142	0,249	0,189	0,438	0,213	-	-
PGDP	0,000	0,111	0,000	0,260	0,000	0,264	0,003	0,311
TOPEX	-	-	-	-	-	-	-13,234	-0,151
R^2	0,071		0,176		0,192		0,133	
F	9,144		12,272		9,827		3,259	
p	0,0001		0,0001		0,0001		0,031	

Generalno, neovisno o duljini dionice broj naleta na krupnu divljač ukupno će biti veći ako je:

- veća gustoća populacije srne obične ili krupne divljači
- viši udio zapuštenog poljoprivrednog zemljišta
- viši udio vriština i bujadnica
- veća udaljenost do pojilišta
- viši godišnji promet.

Broj naleta na krupnu divljač ukupno biti će manji ako je:

- cesta zavojitija ili ima više raskrižja
- viši udio goleti
- viši udio izgrađenog zemljišta
- viši udio mora
- razvedeniji reljef (viša TPI vrijednost).

Različite duljine dionica imaju i različito izražene koeficijente utjecaja na zavisnu varijablu *(β)*. Najjači pozitivan utjecaj na broj naleta na krupnu divljač na dionicama cesta od 500 m ima blizina do pojilišta (β = 0,142), a negativan udio mora u ćeliji (β = -0,092). Čini se da je blizina pojilišta dosta važan čimbenik broja naleta jer je i kod dionica od 1 000 (β = 0,189) i 2 000 m (β = 0,264) njen utjecaj dosta jak i nalazi se na drugom mjestu odmah iza prosječnog godišnjeg dnevnog prometa (β = 0,260 za dionice od 1.000 m i β = 0,264 za dionice od 2 000 m), odnosno gustoće populacije krupne divljači (β = 0,227). Ta pozitivna povezanost količine prometa i broja naleta nastavlja se i na dionicama od 12 000 m gdje je ona još i viša (β = 0,311).

Generalno se može reći kako bi za procjenu broja naleta vozila na krupnu divljač ukupno bilo moguće koristiti modele za dionice od 2 000 m. U tim modelima najveći utjecaj na nalete ima već spomenuti prosječni godišnji dnevni promet, gustoća populacije krupne divljači i blizina pojilišta, ali i udio zapuštenog poljoprivrednog zemljišta (β = 0,194). Najjači negativan utjecaj imaju udio goleti (β = -0,298) i izgrađenog zemljišta (β = -0,161), a vrlo malen negativan utjecaj brojnost divlje svinje (β = -0,025).

Indeks topografske pozicije je i ovdje prepoznat kao čimbenik koji pojačava vjerojatnost naleta, odnosno broja naleta na krupnu divljači na ravnim dionicama cesta. Budući da je on dosta zanimljiva nezavisna varijabla (pretkazivač) u poglavlju diskusija dobivenih rezultata daje se detaljnija analiza TOPEX-a.

3.1.4. Testiranje modela procjene naleta vozila na krupnu divljač

Parametri dobiveni statističkom analizom mogu se koristiti za procjenu vjerojatnosti nastanka naleta te broja naleta vozila na krupnu divljač. Iz prethodnih poglavlja prostornih obrazaca naleta vozila na divljač već je navedeno da je za procjenu opasnosti od naleta kao i za broj naleta operativno gledano najbolje koristiti vrijednosti i modele dane za duljinu

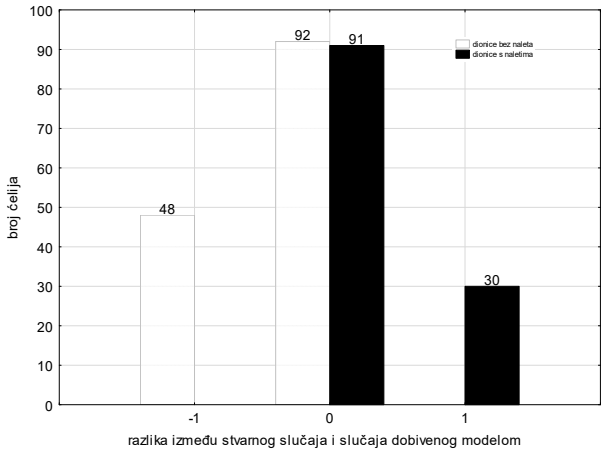
dionice od 2 000 m, odnosno za ćelije polumjera 1 000 m. Pri tome treba istaknuti kako je duljina ceste unutar ćelije polumjera 1 000 m minimalno 2 000 m, a najčešće je puno dulja zbog razvedene konfiguracije terena i zavojitosti ceste. Stoga je uputnije koristiti podatke za polumjer ćelije, odnosno dionicu državne ceste u toj ćeliji.

Sukladno rezultatima logističke regresije vjerojatnost događanja naleta moguće je procijeniti prema slijedećem izrazu (3):

$$N_{UK} = -8{,}463 + 1{,}369 \times ROK_{UK} - 6{,}994 \times CZ - 5{,}17 \times More + 0{,}837 \times St_m \quad (3)$$

Ukoliko se vrijednost kreće od 0 do 0,4 tada se pretpostavlja kako na dionici neće biti naleta, a ukoliko je vrijednost 0,5 i više tada se na dionici tijekom 5 godina može očekivati nalet vozila na krupnu divljač. Iako je modelom mjesta naleta ili nenaleta moguće procijeniti s točnošću od 70,11 % zanimljivo je vidjeti koje su učestalije greške modela. Naime, mogu se očekivati tri ishoda:

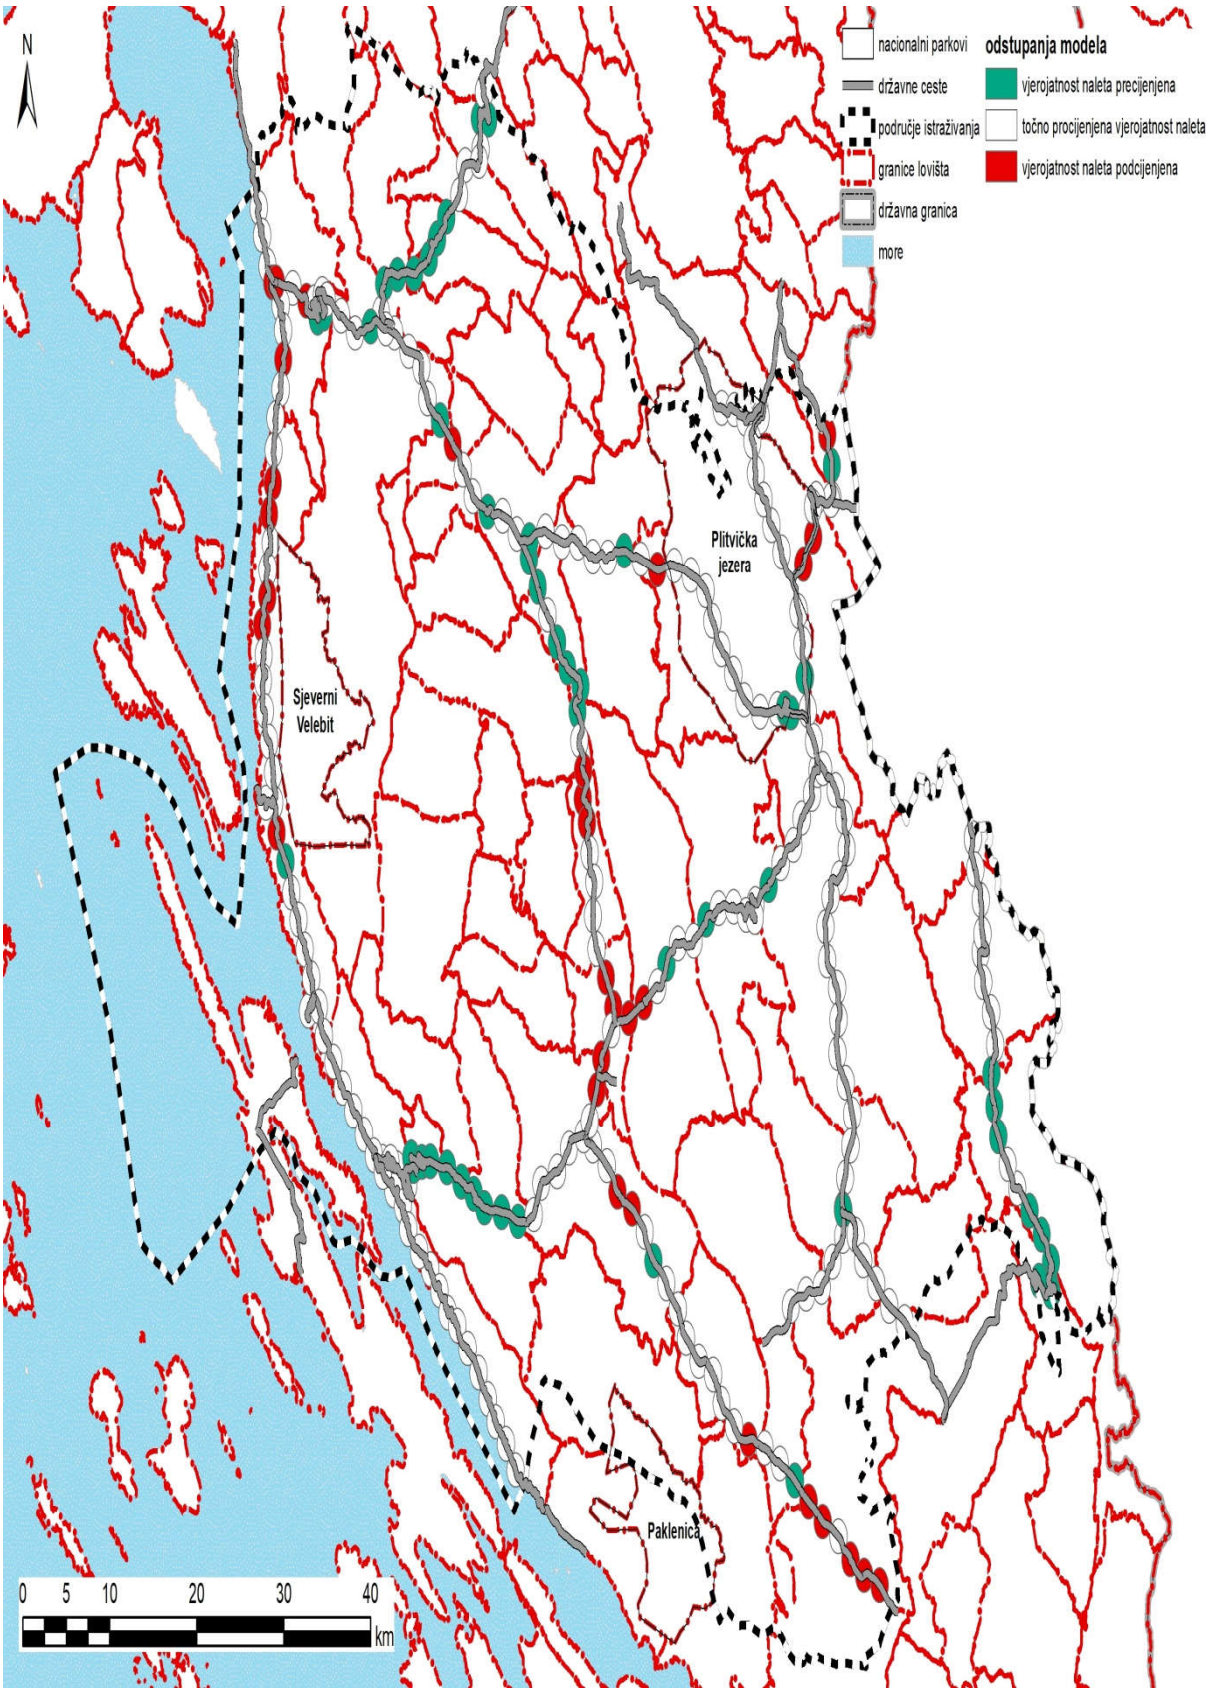
- model je točno procijenio da se na određenoj dionici neće dogoditi ili da će se dogoditi nalet
- na dionici tijekom istraživanog razdoblja nije bilo naleta, no model predviđa da bi se tu mogao dogoditi nalet (greška precjenjivanja naleta)
- na dionici su tijekom istraživanog razdoblja zabilježeni naleti, no model predviđa da se na njoj ne može dogoditi nalet (greška podcjenjivanja naleta).



Grafikon 22. Distribucija slučajeva modelom točno predviđenih naleta, podcijenjenih i precijenjenih naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije

Na *grafikonu 22.* se može vidjeti kako je na dionicama bez naleta (bilo je 140 takvih dionica) model predvidio da se u 92 slučaja neće dogoditi nalet (točno predviđanje), ali i da bi se na 48 dionica mogao dogoditi nalet (precjenjivanje modela, oznaka „-1“). Na dionicama na kojima se dogodio nalet (takvih dionica je bilo 121) model je predvidio da se na njih 91 može dogoditi nalet, ali i da se na njih 30 neće dogoditi nalet (podcjenjivanje naleta, oznaka „1“). Ova potonja greška je daleko opasnija od prethodne jer vozač ne očekuje nalet na dionicama na kojima su se dogodili. U konačnici od 70,11 % točno predviđenih naleta modelom; 65,7 % ih je točno procijenjeno za dionice bez naleta, a 75,2 % za dionice na kojima se dogodio nalet. Pri tome je na 18,4 % duljine državnih cesta vjerojatnost naleta precijenjena, a na 11,5 % podcijenjena.

Najviše točno procijenjenih vjerojatnosti naleta nalazi se na državnoj cesti DC-8 (Jadranska magistrala, *slika 12.*). Nekoliko krivo procijenjenih dionica dolazi u sjevernom dijelu trase ceste, uglavnom uz granicu s Nacionalnim parkom „Sjeverni Velebit“, a najčešća greška je podcjenjivanje naleta. Dobru kvalitetu je predloženi model pokazao i na državnoj cesti DC-1. I ovdje se radi o grupiranju pogrešno procijenjenih dionica uz granicu s NP „Plitvička jezera“. Najmanje točno procijenjenih dionica nalazi se na cestama koje prolaze kroz središte istraživanog prostora (državna cesta DC-50 i DC-23) te cesta koje se s spuštaju s gorskih masiva Velebita (državna cesta DC-23) i Ličke Plješivice (državna cesta DC-218). Kod ovih kategorija cesta uglavnom dolazi do precjenjivanja vjerojatnosti nastanka naleta. Kao posebno opasne dionice treba istaknuti raskrižje državnih cesta DC-50 i DC-25 te dionice državne ceste DC-25, neposredno nakon raskrižja gdje je podcijenjena opasnost naleta na ukupno 6 dionica (cca. 12 000 m ceste).

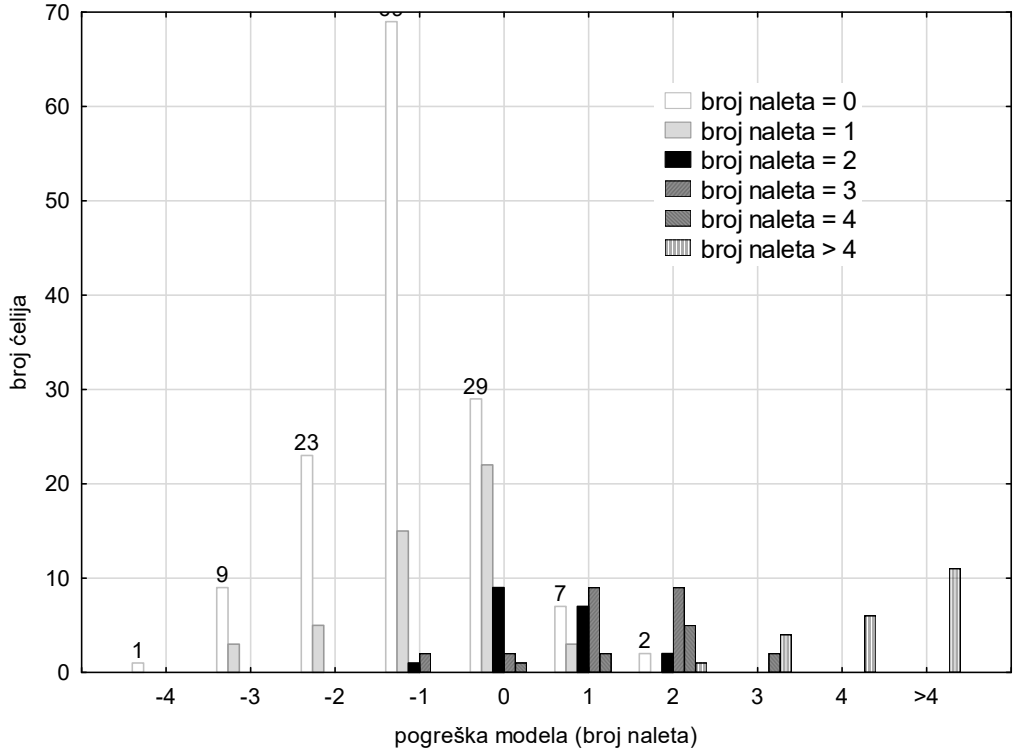


Slika 12. Kvaliteta modela procjene vjerojatnosti naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije

Broj naleta po ćeliji polumjera 1 000 m, s točnošću od 19 % moguće je procijeniti prema slijedećem izrazu (4):

$$N_{UK} = -3{,}927 + 1{,}057 \times ROK_{UK} - 0{,}027 \times ROK_{DS} + 3{,}956 \times ZPZ_{\%} - 4{,}583 \times Golet - 5{,}157 \times Izgrađeno_{\%} + 0{,}438 \times ST_m + 0{,}0004 \times \text{PGDP} \quad (4)$$

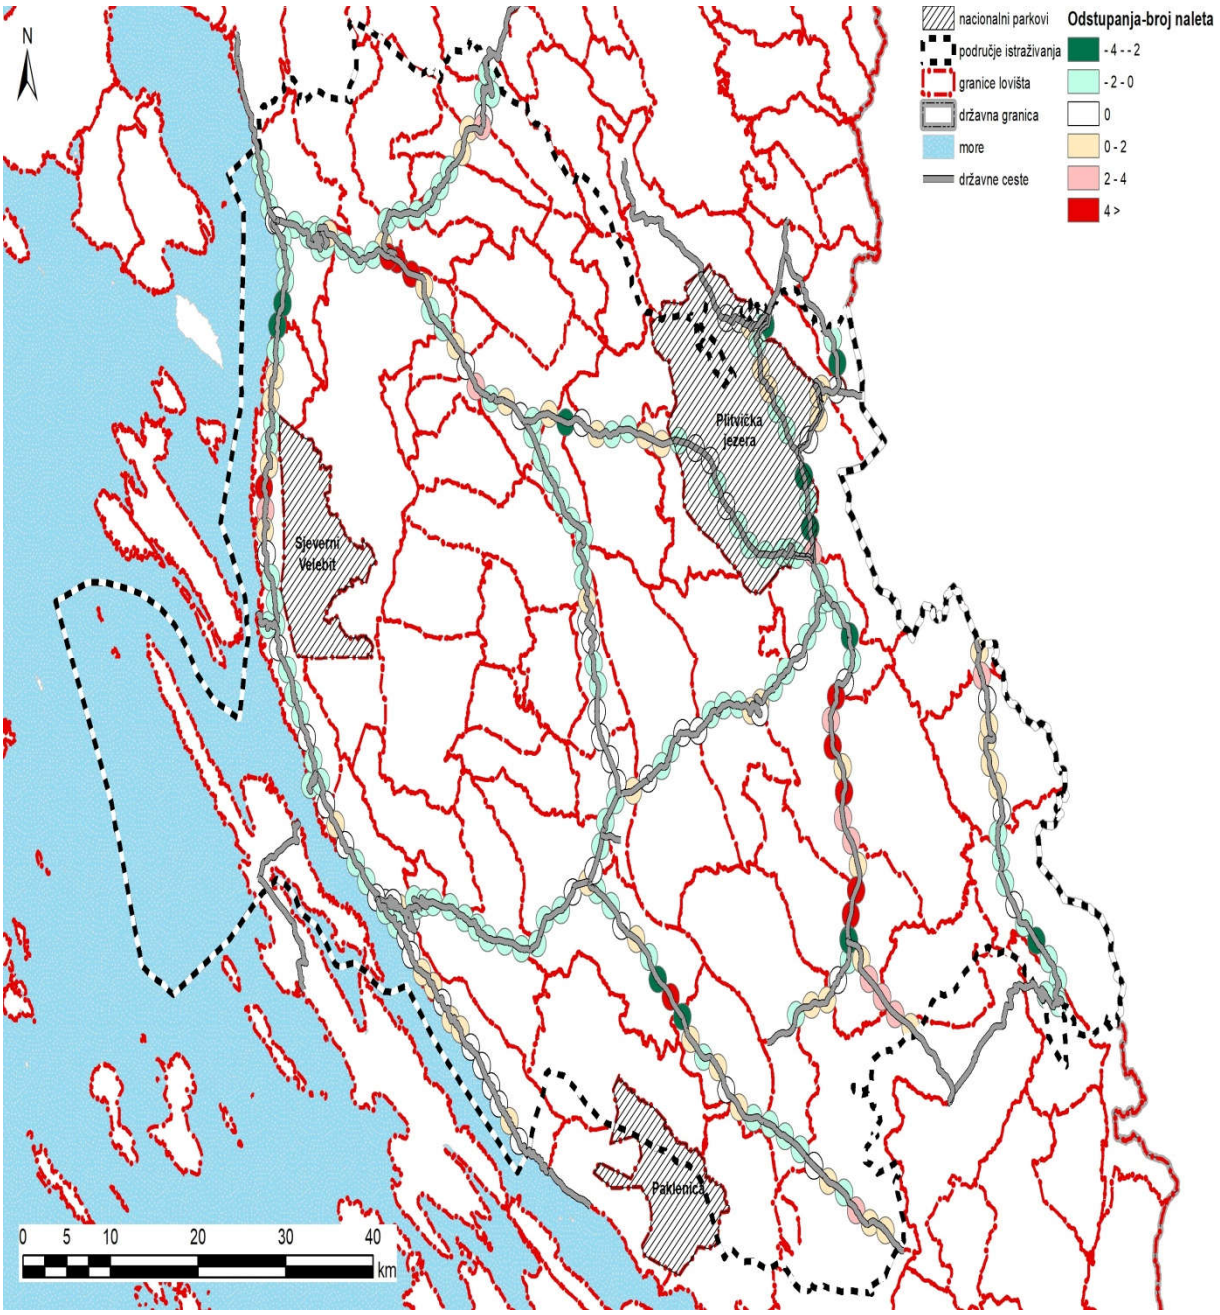
Budući da se broj naleta po ćeliji polumjera 1 000 m kreće od 0 do 14, razmjerno tome mijenja se i razina greške procjene *(grafikon 23.)*. Što je manji broj naleta po ćeliji to je viša vjerojatnost precjenjivanja broja naleta. Tako je predloženim modelom za ćelije bez naleta (0) broj naleta moguće precijeniti za 4, pri čemu je za najveći broj ćelija bez naleta model pretkazao događanje jednog naleta (69 ćelija), dok je u 9 ćelija podcijenio nastanak naleta (u 7 ćelija za 1 nalet, a u 2 ćelije za 2 naleta). Precjenjivanje broja naleta nastaje samo ako je stvaran broj naleta po ćeliji bio od 0 do 3. U daljnjim slučajevima uglavnom dolazi do podcjenjivanja broja naleta. Ako su u ćeliji zabilježena 4 naleta tada je samo u jednom slučaju model predvidio točan broj naleta, a ostale brojeve naleta podcjenjuje. Ako je u ćeliji bilo 5 i više naleta tada model broj naleta isključivo podcjenjuje te broj podcijenjenih naleta može biti čak do 10.



Grafikon 23. Distribucija slučajeva modelom točno predviđenog broja naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije

Na razini cijelog modela i bez obzira na stvaran broj naleta po ćeliji on je točno procijenjen u 24,1 % slučajeva. U 49,0 % slučajeva broj naleta je precijenjen, a u 26,8 % slučajeva je podcijenjen.

Ćelije s precijenjenim brojem naleta uglavnom se nalaze na državnim cestama DC-8 i DC-25, dok se najviše ćelija s podcijenjenim velikim brojem naleta nalazi na državnoj cesti DC-1 *(slika 13.)*. Bez obzira na precjenjivanje i podcjenjivanje broja naleta obje kategorije pokazuju tzv. klasteriranost, odnosno ćelije se javljaju se u skupinama od po dvije ili tri.



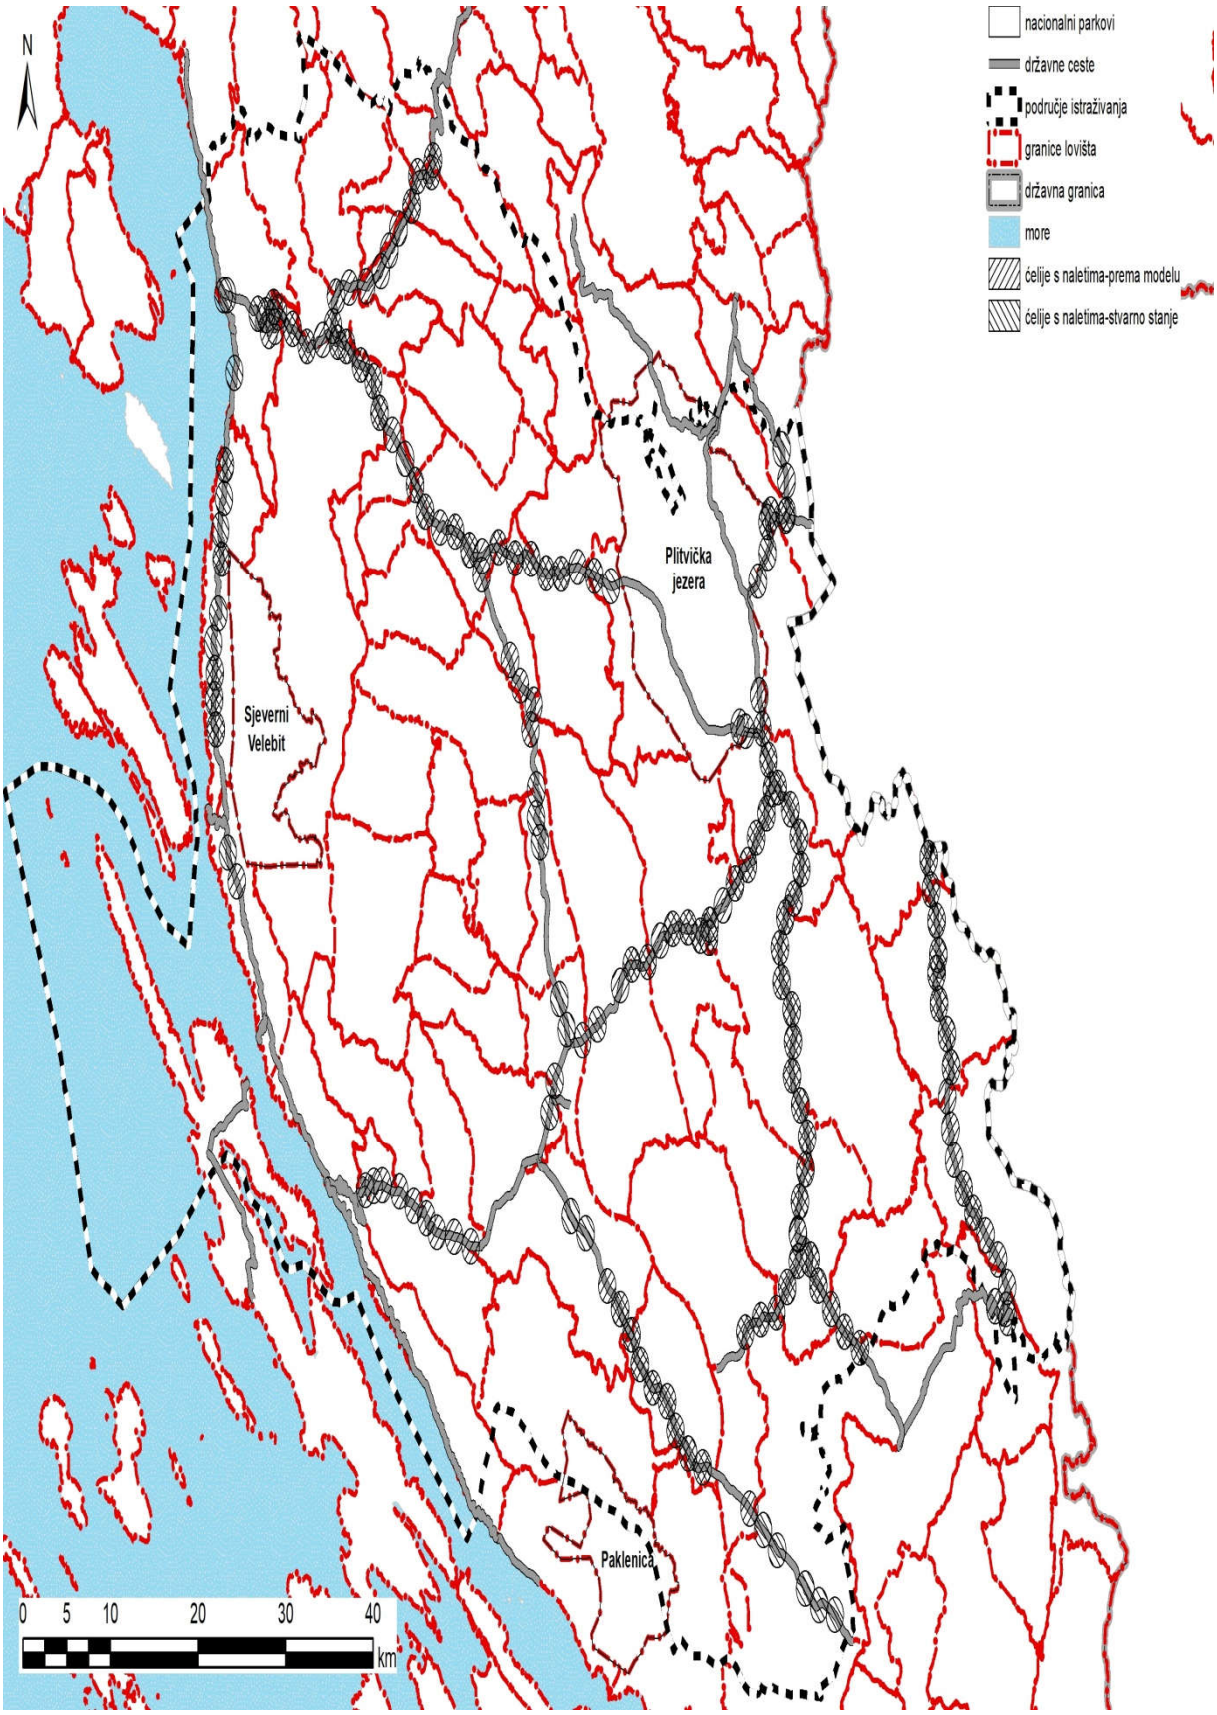
Slika 13. Kvaliteta modela procjene broja naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije

Velike greške u podcjenjivanju broja naleta sporadično se javljaju i na ostalim državnim cestama. Na državnoj cesti DC-50 postoje dvije međusobno jako udaljene dionice (preko 100 000 m), dok se na državnim cestama DC-8, DC-23 i DC-218 nalazi samo jedna takva ćelija.

Analiza prihvatljivosti spomenutih modela pokazala je da je svaki model za sebe relativno manjkav. Prvi tip modela (procjena vjerojatnosti naleta) dosta precizno procjenjuje vjerojatnost nastanka naleta s time da je udio podcijenjenih dionica relativnom malen (11,5 %) u odnosu na precijenjene. Međutim, ako bi se za procjenu vjerojatnosti naleta koristio i drugi model (procjena broja naleta) tada kombinacija daje dosta visoku točnost u procjeni opasnosti. Stoga su i načinjene *slike 14. i 15.* koje prikazuju prostorni raspored stvarnih i procijenjenih ćelija bez naleta i prostorni raspored stvarnih i procijenjenih ćelija s naletima vozila na krupnu divljač na državnim cestama Ličko-senjske županije. Naime, tamo gdje su se do sada događali naleti vjerojatno će se (uz neizmijenjene nezavisne varijable) događati i ubuduće, a takvih ćelija je ukupno bilo 121. Međutim, tim se ćelijama treba pridodati još 48 ćelija na kojima o sada nije bilo naleta, ali bi ih moglo biti ubuduće. To u konačnici ukupno čini 169 opasnih (područja naleta) i 92 sigurne ćelije. Ove potonje ćelije predstavljaju područja gdje se u stvarnosti i pomoću predviđanja ne mogu dogoditi naleti. Te sigurne ćelije su najviše zastupljene u priobalnom području (državne ceste DC-8, DC-106, DC-405 i DC-406), ali se klasterirano javljaju i na državnim cestama DC-23, DC-25, DC-50, DC-52 i DC-429 i sveukupno čine 35,2 % svih ćelija.



Slika 14. Prostorni raspored stvarnih i procijenjenih ćelija bez naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije



Slika 15. Prostorni raspored stvarnih i procijenjenih ćelija s naletima vozila na krupnu divljač na državnim cestama Ličko-senjske županije

3.2. Diskusija dobivenih rezultata

Bez obzira na veličinu područja, odnosno duljinu cesta na kojima vozilo može naletjeti na neku od spomenutih vrsta, srna obična čini najučestaliju "žrtvu". Ovo je u skladu s istraživanjima diljem Europe, a ovisno o regiji u ukupnim naletima udio naleta na ovu vrstu se kreće u rasponu od 64.7 % (sjeverni dio Italije, [23]), 60 do 73 % (Njemačka, [21]), 75 % (Hrvatska, [14]), 88 % (Danska, [154]) do čak 96 % (Slovenija, [12]). Međutim, čak i unutar jedne države mogu biti izražene razlike u strukturi naleta vozila na vrstu životinje jer je u središnjoj Hrvatskoj učestalost naleta vozila na srnu 85 % [24], dok je prema istraživanju u ovom doktorskom radu, udio srne u naletima bio 65,0 % na svim cestama, odnosno 70,5 % na državnim, 79,2 % na lokalnim i županijskim, ali svega 8,8 % na autocesti.

Ovisno o istraživanju, učestalost naleta na divlju svinju kreće se od 9 % [14] do 29,5 % [23]. Donja granica naleta je i u skaldu s istraživanjima u ovom doktorskom radu gdje je udio naleta na divlju svinju bio 11 %. Međutim, s obzirom na veličinu područja u kome ona obitava i njezinu brojnost na razini cijele Europe ta učestalost i nije visoka. Tako prema [14] učestalost naleta na jelena običnog i jelena lopatara iznosi svega 2 %. Slično je i u Sloveniji [12] gdje se jelen lopatar po učestalosti naleta nalazi na petom mjestu (iza srne obične, jelena običnog, divlje svinje i sjeverne divokoze), no on u obje države obitava na relativno malom području. Stoga, uzevši u obzir i čimbenik veličine njegova areala, jelen lopatar je vrsta koja je dosta izložena naletima, što bi trebalo produbiti daljnjim istraživanjima, osobito ako se uzme u obzir da su se svi naleti dogodili na Jadranskoj magistrali, na području oko Senja, pri čemu je 6 od 9 naleta bilo tijekom turističke sezone (razdoblje gušćeg prometa).

Iako je stradavanje zečeva prema istraživanju ovog doktorskog rada 0,9 jedinki/100 km godišnje, u skladu s istraživanjima [38] broj stvarno stradalih zečeva je razmjerno viši. Razlog je što zbog veličine tijela (masa odraslog zeca se kreće do 5 kg, npr. u [146] ova vrsta pri naletu vozila ne može prouzročiti veću materijalnu štetu, a meso mu je ukusno pa nakon naleta vozač najčešće bez prijave naleta lešinu uzme sa sobom). Bez obzira na to ova se vrsta, gledano po veličini istraživanog areala, po broju stradalih jedinki nalazi odmah iza divlje svinje s udjelom u ukupnim naletima na svim cestama od 5,7 %.

3.2.1. Povezanost vremenskih obrazaca naleta s ponašanjem divljači

Već je napomenuto kako na pojavnost naleta vozila na divljač (WVC-a) jednu od sastavnica imaju značajke vrste. Mjesečna dinamika naleta uglavnom ima slučajnu distribuciju, no ona pokazuje određene odnose, a može biti povezana s:

- promjenom trajanja duljine dana
- promjenom ponašanja životinje (npr. tijekom parenja, iste navode navode i autori u [10], [12], [21])
- lovnom aktivnosti čovjeka [23], [115], [117].

Prostorni raspored jedinki je pod velikim utjecajem klimatskih čimbenika, koji vrsti mogu u potpunosti ograničiti područje obitavanja ili je prisiliti da pojedine dijelove njena životnog prostora koristi sezonski. S time u svezi postoji i sezonalnost prelaska preko ceste [155]. Tijekom zime se životinje nastoje manje kretati (zbog gubitka energije), a preko ljeta više. Ovo ne mora biti pravilo jer zimske migracije mogu biti inducirane dubinom snijega, odnosno prelaskom na područja bez snijega ili s plićim snijegom [143]. Tijekom vegetacije su migracije uglavnom povezane s razdobljem parenja ili podizanja mladunčadi, odnosno induciraju povišenu razinu kretanja.

Povezanost sezone parenja s povišenom učestalošću naleta spominje većina autora iako ima izuzetaka, što je povezano s kompleksnošću problema. Tako Neumann i ostali [156] navode kako sezona parenja losa (*Alces alces*) počinje mjesec dana nakon parenja jelena običnog (kraj rujna - sredina listopada). Budući da lovidba losa, u Švedskoj, traje od početka rujna do kraja prosinca (veći dio se poklapa sa sezonom parenja), s time da je vrhunac lova u prva tri tjedna u rujnu. Učestalost naleta vozila na losa tijekom sezone lova ne mora biti izravna posljedica povećane aktivnosti losa zbog uznemiravanja lovom nego sekundarne prirode. Primjerice, zbog lovne sezone povećava se i frekvencija prometa jer lovci putuju na lokacije lova [157].

Prema Šprem i ostalima [14] naleti uglavnom nastaju tijekom travnja, a tijekom godine u jutarnjim satima. Međutim, oni vremensku sastavnicu naleta nisu analizirali po vrstama životinje. Kod srneće divljači [27], [37] postoje dva kritična razdoblja naleta – proljetno (travanj - svibanj) te jesensko (rujan - studeni). Prvi je vezan za pojačano traženje hrane i širenje na nova područja (disperzija mladih jedinki), a drugi za traženje povoljnih staništa tijekom zime. Srneća divljač je danja divljač s kretanjem uglavnom popodne, te u rano večernjim i rano jutarnjim satima. Srna tijekom dana uzima hranu 8 - 11 puta. Ponašanje

srne spada u tzv. distancijalni tip, što znači da srneća divljač izbjegava život u većim skupinama, sve do kasne jeseni kada se udružuje u krda i u njima ostaje do proljeća. U proljeće pred sam okot srna prekida vezu s prošlogodišnjom lanadi, a srnjaci zauzimaju svoj teritorij. Ovisno o staništu, polumjer kretanja srna je razmjerno malen, odnosno od 1 000 do 10 000 m.

Prema Pintur i ostali [24] naleti vozila su učestaliji od travnja do svibnja, a tijekom dana od 5:00 do 8:00 sati i od 18:00 do 20:00 sati. Problem je što su autori obradili učestalost naleta za sve životinjske vrste zajedeno, iako je srna obična u uzorku bila zastupljena s 87 %.

Pokorny u [12] navodi da kulminacija naleta vozila na srneću divljač nastaje tijekom travnja i svibnja (ustanovljenje teritorija), a kod jelena običnog tijekom rujna i listopada, kao posljedica sezone parenja što se i poklapa sa rezultatima ovoga doktorskog rada. Osim divlje svinje i srne obične ova je dinamika zabilježena i kod vrsta jelena roda *Odocoileus* spp. [120], jer se većina naleta dogodi tijekom studenog (razdoblje parenja).

Rezimirajući dosadašnja iskustva godišnja (sezonska) dinamika naleta kod srne obične u većini slučajeva je slična te pokazuje jednu do dvije kulminacije [23], [115]. Iako Madsen i ostali u [21] navode kako je broj naleta vozila na srneću divljač najviši tijekom jeseni prema njima dinamika nije signifikantno povezana s gustoćom prometa [21]. Za razliku od podataka iz ovog doktorskog rada gdje je nađena statistički značajna povezanost između godišnjeg doba i učestalosti naleta, Vincent i ostali u [108] nisu našli signifikantnu povezanost iako navode dvije kulminacije naleta ljetnu (lipanj - srpanj) i jesensku (rujan - listopad). Slična kritična razdoblja naleta vozila na srneću divljač navode Morelle i ostali u [27], no oni razlučuju proljetnu (travanj - svibanj) i jesensku (rujan - studeni) kulminaciju. Ova potonja je na području Ličko-senjske županije pomaknuta na razdoblje listopad - studeni. Razlog pomicanja bi mogao biti i nešto hladnija inačica klime na istraživanom prostoru koja je inducirala fenološki pomak od mjesec dana.

Kulminacija naleta vozila na divlju svinju je u razdoblju listopad - siječanj [27] i [115]. Na temelju baze podataka MUP-a o naletim vozila na divljač autori su u [117] vjerojatnost naleta pokušali dovesti u vezu s lovnom aktivnosti čovjeka. Oni su, doduše, dobili nešto veću učestalost naleta vozila na srneću divljač i divlju svinju tijekom sezone lova (na području Galicije se ove dvije vrste love četvrtkom i nedjeljom od rujna do siječnja), no to može biti povezano i s drugim uzrocima (npr. urod teškog šumskog sjemena, struktura poljoprivrednih kultura, duljina noći). Primi i ostali [110] nisu našli povezanost između

učestalosti naleta te lovnih dana na divlju svinju te zaključuju kako je razlog noćne aktivnosti divlje svinje prijelaz od mjesta odmora do mjesta hranjenja (kolovoz - listopad), odnosno parenje (studeni - siječanj). U Hrvatskoj sezona lova na divlju svinju traje cijelu godinu, međutim, između panonskog (nizinskog) i dinarskog (gorskog) područja postoji izražena razlika u dinamici lova ([158], [159], [160]).

Naime, dok se u državnim lovištima panonskog dijela Hrvatske (lovišta s udjelom šuma od preko 50 %) ova divljač tijekom jeseni i zime uglavnom lovi skupnim lovovima, u dinarskom području se ona uglavnom lovi pojedinačnim lovovima. Kako se skupni lovovi uglavnom provode pomoću pasa goniča, a u njima sudjeluje velik broj lovaca, razumljivo je kako to neminovno dovodi i do rastjerivanja ove divljači, odnosno pridonosi disperziji [161] iako u pojedinim slučajevima to nije jako izraženo [162]. Stoga izostanak kulminacije naleta tijekom glavne lovne sezone na divlju svinju (kraj jeseni i početak zime) može biti i posljedica male frekvencije skupnih lovova. S obzirom da je diljem Europe već dulje vrijeme izražena tendencija smanjivanja brojnosti divlje svinje, ona će se i dalje uglavnom odstreljivati skupnim lovovima jer su učinkovitiji. Doduše, učinkoviti mogu biti i lovovi dočekom (pojedinačni lovovi), no često puta za odstrel jednog grla treba na čeki odsjediti i do 18 sati [163].

Generalno, ne postojanje signifikantne povezanosti između mjeseci i učestalosti naleta kod divlje svinje, odnosno statistički značajna povezanost sezone s naletima kod srneće divljači ide u prilog kako su kod srne obične obrasci definirani sezonom parenja.

Uzrok učestalijim naletima vozila na srnu tijekom razdoblja travanj - svibanj treba tražiti u odjeljivanju majki od lanjske lanadi, a prije razdoblja lanjenja. Nakon toga, godišnjaci oba spola započinju disperziju. Tijekom noći broj naleta uglavnom raste zbog smanjene vidljivosti, ali i činjenice da je aktivnost pojedinih vrsta divljači tijekom noći viša [10], [164]. Tjedna dinamika naleta može biti povezana i s povišenom frekvencijom prometa. U Španjolskoj su naleti viši tijekom vikenda po noći jer mladi vozači izlaze u provod pa se kasno vraćaju kući [117].

Stoga su Lagos i ostali [117], s gledišta aktivnosti srneće divljači godinu podijelili na slijedeće faze:

- razdoblje podizanja mladih (od sredine travnja do sredine lipnja)
- razdoblje sparivanja (srpanj - kolovoz)
- razdoblje lova srne (rujan - siječanj)

- ostatak godine.

Ova je podjela dosta čudna s time da je razdoblje lova podložno regionalnim promjenama.

S time u svezi treba istaknuti kako dnevna aktivnost divlje svinje ovisi o lovnom pritisku te dostupnosti hrane. Naime, ova životinjska vrsta pokazuje relativno učestalu aktivnost tijekom dana (osobito krmače s praščićima), koja osobito dolazi do izražaja tijekom zime (manjak krmiva, odnosno intenzivnije traženje hrane), a može iznositi čak 64 % tijekom 24 sata. Međutim, ukoliko je populacija uznemirena aktivnošću čovjeka (lov, šumski i poljoprivredni radovi), odnosno u uvjetima kultiviranog krajobraza tada se glavnina aktivnosti odvije noću [165].

Dosadašnja istraživanja odnosa plijen - predator ukazuju kako odgovor plijena na rizik izlaganja predatorima može biti:

- morfolški [166]
- fiziološki [167]
- etološki, koji podrazumijevaju izniman oprez ([168], [169], promjena obrasca hranjenja, aktivnosti ili kretanja [170]).

Generalno, rizik od predacije je strukturiran prostorno i vremenski [171], te generira jedan heterogeni „krajobraz straha“ [172], [173], unutar kojeg plijen može nastojati minimizirati izloženost rizika tako što mijenja svoje ponašanje. Budući da na području Ličko-senjske županije obitavaju sva tri krupna predatora (smeđi medvjed, sivi vuk i euroazijski ris - *Lynx lynx*), kojima divlji parnoprstaši predstavljaju okosnicu plijena za očekivati je kako u pojedinim slučajevima predacija može inducirati migracije te životinje izložiti naletima, bez obzira radi li se o plijenu ili predatoru. Stoga bi u budućnosti istraživanje vremenskih obrazaca naleta trebalo usmjeriti k usporedbi obrazaca naleta u područjima sa i bez krupnih predatora.

Interakcija između klimatskih čimbenika i migracija pojedinih životinjskih vrsta je sada već diljem svijeta dobro istražena. Međutim, osim dnevnih i sezonskih migracija, kao posljedica recentnih klimatskih promjena svakako treba uzeti u obzir i pojavu širenja areala nekih vrsta. Osobit primjer tome jest divlja svinja. Još se sredinom 20. stoljeća u znanstvenim krugovima uvriježilo mišljenje kako je glavni ograničavajući čimbenik širenja ove vrste na sjever Europe dubina snijega [174], budući da se tadašnja sjeverna granica njena areala poklapala s izolinijom dubine snijega od 30 do 40 (50) cm. Stoga Briedermann u [174] navodi

kako je ova vrsta u Finsku dospjela 50 - tih godina 20. stoljeća iz Rusije, odnosno uvjet pomaka sjeverne granice areala divlje svinje je gospodarenje, odnosno lovostaj i prihrana [174]. Upravo snijeg i prihrana krepkom hranom može i biti razlog povećane aktivnosti divlje svinje tijekom razdoblja listopad - prosinac. Naime, divlja svinja izbjegava područja sa snježnim pokrivačem dubljim od 30 do 40 cm [174], što je i jedan od temeljnih razloga njena ograničenog širenja prema sjeveru Europe, pogotovo ako joj se tijekom zime ne izlažu krmiva. U pojedinim zemljama ova je činjenica i uzeta u obzir pri određivanju uzgojnih područja za crnu divljač. Prema Hell i ostali [175] optimalne klimatske prilike za ovu divljač su do 400 m nadmorske visine, no ona se cijele godine zadržava i na nadmorskim visinama do 800 m (tijekom ljeta i na većim visinama). Stoga su joj limiti obitavanja područja na kojima se snijeg zadržava dulje od 160 dana. Osim toga za gustoću populacije je od odlučujućeg značaja i tip šumskih sastojina jer je najveća gustoća populacije na području Slovačke zabilježena u sastojinama hrastova (*Quercus* spp.) i obične bukve *(Fagus sylvatica)*, a najmanja u sastojinama smreke. Upravo sastojine obične bukve dominiraju na području Ličko-senjske županije [176], a bukva može biti znatno zastupljena i u smjesi s drugim vrstama (npr. mješovite sastojine bukve i obične jele – *Abies alba*, [177]).

Činjenica je kako pri određivanju ovisnosti ponašanja divljih životinja i WVC-a u obzir svakako treba uvrstiti i zahtjeve određenih vrsta prema staništu, odnosno ne žive svi istovrsnici u staništima jednake kvalitete te stoga nastoje doći u bolja staništa. Uzrok tome ne mora nužno biti trofičke prirode nego potraga za mirnijim područjima (uključujući izbjegavanje predatora) ili područjima s manjim klimatskim ekstremima.

Za razliku od divlje svinje, muflona, divokoze, jelena običnog i jelena lopatara, srna obična je tzv. distancijski, odnosno teritorijalni tip životinja. To znači da otprilike 3 mjeseca pred početak parenja (parenje najčešće počinje u srpnju) srnjaci počinju borbe za teritorije [178]. Teritorijalni srnjaci su stari 2 do 3 godine i nakon toga srnjak taj teritorij može držati iz godine u godinu, i to uzastopno od 3 do 4 godine.

Stubbe i ostali u [179] navode kako se u poljoprivrednim područjima divlja svinja uglavnom zadržava u poljima pod kukuruzom, čak do žetve, a nakon toga se najčešće ne vraćaju u prvotna prebivališta nego osvajaju nova područja. U dobi od 4 do 5 godina na više veprovi pokazuju tendenciju smanjenja veličine životnog prostora. Razlog tome je taj što stariji veprovi bolje poznaju prvotno područje obitavanja, a u povećanoj dobi su oprezniji i tako se na manjoj ploštini životnog prostora osjećaju sigurnije. Iako mužjaci mogu otići i 17 000 m od mjesta gdje su obilježeni, ova udaljenost dosta ovisi o strukturi staništa tako da

je životni prostor divlje svinje čak i unutar jedne regije dosta varijabilan. Primjerice u jednom je reviru krdo otišlo čak 100 000 m od mjesta gdje su jedinke obilježene. Ženska grla su vjernija području gdje su i oprasena. Naime, 65 % nazimica je odstreljeno u područjima na kojima su i obilježena. U dobi od 2 godine na dalje krmače više ne pokazuju tendenciju širenja životnog prostora i zadržavaju se u području promjera 6 000 m.

Kod socijalnih vrsta je vrlo važna distanciranost ženki jer se u slučaju razmaka između legala razvija povoljan odnos između majke i mladunčadi. Budući da se prasenje uglavnom odvija tijekom zime, zbog slabe termoregulacije prasadi, osobito je važno da krmače za gnijezda izaberu toplije mikrolokacije. Izbor pogodnog gnjezdilišta je ključan čimbenik neonatalnog preživljavanja, a isto tako može utjecati na kondiciju jedinke. Prema [180] lokacija utječe na temperaturu u gnijezdu što utječe na vremensko trajanje nazočnosti roditelja u gnijezdu. Stoga je izrada gnijezda prije partusa jedna od temeljnih značajki porodice svinja. Fernández-Llario u [181] navodi kako u sredozemnom području Europe krmače uglavnom prave gnijezda u šumi hrasta crnike *(Quercus ilex)*, u poplavnim šumama, a najmanje u šumama hrasta plutnjaka *(Quercus suber)*. Pri tome je od odlučujuće važnosti blizina vode i u prosjeku ta udaljenost iznosi 54,2 ± 37,6 m, odnosno u ritskim područjima je ta udaljenost signifikantno najkraća (17,5 ± 2,88 m), a najudaljenija u šumama hrasta crnike (44,75 ± 26,53 m) i hrasta plutnjaka (88,75 ± 45,72 m).

Nadalje, unutar nekog povoljnog područja za prasenje gnijezda može praviti više krmača te udaljenost između njih može varirati u prosjeku od 315,6 ± 147,5 m. Generalno, mjesto izrade gnijezda u sredozemnom području je limitirano s 4 čimbenika:

- gustoći raslinja (zaklon od predatora)
- blizini vode (laktacijom se gubi velika količina tekućine)
- minimalan razmak od drugog gnijezda (individualna distanciranost)
- povoljnom temperaturom zraka.

Na pravce i opsege disperzije utječe nekoliko čimbenika kao što su: gustoća populacije, struktura i kvaliteta staništa te klimatske značajke prostora [182], [183] i [184]. Usprkos mišljenjima kako divlja svinja nije vjerna staništu istraživanja [163] su pokazala suprotno. Naime, unutar područja prasenja odstrijeli se 87,5 % „lokalnih“ jedinki, 8,7 % ih se odstreli u polumjeru 4 000 do 10 000 m, a 3,8 % u polumjeru preko 10 000 m, no ona može iznositi i do 41 530 m. Budući da je prostor Ličko-senjske županije relativno velik i

heterogen, čini se da ima dovoljno kvalitetnog prostora za obitavanje divlje svinje te ona ne mora poduzimati znatnije horizontalne migracije.

Dakle za daljnje praćenje i povećanje točnosti modela predviđanja naleta svakako bi osim vrste trebalo upisivati spol i procijenjenu dob jedinke.

Putzu i ostali u [23] navode kako je učestalost naleta na srnu običnu i divlju svinju tijekom dana vrlo mala. Preko 80 % naleta na ove vrste se dogodi u vremenu od 19:00 do 00:00 sati, no kod srne se javlja još jedan vrhunac naleta u zoru. Za razliku od njih Rodríguez-Morales i ostali u [115] su dobili sličnu dnevnu distribuciju naleta onoj na području Ličko-senjske županije, no nisu je povezivali s mjesecima. Iako su naleti na srnu koji se događaju tijekom dana na području Ličko-senjske županije izraženiji tijekom ljetnih mjeseci, oni mogu biti povezani i s fiziologijom ove vrste. Naime, za razliku od svojih srodnika srna spada u tzv. brsni tip biljoždera. To znači da ona pri prehrani bira relativno kvalitetnije i probavljivije dijelove biljaka, čime se skraćuje razdoblje prerade ingesta te se mora češće hraniti, odnosno u prosjeku uzima hranu svaka dva sata [185]. Budući da je hrana tijekom vegetacije probavljivija nego tijekom zime učestaliji su turnusi hranjenja i time veća migracija ove vrste divljači, što potencira i nastanak naleta.

3.2.2. Povezanost prostornih obrazaca naleta s ponašanjem divljači

Pregled radova koji su se bavili problematikom prostornih obrazaca naleta vozila na divljač (WVC-a) ukazuje na postojanje, odnosno upotrebu različitih metoda, uglavnom nema jedinstvenog pristupa. Stoga se izdvajanje ključnih prostornih čimbenika naleta (pretkazivača) unutar svake vrste od autora do autora može razlikovati, što se može vidjeti iz *tablica 37., 38., 39. i 40.*

Generalno se pretkazivači (nezavisne varijable) mogu podijeliti na nekoliko skupina:

- struktura staništa – udjeli pojedine katastarske kulture u istraživanom području ili njena udaljenost od mjesta naleta
- topografske varijable – nagib terena, reljef (usjek, zasjek, nasip, ravnica)
- značajke ceste – udaljenost od zavoja (čak i broj zavoja), ograničenje brzine, nazočnost koridora (nadvožnjaci, podvožnjaci, tuneli, propusti, raskrižja), mostova i ograda (uključujući branike i Jersey-eve barijere) te gustoća prometa

- značajke vrste – vrsta (taksonomska pripadnost, čak do skupine razreda – npr. vodozemci, gmazovi, ptice i sisavci), veličina životinje, trofička skupina (biljožder, mesožder, svežder), nazočnost predatora (uključujući i čovjeka – uznemiravanje, lov) i gustoća populacije.

Utjecaj strukture staništa na pojavnost naleta ovisi o heterogenosti staništa [110]. U monotonom krajobrazu daleko manje varijabli utječe na vjerojatnost naleta. Primjera radi u istraživanju Gunson i ostali u [122] je samo 5 od 25 okolišnih varijabli imalo signifikantan utjecaj na broj naleta (heterogen krajobraz), dok je u monotonom staništu autor u [119] pronašao da signifikantan utjecaj na broj naleta ima čak 14 od 19 okolišnih varijabli.

Kod ptica su mjesta naleta daleko jače povezana sa strukturom staništa. Na primjer, generalno se može reći kako vjerojatnost naleta na pticu u šumskim područjima daleko manja nego na otvorenim prostorima. Osim toga, daleko je veća tendencija da će na pticu naletjeti auto ako cesta ima središnji zeleni pojas, nego ako ga nema (85 % vjerojatnije; omjer izgleda = 1,852; [121]).

Tablica 37. Opis signifikantnih, s krajobraznim strukturama povezanih, pretkazivača naleta vozila na dvopapkara („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta)

CILJANA VRSTA	OPIS PRETKAZIVAČA	+/-	IZVOR
Šume			
Bjelorepi jelen (*Odocoileus virginianus)*	Blizina šuma većih od 0,8 km^2 ili drvoreda povezanih sa šumama	+	[186]
	Blizina do šumskog pokrova veća od 200 m	+	[187]
	Udio šumskih krpa s unutarnjim područjima većim od 50 m od ruba (800 m)	+	[188]
Bjelorepi jelen *(O. virginianus)* i prerijski bjelorepi jelen (*O. hemionus)*	Gustoća i veličina šuma (800 m)	+	[187]
	Nazočnost sastojina četinjača na strani naleta	+	[122]
Srna (*Capreolus capreolus),* jelen (*Cervus elaphus)* i divlja svinja (*Sus scrofa)*	Udio šumskog pokrova šuma koje nisu u poplavnom području (1 000 m)	+	[189]
	Blizina šumskih sastojina	+	
Los (*Alces alces)*	Udio sastojina četinjača (500 m)	+	[119]

	Udio sastojina listača (500 m)	+	
	Blizina ruba šume	+	
Otvorena područja			
Bjelorepi jelen *(O. virginianus)*	Veličina krpa travnjaka (800 m)	+	[188]
Los *(A. alces)*	Udio otvorenih područja (500)	+	[119]
Otvorene vode			
Los *(A. alces)*	Udio vlažnih staništa (500 m)	-	[119]
Poljoprivreda			
Bjelorepi jelen *(O. virginianus)*	Udio oranica pod žitaricama, na nekom području i indeks oblika (800 m)	-	[188]
Los (*A. alces)*	Udio poljoprivrednog zemljišta (500 m)	-	[119]
Urbana područja			
Bjelorepi jelen *(O. virginianus)*	Ploština (ha) kuća i komercijalnih zgrada	-	[186]
Srna *(Capreolus capreolus),* jelen (*Cervus elaphus)* i divlja svinja (*Sus scrofa)*	Udio urbanih područja (1 000 m)	-	[189]
Bjelorepi jelen *(O. virginianus)* iprerijski bjelorepi jelen (*O. hemionus)*	Broj zgrada (100 m)	-	[190]
Los *(A. alces)*	Udio urbanog zemljišta (500 m)	-	[119]
Raznolikost staništa			
Bjelorepi jelen *(O. virginianus)*	Broj nešumskog; drvenaste vrste (< 2 m visine), zeljasta vegetacija i poljoprivrednih kultura	+	[186]
Bjelorepi jelen *(O. virginianus)*	Simpson-ov indeks raznolikosti (800 m)	+	[187]
Bjelorepi jelen *(O. virginianus)* i prerijski bjelorepi jelen (*O. hemionus)*	Nazočnost otvorenih mješovitih šuma u odnosu na otvorena staništa	+	[122]

Srna *(Capreolus capreolus),* jelen (*Cervus elaphus)* i divlja svinja (*Sus scrofa)*	Shannon-ov indeks raznolikosti, šume i otvorena staništa (1 000 m)	+	[189]
Bjelorepi jelen *(O. virginianus)* iprerijski bjelorepi jelen (*O. hemionus)*	Shannon-ov indeks raznolikosti (100 m)	+	[190]
Bjelorepi jelen *(O. virginianus)*	Nazočnost ekotona šuma-polje, uzduž autoceste	+	[191]
Los *(A. alces)*	Duljina rubova pokrova tla (500 m)	+	[119]
Los *(A. alces)*	Broj presjeka s rubovima šuma	-	[119]
Krpe (područja) javnih površina			
Bjelorepi jelen *(O. virginianus)*	Udio javnih rekreacijskih površina, npr. šuma (800 m)	+	[187]
Bjelorepi jelen *(O. virginianus)* iprerijski bjelorepi jelen (*O. hemionus)*	Broj krpa javnih površina (mješovite šume, šikare, travnjaci i vlažna staništa) (100 m)	+	[190]
Korištenje staništa specifično za vrstu			
Los *(A. alces)*	Nazočnost bočatih jezera koja koristi los; salinitet ≥ 300 ppm	+	[164]
Prerađeno iz: [118]			

Tablica 38. Opis signifikantnih, s krajobraznim strukturama povezanih, pretkazivača naleta vozila na zvijeri („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta)

CILJANA VRSTA	OPIS PRETKAZIVAČA	+/-	IZVOR
Šume			
Kuna bjelica (*Martes foina)*	Udio šuma hrasta plutnjaka uz cestu	+	[47]
Urbane površine			
Jež *(Erinaceus* spp.)	Udio izgrađenog zemljišta uzduž ceste	+	[44]
Tvor *(Putorius putorius)*	Blizina izoliranih kuća	-	[192]
	Blizina kunićnjaka	+	
Jazavac (*Meles meles)*	Udio urbanog područja (500 m)	-	[47]
	Blizina do ostalih cesta	-	[47]
Lisica *(Vulpes vulpes)*	Udio urbanog područja (500 m)	+	[47]
Bjelorepi jelen *(O. virginianus)*	Nazočnost ekotona šuma-polje, uzduž autoputa	+	[191]
Los *(A. alces)*	Duljina rubova pokrova tla (500 m)	+	[119]
Los *(A. alces)*	Broj presjeka s rubovima šuma	-	[119]
Krpe (područja) javnih površina			
Bjelorepi jelen *(O. virginianus)*	Udio javnih rekreacijskih površina, npr. šuma (800 m)	+	[187]
Bjelorepi jelen *(O. virginianus)* iprerijski bjelorepi jelen (*O. hemionus)*	Broj krpa javnih površina (mješovite šume, šikare, travnjaci i vlažna staništa) (100 m)	+	[190]
Korištenje staništa specifično za vrstu			
Los *(A. alces)*	Nazočnost bočatih jezera koja koristi los; salinitet ≥ 300 ppm	+	[164]
Prerađeno iz: [118]			

Tablica 39. Opis signifikantnih pretkazivača naleta vozila na dvopapkare povezanih s parametrima ceste („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta)

CILJANA VRSTA	OPIS PRETKAZIVAČA	+/-	IZVOR
Topografija			
Bjelorepi jelen *(O. virginianus)* i prerijski bjelorepi jelen (*O. hemionus)*	Maksimalni nagib terena	-	[122]
Srna *(Capreolus capreolus),* jelen (*Cervus elaphus)* i divlja svinja (*Sus scrofa)*	Nazočnost strmih bankina; ≥ 2 m visoke te vertikalni i horizontalni odnos ≥ 1	-	[189]
	Kontinuiranost strmih bankina	-	
Los *(A. alces)*	Promjenjivost topografije	-	[119]
	Prosječan nagib terena (1 000 m)	+	[164]
Jersey-eve barijere/branici			
Bjelorepi jelen *(O. virginianus)* iprerijski bjelorepi jelen (*O. hemionus)*	Duljina Jersey-evih barijera (800 m)	-	[188]
	Blizina do Jersey-evih barijera	-	[119]
Srna *(Capreolus capreolus),* jelen (*Cervus elaphus)* i divlja svinja (*Sus scrofa)*	Nazočnost branika	-	[189]
	Nazočnost kontinuiranih branika	-	
Vidljivost			
Bjelorepi jelen *(O. virginianus)*	Vidljivost mjerena s udaljenosti od 2 m visoke optičke daske od središta autoceste	+	[186]
	Najkraća vidljivost	-	
Gustoća prometa/ograničenje brzine			
Los *(A. alces)*	Prosječna godišnja gustoća prometa (PGDP)	+	[119]
	Prosječno ograničenje brzine	+	
Bjelorepi jelen *(O. virginianus)*	Propisano ograničenje brzine ili prosječno ograničenje brzine	-	[186]
Širina kolnika			
Bjelorepi jelen	Broj kolničkih i prometnih trakova	+	[188]

(O. virginianus)			
Ograđivanje			
Bjelorepi jelen *(O. virginianus)*	Nazočnost 7,5' visoke ograde postavljene na rub ili 25 jardi do obližnjeg šumskog područja i travnjačke površine ruba autoceste	+	[191]
	Prosječan udio ograde za stoku (< 0,91 m) unutar 100 m	+	[186]
Los *(A. alces)*	Neograđivanje	-	[119]
Cestovni koridor			
Srna *(Capreolus capreolus),* jelen (*Cervus elaphus)* i divlja svinja (*Sus scrofa)*	Nazočnost raskrižja	+	[189]
Los *(A. alces)*	Broj križanja s privatnim putevima	+	[119]
	Duljina privatnih puteva (500 m)	+	
Obalni koridor			
Los *(A. alces)*	Nazočnost udolina s najmanje jednim nagibom < 2 %	+	[164]
Bjelorepi jelen *(O. virginianus)* iprerijski bjelorepi jelen (*O. hemionus)*	Široki obalni koridor koji prelazi preko ceste (800 m)	+	[187]
	Blizina drenažnog sustava	+	[122]
	Broj mostova	+	[188]
Prerađeno iz: [118]			

Tablica 40. Opis signifikantnih pretkazivača naleta vozila na zvijeri povezanih s parametrima ceste („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta)

CILJANA VRSTA	OPIS PRETKAZIVAČA	+/-	IZVOR
Vidljivost			
Tvor *(Putorius putorius)*	Duljine neprekinute linije na cesti	-	[192]
Gustoća prometa/ograničenje brzine			
Tvor *(Putorius putorius)*	Propisano ograničenje brzine	+	[192]
	Prosječna mjesečna gustoća prometa	+	
Jež (*Erinaceus* spp.)	Prosječna dnevna gustoća prometa	+	[44]
Lasica (*Mustela nivalis)*			
Širina kolnika			
Kuna bjelica (*Martes foina)*	Broj javnih cesta u odnosu na autoceste	+	[47]
Presijecajuće strukture			
Lisica *(Vulpes vulpes)*	Broj prelaza iznad i ispod nivelete ceste	+	[47]
Los *(A. alces)*	Broj križanja s privatnim putevima	+	[119]
	Duljina privatnih puteva (500 m)	+	
Obalni koridor			
Tvor *(Putorius putorius)*	Duljina mosta	+	[192]
Prerađeno iz: [118]			

Većina naleta vozila na divljač (WVC-a) se događaju na lokacijama koje su slabo pregledne, slabo osvijetljene, na suhim kolnicima te pri većim brzinama vozila [55]. S druge strane, divlje životinje (npr. parnoprstaši) dosta postojano koriste svoje pravce (rute) kretanja, bez obzira da li se radi o migracijama ili samo o kretanju unutar životnog prostora [193]. Međutim, ako im te pravce presijeku prometnice (cesta ili pruga) tada njihov obrazac kretanja predstavlja zonu visokih rizika i za tu vrstu i za čovjeka. Generalno, divljač nastoji prijeći cestu na mjestima koja su zaklonjena stablima ili grmljem, a nalaze se što dalje od područja ljudske nazočnosti [186], [194], [195].

Modeli predviđanja opasnih mjesta mogu se bazirati na:

- postojećim bazama lokacija naleta
- podacima dobivenim izravnim praćenjem kretanja divljih životinja
- kombinacijom dvaju prethodnih modela.

U prva dva slučaja točnost procjene modela je daleko niža od točnosti dobivene kombinacijom spomenutih metoda. Međutim, vrlo je skupo pratiti kretanje na razini jedinke jer životni prostori i obrasci kretanja ovise o relativno velikom broju čimbenika. Primjerice, obrasci prelaska losa preko ceste su dosta individualni, no pri prelasku velikih prometnica los pokazuje generalan, odnosno uniforman obrazac ponašanja [156]. Los pokazuje bimodalnu aktivnost te strogi sezonski obrazac aktivnosti. On je tijekom dana uglavnom aktivan 3 sata ujutro i 3 sata poslije podne. Stoga Neumann i ostali u [156] zaključuju kako su ključni čimbenici naleta vozila na losa smanjena vidljivost kao posljedica doba dana (sumrak, suton ili mrak) ili paravana od raslinja uz cestu, a ne sama aktivnost losa. Doduše, Neumann i ostali u [156] su na drugačiji način interpretirali ovisnost naleta vozila na ovu vrstu, a uzrok tome može biti taj što su telemetrijski pratili samo košute (102 adultne košute) u području s relativno niskom gustoćom populacije losa, ljudi (od 1 do 18 stanovnika/km^2) i cesta (0,4 do 1 km/km^2). U ovome doktorskom radu je prednost bila upravo ta što su za svaku dionicu ceste izračunate gustoće populacije (relativne odstrelne kvote) koje se od dionice do dionice razlikuju.

Malo i ostali su u [187] za izračun modela procjene naleta koristili vjerojatnost naleta prema izrazu (5):

$$p(x) = \frac{\lambda^x}{\frac{x}{e^{\lambda}}} \tag{5}$$

Gdje su:

- λ = prosječan broj naleta na nekoj dionici ili cesti po kilometru
- x = broj naleta.

Kako bi definirali stacionaže s učestalim naletima autori su načinili procjenu broja naleta za svaki kilometar svake ceste, a nakon toga su radili analizu čimbenika naleta na stacionažama od 100 m. Stacionaže s visokom učestalošću naleta su mjesta s većim udjelom šuma i nižim udjelom oranica u odnosu na mjesta bez naleta.

Prema modelu dobivenim logističkom regresijom stacionaže visokog rizika naleta je moguće predvidjeti s točnošću 80,5 %, a stacionaže niskog rizika naleta s točnošću 85,7 %, što je relativno visoka razina procjene rizika. No, ona je posljedica razdvajanja stacionaža prema učestalosti naleta (jednu kategoriju su činile stacionaže s do 2 naleta – stacionaže niskog rizika naleta, a drugu s tri i više naleta – stacionaže visokog rizika naleta), a na temeljem „univerzalnog“ modela dobivenog u ovom doktorskom radu.

Vjerojatnost nastanka (WVC-a):

1. Dobivanje pretkazivača prema području (strukturi staništa) oko mjesta naleta (podrazumijeva izradu krugova oko mjesta naleta, npr. [114], [119], [120], [122]).
2. Dobivanje pretkazivača iz udaljenosti od mjesta naleta te izračun ključnih čimbenika primjenom PCA ([48], [52]).
3. Predviđanje mjesta naleta iz karata gustoće točaka ([27], [115], [116], [123], [196]).

Ova potonja skupina metoda kao temeljni alat koristi višestruku korespondencijsku analizu ili procjenu gustoće jezgre (Kernel Density Estimation – KDE). Pri tome je potrebno izračunati mrežu najbližeg susjeda, pomoću algoritma najbližeg susjeda (nearest neighbour distance – NND). Primjenom NND metode je moguće dobiti dionice koncentracije naleta (Accident Concentracion Sections – ACS).

Nedostatak trećeg pristupa je što se njime opasna mjesta detektiraju isključivo praćenjem, odnosno evidentiranjem mjesta naleta, dok u prve dvije metode (osobito prva metoda) daju mogućnost predviđanja mjesta naleta i na neistraženom području, ukoliko su poznati parametri procjene. Stoga bismo prva dva modela mogli nazvati dinamičkim modelima jer promjene u krajobraznoj strukturi (npr. sječa šuma ili zapuštanje i sukcesija nešumskih površina ili košnja travnjačkih površina uz ceste) mogu dovesti do promjene u izglednosti naleta na dionici ceste.

Metode identificiranja točaka naleta generalno daju dvije vrste izlaza:

- jednostavna informacija koja ukazuje kako postoji generalna tendencija grupiranja na dionici ceste (K-funkcija ili NND)
- određivanje neke jasne pozicije klastera unutar dionice ili mreže, odnosno dobivanje indeksa opasnosti.

Prve metode ne omogućavaju lokaliziranje skupine unutar dionice, dok su metode iz druge skupine učinkovitije. Prednost KDE metode u odnosu na klasične statističke metode je ta što se nejasno točna pozicija točke naleta objašnjava preko širine pojasa jezgre, što znači nešto poput širenja rizika nesreće. Primjenom KDE metode [123] su za područje južne Moravske uspjeli definirati 840 potencijalno opasnih lokacija, na kojima se dogodilo 3 111 naleta. Pobliže, točnost procjene mjesta naleta je 46,5 % (nalet = 1, nenalet = 0), a ako se žele pronaći mjesta s barem 3 naleta tada je vjerojatnost procjene 36,8%, odnosno duljina opasnih lokacija s 4,1 % pada na 2,6 %. Usprkos tome učinkovitost KDE metode je još uvijek nedovoljno istražena i čini se kako je ta metoda pogodnija za vizualizaciju cilja nego za određivanje mjesta naleta [197]. Stoga će u budućnosti pri izradi i razvoju modela biti potrebno objediniti vremenske i prostorne obrasce naleta kako bi se poboljšala točnost predviđanja naleta.

Do sada su modele za procjenu vjerojatnosti WVC-a na bazi krugova različitih promjera oko točke naleta (metodologija je slična kao i u ovom doktorskom radu) razvijali Seiler u [119] i Ng i ostali u [120]. Za procjenu naleta vozila na losa Seiler je u [119] razvio 3 alternativna modela. Oni međusobno variraju u točnosti, ali im je točnost procjene preko 60 %. Prvi model koristi samo parametre ceste (R^2 = 0,727), drugi krajobrazne varijable (R^2 = 0,675), a treći, i najtočniji, kombinaciju okolišnih i krajobraznih pretkazivača (R^2 = 0,78). No, u trećem modelu je jedna od ključnih varijabli brzina vozila, ali u kombinaciji s utjecajem ograda, brojnošću losa i blizinom šume. U konačnici, ako bi se brzina vozila na kritičnim dionicama smanjila s 90 km/h na 70 km/h, a uz cestu postavile ograde i očistili rubni pojasevi sa svake strane ceste u širini od 100 m, rizik naleta bi se smanjio za čak 65 %. Upravo ovakva mogućnost razrađivanja modela procjene vjerojatnosti naleta u odnosu na ekološke varijable čini dinamičke modele procjene naleta izrazito praktičnim.

Jedna od metoda je i primjena *K*-statistike. Ona se bazira na broju susjednih mjesta naleta unutar određene udaljenosti prema izrazu (6), [121], [198] i [199]:

$$K(t)_{obs} = \frac{RL}{N^{"}} \sum_{\substack{i=1 \\ i \neq j}}^{N} \sum_{j=1}^{N} I(d_{ij}) \tag{6}$$

Gdje su:

- t = referentna udaljenost na kojoj su praćeni naleti. Ta se vrijednost određuje proizvoljno, na način da se dionica ili cesta na kojoj se prate naleti podijeli na 100 dijelova (blokova). Ako se naleti prate na više dionica tada se vrijednost t određuje prema najkraćoj dionici. Npr. ukoliko se prate naleti na 3 dionice duljina 105 600 m; 80 100 m i 62 400 m tada je vrijednost referentne udaljenosti 624 m (62,4 km/100 = 0,624 km)
- N =broj naleta na susjednim dionicama ceste
- RL = duljina ceste
- d_{ij} = udaljenost od mjesta naleta i do mjesta naleta j
- $I(d_{ij})$ = indikacijska funkcija koja iznosi 1 ako je $d_{ij} \leq t$ i 0 u slučajevima kada je $d_{ij} \geq t$.

Za cijeli postupak Levine je u [198] načinio program za spomenutu analizu (https://www.nij.gov/topics/technology/maps/pages/crimestat-downloads.aspx#program) pri čemu je ulazne podatke potrebno prethodno obraditi u nekoj od GIS aplikacija.

Seiler [200] je u istraživanjima koristio više varijantnu regresiju, a nalete je analizirano na makro (država i županija) i mikro razini (okrug i župa). Međutim, točnost modela ovisi i o točnosti podataka, a ona pak ovisi i o koncepciji gospodarenja s divljači. U Švedskoj su podaci o odstrelu srneće divljači pouzdani jedino na razini županija, dok su kod losa pouzdani na razini okruga, a vozači su obavezni nalete vozila na parnoprstaša prijaviti policiji, koja pak vodi bazu samo u odnosu na vrstu i mjesto naleta.

Ng i ostali su u [120] za procjenu naleta vozila na vrste jelena roda *Odocoileus* spp. u području Edmontona također razvili 3 modela, koji bi se mogli okarakterizirati kao:

1. Model visoke preciznosti - kod ovog modela potrebno je u određenom području polumjera 800 m ceste razvrstati s obzirom na maksimalnu dopuštenu brzinu vožnje (do 50 km/h; 60 do 70 km/h i preko 80 km/h). Unutar svake od spomenutih kategorija ključna je gustoća prometnica u polumjeru od 800 m, a točnost procjene naleta je između 80 i 88%.
2. Agregatni model, koji služi za standardiziranje preciznosti akcidentnih lokacija - ovaj model radi procjenu na bazi udaljenosti do najbliže vodene površine, udjela šuma te udjela oranica i travnjaka. Rezultati ovog modela ukazuju da su naleti

vjerojatniji na mjestima gdje je cestovna mreža gušća, tla su bolje kvalitete, a udio nešumske vegetacije velik.

3. Model „vrućih točaka“ - prema ovome modelu, na vjerojatnost naleta jedino utječe ograničenje brzine.

Međutim, i sami prateći dijelovi cesta, kao što su nasipi ili bankine mogu doprinijeti grupiranju divljači. U ovakve elemente spadaju rubovi cesta, koje prate jarci, a obrasli su produktivnim nešumskim raslinjem, osobito ako se na njima siju alohtone vrste trava koje ne samo da rastu brže nego su i fenološki ranije u odnosu na autohtonu okolnu vegetaciju [120].

Model procjene WVC-a koji je razvio Sjöllund u [201] ukazuje da se naleti vozila na divlje preživače javljaju na dionicama cesta:

- s većim udjelom listopadne šumske vegetacije (čak i šikara)
- većom raznolikošću staništa
- gušćom mrežom prometnica
- većim udjelom šumskih granica
- većim udjelom granica rijeka.

Na autocestama od prostornih cestovnih parametara za procjenu WVC-a definitivno ključnu ulogu igraju raskrižja izvan razine (RIR) jer preko njih pojedine vrste divljači (osobito lisica i srna obična) dospijevaju na autocestu [202]. U prilog *tablicama 37. do 40*. idu i istraživanja Cserkész i ostalih [202] jer svaka vrsta divlje životinje ima specifični set pretkazivača naleta na autocesti (3 do 4), od čega je jedan dominantan:

- divlja svinja - nazočnost slobodnog prostora uz autocestu (AIC w_i = 13,58; p = 0,00)
- srna obična i lisica – nazočnost RIR-a (AIC w_i = 13,85; p = 0,00; respektivno AIC w_i = 9,35; p = 0,00)
- vidra – nazočnost vodotoka (AIC w_i = 5,17; p = 0,02)
- jazavac – gustoća populacije (AIC w_i = 17,62; p = 0,00).

Prema njima gustoća populacije nema ključan pozitivan učinak na broj naleta (izuzetak je jazavac). Iako su na razini vrste modeli procjene WVC-a bili relativno dobri (od AIC = 170,80 kod vidre do 1 140,68 kod lisice) generalni, odnosno univerzalni model procjene naleta (za sve vrste zajedno) je bio izrazito nizak (AIC = 1 339,44). Međutim, isti autori navode kako mogu postojati odstupanja od mjesta naleta do mjesta nalaska nastradale životinje. Stoga je ovakav način skupljanja podataka podložan grešci koja ovisi o točnosti

GPS uređaja i putanji koje je vozilo prešlo od mjesta naleta do mjesta zaustavljanja. Stoga se ne može govoriti o točkama naleta nego o liniji (dionici) naleta [123].

Pri izračunu regresijskog modela, metodom višestruke regresije, Seiler [200] je dobio relativno visoke regresijske koeficijente (los: $R^2 = 0,598$; $p < 0,0001$; srna obična: $R^2 = 0,568$; $p < 0,0001$). Budući da je radio s relativno velikim brojem nezavisnih varijabli, Seiler [200] je izbacio sve varijable koje su u autokorelaciji imale vrijednost koeficijenta $R^2 > 0,75$. Međutim, točnost modela ovisi o modulu skale za koji se računa. Drugim riječima, obrasci dobiveni na razini određenog područja (u Seilerovom istraživanju to su bile župe) ne moraju vrijediti i na razini okruga ili županije i obrnuto. Sličan je slučaj i na području državnih cesta Ličko-senjske županije. Naime, s porastom polumjera područja oko mjesta naleta smanjuje se broj nezavisnih varijabli (pretkazivača), ali čak i njihovi predznaci. Ovo je osobito izraženo kod izračuna vjerojatnosti naleta po ćeliji jer pri polumjeru ćelije od 500 m udio zapuštenog poljoprivrednog zemljišta ima negativan utjecaj na pojavnost naleta, a pri polumjeru od 1 000 m pozitivan. S druge strane udio goleti i mora imaju pozitivan utjecaj na pojavnost naleta pri polumjeru ćelije od 500 m, a negativan pri polumjeru ćelije od 1 000 m. Zapušteno poljoprivredno zemljište može smanjiti preglednost ceste, ali i srni može pružiti relativno dobar zaklon. Stoga nije isključeno da se srne rado zavlače u ovakve krajobrazne elemente.

S gledišta kvalitete staništa goleti predstavljaju terene koji ne pružaju kvalitetne trofičke uvjete za srnu, odnosno u pojedinim slučajevima im mogu jedino poslužiti za odmor, dok je more potpuno neprikladno stanište za terestričke vrste - potpun udio mora u ćeliji isključuje mogućnost nazočnosti srne. Zanimljivo je kako na pojavnost naleta vozila na srnu ne utječe brojnost srne nego brojnost divlje svinje.

S obzirom na relativno velik životni prostor i učestaliju noćnu aktivnost divlje svinje objašnjenu u prethodnome poglavlju vrlo je vjerojatno da aktivnost divlje svinje djeluje uznemirujuće na srnu običnu te je prisiljava na kretanje.

Dosadašnja istraživanja su pokazala kako je povišeni rizik od naleta vozila na divljač povezan s linearnim krajobraznim strukturama (npr. obalni koridori, dalekovodi, strme padine ili grebeni ili ostali oblici transportnih infrastruktura) koje navode životinju na kretanje uzduž ili preko ceste [48], [121]. Prema Primi i ostalima u [110] većina naleta vozila na divlju svinju se javlja u blizini oranica ($\chi^2 = 24,133$; $p < 0,001$) i šuma ($\chi^2 = 15,116$; $p < 0,001$), uglavnom na lokacijama gdje cestu obrubljuju ili presijecaju jarci ili stajaće vode zarasle drvenastom vegetacijom. Međutim, u brdskim predjelima većina naleta nastaje tijekom ljeta i jeseni i to

tamo gdje voćnjaci (kestena i lješnjaka) graniče sa šumom. Autori ne navode o kakvim tipovima sastojine se radi, no ovdje je očito da divljač zalazi u spomenute voćnjake radi hranjenja (u to doba dozrijevaju kesteni i lješnjaci). Isto tako nije nađen utjecaj zavojitosti ceste na učestalost naleta, no naleti su bili učestaliji na dionicama sa slabijom vidljivosti, odnosno tamo gdje živice i ostale vizualne barijere ograničavaju vidljivost. Treba istaknuti kako spomenuti autori kao nezavisne varijable nisu koristili udio pojedinih kultura oko ceste nego udaljenost određenih kultura od mjesta naleta.

I na području Ličko-senjske županije udio se voćnjaka, kao nezavisna varijabla, (pretkazivač) javio u nekoliko modela procjene za divlju svinju - vjerojatnosti naleta za ćelije polumjera 1 000 m te broja naleta po ćeliji za ćelije polumjera 250, 500 i 1 000 m. Bez obzira što voćnjaci kasnije nisu uključeni u konačan model procjene naleta vozači ipak trebaju biti oprezni ako voze uz voćnjake, osobito u noćne sate. Pri tome treba naglasiti da se u različitim modelima procjene naleta vozila na srnu javljaju. Stoga se danas sve češće govori o tzv. prostorno – vremenskim (eng. spatio – temporal) obrascima naleta. Naime, u daljnim istraživanjima bi trebalo ispitati da li prostorni modeli naleta razdvojeni prema sezoni, dobu dana i mjesečevim mjenama daju višu vjerojatnost procjene nego generalni, odnosno oni koji su izrađeni na temelju cjelogodišnjih naleta.

Nažalost, na području Ličko-senjske županije je dobivena statistički značajna povezanost između nastanka naleta i krajobraznih struktura tek na prostoru promjera 12 000 m gdje nezavisna varijabla (pretkazivač) može biti jedino TOPEX. Uzrok tome može biti relativno malen uzorak (svega 48 mjesta naleta tijekom 5 godina), no budući da je povezanost s TOPEX-om pozitivna ovo bi moglo ukazivati kako u područjima s izrazitim reljefom divlja svinja cestu ne može prijeći gdje želi nego gdje joj reljef, odnosno konstrukcija ceste dozvoljava. To znači da joj je otežano prelaziti cestu preko izraženih zasjeka, usjeka i nasipa, nego je prelazi tamo gdje je ona što bliže razini okolnog terena.

Prema Malo i ostalima u [189] na dionicama cesta gdje su nasipi (općenito kosine) jače izražene (više od 2 m) a odnos visina / duljina veći od 1V : 2H (npr. visina nasipa je 1 m na duljini od 2 m), vjerojatnost naleta je 3,3 puta niža ako su kosine kontinuirane, odnosno 1,43 puta niža na diskontinuiranim dionicama. Osim toga naleti su učestaliji uz raskrižja, a najmanji u blizini podvožnjaka. Prema [189] većina naleta (70 %) se događa na samo 8 % cestovne mreže. Stoga se i mjere sprječavanja šteta trebaju i ograničiti na tih 8 % lokacija, a ne na cijeloj duljini cesta, što je velika ušteda novca.

Iako se u predloženim modelima na cestama Ličko-senjske županije javlja većina nezavisnih varijabli (pretkazivača), činjenica je kako je gustoća populacije krupne divljači ključan čimbenik naleta, što se poklapa s gotovo svim autorima koji su se bavili ovom problematikom. Stoga će u budućnosti, osim tehničkih mjera zaštite, jedna od mjera definitino morati biti i snižavanje brojnosti divljači na područjima gdje se naleti javljaju intenzivnije.

3.3. Višekriterijsko vrednovanje - AHP metodom opasnih dionica državnih cesta Ličko-senjske županije od pojave divljači

Praćenjem i analizom podataka o prometnim nesrećama u kojima je sudjelovala krupna divljač na državnim cestama, sa stajališta prometne sigurnosti mogu se rangirati opasne dionice od pojave divljači na cestama. Zbog kompleksnosti prometnog sustava bitan je pristup vrednovanja rješenja prometnih problema primjenom više kriterija. Primjena više kriterija koristi se pri ocjeni projekata metodama višekriterijskog odlučivanja. Jedna od najčešće primjenjivanih metoda za vrednovanje projekata u prometu je metoda Analitičkog hijerarhijskog procesa (AHP metoda). Analitički hijerarhijski proces utemeljio je Thomas Saaty 70-tih godina prošlog stoljeća u cilju rješavanja kompleksnih problema odlučivanja, kada postoji veći broj donositelja odluke, kao i kriterija. Jedna je od najpoznatijih, najprovjerenijih i najčešće korištenih metoda donošenja odluke, odnosno metoda za višekriterijsku analizu. Njezina osnovna prednost očituje se u mogućnosti prilagodbe donositelja odluke u smislu broja atributa, odnosno kriterija i varijanata o kojima se istovremeno odlučuje, a koje je moguće opisati i kvantitativno i kvalitativno. Prema tome, AHP metoda omogućava fleksibilnost procesa odlučivanja i pomaže donositeljima odluke postaviti prioritete, te donijeti najbolju odluku uzevši u obzir i kvalitativne i kvantitativne aspekte odluke.

Primjenom višekriterijskog odlučivanja, primjenom AHP metode može se unaprijediti kvaliteta odlučivanja u rangiranju opasnih dionica od pojave divljači. U doktorskom radu obrađene su prometne nesreće naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije u vremenskom periodu 2012. - 2016. godine [106].

Do sada osim postavljanja prometnih znakova (divljač na cesti) nisu poduzete nikakve mjere sprečavanja pojave divljači na cestama, niti su se rangirala potencijalna opasna mjesta od pojave divljači na cestama. U nastavku doktorskog rada višekriterijskim vrednovanjem, primjenom AHP metode rangirat će se opasne dionice od pojave divljači na državnim

cestama Ličko-senjske županije kako bi se mogle sanirati kroz mjere redovnog održavanja cesta, a sve u cilju povećanja sigurnosti cestovnog prometa.

Informacije za izbor opasnih dionica preuzete su iz tablice 5. doktorskog rada (broj naleta vozila krupne divljači i sivog vuka na državnim cestama Ličko-senjske županije po dionicama tijekom razdoblja 2012. - 2016. te gustoća naleta). Kriteriji su također preuzeti iz tablice 5. doktorskog rada (*tablica 41.*), a oni su:

1. *Broj naleta*
   Analiza broja naleta vozila na divljač na državnim cestama Ličko-senjske županije provedena je prema podacima Ministarstva unutarnjih poslova, Policijske uprave Ličko-senjske za razdoblje 2012. - 2016. godine [106]. O svakoj prometnoj nesreći korišteni su sljedeći podaci: datum nastanka prometne nesreće, vrijeme nastanka prometne nesreće, vrsta, broj i dionica ceste, posljedice prometne nesreće i vrsta divlje životinje.

2. *Duljina dionice (km)*
   Duljine dionica državnih cesta Ličko-senjske županije dobivene su iz Hrvatskih cesta d.o.o., poslovna jedinica Zadar, tehnička ispostava Gospić [105].

3. *Broj naleta na 100 km*
   Broj naleta na 100 km dobiven je izrazom (7):

$$N = \frac{n}{d} /5 \cdot 100 \quad (7)$$

   Gdje su:
   - N = broj naleta na 100 km
   - n = broj naleta tijekom 5 godina
   - d = duljina dionice
   - 5 = razdoblje promatranja od 5 godina.

4. *Broj naleta na 100 km godišnje.*
   Broj naleta na 100 km godišnje dobiven je izrazom (8):

$$Ng = \frac{n}{5} \quad (8)$$

   Gdje su
   - Ng = broj naleta na 100 km godišnje
   - n = broj naleta na 100 km
   - 5 = razdoblje promatranja od 5 godina.

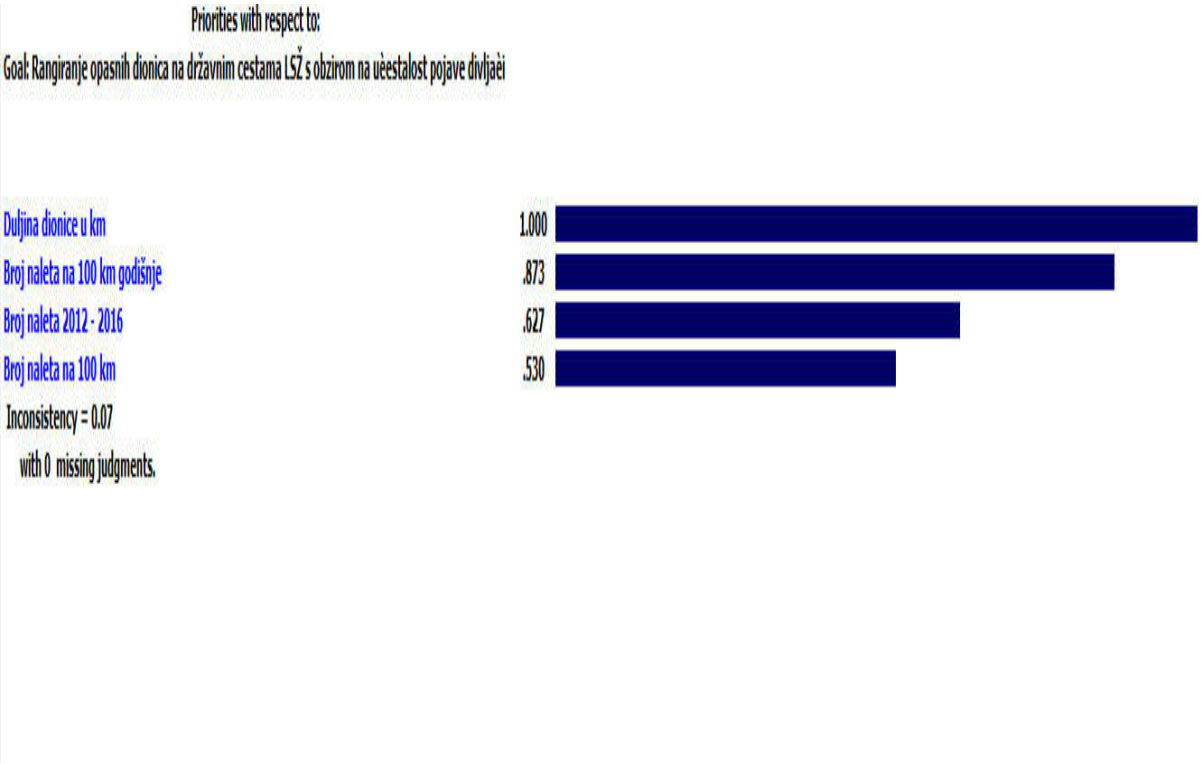
Tablica 41. Broj opasne dionice i izbor kriterija za provedbu AHP metode

BROJ OPASNE DIONICE	CESTA	DIONICA	NAZIV DIONICE	BROJ NALETA	DULJINA DIONICE (km)	BROJ NALETA NA 100 km	BROJ NALETA NA 100 km GODIŠNJE
1	DC-1	12	Grabovac (DC-42) – Vrelo Koreničko (DC-52)	39	23,00	33,91	6,78
2	DC-1	13	Vrelo Koreničko (DC-52) – Mutilić: čvorište Udbina (DC-522)	91	33,17	54,87	10,97
3	DC-1	14	Mutilić: čvorište Udbina (DC-522) – Gračac (DC-27)	26	11,58	44,91	8,98
4	DC-8	7	Senj (DC-23) – Stinica (DC-405/LC-59148)	32	36,67	17,45	3,49
5	DC-8	8	Jablanac (DC-405) – Prizna (DC-406)	2	13,00	3,08	0,62
6	DC-23	3	Jezerane (ŽC-5191) – Žuta Lokva (DC-50)	9	19,19	9,38	1,88
7	DC-23	4	Žuta Lokva (DC-50) –Senj (DC-8)	8	22,26	7,19	1,44
8	DC-25	1	Korenica (DC-1) – Lički Osik (DC-50)	9	36,57	4,92	0,98
9	DC-25	2	Lički Osik (DC-50) – Karlobag (DC-8)	7	47,26	2,96	0,59
10	DC-50	1	Žuta Lokva (DC-23) – Špilnik (DC-52)	27	21,47	25,15	5,03
11	DC-50	2	Špilnik (DC-52) – Lički Osik (DC-25)	8	34,37	4,66	0,93
12	DC-50	3	Gospić (DC-25) – Lovinac (ŽC-5165)	27	31,99	16,88	3,38
13	DC-50	4	Lovinac (ŽC-5165) – Gračac (DC-27)	12	15,19	15,80	3,16
14	DC-52	1	Špilnik (DC-50) - Korenica (DC-1)	31	41,11	15,08	3,02
15	DC-217	1	Ličko Petrovo Selo (DC-1) – Novo Selo Koreničko: GP Ličko Petrovo Selo (granica RH/BIH)	14	2,97	94,28	18,86
16	DC-218	1	Nebljusi: GP Užljebić (Granica RH/BIH) – Dobroselo (ŽC-5203)	14	30,08	9,31	1,86
17	DC-218	2	Dobroselo (ŽC-5203) – Bruvno (DC-1)	1	8,70	2,30	0,46
18	DC-429	1	Selište Drežničko (DC-42) – Prijeboj (DC-1)	12	14,1	17,02	3,4
19	DC-522	1	Mutilić (DC-1) – Gornja Ploča: čvor Gornja Ploča (A1)	21	13,19	31,84	6,37
20	DC-534	1	Gospić (DC-25) –Lički Osik: čvorište Gospić (A1)	1	2,45	8,16	1,63

Prije korištenja softerskog alata Expert Choice [153] zadan je cilj, a on je rangirati opasne dionice na državnim cestama Ličko-senjske županije od pojave divljači. Napravljene su odgovarajuće matrice usporedbe kriterija svaki sa svakim u odnosu na zadani cilj te su na osnovu toga dodane vrijednosti iz Saaty-jeve ljestvice vrednovanja [152]. Program zahtjeva zadavanje varijanti, a one su više opasnih dionica.

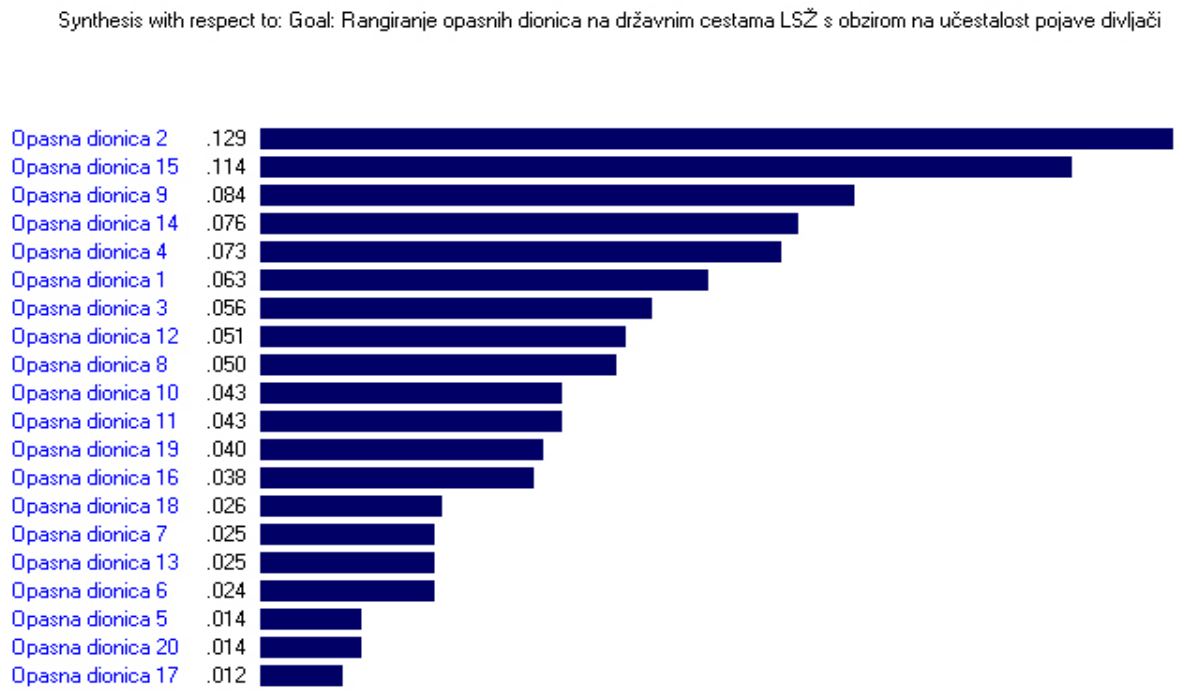
Uspoređivanje kriterija je napravljeno dodjeljivanjem relativnih težina pojedinom kriteriju, a ponderi su utvrđeni ekspertnom ocijenom. Od 4 kriterija (broj naleta, duljina dionice u kilometrima, broj naleta na 100 kilometara i broj naleta na 100 kilometara godišnje),

ekspertnom ocjenom, najutjecajniji kriterij, odnosno kriterij s najvećom težinskom vrijednošću bio je kriterij duljina dionice u kilometrima (*grafikon 24.*), iza njega po težinskoj vrijednosti dolazi kriterij broj naleta na 100 kilometra godišnje, pa kriterij broj naleta 2012. -2016., i posljednji kriterij po težinskoj vrijednosti je kriterij broj naleta na 100 kilometara.

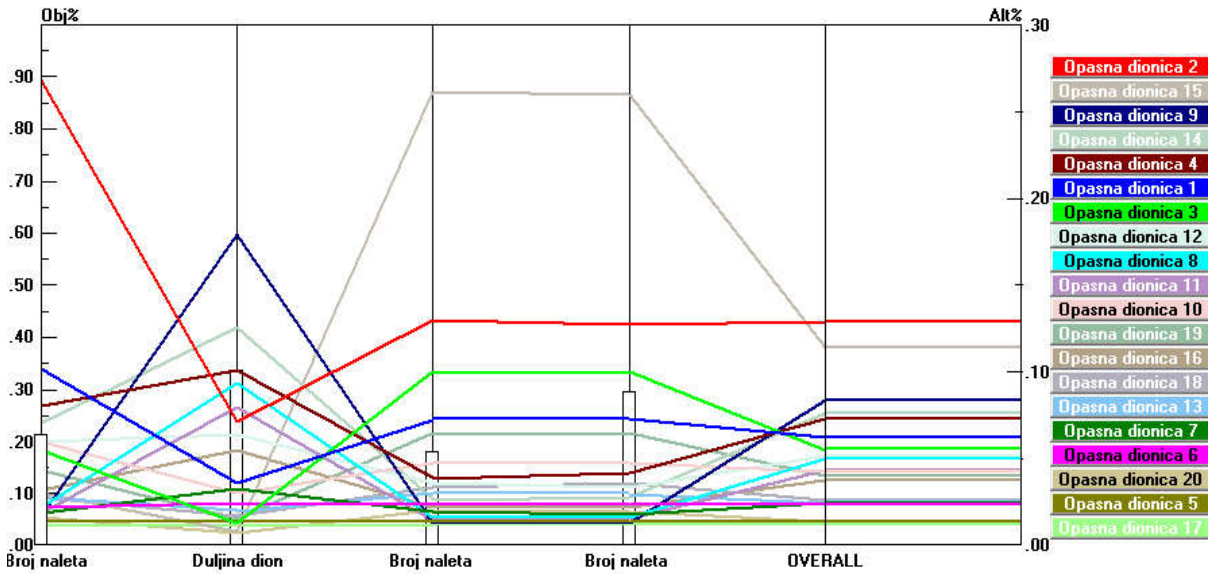


Grafikon 24. Težinske vrijednosti kriterija

Na *grafikonu 25.* dat je prikaz rangiranja ponuđenih varijanti (opasnih dionica) s postotkom. Vidljivo je da je najopasnija dionica, dionica 2, a iza nje slijedi dionica 15, dok je najsigurnija dionica 17. Na *grafikonu 26.* prikazan je utjecaj pojedinih kriterija na varijante te je prikazan i njihov konačni prioritet.



Grafikon 25. Rangiranje opasnih dionica od najmanje opasne do najopasnije dionice od pojave divljači na državnim cestama Ličko-senjske županije



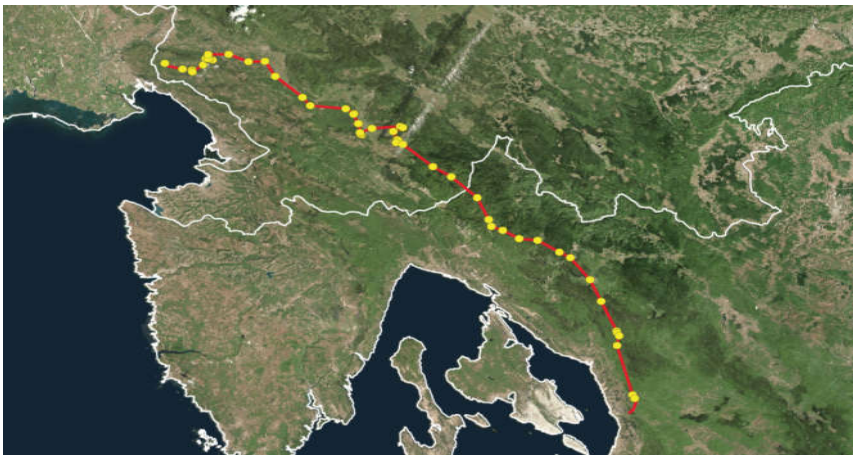
Grafion 26. Utjecaj kriterija na varijante

Višekriterijsko vrednovanje AHP metodom daje dobar uvid u rangiranje opasnih dionica od pojave divljači na državnim cestama Ličko-senjske županije. U doktorskom radu dobiven je egzaktan odabir prioriteta sanacije opasnih dionica od pojave divljači, koji može upraviteljima cestovne infrastrukture signalizirati prioritete sanacije opasnih dionica.

4. MJERE SPRJEČAVANJA ILI UBLAŽAVANJA NALETA VOZILA NA DIVLJAČ

Divljač u svojoj dnevnoj i sezonskoj migraciji prelazi ceste svih kategorija od lokalnih cesta do autocesta. Tipičan primjer migracije divljači je čagalj uhvaćen u Sloveniji 19. studenog 2018. godine na području Krasa uz talijansku granicu južno od Nove Gorice. Čagljevi su poznati kao vrsta divljači kod koje mlade životinje mogu migrirati na velike udaljenosti, ali su do sada izvori podataka o migraciji bili indirektni primjeri pojavljivanja pojedinačnih jedinki daleko izvan poznate raširenosti populacije za koje se nije znalo od kuda i kako su došle na nova područja. Suprotno tome, direktne informacije o disperziji pojedinih vrsta divljači izvan teritorija rođenja do sada nisu bile poznate. Uhvaćeni čagalj obilježen je GPS ogrlicom i pušten na slobodu, sa ciljem preciznog praćenja disperzije ove vrste divljači. Prema procjeni stručnjaka radilo se o jednogodišnjem mužjaku [203].

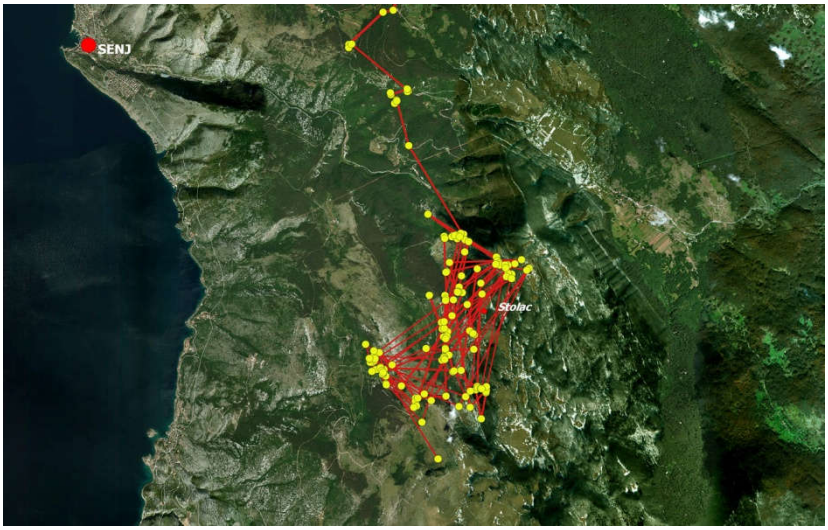
Mladi mužjak je bio član čopora i tri se mjeseca zadržavao na roditeljskom teritoriju veličine cca. 500 hektara. Dana, 21. veljače 2019. godine čagalj napušta roditeljski teritorij i skoro u „ravnoj crti“ kreće prema jugoistoku (*slika 16.*). Pri tome je svaki dan prelazio 15 000 do 30 000 m, a kretao se šumskim područjima Snežnika u Sloveniji i Gorskog kotara u Hrvatskoj. Nije imao nikakvih poteškoća prijeći ograđene autoceste Ljubljana - Koper i Zagreb - Rijeka (kod Delnica) ali i ostale ceste, te je istim tempom nastavio prema planinskim masivima Velika kapela i Velebit u Ličko-senjskoj županiji. Dana 1. ožujka 2019. godine čagalj je na širem području Čabra ušao u Hrvatsku, da bi do 7. ožujka 2019. godine stigao u zaleđe Senja na prijelaz Vratnik u Ličko-senjskoj županiji.



Slika 16. Kretanje čaglja između 21. veljače i 7. ožujka 2019.

Izvor: [203]

Do 15. travnja 2019. godine čagalj je zauzeo teritorij iznad Senja (*slika 17.*), a iz slike je vidljivo da je promatrana divljač puno puta prelazila ceste u Ličko-senjskoj županiji.



Slika 17. Kretanje čaglja do 15. travnja 2019. godine.

Izvor: [203]

Iz navedenog primjera vidljivo je da određene vrste divljači imaju veliki radijus kretanja i da pri tome prelaze ceste, te time direktno ugrožavaju sigurnost prometa.

Da bi se spriječila pojava divljači na cestama, potrebno je kroz mjere održavanja cesta spriječiti divljač da izađe na cestu. Za sada se za ublažavanje ili spriječavanje naleta vozila na divljač na cestama Ličko-senjske županije (zbog izrade ovoga doktorskog rada) provodi nekoliko mjera održavanja cesta, a provode ih pravne osobe koje gospodare javnim cestama Ličko-senjske županije, Hrvatske ceste d.o.o. (HC), ispostava Gospić, Županijske uprave za ceste Ličko-senjske županije (ŽUC) i izvođač radova društvo kapitala Lika ceste d.o.o. iz Gospića. One obuhvaćaju razne radnje vezane od praćenja pojave i intenziteta prijelaza pojedinih mjesta na cestama po vrstama divlje životinje do postavljanja uređaja kojima se pokušava odvratiti divljač od prijelaza ili ukazati vozaču kako je opasnost od naleta na divlju životinju na određenoj dionici visoka.

Detaljnom analizom modela prepoznavanja te uočavanjem opasnih dionica otkrivaju se nedostaci opreme ceste, koji nastanak naleta vozila na divljač čine vjerojatnim. Otklanjanjem ili saniranjem nedostataka na takvim dionicama u većini slučajeva broj naleta vozila na divljač se drastično smanjuje ili se naleti više ne događaju. Uz mjere održavanja cesta koje se provode s ciljem sprječavanja izlaska divljači na ceste, na javnim cestama Ličko-senjske županije (postavljanje zaštitnih žičanih ograda uz cestu, detaljno čišćenje zaštitnog

cestovnog pojasa, postavljanje optičkih i zvučnih senzora na smjerokazne stupiće i postavljanje adekvatnih prometnih znakova) u doktorskom radu ispitane su i mjere sadnje biljnih vrsta uz cestu koje odbijaju divljač i utjecaj lokacije hranilišta divljači na gustoću populacije divljači uz cestu.

4.1. Praćenje frekvencije prelaza divljači pomoću kamera („foto zamki“)

Pomoću lovačkih kamera na odabranim dionicama ispitane su mjere održavanja cesta koje trebaju spriječiti pojavu divljači na cestama. Kako bi se ispitao utjecaj pojedinih mjera održavanja cesta na pojavu divljači na cestama, lovačke kamere su postavljene upravo na dionicama na kojima su provedene navedene mjere. Razvojem digitalne tehnologije na tržištu su se pojavile digitalne kamere specijalizirane za snimanje divljači u mirovanju i pokretu. Neke od postavljenih lovačkih kamera su marke ScoutGuard (*slika 18.),* Minox (*slika 19.),* i SpyPoint (*slika 20.).*

Kamera ScoutGuard je pouzdana i koristi se diljem svijeta. Kamera ima podršku za slanje slika e-poštom, rezolucija fotografija je 14 megapiksela, raspon dekora pokreta je 25 m. Kamera ima ugrađeni nevidljivi IR flash, također kamera ima mogućnost snimanja videa i zvuka, radi na solarnim baterijama i podržava 32 GB SD memorijsku karticu.

Lovačka kamera Mindox dtc 600 ima čvrsto plastično kućište koje je otporno na hladnoću, toplinu i vodu. Kamera ima rezoluciju od 8 megapiksela i veliku brzinu okidanja. Kamera ima ugrađenu IR bljeskalicu i može slikati na udaljenosti do 15 m. Kamera može slikati do 3 slike u nizu i snimati 30 sekundi video zapisa.

Lovačka kamera kanadske tvrtke SpyPoint kombinacija je 12 megapikselne kamere s bežičnim prijemnikom. Kamera odašilja kvalitetne slike tijekom dana te oštre crno bijele slike tijekom noći. Kamera na slikama prikazuje datum, vrijeme, temperaturu i faze mjeseca. Detekcija snimanja je do 25 metara. Duljina videozapisa kamere je 10 - 90 sekundi. Kamera koristi SD karticu od 32 GB. Dimenzije kamere su 11,2 x 13,2 x 8,3 centimetara.

Sve kamere su postavljene na obližnje drveće u visini od 1 m, fokusirane da snimaju ponašanje divljači na dionicama na kojima je napravljena mjera održavanja cesta koja bi spriječila izlazak divljači na opasnu dionicu te da snimaju ponašanje divljači na lokalitetu hranilišta.



Slika 18. Lovačka nadzorna kamera marke ScoutGuard
Izvor: [204]



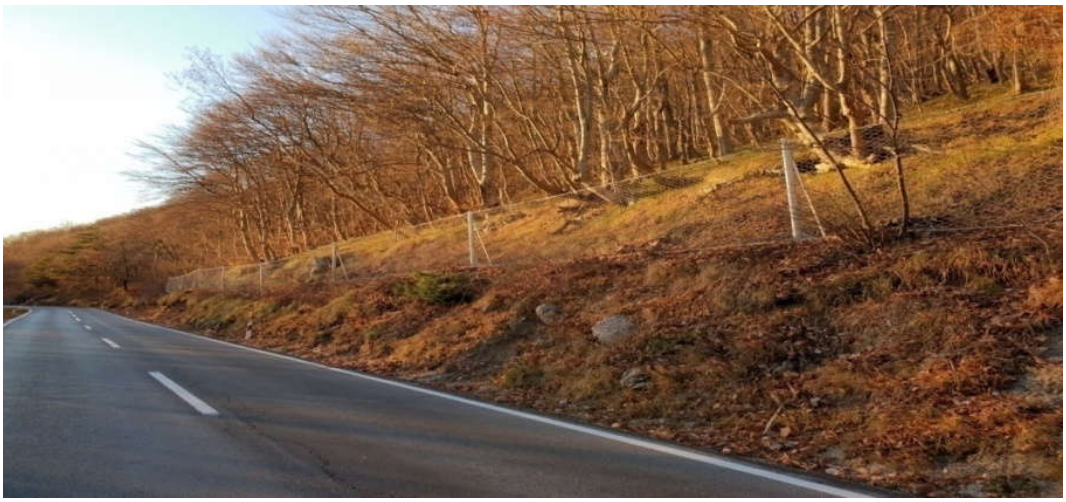
Slika 19. Lovačka nadzorna kamera marke Minox
Izvor: [205]



Slika 20. Lovačka nadzorna kamera marke SpyPoint
Izvor: [206]

4.2. Postavljanje zaštitnih žičanih ograda uz cestu

Svrha postavljanja zaštitnih ograda na određenim dionicama cesta je sprječavanje izlaska divljači na cestu. Postavljanje žičanih ograda iziskuje dosta veliki trošak, ali na dulje vrijeme, s aspekta sigurnosti prometa neupitna je isplativost takve investicije. Jedna od takvih zaštitnih žičanih ograda postavljena je u suradnji s HC ispostava Gospić i Lika cestama d.o.o iz Gospića na rizičnoj lokaciji iznad Senja, na državnoj cesti D-23, (*slika 21.).*



Slika 21. Postavljena zaštitna žičana ograda

Ograda se pokazala kao dobra mjera sprječavanja izlaska divljači na cestu, osim u slučaju zvijeri (medvjed, vuk, čagalj, lisica) koje bi s vremenom, kada bi se navikle, bez problema prešle preko ograde. Ovu tezu potvrđivaju i autori u [51]. Kamere su postavljene u blizini postavljene zaštitne žičane ograde na uočenim pravcima kretanja divljači prema cesti. U promatranom razdoblju postavljene kamere zabilježile su 6 fotografija divljači koja se kretala prema cesti i došla je do postavljene zaštitne ograde. Nakon što je uočila prepreku divljač se okrenula i vratila istim putem od kuda je i došla (*slike 22.-27.)*, odnosno divljač nije prešla cestu. Kamere na navedenoj lokaciji su postavljene od 1. travnja 2019. godine do 1. lipnja 2019. godine. Zadnja poslikana divljač na navedenoj lokaciji bila je 14. svibnja 2019. godine, što se može protumačiti da je divljač zbog prepreke promijenila rutu kretanja.

Međutim, iako je ogradama moguće smanjiti broj naleta na određenoj dionici ceste čak do 80 %, to se smanjenje uglavnom odnosi na parnoprstaše jer za zvijeri one ne predstavljaju ozbiljniju prepreku [51]. Naime zvijeri se mogu penjati preko ograde, preskočiti je ili je potkopati.



Slika 22. Medvjed se vraća od zaštitne žičane ograde



Slika 23. Lisica se vraća od zaštitne žičane ograde



Slika 24. Medvjed se vraća od zaštitne žičane ograde 1



Slika 25. Medvjed se vraća od zaštitne žičane ograde 2



Slika 26. Divlje svinje se vraćaju od zaštitne žičane ograde



Slika 27. Medvjed se vraća od zaštitne žičane ograde 3

4.3. Detaljno čišćenje zaštitnog cestovnog pojasa

Ova je mjera provedena na uočenoj opasnoj dionici bivše županijske ceste ŽC-5126 (danas gradska cesta), dionica 1, na lokalitetu „Krpanovo brdo“. Čišćenje zaštitnog cestovnog pojasa su obavili djelatnici firme Lika ceste d.o.o. iz Gospića, koji su očistili cestovni pojas na dva opasna mjesta na jednoj dionici ceste (*slike 28.,29.).* Očišćena mjesta na dionici ceste su duljine do 300 m.



Slika 28. Očišćeni zaštitni cestovni pojas na ŽC 5126, prvo opasno mjesto



Slika 29. Očišćeni zaštitni cestovni pojas na ŽC 5126, drugo opasno mjesto

Pregledavajući snimke postavljenih nadzornih kamera pokazalo se da divljač dođe do očišćenog zaštitnog cestovnog pojasa, ali preko njega ne prelazi jer na njemu nema prirodnog

zaklona (*slike 30.-33.).* Nadzorne kamere na navedenoj lokaciji bile su postavljene od 1. travnja 2019. godine do 20. kolovoza 2019. godine.



Slika 30. Divlja svinja na rubu očišćenog zaštitnog cestovnog pojasa



Slika 31. Medvjed na rubu očišćenog zaštitnog cestovnog pojasa 1



Slika 32. Srna na rubu očišćenog zaštitnog cestovnog pojasa



Slika 33. Medvjed na rubu očišćenog zaštitnog cestovnog pojasa 2

Međutim samo kilometar dalje, na istoj dionici, na mjestu na kojem nije očišćen cestovni pojas divljač je počela prelaziti cestu, i to na mjestu dionice na kome do tada nije zabilježen niti jedan nalet vozila na divljač. Uskoro se na neočišćenom mjestu dionice dogodio i prvi nalet vozila na divljač (*slika 34.).*



Slika 34. Nalet vozila na divljač na mjestu dionice gdje nije očišćen cestovni pojas

4.4. Postavljanje optičkih i zvučnih senzora na smjerokazne stupiće

Optički i zvučni senzori postavljaju se na smjerokazne stupiće (*slike 35. i 38.*). Postavljanje je jednostavno i to pomoću dva vijka. Senzori su aktivni samo kada se vozilo približava njima i to s upaljenim farovima. Svjetlost farova automobila kreira optičku ili zvučnu „zaštitnu zavjesu“ u pojasu ceste. Kretanjem vozila cestom u sumrak ili noću, obasjavanjem svjetlosnog snopa vozila na reflektore, reflektira se svjetlost u smjeru divljači, koja namjerava preći cestu. Stvara se vizualna ograda - prepreka, odnosno upozorava divljač na opasnost i time spriječava da divljač izlazi na cestu. Ukoliko se reflektori postavljaju na svakom smjerokaznom stupiću u nizu, automobili koji prolaze uzrokuju istovremeno bljesak nekoliko uzastopnih reflektora. Kada prođe vozilo „zaštitna svjetlosna zavjesa“ se deaktivira i divljač može dalje nesmetano preći cestu.



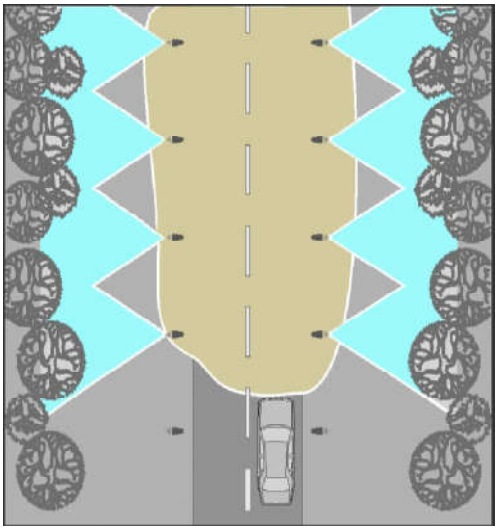
Slika 35. Visina postavljanja senzora na smjerokazni stupić

Izvor : [207]



Slika 36. Optički senzor

Izvor : [207]



Slika 37. Osvjetljavanje cestovnog pojasa pomoću optičkih senzora

Izvor : [207]



Slika 38. Optički senzor na smjerokaznom stupiću

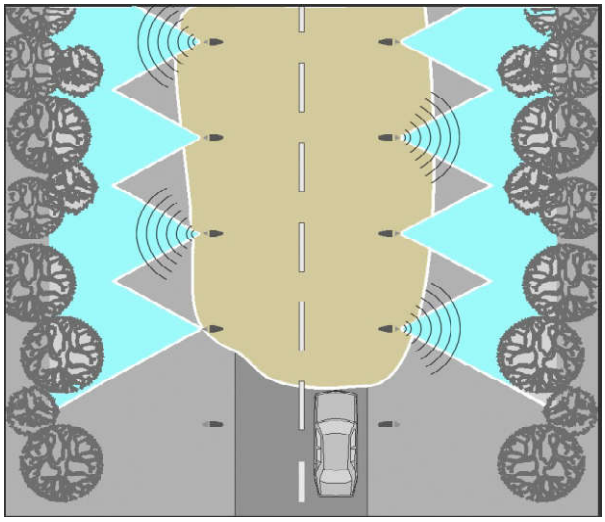
Prednosti optičkih senzora su niski troškovi instaliranja, omogućavanje migracije divljači, dugi vijek trajanja, niski troškovi održavanja te značajno smanjuju učestalost naleta vozila na divljač u vremenskom periodu od sumraka do svitanja. Nedostatci ovakvog uređaja su smetnje optičkih zapreka kao što su živice, grmlje, trava.

Zvučni senzor je uređaj koji se također postavlja na smjerokazni stupić. Svjetla vozila koje se približava smjerokaznom stupiću aktiviraju zvučni signal frekvencije od 2 do 5 kHz. Uređaj ima 5 različitih alternativnih zvukova koji se povremeno izmjenjuju (*slika 40.).* Uređaj može biti aktiviran iz oba smjera vožnje automobila [207].



Slika 39. Zvučni senzor

Izvor : [207]



Slika 40. Ozvučivanje cestovnog pojasa pomoću zvučnih senzora

Izvor : [207]



Slika 41. Zvučni senzor na smjerokaznom stupiću

Kod ovoga uređaja najveća je prednost što nije osjetljiv na prepreke kao što su živice i grmlja, ali je cijena ovakvog uređaja znatno skuplja od optičkog senzora.

Pregledavajući snimke postavljenih kamera pokazalo se da divljač dolazi do ceste, međutim nailaskom automobila i raspršivanjem svjetlosnog snopa i zvučnog signala divljač se zastrašuje i vraća se nazad u zaklon (*slike 42.-46.).*



Slika 42. Vuk fotografiran u blizini optičkog senzora uz cestu



Slika 43. Divlja svinja fotografirana u blizini optičkog senzora uz cestu



Slika 44. Srna fotografirana u blizini zvučnog senzora uz cestu



Slika 45. Jelen fotografiran u blizini optičkog senzora uz cestu



Slika 46. Medvjed fotografiran u blizini zvučnog senzora uz cestu

4.5. Postavljanje adekvatnih prometnih znakova - divljač na cesti

Osnovna uloga postavljanja prometnih znakova je promicanje sigurnosti na cestama. Prometni znak treba biti vidljiv i postavljen na pravilan način. Prometni znak treba omogućiti učinkovito vođenje prometa te mora dati potrebne obavijesti sudionicima u prometu. Postavljanje adekvatnih prometnih znakova zbog mogućnosti pojave divljači na cestama na određenim dionicama ima za cilj upozoriti vozače na mogućnost naleta vozila na divljač. Prometni znakovi ove vrste obavezno moraju biti postavljeni da ih vozači lako uočavaju danju i noću.

Prometni znak „divljač na cesti“ (A44) označuje posebno opasna mjesta na kojima divljač često prelazi preko ceste. Simbol na znaku može biti različit (*slika 47. i 48.),* ovisno o vrsti divljači na koju se znak odnosi, ali je uglavnom na znaku nacrtan jelen.



Slika 47. Znak „divljač na cesti“ sa simbolom divlje svinje



Slika 48. Znak „divljač na cesti“ na DC-50 sa dopunskom pločom

Praksa je da se prometni znakovi postavljaju s dopunskim pločama. Dopunska ploča označuje duljinu dijela ceste na kojem prijeti opasnost označena znakom. Uglavnom su to dionice veće duljine koje su označene na dopunskoj ploči (*slika 48*.), što vozači uoče i vrlo brzo zaborave na iskazanu opasnu dionicu od pojave divljači.

Na dionici državne ceste DC-50, koja se modelom pokazala kao opasna od pojave divljači postavljeni su znakovi „divljač na cesti“ s dopunskom pločom od 300 m. Odnosno na opasnoj dionici od 900 m postavljena su 3 prometna znaka „divljač na cesti“ s dopunskim pločama kako prijeti opasnost na udaljenosti od 300 m od postavljenog znaka. Pokazalo se da vozači znatno sporije voze kroz opasnu dionicu, a daljnjom analizom utvrđeno je da se na promatranoj dionici, u promatranom razdoblju, nije dogodio niti jedan nalet vozila na divljač.

4.6. Sadnja biljnih vrsta uz cestu koje odbijaju divljač

U svrhu smanjivanja naleta vozila na divljač, načinom sadnje biljnih vrsta koje odbijaju divljač svakako treba koristiti i iskustva drugih zemalja. Tako je sa ciljem udaljavanja divljači od cesta načinjen rang palatabilnosti (jestivosti) pojedinih biljnih vrsta za divljač, želeći odvojiti one nepalatabilne [208]. U istraživanju u ograđenom prostoru s jelenom lopatarom, jelenom običnim, muflonom, sika jelenom i srnom običnom, uočeno je da divljač nije konzumirala bujad *(Pteridium aquilinum)*, šumsku paprat *(Dryopteris filix-mas)*, običnu koprivu *(Urtica dioica)* i grimizni naprstak *(Digitalis purpurea)*. Međutim, ako biljke nisu palatabilne to ne znači da će žitovinje izbjegavati takva područja. Ona mogu služiti i kao izvrstan zaklon, što je potvrđeno ovim doktorskim radom, jer na nekim dionicama vjerojatnost naleta raste s udjelom vriština i bujadnica u ćeliji.

Terenskim istraživanjem, usporedbom i lociranjem naleta vozila na divljač iz [106] uočeno je da se na mjestima gdje su samonikle biljne vrste koje divljač ne konzumira nisu događali naleti vozila na divljač - biljojede. S tim u vezi predlaže se da se ove i ostale nepalatabilne vrste sade uz rubove cesta kako bi se iz pojasa cesta udaljila divljač i time smanjilo izlazak divljači na ceste.

Mjera odbijanja divljači od cesta svakako djeluje na biljojede, dok na životinje mesojede ova mjera nema nikakvog učinka.

4.7. Utjecaj lokacije hranilišta divljači na gustoću populacije divljači uz ceste

Lovci mogu dosta utjecati na raspored divljači u prostoru. Tipičan primjer za to su hranilišta i pojilišta, odnosno njihov raspored u lovištu. Ovo je i dokazano modelima u doktorskom radu. Lovačke kamere za praćenje divljači postavljene su na hranilištu, u državnom otvorenom lovištu IX/1 „Antinovica“ kojim gospodari Lovačko društvo „Tetrijeb“ Pazarište. Kamere su snimale lokaciju hranilišta u vremenskom razdoblju od 1. rujna 2018. godine do 1. lipnja 2019. godine.

Naredbom o smanjenju pojedine vrste divljači [209], kojom se zabranila prihrana divljih svinja, divljač više nije prihranjivana, ali su kamere na hranilištu i dalje bile aktivne. Pregledavajući snimke kamera pokazalo se da je u promatranom vremenskom periodu od divljači na hranilištu uslikana srna, divlja mačka, lisica, divlje svinje i medvjed (*slike 49.-56.)*



Slika 49. Srna na hranilištu



Slika 50. Divlja mačka na hranilištu



Slika 51. Divlje svinje na hranilištu 1



Slika 52. Lisica na hranilištu



Slika 53. Divlje svinje na hranilištu 2



Slika 54. Divlje svinje na hranilištu 3



Slika 55. Medvjed na hranilištu



Slika 56. Divlje svinje na hranilištu 4

Uočavajući da se sve divlje životinje, odnosno preživači, predatori i svežderi zadržavaju, odnosno njihovo stanište je u blizini hranilišta pokazalo se da lokalitet hranilišta značajno utječe na brojno stanje divljači oko hranilišta. Prestankom aktivnog hranjenja divljači, slijedom stupanja na snagu Naredbe o smanjenju pojedine vrste divljači [209] gdje se dozvoljava samo minimalna prihrana, divljač se, mada nije bilo hrane na hranilištu i dalje zadržavala u blizini hranilišta (*slika 56.*). Razlog tomu je što je divljač „naučena“ na lokaciju gdje joj je hrana.

Slijedom navedenog, lovačka društva bi hranilišta za divljač trebala postavljati dalje od cesta. Točna udaljenost vjerojatno ovisi o lokaciji najbliže ceste i hranilišta, što bi svakako trebalo biti predmetom istraživanja, radi učinkovitosti zaštite životinja i ljudi.

5. POSTUPAK ODRŽAVANJA JAVNIH CESTA U PODRUČJU OPASNOSTI OD POJAVE DIVLJAČI

Izgradnja prometne infrastrukture stagnira, a prioritetni zadatak postaje gospodarenje postojećim prometnicama radi postizanja dostatne sigurnosti prometa. Planiranje gospodarenja cestovnom infrastrukturom uključuje ocjenu stanja cesta, odlučivanje o prioritetima održavanja i niz drugih aktivnosti koje su usmjerene na podizanje razine prometovanja i sigurnosti prometa na cestama.

Odlukom o razvrstavanju javnih cesta [210] propisano je koji pravni subjekti gospodare određenom kategorijom cesta u prometnoj mreži. Aktivnosti koje propisuju zakoni su obvezujuće za subjekte koji gospodare javnim cestama. Pravni subjekti koji gospodare javnim cestama imaju ovlasti prenijeti radove na drugi subjekt, a obično su to društva kapitala, njih 14 u Republici Hrvatskoj.

Na temelju Zakona o javnoj nabavi [211] pravne osobe koje gospodare javnim cestama provode otvoreni postupak javne nabave za četverogodišnje održavanje javnih cesta kojima oni upravljaju. Ugovaratelji radova (društva kapitala) radove su obavezni izvoditi sukladno zakonima, propisima i standardima koji se odnose na izgradnju i održavanje cesta.

Količine radova potpisanog Okvirnog sporazuma održavanja i zaštite državnih cesta (OS) [212] za četverogodišnje održavanje cesta su predviđene, okvirne. Stvarno odrađene količine radova mogu biti manje ili veće od predviđenih. Obračun radova obavlja se prema stvarno izvedenim radovima, ovjeren od strane ovlaštenog inženjera pravne osobe koja gospodari javnom cestom, na temelju mjesečnog obračuna i ispostavljenog računa.

Troškovnik radova sastoji se od 11 grupa radova, a to su:

1. nadziranje i pregled cesta i objekata
2. održavanje kolnika
3. održavanje bankine i berme
4. održavanje usjeka, zasjeka i nasipa
5. održavanje objekata za odvodnju
6. održavanje opreme ceste
7. košnja trave i održavanje zelenila

8. održavanje objekata
9. sustavi, instalacije, uređaji i oprema na cestama i objektima
10. održavanje cesta i objekata u zimskim uvjetima
11. ostali radovi, troškovi i usluge.

Svaka grupa radova ima opis svoje podgrupe s opisom samih radova, jedinicom mjere, količinom i jediničnom cijenom. Za provedbu godišnjeg plana održavanja pravni subjekti izrađuju operativni program radova održavanja cesta. Posebno za ljetno i posebno za zimsko razdoblje. Operativnim programom radova određuju se potrebna financijska sredstva, materijali, količina i vrsta radova te rokovi izvršenja radova [213].

5.1. Prijedlog postupka održavanja javnih cesta u području opasnosti od pojave divljači

Na temelju predloženog modela prepoznavanja opasnih dionica na javnim cestama u području učestale pojave divljači i na temelju ispitivanja pojedinih mjera održavanja cesta na pojavu divljači, pokazalo se da se kroz postupak održavanja javnih cesta može značajno spriječiti pojava divljači na cestama. Analizirajući trenutno stanje raspoloživosti podataka o naletima vozila na divljač, svakako je i jedan od načina spriječavanja pojave divljači na cestama povećanje sati ophodarske službe na rizičnim dionicama. Daljnji prijedlog je da se u troškovnik radova redovnog održavanja cesta stave slijedeće stavke redovnog održavanja s njihovim opisom i jediničnom cijenom izvođenja:

1. postavljanje zaštitnih ograda radi sprječavanja pojave divljači na cesti
2. čišćenje punog profila cestovnog zaštitnog pojasa radi smanjenja pojave divljači na cestama
3. sadnja biljnih vrsta uz cestu koje odbijaju divljač
4. Postavljanje na smjerokazne stupiće optičkih i zvučnih senzora koji tjeraju divljač.

Također prijedlog doktorskog rada je da se izmjeni Pravilnik o prometnim znakovima, signalizaciji i opremi na cesti na način da se ograniči označavanje duljine na dopunskoj ploči ispod prometnog znaka i da se na rizičnim dionicama od pojave divljači postavljaju elektronički znakovi „divljač na cesti“.

Navedene stavke održavanja javnih cesta trebaju ući u Okvirni sporazum održavanja i zaštite cesta, Operativni program i godišnje planove održavanja javnih cesta.

5.1.1. Povećanje sati ophodarske službe na rizičnim dionicama

Planom ophodnje [214] pravne osobe koje gospodare javnim cestama uspostavljaju ophodnju cesta. Ophodnja državnih cesta obavlja se prvenstveno radi nadziranja prohodnosti i uporabivosti cesta za siguran promet te osiguranja iznenadno nastalog izvora opasnosti na javnoj cesti koji se nije mogao predvidjeti. Ophodnju obavlja osoba koja je stručno osposobljena sukladno Pravilniku o ophodnji javnih cesta [215]. Ophodnja cesta se obavlja ophodarskim vozilima opremljenim sukladno Pravilniku o ophodnji javnih cesta [215].

Ophodnja državnih cesta uspostavlja se na:

- cestama (dionicama) gdje je PGDP veći od 4 000 vozila na dan
- cestama (dionicama) po posebnoj odluci Hrvatskih cesta d.o.o.
- cestama (dionicama) gdje je PLDP veći od 4 000 vozila na dan
- cestama (dionicama) na kojima dolazi do bitnog povećanja prometa u tzv. izvanljetnom razdoblju.

Planom ophodnje državnih cesta [214] nadzire se:

- stalnom ophodnjom obuhvaćeno je 286,570 km državnih cesta u Ličko-senjskoj županiji ili 53,04 % državnih cesta
- redovnim pregledom (dva puta tjedno) obuhvaćeno je 27,085 km državnih cesta u Ličko-senjskoj županiji ili 5,02 % državnih cesta
- programom redovnih pregleda (jednom tjedno) obuhvaćeno je 226,602 km državnih cesta u Ličko-senjskoj županiji ili 41,94 % državnih cesta
- dodatnim planom ophodnje obuhvaćeno je 120,433 km državnih cesta u Ličko-senjskoj županiji ili 22,29 % državnih cesta.

Vezano uz problematiku pojave divljači na državnim cestama Ličko-senjske županije prijedlog je da se povećaju sati ophodarske službe. Prijedlog je da povećanom ophodnjom budu zastupljene sve dionice koje su se modelom pokazale kao rizične od pojave divljači na njima. Također, prijedlog je da se prilikom osposobljavljanja ophodara posebna pažnja posveti uočavanju rizičnih dionica od pojave divljači te da se te kritične dionice od pojave

divljači na cestama zabilježe u bazu podataka upravljača cesta koji bi ih sanirali kroz mjere redovnog održavanja cesta.

5.1.2. Postavljanje zaštitnih ograda radi sprječavanja pojave divljači na cesti

U 4. grupi (održavanje, usjeka, zasjeka i nasipa) troškovnika redovitog održavanja i zaštite državnih cesta, Okvirnog sporazuma održavanja i zaštite državnih cesta [212] ima 14 podgrupa s opisom samih radova, jedinicom mjere, količinom i jediničnom cijenom. Podgrupe radova su:

1. ručno čišćenje usjeka, zasjeka i nasipa od otpada
2. ručno uklanjanje nestabilnog materijala i vegetacije na mjestima visokih pokosa usjeka i zasjeka
3. uklanjanje nestabilnog materijala s pokosa, usjeka i zasjeka
4. uklanjanje materijala nakupljenih iza zaštitnih žičanih mreža
5. popravak zaštitne žičane mreže pokosa
6. popravak zaštitne žičane ograde u bermi
7. popravak manjih oštećenja dijelova trupa ceste
8. popravak manjih površina zatravljenih pokosa nasipa, zasjeka i usjeka
9. manji popravak zaštitne žičane mreže na pokosu postavljanjem nove
10. manji popravak zaštitne žičane ograde na bermi postavljanjem nove
11. dogradnja trupa ceste miješanim kamenim materijalom
12. dogradnja tamponskog sloja od kamenog materijala
13. zaštita pokosa nasipa, usjeka i zasjeka zatravljivanjem
14. hortikulturno održavanje zelenih površina cestovnog zemljišta kao npr. odmorišta, razdjelnih otoka, kružnih tokova i slično.

U troškovniku radova redovitog održavanja i zaštite državnih cesta ne postoji stavka postavljanje zaštitne ograde od divljači, a kako se terenskim istraživanjem pokazala kao učinkovita mjera, prijedlog je da se u troškovnik radova uvrsti nova podgrupa, naziva: „*Postavljanje zaštitnih ograda od pojave divljači na cesti*“.

Prijedlog opisa stavke je: *Stavka obuhvaća nabavu, dopremu i ugradnju žičanog pletiva, uključujući ostali potreban rad i materijal za njezino pričvršćivanje.*

5.1.3. Čišćenje punog profila cestovnog zaštitnog pojasa radi smanjenja pojave divljači na cestama

Temeljem Zakona o cestama [99] javne ceste imaju svoj zaštitni pojas. Zaštitni pojas mjeri se od vanjskog ruba zemljišnog pojasa tako da je širok sa svake strane:

- autoceste - 40 m
- brze ceste - 40 m
- državne ceste - 25 m
- županijske ceste - 15 m
- lokalne ceste - 10 m.

Zakonom je definirano da je zabranjeno poduzimati bilo kakve radove u zaštitnom pojasu javne ceste bez suglasnosti pravne osobe koja upravlja javnom cestom, ako bi ti radovi nanijeli štetu javnoj cesti ili ugrožavali ili ometali promet na njoj. U suglasnosti za izvođenje radova u cestovnom pojasu koju izdaje pravna osoba koja gospodari javnom cestom određuju se uvijeti za obavljanje tih radova ili radnji.

U Okvirnom sporazumu održavanja i zaštite državnih cesta [212] u troškovniku radova održavanja cesta, stavka čišćenje punog profila cestovnog zaštitnog pojasa ne postoji. Trenutno zaštitni cestovni pojas se održava na državnim cestama u širini od 2 m, a na županijskim i lokalnim cestama u širini od 1 m od ruba ceste. Iznimka je kod radova stavka 4, podstavka 4.1. - ručno čišćenje usjeka, zasjeka i nasipa od otpadaka kada se zaštitni cestovni pojas čisti u širini od 4 - 5 m od ruba ceste.

Obračun napravljenih radova izvođači radova, odnosno društva kapitala obračunavaju kroz sljedeće stavke:

- stavka 4, podstavka 4.1. - ručno čišćenje usjeka, zasjeka i nasipa od otpadaka
- stavka 4, podstavka 4.2. - ručno uklanjanje nestabilnog materijala i vegetacije na mjestima visokih pokosa usjeka i zasjeka
- stavka 7, podstavka 7.1. - ručna košnja trave

- stavka 7, podstavka 7.2. - ručno krčenje grmlja i šiblja
- stavka 7, podstavka 7.3. - strojna košnja trave na bankinama ili bermama
- stavka 7, podstavka 7.4. - strojna košnja trave na pokosu nasipa i usjeka
- stavka 7, podstavka 7.9. - strojno krčenje grmlja i šiblja mlatilicom
- stavka 8, podstavka 8.1.5. - čišćenje ostalih površina izvan kolnika.

Na dionicama cesta koje su se modelom prepoznavanja opasnih dionica na javnim cestama u području pojave divljači pokazale kao opasne, potrebno je urediti zaštitni cestovni pojas u punom profilu. Prijedlog je da se u troškovnik radova uvrsti stavka *„Čišćenje punog profila cestovnog zaštitnog pojasa zbog smanjenja pojave divljači na cestama“*.

Prijedlog opisa stavke je: *Stavka obuhvaća ručno i strojno čišćenje, te utovar i odvoz otpada na najbliži legalni deponij komunalnog otpada u Županiji.*

5.1.4. Sadnja biljnih vrsta uz cestu koje odbijaju divljač

U troškovniku radova Okvirnog sporazuma održavanja i zaštite cesta [212] nema stavke sadnja biljnih vrsta koje odbijaju divljač. Troškovnik radova redovnog održavanja i zaštite državnih cesta je predvidio u 4 grupi radova (održavanje usjeka, zasjeka i nasipa) dvije podstavke radova za hortikulturu, a one su:

1. podstavka 4.13. - zaštita pokosa nasipa, usjeka i zasjeka zatravnjivanjem (stavka obuhvaća nabavu, transport i ugradnju humusa u debljini od 10 do 15 cm i sjetvu trave)
2. podstavka 4.14. - hortikularno održavanje zelenih površina cestovnog zemljišta kao npr. odmorišta, razdjelnih otoka, kružnih tokova i slično (stavka obuhvaća okopavanje sadnica, prihranjivanje sadnica umjetnim gnojivom u doba vegetacije s prosječnim utroškom umjetnog gnojiva 45 g/m^2, te zamjena osušenih sadnica u količini od 0,02 sadnice po m^2).

Pošto su prijašnja istraživanja [208] pokazala kako određene biljne vrste odbijaju divljač, odnosno određene vrste divljači (biljojedi) ih ne koriste za prehranu, a samim time divljač mijenja lokaciju svoga staništa, prijedlog doktorskog rada je da se na opasnim dionicama od pojave divljači na cestama, na zaštitnom cestovnom pojasu, sade biljne vrste koje ne konzumira divljač.

Prijedlog je da se u troškovnik redovitog održavanja i zaštite cesta u 4 grupu radova uvrsti podstavaka „*Sadnja biljnih vrsta koje odbijaju divljač“.*

Prijedlog opisa stavke je: *Stavka obuhvaća nabavu, transport i sadnju sadnica te njihovo okopavanje i prehranjivanje do samostalnog rasta biljke.*

5.1.5. Postavljanje na smjerokazne stupiće optičkih i zvučnih senzora koji tjeraju divljač

Troškovnik radova Okvirnog sporazuma održavanja i zaštite cesta [212] vezano za smjerokazne stupiće predvidio je u 6 stavki grupe radova (održavanje opreme ceste) 4 podstavke za smjerokazne stupiće, a one su:

1. podstavka 6.1.1. - čišćenje smjerokaznog stupića (obuhvaća čišćenje odnosno pranje cijelog smjerokaznog stupića)
2. podstavka 6.1.5. - ispravljanje smjerokaznog stupića (obuhvaća ručno ispravljanje smjerokaznog stupića po vertikali i smjeru s utvrđivanjem temelja)
3. podstavka 6.1.8. - zamjena oštećenog smjerokaznog stupića (obuhvaća vađenje oštećenog smjerokaznog stupića, utovar i odvoz oštećenog smjerokaznog stupića na deponiju u nadležnoj nadcestariji na prosječnu udaljenost u županiji prema tablici Prosječne transportne udaljenosti koja je u prilogu troškovnika te nabavu, dopremu i ugradnju novog smjerokaznog stupića)
4. podstavka 6.1.10. - izrada (nabava) i ugradnja temelja smjerokaznog stupića (obuhvaća izradu ili nabavu i dopremu temelja-klasa betona C16/20 prosječne količine 0,01 m^3/kom., s ugradnjom uz prethodno uređenje temeljne jame).

Ova mjera održavanja cesta pokazala se kao vrlo dobra u sprečavanju izlaska divljači na ceste pa je stoga prijedlog da se u troškovnik redovitog održavanja i zaštite cesta u 6 grupu radova uvrsti podstavaka naziva *„Postavljanje na smjerokazne stupiće optičkih i zvučnih senzora koji tjeraju divljač“.*

Prijedlog opisa stavke je: *Stavka obuhvaća nabavu i dopremu te ugradnju optičkih i zvučnih senzora na smjerokazne stupiće.*

5.2. Izmjena Pravilnika o prometnim znakovima, signalizaciji i opremi na cesti

Pravilnikom o prometnim znakovima, signalizaciji i opremi na cestama [216] propisuje se vrsta, značenje, oblik, boja, dimenzije i postavljanje znakova, signalizacije i opreme na cestama. Prometni znakovi su :

- znakovi opasnosti
- znakovi izričitih naredbi
- znakovi obavijesti
- znakovi obavijesti za vođenje prometa
- dopunske ploče
- promjenjivi prometni znakovi.

Pravilnikom o prometnim znakovima, signalizaciji i opremi na cestama [216] propisano je da znakovi opasnosti sudionicima u prometu označuju blizinu dijela ceste ili mjesto na kojem sudionicima u prometu prijeti opasnost. Znakovi opasnosti imaju oblik istostraničnog trokuta, čija se jedna stranica nalazi u vodoravnom položaju, a vrh nasuprot njoj okrenut je prema gore, osim znakova A47 i A48 (andrijin križ) te A49 (približavanje prijelazu ceste preko željezničke pruge s branicima ili polubranicima) i A50 (približavanje prijelazu ceste preko željezničke pruge bez branika ili polubranika). Znakovi opasnosti, u pravilu, se postavljaju izvan naselja na udaljenosti 150 do 250 m ispred opasnog mjesta na cesti. Znak »divljač na cesti« (A44) (*slika 57.*) označuje posebno opasna mjesta na kojima divljač često prelazi preko ceste.



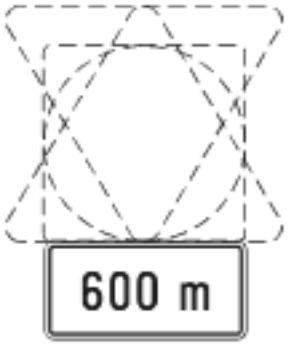
Slika 57. Znak »divljač na cesti« (A44)

Izvor : [216]

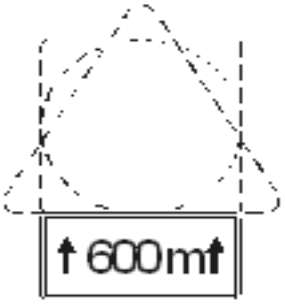
Nadalje, pravilnik [216] definira da uz znakove opasnosti, znakove izričitih naredbi i znakove obavijesti mogu biti istaknute i dopunske ploče. Dopunske ploče pobliže određuju

značenje prometnog znaka. Dopunsku ploču postavlja pravna osoba koja održava cestu ili prometna policija za vrijeme obavljanja policijskog ili sudbenog očevida. Dopunske ploče moraju se ukloniti nakon što prestanu razlozi zbog kojih su postavljene.

Dopunska ploča E01 (*slika 58.)* označuje udaljenost između znaka uz koji je postavljena dopunska ploča i početka dijela ceste, odnosno mjesta na koje se znak odnosi. Dopunska ploča E03 (*slika 59.)* označuje duljinu dijela ceste na kojem prijeti opasnost označena znakom, odnosno na kojem se primjenjuje izričita naredba označena znakom ili na koji se odnosi sadržaj znaka uz koji se ističe dopunska ploča.



Slika 58. Znak dopunska ploča, (E01)
Izvor : [216]



Slika 59. Znak dopunska ploča (E03)
Izvor : [216]

Vidljivo je da u Pravilniku o prometnim znakovima, signalizaciji i opremi na cestama [216] nigdje nije propisana maksimalna duljina dijela ceste na kojem prijeti opasnost označena znakom (dopunska ploča E03), a pokazalo se da se to vrlo često zloupotrebljava na terenu prilikom postavljanja znakova i dopunskih ploča.

Prijedlog doktorskog rada je da se usvoji Pravilnik o izmjenama i dopunama Pravilnika o prometnim znakovima, signalizaciji i opremi na cesti, na način da se stavi da dopunska ploča (E03) koja ide ispod znaka »divljač na cesti« (A44) može označavati duljinu od maksimalno 300 metara, odnosno duljinu jednog opasnog mjesta na dionici. Također je prijedlog da se u Pravilnik uvrsti da se na rizičnim dionicama od pojave divljači obavezno postavljaju elektronički znakovi „divljač na cesti“, koji bi dodatno potaknuli vozače na pažnju na određenoj dionici koja je potencijalno opasna od pojave divljači na njoj.

6. ZAKLJUČAK

Jedan od osnovnih zahtjeva prometnog sustava je sigurnost korisnika u cestovnoj prometnoj mreži, a najbolji pokazatelj sigurnosti je broj prometnih nesreća. Ubrzanim razvojem mreže prometnica te povećanjem broja vozila na cestama, sve su češći naleti divljači na vozila i vozila na divljač. Ljudski utjecaj na okoliš se mijenja i smanjuje prirodna staništa divljači. Divljač u potrazi za hranom i skloništem te u svojim dnevnim i sezonskim migracijama sve češće prilazi rubnim, urbanim područjima i pojavljuje se na cestama gdje izaziva prometne nesreće. Nesreće naleta vozila na divljač nezaustavljivo rastu iz godine u godinu. U praksi se često postavlja pitanje odgovornosti za štetu koju prouzroči divljač naletom na vozila ili vozilom na divljač. Vozač, sudionik prometne nesreće naleta vozila na divljač, osim pretrpljenog straha, a nerijetko i tjelesnih ozljeda, pretrpio je i materijalnu štetu. Kod naleta vozila na divljač oštećen je i lovoovlaštenik koji je izgubio divljač (trenutnim ugibanjem divljači na cesti ili teškim ozljedama divljači koja kasnije ugiba ili postaje lak plijen predatora). Područje naknade štete i odgovornosti uzrokovanih naletom vozila na divljač regulirano je zakonima Republike Hrvatske. Propisi kojima je regulirana ova materija posve su neusklađeni. Uglavnom se šteta ne rješava mirnim putem nego se podnosi tužba s jedne ili druge strane. Tu nastaje problem u sudskoj praksi, jer dolazi do različitih sudskih presuda.

Jedna od najopasnijih radnji je svakodnevna vožnja automobilom, a budući da nalet vozila na divljač nije moguće u potpunosti spriječiti, potrebno je preventivno djelovati na nastanak ove vrste prometne nesreće. Stoga je glavni cilj istraživanja ovoga doktorskog rada predložiti mjere kojima bi se značajno povećala sigurnost prometa i smanjio broj naleta vozila na divljač. Iz toga razloga određene su faze istraživanja važne za ostvarenje cilja istraživanja:

- odrediti na javnim cestama opasne dionice zbog pojave divljači
- izraditi model prepoznavanja opasnih dionica javnih cesta od pojave divljači
- predložiti postupak održavanja rizičnih dionica javnih cesta od pojave divljači.

Ovim doktorskim radom potvrđene su znanstvene hipoteze:

- dubinskom analizom podataka o prometnim nesrećama uzrokovanih naletom vozila na divljač određeni su elementi ceste i okoline koji ističu rizične dionice javnih cesta

- razvijen je model prepoznavanja opasnih dionica javnih cesta s obzirom na pojavu divljači.

Ličko-senjska županija ima središnji geografski položaj, a samim time i vrlo važno spojno značenje unutar Republike Hrvatske, te zauzima 9,46 % površine Republike Hrvatske. Kroz Ličko-senjsku županiju prolazi 540,257 kilometara državnih cesta, 479,970 kilometar županijskih cesta, 651,330 kilometara lokalnih cesta i dionica autoceste A1 od tunela Mala Kapela do tunela Sveti Rok u dužini od 112,80 kilometara. Veliki raspon nadmorskih visina, od mora do vrhova masiva Velebita, Velike i Male Kapele i Ličke Plješivice, čiji najvišlji grebeni prelaze i 1 000 m. n. v., te niži (ravničarski) unutarnji dio Županije definitivno ukazuje da postoje velike klimatske razlike, različitost konfiguracije terena, kao i stanišne razlike divljači, a samim time u Ličko-senjskoj županiji obitavaju gotovo sve vrste divljači Republike Hrvatske. Zbog svih navedenih specifičnosti Ličko-senjske županije, istraživanje za potrebe izrade doktorskog rada provedeno je upravo na javnim cestama Ličko-senjske županije.

Za izradu doktorskog rada, podaci o prometnim nesrećama u kojima je učestovala divljač prikupljeni su od Ministarsva unutarnjih poslova, Policijske uprave Ličko-senjske. Istraživanje je provedeno u vremenskom periodu od 5 godina (2012. - 2016.). Tijekom navedenog razdoblja obrađeno je 548 prometnih nesreća u kojima je sudjelovala divljač na javnim cestama Ličko-senjske županije. Zbog provjere točnosti podataka ankentirani su i lovozakupnici iz rizičnih područja koji su uglavnom potvrdili dobivene podatke MUP-a.

Zbog toga što se najveći broj prometnih nesreća naleta vozila na divljač u promatranom razdoblju dogodio na državnim cestama, daljnja istraživanja u doktorskom radu provedena su uglavnom na državnim cestama Ličko-senjske županije. Isto tako jer je u velikoj većini prometnih nesreća sudjelovala krupna divljač, modeli prepoznavanja opasnih dionica napravljeni su za najučestaliju stradalu divljač i to za srnu običnu i divlju svinju. Zato što kod naleta vozila na krupnu divljači postoji rizik od velike materijalne štete i fatalnog ishoda u konačnoj analizi obrazaca naleta objedinjene su sve vrste krupne divljači. U analizu krupne divljači su osim srne obične i divlje svinje uključeni i podaci o naletima na jelena te na medvjeda, muflona i sivog vuka (iako sivi vuk ne spada u kategoriju divljači).

Za potrebe istraživanja u ovom doktorskom radu, posebna pažnja posvećena je analizi vremenskih i prostornih obrazaca naleta vozila na divljač u istraživanom razdoblju.

Vremenski i prostorni obrasci jedan su od važnijih čimbenika koji su utjecali na izradu i izbor najpouzdanijeg modela prepoznavanja opasnih dionica od pojave divljači.

Analiziranje prostornih obrazaca naleta vozila na divljač je daleko složenije od vremenskih. Ono je zahtjevalo upotrebu velikog broja nezavisnih varijabli ili pretkazivača koji uključuju: značajke ceste, korištenja zemljišta, topografske varijable i značajke populacije divljači. Prostorni podaci su pripremljeni i obrađeni u programskom paketu ArcGIS 9.2. Testiranje normaliteta distribucije izvršeno je Kolmogorov-Smirnov testom i Shapiro-Wilk testom. Korelacijska analiza je načinjena klasičnom Pearsonovom korelacijom.

Za potrebe izrade modela prepoznavanja opasnih dionica od pojave divljači uzeti su elementi ceste i okoline. Kako bi se odredila najkraća duljina dionice na kojoj se može pouzdano procijeniti nalet vozila na divljač državne ceste u doktorskom radu su podijeljene na dionice od 200, 500, 1 000, 2 000 i 12 000 m. Oko središta dionica iscrtani su krugovi (ćelije) polumjera 100, 250, 500, 1 000 i 6 000 m i za svaki krug (ćeliju) određene su nezavisne varijable odnosno pretkazivači. Kao varijable značajke ceste korišteni su: prosječan godišnji dnevni promet, prosječan ljetni dnevni promet i koeficijent zavojitosti cesta. Za određivanje krajobraznih struktura u doktorskom radu korišten je udio voda, obala, goleti, vriština i bujadnica, šikara, šuma, travnjaka, izgrađenog zemljišta, zapuštenog poljoprivrednog zemljišta, oranica, udaljenost od stalnog vodotoka ili jezera te udaljenost od izvora ili lokve i ukupna duljina granica katastarskih kultura u ćeliji u odnosu na opseg ćelije. Za prikaz reljefa, kao nezavisne varijable (pretkazivača) topografskih značajki ceste, korišten je indeks topografske pozicije ili kraće TPI ili TOPEX. Teren je u doktorskom radu, s obzirom na TPI i nagib, razvrstan na šest kategorija i to: udoline, manje strmi tereni, srednje strmi tereni, izrazito strmi tereni, gornji dijelovi strmina i grebeni. Za dobivanje podataka o brojnosti divljači korišteni su podaci o odstrelu divljači (relativna odstrelna kvota, ROK) u pojedinom lovištu, ali svedeni na jedinicu lovne površine.

Osim vjerojatnosti naleta na pojedinu vrstu divljači, broj naleta godišnje po dionici je ključan čimbenik sigurnosti u prometu. Naime, vjerojatnost naleta samo ukazuje hoće li se tijekom određenog vremena i pri istim vrijednostima nezavisnih varijabli (pretkazivača) tijekom godine ili više godina dogoditi nalet ili ne. Broj naleta, dodatno daje informaciju o razini opasnosti naleta jer nije svejedno dogodi li se godišnje na određenoj dionici jedan ili više naleta. Drugim riječima vjerojatnost procjene broja naleta po dionici opasne dionice dijeli na manje opasne (manji broj naleta) i opasnije (veći broj naleta, odnosno učestaliji naleti). Stoga su u doktorskom radu korištenjem programskog paketa Akaike Information

Criterion (AIC) napravljene dvije vrste modela prepoznavanja opasnih dionica od pojave divljači i to modeli procjene vjerojatnosti naleta te modeli procjene broja naleta vozila na divljač. Modeli su napravljeni za srnu običnu, divlju svinju i krupnu divljač ukupno i to za ćelije polumjera 250, 500, 1 000 i 6 000 metara. Za polumjer ćelije od 100 metara korekcijska analiza nije pokazala povezanost između nastanka naleta i pretkazivača te za istu nije bilo moguće načiniti AIC analizu. Izbor modela uslijedio je ukoliko je $\Delta AIC < 2$ jedinice. Isto tako je određena i Akaike-ova težina (w_i), koja predstavlja vjerojatnost da je model najbolji među ostalim uspoređivanim modelima. Od svih ponuđenih modela u doktorskom radu najpouzdaniji model za prepoznavanje opasnih dionica od pojave divljači je onaj model s najnižom AIC vrijednosti. Za izračun pretkazivanja broja naleta po ćeliji korištena je klasična višestruka regresija.

Razvijenim modelima pokazalo se da broj naleta vozila na srnu običnu raste s porastom gustoće populacije srneće divljači za polumjere 250, 500 i 1 000 m, udjela zapuštenog poljoprivrednog zemljišta za dionice od 500, 1 000 i 2 000 m, udjela vriština i bujadnica na dionicama cesta od 500 i 1 000 m, udaljenosti do mogućeg pojilišta (slatka voda) na dionicama cesta od 500 i 1 000 m, prosječnog godišnjeg dnevnog prometa (PGDP) na dionicama od 500 i 12 000 m i nižom TPI (TOPEX) vrijednošću, odnosno u udolinama i manje strmim terenima, ali ovo vrijedi samo za dionice cesta veće duljine. Nadalje se pokazalo da se broj naleta vozila na srnu smanjuje s porastom zavoja na dionici - dionice od 1 000 m ili udjela cesta - dionice 2 000 m, udjela goleti - na svim dionicama, osim dionica od 12 000 m, udjela mora - na svim dionicama, osim dionica od 12 000 m i izgrađenog zemljišta na dionicama od 500 m. Veličina pouzdanosti modela procjene broja naleta na srnu običnu raste s rastom polumjera ćelije. Ona je najniža, ali signifikantna za dionice od 500 m, a najviša za dionice od 12 000 m.

Kod procjene broja naleta vozila na divlju svinju po dionicama gustoća populacije divljači je jedna od ključnih nezavisnih varijabli, odnosno ključni pretkazivač za sve duljine dionica. Modelima se pokazalo da će broj naleta vozila na divlju svinju biti veći ako je veća gustoća populacije srne obične, divlje svinje ili krupne divljači ukupno, viši udio zapuštenog poljoprivrednog zemljišta i veći prosječni ljetni dnevni promet (PLDP). Također se pokazalo da će broj naleta vozila na divlju svinju biti manji ako je viši udio izgrađenog zemljišta, viši udio šuma, viši udio cesta, viši udio mora (izuzetak su ćelije polumjera 6 000 m) i veći PGDP.

Gledajući nalete vozila na krupnu divljač ukupno na cestama Ličko-senjske županije u promatranom razdoblju predloženi modeli pokazali su da broj dionica državnih cesta na

kojima se dogodio nalet na krupnu divljač pokazuje u potpunosti isti obrazac kao za srnu običnu i divlju svinju. Postoci ćelija s naletom krupne divljači približno su isti kao i kod srne obične. Generalno, neovisno o duljini dionice broj naleta vozila na krupnu divljač ukupno će biti veći ako je veća gustoća populacije srne obične, ili krupne divljači, viši udio zapuštenog poljoprivrednog zemljišta, viši udio vriština i bujadnica, veća udaljenost do pojilišta i veći PGDP. Broj naleta vozila na krupnu divljač će biti manji ako je cesta zavojitija ili ima više raskrižja, viši udio goleti, viši udio izgrađenog zemljišta, viši udio mora i razvedeniji reljef (viša TPI vrijednost).

U ovome se doktorskom radu analiziranjem razvijenih modela i rezultata logističke regresije može se zaključiti sigurnošću od 70,11 % da je najkraća dionica ceste na kojoj se pouzdano može utvrditi vjerojatnost naleta na krupnu divljač dionica duljine 2 000 m i to na temelju pretkazivača relativne odstrelne kvote krupne divljači, udjela goleti, udjela mora i udaljenosti do najbližeg pojilišta. Za procjenu broja naleta vozila na krupnu divljač ukupno također je najpouzdanije koristiti model za dionicu od 2 000 m, na temelju pretkazivača prometno opterećenje, gustoća populacije krupne divljači, blizina pojilišta i udio zapuštenog poljoprivrednog zemljišta.

Opasne dionice od pojave divljači u istraživanom razdoblju na državnim cestama Ličko-senjske županije rangirane su višekriterijskim vrednovanjem – AHP metodom, korištenjem programskog alata Expert Choice. Za rangiranje opasnih dionica korišteni su kriteriji broj naleta, duljina dionice, broj naleta na 100 000 metara i broj naleta na 100 000 metara godišnje. Rezultati višekriterijskog vrednovanja daju podatak da je na državnim cestama Ličko-senjske županije u istraživanom razdoblju od opasnosti pojave divljači najopasnija dionica 13-a na DC-1 (Vrelo Koreničko-Udbina) te odmah iza nje dionica 1 na DC-217 (Ličko Petrovo Selo – granica RH/BIH).

Testiranjem modela utvrđeno je da iako je s predloženim modelima vjerojatnosti naleta i procjene broja naleta, mjesta naleta ili ne naleta moguće procijeniti s točnošću većom od 70 %, mogu se očekivati i greške modela. Naime, validacijom modela uočene pogreške modela su:

- model je točno procijenio da se na određenoj dionici neće dogoditi ili da će se dogoditi nalet
- na dionici tijekom istraživanog razdoblja nije bilo naleta, no model je predvidio da bi se tu mogao dogoditi nalet (greška precjenjivanja naleta)

- na dionici su tijekom istraživanog razdoblja zabilježeni naleti, no model predviđa da se na njoj ne može dogoditi nalet (greška podcjenjivanja naleta).

Model je na 140 dionica bez naleta predvidio da se u 92 slučaja neće dogoditi nalet (točno predviđanje), ali i da bi se na 48 dionica mogao dogoditi nalet. Na 121 dionici na kojoj se dogodio nalet model je predvidio da se na njih 91 može dogoditi nalet, ali i da se na njih 30 neće dogoditi nalet. Od 70,1 % točno predviđenih naleta modelom; 65,7 % ih je točno procijenjeno za dionice bez naleta; a 75,2 % za dionice na kojima se dogodio nalet. Pri tome je na 18,4 % duljine državnih cesta vjerojatnost naleta precijenjena, a na 11,5 % podcijenjena.

Testiranje modela pokazalo je da je svaki model za sebe relativno manjkav. Prvi tip modela (procjena vjerojatnosti naleta) dosta precizno procjenjuje vjerojatnost nastanka naleta s time da je udio podcijenjenih dionica relativnom malen (11,5 %) u odnosu na precijenjene. Ako se za procjenu vjerojatnosti naleta koristi i drugi tip modela (procjena broja naleta) tada kombinacija daje dosta visoku točnost u procjeni prepoznavanja opasnosti naleta vozila na divljač.

U doktorskom radu ispitane su mjere održavanja cesta koje bi mogle smanjiti pojavu divljači na cestama i koje trebaju biti podloga upravljačima cesta da kroz održavanje cesta smanje broj naleta vozila na divljač. Ispitivanje utjecaja mjera održavanja cesta na pojavljivanje divljači izvršeno je na javnim cestama Ličko-senjske županije. U doktorskom radu ispitano je nekoliko mjera održavanja cesta kojima se može regulirati pojava divljači na javnim cestama, a one su postavljanje zaštitnih žičanih ograda uz cestu, detaljno čišćenje zaštitnog cestovnog pojasa, sadnja biljnih vrsta uz cestu koje odbijaju divljač, postavljanje optičkih i zvučnih senzora na smjerokazne stupiće. Navedene mjere održavanja cesta, koje trebaju spriječiti pojavu divljači na cestama na odabranim dionicama nadzirane su pomoću lovačkih kamera, a s obzirom da su se pokazale učinkovitima predlaže se njihova implemantacija u postupak održavanja i opremanja cesta.

Također je provedeno ispitivanje utjecaja lokacije hranilišta divljači na gustoću populacije divljači uz ceste. Zbog toga što su lovačke kamere snimile veliki broj divljači na hranilištu, zaključak je da bi lovačka društva hranilišta za divljač trebala postavljati dalje od cesta. Preporučenu udaljenost hranilišta od ceste bi svakako trebalo posebno istražiti.

Ovim doktorskim radom izradom prostornih obrazaca određeni su elementi ceste i okoline koji ističu opasne dionice od pojave divljači, također su predložena i provjerena dva modela prepoznavanja opasnih dionica od pojave divljači od kojih je jedan temelji na procjeni

vjerojatnosti naleta, a drugi na procjeni broja naleta. U tome smislu u potpunosti je ostvaren planirani cilj istraživanja.

Dokazivanjem postavljenog cilja i hipoteza ovaj doktorski rad otvara mogućnosti daljnjeg istraživanja sprječavanja pojave divljači na cestama na način izrade obrazaca sa i bez krupnih predatora; raščlanjivanje stradale divljači kroz spol i procijenjenu dob jedinke; objedinjenja vremenskih i prostornih obrazaca; razdvajanja prostornih obrazaca naleta prema sezoni, dobu dana i mjesečevim mijenama. U daljnjim istraživanjima potrebno je istražiti i utjecaj lokacije hranilišta na „grupiranje“ divljači na određenim lokalitetima, te je svakako potrebno posebno istražiti stradavanje na cestama jelena lopatara, i to kao zasebnu vrstu. Prema provedenom istraživanju u ovom doktorskom radu radi se o divljači koja značajnije stradava u naletima vozila iako je malobrojna i obitava na ograničenom području.

LITERATURA

[1] Ministarstvo unutarnjih poslova : „*Bilten o sigurnosti cestovnog prometa 2012*.“, Zagreb, 2013.

[2] Dobra kob, br. 7-8, 2015.

[3] Lovački vjesnik br. 4, 2018.

[4] Lovački vjesnik, br. 7-8, 2019.

[5] Shad, R., Rahimi, Sh. : *Identification of Road Crash Black-Sites Using Geographical Information System*. IJTTE 7(3): 368-380, 2017. DOI: http://dx.doi.org/10.7708/ijtte.2017.7(3).07

[6] Elzanowski, A., Ciesiołkiewicz, J., Kaczor, M., Radwańska, J., Urban, R. : *Amphibian road mortality in Europe: a meta-analysis with new data from Poland*. Eur J Wildl Res 55(1): 33–43 DOI 10.1007/s10344-008-0211-x, 2009.

[7] Seiler, A., Folkeson, L. : COST 341 - *The Swedish State-of-the-art concerning Habitat fragmentation due totransport infrastructure.* - Office for Official Publicationsof the European Communities, Luxembourg, 153 pp, 2003.

[8] Sullivan, J. M. : *Trends and characteristics of animal-vehicle collisions in the United States*. Journal of Safety Research, vol. 42, no.1., pp. 9-16, 2011.

[9] Lalo, J. : *The problem of roadkill*. American Forests 72 (9/10): 50-52, 1987.

[10] Groot-Bruinderink, G. W., Hazebroek, E. : *Ungulate traffic collisions in Europe*. Conserv. Biol. 10(4): 1059-1067, 1996.

[11] Seiler, A., Helldin, J.-O., Seiler, Ch. : *Road mortality in Swedish mammals: results of a driver' questionare*. Wild life Biol 19(3): 225-233, 2004.

[12] Pokorny, B. : *Roe deer-vehocle collisions in Slovenia: situation, mitigation strategy and Countermeasures*. Veterinarski arhiv 76, pp. 177-187, 2006.

[13] Saenz-de-Santa-Maria, J., Telleria, J. L. : *Wildlife-vehicle collisions in Spain*. Eur J Wildl Res 61, pp. 399-406, 2015.

[14] Šprem, N. Et al. : "*Wildlife-Vehicle Collisions in Croatia – A Hazard for Humans and Animals"*. Collegium antropologicum pp. 531-535, 2013.

[15] Apollonio, M., Andersen, R., Putman R. : *European Ungulates and their Management in the 21st century*. Cambridge University Press, Cambridge, 618 pp., 2010.

[16] Vivoda, B. et al. : *Divlje životinje i promet na autocestama*. Hrvatske ceste, god. 62, br. 1., pp. 15-23, 2014.

[17] Sullivan, J. M. : *Relationships between lighting and animal-vehicle collisions*. University of Michigan, Transportation Research Institute, Umtri -2009-35, 2009.

[18] Ramp, D., Roger, E. : *Frequency of animal-vehicle collisions*. Royal Zoological Society of New South Wales, pp. 118-126, 2008.

[19] Yunteng, L., et al. : *Modeling animal-vehicle collisions considering animal-vehicle interactions*. Accident Analysis & Prevention, Nov. 2011, vol. 43, Issue 6., pp. 1991-1998, 2011.

[20] Fabijanić, N. et al. : *Primjena senzornih infracrvenih kamera i prostornog modela u procjeni populacije divljači u lovištu III/29 'Prolom'.* Ribarstvo, lovstvo i pčelarstvo. Dubrovnik: 48. hrvatski i 8. međunarodni simpozij agronoma, pp. 657-661, 2009.

[21] Madsen, A.B., Strandgaard, H., Prang, A. : *Facors causing traffic killings of roe deer Capreolus capreolus in Denmark*. Wildlife Biol 8(1): 55-61, 2002.

[22] Jeppesen, J.L. : *Home range and movements of free-ranging roe deer (Capreolus capreolus) at Kalø*. - Danish Review of Game Biology 14(1): 1-14, 1990.

[23] Putzu, N., Bonetto, D., Civallero, V., Fenoglio, S., Meneguz, P.G., Preacco, N., Tizzani, P. : *Temporal patterns of ungulate-vehicle collisions in a subalpine Italian region*, Italian Journal of Zoology, 81(3): 463-470, DOI: 10.1080/11250003.2014.945974, 2014.

[24] Pintur, K. et al. : "*Preliminary research of wildlife-vehicle collisions dynamic in Karlovac"*, Croatia (in Croatian with English summary). Proceeding of the 44th Croatian & 4th International Symposium on Agriculture, Opatija, Croatia, 16th – 20th February 2009; Marić, S. Lončarić, Z.; Faculty of Agriculture University of Josip Juraj Strossmayer in Osijek: Opatija, Croatia, 706-710, 2009.

[25] Barthelmess, E., Brooks, M. : *The influence of body-size and diet on road-kill trends in mammals*. Biodiversity and Conservation 19(6): 1611–1629. doi: 10.1007/s10531-010-9791-3, 2010.

[26] Ford, A.T., Fahrig, L. : *Diet and body size of North American mammal road mortalities*. Transportation Research Part D 12(7): 498–505. doi: 10.1016/j.trd.2007.07.002, 2007.

[27] Morelle, K., Lehaire, F., Lejeune, Ph. : *Spatio-emporal patterns of wildlife-vehicle collisions in a region with a high-density road network*. Nature Conservation 5: 53-73, 2013. doi:10.3897/natureconservation.5.4634

[28] Cserkész, T., Farkas, J., Ottlecz, B. : *Complex wildlife–vehicle collision research on The SMMC's highway network*. Report to Hungarian State Motorway Management Company. Eötvös, 2012.

[29] Počuča, M., Tepavac, R. : *Šteta koju prouzrokuje divljač i njena naknada*. Međunarodni simpozijumo lovstvu, "Suvremeni aspekti održivog gazdovanja populacijama divljači" Zemun/Beograd, pp. 151- 158, 2012.

[30] Križaj, D. : *Štete od divljači*. Hrvatski lovački savez, 2010.

[31] Lindov, O., Omerhodžić, A., Tatarević, A. : *Problematika dokazivanja nelogičnih i nerealnih elemenata nastanka saobraćajne nezgode*. XII Simpozijum "Veštačenje saobraćajnih nezgoda i prevare u osiguranju", pp. 291-299, 2013.

[32] Sindičić, M., Zec, D., Huber, Đ. : *Analiza šteta od smeđih medvjeda u Hrvatskoj u razdoblju od 2004. do 2009. godine*. Šumarski list br. 1-2, CXXXVV (2011), pp. 63-68, 2011.

[33] Fuller, R.J., Gill, R.M.A. : *Ecological impacts of increasing numbers of deer in British woodland*. Forestry 74:193–199. doi:10.1093/forestry/74.3.193, 2001.

[34] Rončević, T., Pintur, K. : *Divljač i sigurnost cestovnog prometa na području grada Zagreba*. V. međunarodni stručno-znanstveni skup Zaštita na radu i zaštita zdravlja, Zadar, pp. 1-6, 2014.

[35] Santos, R.A.L., Ascensão, F., Ribeiro, M. L., Bager, A., Santos-Reis, M., Aguiar, L.M.S. : *Assessing the consistency of hotspot and hot-moment patterns of wildlife road mortality over time*. PECON 15(1): 56–60, 2017. https://doi.org/10.1016/j.pecon.2017.03.003.

[36] Hell, P., Plavý, R., Slamečka, J., Gašparik, J. : *Losses of mammals (Mammalia) and Birds (Aves) on roads in the Slovak part of the Danube Basin*. Eur J Wildl Res 51(1): 35-40, DOI 10.1007/s10344-004-0068-6, 2005.

[37] Glavaš, M. : *Wildlife-vehicle collisions on state road D1 between 8th and 9th sections (in Croatian).* Karlovac University of Applied Science – Hunting and Nature Protection, Karlovac (Croatia), 24 pp., 2016.

[38] Slater, F.M. : *An assessment of wildlife road casualties – the potential discrepancy between numbers counted and numbers killed*. Web. Ecol. 3: 33-42, 2002.

[39] Seiler, A., Helldin, J.-O., Seiler, Ch. : *Road mortality in Swedish mammals: results of a driver' questionare*. Wildlife Biol 19(3): 225-233, 2004.

[40] Leif, A.P. : *Avian Nes Densities and Succes in State Highway Roadsides in South Dakota*. Game Report; South Dakota; Deparment of Gamme, Fish and Parks, Completion Repor 2004-11, 17 pp., 2003.

[41] Riley, T.Z. : *Association of Conservation Reserve Program with ringnecked pheasant survey counts in Iowa*. Wildl. Soc. Bull. 23(3): 386-390, 1995.

[42] Keyser, E.J. : *Pheasant nesting andvegetation development in dense nestingcover established under the South Dakota Pheasant Restoration Program*. Thesis,South Dakota State University, Brookings,South Dakota, USA, 58 pp., 1986.

[43] Eldergard K., Lyngved, J.T., Hjeljord, O. : *Coping in a human-dominated landscape: trade-off between foraging and keeping away from roads by moose (Alces alces)*. Eur J Wildl Res 58(6): 969-979, DOI 10.1007/s10344-012-0640-4, 2012.

[44] Orłowski, G., Nowak, L. : *Road mortality of hedgehogs Erinaceus spp. in farmland in Lower Silesia (south-western Poland).* Pol J Ecol 52(3): 377-382, 2004.

[45] Holsbeek, L., Rodts, J., Muyldermans, S. : *Hedgehogs and other animal traffic victims in Belgium: results of a countrywide survey*. Lutra 42(1): 111–119, 1999.

[46] Clarke, G.Ph., White, P.C.L., Harris, S. : *Effects of roads on badger Meles meles populations in south-west England*. Biol Conserv 86(2): 117-124, PII: S0006-3207(98)00018-4, 1998.

[47] Grilo, C., Ascensão, F., Santos-Reis, M. : *Do well-conected landscapes promote road-related mortality*? Eur J Wildl Res 57(4):707–716, DOI 10.1007/s10344-010-0478-6, 2011.

[48] Jancke, S., Giere, P. : *Patterns of otter Lutra lutra road mortality in a landscape abundant in lakes*. Eur J Wildl Res 57(2): 373–381, DOI 10.1007/s10344-010-0442-5, 2011.

[49] Körbel, O. : *Vermeidung der durch den Straßenverkehr bedingten Verluste von Fischottern (Lutra lutra)*. Forsch Straßenbau und Straßenverkehrstechnik 805:1–58, 2001.

[50] Gužvica, G., Šver, L. : *Preliminarni rezultati praćenja prijelaza životinja zelenim mostom Osmakovac u Dalmaciji*, Journal for applied ecology, ISSN 1845-4976, 2006.

[51] Clevenger, A.P., Chruszcz, B., Gunson, K.E. : *Highway mitigation fencing reduces wildlife-vehicle collisions*. Wildl Soc Bull 29:646–653, 2001.

[52] Colino-Rabanal, V.J., Lizana, M., Peris, S.J. : *Factors influencing wolf Canis lupus roadkills in Northwest Spain*. Eur J Wildl Res 57(3): 399–409. DOI 10.1007/s10344-010-0446-1, 2011.

[53] Kaczensky, P., Knauer, F., Krže, B., Jonozovič, M., Adamič, M., Gossow, H. : *The impact of high speed, hig volume traffic axes on brown bears in Slovenia*. Biol Conserv 111(2): 191-204, PII: S0006-3207(02)00273-2, 2003.

[54] Huber, Đ., Kusak, J., Frković, A. : *Traffic kils of brown bears in Gorski kotar*, Croatia. Ursus 10: 167-171, 1998.

[55] Hartwig, D. : *Auswertung der durch Wild verursachten Verkehrsunfälle nach der Statistik für Nordrhein-Westfallen*. Z. Jagdwiss. 39(1): 22-33, 1993.

[56] Ueckermann, E. : *Erhebung über die Wildverluste durch den Straßenverkehr und die Verkehrsunfälle durch Wild*. Z. Jagdwiss. 10(4): 142-168, 1964.

[57] Jonkers, D.A., De Vries, G.W. : *Verkeersschlachtoffers onder der fauna*. Nederlandsa Vereniging tot bescherming van vogels, Zeist, NL, 190 pp., 1977.

[58] Van den Tempel, R. : *Bird casualties in road traffic*. (In Dutch with an English summary). Vogelbescherming Nederland, Ministerie van Verkeer en Waterstaat, Directoraat-Generaal Rijkswaterstaat, Delft, The Netherlands, 75 pp., 1993.

[59] Rodts, J., Holsbeek, L., Muyldermons, S. : *Dieren onder onze wielen*. Koninklijk Belgisch Verbond voor de Bescherming van de Vogels, Vubpress, Brussel, 190 pp., 1998.

[60] Hansen, L. : *Road kills in Denmark.* (In Danish with an English summary). Dansk Ornitologisk Forenings Tidskrift 76: 97-110, 1982.

[61] Harris, S., Cresswell, W., Reason, P.,Cresswell, P. : *An integrated approach to monitoring badger (Meles meles) population changes in Britain*. In: McCullough, D.R. & Barrett, R.H., (Eds.); Wildlife 2001: Populations. Elsevier Applied Science 58, London, pp. 295-311, 1991.

[62] Van der Zee, F.F., Wiertz, J., Terbraak, C.J., Van Apeldoorn, R.C. : *Landscape change as a possible cause of the badger Meles meles L. decline in the Netherlands*. Biological Conservation 61(1): 17-22, 1992.

[63] Bengtsson, S. A. : *En fallviltundersokning*. Faltbiologen 3: 9-15, (In Swedish)., 1962.

[64] Bolund, L. : *Trafikdod*. Djurskyddet 82: 92-95, (In Swedish)., 1974.

[65] Goransson, G., Karlsson, J., Lindgren, A. : *Influence of roads on the surrounding nature*. II Fauna. (In Swedish with an English summary). Swedish Environmental Protection Agency, SNV PM 1069, Stockholm, 124 pp., 1978.

[66] Yunteng, L., et al. : *Fuzzy Logic-Based Mapping Algorithm for Improving Animal-Vehicle Collision Data*. Journal of Transportation Engineering, May 2012, vol. 138, no. 5., pp. 520-526, 2012.

[67] Yunteng, L. et al. : *Modeling animal-vehicle collisions using diagonal inflated bivariate Poisson regression*. Accident Analysis & Prevention, Jan. 2011, vol. 43, Issue 1., pp. 220-227, 2011.

[68] Van der Ree, R., Jaeger, J.A.G., van der Grift, E.A., Clevenger, A.,P. : *Effects of roads and traffic on wildlife populations and landscape function: road ecology is moving towards larger scales*. Ecology and Society 16(1): 48, 2011.
URL: http://www.ecologyandsociety.org/vol16/iss1/art48/.

[69] Moen, R. : *Techniques to Monitor Road-Crossings and Animal-Vehicle Collisions*. Minnesota University, 2009.

[70] Trombulak, S.C., Frissell, Ch. A. : *Review of Ecological Effects of Roads on Terrestrial and Aquatic Communities*. Conserv Biol 14(1): 18-30, 2000.

[71] Bissonette, J.A. : *Scaling roads and wildlife: the Cinderella principe*. Z Jagdwiss 48 (Supppl.): 208-214, 2002.

[72] Asaeda, T., Ca, V.A.: *The subsurface transport of heat and maisture and its effect on the environment: anumerical model*. Boundary Layer Meteorology 65: 159 – 179, 1993.

[73] Bogemans, J., Niernick, L., Stassart, J.M. : *Effect of deacing shloride salts on ion accumulation in spruce (Picea abies (L.) sp.).* Plant and Soil 113: 3 – 11, 1989.

[74] Forman, R.T.T., Sperling, D., Bissonette, J.A., Clevenger, A.P., Cutshall, C.D., Dale, V.H., Fahrig, L., France, R., Goldman, C.R., Heanue, K., Jones, J.A., Swanson, F.J., Turrentine, T.,Winter, T.C. : *Road Ecology*. Science and Solutions. Island Press, Washington DC., 2003.

[75] Rea, R.V., Child, K.N., Spata, D.P., MacDonald, D. : *Road and rail side vegetation management implications of habitat use by moose relative to brush cutting season*. Environ Manag 46(1):101–109.doi:10.1007/s00267-010-9502-6, 2010.

[76] Laurian, C., Dussault, C., Ouellet, J.P., Courtois, R., Poulin, M., Breton, L. : *Behavioral adaptations of moose to roadside salt pools*. JWildl Manag 72(5):1094–1100. doi:10.2193/2007-504, 2008.

[77] Parker, K.L., Robbins, C.T., Hanley, T.A. : *Energy expenditures forlocomotion by mule deer and elk*. J Wildl Manag 48(2):474–488, 1984.

[78] Ritchie, M.E. : *Populations in a landscape context: sources, sinks, and metapopulations*. In: Bissonette J. A., (ed.), Landscape and Wildlife Ecology: Effects of Pattern and Scale. Springer-Verlag, N. Y., 160-184 pp., 1997.

[79] Vitousek, E.M., Moonev, H. A, Lubchenco, J., Melillo, J.M. : *Human domination of the Earth's ecosystems*. Sci 277: 494-499, 1997.

[80] Forman, R.T.T. : *Estimate of the area affected ecologically by the road system in the United States*. Conservation Biology 14(1): 31–35, 2000.

[81] Glista, D.J., De Vault, T.L., De Woody, J.A. : *A review of mitigation measures for reducing wildlife mortality on roadways*. Landscape Urban Plan 91(1): 1-7, 2009.
doi:10.1016/j.landurbplan.2008.11.001

[82] Mammeri, A., Depu, Z., Boukerche, A. : *Animal-Vehicle Collision Mitigation System for Automated Vehicles*. IEEE Transaction on Systems, Man and Cybernetics Systems, Sept. 2016, vol. 46, no. 9., pp.1287-1299, 2016.

[83] Moline, M., et al. : *Integration of Scientific Echo Sounders With an Adaptable Autonomous Vehicle to Extend Out Understanding of Animals*. Journal of Atmospheric & Oceanic Technology, Nov. 2015,vol. 32, Issue 11., pp. 2173-2186, 2015.

[84] Jun, X. et al. : *Animal monitoring with unmanned aerial vehicle-aided wireless sensor networks*. Conference Paper, pp. 125-132, 2015.

[85] Mukherjee, A., et al. : *Large animal detection and continuous traffic monitoring on highways*. Conference Paper, pp. 3, 2013.

[86] Bashir, M., Abu-Zidan, F. M. : *Motor vehicle collisions with large animals*. Saudi Medical Journal, 27(8), pp. 1116-1120, 2006.

[87] Šimunović, LJ. et al. : *Road Network Safety Management in the Republic of Croatia*. Modern Traffic, vol. 34, no. 3.-4., pp. 240-244, 2014.

[88] Malo, J., Suarez, F., Diez, A. : *Can we mitigate animal-vehicle accidents using predictive models?*. Journal of Applied Ecology, Aug. 2004, vol. 41, Issue 4., pp. 701-710, 2004.

[89] Weir, E. : *Collisions with wildlife: the rising toll*. Canadian Medical Association Journal, vol. 166, no. 6., 2002.

[90] Moorhouse, B. : *Watch for wildlife*. Ontario Out of Doors, May 2004, vol. 36, Issue 4., pp. 8-8, 2004.

[91] Ford, A. T. et al. : *Planning and prioritization strategies for phased highway mitigationusing wildlife-vehicle collision data*. Wildlife Biology, vol.17, no. 3.,: pp. 253-265, 2011.

[92] Deluka-Tibljaš, A., Karleuša, B., Dragičević, N. : *Pregled primjene metoda višekriterijske analize pridonošenju odluka o prometnoj infrastrukturi*. Građevinar br. 7., pp. 619-631, 2013.

[93] www.licko-senska.hr

[94] Božičević, S. : *Fenomen krš*. Školska knjiga, Zagreb, 104 pp., 1992.

[95] Šegota, T.; Filipčić, A. : *Köppenova podjela klima i hrvatsko nazivlje*. Geoadria 8(1): 17-37, 2003.

[96] Filipčić, A. : *Klimatska regionalizacija Hrvatske po Köppenu za standardno razdoblje 1961.- 1990. u odnosu na razdoblje 1931.-1960*. Acta Geographica Croatica, 34: 1-15, 1998.

[97] http://www.bioportal.hr/gis/

[98] Velić, I. (ur.); Vlahović, I. (ur.), : *Geološka karta Republike Hrvatske 1:300 000*. Hrvatski geološki institut, Zagreb, 2009.

[99] Republika Hrvatska : *Zakon o cestama*, Narodne novine 84/2011, Republika Hrvatska, 2011.

[100] Republika Hrvatska : *Zakon o javnim cestama*, Narodne novine 180/2004, Republika Hrvatska, 2004.

[101] Republika Hrvatska : *Zakon o obveznim odnosima*, Narodne novine 35/05, Republika Hrvatska, 2005.

[102] Dadić, I., Kos, G. : *Teorija i organizacija prometnih tokova*, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2007.

[103] www.zuc-ls.

[104] hac.hr/hr/home

[105] https://hrvatske-ceste.hr

[106] Republika Hrvatska, Ministarstvo unutarnjih poslova, Policijska uprava Ličko-senjska, broj: 511-04-03/04-4591/2-2017. M.B., *Prometne nesreće- nalet na divlje životinje i sudar sa domaćim životinjama na cesti, podaci za izradu doktorske disertacije*, 05. srpnja 2017.

[107] https://www.hls.com.hr

[108] Vincent, J., Bideau, E., Cibien, C. &Quéré, J. : *Verkehrsopfer beim Rehwild (Capreolus capreolus)*. – Z. Jagdwiss. 34(1): 63-68, 1988.

[109] Bonnot, N., Morellet, N., Verheyden, H., Cargnelutti, B., Lourtet, B., Klein, F., Hewison, A.J.M., 2013 : *Habitat use under predation risk: hunting, roads and human dwellings influence the spatial behavoiur of roe deer*. Eur J Wildl Res 59(2): 185-193, DOI 10.1007/s10344-012-0665-8, 2013.

[110] Primi, R., Pelorosso, R., Ripa, M.N., Amici, A. : *A statistical GIS-based analysis of Wild boar (Sus scrofa) traffic collisions in a Mediterranean area*. Italian Journal of Animal Science 8 (Suppl.2) : 649–651. doi: 10.4081/ijas.2009.s 2.649, 2010.

[111] Steiner, W., Leisch, F., Hackländer, K. : *A rewiev on the temporal pattern of dee-vehicle accidents*. Impact of seasonal, diurnal and lunar effects in cervids. Accident Anal Prev 66: 168-181, 2014.

[112] Gundersen, H.; Andreassen, H.P. : *The risk of moose Alces alces collision A predictive logistic model for moose-train accidents.* Wildlife Biology 4(2): 103-110, 1998. https://doi.org/10.2981/wlb.1998.007

[113] Pierce, A. M. : *Spatial and temporal relationships between deer harvest and deer-vehicle collisions at Oak Ridge Reservation, Tennessee*. Master's Thesis, University of Tennessee, Knoxwille, 89 pp., 2010. https://trace.tennessee.edu/utk_gradthes/742

[114] Mysterud, A. : *Temporal variation in the number of car-killed red deer Cervus elaphus in Norway*. Wildlife Biol 10(3): 203-211, 2004.

[115] Rodríguez-Morales, B., Díaz-Varela, E.R., Marey-Pérez, M.F. : *Spatiotemporal analysis of vehicle collisions involving wild boar and roe deer in NW Spain*. Accident Anal Prev 60: 121-133, 2013.

[116] Díaz-Varela, E.R., Vazquez-Gonzalez, I., Marey-Pérez, M.F., Álvarez-López, C.J. : *Assessing methods of mitigating wildlife-vehicle collisions by accident characterization and spatial analysis.* Transp Res D Transp Environ 16(4): 281-287, 2011. doi:10.1016/j.trd.2011.01.002

[117] Lagos L., Picos, J., Valero, E. : *Temporal pattern of wild ungulate-related traffic accidents in northwest Spain.* Eur J Wildl Res, 58(4): 661-668, DOI 10.1007/s10344-012-0614-6., 2012.

[118] Gunson, K.E., Mountrakis, G., Quackenbush, L.J. : *Spatial wildlife-vehicle collision models.* A rewiev of current work and its application to transportation mitigation projects. J Environ Manage 92(4): 1074-1082, 2011. doi:10.1016/j.jenvman.2010.11.027

[119] Seiler, A. : *Predicting locations of moose-vehicle collisions in Sweden.* J Appl Ecol 42(2): 371-382, doi: 10.1111/j.1365-2664.2005.01013.x, 2005.

[120] Ng, J.W., Nielsen, C., Clair, C.C.St. : *Landscape and traffic factors influencing deer-vehicle collisions in an urban enviroment.* Hum. Wildl. Confl. 2(1): 34-47, 2008.

[121] Clevenger, A.P., Chruszcz, B., Gunson, K.E. : *Spatial patterns and factors influencing small vertebrate fauna road-kill aggregations.* Biol Conserv 109(1): 15-26. PII: S0006-3207(02)00127-1, 2003.

[122] Gunson, K.E., Clevenger, A.P., Ford, A.T., Bissonete, J.A., Hardy, A. : *A Comparison of Data Sets Varying in Spatial Accuracy Used to Predict the Occurrence of Wildlife-Vehicle Collisions.* Environ Manage 44(2): 268-277, 2009. doi 10.1007/s00267-009-9303-y

[123] Bíl, M., Andrášik, R., Janoška, Z. : *Identification of hazardous road locations of traffic accidents by means of kernel density estimation and cluster significance evaluation*. Accident Anal Prev55: 265-273, 2013.

[124] Hawbaker, T.J., Volker, C.R. : *Roads and Landscape Pattern in Northern Wisconsin Based on a Comparison of Four Road Data Sources.* Conserv Biol 18(5): 1233-1244, 2004.

[125] Sutherland, W.J. : *Ecological Census Techniques – a handbook*. Second edition. Cambridge University Press, New York, 432 pp., 2006.

[126] Burnham, K.P., Anderson, D.R. : *Model Selection and Multimodal Inference.* A Practical Information-TheoreticApproach, 2nd edn. Springer Verlag, New York, 488 pp., 2002.

[127] Reijnen, R., Foppen, R., Braak, C.T., Thissen, J. : *The effects of car traffic on breeding bird populations in woodland*. III. Reductions of density in relation to proximity of main roads. Journal of Applied Ecology 32(1): 187–202, 1995.

[128] Ortega, Y.K., Capen, D.E. : *Effects of forest roads on habitat quality for ovenbirds in a forested landscape*. Auk 116: 937–946, 1999.

[129] Rockhill, A. P.; DePerno, Ch. S.; Powell, R. A. : *The Effect of Illumination and Time of Day on Movements of Bobcats (Lynx rufus)*. PLoS ONE 8(7): e 69213.doi:10.1371/journal.pone.0069213, 2013.

[130] http://astrogeo.geoinfo.geof.hr/online_efemeride/sunrise_sunset/)

[131] Roša, D.; Valečić, A.; Drvar, Z.; Hržina, D.; Romštajn, I.; Maričić, D.; Bašić, M. : *Astronomija 1 – web izdanje*. Zvjezdarnica Zagreb – Zagrebački astronomski savez. Zagreb, 156 pp., 2016.

[132] http://aa.usno.navy.mil/faq/docs/moon_phases.php

[133] https://en.wikipedia.org/wiki/Lunar_phase

[134] Božić, M., Kopić, D., Mihoci, F. : *Traffic counts on the Croatian road network in the Year of 2012 (in Crotian).* Prometis d.o.o., Zagreb, 442 pp., 2013.

[135] Božić, M., Kopić, D., Mihoci, F. : *Traffic counts on the Croatian road network in the Year of 2013 (in Crotian).* Prometis d.o.o., Zagreb, 460 pp., 2014.

[136] Božić, M., Kopić, D., Mihoci, F. : *Traffic counts on the Croatian road network in the Year of 2014 (in Crotian).* Prometis d.o.o., Zagreb, 557 pp., 2015.

[137] Božić, M., Kopić, D., Mihoci, F. : *Traffic counts on the Croatian road network in the Year of 2015 (in Crotian).* Prometis d.o.o., Zagreb, 656 pp., 2016.

[138] Božić, M., Kopić, D., Mihoci, F., Marold, N., Gršetić, J. : *Traffic counts on the Croatian road network in the Year of 2016 (in Crotian).* Prometis d.o.o., Zagreb, 764 pp., 2017.

[139] Korlaet, Ž., Dragičević, V. : *Projektiranje i građenje cesta*. Građevinski fakultet Sveučilišta u Zagrebu, 2018.

[140] Legac, I. : *Cestovne prometnice I*. Fakultet prometnih znanosti, Zagreb, 2006.

[141] Guisan, A.,Weiss, S.B.,Weiss, A.D. : *GLM versus CCA spatial modeling of plant species distribution.* Kluwer Academic Publishers. Plant Ecology. 143:107-122, 1999.

[142] Weiss, A. : *Topographic Position and Landforms Analysis.* Poster presentation, ESRI User Conference, San Diego, CA., 2001.

[143] Adamič, M. : *Prehranske značilnosti kot element načrtovanja varstva, gojitve in lova parkljaste divjadi s odudarkom na jelenjadi (Cervus elaphus L.)*. Universa Edvarda Kardelja v Ljubljani – VDO Biotehniška fakulteta, Institut za gozdno in lesno gospodarstvo VTOZD za gozdarstvo; Strokovna in znanstvena dela 105; Doktorska disertacija na Univerzi v Beogradu; Ljubljana; 203 pp., 1990.

[144] Zar, J.H. : *Biostatistical Analysis. 4th edition*. Prentice Hall, New Jersey, 123 pp., 1999.

[145] Huber, D., Roth, H.U. : *Movements of European brown bears in Croatia*. Acta Theriologica 38(2): 151-159, 1993.

[146] Car, Z. : *Razvrstavanje i prirodoslovlje divljači*. Iz Dragišić, P., (ur): Lovački priručnik; Lovačka knjiga; Zagreb; 69-287, 1967.

[147] Ueckermann, E., Hansen, P.: *Das Damwild – Biologie, Hege und Jagd*. 4. Auflage, Franckh-Kosmos Verlags-Gmg H& Co., Stuttgart, 327 pp., 2002.

[148] Hosmer, D. W., Lemeshow, S. : *Applied Logistic Regression*. 2nd ed. New York: Wiley, 2000.

[149] Tabachnick, B.G., Fidell, L.S. : *Using multivariate statistics*. Boston: Pearson, 2013.

[150] Kachigan, S.K. : *Multivariate statistical analysis:* A conceptual introduction (2nd ed.). New York : Radius Press. 1991.

[151] Klanac J., Perkov J., Krajnović A. : *Primjena AHP i PROMETHEE metode na problem diverzifikacije.* Oeconomica Jadertina 2/2013, Zadar, 2013.

[152] Saaty, T. L. (1980) The Analytic hierarchy process. New York: McGraw-Hill

[153] Expert Chioce software; http://www.expertchoice.com

[154] Andersen, P.N., Madsen, A.B. : *Trafic-kills of larger animals in Denmark*. NERI Technical Report No.626, 58 pp., 2007.

[155] Clevenger, A.P., Dorsey, B., Barrueto, M., Ford, A.T. : *Activity patterns of wildlife at crossing structures as measure of adaptability and performance*. Proceedings of the 2013 International Conference on Ecology and Transportation (ICOET 2013)., 2013. http://www.icoet.net/icoet_2013.

[156] Neumannn, W., Ericsson, G., Dettki, H., Bunnefeld, N., Keuler, N., Helmers, D.P., Radeloff, V.C. : *Difference in spatiotemporal patterns of wildlife road-crossings and wildlife-vehicle collisions.* Biol Conserv 145(1): 71-78, doi:10.1016/j.biocon.2011.10.011., 2012.

[157] Sudharsan, K., Riley, S.R., Winterstein, S.R. : *Relationship of autumn hunting season to the frequency of deer-vehicle collisions in Michigan*. J Wildl Manag 70(4): 1161–1164, 2006.

[158] Vujnović, Z. : *Trophy quality of wild boar tusks in eastern part of Croatia during last eight hunting years*. (In Croatian). University in Zagreb, Faculty of Forestry, Master thesis, 46 pp., 2016.

[159] Tomorad, V. : *Trophy quality of wild boar tusks in northern part of Croatia during eight hunting years.* (In Croatian). University in Zagreb, Faculty of Forestry, Master thesis, 32 pp., 2017.

[160] Milas, T. : *Trophy quality of wild boar tusks in west and south part of Croatia during eight hunting years*. (In Croatian), University in Zagreb, Faculty of Forestry, Master thesis, 43 pp., 2018.

[161] Maillard, D., Fournier, P. : *Effect of shooting with hounds on home range size of wild boar* (*Sus scrofa* L.) *groups in Mediterranean habitat.* Ibex J Mt Ecol 3:102–107, 1995.

[162] Keuling, O., Stier, N., Roth, M. : *How does hunting influence activity and space use in wild boar Sus scrofa*. Eur J Wildl Res 54:729–737., 2008, doi:10.1007/s10344-008-0204-9

[163] Keuling, O., Lauterbach, K., Stier, N., Roth, M. : *Hunter feedback of individually marked wild boar Sus scrofa L.: dispersal and efficiency of hunting in northeastern Germany*. Eur J Wildl Res 56(2): 159–167. DOI 10.1007/s10344-009-0296-x., 2010.

[164] Dussault, C., Poulin, M., Courtois. R., Ouellet, J. : *Temporal and spatial distribution of moose-vehicle accidents in the Laurentides Wildlife Reserve, Quebec, Canada*. WildBiol 12(4): 415–425, 2006.

[165] Briedermann, L., 2009 : *Schwarzwild – Neuausgabe bearbeitet von Burkhard Stöcker.* Franckh-Kosmos Verlags-GmbH & Co. KG, Stuttgart, 596 pp., 2009.

[166] Tollrian, R., Harvell, C.D. : *The evolution of inducible defenses: current ideas*. In: Tollrian R, Harvell CD (Eds). The ecology and evolution of inducible defenses. Princeton University Press, Princeton, 306–321pp., 1999.

[167] Creel, S., Christianson, D., Liley, S., Winnie, J.A.Jr. : *Predation risk affects reproductive physiology and demography of elk*. Sci 315:960, 2007.

[168] Benhaiem, S., Delon, M., Lourtet, B., Cargnelutti, B., Aulagnier, S., Hewison, A.J.M., Morellet, N., Verheyden, H. : *Hunting increases vigilance levels in roe deer and modifies feeding site selection*. Anim Behav 76(3):611–618, 2008.

[169] Jayakody, S., Sibbald, A.M., Mayes, R.W., Hooper, R.J., Gordon, I.J., Lambin, X. : *Effects of human disturbance on the diet composition of wild red deer (Cervus elaphus)*. Eur J Wildl Res 57(94):939–948, 2011.

[170] Webb, S.L., Dzialak, M.R., Harju, S.M., Hayden-Wing, L.D., Winstead, J.B. : *Effects of human activity on space use and movement patterns of female elk.* Wildl Soc Bull 35(3):261–269, 2011.

[171] Creel, S., Winnie, J. A. Jr. : *Responses of elk herd size to fine-scale spatial and temporal variation in the risk of predation by wolves*. Anim Behav 69:1181–1189, 2005.

[172] Searle, K. R., Stokes, C. J., Gordon, I. J.: *When foraging and fear meet: using foraging hierarchies toinform assessments of landscapes of fear.* BehaviouralEcology 19, 475–482, 2008.

[173] Iribaren, C., Kotler, B.P. : *Foraging patterns of habitat use reveal landscape of fear of Nubianibex Capra nubiana*. Wild Biol 18(2):194–201, 2012.

[174] Briedermann, L. : *Schwarzwild – Neuausgabe bearbeitet von Burkhard Stöcker.* Franckh-Kosmos Verlags-GmbH & Co. KG, Stuttgart, 596 pp., 2009.

[175] Hell, P., Hrnčiar, M.,Šimiak, M. : *Distribution and territorial planningof wild boar (Sus scrofa L.) in Slovakia* (in Slovak with English summary). Folia venatoria 14: 71-88, 1984.

[176] Vukelić, J., Baričević, D. : *Forest communities of common beech in Croatia.* In: Matić S. (ed.): Common beech (*Fagus sylvatica* L.) in Croatia. Zagreb, Academy of Forestry Sciences, Hrvatske šume Ltd., Zagreb City Ofce for Agriculture and Forestry: 108-123, 2003.

[177] Matić, S., Anić, I., Prpić, B., Oršanić, M. : *Uzgojni postupci u jelovim šumama oštećenim propadanjem.* U: Prpić, B. (ur.), Obična jela (*Abies alba* Mill.) u Hrvatskoj, Akademija šumarskih znanosti i "Hrvatske šume", p.o. Zagreb, 461–472, Zagreb, 2001.

[178] Stubbe, Ch. : *Rehwild – Biologie, Ökologie, Bewirtschaftung*. 5., neubearbeitete Auflage. Franckh-Kosmos Verlags-GmbH. 398 pp., 2008.

[179] Stubbe, Ch., Mehlitz, S., Peukert, R., Goretzki, J., Stubbe, W., Meynhardt, H. : *Lebensraumnutzung und Populationsumsatz des Schwarzwildes in der DDR – Ergebnisse der Wildmarkierung*. Beiträge zur Jagd- und Wildforschung 16: 212-231, 1989.

[180] Zerba, E., Morton, M. : *Dynamics of Incubation in Mountain White-Crowned Sparrows*, The Condor, Volume 85, Issue 1, 1 February 1983, Pages 1–11, 1983. https://doi.org/10.2307/1367879

[181] Fernández-Llario, P. : *Environmental correlates of nest site selection by wild boar* (*Sus Scrofa)*. Acta Theriol 49(3): 383-392, 2004.

[182] Schlichting, P.E., Fritts, S., Mayer, J.J., Gipson, Ph.S., Dabbert, C.B. : *Determinants of Variation in Home Range of Wild Pigs.* Wildlife Soc B 40(3): 487-493, 2016. doi: 10.1002/wsb.662,

[183] Markov, N.I., Neifel'd, N.D., Estaf'ev, A.A. : *Ecological aspects of dispersal of the wild boar, Sus scrofa L., 1758, in the northeast of European Russia.* Russ J Ecol 35:131–134, 2004.

[184] Dexter, N. : *The influence of pasture distribution, temperature and sex on home-range size of feral pigs in a semi-arid environment*. Wildlife Research 26:755–762, 1999.

[185] Hofmann, R. R. : *Evolutionary Steps of ecophysiological adaptation and diversification of ruminants: a comparative view of their digestive system.* Oecologia, Volume 78, Issue 4, pp 443–457 | Cite as March 1989.

[186] Bashore, T. L., Tzilkowski, W. M., Bellis, E. D. : *Analysis of deer-vehicle collision sites in Pennsylvania.* Journal of Wildlife Management 49, 769-774, 1985.

[187] Finder, R. A., Roseberry, J. L., Woolf, A. : *Site and landscape conditions at whitetailed deer/vehicle collision locations in Illinois.* Landscape and Urban Planning 44, 77-85, 1999.

[188] Hubbard, M. W., Danielsen, B. J., Schmitz, R. A. : *Factors influencing the location of deer-vehicle accidents in Iowa*. Journal of Wildlife Management, Vol. 64, No.3, pp. 707-712, 2000.

[189] Malo, J., Suárez, F., Díez, A. : *Can we mitigate animal-vehicle accidents using predictive models?* J Appl Ecol 41(4): 701-710, 2004.

[190] Nielsen, C. K., Anderson, R. G., Grund, M. D.: *Landscape influences on deervehicle accident areas in an urban environment.* Journal of Wildlife Management 67, 46-51, 2003.

[191] Puglisi, M. J., Lindzey, J. S., Bellis, E. D. : *Factors associated with highway mortality of white-tailed deer.* Journal of Wildlife Management 38, 799-807, 1974.

[192] Barrientos, R., Bolonio, L. : *The presence of rabbits adjacent to roads increases polecat road mortality.* Biodiversity and Conservation, Volume 18, Issue 2, pp 405–418, February 2009,

[193] Bunnefeld, N., Borger, L., Van Moorter, B., M. Rolandsen, C., Dettki, H., Solberg, E. J., Ericsson, G. : *A model-driven approach to quantify migration patterns: individual, regional and yearly differences*. Journal of Animal Ecology, volume 80, Issue 2, Pages 466-476, March 2011., https://doi.org/10.1111/j.1365-2656.2010.01776.x

[194] Jaren, V., Andersen, R., Ulleberg, M., Pedersen, P. H., Wiseth, B. : *Moose–train collisions: the effect of vegetation removal with a cost–benefit analysis.* Alces 27(?): 93–99, 1991.

[195] Seiler, A. : *The toll of the automobile Wildlife and roadsin Sweden*. Annex IV. Spatial models to predict moose–vehicle collisions in Sweden. Silvestria 295. PhD Thesis., 2003.

[196] Bíl, M., Andrášik, R., Svoboda, T., Sedoník, J. : *The KDE+ software: a tool for effective identification and ranking of animal-vehicle collision hotspots along networks.* Landscape Ecol 31 (2) : 231-237, 2016.

[197] Plug, C., Xia, J., Caulfield, C. : *Spatial and temporal visualization techniques forcrash analysis.* Accident Analysis and Prevention 43 (?) : 1937–1946, 2011.

[198] Levine, N. : *CrimeStat: A Spatial Statistics Program for the Analysis of Crime Incident Locations.* Ned Levine & Associates, Annandale, Virginia and National Institute of Justice, Washington, DC, 2000.

[199] O'Driscoll, R.L. : *Descriptions of spatial pattern in seabird distributions along line transects using neighbour K statistics*. Marine Ecology Progress Series 165, 81–94, 1998.

[200] Seiler, A. : *Trends and spatial patterns in ungulate-vehicle collisions in Sweden.* Wildlife Biol 10(4): 301-313, 2004.

[201] Sjöllund, M. : *Road and landscape features affecting the aggregation of ungulate vehicle collisions in southern Sweden.* Master's thesis, Swedish University of Agricultural Sciences, Grimsö., 2016.

[202] Cserkész, T., Ottlecz, B., Cserkész-Nagy, Á., Farkas, J. : *Interchange as the main factor detemining wildlife-vehicle collision hotspots on the fenced highways: spatial analysis and applications*. Eur J Wildl Res 59(4): 587-597, 2013.

[203] *Projektna grupa*, Biotehnički fakultet Sveučilišta u Ljubljani, Visoka škola za zaštitu okoliša, Velenje, Nacionalni institut za šumarstvo, 2019.

[204] https://smart-kamera.net/wp-content/uploads/2018/01/Lovacka-GSM-kamera-ScoutGuard

[205] https://s3.eu-central-1.amazonaws.com/cnj-img/images/Y5/Y5YY8ILvDZtO

[206] http://fanzoj.hr/index.php?route=product/manufacturer/info&manufacturer_id=32

[207] http://instel.hr/ponuda.php#

[208] Entzeroth, R. : *Floristische Aufnahme von Wildgehegen in Rheinland zur Ermittlung der von wiederkäuerden Schalenwildarten verschmähten Pflanzen*. Z. Jagdwiss. 24 (4) : 187-194, 1978/79

[209] Republika Hrvatska : *Naredba o smanjenju pojedine vrste divljači*, Narodne novine 115/2018, Republika Hrvatska, 2018.

[210] Republika Hrvatska : *Odluka o razvrstavanju javnih cesta u državne ceste, županijske ceste i lokalne ceste,* Narodne novine 17/2010, Republika Hrvatska, 2010.

[211] Republika Hrvatska : *Zakon o javnoj nabavi*, Narodne novine 120/2016, Republika Hrvatska, 2016.

[212] Hrvatske ceste d.o.o. – Lika ceste d.o.o.: *Okvirni sporazum održavanja i zaštite državnih cesta 2019.-2022.*.

[213] Marević, M. Ištoka Otković, I. : *Zakonski okviri i planiranje gospodarenja cestama,* Elektronic Journal oft he Faculty of Civil Engineering Osijek-e-Gfos, Vol.3 No.4, pp 83-92, 2012.

[214] Hrvatske ceste d.o.o., poslovna jedinica Zadar, tehnička ispostava Gospić : *Plan ophodnje državnih cesta,* (01.01.2019.-31.12.2019. god.).

[215] Republika Hrvatska : *Pravilnik o ophodnji javnih cesta*, Narodne novine 75/2014, Republika Hrvatska, 2014.

[216] Republika Hrvatska : *Pravilnik o prometnim znakovima, signalizaciji i opremi na cestama*, Narodne novine 92/2019, Republika Hrvatska, 2019.

POPIS SLIKA

Slika 1. Položaj Ličko-senjske županije u Republici Hrvatskoj 19
Slika 2. Pregledni prikaz Ličko-Senjske županije s gradovima i općinama 20
Slika 3. Karta tipova klime prema Köppenu na području Ličko-senjske županije 22
Slika 4. Područje istraživanja 25
Slika 5. Karta javnih cesta Ličko-senjske županije 27
Slika 6. Trasa autoceste kroz Ličko-senjsku županiju 28
Slika 7. Mjesečeve mijene prema Pomorskom oceanografskom portalu. 46
Slika 8. Položaj ćelija korišten za izračun modela predviđanja naleta vozila na divljač 47
Slika 9. Informacijski sustav brojenja prometa 48
Slika 10. Prostorni razmještaj mjesta naleta vozila na krupnu divljač tijekom istraživanog razdoblja (2012. - 2016.) na području Ličko-senjske županije 53
Slika 11. Učestalost naleta po dionicama državnih cesta Ličko-senjske županije na krupnu divljač tijekom promatranog razdoblja (2012. - 2016.) 56
Slika 12. Kvaliteta modela procjene vjerojatnosti naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije 105
Slika 13. Kvaliteta modela procjene broja naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije 107
Slika 14. Prostorni raspored stvarnih i procijenjenih ćelija bez naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije 109
Slika 15. Prostorni raspored stvarnih i procijenjenih ćelija s naletima vozila na krupnu divljač na državnim cestama Ličko-senjske županije 110
Slika 16. Kretanje čaglja između 21. veljače i 7. ožujka 2019. 138
Slika 17. Kretanje čaglja do 15. travnja 2019. godine. 139
Slika 18. Lovačka nadzorna kamera marke ScoutGuard 141
Slika 19. Lovačka nadzorna kamera marke Minox ..... .141
Slika 20. Lovačka nadzorna kamera marke SpyPoint 141
Slika 21. Postavljena zaštitna žičana ograda 142
Slika 22. Medvjed se vraća od zaštitne žičane ograde 143
Slika 23. Lisica se vraća od zaštitne žičane ograde 143
Slika 24. Medvjed se vraća od zaštitne žičane ograde 1 143
Slika 25. Medvjed se vraća od zaštitne žičane ograde 2 143

Slika 26. Divlje svinje se vraćaju od zaštitne žičane ograde 144
Slika 27. Medvjed se vraća od zaštitne žičane ograde 3 144
Slika 28. Očišćeni zaštitni cestovni pojas na ŽC 5126, prvo opasno mjesto 144
Slika 29. Očišćeni zaštitni cestovni pojas na ŽC 5126, drugo opasno mjesto 144
Slika 30. Divlja svinja na rubu očišćenog zaštitnog cestovnog pojasa 145
Slika 31. Medvjed na rubu očišćenog zaštitnog cestovnog pojasa 1 145
Slika 32. Srna na rubu očišćenog zaštitnog cestovnog pojasa 145
Slika 33. Medvjed na rubu očišćenog zaštitnog cestovnog pojasa 2 145
Slika 34. Nalet vozila na divljač na mjestu dionice gdje nije očišćen cestovni pojas 146
Slika 35. Visina postavljanja senzora na smjerokazni stupić 147
Slika 36. Optički senzor 147
Slika 37. Osvjetljavanje cestovnog pojasa pomoću optičkih senzora 147
Slika 38. Optički senzor na smjerokaznom stupiću 147
Slika 39. Zvučni senzor 148
Slika 40. Ozvučivanje cestovnog pojasa pomoću zvučnih senzora 148
Slika 41. Zvučni senzor na smjerokaznom stupiću 148
Slika 42. Vuk fotografiran u blizini optičkog senzora uz cestu 149
Slika 43. Divlja svinja fotografirana u blizini optičkog senzora uz cestu 149
Slika 44. Srna fotografirana u blizini zvučnog senzora uz cestu 149
Slika 45. Jelen fotografiran u blizini optičkog senzora uz cestu 149
Slika 46. Medvjed fotografiran u blizini zvučnog senzora uz cestu 150
Slika 47. Znak „divljač na cesti“ sa simbolom divlje svinje 150
Slika 48. Znak „divljač na cesti“ na DC-50 sa dopunskom pločom 150
Slika 49. Srna na hranilištu 152
Slika 50. Divlja mačka na hranilištu 152
Slika 51. Divlje svinje na hranilištu 1 152
Slika 52. Lisica na hranilištu 152
Slika 53. Divlje svinje na hranilištu 2 153
Slika 54. Divlje svinje na hranilištu 3 153
Slika 55. Medvjed na hranilištu 153
Slika 56. Divlje svinje na hranilištu 4 153
Slika 57. Znak »divljač na cesti« (A44) 161
Slika 58. Znak dopunska ploča, (E01) 162
Slika 59. Znak dopunska ploča (E03) 162

POPIS TABLICA

Tablica 1. Struktura zemljišta u Ličko-senjskoj županiji 23
Tablica 2. Vrste kategorizirane ceste na kojima se dogodio nalet vozila na divljač u Ličko – senjskoj županiji 31
Tablica 3. Relativna odstrelna kvota krupne divljači na području Ličko-senjske županije i njen trend tijekom istraživanog razdoblja 51
Tablica 4. Relativna odstrelna kvota krupne divljači na području državnih cesta Ličko-senjske županije i njen trend tijekom istraživanog razdoblja 52
Tablica 5. Broj naleta vozila krupne divljači i sivog vuka na državnim cestama Ličko-senjske županije po dionicama tijekom razdoblja 2012. - 2016. te gustoća naleta 57
Tablica 6. Rezultati analize Kolmogorov-Smirnov testa za kumulativne frekvencije mjesečnih naleta krupne divljači na državnim cestama Ličko-senjske županije za razdoblje 2012. - 2016. 59
Tablica 7. Broj dionica u kojima nije zabilježen nalet te dionica s određenim brojem naleta vozila na srnu običnu 68
Tablica 8. . Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 250 m 69
Tablica 9. Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 500 m 70
Tablica 10. Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 1 000 metara 70
Tablica 11. Izbor modela varijabilnosti naleta na srnu običnu (0 ili 1) za ćelije polumjera 6 000 metara 71
Tablica 12. Vrijednost parametara za procjenu vjerojatnosti naleta vozila na srnu običnu dobivenih logističkom regresijom pri različitim polumjerima ćelija 73
Tabela 13. Izbor modela varijabilnosti broja naleta srne obične za ćelije polumjera 250 metara 74
Tabela 14. Izbor modela varijabilnosti broja naleta srne obične za ćelije polumjera 500 metara 75
Tablica 15. Izbor modela varijabilnosti broja naleta srne obične za ćelije polumjera 1 000 i 6 000 metara 76
Tablica 16. Rezultati analize broja naleta vozila na srnu običnu po dionici državnih cesta s obzirom na različite polumjere ćelija primjenom višestruke regresije 77

Tablica 17. Broj dionica u kojima nije zabilježen nalet te dionica s određenim brojem naleta vozila na divlju svinju 79
Tablica 18. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 250 metara 80
Tabela 19. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 500 metara 81
Tablica 20. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 1 000 metara 83
Tablica 21. Izbor modela varijabilnosti naleta na divlju svinju (0 ili 1) za ćelije polumjera 6 000 metara 84
Tabela 22. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 250 metara 85
Tablica 23. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 500 metara 86
Tablica 24. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 1 000 metara 87
Tablica 25. Izbor modela varijabilnosti broja naleta divlje svinje za ćelije polumjera 6 000 metara 88
Tablica 26. Rezultati analize broja naleta vozila na divlju svinju po dionici državnih cesta s obzirom na različite polumjere ćelija primjenom višestruke regresije 89
Tablica 27. Broj dionica u kojima nije zabilježen nalet te dionica s određenim brojem naleta vozila na krupne divlje životinje 91
Tablica 28. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 250 metara 92
Tablica 29. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 500 metara 93
Tablica 30. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 1 000 metara 95
Tablica 31. Izbor modela varijabilnosti naleta na sve vrste krupne divljači (0 ili 1) za ćelije polumjera 6 000 metara 96
Tablica 32. Vrijednost parametara za procjenu vjerojatnosti naleta vozila na krupnu divljač dobivenih logističkom regresijom pri različitim polumjerima ćelija 98
Tablica 33. Izbor modela varijabilnosti broja naleta svih vrsta krupne divljači za ćelije polumjera 250 metara 99

Tablica 34. Izbor modela varijabilnosti broja naleta svih vrsta krupne divljači za ćelije polumjera 500 metara 99
Tablica 35. Izbor modela varijabilnosti broja naleta svih vrsta krupne divljači za ćelije polumjera 1 000 i 6 000 metara 100
Tablica 36. Rezultati analize broja naleta vozila na krupnu divljač po dionici državnih cesta s obzirom na različite polumjere ćelija primjenom višestruke regresije 101
Tablica 37. Opis signifikantnih, s krajobraznim strukturama povezanih, pretkazivača naleta vozila na dvopapkara („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta) 119
Tablica 38. Opis signifikantnih, s krajobraznim strukturama povezanih, pretkazivača naleta vozila na zvijeri („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta) 122
Tablica 39. Opis signifikantnih pretkazivača naleta vozila na dvopapkare povezanih s parametrima ceste („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta) 123
Tablica 40. Opis signifikantnih pretkazivača naleta vozila na zvijeri povezanih s parametrima ceste („+“ = povećanje vjerojatnosti naleta; „-“ = snižavanje vjerojatnosti naleta) 125
Tablica 41. Broj opasne dionice i izbor kriterija za provedbu AHP metode 135

POPIS GRAFIKONA

Grafikon 1. Nalet vozila na divljač po kategorizaciji ceste u Ličko – senjskoj županiji 31
Grafikon 2. Broj stradalih parnoprstaša i dvojezubaca na cestama Ličko-senjske županije tijekom 5 godina praćenja, prema vrsti životinje i kategoriji ceste..... 33
Grafikon 3. Broj stradalih zvijeri na cestama Ličko-senjske županije tijekom 5 godina praćenja, prema vrsti životinje i kategoriji ceste..... 33
Grafikon 4. Promjene učestalosti boravka srneće divljači u pojedinoj kulturi s obzirom na udaljenost od ceste. 37
Grafikon 5. Promjene učestalosti boravka srneće divljači u pojedinoj kulturi s obzirom na udaljenost od ljudskih nastambi 37
Grafikon 6. Dnevni obrazac učestalosti naleta losa, bjelorepog jelena, vapitija i srne obične. 38
Grafikon 7. Devet različitih sezonskih obrazaca učestalosti naleta šest različitih vrsta divljih preživača..... 39
Grafikon 8. Godišnji hod trajanja dana i noći prema izlascima i zalascima sunca od 1. siječnja. do 31. prosinca za istraživani prostor. 44
Grafikon 9. Duljina cesta i brojevi naleta na jelene, srnu običnu i divlju svinju po nadmorskim visinama 54
Grafikon 10. Mjesečna dinamika naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije tijekom razdoblja (2012. - 2016.) 58
Grafikon 11. Kumulativna frekvencija mjesečne dinamike naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije tijekom razdoblja (2012. - 2016.)..... 59
Grafikon 12. Dnevne fluktuacije naleta vozila na srnu običnu tijekom godine..... 61
Grafikon 13. Godišnje fluktuacije u učestalosti naleta vozila na srnu običnu s obzirom na doba dana..... 61
Grafikon 14. Dnevne fluktuacije naleta vozila na jelena običnog tijekom godine 61
Grafikon 15. Godišnje fluktuacije u učestalosti naleta vozila na jelena običnog s obzirom na doba dana..... 61
Grafikon 16. Dnevne fluktuacije naleta vozila na divlju svinju tijekom godine..... 62
Grafikon 17. Godišnje fluktuacije u učestalosti naleta vozila na divlju svinju s obzirom na doba dana..... 62
Grafikon 18. Dnevne fluktuacije naleta vozila na krupne divlje životinje tijekom godine 63

Grafikon 19. Godišnje fluktuacije u učestalosti naleta vozila na krupne divlje životinje s obzirom na doba dana 63
Grafikon 20. Distribucija naleta krupnih divljih životinja tijekom noći u ovisnosti o mjesečevim mijenama 64
Grafikon 21. Distribucija naleta krupnih divljih životinja tijekom sumraka u ovisnosti o mjesečevim mijenama 64
Grafikon 22. Distribucija slučajeva modelom točno predviđenih naleta, podcijenjenih i precijenjenih naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije.103
Grafikon 23. Distribucija slučajeva modelom točno predviđenog broja naleta vozila na krupnu divljač na državnim cestama Ličko-senjske županije 106
Grafikon 24. Težinske vrijednosti kriterija 136
Grafikon 25. Rangiranje opasnih dionica od najmanje opasne do najopasnije dionice od pojave divljači na državnim cestama Ličko-senjske županije 137
Grafikon 26. Utjecaj kriterija na varijante 137

POPIS AKRONIMA

A1 – *Autocesta Zagreb-Split*

AIC – *Akaike Information Criterion*

BN_{DS} – *Ukupan broj naleta u ćeliji na divlju svinju*

BN_{SO} – *Ukupan broj naleta u ćeliji na srnu običnu*

BN_{uk} – *Ukupan broj naleta u ćeliji na krupnu životinju*

$Ceste_{\%}$ – *Udio cesta (%)*

CS – *Trošak površine*

CZ – *Koeficijent zavojitosti ceste u ćeliji*

DC – *Državana cesta*

DEM – *Digitalni elevacijski model*

Ds – *Divlja svinja*

Gb – *Giga bajt*

GIS – *Geografski informacijski sustav*

$Golet_{\%}$ – *Udio goleti (%)*

GPS – *Globalni položajni sustav*

Granice – *Duljina ekotona na 100 ha ćelije (km)*

HC – *Hrvatske ceste*

$Izgrađeno_{\%}$ – *Udio izgrađnog zemljišta (%)*

$Izvor_{m}$ – *Udaljenost do izvora (m)*

Khz – *Kiloherc*

Km – *Kilometar*

LC – *Lokalna cesta*

LSŽ – *Ličko-senjska županija*

M.n.v. - *Metar nadmorske visine*

$More_{\%}$ – *Udio mora (%)*

MUP – *Ministarstvo unutarnjih poslo*va

NAB – *Neprekidno automatsko brojenje prometa*

N_{DS} – *Događaj naleta u ćeliji na divlju svinju*

NP – *Nacionalni park*

N_{SO} – *Događaj naleta u ćeliji na srnu običnu*

N_{uk} – *Događaj naleta u ćeliji na krupnu životinjsku vrstu*

NVD – *Nalet vozila na divljač*

OS – *Okvirni sporazum održavanja i zaštite državnih cesta*

PAB – *Povremeno automatsko brojenje prometa*

PGDP – *Prosječni godišnji dnevni promet*

PLDP – *Prosječni ljetni dnevni promet*

PU – *Policijska uprava*

PULS – *Policijska uprava Ličko – senjska*

RH - *Republika Hrvatska*

ROK – *Relativna odstrelna kvota*

ROK_{DS} – *Relativna odstrelna kvota (grla/100 ha) divlje svinje*

ROK_{SO} – *Relativna odstrelna kvota (grla/100 ha) srne obične*

ROK_{uk} – *Relativna odstrelna kvota (grla/100 ha) krupne divljači*

SAD – *Sjedinjene Američke Dr*žave

So – *Srna obična*

ST_m – *Udaljenost do stajaćice ili tekućice (m)*

$Šume_{\%}$ – *Udio šuma (%)*

TPI ili TOPEX – *Indeks topografske pozicije*

$VB_{\%}$ – *Udio vriština i bujadnica (%)*

$Voćnjaci_{\%}$ – *Udio voćnjaka (%)*

$ZPZ_{\%}$ – *Udio zapuštenog poljoprivrednog zemljišta (%)*

ŽC – *Županijska cesta*

ŽUC – *Županijska uprava za ceste*

Wi – *Akaike-ova težina*

WVC – *Wildlife vehicle collision* (sudar divljih životinja i vozila)

PRILOZI

Prilog 1. Popis državnih cesta koje prolaze kroz Ličko-senjsku županiju

Izvor: [193]

Broj državne ceste koja prolazi kroz LSŽ	Dionice državne ceste koje prolaze kroz Ličko-senjsku županiju	Duljina Dionice (km)	Ukupna duljina državne ceste koja prolazi kroz LSŽ (km)
1	012 – Grabovac (D42) – Vrelo Koreničko (D52) 013 – Vrelo Koreničko (D52) – Mutilić: Čvorište Udbina (D522) 014-Mutilić: Čvorište Udbina (D522)- Gračac (D27)	22,978 33,160 11,578	67,716
8	006 – Kraljevica (D102/D523) – Senj (D23) 007 – Senj (D23) – Stinica (D405/L59148) 008 – Stinica (D405) – Prizna (D406) 009 – Prizna (D406) – Karlobag (D25) 010 – Karlobag (D25) – Starigrad-Paklenica (Ž6008)	6,610 36,670 12,960 13,120 31,843	101,203
23	002 – Josipdol (D42) – Jezerane (Ž5191) 003 – Jezerane (Ž5191) – Rapain Klanac (D50) 004 – Rapain Klanac (D50) – Senj (D8)	7,871 19,214 22,110	49,195
25	001 – Korenica (D1) – Lički Osik (D50) 002 – Lički Osik (D50) – Karlobag (D8)	36,617 47,056	83,673
42	002 – Munjava (D23) – Grabovac (D1) 001 – Žuta Lokva (D23) – Špilnik (D52)	7,517 21,467	7,517
50	002 – Špilnik (D52) – Lički Osik (D25) 003 – Gospić (D25) – Lovinac (Ž5165) 004 – Lovinac (Ž5165) – Gračac (D27)	34,423 31,989 15,192	103,071
52	001 – Špilnik (D50) – Korenica (D1)	41,086	41,086
106	001 – Žigljen (trajektna luka) – Novalja (Ž6274) 002 – Novalja (Ž6274) – Gorica (Ž6275)	7,970 1,250	9,220
217	001 – Ličko Petrovo Selo (D1)-Novo Selo Koreničko:GP Ličko Petrovo Selo (granica RH/BIH)	2,983	2,983
218	001 – Nebljusi: GP Užljebić (granica RH/BIH) – Dobroselo (Ž5203) 002 – Dobroselo (Ž5203) – Bruvno (D1)	30,009 8,690	38,699
405	001 – Stinica (trajektna luka) – D8	3,851	3,851
406	001 – D8 – Prizna (trajektna luka)	2,925	2,925
429	001 - Selište Drežničko (D42) – Prijeboj (D1)	13,296	13,296
522	001 – Mutilić (D1) – Gornja Ploča: čvor Gornja Ploča (A1)	13,368	13,368
534	001 – Gospić (D25) – Lički Osik: čvor Gospić (A1)	2,454	2,454
UKUPNO:		**540,257**	**540,257**

Prilog 2. Popis županijskih i lokalnih cesta u Ličko-senjskoj županiji

Izvor: [139]

	Broj ceste	Naziv ceste	duljina	asfalt	makadam
ŽC	5110	Klenovica (D8) – Krivi Put – Prokike (D23)	20,070	**20,070**	
ŽC	5111	Križ Kamenica (L59005) – Križpolje (D23)	2,660	**2,660**	
ŽC	5112	Stajnica (L59007) – Ž5113	3,000	**3,000**	
ŽC	5113	Križpolje (D23) – Glibodol – Lička Jasenica (D42)	20,600	**15,500**	**5,100**
ŽC	5114	Brinje (D23) – Letinac	7,800	**7,800**	
ŽC	5126	Sv. Juraj (D8) – Krasno Polje – A.G. Grada Gospića	49,500	**49,500**	
ŽC	5127	Hrvatsko Polje (L59013) – D50	4,400	**4,400**	
ŽC	5128	Ž5113 – Dabar – Glavace – Otočac (D50)	29,200	**29,200**	
ŽC	5129	Ž5128 – Škare (L59022)	3,500	**3,500**	
ŽC	5130	Doljani – Zalužnica (D52)	4,800	**4,800**	
ŽC	5140	Krasno Polje (Ž5126) – Švica – Otočac (D50)	22,100	**22,100**	
ŽC	5141	Ž5140 – Kuterevo (L59134)	3,100	**3,100**	
ŽC	5142	Ž5140 – Lipovlje (L59134)	3,500	**3,500**	
ŽC	5143	Otočac (D50) – Prozor (L59033)	4,600	**4,600**	
ŽC	5144	Podum (D52) – Čovići (D50)	4,800	**4,800**	
ŽC	5145	Ž5144 – Sinac (L59035)	1,100	**1,100**	
ŽC	5146	Ž5140 – D. Kosinj – Studenci – D50	32,500	**32,500**	
ŽC	5147	Ličko Lešće (D50) – Vrelo Gacke (L59036)	3,300	**3,300**	
ŽC	5148	D50 – Ramljani (L59041)	3,900	**3,900**	
ŽC	5149	Vrhovine (D52) – Gornje Vrhovine (L59039)	2,300	**2,300**	
ŽC	5151	Lun (L59046) – Novalja – D106	19,100	**19,100**	
ŽC	5152	Lipovo Polje (L59031) – Ž5153	6,200	**6,200**	
ŽC	5153	Bakovac Kosinjski (L59124) – G. Kosinj – Ž5146	9,460	**9,460**	
ŽC	5154	A.G. Grada Gospića – Perušić (D50)	7,140	**7,140**	
ŽC	5155	Kosa Janjačka (L59060) – Perušić (D50)	10,400	**10,400**	
ŽC	5156	Čanak (L59041) – Kozjan – Bunić (D25)	14,100	**3,460**	**10,640**
ŽC	5164	A.G. Grada Gospića – Podlapača – D1	22,340	**12,830**	**9,510**
ŽC	5165	A.G. Grada Gospića – G. Ploča – Lovinac (D50)	14,150	**14,150**	
ŽC	5166	D50 – Rok – Obrovac (D27)	17,300	**9,311**	**7,989**
ŽC	5167	Udbina (Ž5195) – D. Lapac (D218)	27,400	**13,072**	**14,328**
ŽC	5168	G. Lapac (D218) – Boricevac – gr. BiH	5,200	**2,797**	**2,403**
ŽC	5169	Bjelopolje (D1) – Donji Lapac (D218)	31,600	**31,600**	
ŽC	5170	Doljani (Ž5203) – gr. BiH	5,100	**1,400**	**3,700**
ŽC	5191	Lokve (D3) – Mrkopalj – Jezerane (D23)	7,000	**7,000**	
ŽC	5195	Udbina: D1 – D1	7,080	**7,080**	
ŽC	5196	Udbina: Ž5195 – D522	3,490	**3,490**	
ŽC	5199	Štirovača (Ž5126) – Šušanj (L59122)	29,450	**5,300**	**24,150**
ŽC	5203	Dobroselo (D218) – Donji Srb – Otrić (D1)	8,700	**8,700**	
ŽC	5210	Stara Novalja (trajektna luka) – D106	8,030	**8,030**	
LC	59001	Podbilo (Ž5110) – Senj (D8)	11,500	**11,500**	
LC	59002	L59001 – D23	6,700	**6,700**	
LC	59003	Krivi Put (Ž5110) – Vodoteč – Brinje (D23)	26,400	**12,431**	**13,969**
LC	59004	Krivi Put (Ž5110) – Grabova Lokva	5,600	**5,600**	
LC	59005	L59003 – Križ Kamenica (Ž5111)	3,200	**3,200**	
LC	59006	Brinje (D23) – Linarići	3,800	**3,800**	
LC	59007	Jezerane (D23) – Stajnica – Tominac Draga	9,500	**9,500**	
LC	59008	Senj: Vrataruša – L59001	1,700	**1,700**	

LC	59009	D23 – Stolac	4,900	**4,900**	
LC	59010	Biljevine – Ž5126	3,200	**3,200**	
LC	59011	D23 – Vratnik – D23	3,200	**3,200**	
LC	59012	D23 – Melnice – L59013	1,600	**1,600**	
LC	59013	D23 – Vrzići – Hrvatsko Polje (Ž5127)	12,000	**12,000**	
LC	59014	L59013 – Crni Kal – Đomine	5,100	**3,032**	**2,068**
LC	59015	Brinje (D23) – Hobari – Vučetići – Ž5114	8,900	**3,700**	**5,200**
LC	59016	Brlog (D50) – Drenov Klanac – Škare (Ž5129)	16,300	**16,300**	
LC	59017	L59016 – Kompolje (D50)	5,200	**5,200**	
LC	59018	Ž5127 – Kompolje (D50)	4,000	**4,000**	
LC	59019	D50 – Ponori	6,200	**6,200**	
LC	59020	Ž5128 – L59304	1,000		**1,000**
LC	59021	Ž5129 – Podum – D52	6,600	**6,600**	
LC	59022	Škare (Ž5129) – Ž5130	3,100	**1,000**	**2,100**
LC	59023	L59022 – Doljani (Ž5130)	1,800	**1,800**	
LC	59024	Ž5201 – Smoljanac – Rešetar – D1	11,600	**11,600**	
LC	59025	Ž5201 – Rastovača	2,000	**2,000**	
LC	59026	D1 – Donji Vaganac	1,000	**1,000**	
LC	59027	D1 – Ličko Petrovo Selo – Novo Selo Koreničko – Željava	2,800	**2,800**	
LC	59028	Lukovo – D8	2,800	**2,800**	
LC	59029	Dulibe (L59133) – Vukelići – Anići – Krasno Polje (Ž5126)	5,300	**1,800**	**3,500**
LC	59031	Ž5146 – Lipovo Polje (Ž5152)	9,200	**9,200**	
LC	59032	Luka (Ž5143) – Obilje – Orešković Most – Prozor (L59033)	5,400	**4,038**	**1,362**
LC	59033	D50 – Prozor – Čovići (D50)	4,200	**4,200**	
LC	59034	D50 – Staro Selo – D52	9,100	**5,089**	**4,011**
LC	59035	Sinac – L59036	6,600	**6,600**	
LC	59036	Ž5147 – Ramljani (Ž5148)	3,800	**3,800**	
LC	59037	Želj. Kolodvor Rudopolje – Rudopolje – D52	4,800	**4,800**	
LC	59038	D52 – Donji Babin Potok – D52	2,600	**2,600**	
LC	59039	Gornje Vrhovine (Ž5149) – Turjanski	7,700	**7,700**	
LC	59040	L59039 – L59041	5,100	**0,306**	**4,794**
LC	59041	Ramljani (Ž5148) – Čanak (Ž5156)	12,100	**12,100**	
LC	59042	Trnavac – D52	5,500	**5,500**	
LC	59043	D52 – Krbavica – D25	12,400	**4,682**	**7,718**
LC	59045	D1 – Mihaljevac – Korenica (D1)	4,830	**4,830**	
LC	59046	Tovernale – Lun (Ž5151)	2,200	**2,200**	
LC	59047	D405 – Jablanac – D405	4,990	**4,990**	
LC	59048	Zavrtnica – D8	1,500	**1,500**	
LC	59052	Ž5146 – Mlakva – T.L. »Kruščica«	6,000	**6,000**	
LC	59054	Ž5154 – Kaluđerovac – Ž5154	2,100	**2,100**	
LC	59055	Ž5146 – Perušić (D50)	6,400	**6,400**	
LC	59056	Mezinovac – L59055	2,400	**2,400**	
LC	59057	Malo Polje – Ž5154	1,600	**1,600**	
LC	59058	Ž5154 – A.G. Grada Gospića	0,810	**0,810**	
LC	59059	Krš (Ž5146) – D50	3,800	**3,800**	
LC	59060	D50 – Kosa Janjačka (Ž5155)	9,000	**9,000**	
LC	59061	Konjsko Brdo – Perušić (L59146)	2,290	**2,290**	
LC	59062	Perušić (L59146) – Bukovac Perušićki	3,980	**3,980**	
LC	59063	D25 – L59065	12,000	**2,043**	**9,957**
LC	59064	D25 – Debelo Brdo – D1	7,700	**7,700**	
LC	59065	Bunić (D25) – Krbava – Podlapača – Ž5164	15,000	**15,000**	
LC	59066	Korenica (D1) – Šeganovac – L59067	2,980	**1,352**	**1,628**
LC	59067	Gradina Korenička (D1) – Šeganovac (L59066)	2,920	**2,920**	
LC	59068	Gradina Korenička (D1) – Oravac	1,290	**0,850**	**0,440**
LC	59069	Tuk Bjelopoljski – D1	1,900		**1,900**
LC	59070	Grabušić – D1	2,700	**1,015**	**1,685**

LC	59071	D1 – Frkašić (Ž5169)	6,100	**1,000**	**5,100**
LC	59072	Gr. BiH – Melinovac – D218	6,700	**0,334**	**6,366**
LC	59073	Nebljusi (D218) – Kestenovac – L59075	9,100	**9,100**	
LC	59074	L59073 – Donji Štrbci	4,000	**0,500**	**3,500**
LC	59075	Kruge (D218) – gr. BiH	10,300	**2,500**	**7,800**
LC	59076	L59075 – Birovača (D218)	11,700	**2,841**	**8,859**
LC	59077	Novalja (D106) – Zubovići – Metajna	10,600	**10,600**	
LC	59098	L59065 – Tolić – Ž5164	6,900	**6,900**	
LC	59099	Ž5164 – Kurjak – Ž5166	12,800	**8,666**	**4,134**
LC	59100	D1 – Visuć (Ž5167)	6,820	**5,660**	**1,160**
LC	59101	Udbina (D1) – D1	3,600	**1,401**	**2,199**
LC	59102	D218 – Ž5169	4,300	**4,300**	
LC	59103	Ž5167 – Oraovac – Ž5167	5,000	**5,000**	
LC	59104	L59076 – Mišljenovac	0,400	**0,166**	**0,234**
LC	59105	Gornji Lapac – D218	0,900	**0,900**	
LC	59106	Ž5168 – Doljani (Ž5203)	13,400	**0,805**	**12,595**
LC	59110	A.G. Grada Gospića – Ž5165	5,440	**2,779**	**2,661**
LC	59111	L59110 – Kik – Ž5165	5,700	**0,032**	**5,668**
LC	59112	D522 – Komić	2,700	**2,700**	
LC	59113	Ž5165 – Lovinac – D50	14,000	**9,100**	**4,900**
LC	59114	Lovinac (Ž5165) – Tomingaj (L59117)	10,000	**3,220**	**6,780**
LC	59115	L59114 – L59113	3,700	**3,700**	
LC	59116	D50 – Rok – Poljana – Ž5166	18,490	**18,490**	
LC	59117	D1 – Tomingaj – Gračac (L63030)	1,500		**1,500**
LC	59118	D218 – Zaklopac – Donja Suvaja (L63011)	3,290	**0,050**	**3,240**
LC	59119	Brezovac Dobroselski – L59118	1,600		**1,600**
LC	59120	Ličko Cerje (D50) – L59116	0,900	**0,900**	
LC	59121	Ričice (D50): naselje – naselje	1,630	**1,630**	
LC	59122	Ledenik – D25	3,270	**3,270**	
LC	59123	D25 – Konjsko	2,800	**2,800**	
LC	59124	Ž5126 – Bakovac Kosinjski(Ž5153)	13,600	**4,214**	**9,386**
LC	59125	Kosa Janjačka(Ž5155) – Čanak (Ž5156)	6,100	**6,100**	
LC	59132	Ž5110 – Veljun – D23	9,500	**9,500**	
LC	59133	Oltari (Ž5126) – Zavižan (NP »Sjeverni Velebit«)	16,000	**9,500**	**6,500**
LC	59134	Kuterevo (Ž5141) – Lipovlje (Ž5142)	6,500	**6,500**	
LC	59136	Gornji Vaganac – D1	1,400	**1,400**	
LC	59137	Jagodnje – Podlapača (L59065)	4,800	**4,800**	
LC	59138	Ćojluk – Udbina (D1)	2,500	**2,081**	**0,419**
LC	59139	Dugi Do – Vrhovine (D52)	3,800	**3,800**	
LC	59140	Željeznički kolodvor Vrhovine – Vrhovine (D52)	0,400	**0,400**	
LC	59141	Ćepaćuše (D218) – željeznički kolodvor Loskun	5,300		**5,300**
LC	59142	Prpići – Varoš (D50)	1,100	**1,100**	
LC	59143	D50 – Potkosa – Gudura	1,300	**1,300**	
LC	59144	Vagan – L59113	0,800	**0,800**	
LC	59146	Perušić: D50 – Ž5155	0,900	**0,900**	
LC	59148	Jablanac (D8) – Bileni – Štirovača (Ž5126)	25,200	**18,080**	**7,120**
LC	59149	Dolac – Karlobag (D25)	0,600	**0,600**	
UKUPNO ŽUPANIJSKE CESTE			**479,970**	**402,150**	**77,820**
UKUPNO LOKALNE CESTE			**651,330**	**482,977**	**168,353**
SVEUKUPNO ŽUPANIJSKE + LOKALNE CESTE			**1 131,300**	**885,127**	**246,173**

Prilog 3. Anketni listić

ANKETNI LISTIĆ							
NALET VOZILA NA DIVLJAČ							
DA LI STE U VAŠEM LOVIŠTU IMALI NALET VOZILA NA DIVLJAČ (Zaokružiti)							**DA - NE**
Ukoliko je odgovor DA, molimo Vas da ispunite slijedeća pitanja:							
Redni broj	**Datum nastanka prometne nesreće**	**Vrijeme nastanaka prometne nesreće**	**Vrsta i broj ceste**	**Posljedice prometne nesreće**	**Vrsta stradale divljači**	**Da li je obavljen policijski očevid**	**Da li je nalet uzrokovao smrt divljači**
1.							
2.							
3.							
4.							
5.							
6.							
7.							
8.							
9.							
10.							
Da li je hitno potrebno rješavanje problema naleta vozila na divljač (Zaokružiti)							**DA - NE**
ANKETA SE PROVODI ZA POTREBE IZRADE DOKTORSKOG RADA							

ŽIVOTOPIS

Joso Vrkljan je rođen 24. svibnja 1976. godine u Gospiću, od oca Ivana i majke Mande. Oženjen je, otac dvoje djece. U Gospiću je 1991. godine završio osnovnu školu, a maturirao je 1995. godine u Općoj gimnaziji Gospić.

Više stupnjeve obrazovanja stjecao je na Fakultetu prometnih znanosti Sveučilišta u Zagrebu, cestovni smjer gdje je 1998. godine stekao višu stručnu spremu i stručni naziv inženjera prometa, a 2002. godine visoku stručnu spremu i stručni naziv diplomiranog inženjera prometa. Na Fakultetu prometnih znanosti Sveučilišta u Zagrebu akademski stupanj magistra znanosti iz znanstvenog područja tehničkih znanosti, znanstvenog polja tehnologija prometa i transport, znanstvena grana cestovni i željeznički promet stekao je 2010. godine. Na poslijediplomskom doktorskom studiju Fakulteta prometnih znanosti Sveučilišta u Zagrebu doktorirao je 15. srpnja 2020. godine, ocjenom *summa cum laude* i stekao akademski stupanj doktora znanosti (tema doktorskog rada: „ *Model prepoznavanja opasnih dionica na javnim cestama u područjima učestale pojave divljači*“) pod mentorstvom izv. prof. dr. sc. Dubravke Hozjan sa Fakulteta prometnih znanosti Sveučilišta u Zagrebu i prof. dr. sc. Krešimira Krapineca sa Šumarskog fakulteta Sveučilišta u Zagrebu.

Prilikom reguliranja vojne obaveze pohađao je i Školu za pričuvne časnike Hrvatske vojske u Zagrebu, gdje je stekao zvanje zapovjednika prometnog voda i časnički čin hrvatske vojske poručnika u pričuvi. Sudjelovao je na II. svjetskim vojnim igrama u Hrvatskoj, kao jedan od zapovjednika sektora za promet.

Član je Hrvatske udruge diplomiranih inženjera Fakulteta prometnih znanosti Sveučilišta u Zagrebu „AMAC-FSC“, Hrvatskog kinološkog saveza i Hrvatskog lovačkog saveza. Član je upravnog odbora Matice hrvatske, ogranka Gospić.

Ovlašteni je ispitivač i predavač u Školi Hrvatskog lovačkog saveza za izobrazbu lovaca i lovočuvara. Lovnokinološki je sudac za rad i oblik lovačkih pasa. Ima položen lovački, lovočuvarski i ispit za ocjenjivača trofeja divljači. Član je skupštine Lovačkog saveza Ličko-senjske županije. Za svoj rad na polju lovstva nagrađivan je najvišim lovačkim odlikovanjima.

Aktivan je i u humanom radu. Za vrijeme Domovinskog rata dragovoljno se aktivirao kao maloljetni aktivist crvenog križa u Gospiću, te je za svoje zasluge nagrađen Jubilarnom zahvalnicom Hrvatskog crvenog križa. Jedan je od osnivača Dobrovoljnog vatrogasnog

društva Pazarište, a trenutno obnaša funkciju člana upravnog odbora istog društva. Za svoj rad u vatrogastvu nagrađen je mnogobrojnim vatrogasnim priznanjima, kao i vatrogasnom spomenicom.

Radno iskustvo stjecao je obavljajući različite poslove od rada u obrtništvu (vlasnik obrta) do rada u društvu kapitala za održavanje i građenje cesta Lika ceste d.o.o. iz Gospića. Na polju obrtništva aktivan je u udruženju obrtnika Gospić, gdje je više puta biran za člana upravnog odbora do zamjenika predsjednika Udruženja, što mu je i trenutna funkcija. U Obrtničkoj komori Ličko-senjske županije obnašao je funkciju predsjednika nadzornog odbora, a trenutno je član upravnog odbora i skupštine Obrtničke komore Ličko-senjske županije.

Zaposlen je u društvu kapitala za održavanje i građenje cesta Lika ceste d. o. o. iz Gospića, gdje je obavljao niz rukovodećih funkcija, a među njima bio je i predsjednik radničkog vijeća, član nadzornog odbora, zamjenik predsjednika nadzornog odbora, te i direktor društva kapitala. Radi i kao stručni suradnik na Veleučilištu Nikola Tesla u Gospiću na studiju cestovni promet, te je izabran za nastavnika u naslovnom nastavnom zvanju predavač na području tehničkih znanosti, polje tehnologija prometa i transport.

Autor i koautor je brojnih članaka, objavljenih u znanstvenim i stručnim časopisima i skupovima. Kao koautor sudjelovao je u izradi monografije „Lovačko društvo Lika Gospić 1926. - 2016.“. Autor je monografije naslova „70 godina uspjeha - Lovačko društvo Tetrijeb Pazarište 1947. - 2017.“.

Javno priznanje Grada Gospića dobio je 2020. godine za vrijedan doprinos visokoškolskom obrazovanju i razvoju lovstva na području Grada Gospića kroz izdavanje stručnih i znanstvenih publikacija.

Znanstveni interes usmjerio je na unapređenje i poboljšanje sustava održavanja javnih cesta u Ličko-senjskoj županiji, kao i na primjenu novih tehnologija održavanja cesta, sigurnosti prometa, te rješavanje problematike naleta vozila na divljač.

Uključen je u istraživanja na Fakultetu prometnih znanosti, Sveučilišta u Zagrebu na stručnom projektu naziva „ Mjerenje kakvoće prijenosa pismovnih pošiljaka u unutarnjem prometu“ i na znanstvenom projektu naziva „Višekriterijska analiza rizičnog ponašanja korisnika željezničko - cestovnih prijelaza“.

POPIS OBJAVLJENIH RADOVA I KNJIGA

Znanstveni radovi u časopisima

1. Bago, D.; Puškarić, N.; Vrkljan, J.
   Organization of passenger transport in town of Zaprešić by harmonizing operator services
   Promet-Traffic&Transportation, 6; 413 - 421, 2006.

2. Vrkljan, J.; Hozjan, D.; Barić, D.; Ugarković, D.; Krapinec, K.
   Temporal Patterns of Vehicle Collisions with Roe Deer and Wild Boar in the Dinaric Area
   Croatian journal of forest engineering, 41, 2; 347 - 358, 2020.

Pregledni radovi u časopisima

1. Vrkljan, J.; Mustapić, M.; Štimac, A.
   Ekspertni pristup poboljšanju sigurnosti u zonama radova na cesti
   Sigurnost : časopis za sigurnost u radnoj i životnoj okolini, 3; 247 - 260, 2018.

Znanstveni radovi u postupku objavljivanja

1. Mustapić, M.; Vrkljan, J.; Jeleč, V.
   Research on Influence of Roadside Billboards on Cognitive Workload of Young Drivers and Traffic Safety
   Tehnički vjesnik : znanstveno-stručni časopis tehničkih fakulteta Sveučilišta u Osijeku, 2020.

Znanstveni radovi u zbornicima skupova

1. Aščić, I.; Vrkljan, J.; Vukadin, D.
   Prepaid cards as a means of sales promotion in the transport sector
   International conference on transport science, Portorož: ICTS, 1 - 8, 2011.

2. Mustapić, M.; Vrkljan, J.; Štimac, A.
   Marketing in traffic safety
   Transport market: Intermodality & Liberalisation, Zagreb: POWA, 1 - 6, 2011.

3. Mustapić, M.; Vrkljan, J.; Štimac, A.
   Influence of marketing in traffic safety
   Towards a human city**,** Novi Sad: International conference 2011, 303 - 307, 2011.

4. Aščić, I.; Vukadin, D.; Vrkljan, J.
   Utjecaj cestovnih poštanskih vozila na održivi okoliš u gradovima
   Automatizacija u prometu 2011**,** Pula/Milano: KOREMA, 13 - 17, 2011.

Sažeci sa skupova

1. Burazer Pavešković, J.; Čačić, M.; Vrkljan, J.
   3D monitoring u procesu projektiranja cestovnih prometnica
   Ceste 2020, Rovinj : Tom signal, 2020.

Autorske knjige (monografije)

1. Sokolić, M.; Grospić, F.; Mataija, I.; Došen, A.; Stilinović, M.; Vrkljan, J.; Ugarković, M.; Alić, M.
   Lovačko društvo Lika Gospić 1926. - 2016.
   Gospić, Državni arhiv u Gospiću, 2016.

2. Vrkljan, J.
   70 godina uspjeha - Lovačko društvo „Tetrijeb“ Pazarište 1947. - 2017.
   Gospić, Lovačko društvo „Tetrijeb“ Pazarište, 2017.