

Razvoj sustava za procjenu ugroženosti od odrona duž željezničkih pruga u karbonatnim stijenama u Republici Hrvatskoj

Bostjančić, Iris

Doctoral thesis / Disertacija

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mining, Geology and Petroleum Engineering / Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:169:293509>

Rights / Prava: [Attribution-NonCommercial-NoDerivatives 4.0 International](#)/[Imenovanje-Nekomercijalno-Bez prerada 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2024-04-20**



Repository / Repozitorij:

[Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb](#)





Sveučilište u Zagrebu

Rudarsko-geološko-naftni fakultet

Iris Bostjančić

**RAZVOJ SUSTAVA ZA PROCJENU
UGROŽENOSTI OD ODRONA
DUŽ ŽELJEZNIČKIH PRUGA
U KARBONATNIM STIJENAMA
U REPUBLICI HRVATSKOJ**

DOKTORSKI RAD

Zagreb, 2016.



Sveučilište u Zagrebu

Rudarsko-geološko-naftni fakultet

Iris Bostjančić

**RAZVOJ SUSTAVA ZA PROCJENU
UGROŽENOSTI OD ODRONA
DUŽ ŽELJEZNIČKIH PRUGA
U KARBONATNIM STIJENAMA
U REPUBLICI HRVATSKOJ**

DOKTORSKI RAD

Mentori:

Dr. sc. Petar Hrženjak

Dr. sc. Davor Pollak

Zagreb, 2016.



University of Zagreb

Faculty of mining, geology and petroleum engineering

Iris Bostjančić

**DEVELOPMENT OF ROCKFALL
THREAT ASSESSMENT SYSTEM
ALONG RAILWAYS
IN CARBONATE ROCKS
IN THE REPUBLIC OF CROATIA**

DOCTORAL THESIS

Supervisors:
Ph. D. Petar Hrženjak
Ph. D. Davor Pollak

Zagreb, 2016.

Mentori:

Dr.sc. Petar Hrženjak

Izvanredni profesor pri Rudarsko-geološko-naftnom fakultetu

Dr.sc. Davor Pollak

Viši znanstveni suradnik pri Hrvatskom geološkom institutu

mami i tati,

*koji podržavaju sve moje životne odluke
pa tako i onu o odabiru mojeg zanimanja...*

Od srca zahvaljujem svima koji su na bilo koji način doprinijeli izradi ovog rada!

...mentoru dr. sc. Petru Hrženjaku, na prihvaćanju mentorstva, dobronamjernim primjedbama i prijedlozima koji su poboljšali kvalitetu rada,

...mentoru dr. sc. Davoru Pollaku, na usmjeravanju, prenesenom znanju i brojnim konstruktivnim savjetima tijekom izrade rada, a posebno na prijateljstvu i velikoj podršci od mog dolaska u Institut,

...dr. sc. Dariu Perkoviću, dr. sc. Rajni Rajić i dr. sc. Renatu Buljanu na korisnim sugestijama i pregledu rada u kratkom vremenskom roku,

...predstojniku Zavoda za hidrogeologiju i inženjersku geologiju Hrvatskog geološkog instituta dr.sc. Josipu Terziću i voditelju projekta u sklopu kojeg sam zaposlena dr.sc. Renatu Buljanu, na razumijevanju,

...inženjercima koji su sudjelovali u prikupljanju podataka tijekom inženjerskogeološke prospekcije: Renatu, Draženu, Davoru, Tihaču, Laciju i Tomi,

...svim kolegama iz Instituta, a posebno: Draženu, na pomoći kod definiranja teme rada i brojnim savjetima, te cimerima Vlatku i Laciju, Tihaču, Hrvoju i Mariu, koji su radnu atmosferu učinili ljepšom,

...djelatnicama HŽ infrastrukture Regionalnih jedinica održavanja Ogulin i Rijeka, gđi Josipi Biondić Atanasovski, gđi Zorici Pavelić i gđi Dubravki Supićić, na suradnji,

...svojoj obitelji, na tome što je baš takva kakva je,

...svojim najdražim dečkima: Juraju, na iznimnom povjerenju i visokom pragu tolerancije i Andreju, koji će sigurno prolistati cijeli rad ne bi li na nekoj slici pronašao barem jedan vlak ;)

Odroni su kao geološki hazard posebno značajni uz ceste i željezničke pruge. Kako bi se njihovu upravljanju pristupilo proaktivno, nužna je standardizirana metoda kojom je moguće međusobno usporediti kosine i na logičan način izdvojiti one koje predstavljaju prioritet za sanaciju. Za njezino provođenje potrebno je odabrati relevantne parametre i način njihovog vrednovanja, a oni se u sklopu doktorskog rada temelje na nekoliko verzija postojećeg *Rockfall Hazard Rating System*-a. Pri tome je glavni cilj istraživanja usmjeren na njegovu prilagodbu kosinama izvedenim uz željezničku prugu u karbonatnim stijenama Hrvatske.

Sustav se temelji na eksponencijalnom bodovanju inženjerskogeoloških i klimatskih značajki koje utječu na mogućnost pojave odrona, te geometrijskih značajki kosine koje utječu na mogućnost da odlomljeni materijal dosegne prugu. Podaci o svim značajkama prikupljeni su jednostavnim opažanjima tijekom inženjerskogeološke prospekcije. Analizirano je 366 segmenata kosina koje su prostorno smještene u području Krških Dinarida i generalno obuhvaćaju područje od Rijeke, preko Gorskog Kotara i Like, do Splita.

Prema odabiru parametara i načinu njihovog vrednovanja definirano je 16 bodovnih modela. Za svaki od njih provedena je klasifikacija kosina koja se temelji na kombinaciji klasa prema ukupnom broju bodova i klasa prema odnosu bodova parametara uzroka i posljedice. Konačni rezultat predstavlja jedna od četiri definirane klase kosine prema ugroženosti od odrona.

Najprikladniji bodovni model prema uvjetima na istraživanom području odabran je na temelju rezultata verifikacije provedene s tri seta podataka. Oni uključuju preliminarnu procjenu, stabilnost kosina definiranu prema Regionalnim jedinicama održavanja i tragove odrona. Za odabrani model provedene su statističke analize linearne i logističke regresije. One su omogućile određivanje statistički značajnih parametara za svaki korak razrađene metodologije procjene ugroženosti od odrona, kao i optimizaciju bodovnog modela.

U sklopu doktorskog rada razrađeni su elementi za razvoj sustava ugroženosti od odrona koji predstavlja prvi korak u cjelovitom upravljanju hazardima i rizicima od odrona.

Ključne riječi: odron, procjena ugroženosti, klasifikacija kosina, *Rockfall Hazard rating System* (RHRS), karbonatne stijene, željeznička pruga

Rockfalls, as a type of geological hazard, are especially important along the roads and railways. In terms of proactive management approach, it is necessary to standardize a method which allows comparison between slopes and logical separation of those that represent a priority for remediation. For its implementation, selection of the relevant parameters and the manner of their rating is required. In this doctoral dissertation they are based on several versions of existing *Rockfall Hazard Rating System*. However, the main aim of the research is focused on system modification to the slopes along railways in carbonate rocks of Croatia.

The system is based on an exponential scoring of engineering geological (EG) and climatic characteristics that affect the rockfall potential, and geometric features of slopes that affect the possibility that the material reaches the railway. Data about all these features is collected within a simple observation during EG prospecting. A total of 366 segments of slopes have been analysed. They are spatially located in the Karst Dinarides of Croatia, generally including the area from Rijeka, through the Gorski Kotar area and Lika, to Split.

According to the selection parameters and their ratings, 16 scoring models are defined. For each of them, the slope classification is conducted, based on the combination of classes of the total scores of all parameters and classes of the relation between the scores for causes and consequences. The final result represents one of the four defined slope classes according to rockfall threat.

The most appropriate scoring model was chosen based on the results of the verification carried out with three sets of parameters. They include information of the preliminary rating, slope stability defined by the Regional Maintenance Administration and traces of rockfall. For the selected model statistical analysis of linear and logistic regression are performed. They enabled the determination of statistically significant parameters for assessing the rockfall threat, as well as the optimization of the scoring model.

The main elements for the development of rockfall threat system are elaborated. Those represent the first step in the comprehensive rockfall hazard and risk management.

Keywords: rockfall, threat assessment, slope classification, *Rockfall Hazard Rating System (RHRS)*, carbonate rocks, railway

Sažetak.....	i
Abstract.....	ii
Sadržaj.....	iii
Popis slika.....	v
Popis tablica	vii
1. UVOD.....	1
1.1. CILJEVI I HIPOTEZE ISTRAŽIVANJA.....	3
2. TEORIJSKE OSNOVE	4
3. DOSADAŠNJA ISTRAŽIVANJA	14
3.1. PROCJENA HAZARDA OD ODRONA (<i>RHRS</i>).....	15
3.1.1. Upotreba <i>RHRS</i> -a i njegove modifikacije	18
3.2. SUSTAVI PROCJENE OPASNOSTI ODRONA U HRVATSKOJ.....	21
4. PODRUČJE ISTRAŽIVANJA	22
4.1. GEOGRAFSKE I KLIMATOLOŠKE ZNAČAJKE.....	24
4.2. GEOLOŠKE I GEOMORFOLOŠKE ZNAČAJKE	28
4.3. INŽENJERSKOGEOLOŠKE ZNAČAJKE KARBONATNE STIJENSKE MASE	32
5. METODE PRIKUPLJANJA I OBRADJE PODATAKA	37
5.1. INŽENJERSKOGEOLOŠKA PROSPEKCIJA	42
5.1.1. Preliminarna procjena	44
5.1.2. Detaljna procjena	47
5.2. INVENTAR KOSINA	62
6. PROCJENA UGROŽENOSTI OD ODRONA.....	65
6.1. VREDNOVANJE KLASIFIKACIJSKIH PARAMETARA.....	66
6.1.1. Vrednovanje inženjerskogeoloških značajki	67
6.1.2. Vrednovanje klimatskih značajki.....	69
6.1.3. Vrednovanje geometrijskih značajki	69

6.2. BODOVNI MODELI	71
6.3. METODOLOGIJA KLASIFIKACIJE KOSINA PREMA UGROŽENOSTI OD ODRONA	72
6.4. METODOLOGIJA VERIFIKACIJE BODOVNIH MODELA	75
6.4.1. Preliminarna procjena	77
6.4.2. Stabilnost kosina	77
6.4.3. Tragovi odrona	78
6.5. REZULTATI KLASIFIKACIJE I VERIFIKACIJE	79
6.6. NAJPRIKLADNIJI BODOVNI MODEL ZA UVJETE NA ISTRAŽIVANOM PODRUČJU	83
6.7. PRIKAZ PROCJENE UGROŽENOSTI OD ODRONA	92
6.7.1. Primjer za kosinu A klase prema ugroženosti od odrona - 202-61-D	92
6.7.2. Primjer za kosinu D klase prema ugroženosti od odrona - 604-7-D	96
7. STATISTIČKE ANALIZE	101
7.1. LINEARNA REGRESIJA	104
7.1.1. Rezultati linearne regresije	108
7.2. LOGISTIČKA REGRESIJA	113
7.2.1. Rezultati logističke regresije	116
8. RASPRAVA	120
8.1. KLASIFIKACIJSKI PARAMETRI I NJHOVO BODOVANJE	120
8.2. KLASIFIKACIJA KOSINA PREMA UGROŽENOSTI OD ODRONA	124
8.3. STATISTIČKE ANALIZE I OPTIMIZACIJA BODOVNOG MODELA	136
8.4. OGRANIČENJA SUSTAVA I PREPORUKE ZA POBOLJŠANJE	146
9. ZAKLJUČAK	152
LITERATURA	158
ŽIVOTOPIS	169
PRILOG 1.	171

Popis slika

SLIKA 2-1. OSNOVNI TIPOVI ODRONA KORIŠTENI U DOKTORSKOM RADU (MODIFICIRANO PREMA MAULDON ET AL., 2007)	5
SLIKA 2-2. RAVNINSKI SLOM (502-11-D)	7
SLIKA 2-3. KLINASTI SLOM (202-56-3-D)	7
SLIKA 2-4. PREVRTANJE: A) 502-12-L; B) 604-25A-D	8
SLIKA 2-5. OBRUŠAVANJE (202-66-1-D)	9
SLIKA 2-6. OSIPAVANJE (202-67-D)	10
SLIKA 2-7. OSIPAVANJE VEZANO UZ RAZLOMLJENE ZONE: A) 202-16-L; B) 202-61-D	10
SLIKA 2-8. DIFERENCIJALNO TROŠENJE (202-19-1-D)	11
SLIKA 2-9. CJELOVITI PROCES UPRAVLJANJA RIZIKOM (PREMA FELL ET AL., 2005)	13
SLIKA 4-1. PREGLED LOKACIJA NA KOJIMA JE PROVEDENA INŽENJERSKOGEOLOŠKA PROSPEKCIJA	23
SLIKA 4-2. KARTA SREDNJE GODIŠNJE TEMPERATURE ŠIREG PODRUČJA ISTRAŽIVANJA (PREMA ZANINOVIĆ ET AL., 2004)	26
SLIKA 4-3. KARTA SREDNJIH GODIŠNJIH OBORINA ŠIREG PODRUČJA ISTRAŽIVANJA (PREMA GAJIĆ-ČAPKA ET AL., 2003)	27
SLIKA 4-4. PREGLEDNA GEOLOŠKA KARTA ŠIREG PODRUČJA ISTRAŽIVANJA (PREMA HGI, 2009; OSNOVNA GEOLOŠKA KARTA, 1:300.000)	30
SLIKA 4-5. KONTAKT FLIŠNIH NASLAGA I KARBONATNE STIJENE (604-133-L)	31
SLIKA 4-6. MORFOLOŠKI FENOMENI KRŠA I NJIHOVE ZNAČAJKE (PREMA WALTHAM & FOOKES, 2003)	34
SLIKA 4-7. POVRŠINSKA I GORNJA ZONA TROŠENJA (604-85-L)	36
SLIKA 4-8. GORNJA ZONA TROŠENJA (604-60-L)	36
SLIKA 5-1. DIJAGRAM TOKA ZA 1. SEGMENT ISTRAŽIVANJA - PRIKUPLJANJE PODATAKA	38
SLIKA 5-2. TERENSKI FORMULAR KORIŠTEN TIJEKOM IG PROSPEKCIJE	41
SLIKA 5-3. INŽENJERSKOGEOLOŠKA PROSPEKCIJA: A) MJERENJE <i>VISINE</i> ; B) MJERENJE <i>VELIČINE BLOKA</i>	43
SLIKA 5-4. PRELIMINARNA PROCJENA - KLASA A (604-11-D)	45
SLIKA 5-5. PRELIMINARNA PROCJENA - KLASA B (502-20-D)	46
SLIKA 5-6. PRELIMINARNA PROCJENA - KLASA C (604-99-D)	46
SLIKA 5-7. VIZUALNI PRIKAZ (LINIJSKI I TOČKASTI) GRANIČNIH VRIJEDNOSTI KLASA PARAMETRA <i>IZRAŽENOST</i> (PREMA MAULDON ET AL., 2007): A) 10 %; B) 20 %; C) 30 %; D) 40 %	48
SLIKA 5-8. PROCJENA PARAMETRA <i>IZRAŽENOST</i> : A) KLASA I (604-56-L); B) KLASA IV (202-11-D)	49
SLIKA 5-9. PROCJENA PARAMETRA <i>VELIČINA BLOKA</i> : A) DOMINANTNA I MAKSIMALNA VELIČINA BLOKA (604-13-L); B) VOLUMEN POTENCIJALNO NESTABILNOG MATERIJALA (202-55-2-L)	51
SLIKA 5-10. PROCJENA PARAMETRA <i>OKRŠENOST</i> - KLASA IV (202-51-1-L)	55
SLIKA 5-11. KLASA PARAMETRA <i>VISINA</i> : A) KLASA I: NISKA KOSINA (604-30-L); B) KLASA II: SREDNJE VISOKA KOSINA (502-25-L); C) KLASA III: VISOKA KOSINA (202-70-D); D) KLASA IV: VRLO VISOKA KOSINA (604-90-L)	58
SLIKA 5-12. SIMULACIJA ODRONA POMOĆU ROCFALL SOFTVERA - ODREĐIVANJE MAKSIMALNE UDALJENOSTI ODLOMLJENIH BLOKOVA	59

Slika 5-13. PROCJENA PARAMETRA <i>RAZVEDENOST</i> : A) KLASA I (604, 95-D); B) KLASA II (604, 19-D); C) KLASA III (502-19-D); D) KLASA IV (202-59-L).....	62
Slika 5-14. INVENTAR KOSINA - PRIKAZ FORME ZA UNOS PODATAKA U BAZU	63
Slika 6-1. DIJAGRAM TOKA ZA 2. SEGMENT ISTRAŽIVANJA - PROCJENA UGROŽENOSTI OD ODRONA	66
Slika 6-2. DVA NAČINA VREDNOVANJA PARAMETRA <i>VISINA</i>	71
Slika 6-3. KLASIFIKACIJA KOSINA PREMA U-P ODNOSU	74
Slika 6-4. SHEMA POLJA ZA VERIFIKACIJU.....	76
Slika 6-5. VERIFIKACIJA PREMA PARAMETRU <i>PRELIMINARNA PROCJENA</i>	81
Slika 6-6. VERIFIKACIJA PREMA PARAMETRU <i>STABILNOST KOSINA</i>	81
Slika 6-7. VERIFIKACIJA PREMA PARAMETRU <i>TRAGOM ODRONA</i>	81
Slika 6-8. VERIFIKACIJA NA TEMELJU ZBROJA SEGMENTA KOMBINACIJA KLASA SVIH PARAMETRA VERIFIKACIJE I KLASA KOSINE	82
Slika 6-9. REZULTATI VERIFIKACIJE PREMA SVA TRI SETA PODATAKA ZA BM16 I BM01, ZA 208 SEGMENTA	83
Slika 6-10. POSTOTAK SEGMENTA PREMA UKUPNOM BROJU BODOVA	86
Slika 6-11. POSTOTAK SEGMENTA UNUTAR DEFINIRANIH KLASA UKUPNOG BROJA BODOVA.....	87
Slika 6-12. DISTRIBUCIJA SEGMENTA PREMA U-P ODNOSU	88
Slika 6-13. POSTOTAK SEGMENTA UNUTAR SVAKE KLASA PREMA U-P ODNOSU	88
Slika 6-14. POSTOTAK BROJA SEGMENTA UNUTAR SVAKE KLASA KOSINE PREMA UGROŽENOSTI OD ODRONA.....	90
Slika 6-15. ZASTUPLJENOST NAJKRITIČNIJEG TIPRA ODRONA (RS-RAVNINSKI SLOM, KS-KLINASTI SLOM, P-PREVRTANJE, DT-DIFERENCIJALNO TROŠENJE, O-OSIPAVANJE)	90
Slika 6-16. ZASTUPLJENOST NAJKRITIČNIJEG TIPRA ODRONA UNUTAR SVAKE KLASA KOSINE PREMA UGROŽENOSTI OD ODRONA (RS-RAVNINSKI SLOM, KS-KLINASTI SLOM, P-PREVRTANJE, DT-DIFERENCIJALNO TROŠENJE, O-OSIPAVANJE).....	91
Slika 6-17. RASPODJELA NAJKRITIČNIJEG TIPRA ODRONA PO POJEDINIM KLASAMA KOSINE PREMA UGROŽENOSTI OD ODRONA (RS - RAVNINSKI SLOM, KS - KLINASTI SLOM, P - PREVRTANJE, DT - DIFERENCIJALNO TROŠENJE, O - OSIPAVANJE).....	92
Slika 6-18. LOKACIJA KOSINE 202-61-D NA TRASI PRUGE M202: A) ISJEČAK TOPOGRAFSKE KARTE (1:25.000); B) ISJEČAK OGK (1:100.000), LIST CRIKVENICA (PREMA ŠUŠNJAR ET AL., 1970)	93
Slika 6-19. IG PROSPEKCIJA KOSINE 202-61-D: A) RAZLOMLJENA ZONA S IZRAŽENOM POJAVOM OKRŠAVANJA; B) ŠIROKA RASJEDNA ZONA SANIRANA POTPORIM ZIDOM	94
Slika 6-20. ODNOS POTENCIJALA ODRONA I MOGUĆNOSTI DA ODLOMLJENI MATERIJAL DOSEGNE PRUGU ZA KOSINU 202-61-D	96
Slika 6-21. LOKACIJA KOSINE 604-7-D NA TRASI PRUGE M604: A) ISJEČAK TOPOGRAFSKE KARTE (1:25.000); B) ISJEČAK OGK (1:100.000) LIST OGULIN (PREMA VELIĆ & SOKAČ, 1982)	97
Slika 6-22. IG PROSPEKCIJA KOSINE 604-7-D: A) SIPAR FORMIRAN NA VEĆEM DIJELU KOSINE; B) STIJENSKA MASA NA KRAJU KOSINE	98
Slika 6-23. ODNOS POTENCIJALA ODRONA I MOGUĆNOSTI DA ODLOMLJENI MATERIJAL DOSEGNE PRUGU ZA KOSINU 604-7-D	100
Slika 7-1. DIJAGRAM TOKA ZA 3. SEGMENT ISTRAŽIVANJA - STATISTIČKE ANALIZE	102
Slika 7-2. TUMAČENJE UKUPNE SUME KVADRATA ODSUPANJA KOD JEDNOSTAVNE LINEARNE REGRESIJE	106
Slika 7-3. JEDNOSTAVNA LINEARNA REGRESIJA: A) <i>IZRAŽENOST</i> (ZA PREVRTANJE) KAO STATISTIČKI ZNAČAJAN PARAMETAR; B) <i>OBORINE I TEMPERATURA</i> (ZA PREVRTANJE) KAO STATISTIČKI NEZNAČAJAN PARAMETAR.....	111

Slika 7-4. RAZLIČITI ISHODI VRIJEDNOSTI ZAVISNE VARIJABLE (PREMA SAS INSTITUTE INC., 2016): A) VRIJEDNOST ZAVISNE VARIJABLE POPRIMA VRIJEDNOSTI $<-\infty, +\infty>$; B) VRIJEDNOST ZAVISNE VARIJABLE POPRIMA VRIJEDNOSTI UNUTAR INTERVALA $[0,1]$	114
Slika 7-5. LOGIT TRANSFORMACIJA (PREMA SAS INSTITUTE INC., 2016)	115
Slika 8-1. FREKVENCIJE KLASA PREMA UKUPNOM BROJU BODOVA ZA RAZLIČITE VRIJEDNOSTI BODOVA KLASA PARAMETARA: A) VRIJEDNOSTI BODOVA 1-2-3-4, 2-4-8-16 I 3-9-27-81; B) VRIJEDNOSTI BODOVA 4-16-64-256	124
Slika 8-2. LINEARNO I EKSPONENCIJALNO RAZGRANIČAVANJE KLASA UKUPNOG BROJA BODOVA: A) JEDAN PARAMETAR; B) DVA PARAMETRA; C) TRI PARAMETRA; A) MOGUĆE VARIJACIJE UKUPNOG BROJA BODOVA; B) LINEARNO RAZGRANIČAVANJE GRANICA KLASA; C) EKSPONENCIJALNO RAZGRANIČAVANJE GRANICA KLASA	127
Slika 8-3. DISTRIBUCIJA KLASA PREMA UKUPNOM BROJU BODOVA PREMA TEORETSKOM MAKSIMALNOM BROJU BODOVA, ZA SVE ISTRAŽIVANE SEGMENTE: A) LINEARNO RAZGRANIČAVANJE KLASA; B) EKSPONENCIJALNO RAZGRANIČAVANJE KLASA	130
Slika 8-4. DISTRIBUCIJA KLASA PREMA UKUPNOM BROJU BODOVA PREMA MAKSIMALNOM DOBIVENOM BROJU BODOVA, ZA SVE ISTRAŽIVANE SEGMENTE: A) LINEARNO RAZGRANIČAVANJE KLASA; B) EKSPONENCIJALNO RAZGRANIČAVANJE KLASA	130
Slika 8-5. POSTOTAK BODOVA UZROKA I BODOVA POSLJEDICE U UKUPNOM BROJU BODOVA ZA SVE ČETIRI KLASKE KOSINE PREMA UGROŽENOSTI OD ODRONA	132
Slika 8-6. KOSINE KLASKE 4 PREMA UKUPNOM BROJU BODOVA: A) 604-54-D; B) 202-82-D	134
Slika 8-7. KOSINE KLASKE 4 PREMA U-P ODNOSU: A) 604-47-L; B) 604-86-F	135
Slika 8-8. ZBROJ SEGMENTA ZA SVE KOMBINACIJE KLASA KOSINA I PARAMETARA KORIŠTENIH ZA VERIFIKACIJU, ZA KLASU PREMA UKUPNOM BROJU BODOVA (BM14-1), KLASU PREMA U-P ODNOSU (BM14-2) I KONAČNO DEFINIRANU KLASU KOSINE PREMA UGROŽENOSTI OD ODRONA (BM14-3)	136
Slika 8-9. OČEKIVANE KUMULATIVNE VJEROJATNOSTI ZA KLASU KOSINE PREMA UGROŽENOSTI OD ODRONA NA TEMELJU UKUPNOG BROJA BODOVA: A) RAVNINSKI I KLINASTI SLOM; B) PREVRTANJE; C) OSIPAVANJE	142
Slika 8-10. KORELACIJA UKUPNOG BROJA BODOVA DOBIVENIH NA TEMELJU SVIH KLASIFIKACIJSKIH PARAMETARA I NA TEMELJU STATISTIČKI ZNAČAJNIH PARAMETARA ODREĐENIH VIŠESTRUKOM LINEARNOM REGRESIJOM: A) RAVNINSKI I KLINASTI SLOM; B) PREVRTANJE; C) OSIPAVANJE	145

Popis tablica

TABLICA 3-1. KLASKE PRELIMINARNE PROCJENE (PREMA PIERSON & VAN VICKLE, 1993)	15
TABLICA 3-2. DETALJNO OCJENJIVANJE (PREMA PIERSON & VAN VICKLE, 1993)	17
TABLICA 5-1. PREGLED BROJA LOKACIJA NA KOJIMA JE PROVEDENA IG PROSPEKCIJA	44
TABLICA 5-2. KLASKE PARAMETRA <i>IZRAŽENOST</i>	48
TABLICA 5-3. KLASKE PARAMETRA <i>VELIČINA BLOKA (A)</i>	52
TABLICA 5-4. KLASKE PARAMETRA <i>VELIČINA BLOKA (B)</i>	52
TABLICA 5-5. KLASKE PARAMETARA <i>NAGIB DISKONTINUITETA, HRPAVOST DISKONTINUITETA, ZJUEV DISKONTINUITETA I ISPUNA DISKONTINUITETA</i>	53
TABLICA 5-6. KLASKE PARAMETRA <i>NEKOMPETENTNI SLOJEVI</i>	54

TABLICA 5-7. KLASSE PARAMETRA <i>OBLIK BLOKA</i>	54
TABLICA 5-8. KLASSE PARAMETRA <i>OKRŠENOST</i>	55
TABLICA 5-9. KLASSE PARAMETRA <i>VODA</i>	56
TABLICA 5-10. KLASSE PARAMETRA <i>BROJ TIPOVA ODRONA</i>	56
TABLICA 5-11. KLASSE PARAMETRA <i>OBORINE I TEMPERATURA</i>	57
TABLICA 5-12. KLASSE PARAMETRA <i>VISINA</i>	57
TABLICA 5-13. KLASSE PARAMETRA <i>NAGIB (A)</i>	59
TABLICA 5-14. MAKSIMALNA UDALJENOST [M] KOJU MOŽE DOSEĆI BAREM JEDAN ODLOMLJENI BLOK U OVISNOSTI TEŽINE ODLOMLJENOG BLOKA I NAGIBA KOSINE, ZA VISINE 5 M, 11 M I 16M	60
TABLICA 5-15. KLASSE PARAMETRA <i>NAGIB (B)</i>	60
TABLICA 5-16. KLASSE PARAMETRA <i>UDALJENOST</i>	61
TABLICA 5-17. KLASSE PARAMETRA <i>RAZVEDENOST</i>	62
TABLICA 6-1. VREDNOVANJE PARAMETARA <i>IZRAŽENOST, VELIČINA BLOKA I ZNAČAJKE ODREĐENOG TIPRA ODRONA</i> PREMA DEFINIRANIM KLASAMA	68
TABLICA 6-2. VREDNOVANJE PARAMETARA <i>OKRŠENOST, VODA I BROJ TIPOVA ODRONA</i> PREMA DEFINIRANIM KLASAMA	69
TABLICA 6-3. VREDNOVANJE PARAMETRA <i>OBORINE I TEMPERATURA</i> PREMA DEFINIRANIM KLASAMA	69
TABLICA 6-4. VREDNOVANJE PARAMETARA <i>VISINA, NAGIB, UDALJENOST I RAZVEDENOST</i> PREMA DEFINIRANIM KLASAMA.....	70
TABLICA 6-5. BODOVNI MODELI	72
TABLICA 6-6. PARAMETAR <i>PRELIMINARNA PROCJENA</i> - TABLICA FREKVENCIJA	77
TABLICA 6-7. PARAMETAR <i>STABILNOST KOSINE</i> - TABLICA FREKVENCIJA	78
TABLICA 6-8. PARAMETAR <i>TRAGOVI ODRONA</i> - TABLICA FREKVENCIJA	79
TABLICA 6-9. BROJ SEGMENTATA UNUTAR SVAKE KLASSE KOSINE PREMA UGROŽENOSTI OD ODRONA ZA SVAKI DEFINIRANI BODOVNI MODEL	79
TABLICA 6-10. BROJ SEGMENTATA ZA SVAKU KLASU KOSINE SVIH BODOVNIH MODELA: SREDNJA VRIJEDNOST, MEDIJAN TE MINIMALNI I MAKSIMALNI BROJ SEGMENTATA	80
TABLICA 6-11. REZULTATI VERIFIKACIJE ZA BODOVNI MODEL BM14: A) PARAMETAR VERIFIKACIJE <i>PRELIMINARNA PROCJENA</i> ; B) PARAMETAR VERIFIKACIJE <i>STABILNOST KOSINA</i> ; C) PARAMETAR VERIFIKACIJE <i>TRAGOVI ODRONA</i>	84
TABLICA 6-12. KLASIFIKACIJSKI PARAMETRI I NAČIN VREDNOVANJA NJIHOVIH KLASA ZA BODOVNI MODEL BM14.....	85
TABLICA 6-13. BROJ SEGMENTATA ZA SVE KOMBINACIJE KLASA (KLASA PREMA UKUPNOM BROJU BODOVA – KLASA PREMA U-P ODNOSU)	89
TABLICA 6-14. BODOVANJE KLASIFIKACIJSKIH PARAMETARA ZA KOSINU 202-61-D.....	95
TABLICA 6-15. PROCJENA UGROŽENOSTI OD ODRONA ZA KOSINU 202-61-D	96
TABLICA 6-16. BODOVANJE KLASIFIKACIJSKIH PARAMETARA ZA KOSINU 604-7-D.....	99
TABLICA 6-17. PROCJENA UGROŽENOSTI OD ODRONA ZA KOSINU 604-7-D	100
TABLICA 7-1. INTERPRETACIJA VRIJEDNOSTI KOEFICIJENTA DETERMINACIJE (PREMA CHADDOCK, 1925).....	106
TABLICA 7-2. STATISTIČKI ZNAČAJNI PARAMETRI ODREĐENI JEDNOSTAVNOM LINEARNOM REGRESIJOM: A) RAVNINSKI I KLINASTI SLOM; B) PREVRTANJE; C) OSIPAVANJE	109

TABLICA 7-3. STATISTIČKI ZNAČAJNI PARAMETRI ODREĐENI JEDNOSTAVNOM LOGISTIČKOM REGRESIJOM: A) RAVNINSKI I KLINASTI SLOM, B) PREVRTANJE, C) OSIPAVANJE	117
TABLICA 8-1. BROJ PARAMETARA UNUTAR POJEDINIH BODOVNIH KLASA ZA NAJNEPOVOLJNIJI SLUČAJ PREMA ODREĐENIM KLASAMA UKUPNIH BODOVA (ZA 15 PARAMETARA: A) LINEARNO RAZGRANIČAVANJE GRANICA KLASA; B) EKSPONENCIJALNO RAZGRANIČAVANJE GRANICA KLASA	128
TABLICA 8-2. MINIMALNI I MAKSIMALNI TEORETSKI MOGUĆI BROJ BODOVA UZROKA I POSLJEDICA ZA 15 PARAMETARA I NJIHOVE VRIJEDNOSTI ZA ODREĐENE GRANIČNE SLUČAJEVE	131
TABLICA 8-3. USPOREDBA FREKVENCIJA KLASA KOSINA PREMA UGROŽENOSTI S FREKVENCIJAMA KLASA KOSINA PREDVIĐENIH NA TEMELJU REGRESIJSKOG MODELA: A) RAVNINSKI I KLINASTI SLOM; B) PREVRTANJE; C) OSIPAVANJE.....	145
TABLICA 8-4. PRIJEDLOG ZA OBJEKTIVNIJE PROVOĐENJE PRELIMINARNE PROCJENE	148

1. UVOD

*Ako ne znate kako, promatrajte pojave prirode,
ona će vam dati jasne odgovore i inspiraciju.*

Nikola Tesla (1856-1943)

Predmet ovog istraživanja predstavljaju pokreti na kosinama koji su vezani za stijensku masu, a nazvani su odroni u širem smislu, odnosno odroni. Uz ostale pokrete na padinama, oni spadaju u skupinu pokreta masa i događaju se dominantno pod utjecajem gravitacije. Glavni su i teško predvidivi izvor opasnosti, osobito uz cestovne i željezničke prometnice (Delonca et al., 2014), na kojima u smislu geološkog hazarda mogu ugroziti ljudske živote i uzrokovati velike materijalne štete.

Kako bi se zaštititi od odrona moglo pristupati proaktivno, nužan je sustav koji će standardiziranom metodom omogućiti klasifikaciju kosina. Na taj način moguće je, prije nego se nesreća dogodi, logično izdvojiti one kosine kod kojih je prometnica najviše ugrožena, a samim time i sigurnost prometa i njezinih korisnika. Isto tako, moguće je i pravilno raspodijeliti najčešće ograničena financijska sredstva koja su predviđena za sanaciju.

Potrebu za razvojem ovakvog sustava prva je prepoznala Uprava za transport države Oregon (*Oregon Department of Transportation, ODOT*). 1984. godine započela je s razvojem sustava, rezultat kojega je Sustav za procjenu hazarda od odrona (*Rockfall Hazard Rating System, RHRS*), namjenjenom za utvrđivanje najopasnijih kosina uz cestovne prometnice. Sustav je u širokoj primjeni i iako su mnoge države uvele značajne ili manje modifikacije, nastojeći ga poboljšati ili prilagoditi lokalnim uvjetima i potrebama, neke ga koriste i u originalnoj verziji iz

1991. godine (Pierson, 1991). U sklopu sustava razrađena je metodologija za mjerenje i procjenu klasifikacijskih parametara te njihovo vrednovanje, te je on preuzet kao temeljna metoda u sklopu ovog istraživanja. Pri tome je osnovni cilj istraživanja usmjeren na modifikaciju sustava kosinama izvedenim uz željezničku prugu u karbonatnim stijenama Hrvatske.

U sklopu istraživanja najveća je pozornost usmjerena na klasifikacijske parametre koji utječu na mogućnost pojave odrona (inženjerskogeološke i klimatske značajke) i mogućnost da, ukoliko do odrona dođe, odlomljeni materijal dosegne željezničku prugu (geometrijske značajke kosine). Prema spomenutim parametrima procijenjena je ugroženost od odrona, na temelju koje su kosine klasificirane. Bitno je reći kako pri tome u obzir nisu uzimani elementi za procjenu hazarda i rizika.

Ovakav način klasificiranja kosina u Hrvatskoj se do sada nije primjenjivao. Stoga su istraživanja provedena sa svrhom razvoja cjelokupnog sustava za procjenu ugroženosti od odrona. To uključuje odabir parametara koji se koriste za klasifikaciju kosina, metodologiju njihovog mjerenja i procjene, razradu klasa svakog parametra i njihovo vrednovanje te metodologiju klasificiranja kosina. Konačni rezultat klasifikacije predstavlja jedna od četiri klase kosine prema ugroženosti od odrona (A, B, C, D), koja je određena na temelju procjene i mjerenja 15-tak klasifikacijskih parametara. Pri tome je potrebno naglasiti kako je korištenje rezultata klasifikacije namijenjeno isključivo za odabir lokacija koje predstavljaju prioritet za sanaciju. Za izradu projekata sanacije potrebna su detaljna istraživanja uz suradnju inženjera različitih struka (inženjerska geologija, geodezija, geotehnika, građevinarstvo).

Inženjerskogeološka prospekcija, tijekom koje su prikupljeni svi podaci o relevantnim parametrima, analiza podataka i procjena ugroženosti od odrona provedena je za 366 kosima. One se nalaze duž željezničkih pruga M202, M602, M502 i M604, a prostorno su smještene unutar područja Dinarskog krša Hrvatske i izvedene su u karbonatnim stijenama.

U sklopu doktorskog rada istraživanje je koncipirano u tri segmenta. To su:

- prikupljanje i obrada podataka,
- procjena ugroženosti od odrona,
- statističke analize.

Za svaki segment prikazani su provedeni koraci i rezultati koji su iz njih proizašli.

1.1. CILJEVI I HIPOTEZE ISTRAŽIVANJA

Glavni ciljevi istraživanja sažeti su kroz sljedeće četiri točke:

1. Odrediti parametre za procjenu ugroženosti od odrona duž željezničke pruge.
2. Razviti bodovni model za kvantificiranje relativne ugroženosti od odrona duž željezničke pruge.
3. Statističkim analizama potvrditi parametre koji značajno utječu na procjenu ugroženosti od odrona duž željezničke pruge.
4. Predložiti bodovne kategorije koje definiraju ugroženost od odrona duž željezničke pruge.

U skladu sa svrhom istraživanja i definiranim ciljevima, postavljene hipoteze istraživanja su:

1. Inženjerskogeološke značajke stijenske mase, klimatski uvjeti i geometrijske značajke kosine utječu na mogućnost pojave odrona i ugroženost željezničke pruge.
2. Relativnu ugroženost od odrona duž željezničke pruge moguće je pouzdano kvantificirati jednostavnim inženjerskogeološkim opažanjima.
3. Statističkim analizama broj parametara u procesu kvantificiranja relativne ugroženosti od odrona moguće je optimizirati.

2. TEORIJSKE OSNOVE

Repetitio est mater studiorum.


Latinska izreka

Sistematizaciju osnovnih egzogenih procesa na temelju postojeće literature objedinio je Gulam (2012) u okviru istraživanja ogolina središnje Istre. Prema njemu, pokreti na padinama spadaju u skupinu pokreta masa u okviru šire definicije denudacijskih procesa. Za razliku od erozije, pokreti masa podrazumijevaju pokrete koji se događaju dominantno pod utjecajem gravitacije (Dikau, 2006).

Vrlo jednostavnu, ali široko prihvaćenu i korištenu definiciju pokreta na padinama dao je Cruden (1991). Prema njoj se pod tim pojmom podrazumijevaju svi pokreti niz padinu bez obzira obuhvaćaju li oni stijensku masu, tlo ili njihovu mješavinu. Definicija je kao takva prihvaćena i unutar Radne skupine za svjetski inventar klizišta (*Working Party for World Landslide Inventory*) (WP/WLI, 1993). Većina klasifikacija pokreta na padinama temelji se na morfološkim značajkama, vrsti materijala uključenog u proces, mehanizmu kretanja ili brzini kretanja (Dikau, 2006). Pri tome svakako treba spomenuti Varnes-a (1978) koji je značajno doprinio klasifikaciji koja se i danas najviše primjenjuje. Temelji se na dva termina, pri čemu prvi opisuje tip materijala - stijenu, tlo i njihovu mješavinu, a drugi opisuje tip pokreta - klizanje (*eng. slide*), prevrtanje (*eng. topple*), odron (*eng. fall*), širenje (*eng. spread*), tečenje (*eng. flow*) i složeni tip (*eng. complex*). Detaljniji prikaz različitih tipova sloma u stijenskoj masi dali su Goodman & Kieffer (2000).

U sklopu doktorskog rada istražuju se pokreti na padinama koji su vezani uz stijensku masu i skupno su nazvani odroni u širem smislu, odnosno odroni. Osnovni tipovi odrona definirani su prema Vandewater et al. (2005) i Mauldon et al. (2007), a razlikuju se klizanje, prevrtanje, odron u užem smislu i diferencijalno trošenje (Slika 2-1). Kod navedenih tipova odrona dimenzije odlomljenog materijala kreću se od sitnih fragmenata do velikih blokova ili većih volumena materijala, a prema brzini odvijanja događaja ubrajaju se u brze, gotovo trenutne pokrete.

Istraživanja su provedena za kosine i prirodne padine koje se nalaze duž željezničkih pruga. Budući kod njih prevladavaju umjetno izvedene kosine (usjeci i zasjeci), u daljnjem tekstu će pojam *kosine* uključivati i prirodne padine.




Slika 2-1. Osnovni tipovi odrona korišteni u doktorskome radu (modificirano prema Mauldon et al., 2007)

Klizanje podrazumijeva proces odvajanja, a zatim translacijskog i/ili rotacijskog kretanja materijala duž najčešće jasno izražene plohe sloma ili diskontinuiteta. Za područje istraživanja značajno je translacijsko klizanje, unutar kojeg se razlikuju ravninski i klinasti slom.


Ravninski slom (*eng. planar failure*) zahtijeva postojanje ravne klizne površine, odnosno izražene plohe jednog diskontinuiteta, koja je nepovoljno orijentirana u odnosu na kosinu (Slika 2-2). Nepovoljna orijentacija podrazumijeva pružanje diskontinuiteta subparalelno pružanju kosine, odnosno nagib u smjeru nagiba kosine. Pri tome je nagib diskontinuiteta manji od nagiba kosine, a veći od kuta unutarnjeg trenja na plohi diskontinuiteta.

Klinasti slom (*eng. wedge failure*) zahtijeva postojanje dva (ili više) diskontinuiteta koji se sijeku i čija je presječnica nepovoljno orijentirana u odnosu na kosinu (Slika 2-3). Nepovoljna orijentacija podrazumijeva nagib presječnice u smjeru nagiba kosine, pri čemu je kut nagiba manji od nagiba kosine i veći od kuta unutarnjeg trenja u stijenskoj masi.



Prevrtanje (*eng. topple*) predstavlja tip odrona za koji je nužno postojanje diskontinuiteta čije je pružanje subparalelno pružanju kosine i nagib suprotnog smjera od smjera nagiba kosine. Uz to, uključuje rotaciju odlomljenog bloka oko približno horizontalno položene osi u njegovom podnožju (Slika 2-4.a). Kao ovaj tip odrona promatrano je i ispadanje blokova bez potpore u podlozi unutar stijenske mase koja ima jasno izražene strukturne elemente te su u tom slučaju diskontinuiteti subhorizontalni (Slika 2-4.b).



Slika 2-2. Ravninski slom (502-11-D)




Slika 2-3. Klinasti slom (202-56-3-D)



Slika 2-4. Prevrtanje: a) 502-12-L; b) 604-25a-D

Odron u užem smislu (eng. *raveling*) obuhvaća obrušavanje i osipavanje. Obrušavanje se odnosi na tip odrona vezanog uz stijensku masu kod koje, za razliku od ravninskog i klinastog sloma te prevrtanja, nisu jasno izraženi strukturni elementi, tj. setovi diskontinuiteta koji dovode do njihove pojave (Slika 2-5). Ovaj tip odrona uključuje i slobodne blokove unutar površinske zone trošenja. Osipavanje se odnosi na tip odrona za koji je karakteristično izrazito fizičko trošenje i/ili značajna tektonska razlomljenost (Slika 2-6). Podrazumijeva veličinu odlomljenih blokova od dimenzija kršja do malih blokova, odnosno duljine stranica blokova centimetarskih dimenzija.

Postoje kosine kod kojih pojave obrušavanja i osipavanja nisu zastupljene duž cijele kosine, već su isključivo vezane uz razlomljene zone (rasjedne zone ili značajnije i šire pukotine) koje se mogu pratiti duž cijele visine kosine (Slika 2-7). Ovakvi su slučajevi tijekom inženjerskogeološke prospekcije posebno bilježeni kao osipavanje vezano uz razlomljene zone.



Slika 2-5. Obrušavanje (202-66-1-D)




Slika 2-6. Osipavanje (202-67-D)



Slika 2-7. Osipavanje vezano uz razlomljene zone: a) 202-16-L; b) 202-61-D

Diferencijalno trošenje (*eng. differential weathering*) izdvojeno je kao poseban tip odrona koje je karakteristično za slojevitú stijensku masu koja se sastoji od materijala različite otpornosti prema trošenju (kompetentnih - rezistentnijih i nekompetentnih - manje rezistentnih slojeva). Pri tome dolazi do bržeg i značajnijeg trošenja materijala unutar nekompetentnih slojeva što dovodi do podsijecanja i formiranja prevjesa kompetentnog materijala (Slika 2-8), te narušavanja stabilnosti njegovih blokova.



Slika 2-8. Diferencijalno trošenje (202-19-1-D)

Kod definiranja tipova odrona termin *odron* koristi se na različitim razinama unutar klasifikacije – odron u širem smislu i odron u užem smislu. Kako u daljnjem tekstu ne bi dolazilo do zbrke, termin *odron* koristit će se za odron u širem smislu, dok će termin *osipavanje* zamijeniti sve tipove koji spadaju u odron u užem smislu.

Jednom kada se dogodi slom u stijenskoj masi, odlomljeni blok/materijal može se niz kosinu kretati na različite načine, koji prvenstveno ovise o prosječnom nagibu kosine. Razlikuju se slobodni pad, odskakivanje i kotrljanje. Slobodni pad pojavljuje se kod jako strmih nagiba gdje

ne bi trebalo biti kontakta između odlomljenog materijala i kosine. Odskakivanje je karakteristično za nagibe 45° - 70° , a kotrljanje za nagibe $< 45^{\circ}$. Prilikom kretanja može doći do dodatnog razbijanja pokrenutog materijala (Dorren, 2003). Ukoliko se kosina postupno ublažava, moguć je prijelaz iz jednog tipa kretanja u drugi.


U literaturi koja je vezana uz proučavanu problematiku vrlo često se pojmovi hazarda i rizika miješaju ili poistovjećuju. Stoga se u daljnjem tekstu daje njihovo kratko pojašnjenje u kontekstu korištenom u ovom radu.

Općenito se može reći kako hazard predstavlja opasnost odvijanja nekog događaja, odnosno situaciju, u kojoj postoji određena prijetnja ili ugroženost života, zdravlja, okoliša ili imovine (Bell, 2002). Pri tome se geološki hazard, koji spada u skupinu prirodnih hazarda, odnosi na opasnosti koje su prouzročene endogenetskim ili egzogenetskim silama, a uključuju pojavu potresa, erupcije vulkana, ekstremno velike valove, različite tipove pokreta masa na padinama, poplave te slijeganja terena (Benac, 2013).

Cjeloviti proces upravljanja rizicima detaljno su razradili Fell et al. (2005). Prema njima se razlikuje pet glavnih faza, a svaka od njih uključuje faze koje joj prethode (Slika 2-9).

Kroz glavne faze definirani su sljedeći pojmovi:

- Ugroženost ili opasnost (eng. *threat/danger*) podrazumijeva prirodni događaj koji može dovesti do štete, a opisuje se u smislu njegovih geometrijskih, mehaničkih i drugih značajki. Karakteristike ugroženosti ne uključuju predviđanja.
- Hazard (eng. *hazard*) se definira kao vjerojatnost pojave štetnog događaja unutar određenog vremenskog perioda.
- Rizik (eng. *risk*) podrazumijeva mjeru vjerojatnosti i ozbiljnosti štetnog utjecaja na život, zdravlje, imovinu ili okoliš.
- Procjena rizika (eng. *risk assessment*) predstavlja proces donošenja preporuka za odluke je li postojeći rizik prihvatljiv i postojeće mjere kontrole rizika adekvatne.
- Upravljanje rizicima (eng. *risk management*) uključuje sustavnu primjenu politike upravljanja, procedure i prakse za identificiranje, analizu, procjenu, ublažavanje i praćenje rizika.



Slika 2-9. Cjeloviti proces upravljanja rizikom (prema Fell et al., 2005)

U sklopu doktorskog rada razrađeni su elementi razvoja sustava procjene ugroženosti od odrona koji predstavlja prvi korak u cjelovitom upravljanju hazardima i rizicima povezanih s odronima.

3. DOSADAŠNJA ISTRAŽIVANJA

Is there anyone so wise as to learn by the experience of others?

Voltaire - François Marie Arouet (1694-1778)

Kod upravljanja odronima razlikuju se dva osnovna pristupa: proaktivni i reaktivni. Proaktivni pristup podrazumijeva identificiranje i stabilizaciju kritičnih lokacija ili zona prije nego se odron ili nesreća dogode. Suprotno tomu, reaktivni pristup stavlja naglasak na područja gdje su se odron ili nesreća već dogodili (Wyllie & Mah, 2005). U skladu s proaktivnim pristupom, procjena ugroženosti od odrona određuje se na više različitih lokacija temeljem razrađenog sustava bodovanja. To omogućuje usporedbu i odabir prioriternih lokacija za sanaciju. Prvi radovi vezani za tu tematiku potječu iz 1975. i 1987. godine.

Za Kanadsku pacifičku željeznicu, Brawner & Wyllie (1975) razvili su sustav ocjenjivanja kojim se lokacije s mogućom pojavom odrona ocjenjuju ocjenama A-E na temelju vjerojatnosti pojave odrona i očekivanog efekta. Pri tome se one s ocjenom A smatraju najopasnije i zahtijevaju hitnu sanaciju.

Potrebu za kvantitativnim sustavom procjene opasnosti od potencijalnih odrona prvi je prepoznao *ODOT*, koji je 1984. godine započeo s njegovim razvojem, kako bi se unaprijedilo upravljanje hazardima i rizicima povezanih s odronima. Wyllie (1987) je dao opsežniji pregled metode za procjenjivanje koja uključuje kategorije i opis parametara koji se mjere/procjenjuju i na kraju vrednuju (boduju), te uvodi eksponencijalni bodovni sustav. Takav su princip preuzeli Pierson & Van Vickle (1989) u procesu razvoja sustava upravljanja kosinama duž prometnica, rezultat kojega je prototip nazvan *RHRS*. Preuzeti su obrazac za unos vrijednosti parametara,

eksponencijalni bodovni sustav, većinu parametara koji se ocjenjuju i njihove kategorije. Nakon terenskog testiranja na oko 50 lokacija, sustav su isti autori i revidirali. Financiranje razvoja i implementacije sustava od strane Savezne uprave za autoceste (*Federal Highway Administration, FHWA*) i odjela za transport pojedinih država, omogućilo je njegovo testiranje na više od 3.000 lokacija. Tijekom višegodišnjeg korištenja, na temelju prikupljenog terenskog iskustva, sustav je modificiran i poboljšan (Pierson, 1991). U tom obliku je korišten i u Priručniku (Pierson & Van Vickle, 1993) napisanom za tečaj koji je proveo Državni institut za autoceste (*National Highway Institute, NHI*), a namijenjen je za osposobljavanje osoblja održavanja prometnica za provođenje procjene (u literaturi se navodi kao *NHI RHRS*).

3.1. PROCJENA HAZARDA OD ODRONA (*RHRS*)

Budući je većina sustava koji uključuju procjene hazarda vezanih uz odrone proizašla upravo iz *RHRS* države Oregon (*NHI RHRS*), u ovom se poglavlju daje ukratko njegov prikaz, sa svrhom pregleda klasifikacijskih parametara i razumijevanja osnovnog principa njihovog vrednovanja.

Provođenje sustava može se podijeliti na inventarizaciju (utvrđivanje broja kosina i njihovih lokacija) i vrednovanje (bodovanje) parametara, pri čemu se razlikuju preliminarna i detaljna procjena.

Preliminarna procjena, uz određene modifikacije, preuzeta je od Brawner & Wyllie-a (1975). Provi se paralelno s inventarizacijom kosina na temelju procjene dva osnovna parametra - ugroženosti prometnice od potencijalnog odrona i njegove učestalosti, odnosno frekvencije pojavljivanja odrona u prošlosti (Tablica 3-1).

Tablica 3-1. Klase preliminarne procjene (prema Pierson & Van Vickle, 1993)

PARAMETAR ZA VREDNOVANJE	KLASA PRELIMINARNE PROCJENE		
	A	B	C
Ugroženost prometnice od potencijalnog odrona	visoka	srednja	niska
Učestalost odrona (frekvencija pojavljivanja u prošlosti)	visoka	srednja	niska

Ugroženost prometnice od potencijalnog odrona uključuje procjenu:

- 1) veličine blokova potencijalno nestabilnog materijala,
- 2) količine materijala po događaju,
- 3) ukupne količine potencijalno nestabilnog materijala,
- 4) učinkovitost zaštitnog jarka.

Za procjenu učestalosti odrona potrebno je razmotriti sljedeće:

- 1) koliko često je odlomljeni materijal dosego prometnicu,
- 2) količinu materijala,
- 3) veličinu blokova materijala,
- 4) učestalost čišćenja.

Pri tome se veća važnost daje prvom kriteriju a drugi se koristi kao pomoćni, posebno u slučajevima kada se procjenom prvog parametra usjek/zasjek nalazi na granici između dviju klasa.

Kosine se prema preliminarnoj procjeni svrstavaju u jednu od sljedećih klasa:

- A: nestabilne i značajno ugrožavaju prometnicu; za njih se u sljedećem koraku provodi detaljno ocjenjivanje,
- B: uvjetno stabilne i djelomično ugrožavaju prometnicu; za njih se provodi detaljna kategorizacija u slučaju kada to dopuštaju vrijeme i financijska sredstva,
- C: stabilne i ne ugrožavaju prometnicu; one se isključuju iz daljnjeg detaljnog ocjenjivanja.

Ovo ocjenjivanje je subjektivno, tj. dodjeljuju se opisne ocjene, zbog čega preliminarnu procjenu moraju provoditi iskusne osobe koje mogu napraviti valjane prosudbe. Isto tako je potrebno zadržati konzistentnost u interpretaciji i korištenju kriterija ocjenjivača, a ocjenjivanje bi trebalo ponoviti na lokacijama gdje se odron dogodio kako bi se utvrdilo jesu li mogućnost ponovne pojave događaja i ugrožavanja prometnice smanjeni. Ipak, značaj provođenja ovog koraka je u tome što se u samom startu izdvajaju one lokacije za koje je procijenjena mala vjerojatnost da se uopće ostvare kritični uvjeti (za pojavu odrona i ugroženost prometnice i korisnika) pa bi za njih provođenje detaljnog ocjenjivanja bilo nepotrebno utrošeno vrijeme.

Za detaljno ocjenjivanje kosina predviđeno je mjerenje/procjena onih parametara koji značajno utječu na mogućnost pojave odrona i ugroženost prometnice, uključujući i određene

parametre koji se odnose na sam promet. Ocjenjivanje uključuje 10 parametara, za svaki od dva definirana slučaja različitih geoloških značajki. Oni uključuju pojavu odrona koja je dominantno vezana uz diskontinuitete i pojavu odrona na koju dominantni utjecaj ima diferencijalno trošenje. Značajke se vrednuju za onaj slučaj koji je kritičniji. Svi parametri prikazani su u sklopu tablice 3-2.

Tablica 3-2. Detaljno ocjenjivanje (prema Pierson & Van Vickle, 1993)

PARAMETAR			KLASE PARAMETRA I NJIMA PRIDRUŽEN BROJ BODOVA			
			3	9	27	81
Visina [ft]			25	50	75	100
Učinkovitost zaštitnog jarka			dobar	srednji	ograničen	nema
Izloženost vozila riziku [% vremena]			25	50	75	100
Vidljivost			prikladna	srednja	ograničena	vrlo ograničena
Širina prometnice [ft]			44	36	28	20
Geološke značajke	I	Strukturne značajke (diskontinuiteti)	nepostojani, povoljne orijentacije	nepostojani, nasumične orijentacije	nepostojani, nepovoljne orijentacije	postojani, nepovoljne orijentacije
		Hrapavost	hrapavo, nepravilno	valovito	ravno	glatko ili ispunjeno glinom
	II	Strukturne značajke (elementi trošenja)	malo	povremeno	mnogo	značajno
		Razlike u trošenju materijala	male	srednje	velike	ekstremne
		Veličina bloka [ft]/Volumen [yd ³]	1/3	2/6	3/9	4/12
Klima i prisutnost vode			malo do srednje oborina, bez perioda smrzavanja, bez vode	srednje oborina ili kratki periodi smrzavanja, isprekidano vode	puno padalina ili dugi periodi smrzavanja, kontinuirano voda	puno padalina i dugi periodi smrzavanja, kontinuirano voda i dugi periodi smrzavanja
Učestalost pojave odrona			rijetko	povremeno	često	stalno

Za svaki parametar određene su četiri klase kojima se pokriva raspon prirodnih uvjeta njegovih značajki. Svakoj klasi parametra pridružuje se određen broj bodova te se u konačnici njihovim zbrajanjem dobiva ukupan broj bodova, koji predstavlja relativnu opasnost od odrona.

Sam princip bodovanja klasa parametara zasniva se na eksponencijalnom bodovnom sustavu sa četiri bodovne vrijednosti klasa, 3-9-27-81. Veći broj bodova dodjeljuje se klasama (značajkama) parametra koji nepovoljnije utječu na samu pojavu odrona i na ugroženost prometnice. Eksponencijalni način bodovanja koristi se jer se na taj način naglašava nagli porast bodova kod najnepovoljnijih značajki parametara. Pri tome je dopuštena, prema procijenjenoj potrebi, interpolacija bodovnih vrijednosti između pojedinih klasa.

Svrha detaljnog ocjenjivanja je upravo u mogućnosti razlikovanja istraživanih kosina na temelju dobivenog ukupnog broja bodova te samim time izdvajanja onih s najvećim brojem bodova. Kod njih je i najveći broj onih parametara koji su prospekcijom procijenjeni kao nepovoljni.

3.1.1. Upotreba RHRS-a i njegove modifikacije

Opisani sustav u širokoj je primjeni u brojnim državama SAD-a. Neke od njih preuzele su sustav u originalnoj verziji (*California, Kentucky, Nevada, North Carolina, Oregon, Pennsylvania, Utah, Virginia, West Virginia, Wyoming*), a neke su uvele značajne ili manje modifikacije (*Arizona, Colorado, Idaho, New Hampshire, New Jersey, New York, Ohio, Tennessee, Vermont*) uz zadržavanje temeljnog principa (Bateman, 2003; Russell et al., 2008). Osim toga, sustav je u nekom od navedenih oblika, ponekad uz prilagodbu, korišten i u drugim državama (npr. Italija – Budetta, 2004; Palma et al., 2012; Pappalardo et al., 2013; Španjolska – Morales et al., 2005; Velika Britanija – Nichol, 2006; Kina – Li et al., 2007; Egipat – Youssef & Maerz, 2009; Južnoafrička Republika – Leyland & Paige-Green, 2011; Makedonija – Peševski et al., 2011; Saudijska Arabija – Youssef et al., 2012; Kanada - Franklin et al., 2013; Iran – Taherynia et al., 2014).

Pregledom literature može se ustanoviti kako se većina modifikacija odnosi na:

- zamjenu opisne s kvantitativnom procjenom parametara: učinkovitost zaštitnog jarka, prisutnost vode, učestalost pojave odrona u prošlosti; što značajno utječe na objektivnost i dosljednost kod procjene parametara od strane različitih ocjenjivača;
- prilagodbu geometrijskim karakteristikama usjeka (npr. klase parametra visine usjeka potrebno je prilagoditi izmjerenim vrijednostima, što preporuča i Pierson (1991));
- prilagodbu lokalnim uvjetima, prvenstveno klimatskim i geološkim značajkama;

- isključivanje parametara koji se lokalno ne mijenjaju;
- uključivanje parametara koji nisu uvršteni u sustav, a za koje je dokazano kako doprinose mogućnosti pojave odrona (klimatske značajke – orijentacija kosine, odnosno izloženost kosine suncu (Russell et al., 2008; Santi et al., 2009), ciklusi smrzavanja-odmrzavanja, *slake durability test* (Pack & Boie, 2002), količina oborina (Chau et al. 2003, Delonca et al., 2014); procesi okršavanja (Roje-Bonacci, 2009)) ili su značajni za određivanje ugroženosti prometa, kao što su nagib i reljefna razvedenost kosine, dužina kosine (Russell et al., 2008);
- prilagodbu lokalnoj državnoj regulativi, što se odnosi na tehničke standarde potrebne za ocjenu određenih elemenata prometnice ili prometa (npr. vidljivost, dozvoljena brzina).

Pack & Boie (2002) predlažu detaljniju skalu preliminarne procjene uvođenjem osam kategorija (A+, A, A-, B+, B, B-, C+, C), kako bi se mogla preciznije odrediti kategorija kojoj kosina pripada.

Ocjenjivanje geoloških značajki u postojećem sustavu temelji se na ocjenjivanju najkritičnijeg tipa odrona na lokaciji, kako bi se na taj način naglasio najkritičniji slučaj. Mauldon et al. (2007) dozvoljavaju više različitih tipova odrona na jednoj lokaciji, pri čemu se značajke svih modela vrednuju kumulativno. Uz to, u sustav uključuju i sam tip potencijalnog odrona (prema Vandewater et al., 2005). Budetta (2004) preporuča korištenje SMR klasifikacije kao zamjenu za ocjenjivanje geoloških značajki. Russel et al. (2008) smatraju kako bi se u sustav trebali uvrstiti dodatni geološki parametri. Budući se u postojećem sustavu geološke značajke opisuju i ocjenjuju samo s dva parametra, naglašavaju kako postoji mogućnost da kosina bude ocijenjena s velikim brojem bodova, iako geološki uvjeti uopće nisu povoljni za formiranje odrona.

Klimatske značajke i njihove kategorije potrebno je prilagoditi lokalnim značajkama. Tako Mauldon et al. (2007) za područje države Tennessee uzimaju u obzir samo prisutnost vode, jer je klima ujednačena. Za državu Alaska, Huang et al. (2009) prilagodili su sustav njihovim klimatskim osobitostima, uvažavajući ubrzano mehaničko trošenje uslijed velikog broja godišnjih ciklusa smrzavanja-odmrzavanja te prisutnosti permafrosta.

Za primjenu u seizmički aktivnim područjima u vrednovanje su kao parametar uključene i seizmološke značajke (Đurović et al., 2005; Saroglou et al., 2012; Si-qiao et al., 2014).

Parametri su u RHRS za Ontario (Franklin et al, 2013) bodovani ocjenama 1-9. Bodovanje različitog broja parametara geoloških značajki za pojedine tipove odrona (Mauldon et al., 2007) svedeno je na razinu kako bi ukupan broj bodova geoloških značajki za sve tipove odrona bio jednak. Youssef & Maerz (2012) parametrima dodjeljuju vrijednosti bodova 0-12. Saroglou et al. (2012) dodjeljuju različite težinske faktore pojedinim skupinama parametara.

Pierson & Van Vickle (1993) preporučuju dodjeljivanje određenim parametrima bodove 1-100 u obliku kontinuiranih funkcija.

Većina autora ovih sustava naglašava kao česti problem nepostojanje inventara o učestalosti pojave odrona, odnosno o frekvenciji njihovog pojavljivanja u prošlosti. Tamo gdje inventari postoje često se ne vode na sustavan i jedinstven način. U takvim slučajevima za ocjenjivanje ovog parametra od velike su pomoći informacije od strane službe za održavanje, u obliku usmene informacija o pojavama odrona ili podataka o učestalosti čišćenja (održavanja) i njihovim troškovima. U smislu prikupljanja ovih podataka Russell et al. (2008) koriste i podatke o nesrećama koje se mogu povezati s pojavom odrona duž prometnice, a koji se prikupljaju unutar baze podataka u sklopu Informacijskog sustava za ceste države Colorado (*Colorado Roadway Information System*).

Chau et al. (2003) prezentiraju analizu hazarda od odrona za Hong Kong na temelju inventara odrona, koji sadrži podatke za period od 50 godina. Coro et al. (2015) naglašavaju kako je za procjenu hazarda i rizika korisna uspostava baze podataka o odronima ako su podaci o pojavi odrona potpuni. Oni uključuju sve korisne informacije povezane sa njihovom prostornom i vremenskom distribucijom, zajedno sa geološkim značajkama.

Tehnološki napredak omogućio je razvoj novih „alata“ kojima se može olakšati rad kod izdvajanja lokacija s potencijalnim pojavama odrona (Mauldon et al., 2007) i prikupljanja podataka geometrijskih značajki kosina i prometnica (Youssef & Maerz, 2012). Također, Youssef et al. (2009) prezentiraju Geografski informacijski sustav (GIS) kao snažan alat kod procjene rizika i upravljanja hazardnim prirodnim događajima. Uz to, razvoj LiDAR tehnologije doprinio je izradi 3D modela kosina uz definiranje osnovnih strukturnih značajki stijenske mase (Lato et al., 2009; Maerz et al., 2015) te se predviđa kako će u sljedećih nekoliko godina upravo ta tehnologija postati standardni alat za različite analize pokreta na padinama (Jaboyedoff et al., 2012).

Budetta & Nappy (2013) provode usporedbu rezultata dobivenu s tri različita sustava procjene opasnosti od odrona. Uz to, naglašavaju njihovu primjenjivost u prvim fazama istraživanja koja prethode detaljnim geomehaničkim analizama na izdvojenim lokacijama.

3.2. SUSTAVI PROCJENE OPASNOSTI ODRONA U HRVATSKOJ

Na postojećim hrvatskim prometnicama radovi zaštite kosina provode se u sklopu redovnog održavanja (Librić, 2014). Problemi s odronima rješavaju se često tek onda kada se pojave, uglavnom na lokalnoj razini.

Unutar Hrvatskih željeznica pojavama odrona bave se Regionalne jedinice održavanja. Tijekom redovitih pregleda kosina ili nakon dojave, uočeni se odroni evidentiraju putem evidencijskih listova i knjiga. Evidencija odrona sustavno se provodi posljednjih dvadesetak godina, ali bez razvijene baze podataka i cjelovitog informacijskog sustava. Odroni se evidentiraju i kao izvanredni događaji u slučaju da su oni uzrok nesreće. Ipak, ovih podataka o odronima nema dovoljno kako bi se na njihovoj osnovi parametar pojave odrona mogao pripisati svim kosinama. Uz to, podaci koji postoje nisu na istoj razini kod svih jedinica održavanja te su samim time teško usporedivi.

Sustav procjene ugroženosti od odrona u Hrvatskoj, prilagođen lokalnim geološkim i klimatskim značajkama, nije razvijen i ne postoje službene preporuke za njegovo provođenje (Arbanas et al., 2012). Uz to, nije pronađena niti literatura s konkretnim primjerom i rezultatima korištenja nekih od postojećih sustava.

Iz navedenog proizlazi kako je za Hrvatsku nužno razviti sustav upravljanja odronima, koji bi uključio proaktivni pristup i definirao kosine kod kojih postoji velika mogućnost da potencijalni odron ugrozi željezničku prugu. Takav sustav omogućio bi standardiziran način određivanja prioriternih lokacija za monitoring i/ili sanaciju na lokacijama koje su ugrožene odronima te učinkovito i ekonomski opravdano korištenje resursa.

4. PODRUČJE ISTRAŽIVANJA


Knowing is not enough; we must apply. Willing is not enough; we must do.

Johann Wolfgang von Goethe (1749-1832)

Kosine za koje je provedena inženjerskogeološka prospekcija i procjena ugroženosti od odrona nalaze se na izdvojenim dionicama duž željezničkih pruga M202 - Zagreb GK-Rijeka, M602 - Škrljevo-Bakar, M502 - Rijeka-Šapjane-DG i M604 - Oštarije-Split Predgrađe (Slika 4-1).

Budući da je područje istraživanja široko i zahvaća nekoliko regija - Pokuplje, Primorje, Gorski Kotar, Liku i Dalmaciju, u sklopu ovog poglavlja daje se opći pregled geografskih, klimatskih, geoloških i geomorfoloških te inženjerskogeoloških značajki područja u mjerilu kojim se mogu obuhvatiti sve lokacije kosina. Pri tome se nije ulazilo u detaljan prikaz svake lokacije u mjerilu kosine, za što je bitan lokalni utjecaj svih spomenutih značajki.

Valja napomenuti kako su sve predmetne kosine smještene unutar područja koje pripada Dinarskom kršu Hrvatske. Raznolikosti između regija odnose se na gore spomenute značajke i upravo one omogućuju sagledavanje utjecaja različitih uvjeta na mogućnost pojave odrona.



Slika 4-1. Pregled lokacija na kojima je provedena inženjerskogeološka prospekcija

4.1. GEOGRAFSKE I KLIMATOLOŠKE ZNAČAJKE

Generalno se može reći kako se kosine prostiru na prostoru od hrvatsko-slovenske granice i Rijeke na sjeverozapadu, preko Gorskog kotara i Like, do Splita na jugoistoku. Najsjevernija točka, ujedno i najzapadnija, ima koordinate 45°29' N i 14°15' E, najjužnija točka, ujedno i najistočnija, ima koordinate 43°31' N i 16°28' E (Slika 4-1). Prema administrativnoj podjeli, kosine su smještene unutar pet županija.

Kosine se nalaze unutar dvije prirodno-geografske cjeline, pri čemu se razlikuju primorski i planinski prostor (Bertić et al., 2001). Primorski prostor obuhvaća sjeverno i južno Hrvatsko primorje, odnosno Podvelebitsko primorje i Kvarner te Dalmaciju. Tu su smještene i dva regionalna središta Rijeka i Split. Planinski prostor obuhvaća Gorski kotar i Liku, unutar kojih su visoke gore i planine odvojene krškim dolinama i poljima. Ovo je ujedno i područje od osobite važnosti u prometnoj povezanosti panonsko-peripanonskog i primorskog dijela Hrvatske.

Prema hipsometrijskim značajkama, najveći broj kosina nalazi se na nadmorskoj visini iznad 200 m (83 % segmenata), od čega je 126 segmenata na visinama iznad 500 m. Oko 17 % segmenata podjednako je raspoređeno unutar klasa s rasponom 0-100 m i 100-200 m nadmorske visine.


Prema geografskim cjelinama koje zahvaća područje istraživanja, mogu se definirati i tipovi klime koji uključuju gorsko-planinski i jadranski (mediteranski) tip. Unutar istraživanog područja čimbenici koji najviše utječu na klimatske značajke uključuju umjerene geografske širine, Jadransko i šire Sredozemno more te planinski lanac Dinarida koji predstavlja visoku barijeru duž jadranske obale (Zaninović et al., 2008).

Raspon srednjih godišnjih temperatura zraka u području Like i Gorskog kotara je najveći, zbog značajne orografske razvedenosti unutar tih područja, a on iznosi 5°C - 9°C, odnosno 3°C - 11°C. Najniže godišnje temperature vezane su uz nadmorske visine iznad 1.500 m. Godišnji hod temperature zraka pokazuje maksimume najčešće u srpnju i minimume u siječnju. Dnevni hod temperature zraka izraženiji je ljeti nego zimi i pokazuje veće razlike u unutrašnjosti nego u primorju (Zaninović et al., 2008). Lokacije na kojima je provedeno istraživanje nalaze se unutar područja s varijacijama srednje godišnje temperature zraka od 5°C do 16°C (Slika 4-2).


Za najveći broj kosina ona je u rasponu 8°C - 9°C (19 % segmenata), odnosno 12°C - 13°C (18 % segmenata).

Prosječne količine oborina tijekom godine kreću se između 700 i 1.000 mm u obalnom pojasu pa do više od 3.000 mm u planinskom području (Slika 4-3). Najveće godišnje količine oborina u Hrvatskoj vezane su za područje Gorskog Kotara i Velebita. Najveći broj kosina nalazi se u području srednje godišnje količine oborina 1.500 - 1.750 mm (28 % segmenata).

Za oba ova parametra klimatskih značajki zajednička je postupna promjena njihovih vrijednosti s porastom nadmorske visine, smanjenje za temperature i povećanje za oborine.



Slika 4-2. Karta srednje godišnje temperature šireg područja istraživanja (prema Zaninović et al., 2004)



Slika 4-3. Karta srednjih godišnjih oborina šireg područja istraživanja (prema Gajić-Čapka et al., 2003)

4.2. GEOLOŠKE I GEOMORFOLOŠKE ZNAČAJKE

Istraživani teren pripada krškom području Dinarida, koji je dominantno izgrađen od karbonatnih naslaga. Njihova je kontinuirana sedimentacija u najvećem dijelu vezana za mezozoik.

Najstarije su naslage obilježene siliciklastičnim i karbonatnim kompleksom stijena koje su taložene od karbona do srednjeg trijasa. Nakon trijaskе tektonske i vulkanske aktivnosti, karbonatno taloženje vezano je uz veliku karbonatnu platformu. Krajem donje jure, tijekom plinsbaha i toarcija, dolazi do njezine dezintegracije te nastaje više manjih platformi. Najveća među njima je Jadranska karbonatna platforma koja je kao izolirana karbonatna platforma trajala do kraja krede. Ona predstavlja paleogeografski sinonim za krške Dinaride (Velić et al., 2002; Vlahović et al., 2002; Dragičević & Velić, 2002). Glavno njezino obilježje je plitkovodna marinska sedimentacija, uz lokalna produbljivanja taložnih sredina i povremenih okopnjavanja. Ukupna debljina karbonatnih naslaga koje su formirane za vrijeme trajanja jadranske karbonatne platforme varira između 3.500 i 5.000 m (Vlahović et al., 2005). Kraj postojanja Jadranske karbonatne platforme obilježen je regionalnom emerzijom na granici krede i paleogena. Tijekom paleogena taloženje je ograničeno je na tektonski formirane bazene.


Strukturno tektonski odnosi i razlomljenost stijenske mase duž područja istraživanja koje nalazimo danas, produkt su tektonske aktivnosti u prostoru tijekom dezintegracije Jadranske karbonatne platforme i nakon toga emerzije (kopnene faze tijekom koje je dominantan proces okršavanje uslijed erozije i korozije, a koja traje i danas).

Prema ranijim istraživanjima (Blašković, 1998; Jamičić et al., 1995; Prelogović et al., 1981) moguće je izdvojiti dva ključna tektonski aktivna razdoblja koja su utjecala na formiranje izgleda današnjih struktura. Glavno obilježje čine borane, ljuskave i navlačne strukture, čiji je nastanak vezan za kompresijske tektonske pokrete koji su kulminirali konačnim izdizanjem Dinarida tijekom oligocena i miocena. Kontinuirana kompresijska tektonika s maksimalnim stresom JZ-SI uvjetovala je dominantno pružanje struktura okomito na taj smjer, odnosno dinarski pravac pružanja SZ-JI. Drugo obilježje odnosi se na neotektonsku fazu tektonike koja započinje u pliocenu i traje do danas. Pružanje glavne komponente regionalnog naprezanja je približno S-J, što je posljedica promjene smjera kretanja Jadranske mikroploče i rotacije smjera

djelovanja najvećeg regionalnog stresa. Ranije formirane strukture tim su promjenama deformirane, uz nastajanje novih rasjeda i reaktiviranje postojećih, koji se uslijed promjene orijentacije stresa uglavnom reaktiviraju kao transkurentni s desnim pomakom. Unutar područja istraživanja nastalo je više tektonskih jedinica i brojnih struktura lokalnog i šireg prostiranja.

Prema Osnovnoj geološkoj karti mjerila 1:300.000 (HGI, 2009) najveći broj promatranih kosina nalazi se u području izgrađenom od (Slika 4-4):

- vapnenaca i dolomita donje krede (41 % segmenata), koji su generalno vezani za kosine duž željezničke pruge M502 od Rijeke do državne granice sa Slovenijom te u području Gorskog kotara i Like;
- flišnih naslaga srednjeg i gornjeg eocena (13 % segmenata), koje su vezane za kosine u području splitskog fliškog bazena;
- gornjojurskih vapnenaca i dolomita (12 % segmenata), koji se najviše nalaze unutar kosina u području Gorskog kotara i Like; te
- rudistnih vapnenaca (10 % segmenata), koji izgrađuju kosine koje su prostorno najviše vezane uz zaleđe Rijeke i Splita.



Slika 4-4. Pregledna geološka karta šireg područja istraživanja (prema HGI, 2009; Osnovna geološka karta, 1:300.000)

U sklopu ovoga rada procjena ugroženosti od odrona provedena je isključivo za karbonatne stijene. Budući je prema gornjem prikazu dio kosina vezan uz naslage fliša, potrebno je naglasiti mjerilo izvora (1:300.000) zbog kojeg su nastala lokalna odstupanja. Treba napomenuti i kako se u tim područjima promatrane kosine često nalaze unutar ili blizu tektonskog kontakta sedimenata fliša i karbonatne stijene (Slika 4-5). U tim slučajevima navučene karbonatne naslage vrlo često strše iznad fliša i kao takve predstavljaju najveću prijetnju za željezničku prugu. Zbog toga su na tim lokacijama vrednovane upravo značajke karbonatne stijenske mase.



Slika 4-5. Kontakt flišnih naslaga i karbonatne stijene (604-133-L)

Karbonatnim sedimentnim stijenama smatraju se stijene koje sadrže više od 50 % karbonatnih minerala, a u njih se ubrajaju vapnenci, dolomitični vapnenci i dolomiti. Pri tome postoje svi postupni prijelazi od vapnenaca u dolomite (Tišljier, 1994).

Područje istraživanja odlikuje se geomorfološkim značajkama krša, koji nastaje kao posljedica uglavnom kemijskog trošenja ili korozijske stijena topivih u vodi. Za formiranje krša nužna su tri

glavna preduvjeta: odgovarajuća litologija koja se odnosi na topive stijene, raspoloživost vode i tektonika koja utječe na stvaranje brojnih diskontinuiteta čime dolazi do znatnog povećanja sekundarne poroznosti. Krš je u Hrvatskoj nastao kao posljedica trošenja karbonatnih naslaga koje su bile izložene izrazito snažnoj tektonici tijekom geološke prošlosti (Vlahović et al., 2005). Sve zajedno, intenzivna tektonika uz prateće procese erozije i okršavanja, kojima pogoduju karbonatna stijenska masa i klimatske značajke, utjecali su na razvoj reljefa kakav je danas prisutan u području Krških Dinarida.

4.3. INŽENJERSKOGEOLOŠKE ZNAČAJKE KARBONATNE STIJENSKE MASE

Za opis inženjerskogeoloških značajki stijena postoje dva osnovna segmenta razmatranja, kod kojih se prema mjerilu promatranja razlikuju značajke koje su vezane za materijal stijene i značajke koje su vezane za stijensku masu. Intaktna stijena je materijal stijene koji se nalazi između diskontinuiteta, tipično predstavljen cijelom jezgrom iz bušotine koja ne sadrži guste strukturne diskontinuitete (ISRM, 1975). Stijenska masa uključuje intaktnu stijenu i diskontinuitete s njihovom ispunom. Pri tome diskontinuitet podrazumijeva bilo koji mehanički prekid u stijenskoj masi koji ima malu vlačnu čvrstoću ili je nema (Benac, 2013) i odnosi se na plove slojevitosti, pukotine te oslabljene zone i rasjede.

Pod značajkama stijenske mase vrlo često se podrazumijevaju: orijentacije diskontinuiteta, veličine blokova, značajke diskontinuiteta, trošnost i prisutnost vode, dok se pod značajkama materijala stijene razmatraju: litologija, struktura, defekti i poroznost. U čvrstim materijalima inženjerskogeološke značajke stijenske mase više ovise o diskontinuitetima nego o značajkama intaktne stijene, jer je materijal stijene oslabljen prisutnim diskontinuitetima. Značajke materijala, s druge strane, utječu na čvrstoću materijala, ali i stijenske mase u slučajevima kad su diskontinuiteti široko razmaknuti ili ne postoje.

U sklopu ovog istraživanja inženjerskogeološke značajke promatrane su na razini cijele kosine, odnosno terenski mjereni/procjenjeni parametri korišteni su za procjenu karakteristika stijenske mase. Za karbonatne stijene karakteristično je formiranje tri osnovna sustava diskontinuiteta koji definiraju blokove unutar stijenske mase te time utječu na njihovu veličinu i oblik. Može se generalno konstatirati kako je karbonatna stijenska masa unutar istraživanog

područja uglavnom blokovita, rjeđe masivna, nepravilna i zdrobljena. Pri tome su česte lokalne, značajno razlomljene zone, od kojih je većina ispunjena glinom ili mješavinom kršja i gline.


Poseban značaj u procjeni ponašanja stijenske mase kod različitih inženjerskih situacija imaju klasifikacije stijenske mase (Hack, 2002). One čine osnovu empirijskog pristupa kojim se povezuju praktično iskustvo prikupljeno na dosadašnjim projektima i uvjeti koji se očekuju na novoj lokaciji istraživanja. Danas se u svijetu najviše koriste klasifikacije RMR (Bieniawski, 1989) i Q (Barton et al., 1974), koje su razvijene za potrebe projektiranja tunelskih podgradnih sustava, zbog čega se i najčešće primjenjuju kod podzemnih iskopa.

Geološki indeks čvrstoće (GSI) razvijen je na temelju nedostataka *RMR* i *Q* klasifikacija u općoj primjeni kategorizacije stijenske mase. Uveo ga je Hoek (Hoek, 1994) te ga razvijao sljedećih desetak godina. GSI u odnosu na spomenute klasifikacije ne uključuje RQD indeks, stanje vode i stanja naprezanja te daje naglasak na osnovna inženjerskogeološka svojstva, čime se više bavi samim svojstvima stijenske mase od mjera zaštite (npr. mjera podgrađivanja). Temelji se na vizualnoj procjeni dvije skupine parametara, blokovitosti preko veličine blokova i teksture te stanju stijenki diskontinuiteta, odnosno njihovoj hrapavosti i trošnosti. Prema takvom opisu stijenske mase, GSI indeks se procjenjuje preko dijagrama.

GSI vrijednosti koje se mogu očekivati za masivne, tankoslojevite i brečaste vapnenačke stijenske mase unutar dijagrami prikazali su Marinos & Hoek (2000). Na temelju procjena tijekom IG prospekcije ali i rezultata detaljnog IG kartiranja i geofizičkih istraživanja za 62 izdvojena „kritična“ segmenta kosina, može se reći kako se većinom radi o povoljnoj (GSI = 41 - 60) i rjeđe dobroj (GSI = 61 - 80) stijenskoj masi. U manjem dijelu je stijenska masa definirana kao slaba (GSI = 21 - 40). Manje GSI vrijednosti mogu se očekivati unutar površinske zone trošenja i zona intenzivnijeg okršavanja ili jače razlomljenih zona koje su vezane uz rasjede ili značajnije pukotine. Prikazane GSI vrijednosti definirane su prema modificiranoj GSI klasifikaciji (Sonmez & Ulusay, 1999).

Inženjerska klasifikacija krša (Waltham & Fookes, 2003) temelji se na trošenju karbonatnih stijena, izdvajanju različitih krških pojava i morfoloških značajki. Ona predstavlja regionalnu klasifikaciju za procjenu okvirnih značajki i stupnja trošenja stijenske mase, a definirano je pet osnovnih tipova krša (Slika 4-6). Može se uočiti kako vrlo mladi i mladi krš imaju dominantno sub-horizontalne diskontinuitete, dok se vertikalni diskontinuiteti značajno pojavljuju unutar

zrelog i kompleksnog krša. Posljednji je stupanj u razvoju ekstremni krš. Najveći dio Dinarskog krša prema ovoj klasifikaciji pripada zrelom i kompleksnom kršu.



Slika 4-6. Morfološki fenomeni krša i njihove značajke (prema Waltham & Fookes, 2003)

Kategorizaciju karbonatnih stijenskih masa u zonama unutar kojih se izvode objekti kao što su usjeci i zasjeci dali su Novosel et al. (1980). Ona se temelji na stupnju okršenosti i razlomljenosti stijene te značajkama pukotina. Uz to, svakoj od sedam definiranih kategorija pridružena su geofizička i mehanička svojstva.

Povećanje intenziteta trošenja kod karbonatne stijenske mase vrlo često uzrokuje otvaranje diskontinuiteta bližih površini, povećanje postojanosti diskontinuiteta, njihovo proširivanje i smanjenje veličine bloka (Pollak et al., 2005; Pollak et al., 2013). Budući je taj intenzitet najizraženiji u površinskim zonama, može se zaključiti kako u karbonatnim stijenama inženjerskogeološke značajke stijenske mase s promjenom dubine mijenjaju svojstva prema povoljnijim značajkama. Pollak (2007) je razvio klasifikaciju karbonatnih stijenskih masa prema trošenju. Klasifikacija definira pet zona trošenja - I: svježja stijena, II: donja zona trošenja, III: gornja zona trošenja, IV: površinska zona trošenja i V: pokrivač. Unutar karbonatnih stijena prepoznata su dva različita modela trošenja, definirana prema karakteristikama intaktnog uzorka i veličini bloka, a značajke spomenutih zona trošenja obuhvaćaju oba modela. Prema spomenutim modelima GSI je modificiran i prilagođen korištenju u okršenim vapnenačkim stijenskim masama.

Kosine promatrane u sklopu istraživanja najčešće su izvedene unutar III. zone i IV. zone trošenja (Slika 4-7, Slika 4-8), rjeđe u II. zoni trošenja i često uz izostajanje pokrivača na vrhu kosine. U određenim slučajevima III. zona trošenja se može prostirati do površine terena. Zbog toga je teško govoriti o debljinama pojedinih zona koje lokalno variraju. Generalno, može se konstatirati kako su granice među zonama jasno vidljive, ali su često vrlo nepravilne.

IV. zona trošenja uglavnom je obilježena slabo vezanim i slobodnim blokovima, te često mješavinom slobodnih blokova i/ili kršja i gline u različitim omjerima. Kod brojnih kosina ovi slobodni blokovi, potpuno odvojeni od stijenske mase, predstavljaju kritična mjesta mogućih pojava odrona, što je posebno značajno kod visokih kosina. Unutar III. zone trošenja stijenska masa je obično jače okršena duž diskontinuiteta, čiji je zijeve uglavnom do centimetarskih, rjeđe decimetarskih veličina. Ispuna diskontinuiteta je najčešće glinovita ili je nema. Karakteristično karbonatnim stijenama, diskontinuiteti su unutar ove zone izraženiji te se zatvaraju prema dubljim zonama. Tako je na mjestima gdje je prisutna II. zona trošenja, postojanost diskontinuiteta manja nego u III. zoni, a diskontinuiteti su milimetarskih širina glinovite ili kalcitne ispune.

Budući se radi o području koje je u geološkoj prošlosti bilo izvrgnuto izrazitim strukturno-tektonskim destrukcijama primarnih platformnih karbonatnih sedimenata, potrebno je naglasiti kako su za mnoge kosine značajne izrazito izražene pukotine ili široke i jače razlomljene zone koje se mogu pratiti po cijeloj visini motrenih kosina. Takvi su segmenti redovito praćeni značajnijim intenzitetom okršavanja, manjom veličinom blokova i glinovitim ispunama ili mješavinom kršja i gline. Osim uz ovakve, subvertikalne diskontinuitete, pojačani intenzitet okršavanja na određenim se lokacijama može pripisati pojavama kaverni.



Slika 4-7. Površinska i gornja zona trošenja (604-85-L)



Slika 4-8. Gornja zona trošenja (604-60-L)


5. METODE PRIKUPLJANJA I OBRADJE PODATAKA

*If we knew what it was we were doing,
it would not be called research, would it?*

Albert Einstein (1879-1955)

Postupku procjene ugroženosti od odrona prethodi segment istraživanja koji se odnosi na prikupljanje i obradu podataka (Slika 5-1). Podaci podrazumijevaju parametre za koje se prema postojećoj literaturi i iskustvu istraživača pretpostavlja da utječu na ugroženost od moguće pojave odrona.

Kao osnova za odabir klasifikacijskih parametara i princip njihovog vrednovanja preuzet je *Rockfall Hazard Rating System* (RHRS). Iako postoje njegove brojne modifikacije (poglavljje 3.1.1.), u sklopu doktorskog rada temelje se na kombinaciji sustava sjevernoameričkih država Oregon (Pierson & Van Vickle, 1993), Tennessee (Mauldon et al., 2007) i Colorado (Russell et al., 2008). Kod njih su, kao i kod većine razrađenih sustava, u sustav uključeni i parametri koji se odnose na značajke prometnice i prometa (npr. vidljivost, izloženost vozila riziku, širina prometnice, frekvencija prometa). Potrebno je naglasiti kako je u sklopu ovog istraživanja naglasak stavljen na prikupljanje podataka o inženjerskogeološkim značajkama i geometrijskim značajkama kosine, dok se podaci o značajkama željezničke pruge i prometa nisu prikupljali. Isto tako, postojeći sustavi u postupak klasifikacije kosina uključuju i vrednovanje podataka o učestalosti pojave odrona na određenoj lokaciji, dok se u sklopu doktorskog rada ti podaci koriste za verifikaciju.



Slika 5-1. Dijagram toka za 1. segment istraživanja - Prikupljanje podataka

Prikupljanje podataka obavljeno je u okviru inženjerskogeološke (IG) prospekcije. Obzirom na velik broj lokacija na kojima je provedena, IG prospekcija predstavlja najdugotrajniji postupak u sklopu istraživanja, a podrazumijeva mjerenje i procjenu 15-tak parametara na svakoj izdvojenoj lokaciji.

Naravno da je u konačnici procjena ugroženosti preciznija što se u obzir uzima veći broj parametara. Ipak, kao i kod klasifikacija stijenske mase poželjno je držati se pravila kako se treba koncentrirati na one klasifikacijske parametre koji najviše utječu na promatranu pojavu i koji se mogu na terenu odrediti jednostavnim metodama (Bieniawski, 1989). Tada je i IG prospekcija ostvarila svoju svrhu - prikupljanje podataka o najvažnijim parametrima na brz i jednostavan način.

Ranije spomenuti sustavi većinom su razvijeni za primjenu kod kosina duž cestovnih prometnica. U odnosu na njih, tijekom IG prospekcije koja je provedena uz željezničku prugu uočene su sljedeće razlike:

- kosine su najčešće izvedene vrlo strmo, mogu biti značajno visoke i uglavnom su na relativno maloj udaljenosti od osi pruge,
- odroni osim same pruge mogu ugroziti i prateće infrastrukturne elemente (npr. limene kanalice s električnim instalacijama),
- te ono što je najvažnije, na tračnicama ne postoji mogućnost zaobilaženja odlomljenog bloka ili materijala kao i naglo zaustavljanje vlaka.

Za potrebe prikupljanja podataka oblikovan je terenski formular (Slika 5-2), za čiju su izradu osnovne smjernice preuzete od onih vezanih za izradu cijelog *RHRS* sustava (Pierson & Van Vickle, 1989). One se mogu sažeti u četiri glavne točke, a njima se naglašava kako:

- sustav mora biti razumljiv i primjenjiv,
- svi parametri koji se vrednuju moraju biti dobro objašnjeni,
- nekoliko različitih ocjenjivača može dobiti ujednačene rezultate,
- rezultirajući bodovi ispravno procjenjuju opasnost od odrona.

Uz to, terenski je formular prema različitim tipovima snimanih podataka prilagođen na sljedeći način:

- za parametre čije se vrijednosti procjenjuju unaprijed su definirane četiri klase, kojima se obuhvatio raspon vrijednosti njihovih značajki od najpovoljnijih do najnepovoljnijih (npr. *Izraženost moguće pojave odrona*), pri čemu klasa I podrazumijeva najpovoljnije vrijednosti parametra, a klasa IV najnepovoljnije,
- za parametre čije se vrijednosti direktno mjere predviđeno je upisivanje izmjerenih vrijednosti kako bi se klase parametara mogle kreirati naknadno (npr. *Visina kosine*);
- za parametre koji su opisni predviđeno je mjesto za upisivanje teksta (npr. *Litologija*).

Kako bi se osigurala dosljednost kod mjerenja/procjene te usporedivost podataka, prije provođenja IG prospekcije usuglašena je metodologija prikupljanja podataka kod svih istraživača uključenih u proces. Isto tako, kako bi se subjektivnost kod procjene parametara

svela na minimum, prikupljanje podataka na jednoj lokaciji provodila su minimalno dva istraživača.

Metodologija za procjenu ugroženosti od odrona, pa tako i prikupljanja podataka, razvijala se prije, ali i tijekom provođenja IG prospekcije. To je dovelo do manjih izmjena u prikupljanju podataka, u smislu dodavanja nekoliko novih parametara (procjenu/mjerenje *Značajki pojedinog tipa odrona* i *Veličine bloka* za sve tipove odrona, a ne samo za tip odrona koji je na lokaciji procijenjen kao najkritičniji, procjenu *Tragova odrona*). Zbog toga ti podaci za određene lokacije, one na kojima je prospekcija provedena u ranijoj fazi, ne postoje. Koliko god se nastojala na određeni način zadržati sustavnost, kako bi se svi podaci u konačnici mogli uspoređivati, ipak su kod određenih analiza razmatrani samo segmenti na kojima je prikupljanje podataka provedeno na jednak način (npr. kod provođenja verifikacije prema parametru *Tragovi odrona*).

PRUGA No	USJEK No	STRANA USJEKA	PROCIJENJENA STABILNOST	FOTO
		D ☐ L ☐ F ☐	A ☐ A- ☐ B+ ☐ B ☐ B- ☐ C+ ☐ C ☐	DATUM
STACIONAŽA (OD-DO) [km+m]				GEOLOG

OSOBNI DOJAM	
--------------	--

MAX. VISINA USJEKA [m]		NAGIB [°]		BROJ BERMI	
VISINA POTENCIJALNOG ODRONA [m]		LITOLOGIJA		POSTOJEĆA SANACIJA	
UDALJENOST OD OSI PRUGE [m]		JARAK DA NE	BROJ SUSTAVA DISKONTINUITETA	VOLUMEN mogućeg odrona [cm³cm³cm]	

TRAGOV ODRONA	svježi tragovi odrona na stijeni	nema	vrlo rijetko / lokalno	sporadično	učestalo / kontinuirano
	odronjeni blokovi u jarku				

RAZVEDENOST KOSINE (topografske varijacije)	blage padine sa vrlo malo ili bez varijacija	male varijacije (< 0,6m)	srednje varijacije (0,6 - 1,8m)	značajne varijacije (> 1,8m)
OKRŠENOST	nema	rijetko	srednje	učestalo
VODA	suho	vlažno	kapanje	tečenje

RAVNINSKI SLOM	KLINASTI SLOM	
IZRAŽENOST [%]	malo (< 10)	umjereno (10-20) izražen (20-30) jako (> 30)
dom.VELIČINA BLOKA max.VELIČINA BLOKA [cm³cm³cm]		
ZIJEV diskontinuiteta	zatvoreni	mm dimenzija cm dimenzija dm dimenzija
ISPUNA diskontinuiteta	nema	prevlaka (< 1 mm) tvrda ispuna (> 1 mm) meka ispuna (> 1 mm)
NAGIB diskontinuiteta [°]	0-20	20-40 40-60 > 60
HRAPAVOST diskontinuiteta	valovito / hrapavo	valovito / glatko ravno / hrapavo ravno / glatko
PREVRTANJE		
IZRAŽENOST [%]	malo (< 10)	umjereno (10-20) izražen (20-30) jako (> 30)
dom.VELIČINA BLOKA max.VELIČINA BLOKA [cm³cm³cm]		
DIF. TROŠENJE		
IZRAŽENOST [%]	malo (< 10)	umjereno (10-20) izražen (20-30) jako (> 30)
dom.VELIČINA BLOKA max.VELIČINA BLOKA [cm³cm³cm]		
NEKOMPETENTNI SLOJEVI	< 2 sloja; < 15 cm	< 2 sloja; > 15 cm > 2 sloja; < 15 cm > 2 sloja; > 15 cm
OBRUŠAVANJE	OSIPAVANJE	
IZRAŽENOST [%]	malo (< 10)	umjereno (10-20) izražen (20-30) jako (> 30)
dom.VELIČINA BLOKA max.VELIČINA BLOKA [cm³cm³cm]		
OBLIK BLOKA	pločast	nepravilan ekvidimenzionalan zaobljen
RAZLOMLJENE ZONE		
IZRAŽENOST [%]	malo (< 10)	umjereno (10-20) izražen (20-30) jako (> 30)
dom.VELIČINA BLOKA max.VELIČINA BLOKA [cm³cm³cm]		
OBLIK BLOKA	pločast	ekvidimenzionalan nepravilan zaobljen

NAPOMENA	
----------	--

Slika 5-2. Terenski formular korišten tijekom IG prospekcije

5.1. INŽENJERSKOGEOLOŠKA PROSPEKCIJA

IG prospekcija provedena je unutar istraživanog područja na lokacijama koja su Nadzorna središta Hrvatskih željeznica procijenila kao potencijalno opasne. U njoj je sudjelovalo sedam inženjera Zavoda za hidrogeologiju i inženjersku geologiju Hrvatskog geološkog instituta. Provedena je tijekom veljače, ožujka, travnja i kolovoza 2014., te ožujka i travnja 2015. godine (Slika 5-3).

Lokacije na kojima je provedeno istraživanje uključuju ukupno 332 kosine, odnosno 317 usjeka i zasjeka, u duljini od 74,888 km te 15 nadusjeka tunela (Tablica 5-1). Prosječna duljina kosine iznosi 225 m.

Valja napomenuti kako su pri tome zasebno brojane desna i lijeva strana kada se radilo o istom usjeku, te je u pojedinim slučajevima kosina izdvajana u segmente kada se procijenilo da:

- geometrijski odnosi između kosine ili diskontinuiteta i pruge duž kosine se značajno mijenjaju i drugačije utječu na mogućnost pojave određenog tipa odrona (npr. zavoj pruge),
- na određenim dijelovima dugih kosina značajno dominiraju različiti tipovi odrona,
- kosina je predugačka da bi se mogla napraviti dobra vizualna procjena parametara.



Slika 5-3. Inženjerskogeološka prospekcija: a) mjerenje *Visine*; b) mjerenje *Veličine bloka*

Tablica 5-1. Pregled broja lokacija na kojima je provedena IG prospekcija

	PRUGA	USJEK (L i D)	ZASJEK (D)	ZASJEK (L)	NADUSJEK	UKUPNO	SEGMENT
broj	M202	86	17	17	8	128	145
dužina [km]		22,666	4,258	3,640	0	30,564	
broj	M602	4	0	1	0	5	9
dužina [km]		2,100	0	0,420	0	2,520	
broj	M502	60	2	4	0	66	75
dužina [km]		16,276	0,500	0,850	0	17,626	
broj	M604	52	35	39	7	133	146
dužina [km]		11,196	4,691	8,291	0	24,178	
UKUPNO (M202, M602, M502, M604)							
broj		202	54	61	15	332	375
dužina [km]		52,238	9,449	13,201	0	74,888	

U sklopu istraživanja na svakoj lokaciji provedena je najprije preliminarna, a onda i detaljna procjena.

5.1.1. Preliminarna procjena

Preliminarna procjena predstavlja ugroženost željezničke pruge od odrona koja je procijenjena na temelju vizualnog subjektivnog dojma istraživača, sa svrhom preliminarnog definiranja stanja kosine. U sklopu ovog istraživanja, zbog razloga koji su već obrazloženi, povijesni podaci o pojavi odrona nisu uzeti u obzir. Tako su preliminarnom procjenom procijenjene mogućnost pojave odrona i značajke kosine, koje utječu da odron ugrozi željezničku prugu.

Bez obzira na klasu preliminarne procjene, daljnja detaljna procjena provedena je za sve segmente. Podaci preliminarne procjene korišteni su za verifikaciju bodovnih modela (poglavlje 6.4.1.).

Kosine su prema preliminarnoj procjeni svrstane u jednu od sljedećih klasa:

- A: značajna mogućnost pojave odrona i/ili nepovoljne značajke kosine (Slika 5-4),
- B: umjerena mogućnost pojave odrona i/ili umjereno nepovoljne značajke kosine (Slika 5-5),
- C: mala mogućnost pojave odrona i/ili povoljne značajke kosine (Slika 5-6).

U sklopu istraživanja, tijekom IG prospekcije, za kosine koje su procjenom bile na granici između dvije klase, u ranoj fazi istraživanja uvedene su i dodatne klase (A-, B+, B-, C+).



Slika 5-4. Preliminarna procjena - klasa A (604-11-D)



Slika 5-5. Preliminarna procjena - klasa B (502-20-D)



Slika 5-6. Preliminarna procjena - klasa C (604-99-D)

5.1.2. Detaljna procjena

Detaljna procjena podrazumijeva prikupljanje podataka o parametrima koji su definirani u sklopu terenskog formulara (Slika 5-2). U nastavku se daje prikaz onih parametara koji su prikupljeni tijekom IG prospekcije i koji su u nastavku doktorskog rada korišteni u sklopu barem jednog bodovnog modela.

Pri tome se razlikuju tri skupine parametara. Prva skupina, u koju spada većina parametara, odnosi se na one kod kojih su vrijednosti njihovih značajki pripisivane unaprijed definiranim klasama, prije detaljne procjene (npr. *Izraženost moguće pojave odrona*). Druga skupina odnosi se na parametre za čije su značajke bilježene izmjerene vrijednosti (npr. *Visina potencijalnog odrona*). Klase parametara definirane su naknadno - za *Veličinu bloka* na temelju postojećih klasifikacija, za *Visinu*, *Nagib* i *Udaljenost* na temelju raspona izmjerenih vrijednosti na svim segmentima. Za definiranje klase *Nagiba* korištene su i simulacije odrona. Treća skupina parametara odnosi se na one čije vrijednosti nisu mjerene niti procijenjene tijekom IG prospekcije. Vrijednosti su izvedene iz već postojećih podataka (npr. *Broj tipova odrona*).

Zbog bolje preglednosti, u sklopu ovog poglavlja prikazane su razrade klase za sve navedene skupine parametara.

Prema karakteristikama koje pojedini parametar opisuje, također se razlikuju tri skupine parametara: inženjerskogeološke značajke, klimatske značajke i geometrijske značajke kosine.


Inženjerskogeološke značajke uključuju one parametre koji su vezani za značajke stijenske mase i pripisuju se onom tipu odrona koji je prepoznat na segmentu kosine (ravninski slom, klinasti slom, prevrtanje, obrušavanje, osipavanje, obrušavanje i osipavanje uz razlomljene zone, diferencijalno trošenje). Pri tome je *Izraženost moguće pojave odrona*, ukoliko je na pojedinom segmentu prisutno više različitih tipova odrona, procijenjena za sve pojedine tipove odrona, dok su *Veličina bloka* i *Značajke određenog tipa odrona* mjerene/procijenjene samo za onaj tip odrona koji je definiran kao najkritičniji. Za željezničke pruge M502 i M604 podaci svih parametara prikupljeni su za sve tipove odrona, neovisno o tome koji je najkritičniji. Uz njih, ovoj skupini značajki pripadaju *Okršenost* i *Voda na kosini*, koji se pripisuju segmentu kosine.

▪ *Izraženost moguće pojave odrona (Izraženost)*

predstavlja postotni dio ukupne površine kosine u kojem može doći do pojave određenog tipa odrona. Vrijednosti parametra procijenjene su prema unaprijed definiranim klasama (Tablica 5-2), preuzetim od Mauldon et al. (2007). Kao pomoć pri procjeni korišten je vizualni prikaz graničnih vrijednosti klasa parametra (Slika 5-7). Veća izraženost procesa upućuje na veću mogućnost pojave odrona, pa prema tome podrazumijeva i nepovoljniju klasu (Slika 5-8).

Tablica 5-2. Klase parametra *Izraženost*

PARAMETAR	KLASA			
	I	II	III	IV
IZRAŽENOST [%]	< 10	10-20	20-30	> 30



Slika 5-7. Vizualni prikaz (linijski i točkasti) graničnih vrijednosti klasa parametra *Izraženost* (prema Mauldon et al., 2007): a) 10 %; b) 20 %; c) 30 %; d) 40 %



Slika 5-8. Procjena parametra *Izraženost*: a) klasa I (604-56-L); b) klasa IV (202-11-D)

▪ *Veličina bloka*

predstavlja veličinu potencijalno nestabilnog bloka/volumena materijala (Slika 5-9), a razlikuju se:

- dominantna veličina bloka koja predstavlja najučestaliju veličinu potencijalno nestabilnih blokova za određeni tip odrona,
- maksimalna veličina bloka koja predstavlja veličinu procijenjenog maksimalnog potencijalno nestabilnog bloka za određeni tip odrona,
- volumen potencijalno nestabilnog materijala, ukoliko postoji mogućnost odrona određenog volumena koji se sastoji od blokova različite veličine, za određeni tip odrona.

Sve ove veličine procijenjene su vizualno za manje blokove, a za veće su mjerene metrom ili laserskim daljinomjerom (TruPulse 360B, Laser Technology Inc.) kod nedostupnih blokova. Veličine su izražene kao dužine tri međusobno okomite stranice bloka/volumena materijala.

Slika 5-9.a prikazuje primjer procjene veličine blokova, gdje je jasno vidljiva razlika između dominantnog i maksimalnog bloka. Dimenzije stranica dominantnog bloka u konkretnom slučaju iznose 8*15*8 cm, dok su dimenzije stranica maksimalnog bloka 60*40*20 cm. Slika 5-9.b prikazuje potencijalno nestabilan volumen materijala.



Slika 5-9. Procjena parametra *Veličina bloka*: a) dominantna i maksimalna veličina bloka (604-13-L); b) volumen potencijalno nestabilnog materijala (202-55-2-L)

Za definiranje klasa preuzete su dvije postojeće klasifikacije.

– *Veličina bloka (a)*

Klase se temelje na klasifikaciji prema Palmstrom-u (Palmstrom, 2005), koji u obzir uzima volumen bloka, uz modifikaciju u četiri klase od originalnih pet klasa (Tablica 5-3).

– *Veličina bloka (b)*

Klase se temelje na klasifikaciji prema ISO standardu (ISO, 14689-1, 2003), koja u obzir uzima prosječnu dužinu stranice, uz modifikaciju u četiri klase od originalnih pet klasa (Tablica 5-4).

U tom je slučaju veličina izražena preko sljedeće formule:

$$x = \sqrt[3]{a * b * c} \text{ [cm]} \quad (5-1)$$

gdje je: x ... veličina bloka/volumena [cm]; a, b, c ... dužine tri međusobno okomite stranice bloka/volumena [cm].

Tablica 5-3. Klase parametra *Veličina bloka (a)*

PARAMETAR	KLASA			
	I	II	III	IV
VELIČINA BLOKA [dm ³]	< 0,2	0,2-10	10-200	> 200

Tablica 5-4. Klase parametra *Veličina bloka (b)*

PARAMETAR	KLASA			
	I	II	III	IV
VELIČINA BLOKA [cm]	< 20	20-60	60-200	> 200

U nastavku se navode parametri koji predstavljaju *Značajke određenog tipa odrona* i pripisuju se isključivo njemu. Za sve ove parametre unaprijed su definirane klase te su njihove vrijednosti određene na temelju vizualne procjene.

Kod ravninskog i klinastog sloma značajke diskontinuiteta od izuzetnog su značaja, jer direktno utječu na mogućnost pojave odrona. Uključuju sljedeće parametre:

- *Nagib diskontinuiteta,*
- *Hrapavost diskontinuiteta,*
- *Zijev diskontinuiteta,*
- *Ispuna diskontinuiteta.*

Klase parametara *Nagib* i *Hrapavost* preuzete se prema Mauldon et al. (2007), dok su klase parametara *Zijev* i *Ispuna* definirane na temelju poznavanja inženjerskogeoloških značajki karbonatne stijenske mase istraživanog područja od strane istraživača (Tablica 5-5).

Tablica 5-5. Klase parametara *Nagib diskontinuiteta*, *Hrapavost diskontinuiteta*, *Zijev diskontinuiteta* i *Ispuna diskontinuiteta*

PARAMETAR	KLASA			
	I	II	III	IV
NAGIB DISKONTINUITETA [°]	< 20	20-40	40-60	> 60
HRAPAVOST DISKONTINUITETA	valovito-hrapavo	valovito-glatko	ravno-hrapavo	ravno-glatko
ZIJEV DISKONTINUITETA	zatvoreni	mm dimenzija	cm dimenzija	dm dimenzija
ISPUNA DISKONTINUITETA	nema	prevlaka (< 1 mm)	tvrda (> 1 mm)	meka (> 1 mm)

Za prevrtanje nisu uzete u obzir posebne značajke, tako da za taj tip odrona nema dodatnih parametara (Mauldon et al., 2007).

Iako Mauldon et al. (2007) diferencijalnom trošenju pripisuju parametar *Reljef*, u sklopu doktorskog rada umjesto njega je za ovaj tip odrona korišten parametar koji opisuje značajke nekompetentnih slojeva. Budući su značajke koje vrednuju parametar *Reljef* uključene unutar parametra *Razvedenost* u sklopu geometrijskih značajki, na ovaj se način izbjeglo vrednovanje iste značajke dva puta.

- *Nekompetentni slojevi*

odnose se na broj i debljinu nekompetentnih slojeva u vertikalnom presjeku cijele visine kosine. Klase parametra unaprijed su definirane (Tablica 5-6) prema Russell et al. (2008). Budući kako njihova zastupljenost direktno utječe na stvaranje nepovoljnih uvjeta za pojavu mogućeg odrona kompetentnih slojeva, najveći broj i najveća debljina nekompetentnih slojeva predstavlja najnepovoljniju klasu.

Tablica 5-6. Klase parametra *Nekompetentni slojevi*

PARAMETAR	KLASA			
	I	II	III	IV
NEKOMPETENTNI SLOJEVI	< 2 sloja; < 15 cm	< 2 sloja; > 15 cm	> 2 sloja; < 15 cm	> 2 sloja; > 15 cm

▪ *Oblik bloka*

predstavlja parametar koji se pripisuje osipavanju. Klase parametra unaprijed su definirane i modificirane su prema Russel et al. (2008). Modifikacija se odnosi na promjenu redoslijeda klasa II i III, smatrajući nepravilan oblik povoljniji zbog omogućavanja boljeg uklještenja u stijenskoj masi (Tablica 5-7).

Tablica 5-7. Klase parametra *Oblik bloka*

PARAMETAR	KLASA			
	I	II	III	IV
OBLIK BLOKA	pločast	nepravilan	ekvidimenzionalan	zaobljen

▪ *Okršenost*

podrazumijeva procjenu izraženosti procesa okršavanja duž kosine koji može doprinijeti lakšem odvajanju blokova od stijenske mase. Procjenjuje se prema vizualnim pokazateljima samog procesa, pri čemu se u obzir uzimaju značajke stijenki i ispune diskontinuiteta odnosno postojanje znakova korozije, većih ili manjih kaverni i učestalost navedenih pojava. Klase su unaprijed definirane (Tablica 5-8) prema Saroglou et al. (2012). Veća izraženost procesa pogoduje mogućnosti pojave odrona, pa prema tome predstavlja nepovoljniju značajku (Slika 5-10).

Tablica 5-8. Klase parametra *Okršenost*

PARAMETAR	KLASA			
	I	II	III	IV
OKRŠENOST	nema	rijetko	srednje	učestalo



Slika 5-10. Procjena parametra *Okršenost* - klasa IV (202-51-1-L)

▪ *Voda na kosini (Voda)*

odnosi se na odsutnost ili prisutnost i količinu vode na kosini u vrijeme provođenja IG prospekcije. Klase su unaprijed definirane (Tablica 5-9) prema Russell et al. (2008). Kako pojava vode direktno utječe na stabilnost kosine, prisutnost tečenja čini najnepovoljniju klasu.

Tablica 5-9. Klase parametra *Voda*

PARAMETAR	KLASA			
	I	II	III	IV
VODA NA KOSINI	suho	vlažno	kapanje	tečenje

▪ *Broj tipova odrona*

predstavlja parametar izveden iz podataka parametra *Izraženost*. Odnosi se na ukupan broj svih tipova odrona koji su utvrđeni na segmentu kosine. Pri tome se u obzir uzimaju oni tipovi odrona kojima je, uz onaj koji je procijenjen kao najkritičniji, *Izraženost* u ili iznad klase s vrijednosti 10-20 %. Veći broj različitih tipova odrona označava i veću izraženost moguće pojave odrona, u odnosu na onu promatranu samo za najkritičniji tip odrona. Samim time veći broj tipova odrona podrazumijeva i nepovoljniju značajku (Tablica 5-10).

Tablica 5-10. Klase parametra *Broj tipova odrona*

PARAMETAR	KLASA			
	I	II	III	IV
BROJ TIPOVA ODRONA	1	2	3	>3

Klimatske značajke unutar nekog područja, uz inženjerskogeološke značajke i metodu izvedbe kosine, značajno utječu na trošenje stijenske mase. Pri tome su od velikog značaja temperaturne promjene, odnosno ciklusi smrzavanja - odmrzavanja te hidratacija-dehidratacija. Stoga su u procjenu ugroženosti od odrona uključene značajke koje direktno utječu na spomenute procese.

▪ *Srednja godišnja količina oborina i srednja godišnja temperatura zraka (Oborine i temperatura)*

čine parametar čije su vrijednosti preuzete iz postojećih podataka. Prema srednjoj godišnjoj količini oborina (Gajić-Čapka et al., 2003) i srednjoj godišnjoj temperaturi zraka (Zaninović et al., 2004) definirane su četiri klase za istraživano područje. Pri tome je kao najnepovoljnija definirana ona s najvećom srednjom godišnjom količinom oborina i najnižom srednjom godišnjom temperaturom zraka (Tablica 5-11).

Tablica 5-11. Klase parametra *Oborine i temperatura*

PARAMETAR	KLASA			
	I	II	III	IV
SREDNJA GOD. KOLIČINA OBORINA [mm], SREDNJA GOD. TEMPERATURA ZRAKA [°C]	< 2000, > 9	< 2000, < 9	> 2000, > 9	> 2000, < 9

Geometrijske značajke odnose se na one karakteristike kosine koje direktno utječu na ugroženost, u smislu mogućnosti da pokrenuti materijal dosegne željezničku prugu. To uključuje visinu potencijalnog odrona, nagib kosine, udaljenost kosine od pruge i postojanje zaštitnog jarka te razvedenost kosine.

▪ *Visina potencijalnog odrona (Visina)*


odnosi se, kao i prema postojećim sustavima, na maksimalnu visinu na kojoj postoji mogućnost pojave odrona. Ovu visinu treba razlikovati od maksimalne visine kosine, od koje može biti i veća ukoliko iznad izvedene kosine postoji prirodna padina s koje se može očekivati pojava odrona. Mjerena je laserskim daljinomjerom, kao vertikalna udaljenost od podnožja kosine do najvišeg mjesta potencijalnog odrona.

Klase su definirane prema rasponu vrijednosti svih izmjerenih visina na način da granice klasa čine 25 %, 50 % i 75 % od maksimalne vrijednosti visine kada se ne uzimaju u obzir netipične vrijednosti. Na taj način granice klasa čine vrijednosti visine od 6 m, 11 m i 16 m (Tablica 5-12). Kosine se prema tim klasama mogu opisati kao niska, srednje visoka, visoka i vrlo visoka (Slika 5-11).

Blok/materijal odlomljen s veće visine imat će veću kinetičku energiju, a time i značajniju (veću) pokretljivost, čime se povećava mogućnost da dosegne željezničku prugu. Zbog toga veća visina označava nepovoljniji utjecaj.

Tablica 5-12. Klase parametra *Visina*

PARAMETAR	KLASA			
	I	II	III	IV
VISINA [m]	<6	6-11	11-16	>16



Slika 5-11. Klase parametra *Visina*: a) klasa I: niska kosina (604-30-L); b) klasa II: srednje visoka kosina (502-25-L); c) klasa III: visoka kosina (202-70-D); d) klasa IV: vrlo visoka kosina (604-90-L)

▪ *Nagib kosine (Nagib)*

predstavlja prosječan nagib pod kojim je kosina izvedena. Mjeren je geološkim kompasom. Ukoliko je nagib kosine promjenjiv, mjereno je na dijelu kosine gdje je on najveći, a gdje postoji mogućnost pojave odrona. Za definiranje klasa korištene su dvije metode.

– *Nagib (a)*


Klase su definirane prema rasponu vrijednosti svih izmjerenih nagiba, polazeći od pretpostavke kako veći nagib podrazumijeva nepovoljniju značajku. Granične vrijednosti klasa postavljene su na 60°, 70° i 80° (Tablica 5-13).

Tablica 5-13. Klase parametra *Nagib (a)*

PARAMETAR	KLASA			
	I	II	III	IV
NAGIB (a) [°]	< 60	60-70	70-80	> 80

– *Nagib (b)*

Klase su definirane na temelju simulacija odrona provedenih korištenjem programa *Rockfall* (RocScience Inc., 2010). U simulacijama su uzeti u obzir profili kosine prema karakterističnim vrijednostima visine i veličine bloka na istraživanom području, sa ciljem određivanja utjecaja promjene nagiba na udaljenost koju odlomljeni blok može doseći (Slika 5-12).



Slika 5-12. Simulacija odrona pomoću Rocfall softvera - određivanje maksimalne udaljenosti odlomljenih blokova

Za visine su uzete one vrijednosti koje čine granice klase parametra *Visina*, odnosno 6 m, 11 m i 16 m. Za veličine bloka vrijednosti su preuzete prema granicama klase volumena blokova (parametar *Veličina bloka (a)*), odnosno 0,5 kg, 27 kg i 540 kg. Simulacije su pojednostavljene na način da nije uziman u obzir zaštitni jarak, te su vrijednosti ulaznih parametara potrebnih za provođenje simulacije (gustoća stijene, razvedenost kosine, kutna brzina) predstavljale konstantne vrijednosti. Uz to, za provođenje simulacija broj odlomljenih blokova definiran je na 100 blokova.

Za svaku od kombinacija spomenutih vrijednosti visine i veličine bloka, nagib kosine mijenjan je u intervalima od 10°, odnosno 5°. Na taj način provedene su 72 simulacije, a bilježena je maksimalna udaljenost koju može doseći barem jedan odlomljeni blok (Tablica 5-14). Rezultati su pokazali kako na nju puno veći utjecaj ima visina od veličine bloka. Na temelju dobivenih rezultata definirane su klase parametra *Nagib* (Tablica 5-15).

Tablica 5-14. Maksimalna udaljenost [m] koju može doseći barem jedan odlomljeni blok u ovisnosti težine odlomljenog bloka i nagiba kosine, za visine 5 m, 11 m i 16m

	nagib kosine [°]											
visina = 5 m	10	20	30	40	50	55	60	70	75	80	85	90
0,5 kg	0	0	0,9	2	2,8	2,9	3	2,1	1,8	1	2,8	0
27 kg	0	0	0,9	2	2,8	2,6	3	2,6	1,8	1	3	0
540 kg	0	0	0,9	2	2,8	2,9	3	2,3	2	2	3	0
visina = 11 m												
0,5 kg	0	0	2,2	4	6	6	6	5,4	3,7	3	5,5	0
27 kg	0	0	2,2	4	6	6	6	4,8	4,5	4	5,5	0
540 kg	0	0	2,2	5	6	6	6	4,8	4	4	5	0
visina = 16 m												
0,5 kg	0	0	2,9	6	7,9	9	8	6,7	6,1	6	7,2	0
27 kg	0	0	2,9	6	8,8	8	8	6,4	5,8	4	7,4	0
540 kg	0	0	2,9	6	7,4	9,4	9	7	5,9	4	8,3	0

Tablica 5-15. Klase parametra *Nagib* (*b*)

PARAMETAR	KLASA			
	I	II	III	IV
NAGIB (<i>b</i>) [°]	0-25, 87-90	25-45, 70-82	55-70	45-55, 82-87

Prema vrijednostima nagiba unutar klasa parametra može se vidjeti kako su dobiveni rezultati slični onima u sklopu provedenih istraživanja (Pfeiffer & Higgins, 1990). Kod njih je korištenjem Programa za simulaciju odrona države Colorado (*Colorado Rockfall Simulation Program*) zaključeno kako su najpovoljniji nagibi kosina 20° i 90°, a najnepovoljniji nagibi kosina 30° i 85°.

- *Udaljenost kosine i zaštitni jarak (Udaljenost)*

Udaljenost predstavlja razmak kosine od osi pruge i mjerena je laserskim daljinomjerom. Ukoliko ona nije ujednačena duž kosine, mjerena je najmanja udaljenost na dijelu kosine gdje postoji mogućnost pojave odrona te je u slučaju postojanja dva kolosijeka udaljenost mjerena od osi onog koji je bliže kosini. Zaštitni jarak odnosi se na postojanje jarka u podnožju kosine. Tijekom istraživanja ovaj je parametar bilježen kao binarni podatak (jarak postoji/jarak ne postoji), dok dimenzije jarka i njegova učinkovitost zadržavanja odlomljenih blokova nisu mjereni/procijenjeni.

Klase su definirane kombinacijom vrijednosti udaljenosti i podataka o postojanju zaštitnog jarka. Na temelju raspona vrijednosti svih izmjerenih udaljenosti, klase su definirane na način da granice klase čine 50 % i 75 % od vrijednosti maksimalne udaljenosti kada se ne uzimaju u obzir netipične vrijednosti. Podaci o postojanju zaštitnog jarka uključeni su kod definiranja klase II i klase III (Tablica 5-16).

Tablica 5-16. Klase parametra *Udaljenost*


PARAMETAR	KLASA			
	I	II	III	IV
UDALJENOST KOSINE [m], ZAŠTITNI JARAK	> 5	3-5, jarak postoji	3-5, jarak ne postoji	< 3

- *Razvedenost kosine (Razvedenost)*

odnosi se na procjenu morfološke razvedenosti vertikalnog poprečnog profila koja utječe na mogućnost lansiranja odlomljenog materijala na željezničku prugu. Procijenjena je vizualno na temelju unaprijed definiranih klasa (Tablica 5-17) prema Santi et al. (2009). Značajnija razvedenost kosina upućuje na veću mogućnost lansiranja odlomljenog materijala do željezničke pruge te time označava nepovoljniji utjecaj (Slika 5-13).

Tablica 5-17. Klase parametra *Razvedenost*

PARAMETAR	KLASA			
	I	II	III	IV
RAZVEDENOST KOSINE	blage kosine ili kosine bez varijacija	male varijacije (< 0,6 m)	srednje varijacije (0,6 - 1,8 m)	značajne varijacije (> 1,8 m)



Slika 5-13. Procjena parametra *Razvedenost*: a) klasa I (604, 95-D); b) klasa II (604, 19-D); c) klasa III (502-19-D); d) klasa IV (202-59-L)

5.2. INVENTAR KOSINA

Jedan od bitnih segmenata kod razvoja i uspostave bilo kojeg sustava je način pohranjivanja podataka, a posebno je važan kada se radi o velikom broju podataka. Jednostavan i brz pristup traženim informacijama predstavlja problem ako podatke nije moguće pretraživati i sortirati na određeni način (Bateman, 2003), što je slučaj kod formulara, odnosno podataka

pohranjenih u papirnatom obliku. U tu svrhu, u MS Accessu kreirana je baza podataka – Inventar kosina (Slika 5-14).

Ona omogućava unos snimljenih podataka preko definiranih formi, pohranjivanje podataka na jednom mjestu te upravljanje njima, odnosno njihovu izmjenu, ažuriranje, pretraživanje. Osim toga, predstavlja podlogu koju je moguće jednostavno prilagoditi mogućim unaprjeđenjima same baze ako se za to ukaže potreba (npr. integracija baze podataka u GIS okruženje). U sklopu Inventara kosina, osim parametara koji su korišteni za klasificiranje kosina prema ugroženosti od odrona, pohranjeni su i podaci o lokaciji (u obliku stacionaže) i postojećim mjerama sanacije, kao i brojevi fotografija, datum mjerenja/procjene parametara i imena osoba koje su prikupile podatke.

STABILNOST USJEKA / ZASJEKA

OPĆI PODACI

Id 105	Pruga 202	Usjek 69	Segment 0	Strana usjeka Desna	Procijenjena stabilnost B	Foto - od 8038	Foto - do 8069
Stacionaža - od 630020		Stacionaža - do 630200		Geolog Buljan, Navratil		Datum: 28.2.2014.	

Osobni dojam
Do 630+120 ravni srom po izraženim diskontinuitetima nepovoljne orijentacije. U ostalom dijelu prevrtanje blokova iz površinske zone trošenja uz rjeđu pojavu ravnog sloma.

Napomena
Postoje limene kanalice.
Kišni dan.

SearchID 105

GEOMETRIJA USJEKA OSNOVNE ZNAČAJKE RAVNI SROM KLINASTI SROM PREVRTANJE DIF. TROŠENJE OSIPAVANJE RASJEDNE ZONE

Id 105

Litologija Vapnenac

Broj sustava disk. 3+1

Značajke padine srednje varijacije (0,6-1,8m)

Okršenost srednje

Vegetacija nema

Voda vlažno

TRAGOVİ ODRONA

Tragovi na stijeni

Tragovi u jarku

VOLUMEN potencijalnog odrona

volumen x 0

volumen y 0

volumen z 0

VELIČINE BLOKA

dom. vel. x 35 max. vel. x 120

dom. vel. y 20 max. vel. y 130

dom. vel. z 30 max. vel. z 50

Record: 100 of 368 Unfiltered Search

Slika 5-14. Inventar kosina - prikaz forme za unos podataka u bazu.

Potrebno je napomenuti kako je ranije spomenuti način prikupljanja podataka IG prospekcijom odredio pripisivanje vrijednosti snimljenih parametara na pojedinoj lokaciji segmentu kosine. U tom obliku podaci su pohranjeni i u Inventar kosina, na način da je svakom segmentu kosine dodijeljen jedinstveni identifikacijski broj (ID) za koji su vezani svi njemu pripadajući podaci. Prema tome, postupci za procjenu ugroženosti od odrona i sve ostale analize provedene su na razini segmenata.

6. PROCJENA UGROŽENOSTI OD ODRONA


Declare the past, diagnose the present, foretell the future.

Hippocrates (460-370 pr. Kr.)

Nakon prikupljanja i obrade podataka slijedi segment istraživanja koji se odnosi na razradu metodologije i provođenje postupaka procjene ugroženosti od odrona kod istraživanih kosina (Slika 6-1).

Prvi korak ovog segmenta uključuje razradu vrednovanja definiranih klasa parametara. U nastavku je, na temelju toga, razrađeno nekoliko bodovnih modela. Oni su korišteni za klasifikaciju kosina prema ugroženosti od odrona, a podloga su joj rezultati ukupnog broja bodova i odnosa bodova određenih skupina parametara. Za sve bodovne modele provedena je verifikacija, kojom je odabran najprikladniji bodovni model za kosine izvedene u karbonatnim stijenama uz željezničku prugu na istraživanom području.

Od ukupnog broja segmenata na kojima je provedena IG prospekcija (377), klasifikacija kosina prema ugroženosti od odrona provedena je za 366 segmenata.



Slika 6-1. Dijagram toka za 2. segment istraživanja - Procjena ugroženosti od odrona

6.1. VREDNOVANJE KLASIFIKACIJSKIH PARAMETARA

Vrednovanje klasifikacijskih parametara temeljeno je na eksponencijalnom bodovnom sustavu, koji je uveden već u prvoj verziji RHRS-a (Pierson & Van Vickie, 1989) i koji je bazno zadržan i kod spomenutih modifikacija. Prema njemu se svakoj od četiri definirane klase parametra dodjeljuje određen broj bodova. Na taj način bodovni sustav odvaja utjecaj svakog parametra u četiri bodovne klase, uz povećanje broja bodova prema eksponencijalnoj funkciji $y=3^x$. Prema njoj su klasama parametra pridruženi bodovi s vrijednostima 3^1 - 3^2 - 3^3 - 3^4 , odnosno 3-9-27-81. Najmanji broj bodova dodjeljuje se najpovoljnijim značajkama, a najveći broj najnepovoljnijim značajkama. Takav način bodovanja omogućava naglašavanje najnepovoljnijih značajki, koje su u konkretnom problemu proučavanja odrona kao neželjene pojave, od najvećeg interesa.

6.1.1. Vrednovanje inženjerskogeoloških značajki

Unutar IG značajki postoji nekoliko parametara koji opisuju određeni tip odrona. Oni su skupno, u prikazu parametara (poglavlje 5.1.2.) nazvani *Značajke određenog tipa odrona*. Broj tih značajki razlikuje se za različite tipova odrona te je stoga način njihovog vrednovanja potrebno prilagoditi njemu (Mauldon et al., 2007, Russell et al., 2008). U suprotnome bi veći broj bodova bio dodijeljen onim tipovima odrona kojima je u startu pripisan i veći broj parametara.

Najveći broj parametara pridružen je ravninskom slomu i klinastom slomu. Zajedno s parametrima *Izraženost* i *Veličina bloka*, njih je ukupno šest pa je bodovanje parametara za ostale tipove odrona usklađeno prema njima. Tako se, kod prevrtanja, kojem su pridružena samo dva parametra, bodovi klasa svakog parametra množe s 3. Kod diferencijalnog trošenja i osipavanja, kojima su pridružena tri parametra, bodovi klasa svakog parametra množe se s 2 (Tablica 6-1). Na taj način bodovanje je svedeno na istu razinu, odnosno ukupni minimalni i maksimalni broj bodova ovih značajki jednak je za sve tipove odrona.

Tablica 6-1. Vrednovanje parametara *Izraženost*, *Veličina bloka* i *Značajke određenog tipa odrona* prema definiranim klasama

KLASA	I	II	III	IV
RAVNINSKI SLOM I KLINASTI SLOM				
Izraženost [%]	< 10	10-20	20-30	> 30
Veličina bloka (b) [cm]*	< 20	20-60	60-200	> 200
Nagib diskontinuiteta [°]	0-20	20-40	40-60	> 60
Hrapavost diskontinuiteta	valovito-hrapavo	valovito-glatko	ravno-hrapavo	ravno-glatko
Zijev	zatvoreni	mm dimenzija	cm dimenzija	dm dimenzija
Ispuna	nema	prevlaka	tvrda	meka
Bod	3	9	27	81
PREVRTANJE				
Izraženost [%]	< 10	10-20	20-30	> 30
Veličina bloka (b) [cm]*	< 20	20-60	60-200	> 200
Bod	3*3 (9)	9*3 (27)	27*3 (81)	81*3 (243)
DIFERENCIJALNO TROŠENJE				
Izraženost [%]	< 10	10-20	20-30	> 30
Veličina bloka (b) [cm]*	< 20	20-60	60-200	> 200
Nekompetentni slojevi	< 2 sloja; < 15 cm	< 2 sloja; > 15 cm	> 2 sloja; < 15 cm	> 2 sloja; > 15 cm
Bod	3*2 (6)	9*2 (18)	27*2 (54)	81*2 (162)
OSIPAVANJE				
Izraženost [%]	< 10	10-20	20-30	> 30
Veličina bloka (b) [cm]*	< 20	20-60	60-200	> 200
Oblik bloka	pločast	nepravilan	ekvidimenzionalan	zaobljen
Bod	3*2 (6)	9*2 (18)	27*2 (54)	81*2 (162)

* U sklopu ove tablice veličina bloka vrednovana je prema klasama definiranim za *Veličinu bloka (b)*. U nastavku rada, u sklopu bodovnih modela uzima se u obzir i *Veličina bloka (a)*, što ne mijenja koncept pridruživanja bodova klasama ovih značajki.

Ostali parametri IG značajki - *Okršenost*, *Voda* i *Broj tipova odrona* nisu vezani za određeni tip odrona. Vrednovanje, prema ranije opisanom bodovnom sustavu, podrazumijeva dodjeljivanje bodova 3-9-27-81 svakom parametru prema definiranim klasama (Tablica 6-2).

Tablica 6-2. Vrednovanje parametara *Okršenost*, *Voda* i *Broj tipova odrona* prema definiranim klasama

PARAMETAR	KLASA			
	I	II	III	IV
OKRŠENOST	nema	rijetko	srednje	učestalo
VODA	suho	vlažno	kapanje	tečenje
BROJ TIPOVA ODRONA	1	2	3	> 3
BOD	3	9	27	81

6.1.2. Vrednovanje klimatskih značajki

Na temelju kombinacije vrijednosti srednje godišnje količine oborina i srednje godišnje temperature definiran je jedan parametar klimatskih značajki. On je vrednovan prema dodjeljivanjem bodova 3-9-27-81 prema definiranim klasama (Tablica 6-3).

Tablica 6-3. Vrednovanje parametra *Oborine i temperatura* prema definiranim klasama

PARAMETAR	KLASA			
	I	II	III	IV
OBORINE [mm] I TEMPERATURA [°C]	< 2000, > 9	< 2000, < 9	> 2000, > 9	> 2000, < 9
BOD	3	9	27	81

6.1.3. Vrednovanje geometrijskih značajki

Svi parametri geometrijskih značajki - *Visina*, *Nagib*, *Udaljenost* i *Razvedenost* također su vrednovani bodovima 3-9-27-81 prema definiranim klasama parametara (Tablica 6-4).

Tablica 6-4. Vrednovanje parametara *Visina*, *Nagib*, *Udaljenost* i *Razvedenost* prema definiranim klasama

PARAMETAR	KLASA			
	I	II	III	IV
VISINA [m]	<6	6-11	11-16	>16
NAGIB (a) [°]*	< 60	60-70	70-80	> 80
UDALJENOST [m]	> 5	3-5, jarak postoji	3-5, jarak ne postoji	< 3
RAZVEDENOST	blage kosine ili kosine bez varijacija	male varijacije (< 0,6 m)	srednje varijacije (0,6 - 1,8 m)	značajne varijacije (> 1,8 m)
BOD	3	9	27	81

* U sklopu ove tablice nagib kosine vrednovan je prema klasama definiranim za *Nagib (a)*. U nastavku rada, u sklopu bodovnih modela uzima se u obzir i *Nagib (b)*, što ne mijenja koncept pridruživanja bodova klasama ovih značajki.


Pierson & Van Vickle (1993) navode kako se za bodovanje određenih parametara, kod kojih vrijednosti parametara predstavljaju kontinuirane vrijednosti, mogu koristiti eksponencijalne funkcije. Stoga su za parametar *Visina* vrijednosti bodova interpolirane uz zadržavanje broja bodova za definirane granične vrijednosti klasa (6 m, 11 m, 16 m). Bodovi su preko funkcije izraženi kao kontinuirane vrijednosti od 1 do 100 (Slika 6-2). Pri tome je maksimalni broj bodova 100 pripisan svim visinama jednakim ili većim od 22 m. Broj bodova dodjeljuje se prema izrazu:

$$y = 3^{\frac{x}{5,25}} \quad (6-1)$$

gdje je: y ... broj bodova; x ... izmjerena visina na određenoj lokaciji [m].

Ovakav način bodovanja omogućuje veću fleksibilnost u procjeni učinka parametra. To je posebno značajno za vrijednosti parametra koji su blizu graničnih vrijednosti ranije definiranih klasa visine.

Usporedba dva načina bodovanja prikazana je na slici 6-2. Pri tome *Visina (a)* označava vrednovanje parametra preko definiranih klasa, dok *Visina (b)* označava vrednovanje preko eksponencijalne funkcije.



Slika 6-2. Dva načina vrednovanja parametra *Visina*

6.2. BODOVNI MODELI

Na temelju definiranih klasa parametara i bodovnog sustava kojim su oni vrednovani, uspostavljeno je 16 bodovnih modela (BM) (Tablica 6-5).

Bodovni modeli temelje se na različitim kombinacijama klasifikacijskih parametara uključenih u procjenu ugroženosti od odrona. Njihove razlike vezane su uz parametre kod kojih su na više načina definirane njihove klase - *Maksimalna veličina bloka*, *Dominantna veličina bloka* i *Nagib* te uz parametar *Visina* kod kojeg su definirana dva različita načina vrednovanja. Nadalje, za sve bodovne modele *Značajke određenog tipa odrona* odnose se na tip odrona koji je za segment kosine procijenjen kao najkritičniji. Izuzetak čini BM16 koji, uz njega, u obzir uzima i značajke ostalih tipova odrona čija je *Izraženost* unutar ili iznad klase 10-20 %. Uz to, za sve bodovne modele klase parametara bodovane su prema načinu opisanom u prethodnim poglavljima. Izuzetak je BM13, kod kojeg su bodovi 3-9-27-81 zamijenjeni s bodovima 1-2-3-4.

Osnovna svrha uvođenja bodovnih modela je pronalazak onog koji uključuje najbolju kombinaciju spomenutih parametara za procjenu ugroženosti od odrona na istraživanom području. Upravo taj bodovni model potvrdit će postupci verifikacije, nakon provođenja klasifikacije kosina za svih 16 bodovnih modela.

Tablica 6-5. Bodovni modeli

	BM01	BM02	BM03	BM04	BM05	BM06	BM07	BM08	BM09	BM10	BM11	BM12	BM13	BM14	BM15	BM16
Izraženost	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Dom veličina bloka (a)	+		+			+				+				+	+	+
Dom veličina bloka (b)		+		+	+				+			+				
Maks. veličina bloka (a)							+			+	+	+	+			
Maks. veličina bloka (b)								+	+					+	+	
Značajke određenog tipa odrona	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Broj tipova odrona	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	
Okršenost	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Oborine i temperatura	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Voda	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Visina (a)	+	+				+	+	+							+	+
Visina (b)			+	+	+				+	+	+	+	+	+		
Nagib (a)			+		+									+		
Nagib (b)	+	+		+		+	+	+	+	+	+	+	+		+	+
Udaljenost	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Razvedenost	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+

* Korištene su klase prema parametru *Nagib (b)* uz modifikaciju bodova za klasu 87°-90°, kod BM10 s 3 na 27 boda, odnosno za BM06 s 3 na 81 bod.

6.3. METODOLOGIJA KLASIFIKACIJE KOSINA PREMA UGROŽENOSTI OD ODRONA

U većini postojećih sustava, klasifikacija kosina temelji se na ukupnom broju bodova klasifikacijskih parametara, dok rezultat predstavlja kvantificirani hazard odnosno rizik, bez jasnog definiranja veze ili razlike hazarda i rizika. Budetta (2004) smatra kako sustav sadrži sve elemente koji se odnose na hazard i na ranjivost vozila, pa se prema tome krajnji rezultat može smatrati procjenom stupnja izlaganja riziku duž prometnica. Russel et al. (2008) dodjeljuju odvojeno bodove hazardu i riziku. Sustavi država New York (NYSDOT, 2007) i Utah (Pack & Boie, 2002) krajnji rezultat bodovanja nazivaju ukupni relativni rizik. On predstavlja produkt procjene vjerojatnosti pojave događaja (geološki parametri), posljedica (hoće li odlomljeni materijal dosegnuti prometnicu) i faktora izloženosti korisnika samoj pojavi odrona (učestalost prometa i prometne značajke). Maerz & Youssef (2004) razvili su sustav koji se temelji na zasebnom bodovanju parametara koji se odnose na rizik i one koji se odnose na posljedice. Na

taj način omogućena je njihova odvojena procjena. Za regiju Bavorskih Alpi Bauer & Neumann (2011) su definirali matricu hazarda, koja se temelji na kombinaciji vjerojatnosti pojave odrona i njegovog intenziteta. Đurović et al. (2005) matricu potencijalne ugroženosti sastavljaju iz veličine događaja (magnitude) i podložnosti za pojavu događaja.

U sklopu doktorskog rada rezultat klasifikacije predstavljaju klase kosina prema ugroženosti od odrona. One su definirane na temelju kombinacije klasa prema ukupnom broju bodova svih klasifikacijskih parametara i klasa prema odnosu zbroja bodova određenih skupina parametara.


Prema ukupnom broju bodova definirane su četiri klase kosine - 1, 2, 3 i 4. Granice klasa, pri tome čine 25 %, 50 % i 75 % vrijednosti maksimalnog dobivenog broja bodova određenog bodovnog modela. Pri tome viša klasa podrazumijeva veći ukupni broj bodova i upućuje na veću ugroženost od odrona.

Za klasifikaciju prema odnosu zbroja bodova određenih skupina parametara dovode se u odnos uzrok i posljedica. Uzrok se definira kao potencijal odrona i klasificiran je kao vrlo visok, visok, srednji i nizak. Određuju ga parametri koji utječu na samu pojavu odrona (parametri uzroka - U). Posljedica se opisuje kao mogućnost da odlomljeni materijal ugrozi željezničku prugu i klasificirana je kao vrlo velika, velika, srednja i mala. Nju određuju parametri koji utječu na to hoće li odlomljeni materijal doseći željezničku prugu (parametri posljedice - P). Pri tome je podjela parametara unutar ove dvije skupine pojednostavljena na sljedeći način. Uzrok određuju parametri iz skupina IG značajki i klimatskih značajki, dok posljedicu određuju parametri iz skupine geometrijskih značajki.

Klasifikacija uzroka temelji se na zbroju bodova parametara uzroka, a granice klasa definirane su kao 25 %, 50 % i 75 % vrijednosti maksimalnog dobivenog broja bodova parametara uzroka određenog bodovnog modela. Na isti način, klasifikacija posljedice temelji se na zbroju bodova parametara posljedice, a granice klasa definirane su kao 25 %, 50 % i 75 % vrijednosti maksimalnog dobivenog broja bodova parametara posljedice određenog bodovnog modela.

Prema odnosu uzroka i posljedice (U-P odnos) kosine su klasificirane prema shemi na slici 6-3. Na taj način razlikuju se četiri klase:

- klasa 1 - od male mogućnosti da odlomljeni materijal dosegne prugu za nizak potencijal odrona do nema mogućnosti da odlomljeni materijal dosegne prugu za vrlo visok potencijal odrona,
- klasa 2 - od srednje mogućnosti da odlomljeni materijal dosegne prugu za nizak potencijal odrona do male mogućnosti da odlomljeni materijal dosegne prugu za vrlo visok potencijal odrona,
- klasa 3 - od velike mogućnosti da odlomljeni materijal dosegne prugu za nizak potencijal odrona do srednje mogućnosti da odlomljeni materijal dosegne prugu za vrlo visok potencijal odrona,
- klasa 4 - od vrlo velike mogućnosti da odlomljeni materijal dosegne prugu za nizak potencijal odrona do velike i vrlo velike mogućnosti da odlomljeni materijal dosegne prugu za vrlo visok potencijal odrona.



Slika 6-3. Klasifikacija kosina prema U-P odnosu

U konačnici su, na temelju kombinacije klasa prema ukupnom broju bodova i klasa prema U-P odnosu, definirane četiri klase koje predstavljaju klase kosina prema ugroženosti od odrona.

Klase su definirane sljedećim kombinacijama (klasa prema ukupnom broju bodova-klasa prema U-P odnosu):

- klasa A : 4-4, 3-4, 4-3;
- klasa B : 2-4, 3-3, 2-3, 4-2, 3-2;
- klasa C : 1-4, 1-3, 2-2, 4-1, 3-1;
- klasa D : 1-2, 2-1, 1-1.

Pri tome klasa A označava vrlo visoku ugroženost od odrona, klasa B visoku ugroženost od odrona, klasa C srednju ugroženost od odrona i klasa D nisku ugroženost od odrona.

6.4. METODOLOGIJA VERIFIKACIJE BODOVNIH MODELA

Nakon definiranja klasa kosina prema ugroženosti od odrona, za svaki bodovni model provedena je verifikacija. Ona uključuje tri različita seta podataka, koja su prikazana u nastavku ovog poglavlja. To su:

- podaci preliminarne procjene koji su prikupljeni tijekom IG prospekcije,
- podaci o stabilnosti kosina Regionalnih jedinica održavanja Hrvatskih željeznica,
- podaci o tragovima odrona koji su prikupljeni tijekom IG prospekcije.

Postupak verifikacije proveden je prema shemi na slici 6-4. Svako polje predstavlja odgovarajuću kombinaciju klase jednog od parametra korištenog za verifikaciju i klase kosine prema ugroženosti od odrona. U svako polje upisuje se broj segmenata koji pripada određenoj kombinaciji klasa. Klase parametra korištenog za verifikaciju (klase parametra verifikacije) označene su kao 1, 2, 3 i 4, a klase kosine prema ugroženosti od odrona (klase kosine) kao A, B, C i D.

klasa parametra verifikacije (1, 2, 3, 4)	4-A	4-B	4-C	4-D
	3-A	3-B	3-C	3-D
	2-A	2-B	2-C	2-D
	1-A	1-B	1-C	1-D
klasa kosine (A, B, C, D)				

Slika 6-4. Shema polja za verifikaciju

Prema prikazu, polja unutar sheme verifikacije mogu se podijeliti u četiri skupine, na sljedeći način:

- zelena polja odnose se na kombinacije kod kojih se klasa parametra verifikacije i klasa kosine podudaraju (npr. najnepovoljnija klasa parametra - 4 i klasa kosine vrlo visoke ugroženosti od odrona - A);
- žuta polja odnose se na kombinacije kod kojih se klasa parametra verifikacije i klasa kosine razlikuju za jednu kategoriju;
- narančasta polja odnose se na kombinacije kod kojih se klasa parametra verifikacije i klasa kosine razlikuju za dvije kategorije;
- crvena polja odnose se na kombinacije kod kojih se klasa parametra verifikacije i klasa kosine razlikuju za maksimalne tri kategorije (npr. najpovoljnija klasa parametra - 1 i klasa kosine vrlo visoke ugroženosti od odrona - A).

6.4.1. Preliminarna procjena

Preliminarna procjena, kako je već rečeno u poglavlju 5.1.1., predstavlja ugroženost kosine od odrona koja je procijenjena na temelju vizualnog subjektivnog dojma istraživača, prema mogućnosti pojave odrona i značajkama kosine. Provedena je u sklopu IG prospekcije, a kosinama je dodijeljena jedna od sljedećih klasa: A, A-, B+, B, B-, C+, C. Prema broju klasa kosine prema ugroženosti od odrona verifikacija zahtijeva četiri klase. One su definirane na sljedeći način:

- klasa 1: procijenjena klasa C
- klasa 2: procijenjene klase B- i C+;
- klasa 3: procijenjena klasa B;
- klasa 4: procijenjene klase A, A- i B+;.

Prema distribuciji klasa, najveći postotak segmenata (70 %) pripada klasi 3 - procijenjene preliminarne procjene B. Najmanji je postotak segmenata (6 %) unutar klase 1 - procijenjene preliminarne procjene C (Tablica 6-6).

Tablica 6-6. Parametar *Preliminarna procjena* - tablica frekvencija

Klasa	<i>Preliminarna procjena</i>	Broj segmenata	%
1	C	23	6,28
2	B-, C+	40	10,93
3	B	257	70,22
4	A, A-, B+	46	12,57

6.4.2. Stabilnost kosina

Broj zabilježenih pojava odrona koji su na području istraživanja ugrozili željezničku prugu premalen je da bi se ti podaci sami mogli koristiti za verifikaciju. Kao set podataka za verifikaciju korištene su klase kosina koje se temelje na vizualnoj procjeni i terenskom iskustvu osoba koje obilaze željezničku prugu, uključujući i učestalost pojava odrona. Pri tome je poseban naglasak stavljen na utjecaj stanja kosine na sigurnost prometa.

Kosine su svrstane u jednu od sljedećih klasa koje su definirane od strane Regionalnih jedinica održavanja Hrvatskih željeznica (RJO HŽ), a iste su preuzete i za verifikaciju. To su:

- klasa 1: I. kategorija - potpuno stabilan usjek - osim redovitog održavanja drugi radovi na usjeku nisu potrebni,
- klasa 2: II. kategorija - uvjetno stabilan usjek - potrebno je izvesti radove uklanjanja uzroka potencijalnog odrona koji se većinom mogu izvesti u sklopu održavanja,
- klasa 3: III. kategorija - uvjetno nestabilan usjek - potrebno je izvesti radove uklanjanja uzroka lokalnih odrona i sanacije, koji se djelomično mogu izvesti u sklopu održavanja te uz izradu projektne dokumentacije za cjelovitu sanaciju,
- klasa 4: IV. kategorija - nestabilan usjek - potrebna je hitna sanacija uz prethodnu izradu projektne dokumentacije.

Prema distribuciji klasa najveći postotak segmenata (61 %) nalazi se unutar klase 3 - III. kategorija stabilnosti. Niti jedan istraživani segment nije svrstan unutar klase 1 - I. kategorija stabilnosti (Tablica 6-7).

Tablica 6-7. Parametar *Stabilnost kosine* - tablica frekvencija

Klasa	<i>Stabilnost prema RJO HŽ</i>	Broj segmenata	%
1	I	0	0,00
2	II	37	10,11
3	III	224	61,20
4	IV	105	28,69

6.4.3. Tragovi odrona

Tragovi odrona predstavljaju procjenu količine prisutnih tragova odrona na kosini i količine odlomljenih blokova u jarku te su klase parametra unaprijed definirane. Ovaj parametar uveden je naknadno tijekom provođenja IG prospekcije. Stoga ovi podaci postoje samo za lokacije na željezničkim prugama M502 i M604, odnosno za 208 segmenata.

Prema distribuciji klasa najveći postotak segmenata (60 %) nalazi se unutar klase 2 - vrlo rijetko / lokalno, dok je najmanji broj segmenata (5 %) unutar klase 1 - nema (Tablica 6-8).

Tablica 6-8. Parametar *Tragovi odrona* - tablica frekvencija

Klasa	<i>Tragovi odrona</i>	Broj segmenata	%
1	nema	10	4,81
2	vrlo rijetko / lokalno	124	59,61
3	sporadično	50	24,04
4	učestalo / kontinuirano	24	11,54

6.5. REZULTATI KLASIFIKACIJE I VERIFIKACIJE

Metodologija za klasifikaciju kosina prema ugroženosti od odrona opisana je u sklopu poglavlja 6.3.

Kao grupni prikaz rezultata za sve bodovne modele dan je prikaz broja segmenata za konačni korak klasifikacije, koji predstavlja klase kosina prema ugroženosti od odrona (Tablica 6-9). Te su klase ujedno i ulazni parametar za kosine kod provođenja verifikacije bodovnih modela.

Tablica 6-9. Broj segmenata unutar svake klase kosine prema ugroženosti od odrona za svaki definirani bodovni model

KLASA KOSINE	BM01	BM02	BM03	BM04	BM05	BM06	BM07	BM08	BM09	BM10	BM11	BM12	BM13	BM14	BM15	BM16
A	21	30	21	34	38	18	43	19	26	30	40	39	11	42	44	23
B	103	107	140	110	143	130	162	112	103	114	156	155	16	198	155	64
C	117	120	131	118	142	106	87	118	123	128	97	98	185	94	92	70
D	125	109	74	104	43	112	74	117	114	94	73	74	154	32	75	51
Σ	366	366	366	366	366	366	366	366	366	366	366	366	366	366	366	208

Prema rezultatima klasifikacije, najveći broj segmenata nalazi se za osam bodovnih modela unutar klase B, za sedam bodovnih modela unutar klase C i za jedan bodovni model unutar klase D. Najmanji broj segmenata za sve bodovne modele pripada klasi A, uz izuzetak BM14, kod kojeg je najmanji broj segmenata unutar klase D.

Nadalje, najveći broj segmenata unutar D klase (> 90 segmenata, odnosno > 25 % segmenata) pojavljuje se kod osam bodovnih modela. Najmanji broj segmenata unutar klase D (32

odnosno 43 segmenata) prisutno je kod bodovnog modela BM14 odnosno BM05. Najveći broj segmenata unutar klase A (> 40 segmenata) prisutno je kod tri bodovna modela - BM07, BM14 i BM15.


Bodovni modeli dali su različite distribucije broja segmenata unutar pojedinih klasa kosine, što govori o važnosti načina vrednovanja klasifikacijskih parametara. Najveće razlike prisutne su za klasu kosine B, unutar koje broj segmenata varira od minimalno 16 do maksimalno 198 segmenata. Srednja vrijednost i medijan broja segmenata za sve bodovne modele najveći su za klasu B (Tablica 6-10).

Tablica 6-10. Broj segmenata za svaku klasu kosine svih bodovnih modela: srednja vrijednost, medijan te minimalni i maksimalni broj segmenata


KLASA KOSINE	BROJ SEGMENTATA			
	srednja vrijednost	medijan	minimalna vrijednost	maksimalna vrijednost
A	30	30	11	44
B	127	130	16	198
C	117	118	87	185
D	92	94	32	154

Budući su kosine na kojima je istraživanje provedeno već izdvojene kao potencijalno opasne lokacije, ove interpretacije rezultata klasifikacije kosina mogu pomoći u odabiru najprikladnijeg bodovnog modela. U tom smislu, treba obratiti pažnju na bodovne modele kod kojih je velik broj segmenata unutar najpovoljnije klase - klase D (> 100 segmenata), odnosno one bodovne modele kod kojih je unutar te klase broj segmenata najmanji.


Odabir najprikladnijeg bodovnog modela prema geometrijskim značajkama kosina i značajkama karbonatne stijenske mase proveden je prema shemi verifikacije (Slika 6-4). Pri tome je promatran najveći broj segmenata koji se nalazi unutar polja kod kojih se klase kosine i klase parametra podudaraju ili razlikuju za jednu kategoriju (zelena i žuta polja), odnosno najmanji broj segmenata kod kojih se spomenute klase razlikuju za dvije ili tri kategorije (narančasta i crvena polja). U nastavku je dan zbirni prikaz rezultata verifikacije za sve bodovne modele, prema parametrima *Preliminarna procjena* (Slika 6-5), *Stabilnost kosina* (Slika 6-6) i *Tragovi odrona* (Slika 6-7).



Slika 6-5. Verifikacija prema parametru *Preliminarna procjena*




Slika 6-6. Verifikacija prema parametru *Stabilnost kosina*



Slika 6-7. Verifikacija prema parametru *Tragovi odrona*

Budući su u obzir uzeta sva tri seta podataka, osim njihove pojedinačne analize, zbrojeni su segmenti za sve kombinacije klasa parametra - klasa kosine (Slika 6-8). Ukupni broj segmenata u tom slučaju iznosi 940 (366 za parametar *Preliminarna procjena* + 366 za parametar *Stabilnost kosina* + 208 za parametar *Tragovi odrona*).




Slika 6-8. Verifikacija na temelju zbroja segmenata kombinacija klasa svih parametara verifikacije i klasa kosine

U sklopu prethodnih grafova prikazani su svi bodovni modeli izuzev bodovnog modela BM16 kojim je definirano bodovanje značajki svih tipova odrona čija je *Izraženost* unutar ili iznad klase 10-20 %, uz najkritičniji tip odrona. Ti su podaci, kao što je već ranije rečeno, prikupljeni za 208 segmenata. Zbog toga ovaj bodovni model nije moguće uspoređivati s ostalim modelima koji uzimaju u obzir svih 366 segmenata.

Od ukupnog broja segmenata za koje je provedena klasifikacija kosina, kod 72 segmenta (29 %) uz najkritičniji tip odrona zabilježen je minimalno još jedan tip odrona čija je *Izraženost* unutar ili iznad kategorije 10-20 %. Međutim, IG prospekcijom podaci o značajkama svih tipova odrona za tih 72 segmenta, prikupljeni su za 19 segmenata, što iznosi svega 5 % od ukupnog broja segmenata.

U nastavku se daje primjer usporedbe bodovnih modela BM16 i BM01 (Slika 6-9). Kod definiranja bodovnih modela, za oba ova bodovna modela uzeti su u obzir isti klasifikacijski parametri, a razlike su u bodovanju značajki određenih tipova odrona. Generalno se može konstatirati kako su razlike vidljive, posebno u kombinacijama klasa 4-A, 3-B, 3-C, 4-C i 3-D za

sva tri seta podataka verifikacije. Razlike idu u prilog modelu BM16. No ipak, razlike u bodovanju odnose se na premali broj segmenata (samo 19) te stoga ovi rezultati nisu korišteni u donošenju odluke o adekvatnosti modela.



Slika 6-9. Rezultati verifikacije prema sva tri seta podataka za BM16 i BM01, za 208 segmenata

6.6. NAJPRIKLADNIJI BODOVNI MODEL ZA UVJETE NA ISTRAŽIVANOM PODRUČJU

Na temelju rezultata verifikacije, bodovni model BM14 odabran je kao najadekvatniji model za istraživano područje te se u nastavku daje njegov detaljniji prikaz.

Prema shemi verifikacije za ovaj bodovni model, najbolje poklapanje u klasama iste kategorije pokazalo se kod verifikacije prema parametru *Preliminarna procjena*, za 57 % segmenata. Kod druga dva seta podataka najveći je broj segmenata unutar razlike od jedne kategorije između klase parametra i klase kosine. Najmanji broj segmenata za sva tri seta podataka pripada razlici od maksimalne tri kategorije, a on je najveći za parametar *Stabilnost kosina* (3 %). Također, za sva tri seta podataka broj segmenata za istu kategoriju klase ili razliku od jedne kategorije klase iznosi > 75 % (96 % za parametar *Preliminarna procjena*, 86 % za parametar *Stabilnost kosina* te 82 % za parametar *Tragovi odrona*). Nasuprot njima, za sva tri seta podataka broj segmenata za razliku od dvije ili tri kategorije klase iznosi < 25 % (4 % za parametar *Preliminarna procjena*, 14 % za parametar *Stabilnost kosina* te 18 % za parametar *Tragovi odrona*).

Zbrojeno za sva tri seta podataka, broj segmenata unutar istih kategorija klasa iznosi 412, (207+139+66) odnosno 44%, dok je broj segmenata unutar klasa koje se razlikuju za tri kategorije klasa 14 (1+11+2) odnosno 1 % (Tablica 6-11).

Tablica 6-11. Rezultati verifikacije za bodovni model BM14: a) parametar verifikacije *Preliminarna procjena*; b) parametar verifikacije *Stabilnost kosina*; c) parametar verifikacije *Tragovi odrona*

a)

klasa parametra verifikacije	klasa kosine				razlika u kategorijama klasa	broj segmenata i (%)
	A	B	C	D		
4	20	25	1	0	3	1 (0,3)
3	20	158	67	12	2	15 (4,1)
2	1	14	17	8	1	143 (39,1)
1	1	1	9	12	0	207 (56,5)

b)

klasa parametra verifikacije	klasa kosine				razlika u kategorijama klasa	broj segmenata i (%)
	A	B	C	D		
4	10	63	21	11	3	11 (3,0)
3	29	117	61	17	2	41 (11,2)
2	3	18	12	4	1	175 (47,8)
1	0	0	0	0	0	139 (38,0)

c)

klasa parametra verifikacije	klasa kosine				razlika u kategorijama klasa	broj segmenata i (%)
	A	B	C	D		
4	2	12	8	2	3	2 (1,0)
3	5	26	11	8	2	35 (16,8)
2	13	67	34	10	1	105 (50,5)
1	0	6	0	4	0	66 (31,7)

Bodovni model BM14 definiran je sljedećim parametrima:

- inženjerskogeološke značajke: *Izraženost*, *Dominantna veličina bloka (a)*, *Maksimalna veličina bloka (b)* i *Značajke određenog tipa odrona* za najkritičniji tip odrona te *Broj tipova odrona* i *Okršenost*;
- klimatske značajke: *Oborine i temperatura*, *Voda*;
- geometrijske značajke: *Visina (b)*, *Nagib (a)*, *Udaljenost*, *Razvedenost*.


Svi parametri bodovani su prema eksponencijalnom bodovnom sustavu s vrijednosti bodova 3-9-27-81 koji se pripisuju definiranim klasama parametara, uz izuzetak parametra *Visina* koja je bodovana preko eksponencijalne funkcije $y = 3^{\frac{x}{5,25}}$ te su vrijednosti bodova u rasponu 1-100. Vrednovanje IG značajki pojedinog tipa odrona prilagođeno je broju parametara pojedinog tipa odrona (Tablica 6-12).

Tablica 6-12. Klasifikacijski parametri i način vrednovanja njihovih klasa za bodovni model BM14

PARAMETAR	KLASA PARAMETRA I BROJ BODOVA			
INŽENJERSKOGEOLOŠKE ZNAČAJKE				
RAVNINSKI I KLINASTI SLOM				
Izraženost [%]	< 10	10-20	20-30	> 30
Maksimalna veličina bloka (a) [dm³]*	< 0,2	> 0,2, < 10	> 10, < 200	> 200
Nagib diskontinuiteta [°]	0-20	20-40	40-60	> 60
Hrapavost diskontinuiteta	valovito-hrapavo	valovito-glatko	ravno-hrapavo	ravno-glatko
Zijev	zatvoreni	mm dimenzija	cm dimenzija	m dimenzija
Ispuna	nema	prevlaka	tvrd	meka
Bod	3	9	27	81
PREVRTANJE				
Izraženost [%]	< 10	10-20	20-30	> 30
Maksimalna veličina bloka (a) [dm³]*	< 0,2	> 0,2, < 10	> 10, < 200	> 200
Bod	3*3 (9)	9*3 (27)	27*3 (81)	81*3 (243)
DIFERENCIJALNO TROŠENJE				
Izraženost [%]	< 10	10-20	20-30	> 30
Maksimalna veličina bloka (a) [dm³]*	< 0,2	> 0,2, < 10	> 10, < 200	> 200
Nekompetentni slojevi	< 2 sloja; < 15 cm	< 2 sloja; > 15 cm	> 2 sloja; < 15 cm	> 2 sloja; > 15 cm
Bod	3*2 (6)	9*2 (18)	27*2 (54)	81*2 (162)
OSIPAVANJE				
Izraženost [%]	< 10	10-20	20-30	> 30
Maksimalna veličina bloka (a) [dm³]*	< 0,2	> 0,2, < 10	> 10, < 200	> 200
Oblik bloka	pločast	nepravilan	ekvidimenzionalan	zaobljen
Bod	3*2 (6)	9*2 (18)	27*2 (54)	81*2 (162)
Broj tipova odrona	1	2	3	> 3
Dominantna veličina bloka (b) [cm]	< 20	20-60	60-200	> 200
Okršenost	nema	rijetko	srednje	učestalo
Voda	suho	vlažno	kapanje	tečenje
Bod	3	9	27	81

KLIMATSKE ZNAČAJKE				
Oborine i temperatura	< 2000, > 9	< 2000, < 9	> 2000, > 9	> 2000, < 9
Bod	3	9	27	81
GEOMETRIJSKE ZNAČAJKE				
Visina (b)	izmjerena vrijednost			
Bod	prema funkciji $y = 3^{\frac{x}{5,25}}$, s rasponom bodova od 1 do 100			
Nagib (a)	< 60	60-70	70-80	> 80
Udaljenost	> 5	> 3, < 5; s jarkom	> 3, < 5; bez jarka	< 3
Razvedenost	blage kosine ili kosine bez varijacija	male varijacije (< 0,6 m)	srednje varijacije (0,6 - 1,8 m)	značajne varijacije (> 1,8 m)
Bod	3	9	27	81

Ukupni broj bodova klasifikacijskih parametara kreće se u širokom rasponu od 80 do 749. Pri tome je najveći broj segmenata zastupljen unutar klase raspona bodova 300-400 s 37 % segmenata te unutar klase raspona bodova 400-500 s 24 % segmenata (Slika 6-10).




Slika 6-10. Postotak segmenata prema ukupnom broju bodova

Prema ukupnom broju bodova definirane su četiri klase kosine, prema metodologiji klasifikacije (poglavlje 6.3.), sa sljedećim vrijednostima bodova:

- klasa 1 s ukupnim brojem bodova < 187,


- klasa 2 s ukupnim brojem bodova 187-375,
- klasa 3 s ukupnim brojem bodova 375-562,
- klasa 4 s ukupnim brojem bodova > 562.

Za klase prema ukupnom broju bodova podjednak je broj segmenata unutar klase 2 i klase 3 (47 % odnosno 41 %), što zajedno čini čak 88 % segmenata. Unutar klase 4 nalazi se 6 % segmenata, kao i unutar klase 1 (Slika 6-11).




Slika 6-11. Postotak segmenata unutar definiranih klasa ukupnog broja bodova

Na temelju U-P odnosa (Slika 6-12), dobivena je distribucija klasa prema definiranim granicama. Kao kod klasa prema ukupnom broju bodova, najveći je broj segmenata unutar klase 3 (45 %), ali je razmjerno manji broj segmenata unutar klase 2 (38 %). Razmjerno je veći broj segmenata unutar klase 4 (11 %). Najmanji je broj segmenata unutar klase 1 (6 %) (Slika 6-13).



Slika 6-12. Distribucija segmenata prema U-P odnosu



Slika 6-13. Postotak segmenata unutar svake klase prema U-P odnosu


U konačnici, kombinacijom ovih dviju klasa, definirane su klase kosine prema ugroženosti od odrona. U nastavku je dan prikaz za sve kombinacije klasa (Tablica 6-13).

Tablica 6-13. Broj segmenata za sve kombinacije klasa (klasa prema ukupnom broju bodova – klasa prema U-P odnosu)

klasa kosine prema ugroženosti od odrona	klasa prema ukupnom broju bodova-klasa prema U-P odnosu	broj segmenata	
A	4-4	10	42
	3-4	24	
	4-3	8	
B	2-4	5	198
	3-3	95	
	2-3	63	
	4-2	3	
	3-2	32	
C	1-4	0	94
	1-3	0	
	2-2	94	
	4-1	0	
	3-1	0	
D	1-2	9	32
	2-1	10	
	1-1	13	


Najveći broj segmenata je unutar kombinacija klasa 3-3 i 2-2, a najmanji broj segmenata unutar kombinacija klasa 2-4 i 4-2. Niti jedan segment nije dobiven kombinacijom klasa 1-4, 1-3, 4-1 i 3-1.

U usporedbi konačnih klasa kosina s klasama prema ukupnom broju bodova i klasama prema U-P odnosu, trend broja segmenata po klasama je zadržan. Najveći je broj segmenata (54 %) unutar klase B. Slijede klasa C (26 %) i klasa A (11 %). Najmanji je broj segmenata unutar klase D (9 %) (Slika 6-14).




Slika 6-14. Postotak broja segmenata unutar svake klase kosine prema ugroženosti od odrona

Prema podacima prikupljenim tijekom IG prospekcije, moguće je odrediti zastupljenost različitih tipova odrona unutar karbonatne stijenske mase. Ako promatramo tip odrona koji je na određenoj lokaciji procijenjen kao najkritičniji, najzastupljeniji su osipavanje (50 % segmenata) i prevrtanje (28 % segmenata). Ravninski slom prisutan je kod 17 % segmenata. Najmanje su zastupljeni klinasti slom i diferencijalno trošenje, koji su zajedno prisutni kod 16 segmenata (Slika 6-15).




Slika 6-15. Zastupljenost najkritičnijeg tipa odrona (RS-ravninski slom, KS-klinasti slom, P-prevrtanje, DT-diferencijalno trošenje, O-osipavanje)

Zastupljenost najkritičnijeg tipa odrona unutar dobivenih klasa kosine prema ugroženosti od odrona prikazana je na slici 6-16. Unutar najnepovoljnije klase - klase kosine A najveći je postotak kosina sa prevrtanjem. Unutar ostalih klasa najveći je postotak kosina sa osipavanjem, koji je i najzastupljeniji tip odrona na cijelom području istraživanja.



Slika 6-16. Zastupljenost najkritičnijeg tipa odrona unutar svake klase kosine prema ugroženosti od odrona (RS-ravninski slom, KS-klinasti slom, P-prevrtanje, DT-diferencijalno trošenje, O-osipavanje)

Nadalje, svi tipovi odrona najzastupljeniji su unutar B klase kosine prema ugroženosti od odrona, koja je i najzastupljenija klasa kosine. Za ravninski i klinasti slom slijede klase kosine C i A, a segmenata unutar D klase gotovo i nema. Prisutan je samo jedan posto segmenata ravninskog sloma. Za prevrtanje je broj segmenata unutar klase A i C podjednak, najmanji broj segmenata je unutar D klase. Za osipavanje je unutar klase C duplo manji broj segmenata u odnosu na klasu B te je podjednak broj segmenata unutar klase A i D. Diferencijalno trošenje, uz klasu B pojavljuje se samo unutar klase C (Slika 6-17).



Slika 6-17. Raspodjela najkritičnijeg tipa odrona po pojedinim klasama kosine prema ugroženosti od odrona (RS - ravinski slom, KS - klinasti slom, P - prevrtanje, DT - diferencijalno trošenje, O - osipavanje)


6.7. PRIKAZ PROCJENE UGROŽENOSTI OD ODRONA

U sklopu ovog potpoglavlja prikazan je postupak klasifikacije kosina prema ugroženosti od odrona. Postupak je proveden prema bodovnom modelu BM14, a za primjer su odabrane dvije kosine za koje procijenjena ugroženost od odrona predstavlja krajnje klase - A i D.

6.7.1. Primjer za kosinu A klase prema ugroženosti od odrona - 202-61-D

Usjek Gornje Draževo nalazi se na željezničkoj pruzi M202, između kolodvora Zlobin i Plase, na stacionaži 622+100 - 622+340 (Slika 6-18.a). Pripada području rada Regionalne jedinice održavanja Zapad (Rijeka). Kosina se nalazi na desnoj strani i pridodana joj je oznaka 202-61-D. IG prospekcija provedena je duž cijele njezine duljine od 240 m, a promatrana je kao jedan segment.

Prema Osnovnoj geološkoj karti (OGK) predmetna kosina nalazi se na listu Crikvenica (Šušnjar et al., 1970). Smještena je unutar litostratigrafske jedinice grebenski vapnenci i dolomiti gornje jure - $J_3^{2,3}$ (Slika 6-18.b). Šire područje pripada strukturnoj jedinici Fužine-Krivi Put koja se nalazi unutar litološko-tektonske jedinice Gorski Kotar (Grimani et al., 1973).



Slika 6-18. Lokacija kosine 202-61-D na trasi pruge M202: a) isječak topografske karte (1:25.000); b) isječak OGK (1:100.000), list Crikvenica (prema Šušnjar et al., 1970)

Kosina je prema preliminarnoj procjeni svrstana u klasu A – umjeren do visok potencijal blokova da dosegnu prugu i/ili visoka aktivnost odrona. Tragovi odrona za kosine na željezničkoj pruzi M202 tijekom IG prospekcije nisu procijenjeni.

IG prospekcijom kao najkritičniji tip odrona definirano je osipavanje vezano uz razlomljene zone. Uz to, zabilježena je i umjerena izraženost moguće pojave prevrtanja. Potencijalni odroni dominantno su vezani uz nekoliko rasjednih zona, širine 5 m - 20 m, unutar kojih je pojava okršavanja značajno izražena (Slika 6-19.a) a stijenska masa izrazito razlomljena (izmjena kršja i gline). Procijenjene veličine potencijalno nestabilnih blokova iznose 50 cm*25 cm *20 cm za dominantni blok, odnosno 80 cm *80 cm *35 cm za maksimalni blok.

Kosina je generalnog nagiba 84°, a maksimalna visina s koje je moguća pojava odrona jednaka je visini kosine i iznosi 19 m. Udaljenost od osi pruge iznosi 4,6 m i u podnožju kosine postoji zaštitni jarak. Postojeće mjere sanacije uključuju torkret s drenažom na početku usjeka te kameni potporni zid u nekoliko zona, uglavnom visoki, dijelom u dvije etaže, mjestimično oštećen (Slika 6-19.b).




Slika 6-19. IG prospekcija kosine 202-61-D: a) razlomljena zona s izraženom pojavom okršavanja; b) široka rasjedna zona sanirana potpornim zidom

Bodovanjem klasifikacijskih parametara dobiven je ukupan broj bodova od 647,30 (Tablica 6-14). Na temelju definiranih granica klasa prema ukupnom broju bodova kosina je svrstana unutar klase 4 (broj bodova > 562). Prema U-P odnosu kosina je također svrstana u klasu 4 (Slika 6-20). U konačnici je, kombinacijom ovih dviju klasa, za kosinu 202-61-D procijenjena vrlo visoka ugroženost od odrona koja se označava kao klasa A (Tablica 6-15)

Tablica 6-14. Bodovanje klasifikacijskih parametara za kosinu 202-61-D

PARAMETAR	KLASA PARAMETRA I BROJ BODOVA			
Prevrtanje				
Izraženost [%]	< 10	10-20	20-30	> 30
Osipavanje				
Izraženost [%]	< 10	10-20	20-30	> 30
Maksimalna veličina bloka (a) [dm³]	< 0,2	> 0,2, < 10	> 10, < 200	> 200
Oblik bloka	pločast	nepravilan	ekvidimenzi- nalan	zaobljen
Bod	3*2 (6)	9*2 (18)	27*2 (54)	81*2 (162)
Broj tipova odrona	1	2	3	> 3
Dominantna veličina bloka (b) [cm]	< 20	20-60	60-200	> 200
Okršenost	nema	rijetko	srednje	učestalo
Voda	suho	vlažno	kapanje	tečenje
Bod	3	9	27	81
INŽENJERSKOGEOLOŠKE ZNAČAJKE: BODOVI = 162 + 162 + 18 + 9 + 9 + 27 + 27 = 414				
Oborine i temperatura	< 2000, > 9	< 2000, < 9	> 2000, > 9	> 2000, < 9
Bod	3	9	27	81
KLIMATSKE ZNAČAJKE: BODOVI = 27				
Visina	19			
Bod	$\frac{19}{3^{5,25}} = 53,30$			
Nagib	< 60	60-70	70-80	> 80
Udaljenost	> 5	> 3, < 5; s jarkom	> 3, < 5; bez jarka	< 3
Razvedenost	blage kosine ili kosine bez varijacija	male varijacije (< 0,6 m)	srednje varijacije (0,6 - 1,8 m)	značajne varijacije (> 1,8 m)
Bod	3	9	27	81
GEOMETRIJSKE ZNAČAJKE: BODOVI = 53,30 + 81 + 9 + 27 = 170,30				
UKUPAN BROJ BODOVA = 611,30				



Slika 6-20. Odnos potencijala odrona i mogućnosti da odlomljeni materijal dosegne prugu za kosinu 202-61-D


Tablica 6-15. Procjena ugroženosti od odrona za kosinu 202-61-D

klasa prema ukupnom broju bodova	4
klasa prema U-P odnosu	4
klasa kosine prema ugroženosti od odrona	A

6.7.2. Primjer za kosinu D klase prema ugroženosti od odrona - 604-7-D

Usjek se nalazi na željezničkoj pruzi M604, između kolodvora Plaški i Blata, na stacionaži 30+420 - 30+500 (Slika 6-21.a). Pripada području rada Regionalne jedinice održavanja Zapad (Ogulin). Kosina se nalazi na desnoj strani i pridodana joj je oznaka 604-7-D. IG prospekcija provedena je duž cijele njezine duljine od 80 m, a promatrana je kao jedan segment.

Prema Osnovnoj geološkoj karti (OGK) predmetna kosina nalazi se na listu Ogulin (Velić & Sokač, 1982). Smještena je unutar litostratigrafske jedinice dolomiti gornje jure - 3J_3 (Slika 6-21.b). Šire područje pripada strukturnoj jedinici Ogulin - Tobolić (Velić et al., 1982).



Slika 6-21. Lokacija kosine 604-7-D na trasi pruge M604: a) isječak topografske karte (1:25.000); b) isječak OGK (1:100.000) list Ogulin (prema Velić & Sokač, 1982)

Kosina je prema preliminarnoj procjeni označena kao B-, između klase B – umjeren do visok potencijal blokova da dosegnu prugu i/ili visoka aktivnost odrona i klase C - niska aktivnost odrona i/ili neznatan do nizak potencijal blokova da dosegnu prugu. Tragovi odrona procijenjeni su kao sporadična pojava.

IG prospekcijom kao najkritičniji tip odrona definirano je osipavanje. Ono je posljedica intenzivnog trošenja dolomita. Na kosini je velikim dijelom formiran sipar (Slika 6-22.a) koji čini dolomitni pijesak i kršje (dominantne veličine 5 cm*4 cm*2 cm). Mjestimice kroz sipar „izbija“ stijenska masa, koja je značajna za sami kraj kosine, na dijelu 30+454 - 30+500 (Slika 6-22.b). Stijenska masa je značajno raspucana. Na tom dijelu procijenjene su veličine potencijalno nestabilnih blokova koje iznose 20 cm*14 cm *6 cm za dominantni blok, odnosno 75 cm *50 cm *20 cm za maksimalni blok. Kosina je djelom obrasla niskom i visokom vegetacijom (grmlje i drveće).

Kosina je generalnog nagiba 50°, a maksimalna visina s koje je moguća pojava odrona jednaka je visini kosine i iznosi 12 m. Udaljenost od osi pruge je 10 m i u podnožju kosine postoji zaštitni jarak. Nema postojećih mjera sanacije.




Slika 6-22. IG prospekcija kosine 604-7-D: a) sipar formiran na većem dijelu kosine; b) stijenska masa na kraju kosine

Bodovanjem klasifikacijskih parametara dobiven je ukupan broj bodova od 156,32 (Tablica 6-16). Na temelju definiranih granica klasa prema ukupnom broju bodova kosina se nalazi unutar klase 1 (broj bodova < 187). Prema U-P odnosu kosina je svrstana u klasu 1 (Slika 6-23). U konačnici je, kombinacijom ovih dviju klasa, za kosinu 202-61-D procijenjena niska ugroženost od odrona koja se označava kao klasa D (Tablica 6-17).

Tablica 6-16. Bodovanje klasifikacijskih parametara za kosinu 604-7-D

PARAMETAR	KLASA PARAMETRA I BROJ BODOVA			
Osipavanje				
Izraženost [%]	< 10	10-20	20-30	> 30
Maksimalna veličina bloka (a) [dm³]	< 0,2	> 0,2, < 10	> 10, < 200	> 200
Oblik bloka	pločast	nepravilan	ekvidimenzi- nalan	zaobljen
Bod	3*2 (6)	9*2 (18)	27*2 (54)	81*2 (162)
Broj tipova odrona	1	2	3	> 3
Dominantna veličina bloka (b) [cm]	< 20	20-60	60-200	> 200
Okršenost	nema	rijetko	srednje	učestalo
Voda	suho	vlažno	kapanje	tečenje
Bod	3	9	27	81
INŽENJERSKOGEOLOŠKE ZNAČAJKE: BODOVI = 18 + 54 + 18 + 3 + 3 + 9 + 3 = 108				
Oborine i temperatura	< 2000, > 9	< 2000, < 9	> 2000, > 9	> 2000, < 9
Bod	3	9	27	81
KLIMATSKE ZNAČAJKE: BODOVI = 3				
Visina	12			
Bod	$3^{\frac{19}{5,25}} = 12,32$			
Nagib	< 60	60-70	70-80	> 80
Udaljenost	> 5	> 3, < 5; s jarkom	> 3, < 5; bez jarka	< 3
Razvedenost	blage kosine ili kosine bez varijacija	male varijacije (< 0,6 m)	srednje varijacije (0,6 - 1,8 m)	značajne varijacije (> 1,8 m)
Bod	3	9	27	81
GEOMETRIJSKE ZNAČAJKE: BODOVI = 12,32 + 3 + 3 + 27 = 45,32				
UKUPAN BROJ BODOVA = 144 + 3 + 45,32 = 156,32				



Slika 6-23. Odnos potencijala odrona i mogućnosti da odlomljeni materijal dosegne prugu za kosinu 604-7-D

Tablica 6-17. Procjena ugroženosti od odrona za kosinu 604-7-D

klasa prema ukupnom broju bodova	1
klasa prema U-P odnosu	1
klasa kosine prema ugroženosti od odrona	D


7. STATISTIČKE ANALIZE

*Everything that happens once can never happen again.
But everything that happens twice will surely happen a third time.*

Paulo Coelho (1947 -)

Posljednji segment istraživanja obuhvaća statističke analize (Slika 7-1), koje su logičan nastavak, s obzirom na veliki broj prikupljenih podataka tijekom istraživanja. Jedna od osnovnih svrha provođenja statističkih analiza je pronalazak i definiranje veza među podacima, kako bi se one mogle koristiti za buduća predviđanja.

Osnovni cilj statističkih analiza provedenih u sklopu doktorskog rada odnosi se na identificiranje parametara koji statistički značajno utječu na procjenu ugroženosti od odrona. Na temelju njih moguće je optimizirati bodovni model, odnosno smanjiti broj ulaznih parametara u procesu klasificiranja kosina prema ugroženosti od odrona. Uz to, cilj je bio i usporediti statistički značajne parametre dobivene za klase prema ukupnom broju bodova i one koji su kao takvi određeni za klase prema U-P odnosu, kao i za konačno definirane klase kosine prema ugroženosti od odrona.



Slika 7-1. Dijagram toka za 3. segment istraživanja - Statističke analize

Značajke koje mogu poprimiti više od jedne vrijednosti u statistici se nazivaju varijable (npr. klasifikacijski parametar, ukupan broj bodova, klasa kosine prema ugroženosti od odrona). Osnovna podjela varijabli zasniva se na svojstvima vrijednosti koje one mogu poprimiti te se prema tome razlikuju kvantitativne i kategorijske varijable. Kvantitativne varijable poprimaju vrijednosti iz skupa realnih brojeva, dok vrijednosti kategorijskih varijabli predstavljaju atributi koji se jedino mogu poredati u određene klase, a mjere se na nominalnoj ili ordinalnoj skali (Berenson et al., 2012). Nominalna skala svrstava podatke u različite klase unutar kojih se ne podrazumijeva rangiranje, dok ordinalna skala klasificira vrijednosti u klase unutar kojih se rangiranje podrazumijeva, odnosno među klasama se može uspostaviti prirodni (logični) slijed. Ova podjela bitna je za odabir statističke metode koja se koristiti za analizu. Tako npr. metode dizajnirane za nominalne varijable mogu biti korištene i kod ordinalnih varijabli, no one neće uzeti u obzir značaj rangiranja što može dovesti do znatnog gubitka snage testa (Agresti, 2007).

Uz to, brojne statističke analize zahtijevaju podjelu varijabli na:

- zavisnu varijablu ili ishod (eng. *dependent/response variable, outcome*), koja predstavlja varijablu od primarnog interesa, odnosno onu koju želimo opisati ili procijeniti;

- prediktor ili nezavisnu varijablu (eng. *predictor, independent/explanatory variable*), koja predstavlja varijablu pomoću koje opisujemo ili procjenjujemo zavisnu varijablu.

Metoda ispitivanja ovisnosti zavisne varijable o jednom ili više prediktora naziva se regresijska analiza. Linearna i logistička regresija najpopularnije su metode u regresijskoj analizi. Njihov se rezultat prikazuje preko regresijskog modela, koji predstavlja matematički izraz, a on pokazuje kako vrijednosti jednog ili više prediktora utječu na zavisnu varijablu.

U sklopu doktorskog rada, ovisno o tipu zavisne varijable, provedene su linearna i logistička regresija. Kao zavisna varijabla promatran je ukupan broj bodova, klasa kosine prema ukupnom broju bodova, klasa kosine prema U-P odnosu te klasa kosine prema ugroženosti od odrona. Prediktore predstavljaju klasifikacijski parametri, njima dodijeljen broj bodova ili klase parametara. Iako je zavisnost između pojedinih klasifikacijskih parametara logična i vjerojatno postoji, kako zavisnosti nisu kvantificirane, teško je govoriti o tome koje su veze više zavisne u odnosu na druge. Iz tog razloga analize su provedene uz pretpostavku da su klasifikacijski parametri međusobno nezavisni, odnosno u obzir nisu uzete njihove interakcije. Statističke analize provedene su za najprikladniji bodovni model - BM14. Uz to, analize su provedene za tri grupe podataka ovisno o tipu odrona koji je za određeni segment procijenjen kao najkritičniji - ravninski i klinasti slom (74 segmenata), prevrtanje (102 segmenta) i osipavanje (184). Segmenti s klinastim slomom pribrojani su onima s ravninskim slomom, budući su značajke određenog tipa odrona za njih jednake. Uz to, kosine s diferencijalnim trošenjem izuzete su iz analiza zbog premalog broja uzoraka (6 segmenata), koji prema distribuciji najkritičnijeg tipa odrona (Slika 6-17) iznosi svega 3 % ukupnog broja segmenata.

Za provedbu statističkih analiza korišten je softver SAS (SAS Institute Inc., 2003).

Iako su kategorijske ordinalne varijable, a samim time i statističke analize koje se njima bave, najviše zastupljene u društvenim znanostima i medicini, nalaze se i u izrazito kvantitativnim poljima kao što su inženjerske znanosti ili kontrola kvalitete u industriji (Agresti, 2007). Za definiranje parametara koji najviše utječu na pojavu odrona i ostalih tipova pokreta masa primjenjivane su statističke analize logističke regresije (Vandewater et al., 2005; Santi et al., 2009), posebno unutar GIS okruženja (Ayalew & Yamagishi (2005); Das et al., 2010; Shirzadi et al., 2012; Akbari et al., 2014).

O navedenim statističkim analizama postoji brojna literatura od koje su za teorijski prikaz korištenih metoda korišteni Hosmer & Lemeshow (2000), Agresti (2007), Rumsey (2009), Kleinbaum & Klein (2010), Berenson et al. (2012). Provođenje analiza korištenjem SAS softvera i interpretacija dobivenih rezultata temeljeni su na sljedećoj literaturi: Peng & So (2002), Cody (2011), Allison (2012), Stokes et. al (2012), SAS Institute Inc. (2014), SAS Institute Inc. (2016).

7.1. LINEARNA REGRESIJA

Za određivanje prediktora koji statistički značajno utječu na ukupan broj bodova klasifikacijskih parametara korištena je linearna regresija koja podrazumijeva kontinuiranu zavisnu varijablu.

Jednostavna linearna regresija preko regresijskog pravca definira linearnu vezu između zavisne varijable i jednog prediktora. Na taj način pokazuje se koliko dobro prediktor sam može objasniti varijabilnost zavisne varijable.

Veza između zavisne varijable i prediktora uspostavlja se modelom jednostavne linearne regresije i definira se izrazom:

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (7-1)$$

gdje je:

Y_i ... zavisna varijabla za opažanje i ; X_i ... prediktor za opažanje i ; β_0 ... odsječak na ordinati (vrijednost zavisne varijable kada je prediktor jednak nuli); β_1 ... nagib pravca regresije (prosječna promjena vrijednosti zavisne varijable za promjenu jedne jedinice vrijednosti prediktora); ε_i ... slučajna pogreška u Y za opažanje i (razlika između vrijednosti predviđene modelom i mjerene vrijednosti zavisne varijable, odnosno varijacija mjerenih vrijednosti oko regresijskog pravca).

Analogno jednostavnoj linearnoj regresiji, višestruka linearna regresija definira postojanje linearne veze između zavisne varijable i dva ili više prediktora u isto vrijeme. Za k broj prediktora definira se izrazom:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad (7-2)$$

gdje se razlike u odnosu na jednostavnu linearnu regresiju odnose na:

$[X_{1i}, X_{ki}] \dots k$ prediktora za opažanje i ; $[\beta_1, \beta_k] \dots$ koeficijenti koji upućuju na stupanj povezanosti između svakog pojedinog prediktora i zavisne varijable (prosječna promjena vrijednosti zavisne varijable za promjenu jedne jedinice vrijednosti prediktora pod pretpostavkom da su ostali prediktori konstantni).

Preko navedenih izraza, model jednostavne linearne regresije podešava pravac regresije u 2-dimenzionalni prostor. Višestruka linearna regresija za dva prediktora podešava plohu u 3-dimenzionalni prostor, odnosno za k nezavisnih prediktora podešava regresijsku „površinu“ u $k+1$ -dimenzionalni prostor.

Budući su regresijski koeficijenti β_0 i β_1 (odnosno β_0 i $[\beta_1, \beta_k]$) nepoznati, oni se procjenjuju. Na temelju njih moguće je nadalje procijeniti vrijednost zavisne varijable preko izraza koji se naziva jednadžba predviđanja.


Za jednostavnu linearnu regresiju definira se izrazom $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{1i}$, za višestruku linearnu regresiju izrazom $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \dots + \hat{\beta}_k X_{ki}$.

Regresijski koeficijenti procjenjuju se metodom najmanjih kvadrata (eng. *least squares method*) na način da je suma kvadrata odstupanja mjerenih vrijednosti zavisne varijable od vrijednosti regresijske funkcije (eng. *error sum of squares, SSE*) minimalna. Drugim riječima, metodom najmanjih kvadrata minimizira se suma kvadriranih reziduala, odnosno suma kvadrata koja se ne može objasniti regresijskim modelom.

Uz spomenuta odstupanja razlikuje se i suma kvadrata odstupanja vrijednosti regresijske funkcije od srednje vrijednosti zavisne varijable (eng. *model sum of squares, SSM*). Ona predstavlja sumu kvadrata koja se može protumačiti regresijskim modelom.

Prema navedenom, ukupnu varijabilnost predstavlja suma kvadrata odstupanja mjerenih vrijednosti zavisne varijable od njezine srednje vrijednosti (Slika 7-2). Prema tome je ukupna suma kvadrata odstupanja (eng. *total sum of squares, SST*) jednaka zbroju protumačene i neprotumačene varijabilnosti u modelu i može se izraziti kao:

$$SST = SSE + SSM = \sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \quad (7-3)$$



Slika 7-2. Tumačenje ukupne sume kvadrata odstupanja kod jednostavne linearne regresije

Mjera za prikladnost modela je koeficijent determinacije (R^2), koji govori koliki se postotak ukupne varijabilnosti zavisne varijable može objasniti samim modelom. Koeficijent determinacije računa se prema izrazu:

$$R^2 = \frac{SSM}{SST} \quad (7-4)$$

Vrijednost koeficijenta determinacije kreće se u intervalu $[0,1]$, pri čemu veća vrijednost ukazuje na reprezentativniji model. Budući se koeficijent determinacije povećava s brojem prediktora, kod višestruke regresije koristi se korigirani koeficijent determinacije ($\bar{R}^2$). On u obzir uzima broj prediktora i veličinu uzorka.

Za interpretaciju koeficijenata determinacije koristi se *Chaddock-ova* skala (Chaddock, 1925) koja je prikazana u nastavku (Tablica 7-1).

Tablica 7-1. Interpretacija vrijednosti koeficijenta determinacije (prema Chaddock, 1925)

KOEFICIJENT DETERMINACIJE	INTERPRETACIJA VEZE
0,0-0,1	nepostojeća veza
0,1-0,3	slaba veza
0,3-0,5	srednje jaka veza
0,5-0,7	izražena veza
0,7-0,9	jaka veza
0,9-1,0	vrlo jaka veza

Određivanje značajnosti veze između zavisne varijable i prediktora temelji se na testnoj statistici, pri čemu se uspoređuje je li regresijski model bolji od osnovnog modela, odnosno je li regresijski model objasnio značajno više varijabilnosti od osnovnog modela. Za osnovni model pretpostavlja se da ne postoji veza između zavisne varijable i prediktora ($\beta_0 = \bar{Y}$; $\beta_1 = 0$).

Prema navedenome postavljaju se sljedeće hipoteze:

- nulta hipoteza (H_0) kaže kako ne postoji veza između zavisne varijable i prediktora te je osnovni model bolji - $H_0 : \beta_1 = 0$;
- alternativna hipoteza (H_a) kaže kako postoji veza između zavisne varijable i prediktora te je regresijski model bolji čime je β_1 statistički značajno različit od nule - $H_A : \beta_1 \neq 0$.

Potvrđivanje jedne od hipoteza temelji se na p -vrijednosti, koja predstavlja empirijsku razinu značajnosti, odnosno onu vjerojatnost dobivanja rezultata jednakih (ili čak ekstremnijih) onima kakvi su na promatranom uzorku, uz pretpostavku da je nulta hipoteza istinita.

Prihvatanje ili odbijanje hipoteze ovisi o definiranoj razini značajnosti - α , koji se definira prije provođenja testa. Razina značajnosti predstavlja količinu dokaza koja je potrebna za odbacivanje nulte hipoteze. Ta vrijednost ujedno predstavlja i vjerojatnost pojave pogreške I. tipa koja se odnosi na uvjet kada je nulta hipoteza odbačena, a u stvarnosti je ona istinita. Uz nju, postoji i pogreška II. tipa koja se odnosi na uvjet kada je nulta hipoteza prihvaćena, a ona u stvarnosti nije istinita. Vjerojatnost njezine pojave označava se kao β . Ta vrijednost definira i snagu statističkog testa ($1 - \beta$), koja predstavlja vjerojatnost ispravnog odbijanja nulte hipoteze.

Prema ranije postavljenim hipotezama, na temelju definirane razine značajnosti za određenu p -vrijednost odlučuje na sljedeći način:

- ako je $p < \alpha$ možemo reći kako na razini α ima dovoljno dokaza za postojanje veze između zavisne varijable i prediktora, te H_0 hipotezu odbacujemo;
- ako je $p > \alpha$ možemo reći kako na razini α nema dovoljno dokaza za odbacivanje H_0 hipoteze, te se može zaključiti da veza između zavisne varijable i prediktora nije statistički značajna.

Kod odabira vrijednosti razine značajnosti najčešće se uzimaju vrijednost 0,05 i 0,1.

U sklopu doktorskog rada u prvom koraku provedena je jednostavna linearna regresija (eng. *simple linear regression*) kako bi se odredilo postojanje veze između svakog pojedinog prediktora i ukupnog broja bodova. Parametri koji su na ovaj način određeni kao statistički značajni korišteni su u drugom koraku kojim je provedena višestruka linearna regresija (eng. *multiple linear regression*) metodom *stepwise* regresije (eng. *stepwise regression method*) sa ciljem definiranja višestrukog linearnog regresijskog modela.

Kod višestruke *stepwise* regresijske metode proces počinje bez ijednog prediktora u modelu. Prediktori se dodaju jedan po jedan, pri čemu se prati povećanje/smanjenje adekvatnosti modela. Varijabla koja je ušla u model ne mora nužno i ostati u njemu, jer se kao uvjeti zadaju razina značajnosti za ulazak u model i razina značajnosti za ostanak u modelu.

7.1.1. Rezultati linearne regresije

U nastavku su prikazani rezultati dobiveni za provedene analize linearne regresije. Rezultati su prikazani odvojeno za svaki tip odrona.

Za jednostavnu linearnu regresiju statistički značajni parametri ($p < 0,05$) unutar tablica su podebljani, a rangirani su prema vrijednosti koeficijenta determinacije R^2 . U prikazu rezultata dane su i jednadžbe za pravce linearne regresije za svaki prediktor, odnosno njemu dodijeljen broj bodova (Tablica 7-2).

Tablica 7-2. Statistički značajni parametri određeni jednostavnom linearnom regresijom: a) ravninski i klinasti slom; b) prevrtanje; c) osipavanje

a)

PREDIKTOR (X)	R ²	p-vrijednost	jednadžba regresijskog pravca
Ispuna	0,2874	0,0001	$Y = 328,18 + 1,49 \cdot X$
Izraženost	0,2268	0,0001	$Y = 324,72 + 1,46 \cdot X$
Okršenost	0,2235	0,0001	$Y = 316,21 + 1,80 \cdot X$
Zijev	0,2178	0,0001	$Y = 288,18 + 4,53 \cdot X$
Voda	0,1966	0,0001	$Y = 329,05 + 3,61 \cdot X$
Nagib	0,1175	0,0028	$Y = 290,00 + 1,08 \cdot X$
Maks. vel. bloka	0,1077	0,0043	$Y = 182,54 + 2,24 \cdot X$
Broj tipova odrona	0,088	0,0103	$Y = 331,00 + 4,35 \cdot X$
Razvedenost	0,0822	0,0132	$Y = 323,21 + 1,09 \cdot X$
Visina	0,0593	0,0365	$Y = 334,09 + 2,47 \cdot X$
Nagib disk.	0,0589	0,0372	$Y = 329,48 + 0,91 \cdot X$
Dom. vel. bloka	0,0278	0,1556	$Y = 334,58 + 2,04 \cdot X$
Hrapavost	0,0247	0,1815	$Y = 346,81 + 0,51 \cdot X$
Udaljenost	0,0079	0,4515	$Y = 351,78 + 0,48 \cdot X$
Oborine i temperatura	0,0026	0,6663	$Y = 353,68 + 0,50 \cdot X$


b)


Prediktor (X)	R ²	p-vrijednost	jednadžba regresijskog pravca
Izraženost	0,4825	0,0001	$Y = 373,79 + 3,33 \cdot X$
Maks. vel. bloka	0,322	0,0001	$Y = 196,74 + 3,29 \cdot X$
Dom. vel. bloka	0,1464	0,0001	$Y = 631,07 + 8,20 \cdot X$
Razvedenost	0,1438	0,0001	$Y = 376,33 + 2,30 \cdot X$
Visina	0,1242	0,0003	$Y = 404,67 + 2,50 \cdot X$
Nagib	0,0972	0,0014	$Y = 339,43 + 1,44 \cdot X$
Okršenost	0,0877	0,0025	$Y = 393,46 + 2,25 \cdot X$
Voda	0,0208	0,1478	$Y = 416,51 + 3,32 \cdot X$
Udaljenost	0,0187	0,17	$Y = 422,70 + 0,84 \cdot X$
Broj tipova odrona	0,0163	0,2007	$Y = 417,86 + 3,86 \cdot X$
Oborine i temperatura	0,0012	0,7281	$Y = 430,98 + 0,55 \cdot X$

c)

Prediktor (X)	R ²	p-vrijednost	jednadžba regresijskog pravca
Maks. vel. bloka	0,4157	< 0,0001	Y = 199,22 + 2,45*X
Izraženost	0,2844	< 0,0001	Y = 280,26 + 1,95*X
Okršenost	0,2322	< 0,0001	Y = 265,93 + 3,16*X
Razvedenost	0,2080	< 0,0001	Y = 261,54 + 2,71*X
Dom. vel. bloka	0,1506	< 0,0001	Y = 267,60 + 11,46*X
Visina	0,1122	< 0,0001	Y = 304,76 + 2,15*X
Nagib	0,1078	< 0,0001	Y = 261,89 + 1,18*X
Broj tipova odrona	0,0667	0,0004	Y = 299,05 + 7,04*X
Oborine i temperatura	0,0246	0,0335	Y = 312,75 + 2,00*X
Udaljenost	0,0197	0,0571	Y = 318,60 + 0,66*X
Oblik bloka	0,0044	0,3720	Y = 319,82 + 1,08*X
Voda	0,0016	0,5914	Y = 324,76 + 0,97*X

Za svaki klasifikacijski parametar izrađen je graf na kojem regresijski pravac pokazuje vezu između njemu dodijeljenog broja bodova i ukupnog broja bodova. Na slici 7-2 dan je primjer za parametar koji je jednostavnom linearnom regresijom određen kao statistički značajan - *Izraženost* za prevrtanje (Slika 7-3.a) i primjer za parametar koji nije određen kao statistički značajan - *Oborine i temperatura* za prevrtanje (Slika 7-3.b).





Slika 7-3. Jednostavna linearna regresija: a) *Izraženost* (za prevrtanje) kao statistički značajan parametar; b) *Oborine i temperatura* (za prevrtanje) kao statistički neznačajan parametar

Višestruka linearna regresija definirala je za svaki tip odrona model s parametrima koji su zadovoljili uvjete modela ($\alpha = 0,05$ za ulazak i ostanak u modelu). Procijenjene su vrijednosti koeficijenata za sve prediktore uključene u model, a jednadžbe regresije dane su u nastavku.

Za ravninski i klinasti slom je od 11 ulaznih parametara u modelu zadržano njih devet (bez parametara *Zijev* i *Broj tipova odrona*). Regresijski model, s korigiranim koeficijentom determinacije $\bar{R}^2 = 0,8657$, definiran je izrazom:

$$Y = 51,86 + (2,43 \cdot \text{Visina}) + (1,62 \cdot \text{Voda}) + (1,3 \cdot \text{Maks. vel. bloka}) + (1,01 \cdot \text{Izraženost}) + (0,99 \cdot \text{Ispuna}) + (0,91 \cdot \text{Razvedenost}) + (0,91 \cdot \text{Okršenost}) + (0,90 \cdot \text{Nagib disk.}) + (0,79 \cdot \text{Nagib}) \quad (7-5)$$

Za prevrtanje je svih sedam ulaznih parametara zadržano u modelu. Regresijski model, s korigiranim koeficijentom determinacije $\bar{R}^2 = 0,9688$, definiran je izrazom:

$$Y = 34,93 + (2,96 \cdot \text{Izraženost}) + (2,96 \cdot \text{Maks. vel. bloka}) + (1,51 \cdot \text{Visina}) + (0,99 \cdot \text{Okršenost}) + (0,97 \cdot \text{Dom. vel. bloka}) + (0,95 \cdot \text{Nagib}) + (0,90 \cdot \text{Razvedenost}) \quad (7-6)$$

Za osipavanje je od devet ulaznih parametara u modelu zadržano njih osam (bez parametara *Oborine i temperatura*). Regresijski model, s korigiranim koeficijentom determinacije $\bar{R}^2 = 0,9736$, definiran je izrazom:

$$Y = 50,39 + (1,91 \cdot \text{Maks. vel. bloka}) + (1,98 \cdot \text{Izraženost}) + (1,07 \cdot \text{Okršenost}) + (0,89 \cdot \text{Razvedenost}) + (1,47 \cdot \text{Dom. vel. bloka}) + (1,09 \cdot \text{Visina}) + (0,98 \cdot \text{Nagib}) + (1,42 \cdot \text{Broj tipova odrona}) \quad (7-7)$$

Kod jednostavne linearne regresije, za većinu statistički značajnih parametara, promatrajući zajedno sva tri tipa odrona, p -vrijednost iznosi $< 0,0001$. Međutim, prema *Chaddock-ovoj* skali koeficijenta determinacije za najveći broj parametara (njih 12), za sva tri tipa odrona, veza između varijabli može se interpretirati kao slaba veza (0,1-0,3). Za osam parametara koeficijent determinacije je manji od 0,1. Za tri parametra može se konstatirati kako je njihova veza sa zavisnom varijablom srednje jaka (0,3-0,5). Parametri s najvećom vrijednosti koeficijenta determinacije za svaki pojedini tip odrona su: *Ispuna* za ravninski i klinasti slom, *Izraženost* za prevrtanje i *Maksimalna veličina bloka* za osipavanje (Tablica 7-2).

U odnosu na početni bodovni model, višestrukom regresijom najmanji broj ulaznih parametara u modelu zadržan je za ravninski i klinasti slom (9 od 15). Slijede prevrtanje (7 od 11) i osipavanje (8 od 12). Pri tome su korigirani koeficijenti determinacije za jednadžbe višestruke linearne regresije pokazali značajne vrijednosti, u prosjeku za sva tri tipa odrona 0,94.

Višestrukom regresijom definirani su modeli sa statistički značajnim parametrima prema utjecaju na ukupan broj bodova na sljedeći način:

- *Visina, Nagib, Razvedenost, Okršenost, Izraženost, Maksimalna veličina bloka* za sva tri tipa odrona;
- *Dominantna veličina bloka* za prevrtanje i osipavanje;
- *Broj tipova odrona* za osipavanje;
- *Voda* za ravninski i klinasti slom;
- od značajki pojedinog tipa odrona *Nagib diskontinuiteta* i *Ispuna* za ravninski i klinasti slom.

Uz to,

- *Oborine i temperatura* se nije pokazala kao statistički značajan parametar za niti jedan tip odrona.

7.2. LOGISTIČKA REGRESIJA

Za određivanje parametara koji statistički značajno utječu na klase prema ukupnom broju bodova, klase prema U-P odnosu te na konačno definirane klase kosina prema ugroženosti od odrona korištena je logistička regresija. Na taj način logistička regresija provedena je za svaki korak korišten u klasifikaciji kosina.

Logistička regresija (logistički model ili *logit* model) je tip statističke analize koja se koristi za predviđanje kategorijske zavisne varijable na temelju jednog ili više prediktora. Tri su tipa logističke regresije (binarna, nominalna i ordinalna), a odabir one koja je najprikladnija za određeni problem temelji se na karakteristikama zavisne varijable. U ovom radu zavisnu varijablu predstavljaju rangirane klase s logičnim slijedom od najpovoljnije do najnepovoljnije, što podrazumijeva upotrebu ordinalne logističke regresije.

Prediktore predstavljaju klasifikacijski parametri pojedinog tipa odrona. Za sve njih klase parametra kodirane su s vrijednostima 1, 2, 3 i 4 za vrijednosti bodova 3, 9, 27 i 81. Na taj način, u interpretaciji regresijskih koeficijenata, povećanje od jedne jedinice predstavlja pomak iz jedne klase u sljedeću klasu i može se promatrati koji efekt taj pomak ima na vrijednost zavisne varijable (Russell et al., 2008). Izuzetak predstavlja parametar *Visina*, za čije je bodovanje korištena kontinuirana funkcija s vrijednosti bodova 1-100 te kod interpretacije koeficijenta povećanje od jedne jedinice predstavlja povećanje od jednog boda.


Najjednostavniji tip logističke regresije je binarna regresija. U slučaju binarne zavisne varijable ishod je definiran s dvije vrijednosti - 0 i 1, koje predstavljaju dva moguća ishoda (događaj se neće pojaviti ili događaj će se pojaviti). Upotreba linearne regresije u tom slučaju nije prikladna. Regresijski pravac, naime, kao rezultate procjene zavisne varijable daje i vrijednosti izvan intervala $[0,1]$ (Slika 7-4.a). Stoga se za definiranje ovakvog modela koristi logistička funkcija. Budući ona procjenjuje vrijednosti koje leže unutar cijelog intervala $[0,1]$, a ne samo

vrijednosti 0 i 1, potrebno je redefinirati zavisnu varijablu na način da se predviđa vjerojatnost pojave događaja (Slika 7-4.b). To se može prikazati preko izraza:

$$\widehat{p(Y_i)} = \frac{e^{\widehat{\beta}_0 + \widehat{\beta}_1 X_i}}{1 + e^{\widehat{\beta}_0 + \widehat{\beta}_1 X_i}} \quad (7-8)$$

gdje je:

$\widehat{p(Y_i)}$... procijenjena vjerojatnost pojave događaja zavisne varijable za opažanje i ; X_i ... prediktor za opažanje i ; $\widehat{\beta}_0, \widehat{\beta}_1$... procijenjeni koeficijenti regresije; e ... baza prirodnog logaritma (2,71).



Slika 7-4. Različiti ishodi vrijednosti zavisne varijable (prema SAS Institute Inc., 2016): a) vrijednost zavisne varijable poprima vrijednosti $-\infty, +\infty$; b) vrijednost zavisne varijable poprima vrijednosti unutar intervala $[0,1]$

Za objašnjenje logističke regresije potrebno je definirati nekoliko pojmova.

Šansa nekog događaja (eng. *odds*) predstavlja omjer vjerojatnosti pojave događaja (p) i vjerojatnosti da se događaj neće dogoditi ($1-p$). Šansa može biti bilo koji pozitivni broj te je na taj način definirana samo donja granica njezinog intervala $[0, +\infty>$, za razliku od vjerojatnosti kojoj su definirane i donja i gornja granica intervala $[0,1]$.

Veza između šanse i vjerojatnosti može se prikazati sljedećim odnosima:

$$odds = \frac{p}{(1-p)} \quad (7-9)$$

$$p = \frac{odds}{(1+odds)} \quad (7-10)$$

Model logističke regresije koristi i omjer šansi (eng. *odds ratio*, *OR*). Omjer šansi mjeri povećanje ili smanjenje šanse nekog događaja u odnosu na promjenu jedinice vrijednosti prediktora.


Jedna od osobina logističke funkcije je što ju je moguće transformirati u pravac (Slika 7-5). Transformacija uključuje dva koraka.

1. korak podrazumijeva uvođenje šansi i korištenje izraza (7-8), čime se „miče“ gornja granica logističke funkcije. Iz toga slijedi:

$$odds = \frac{p(Y_i)}{(1-p(Y_i))} = \frac{\frac{e^{\beta_0 + \beta_1 X_i}}{1 + e^{\beta_0 + \beta_1 X_i}}}{1 - \frac{e^{\beta_0 + \beta_1 X_i}}{1 + e^{\beta_0 + \beta_1 X_i}}} = e^{\beta_0 + \beta_1 X_i} \quad (7-11)$$

2. korak odnosi se na prirodno logaritmiranje šanse, čime se „miče“ donja granica logističke funkcije. *Logit* predstavlja prirodni logaritam šansi i predstavlja vezu između transformiranih vjerojatnosti zavisne varijable i prediktora. Na taj način model prikazuje pravac koji definira linearnu vezu, po čemu postaje sličan linearnoj regresiji.

$$logit = \ln(odds) = \beta_0 + \beta_1 X_i \quad (7-12)$$



Slika 7-5. *Logit transformacija* (prema SAS Institute Inc., 2016)

Budući zavisna varijabla u našem istraživanju u svim slučajevima sadrži više od dvije klase korišten je kumulativni logit model (eng. *cumulative logit model*) koji se naziva i ordinalni logit model (eng. *ordinal logit model*) (McCullagh, 1980). Na temelju njega model predviđa prirodni logaritam šanse ($\ln(odds)$) za određenu klasu zavisne varijable i klasu iznad. U našem je slučaju zavisna varijabla definirana sa četiri klase. Kumulativni logit model, prema tome, dat će rezultate za sljedeće kombinacije klasa: 4 prema 3, 2 i 1; 3 i 4 prema 2 i 1; te 2, 3 i 4 prema 1. Rezultat logističke regresije predstavljaju jednadžbe regresije, čiji broj ovisi o broju klasa zavisne varijable i uvijek ih je $k-1$ (k - broj klasa zavisne varijable). Unutar jednadžbi, za razliku od linearne regresije, model logističke regresije „dozvoljava“ y -odsječku (β_0) da se mijenja zadržavajući koeficijent regresije β_1 jednakim. Samim time utjecaj prediktora je uvijek isti, bez obzira na koji način grupiramo klase zavisne varijable u dvije. Kod kumulativnog *logita* ta se pretpostavka naziva proporcionalnost šansi (eng. *proportional odds assumption*). Za nju je jedino bitno da se grupiranje odradi prema redoslijedu klasa zavisne varijable odnosno zadržavajući njihov logični slijed.

Za razliku od linearne regresije kod koje se koeficijenti regresije procjenjuju metodom najmanjih kvadrata, kod logističke regresije isti se procjenjuju metodom maksimalne vjerodostojnosti (eng. *maximum likelihood*). Ova metoda daje vrijednosti koeficijenata koje maksimiziraju vjerojatnost dobivanja registriranog skupa podataka (mjerenih vrijednosti).

Ostali aspekti, koji se odnose na testiranje veze i prihvaćanje/odbijanje hipoteze jednaki su onima u linearnoj regresiji.

U sklopu doktorskog rada provedena je jednostavna logistička regresija (eng. *simple logistic regression*), kako bi se odredila veza između svakog pojedinog prediktora i klase određene zavisne varijable.

7.2.1. Rezultati logističke regresije

U nastavku su prikazani rezultati jednostavne logističke regresije za svaki pojedini tip odrona. Za svaki parametar dana je p -vrijednost te omjer šansi za parametre koji su određeni kao statistički značajni ($p < 0,05$) (Tablica 7-3).

Tablica 7-3. Statistički značajni parametri određeni jednostavnom logističkom regresijom: a) ravninski i klinasti slom, b) prevrtanje, c) osipavanje

a)	Klasa prema ukupnom broju bodova		Klasa prema U-P odnosu		Klasa kosine prema ugroženosti od odrona	
	<i>p</i> -vrijednost	omjer šansi	<i>p</i> -vrijednost	omjer šansi	<i>p</i> -vrijednost	omjer šansi
Visina	0,0411	1,066	0,0025	1,103	0,0043	1,096
Nagib	0,2476		< 0,0001	13,639	< 0,0001	13,082
Udaljenost	0,1601		0,8476		0,8246	
Razvedenost	0,0541		< 0,0001	8,038	< 0,0001	6,743
Okršenost	0,0048	2,843	0,1638		0,0541	
Voda	0,0848		0,0341	2,188	0,0353	2,202
Oborine i temperatura	0,3047		0,3688		0,5102	
Izraženost	0,0033	2,049	0,1966		0,1561	
Maks. vel. bloka	0,9739		0,5351		0,4637	
Dom. vel. bloka	0,1153		0,3115		0,3280	
Hrapavost	0,0824		0,5025		0,5006	
Nagib disk.	0,5855		0,2870		0,6674	
Zijev	0,0120	3,638	0,0508		0,0122	3,944
Ispuna	0,0009	2,118	0,2959		0,0654	
Broj tipova odrona	0,2855		0,0430	2,328	0,0752	

b)	Klasa prema ukupnom broju bodova		Klasa prema U-P odnosu		Klasa kosine prema ugroženosti od odrona	
	<i>p</i> -vrijednost	omjer šansi	<i>p</i> -vrijednost	omjer šansi	<i>p</i> -vrijednost	omjer šansi
Visina	0,0031	1,042	< 0,0001	1,090	0,0005	1,066
Nagib	0,0008	3,565	< 0,0001	16,335	< 0,0001	6,174
Udaljenost	0,3555		0,0004	2,684	0,0212	1,889
Razvedenost	0,0101	2,438	< 0,0001	4,705	0,0005	3,440
Okršenost	0,1785		0,1370		0,0563	
Voda	0,0345	2,231	0,8320		0,1347	
Oborine i temperatura	0,7879		0,2293		0,7958	
Izraženost	< 0,0001	6,054	0,0379	1,488	< 0,0001	2,958
Maks. vel. bloka	< 0,0001	58,674	0,0027	4,772	< 0,0001	20,473
Dom. vel. bloka	< 0,0001	5,879	0,0060	2,924	< 0,0001	5,678
Broj tipova odrona	0,3806		0,2940		0,3314	

c)	Klasa prema ukupnom broju bodova		Klasa prema U-P odnosu		Klasa kosine prema ugroženosti od odrona	
	<i>p</i> -vrijednost	omjer šansi	<i>p</i> -vrijednost	omjer šansi	<i>p</i> -vrijednost	omjer šansi
Visina	< 0,0001	1,039	< 0,0001	1,061	< 0,0001	1,065
Nagib	< 0,0001	2,729	< 0,0001	6,610	< 0,0001	4,639
Udaljenost	0,0401	1,432	< 0,0001	3,712	< 0,0001	2,680
Razvedenost	< 0,0001	3,561	< 0,0001	8,784	< 0,0001	6,940
Okršenost	< 0,0001	5,939	< 0,0001	3,662	< 0,0001	5,573
Voda	0,0704		0,8532		0,2638	
Oborine i temperatura	0,4568		0,5969		0,9331	
Izraženost	< 0,0001	2,348	0,1697		0,0016	1,505
Maks. vel. bloka	< 0,0001	11,621	< 0,0001	3,052	< 0,0001	5,745
Dom. vel. bloka	< 0,0001	3,501	< 0,0001	3,312	< 0,0001	3,581
Oblik bloka	0,9581		0,1427		0,2062	
Broj tipova odrona	0,0028	2,737	0,6550		0,1874	

Za klase prema ukupnom broju bodova, statistički značajni parametri su:

- *Visina* i *Izraženost* za sva tri tipa odrona;
- *Nagib*, *Razvedenost*, *Maksimalna veličina bloka* i *Dominantna veličina bloka* za prevrtanje i osipavanje;
- *Okršenost* za ravninski i klinasti slom i osipavanje;
- *Voda* za prevrtanje;
- od značajki pojedinog tipa odrona *Zijev* i *Ispuna* za ravninski i klinasti slom.

Za klase prema U-P odnosu, statistički značajni parametri su:

- *Visina*, *Nagib* i *Razvedenost* za sva tri tipa odrona;
- *Udaljenost*, *Maksimalna veličina bloka* i *Dominantna veličina bloka* za prevrtanje i osipavanje;
- *Voda* i *Broj tipova odrona* za ravninski i klinasti slom;
- *Izraženost* za prevrtanje;
- *Okršenost* za osipavanje.

Za klase prema ugroženosti od odrona, statistički značajni parametri su:

- *Visina*, *Nagib* i *Razvedenost* za sva tri tipa odrona;

- *Udaljenost, Izraženost, Maksimalna veličina bloka i Dominantna veličina bloka* za prevrtanje i osipavanje;
- *Voda* za ravninski i klinasti slom;
- *Okršenost* za osipavanje;
- od značajki pojedinog tipa odrona *Zijev* za ravninski i klinasti slom i *Oblik bloka* za osipavanje.

Uz navedeno, *Oborine i temperatura* se nije pokazala kao statistički značajan parametar niti kod jednog tipa odrona za sve provedene logističke regresije.

Statistički značajni parametri mogu se rangirati prema omjeru šansi.

8. RASPRAVA

*A wise man can learn more from a foolish question,
than a fool can learn from a wise answer.*

Bruce Lee (1940 - 1973)

Rasprava u sklopu ovog poglavlja prati redoslijed izlaganja prikazanog u doktorskom radu, a koji ujedno predstavlja i slijed razvoja sustava za procjenu ugroženosti od odrona u karbonatnim stijenama Hrvatske. Dan je osvrt na odabir parametara korištenih u procjeni ugroženosti od odrona i način njihovog bodovanja, korake klasifikacije kosina prema ugroženosti od odrona te optimizaciju odabranog bodovnog modela na temelju provedenih statističkih analiza. Na kraju rasprave iznijeta su ograničenja sustava i preporuke za njegovo poboljšanje.

8.1. KLASIFIKACIJSKI PARAMETRI I NJHOVO BODOVANJE

Odabir značajki koje će se koristiti kao klasifikacijski parametri predstavlja jedan od ključnih stavki izrade bilo kojeg klasifikacijskog sustava. U sklopu ovoga rada odabir parametara baziran je na dvije postojeće verzije *RHRS*-a (Mauldon et al., 2007; Russell et al., 2008).

U odnosu na njih uvedene modifikacije odnose se na:

- dodavanje parametara *Okršenost*, *Broj tipova odrona*, *Udaljenost*;
- vrednovanje dvije veličine bloka - *Maksimalna veličina bloka* i *Dominantna veličina bloka* i definiranje njihovih klasa prema već razvijenim klasifikacijama;

- izmjena parametara unutar klimatskih značajki;
- definiranje klasa parametara za *Zijev diskontinuiteta* i *Ispunu diskontinuiteta* te *Visinu, Nagib* i *Udaljenost*.

Uz to, potrebno je ponoviti kako u korištenom sustavu nije vrednovan parametar o učestalosti pojave odrona, koji podrazumijeva procjenu hazarda od odrona. Također, u sustav nisu uključene ni značajke prometa i prometnice, koje su u spomenutim sustavima obuhvaćene s tri parametra i podrazumijevaju procjenu rizika od odrona. Time je prikazani sustav u doktorskom radu opravdano smatrati procjenom ugroženosti od odrona.

Prikaz klasifikacijskih parametara i njihovih klasa dan je u sklopu poglavlja 5.1.2. te se ovdje navode samo pojedina razmatranja vezana uz spomenute modifikacije.

Kod većine postojećih sustava vrednuje se **veličina bloka**, no ne navodi se izričito o kojoj se veličini radi. Ipak, naglašeno je kako se trebaju vrednovati najnepovoljnije značajke, što bi značilo da se preporučuje korištenje maksimalne veličine. U sklopu ovog istraživanja tijekom IG prospekcije odvojeno su mjerene veličine za dominantne i maksimalne veličine potencijalno nestabilnih blokova te su na različite načine kombinirane u sklopu bodovnih modela. Kod modela koji je odabran kao najprikladniji u obzir su uzete obje veličine bloka.

Što se tiče **klimatskih značajki**, srednje godišnje količine oborine i temperature zraka vrednovane su kao jedan parametar, kako se značaj ovog parametra ne bi prenasladio. Naime, za mogućnost pojave odrona od prosječne temperature važnije su dnevne temperaturne promjene koje utječu na cikluse smrzavanja - odmrzavanja te time i na dezintegraciju stijenske mase. Međutim takve podatke nije bilo moguće prikupiti za potrebe ovog istraživanja s obzirom na veličinu istraživanog područja. S druge strane, potrebno je uzeti u obzir mrežu meteoroloških postaja na temelju kojih su podaci prikupljeni i obrađivani (njihovu gustoću i prostorni raspored). Oni zajedno s reljefnim karakteristikama diktiraju mjerilo korištenih ulaznih podataka koji ne mogu dati sliku lokalnih klimatskih značajki za svaku predmetnu lokaciju. Uz to, *Orijentacija kosine* u sklopu istraživanja nije uzeta u obzir. Za vrednovanje njenog utjecaja polazi se od činjenice kako su kosine orijentirane na sjevernu stranu veći dio dana u sjeni pa su temperaturne razlike tijekom dana manje, za razliku od kosina orijentiranih na jug (Russel et al., 2008). Vrednovanje ovog parametra na taj način upitno je kod kosina uz željezničku prugu, budući su kosine vrlo često usjeci gdje su desna i lijeva strana na prilično maloj udaljenosti te su na taj način obje kosine veći dio dana u sjeni.

Klase parametara geometrijskih značajki *Visina*, *Nagib* i *Udaljenost* definirane su nakon IG projekcije na temelju izmjerenih vrijednosti. Samim time može se konstatirati kako su klase parametara prilagođene kosinama na istraživanom području.

Pri određivanju postojanja **zaštitnog jarka** u podnožju kosina uz željezničku prugu problem predstavlja činjenica kako je sama pruga najčešće izgrađena na nasipu čime je os pruge već izdignuta u odnosu na dno kosine. Formirani jarak u tom slučaju posljedica je izgradnje nasipa a ne samog projektiranja zaštitnog jarka te je njegova učinkovitost za prihvat odlomljenog materijala upitna. Stoga se učinkovitost jarka u sklopu istraživanja nije procjenjivala. Ipak, ovakve lokacije nastojalo se odvojiti od onih lokacija kod kojih ne postoji nikakav jarak i kod kojih je os pruge na istoj razini kao i dno kosine. U tom smislu, kako se njegov značaj ne bi previše naglasio, parametar je vrednovan u kombinaciji s udaljenosti kosine od osi pruge. Projektiranjem zaštitnog jarka bavio se Ritchie (1963), koji je predložio primjerene dimenzije jarka za različite visine i nagibe kosine. Prema Russell et al. (2008) za bodovanje *Učinkovitosti jarka* uzima se nepovoljniji slučaj između učinkovitosti prema dimenzijama jarka i oblika jarka. Pri tome se za izračun učinkovitosti prema dimenzijama uzima postotak koji se temelji na odnosu stvarnih dimenzija jarka (dubine i širine) i preporučenih *Ritchie-evih* dimenzija. Treba naglasiti kako je ova klasifikacija napravljena za cestovne prometnice.

Iako je za **definiranje klasa parametara** bitno da je njima obuhvaćen raspon vrijednosti od najpovoljnijih do najnepovoljnijih, važne su i njihove frekvencije. Kod parametara koji se ne mijenjaju (dominantna frekvencija jedne klase) njihovi bodovi će utjecati na ukupan broj bodova i definiranje klase kosine prema ugroženosti od odrona, no njihov će utjecaj na svim lokacijama biti jednak. Samim time parametar gubi važnost u procjeni ugroženosti od odrona. U sklopu Priloga 1 dan je prikaz frekvencija klasa svakog pojedinog parametra kao i izmjerenih vrijednosti za *Visinu*, *Nagib* i *Udaljenost*. Na temelju prikaza može se vidjeti kako postoje parametri kod kojih nisu zastupljene sve klase. To su:

- *Maksimalna veličina bloka (a)* - nema podataka unutar I klase;
- *Dominantna veličina bloka (b)*, *Broj tipova odrona* i *Oborine i temperatura* - nema podataka unutar klase IV;
- *Nekompetentni slojevi* - nema podataka unutar klase III (premali ukupan broj podataka);
- *Zijev diskontinuiteta* - nema podataka unutar klasa I i IV.


Ipak, unatoč tome, frekvencije klasa pokazuju da se za sve parametre barem 15 % podataka pojavljuje unutar barem dvije klase.

Za **dodjeljivanje bodova klasama** svakog pojedinog parametra preuzet je eksponencijalni bodovni sustav s bazom broja tri, odnosno s vrijednosti bodova 3-9-27-81. Ovakav način bodovanja uspoređen je s bodovanjem kod kojega su vrijednosti bodova 1-2-3-4, eksponencijalnim bodovanjem s bazom broja dva (vrijednosti bodova 2-4-8-16) i eksponencijalnim bodovanjem s bazom broja četiri (vrijednosti bodova 4-16-64-256). Usporedba bodovanja sa spomenutim vrijednostima bodova za bodovni model BM14 prikazana je u nastavku (Slika 8-1).

Sa širinom klase 50 bodova, s bodovima 1-2-3-4 segmenti su distribuirani unutar četiri klase, odnosno s bodovima 2-4-8-16 unutar pet klase. Za oba ova načina bodovanja značajne su frekvencije dviju klasa. Za prvi slučaj 97 % segmenata nalazi se unutar dvije klase koje uključuju bodove < 100. Za drugi slučaj 91 % segmenata nalazi se unutar dvije klase koje uključuju bodove 50-150. Za bodovanje s vrijednosti bodova 3-9-27-81 distribucija se dispergirala na 14 klasa, pri čemu maksimalni broj segmenata unutar jedne klase iznosi 72, odnosno 20 % (Slika 8-1.a).

Za bodovanje s vrijednosti bodova 4-16-64-256 segmenti su distribuirani unutar čak 38 klasa relativno malih frekvencija. Najveći broj segmenata unutar jedne klase iznosi 28. Zbog toga je broj segmenata za ovaj način bodovanja prikazan sa širinom klase 200 bodova. U tom su slučaju segmenti raspoređeni unutar 12 klasa, distribucije vrlo slične onoj sa bodovima 3-9-27-81, samo sa znatno većim brojem bodova (Slika 8-1.b). Maksimalni broj bodova za dva posljednja načina bodovanja iznosi 749 odnosno 2226.

Prema navedenome, može se zaključiti kako je bodovni model (3-9-27-81) korišten u doktorskom radu prikladan i primjenjiv. Njime je dobiven dovoljno širok raspon bodova na temelju kojeg je moguće jasno diferencirati kosine prema ugroženosti od odrona te broj bodova nije nepotrebno prevelik.



Slika 8-1. Frekvencije klasa prema ukupnom broju bodova za različite vrijednosti bodova klasa parametara: a) vrijednosti bodova 1-2-3-4, 2-4-8-16 i 3-9-27-81; b) vrijednosti bodova 4-16-64-256

8.2. KLASIFIKACIJA KOSINA PREMA UGROŽENOSTI OD ODRONA

Metodologija klasifikacije prema ugroženosti od odrona u sklopu doktorskog rada modificirana je u odnosu na postojeće sustave, kako je prikazano u sklopu poglavlja 6.3. Prema njoj se klase kosina prema ugroženosti od odrona temelje na kombinaciji klasa prema ukupnom broju bodova klasifikacijskih parametara i klasa prema U-P odnosu. U nastavku se daje osvrt na definiranje klasa za svaki korak klasifikacije.







Granice klasa prema ukupnom broju bodova definirane su kao 75, 50 i 25 % vrijednosti maksimalnog ukupnog broja bodova. Preko spomenutih postotaka korišteno je linearno razgraničavanje klasa iako se bodovanje pojedinih parametara temelji na eksponencijalnom bodovanju. Postotci se odnose na vrijednost od maksimalnog dobivenog broja bodova u istraživanju, a ne od teoretski mogućeg maksimalnog broja bodova bodovnog modela. Za eksponencijalno razgraničavanje klasa krenulo se od toga kako varijacija bodova kod koje svi pojedini parametri sadrže najnepovoljnije bodove (81) pripada i najnepovoljnijoj klasi prema ukupnom broju bodova - klasi 4. Na isti način, varijacija bodova kod koje svi pojedini parametri sadrže broj bodova 27 pripada klasi 3 prema ukupnom broju bodova. Također, varijacija bodova kod koje svi pojedini parametri sadrže broj bodova 9 pripada klasi 2 prema ukupnom broju bodova, a varijacija bodova kod koje svi pojedini parametri sadrže broj bodova 3 pripada klasi 1 prema ukupnom broju bodova. Interpolacijom između tih vrijednosti definirane su granice klasa.


Usporedba linearnog i eksponencijalnog razgraničavanja klasa ukupnog broja bodova prikazana je u nastavku (Slika 8-2). Na svim grafovima klase bodova pojedinih parametara (I, II, III, IV) odnosno klase ukupnog broja bodova (1, 2, 3, 4) prikazane su na sljedeći način - zelena označava najpovoljniju klasu, slijede narančasta i žuta, dok crvena označava najnepovoljniju klasu. Kod svih grafova os x predstavlja moguće varijacije broja bodova, a os y ukupni broj bodova.

Kako je svakom parametru moguće dodijeliti jednu od četiri bodovne vrijednosti, povećanjem broja parametara moguće varijacije bodova povećavaju se prema izrazu 4^x (x - broj parametara). To za 15 parametara, koliko ih se uzima u obzir kod ravninskog i klinastog sloma iznosi $\sim 10^9$. Stoga je razgraničavanje klasa prikazano za jedan, dva i tri parametra, odnosno za 4, 16 i 64 moguće varijacij bodova.

Iz dobivenih grafova vidljivo je kako povećanjem broja parametara moguće varijacije ukupnog broja bodova bolje prate linearnu od eksponencijalne funkcije. Ono što je važno konstatirati, granice klasa definirane linearnim razgraničavanjem postavljene su na veće vrijednosti ukupnog broja bodova u odnosu na granice klasa definiranih eksponencijalnim razgraničavanjem. Te razlike posebno su značajne za granice između klasa 3 i 2 te 2 i 1. Na primjeru jednog parametra, kod linearnog razgraničavanja može se uočiti nedostajanje klase 3 prema ukupnim bodovima, a vrijednosti boda koji predstavlja klasu III parametra dodijeljena

je za jednu kategoriju niža klasa prema ukupnim bodovima - klasa 2 (Slika 8-2.A.b). Kod eksponencijalnog razgraničavanja klase dodijeljene parametru podudaraju se u potpunosti s klasom ukupnog broja bodova (Slika 8-2.A.c).





Slika 8-2. Linearno i eksponencijalno razgraničavanje klasa ukupnog broja bodova: A) jedan parametar; B) dva parametra; C) tri parametra; a) moguće varijacije ukupnog broja bodova; b) linearno razgraničavanje granica klasa; c) eksponencijalno razgraničavanje granica klasa

Za 15 parametara prema razrađenom bodovnom modelu teoretski broj bodova može se kretati u rasponu od 45 ($15 \cdot 3$) do 1215 ($15 \cdot 81$). Granice klasa prema linearnom i eksponencijalnom razgraničavanju prikazane su u tablici 8.1. Uz granice klasa naveden je broj parametara unutar svake klase bodova, koji predstavljaju najnepovoljniji slučaj mogućih klasa bodova za 15 parametara. Najveće razlike u broju parametara unutar pojedinih bodovnih klasa parametara mogu se vidjeti za granicu između klasa 2 i 3 prema ukupnom broju bodova. Za linearno razgraničavanje klasa taj slučaj uključuje šest parametara kojima je pojedinačno dodijeljen maksimalan broj bodova (Tablica 8-1.a), odnosno za eksponencijalno razgraničavanje jedan parametar (Tablica 8-1.b).

Tablica 8-1. Broj parametara unutar pojedinih bodovnih klasa za najnepovoljniji slučaj prema određenim klasama ukupnih bodova (za 15 parametara: a) linearno razgraničavanje granica klasa; b) eksponencijalno razgraničavanje granica klasa

a)	klasa kosine prema ukupnom broju bodova	ukupan broj bodova (granice klasa)	broj parametara unutar bodovne klase			
			81	27	9	3
4		1215 (maksimalan broj bodova)	15	0	0	0
		911	10	3	2	0
3		607	6	3	3	3
2		303	2	4	1	8
1		45 (minimalan broj bodova)	0	0	0	15

b)	klasa kosine prema ukupnom broju bodova	ukupan broj bodova (granice klasa)	broj parametara unutar bodovne klase			
			81	27	9	3
4		1215 (maksimalan broj bodova)	15	0	0	0
		810	8	5	2	0
3		270	1	5	4	5
2		90	0	1	3	11
1		45 (minimalan broj bodova)	0	0	0	15


U sklopu provedenog istraživanja ukupni broj bodova kreće se u rasponu 99-749. To pokazuje kako se teoretske krajnje vrijednosti - minimalne i maksimalne nisu pojavile. Dobivena maksimalna vrijednost bodova čak je za 1,6 puta manja od moguće teoretske maksimalne vrijednosti bodova. Time je, kada gledamo definirane granice klasa najveći broj kosina smješteno u srednjem dijelu tablice. Segmenti na kojima je provedeno istraživanje za linearno razgraničavanje distribuirani su u tri klase - 3, 2 i 1 (Slika 8-3.a) te za eksponencijalno razgraničavanje u samo dvije klase - 3 i 2 (Slika 8-3.b). U praksi bi to značilo kako niti jedna kosina na istraživanom području ne predstavlja vrlo visok prioritet sanacije.

Upravo iz tog razloga klase su definirane prema maksimalnim dobivenim vrijednostima bodova. Pri tome je u obzir uzeta pretpostavka kako je uzorak na kojem je istraživanje


provedeno dovoljno velik da se može smatrati reprezentativnim za kosine izvedene u karbonatnim stijenama Hrvatske. Na taj način segmenti na kojima je provedeno istraživanje za linearno razgraničavanje distribuirani su u četiri klase - 4, 3, 2 i 1 (Slika 8-4.a) te za eksponencijalno razgraničavanje u tri klase - 4, 3 i 2 (Slika 8-4.b).

Iz svega navedenoga proizlazi kako se linearno razgraničavanje klasa prema maksimalnom dobivenom broju ukupnog broja bodova za bodovni model u kojem se u obzir uzima veliki broj parametara (15) može smatrati opravdanim. Glavni razlog je što postavljene granice daju distribuciju klasa kosina unutar sve četiri definirane klase i jasno razdvajanje kosina upravo u dijelu koji je od primarnog značaja za ovo istraživanje. Ono se odnosi na izdvajanje kosina kod kojih je u postojećim uvjetima željeznička pruga najviše ugrožena i koje zahtijevaju hitne sanacijske radnje - kosine klase A i B. Primjenom ovog sustava za buduće projekte, sve one kosine kod kojih bi maksimalni broj bodova bio veći od 749 mogu se smatrati klasom 4 prema ukupnom broju bodova.

Uz to, treba podsjetiti i na rezultate verifikacije bodovnog modela, koji su pokazali dobro „poklapanje“ klasa kosina prema ugroženosti sa klasama parametara verifikacije, a kod kojih su granice klasa ukupnog broja bodova određene upravo na ovaj način.



Slika 8-3. Distribucija klasa prema ukupnom broju bodova prema teoretskom maksimalnom broju bodova, za sve istraživane segmente: a) linearno razgraničavanje klasa; b) eksponencijalno razgraničavanje klasa




Slika 8-4. Distribucija klasa prema ukupnom broju bodova prema maksimalnom dobivenom broju bodova, za sve istraživane segmente: a) linearno razgraničavanje klasa; b) eksponencijalno razgraničavanje klasa

Kosine prema ugroženosti od odrona moguće je uspoređivati već samo na temelju ukupnog broja bodova, budući su oni odraz karakteristika promatranih značajki. Međutim, za ugroženost željezničke pruge, uz mogućnost pojave odrona, ključna je i mogućnost da odlomljeni materijal dosegne prugu. U tom smislu, potrebno je spomenuti kako je na početku u sustav uključen veći broj parametara koji utječu na pojavu odrona (**parametri uzroka - U**) od parametara koji utječu na mogućnost da odlomljeni materijal dosegne prugu (**parametri posljedice - P**). Ako se vratimo na raspon bodova koji je teoretski moguć prema korištenom bodovnom sustavu na bazi 15 parametara odnosi ove dvije skupine parametara mogu se prikazati na sljedeći način. Četiri su parametra definirana unutar skupine parametara posljedice i 11 je parametara unutar skupine parametara uzroka (Tablica 8-2). Prema graničnim slučajevima - minimalni broj bodova posljedice i maksimalni broj bodova uzroka te maksimalni broj bodova posljedice i minimalan broj bodova uzroka, teoretski se postotak bodova parametara posljedice prema ukupnom broju bodova može kretati u rasponu od 1 % do 91 %.

Tablica 8-2. Minimalni i maksimalni teoretski mogući broj bodova uzroka i posljedica za 15 parametara i njihove vrijednosti za određene granične slučajeve

broj parametara	minimalan broj bodova	maksimalan broj bodova	broj bodova za određene granične slučajeve	
4 P	12 (4*3)	324 (4*81)	12 (1 %)	324 (91 %)
11 U	33 (11*3)	891 (11*81)	891 (99 %)	33 (9 %)
ukupan broj bodova	45	1215	903 (100 %)	357 (100 %)

Kako se u sklopu istraživanja ne pojavljuju granični slučajevi, maksimalni dobiveni broj bodova uzroka je 627, a posljedice 271. Uz to, samo je 27 kosina kod kojih je broj bodova posljedice veći od broja bodova uzroka. Omjer prosječnog postotka bodova parametara uzroka i posljedice u ukupnom broju bodova iznosi 68:32 (Slika 8-5).



Slika 8-5. Postotak bodova uzroka i bodova posljedice u ukupnom broju bodova za sve četiri klase kosine prema ugroženosti od odrona

Važno je napomenuti kako isti ili sličan broj bodova može biti dodijeljen različitim kosinama - onima kod kojih postoji manja vjerojatnost pojave odrona, ali ako do odrona dođe on će vrlo vjerojatno ugroziti prugu i onima kod kojih će se odron vrlo vjerojatno dogoditi, ali ako se dogodi manja je vjerojatnost da će time biti ugrožena pruga. Jednostavnije rečeno, ukupan broj bodova ne pokazuje jasno koliko je njegovom iznosu doprinijela pojedina skupina parametara.

Upravo iz tog razloga uveden je korak u klasifikaciji koji definira klase kosina prema U-P odnosu. Njime se dovodi u odnos broj bodova parametara uzroka i broj bodova parametara posljedica (izražen preko % maksimalnog dobivenog broja bodova pojedine skupine parametara). Na taj način, kosine kod kojih su vrlo nepovoljne značajke vezane za mogućnost da odlomljeni materijal dosegne i ugrozi prugu svrstane su u najnepovoljniju klasu 4. To je posebno značajno kod nadusjeka tunela (udaljenost je 0 m, nema jarka), kod kojih u slučaju pojave odrona odlomljeni materijal završava direktno na pruzi.

Slično kao i kod klase kosina prema ukupnom broju bodova, kosine je prema ugroženosti od odrona moguće uspoređivati i samo na temelju klase prema U-P odnosu. Međutim, ista klasa prema U-P odnosu može biti dodijeljena kosinama kod kojih se broj bodova parametara uzroka kreće od minimalne do maksimalne vrijednosti. Uz to, treba naglasiti kako je definiranje parametara za skupine uzroka i posljedice pojednostavljeno na način kako je definirano u poglavlju 6.3.

Zbog navedenih nedostataka, za konačno definiranje klasa kosina prema ugroženosti korištena je kombinacija dobivenih klasa. Na taj način kosine kod kojih postoji najveća mogućnost za ugrožavanje željezničke pruge definirane su kao najnepovoljniji slučajevi obje klase.

U nastavku su dani primjeri za ilustraciju utjecaja pojedinih klasa (klase prema ukupnom broju bodova i klase prema U-P odnosu) na konačno definiranje klasa kosina prema ugroženosti od odrona. Postotci uz bodove uzroka/posljedice prikazani su u odnosu na maksimalan dobiveni broj bodova uzroka/posljedice prema bodovnom modelu BM14.

Prvi primjer prikazuje kosine kojima je prema ukupnom broju bodova dodijeljena klasa 4, ali konačna procjena razlikuje kosine za jednu kategoriju klase prema ugroženosti od odrona (Slika 8-6).

Za kosinu 604-54-D ukupan broj bodova iznosi 622 (Slika 8-6.a). Na parametre uzroka odnosi se 429 (68 %) i na parametre posljedice 193 (71 %). Prema U-P odnosu kosini je također dodijeljena klasa 4. Kombinacijom klasa, ugroženost od odrona procijenjena je kao vrlo visoka (klasa A). Za kosinu 202-82-D ukupan broj bodova iznosi 579 (Slika 8-6.b). Na parametre uzroka odnosi se 519 (83 %) ali na parametre posljedice puno manje nego u prethodnom slučaju, 60 (22 %). Prema U-P odnosu kosini je dodijeljena klasa 2. Kombinacijom klasa, ugroženost od odrona procijenjena je kao visoka (klasa B).

Drugi primjer prikazuje kosine kojima je prema U-P odnosu dodijeljena klasa 4, ali konačna procjena razlikuje kosine za jednu kategoriju klase prema ugroženosti od odrona (Slika 8-7).

Za kosinu 604-47-L ukupan broj bodova iznosi 667 (Slika 8-7.a). Na parametre uzroka odnosi se 483 (77 %) i na parametre posljedice 184 (68 %). Prema ukupnom broju bodova kosini je također dodijeljena klasa 4. Kombinacijom klasa, ugroženost od odrona procijenjena je kao vrlo visoka (klasa A). Za kosinu 604-86-F ukupan broj bodova iznosi 329 (Slika 8-7.b). Na parametre uzroka odnosi se puno manje nego u prethodnom slučaju, 135 (22 %) i na parametre posljedice 194 (72 %). Prema ukupnom broju bodova kosini je dodijeljena klasa 2. Kombinacijom klasa, ugroženost od odrona procijenjena je kao visoka (klasa B).




Slika 8-6. Kosine klase 4 prema ukupnom broju bodova: a) 604-54-D; b) 202-82-D



Slika 8-7. Kosine klase 4 prema U-P odnosu: a) 604-47-L; b) 604-86-F

Verifikacija bodovnih modela dala je rezultate koji pokazuju bolje poklapanje u kategorijama klasa svih parametara verifikacije i klasa kosina prema ugroženosti (prema metodologiji klasifikacije) u odnosu na klase definirane samo na temelju ukupnog broja bodova ili samo na temelju U-P odnosa (Slika 8-8).

Kada se promatraju zbrojeno segmenti za sva tri seta podataka verifikacije (preliminarna procjena, stabilnost kosina, tragovi odrona), 422 segmenta nalazi se unutar iste kategorije klasa parametara verifikacije i klasa kosina prema ugroženosti. Za klasu kosina prema ukupnom broju bodova unutar iste kategorije klasa je 377 segmenata, odnosno za klase prema U-P odnosu 379 segmenata. Iako razlike nisu velike, navedeno ide u prilog razrađenoj metodologiji klasifikacije kosina.



Slika 8-8. Zbroj segmenata za sve kombinacije klasa kosina i parametara korištenih za verifikaciju, za klasu prema ukupnom broju bodova (BM14-1), klasu prema U-P odnosu (BM14-2) i konačno definiranu klasu kosine prema ugroženosti od odrona (BM14-3)

8.3. STATISTIČKE ANALIZE I OPTIMIZACIJA BODOVNOG MODELA

Linearnom regresijom određeni su parametri čija varijabilnost statistički značajno utječe na varijabilnost ukupnog broja bodova. Za sva tri tipa odrona broj tih parametara je veći ako je kao zavisna varijabla promatrana klasa prema ukupnom broju bodova. Razlog odstupanja u rezultatima je očekivan i na njega utječe način definiranja klasa ukupnog broja bodova. Za logističku regresiju, uz frekvencije klasa prediktora, važne su i frekvencije svake ćelije unutar

tablice kontingencije (prediktor - zavisna varijabla). S druge strane, svi parametri koji su logističkom regresijom određeni kao statistički značajni, kao takvi su određeni i linearnom regresijom. Izuzetak je jedino *Voda* kod prevrtanja, za koju u logističkoj regresiji p -vrijednost iznosi 0,0345, što je relativno blizu vrijednosti 0,05 u usporedbi s ostalim p -vrijednostima statistički značajnih parametara za klasu kosine prema ukupnom broju bodova.

U usporedbi jednostavne i višestruke linearne regresije, za ravninski i klinasti slom manji je broj parametara koji su određeni kao statistički značajni u sklopu višestruke regresije. Razlog tome je što ona uzima u obzir istovremeni utjecaj svih parametara uključenih u model.

Provedene logističke regresije dale su rezultate koji se mogu objasniti u skladu s razrađenom metodologijom klasifikacije. Za klase prema ukupnom broju bodova veći je broj parametara uzroka od parametara posljedice koji su određeni kao statistički značajni. Za klase prema U-P odnosu veći je broj parametara posljedice od parametara uzroka koji su određeni kao statistički značajni. Isto tako, logični su i odnosi u vrijednostima omjera šansi za parametre koji su određeni kao statistički značajni za obje ove klase. U tim je slučajevima, za parametre uzroka veći omjer šansi kod klasa prema ukupnom broju bodova, dok je za parametre posljedice veći kod klasa prema U-P odnosu.

Za klase prema U-P odnosu, za sva tri tipa odrona, kao statistički značajni određeni su svi parametri iz skupine parametara posljedica. Izuzetak je jedino *Udaljenost* za ravninski i klinasti slom, koji se kod niti jedne analize nije pokazao kao statistički značajan. Tu svakako treba spomenuti *Nagib* i *Razvedenost* za ravninski i klinasti slom te *Udaljenost* za prevrtanje i osipavanje koji su ovom analizom određeni kao statistički značajni iako se za klase prema ukupnom broju bodova nisu pokazali kao takvi.

Za klasu kosine prema ugroženosti od odrona kao statistički značajni parametri određeni su oni parametri koji su kao takvi određeni za klase prema ukupnom broju bodova i/ili za klase prema odnosu bodova pojedinih skupina parametara. Izuzetak je jedino *Oblik bloka* za osipavanje, koji se pokazao kao statistički značajan jedino za klasu kosine prema ugroženosti. Za njega p -vrijednost iznosi 0,0367, što je relativno blizu vrijednosti 0,05 u usporedbi s ostalim p -vrijednostima statistički značajnih parametara za klasu kosine prema ugroženosti.

Iako je u sklopu rada za određivanje statistički značajnih parametara korištena p -vrijednost, ona sama ne može dati cjeloviti prikaz rezultata. Zato je, kao mjerilo jakosti veze, uz p -vrijednost, kod linearne regresije prikazan koeficijent korelacije, odnosno kod logističke regresije omjer šansi. Prema tim vrijednostima može se zaključiti sljedeće:

- parametri koji najviše utječu na ukupan broj bodova i **klase prema ukupnom broju bodova** su:
 - za ravninski i klinasti slom: *Zijev i Ispuna diskontinuiteta, Izraženost i Okršenost*,
 - za prevrtanje: *Maksimalna veličina bloka i Izraženost*,
 - za osipavanje: *Maksimalna veličina bloka, Izraženost, Okršenost i Razvedenost*;
- parametri koji najviše utječu na **klase prema U-P odnosu** su:
 - za ravninski i klinasti slom: *Nagib, Razvedenost, Broj tipova odrona i Voda*,
 - za prevrtanje: *Nagib, Maksimalna veličina bloka, Razvedenost, Dominantna veličina bloka i Udaljenost*,
 - za osipavanje: *Razvedenost, Nagib, Udaljenost, Okršenost, Dominantna veličina bloka, Maksimalna veličina bloka*;
- parametri koji najviše utječu na **klase prema ugroženosti od odrona**:
 - za ravninski i klinasti slom: *Nagib, Razvedenost, Zijev diskontinuiteta i Voda*,
 - za prevrtanje: *Maksimalna veličina bloka, Nagib, Dominantna veličina bloka, Razvedenost, Izraženost*,
 - za osipavanje: *Razvedenost, Okršenost, Nagib, Maksimalna veličina bloka, Dominantna veličina bloka, Udaljenost*.

Potrebno je reći i kako u svim regresijskim analizama kao statistički značajni nisu određeni sljedeći parametri:

- *Oborine i temperatura* za sve tipove odrona,
- *Hrapavost diskontinuiteta, Dominantna veličina bloka i Udaljenost* za ravninski i klinasti slom,
- *Broj tipova odrona* za prevrtanje,
- *Voda* za osipavanje.

Obradom rezultata dobivenih na temelju svih regresijskih analiza može se zaključiti kako određivanje statistički značajnih parametara ovisi o:

- frekvencijama klasa zavisne varijable,
- frekvencijama klasa prediktora, odnosno distribuciji vrijednosti prediktora kada se radi o kontinuiranoj varijabli,
- frekvencijama svake ćelije unutar tablice kontingencije (zavisne varijable - prediktor),
- definiranoj razini značajnosti (α),
- veličini uzorka, koja utječe na p -vrijednost,
- definiranim uvjetima višestruke regresije za ulazak varijable u model i za njezin ostanak u modelu.

Potrebno je napomenuti i kako se za statistički neznačajne rezultate ne može reći kako veza nikako ne postoji, već se samo može zaključiti kako za njezino postojanje nije pronađeno dovoljno dokaza (Ilakovac, 2009). Uz to, bitno je razlikovati statističku od praktične važnosti. U tom smislu svakako treba spomenuti *Temperaturu i oborine* koja nije određena kao statistički značajan parametar u niti jednoj regresijskoj analizi (osim kod jednostavne linearne regresije za osipavanje), a koja prema literaturi i prema iskustvu istraživača ima bitan utjecaj na trošenje stijenske mase, čime doprinosi mogućnosti pojave odrona.

Koeficijenti višestruke regresije uvjetovani su svim varijablama uključenim u model. Stoga isključivanje parametara iz modela, na temelju jednostavne regresije te prema definiranim uvjetima višestruke *stepwise* metode, može biti upitno. Glavni razlog, uz praktičnu važnost parametra, odnosi se na njegovu ulogu u važnim interakcijama s drugim parametrima. Naime, kada postoje dva prediktora koja su značajno korelirana, svu varijabilnost zavisne varijable objasniti će onaj prediktor koji prvi uđe u model te će se samim time izgubiti utjecaj drugog, njemu koreliranog prediktora. Međutim, prema postavljenom cilju optimizacije modela, odnosno smanjenja broja ulaznih parametara i pretpostavci kako ne postoji interakcija među parametrima, ono se može smatrati opravdanim. Uostalom, cilj je bio definirati što jednostavniji model prema „snimljenom“ uzorku, odnosno dobiti generalni obrazac koji će predstavljati najbolji balans između broja varijabli i dobrog predviđanja zavisne varijable.

Iako je prema izloženoj metodologiji klasifikacije logično postojanje veze između klasa kosine prema ugroženosti od odrona i ukupnog broja bodova, ordinalnom logističkom regresijom definirani su jakost i karakter veze.

Dobiveni rezultati pokazali su statistički značajnu vezu za sva tri tipa odrona. Koeficijent regresije parametra BOD (ukupan broj bodova prema modelu BM14) za sva tri tipa sloma je sličan. Iznosi 0,0276 za ravninski i klinasti slom, 0,0376 za prevrtanje i 0,0294 za osipavanje, što je u prosjeku 0,0315. To znači da se u prosjeku, neovisno o tipu odrona, za povećanje jednog boda kod ukupnog broja bodova očekuje povećanje 0,0315 u *logit*-u za veću klasu kosine prema ugroženosti. Drugim riječima, za povećanje jednog boda kod ukupnog broja bodova šansa za klasu kosine A prema klasama B, C i D je u prosjeku 1,032 ($e^{0,0315}$) puta veća. 95 % interval pouzdanosti omjera šansi ne uključuje vrijednost 1, što potvrđuje kako je procijenjeni koeficijent statistički značajan.

Rezultati provedene logističke regresije prikazani su u nastavku.

Za ravninski i klinasti slom regresijski model može se izraziti na sljedeći način:

- za klasu kosine A: $\ln(odds) = \beta_0 + \beta_1 x_i = -14,5811 + 0,0276 * BOD$
- za klasu kosine A i B: $\ln(odds) = \beta_0 + \beta_1 x_i = -8,5958 + 0,0276 * BOD$
- za klasu kosine A, B i C: $\ln(odds) = \beta_0 + \beta_1 x_i = -3,8832 + 0,0276 * BOD$

Za prevrtanje regresijski model može se izraziti na sljedeći način:

- za klasu kosine A: $\ln(odds) = \beta_0 + \beta_1 x_i = -20,1095 + 0,0376 * BOD$
- za klasu kosine A i B: $\ln(odds) = \beta_0 + \beta_1 x_i = -12,5247 + 0,0376 * BOD$
- za klasu kosine A, B i C: $\ln(odds) = \beta_0 + \beta_1 x_i = -7,8600 + 0,0376 * BOD$

Za osipavanje regresijski model može se izraziti na sljedeći način:

- za klasu kosine A: $\ln(odds) = \beta_0 + \beta_1 x_i = -15,1595 + 0,0308 * BOD$
- za klasu kosine A i B: $\ln(odds) = \beta_0 + \beta_1 x_i = -9,6616 + 0,0308 * BOD$
- za klasu kosine A, B i C: $\ln(odds) = \beta_0 + \beta_1 x_i = -6,0055 + 0,0308 * BOD$

Za definiranje klasa kosina prema ugroženosti samo na temelju ukupnog broja bodova granične vrijednosti klasa određene su na temelju predviđenih kumulativnih vjerojatnosti klase kosina prema ukupnom broju bodova (Slika 8-9) na sljedeći način:

- graničnu vrijednost između klasa A i B čini ukupni broj bodova za čiju vrijednost vjerojatnost klase kosine A iznosi 0,50;
- graničnu vrijednost između klasa B i C čini ukupni broj bodova za čiju vrijednost vjerojatnost klase kosine A i B iznosi 0,50;
- graničnu vrijednost između klasa C i D čini ukupni broj bodova za čiju vrijednost vjerojatnost klase kosine A, B i C iznosi 0,50.

Granične vrijednosti izračunate su korištenjem formula prema definiranim modelima logističke regresije u kojoj je zavisna varijabla klasa kosine prema ugroženosti od odrona, a prediktor ukupni broj bodova. Definirane klase kosina prikazane su u nastavku.

Za ravninski i klinasti slom:




- klasa A s ukupnim brojem bodova > 528 ,
- klasa B s ukupnim brojem bodova raspona 311-528,
- klasa C s ukupnim brojem bodova raspona 141-311,
- klasa D s ukupnim brojem bodova < 141 .

Za prevrtanje:

- klasa A s ukupnim brojem bodova > 535 ,
- klasa B s ukupnim brojem bodova raspona 333-535,
- klasa C s ukupnim brojem bodova raspona 209-333,
- klasa D s ukupnim brojem bodova < 209 .

Za osipavanje:

- klasa A s ukupnim brojem bodova > 492 ,
- klasa B s ukupnim brojem bodova raspona 314-492,
- klasa C s ukupnim brojem bodova raspona 195-314,
- klasa D s ukupnim brojem bodova < 195 .





Slika 8-9. Očekivane kumulativne vjerojatnosti za klasu kosine prema ugroženosti od odrona na temelju ukupnog broja bodova: a) ravinski i klinasti slom; b) prevrtanje; c) osipavanje


Za određivanje ukupnog broja bodova mogu se primijeniti rezultati višestruke linearne regresije, odnosno jednadžbe prema izrazima 7-5, 7-6 i 7-7.

Ovakav način određivanja ukupnog broja bodova pokazao je, za sva tri tipa odrona, značajnu korelaciju s ukupnim brojem bodova kada su u obzir uzeti svi klasifikacijski parametri (Slika 8-10).

Na temelju ukupnog broja bodova određenog putem jednadžbi višestruke linearne regresije određene su klase kosina prema ugroženosti od odrona. Pri tome su za granice klasa postavljene vrijednosti bodova na temelju rezultata ordinalne logističke regresije. Dobivene klase uspoređene su s klasama kosina prema ugroženosti od odrona definiranim prema metodologiji klasifikacije (Tablica 8-3).

Za sva tri tipa odrona segmenti su prisutni unutar klasa kosina koje se podudaraju ili razlikuju za jednu kategoriju klasa, dok segmenata unutar klasa kosina koje se razlikuju za dvije ili tri kategorije nema. Izuzetak je samo jedan segment za ravninski i klinasti slom koji se pojavljuje unutar klasa kosine koje se razlikuju za dvije kategorije klasa.





c)

Slika 8-10. Korelacija ukupnog broja bodova dobivenih na temelju svih klasifikacijskih parametara i na temelju statistički značajnih parametara određenih višestrukom linearnom regresijom: a) ravninski i klinasti slom; b) prevrtanje; c) osipavanje

Tablica 8-3. Usporedba frekvencija klasa kosina prema ugroženosti s frekvencijama klasa kosina predviđenih na temelju regresijskog modela: a) ravninski i klinasti slom; b) prevrtanje; c) osipavanje

a)

klasa kosine prema ugroženosti	klasa kosine prema regresijskom modelu				razlika u kategorijama klasa	broj segmenata i (%)
	A	B	C	D		
A	1	4	0	0	3	0 (0,00)
B	2	40	2	0	2	0 (0,00)
C	0	9	15	0	1	18 (24,32)
D	0	0	1	0	0	56 (75,68)

b)

klasa kosine prema ugroženosti	klasa kosine prema regresijskom modelu				razlika u kategorijama klasa	broj segmenata i (%)
	A	B	C	D		
A	15	5	0	0	3	0 (0,00)
B	4	58	2	0	2	0 (0,00)
C	0	7	5	1	1	20 (19,61)
D	0	0	1	4	0	82 (80,39)

c)

klasa kosine prema ugroženosti	klasa kosine prema regresijskom modelu				razlika u kategorijama klasa	broj segmenata i (%)
	A	B	C	D		
A	7	10	0	0	3	0 (0,00)
B	6	60	18	1	2	1 (0,54)
C	0	24	32	0	1	66 (35,87)
D	0	0	8	18	0	117 (63,59)

Ako se vratimo na primjere za koje je dan prikaz procjene ugroženosti od odrona (poglavlje 6.7.) korištenjem rezultata regresijskih analiza dobili bi sljedeće procjene ugroženosti od odrona.

Za kosinu iz primjera 1 (202-61-D) preko jednadžbe višestruke linearne regresije dobiven je ukupan broj bodova 582. Time je, prema definiranim granicama klasa prema ugroženosti od odrona za kosinu procijenjena klasa A (broj bodova > 492). Za kosinu iz primjera 2 (604-7-D) preko jednadžbe višestruke linearne regresije dobiven je broj bodova 178. Time je, prema definiranim granicama klasa prema ugroženosti od odrona za kosinu procijenjena klasa D (broj bodova < 195).

Klase prema ugroženosti od odrona procijenjene na temelju regresijskog modela za obje kosine se podudaraju s klasama dobivenim korištenom klasifikacijom.

8.4. OGRANIČENJA SUSTAVA I PREPORUKE ZA POBOLJŠANJE

Jedna od glavnih značajki prikazanog sustava odnosi se na jednostavno i brzo prikupljanje podataka, što uključuje procjenu većine parametara. Kako procjena podrazumijeva subjektivni pristup u određivanju značajki parametara, bitno je klase parametara definirati na jednostavan i razumljiv način te ih kvantificirati što je više moguće. U tom smislu, za buduća istraživanja preporuča se klase parametara *Okršenost* i *Tragovi odrona* kvantificirati ili detaljnije opisati. Na temelju prikazanih frekvencija klasa svih parametara (Prilog 1) izdvojeni su oni parametri kod kojih nije zastupljena barem jedna klasa. Treba ponoviti kako su za *Zijev diskontinuiteta* podaci distribuirani samo u dvije klase te se stoga za njega preporuča reklasifikacija, odnosno preciznije definiranje klasa.

Uz to, u primjeni kriterija za odabir klasa parametara vrlo je važna konzistentnost. Tek kada je ona zadovoljena moguće je provesti kvalitetnu usporedbu podataka.

Verifikacija bodovnih modela provedena je prema tri različita seta podataka. Svaki od njih ima određene „nedostatke“ koji mogu znatno utjecati na odabir najadekvatnijeg bodovnog modela i navode se u nastavku.

Lokacije na kojima je provedena IG prospekcija već su izdvojene kao potencijalno opasne te stoga definirane klase kosina prema ugroženosti od odrona nisu podjednako zastupljene. Zbog toga je i relativno mali broj segmenata prema *Preliminarnoj procjeni* svrstan u klasu I (svega 6 %), a isti je slučaj i za *Stabilnost kosina* kod kojeg unutar klase I nema niti jednog segmenta. Samim time, verifikacija bodovnog modela nije jednako pouzdana na svim razinama.

Podaci za *Stabilnost kosina* ne vode se jednako unutar svih Regionalnih jedinica održavanja HŽ-a. Naime, za pojedine dionice ovaj se podatak pripisuje cijelom usjeku ne odvajajući pri tome lijevu i desnu stranu. Međutim, pojedine značajke realno mogu značajno varirati od jedne do druge strane usjeka. Često je konfiguracija terena takva da je jedna strana usjeka puno niža od druge, udaljenost od pruge nije nužno jednaka, a strukturni elementi stijenske mase često definiraju različit tip odrona na svakoj strani.

Kod postojećih sustava parametar o učestalosti pojave odrona koristi se kao jedan od klasifikacijskih parametara. Budući je i kod njih prepoznat problem u smislu nepostojanja dovoljno kvalitetnih podataka ili nedovoljnog broja podataka, Mauldon et al. (2007) ovaj parametar vrednuju ili prema postojećim podacima o učestalosti ili prema terenskoj procjeni na temelju tragova odlomljenih blokova. U tom smislu su, za jedan dio kosina u sklopu ovog istraživanja, prikupljeni podaci o *Tragovima odrona* koji su procijenjeni prema odlomljenim blokovima ili tragovima na samoj kosini. Klase parametra definirane su prema količini odlomljenih blokova/materijala. Međutim, puno nakupljenog materijala u podnožju kosine ili zaštitnom jarku ne mora značiti da će odron i ugroziti prugu. Dapače, to može upućivati na znatnu učinkovitost jarka. Uz to, količina odlomljenog materijala u podnožju kosine ovisna je i o učestalosti čišćenja i održavanja samog jarka.

Preliminarna procjena predstavlja vrlo važan korak, kako u postojećim sustavima, gdje se na temelju nje izdvajaju kosine za koje se ne provodi detaljna procjena, tako i u sklopu provedenog istraživanja, gdje su podaci *Preliminarne procjene* korišteni kao jedan od setova podataka za verifikaciju bodovnih modela.

Iako je prepoznavanje kosina koje ne ugrožavaju željezničku prugu i njihovo izdvajanje u najpovoljniju klasu uglavnom jasno i jednoznačno, određivanje nepovoljnih klasa kao i postavljanje granice među njima nisu jasno definirani. To dovodi do značajne subjektivnosti kod procjene te zbog toga bitno ovisi o iskustvu istraživača. Iz tog razloga dan je prijedlog za objektivnije provođenje preliminarne procjene. Prema njemu se ona i dalje temelji na procjeni mogućnosti pojave odrona i procjeni hoće li odlomljeni materijal doseći željezničku prugu, ali procjenama su dodijeljeni bodovi (Tablica 8-4).

Tablica 8-4. Prijedlog za objektivnije provođenje Preliminarne procjene

PRELIMINARNA PROCJENA		procjena mogućnosti pojave odrona			
		velika (10)	srednja (6)	mala (3)	nema (0)
procjena dostizanja odlomljenog materijala do željezničke pruge	velika (10)	100	60	30	0
	srednja (6)	60	36	18	0
	mala (3)	30	18	9	0
	nema (1)	10	6	3	0

Umnožak bodova definira klase *Preliminarne procjene* na sljedeći način:

- klasa A: s iznosom broja bodova 100;
- klasa B: s iznosom broja bodova 60 i 36;
- klasa C: s iznosom broja bodova 30 i 18;
- klasa D: s iznosom broja bodova 10, 9 i 6;
- klasa E: s iznosom broja bodova 3 i 0.

Potrebno je napomenuti kako je pri tome za oba parametra uvedena klasa „nema“. Njoj je za procjenu mogućnosti pojave odrona pridružen broj bodova 0, a za procjenu dostizanja odlomljenog materijala do željezničke pruge pridružen je broj bodova 1. Naime, ako ne postoje

uvjeti da dođe do odrona, željezničku prugu nema što ugroziti. Takve kosine svrstavaju se u klasu E, zajedno s kosinama kojima je pridružen broj bodova 3, i za njih se ne provodi detaljna procjena. Nadalje, koliko god postoji velika mogućnost za pojavu odrona, ako ne postoje uvjeti da odlomljeni materijal dosegne željezničku prugu, također ne možemo govoriti o ugroženosti. Takve kosine, uz procjenu velike i srednje mogućnosti pojave odrona, svrstane su u ipak u klasu D, kako bi se upozorilo na potrebne povremene ophodnje i čišćenja, ovisno o količini odlomljenog materijala.

Na temelju rezultata analiza korištenih za određivanje parametara koji najviše utječu na procjenu ugroženosti od odrona i evidencijskih listova koji se trenutno koriste u HŽ-u, predlaže se popis parametara za sustavno praćenje pojave odrona duž željezničke pruge. Podaci bi se trebali prikupljati periodički ili u slučaju pojave odrona koju je moguće utvrditi tijekom redovitih ophodnji, održavanja, čišćenja ili putem dojave. U definiranim vremenskim intervalima trebalo bi se za svaku kosinu zabilježiti podatak je li se u tom vremenskom periodu odron dogodio ili nije te ako se dogodio je li ugrozio prugu ili nije. U slučaju pojave odrona preporuča se bilježiti sljedeće podatke:

- Datum: datum događaja,
- Lokacija: broj željezničke pruge i stacionaža na kojoj se odron dogodio, strana na kojoj se nalazi kosina mjerena u smjeru rasta stacionaže,
- Visina: visina s koje se odron dogodio,
- Udaljenost: udaljenost od kosine do mjesta gdje je blok zaustavljen, uz napomenu je li dosegao željezničku prugu,
- Tip odrona: procjena tipa odrona:
 - na pojavu odrona utjecali su diskontinuiteti,
 - na pojavu odrona utjecalo je trošenje i razlomljenost stijenske mase,
- Veličina odlomljenog bloka ili volumen materijala (ukoliko je razbijen na više dijelova veličina najvećeg i procjena ukupnog): dimenzije međusobno okomitih stranica bloka,
- Šteta: oštećenost željezničke pruge i/ili kanalice,
- Uzrok: procjena uzroka same pojave odrona,
- Vremenski uvjeti na dan pojave odrona i nekoliko dana ranije: temperature, oborine.

Sustavno i periodičko praćenje pojave odrona preduvjet je procjene hazarda od odrona. Uz to, prikupljenim podacima omogućila bi se pouzdana metoda verifikacije korištenog bodovnog modela, kao i određivanje onih parametara koji statistički značajno utječu na pojavu odrona i ugroženost željezničke pruge. Dobiveni rezultati statističkih analiza mogli bi se upotrijebiti za dodjeljivanje težinskih faktora klasifikacijskim parametrima. Na taj način bi se izbjeglo jednako dodjeljivanje bodovnih vrijednosti svim klasifikacijskim parametrima, što je prepoznato kao još jedan nedostatak prikazanog sustava.

Mjesta za poboljšanje i unaprjeđenje sustava ima te se navode samo neke od smjernica za buduća istraživanja.

- U korišteni model bodovanja i način klasificiranja kosina moguće je jednostavno integrirati parametre koji se odnose na učestalost pojave odrona te na značajke prometa (dozvoljena brzina, vidljivost, frekvencija prometa). Na taj način u sustav bi se uključili i elementi za procjenu hazarda i rizika. Upitno je samo postojanje ovih podataka i njihova kvaliteta.
- Integracijom sustava u GIS okruženje omogućila bi se produkcija karata s lokacijama koje potencijalno ugrožavaju željezničku prugu, njihovim klasama i svim pripadajućim atributima. Također, bilo bi moguće uklopiti i različite interesne slojeve kao što su županijske granice, gradovi i općine, rute željezničkih pruga i cestovnih prometnica te razne tematske podloge. Na taj način, olakšalo bi se donošenje odluka u određivanju lokacija prioriternih za sanaciju i na temelju drugih aspekata, kao što su zahtjevnost pristupa kosini te blizina ostalih kosina A i B klase.
- U Inventar kosina bilo bi korisno unijeti podatke o provedenim sanacijskim mjerama, čime bi se omogućilo praćenje njihove učinkovitosti.
- Sustav je moguće prilagoditi cestovnim prometnicama, posebno državnim i lokalnim cestama kod kojih sustav održavanja i zaštite kosina nije na razini koja se primjenjuje kod autocesta. Uz iste ili slične geometrijske značajke kosina i uz uvjet karbonatne stijenske mase, u sklopu sustava zadržali bi se gotovo svi klasifikacijski parametri. Upitan je parametar *Udaljenost*, koji bi bilo primjereno zamijeniti s parametrom koji se odnosi na širinu prometnice i broj traka, jer za razliku od željezničke pruge na cestovnim je prometnicama moguće zaobići odlomljeni materijal. Od klimatskih značajki svakako bi trebalo provjeriti utjecaj parametra koji se odnosi na orijentaciju kosine, budući su lijeva i

desna strana istog usjeka kod cesta, u odnosu na željezničku prugu, udaljeniji pa samim time i izloženiji suncu. I ovdje se naglašava, kao vrlo bitan parametar Učinkovitost zaštitnog jarka, za kojega treba definirati postupke mjerenja (dimenzije jarka, oblik jarka). Za potrebe provođenja verifikacije sustava svakako bi trebalo prikupiti postojeće podatke o pojavama odrona (županijske uprave za ceste).

- U sklopu sustava, za potrebe definiranja U-P odnosa, uzrok je definiran kao potencijal odrona i određuju ga parametri koji utječu na pojavu odrona (parametri uzroka - inženjerskogeološke značajke i klimatske značajke). Budući je u sklopu sustava već razrađena njegova klasifikacija (vrlo visok, visok, srednji i nizak) i definirane su granice klase, postoji mogućnost korištenja procedure i za druge namjene kod kojih bi se vrednovali samo parametri uzroka. To se odnosi na procjenu potencijala odrona kod površinskih kopova ili bilo kojih usjeka koji ne moraju nužno biti uz prometnicu.

9. ZAKLJUČAK

It always seems impossible until it's done.

Nelson Mandela (1918 - 2013)

U sklopu doktorskog rada prikazani su metodologija i rezultati provedenih istraživanja i analiza, čiji je osnovni cilj predstavljao razvoj sustava za procjenu ugroženosti od odrona duž željezničkih pruga u karbonatnim stijenama Hrvatske. Svrha izrade sustava očituje se u proaktivnom pristupu koji podrazumijeva definiranje kosina kod kojih je ugroženost željezničke pruge od odrona najveća, kako bi se izvele odgovarajuće mjere sanacije prije nego se odron dogodi. Bitno je naglasiti kako sustav kao takav predstavlja koristan alat u identificiranju najkritičnijih lokacija, ali i da se provodi prije detaljnih inženjerskogeoloških istraživanja koja ne može i ne smije zamijeniti. Ona se provode u nastavku istraživanja u sklopu izvedbenih projekata sanacije i nisu predmet istraživanja ovog rada.

- Razvoj cjelovitog sustava procjene ugroženosti od odrona uključio je:
 - definiranje klasifikacijskih parametara i metodologiju njihovog mjerenja i procjene;
 - izradu terenskog formulara za prikupljanje podataka o klasifikacijskim parametrima;
 - IG prospekciju s preliminarnom i detaljnom procjenom;
 - izradu Inventara kosina;
 - klasifikaciju kosina prema procijenjenoj ugroženosti od odrona;
 - verifikaciju bodovnih modela i definiranje onog koji je najprikladniji za istraživano područje;
 - optimizaciju bodovnog modela.

Pri tome valja naglasiti kako je metodologija prvog koraka bazirana prema osnovnoj svrsi izrade sustava. To podrazumijeva mjerenje i procjenu ključnih parametara koji definiraju određeni tip odrona i značajke kosine.

- Prikupljanje podataka tijekom IG prospekcije temelji se najvećim dijelom na procjenama. Budući one zahtijevaju određeno iskustvo, bitno je klase parametara definirati što jasnije i preciznije. Na taj način korisnicima s različitim stupnjem iskustva omogućeno je dobivanje istih ili vrlo sličnih podataka. Pri tome treba napomenuti kako je sustav bodovanja vrlo osjetljiv, čak i za razliku od jedne kategorije klasa ako se radi o klasama parametara III i IV.
- Na temelju provedene IG prospekcije zaključeno je kako je bitno provođenje procjene ugroženosti od odrona odvojeno za lijevu i desnu stranu istog usjeka. Korisno je i izdvajanje kosine u segmente u pojedinim slučajevima, posebno kada je ugroženost od odrona značajna samo za dio kosine, kada su na kosini dominantno prisutni različiti tipovi odrona ili kada se mijenja odnos geometrije linearnog infrastrukturnog objekta (pruge) i geološke strukture (npr. u zavojima).
- Odabir klasifikacijskih parametara i princip njihovog vrednovanja temelje se na postojećim sustavima koji su izvedeni iz *RHRS-a*, a uključuju verzije za države Tennessee (Mauldon et al., 2007) i Colorado (Russell et al., 2008). U odnosu na njih uvedene su sljedeće **modifikacije**:
 - dodavanje parametara: *Okršenost*, *Broj tipova odrona*, *Udaljenost*;
 - vrednovanje dvije veličine bloka - *Maksimalna veličina bloka* i *Dominantna veličina bloka* i definiranje njihovih klasa prema već razvijenim klasifikacijama;
 - definiranje klasa parametara *Zijev diskontinuiteta* i *Ispuna diskontinuiteta* te *Visina*, *Nagib* i *Udaljenost*;
 - izmjena parametara unutar klimatskih značajki;
 - u sustav nisu uključeni učestalost pojave odrona, kao niti parametri koji se odnose na značajke prometa i prometnica, čime je opravdano sustav nazvati sustavom ugroženosti od odrona.
- Za karbonatnu stijensku masu unutar istraživanog područja mogu se definirati tri dominantna tipa odrona: klizanje koje uključuje ravninski i klinasti slom, prevrtanje te

odron u užem smislu koji uključuje obrušavanje, osipavanje i njihovu pojavu vezanu uz razlomljene zone. Kao četvrti tip odrona definirano je diferencijalno trošenje. Ono se unutar istraživanih područja nije pokazalo kao značajan tip odrona (6 je segmenata kod kojih je takav tip odrona definiran kao najkritičniji). Smatra se kako ga za buduća istraživanja ipak ne treba isključiti iz sustava jer je njegova pojava realno moguća. Uz to, već samo definiranje ovog tipa odrona može uputiti na karakteristične mjere sanacije. U tim slučajevima dovoljno je zaštititi samo nekompetentne slojeve, čime se sprječava njihovo daljnje trošenje i formiranje prevjesa unutar kompetentnih slojeva.

- U sklopu rada definirano je 16 bodovnih modela koji se međusobno razlikuju prema načinu vrednovanja određenih klasifikacijskih parametara. Najadekvatniji bodovni model prema uvjetima na istraživanom području odabran je na temelju verifikacije s tri seta podataka. Oni uključuju podatke *Preliminarne procjene* i *Tragova odrona*, koji su procijenjeni tijekom IG prospekcije i *Stabilnosti kosina*, koje su definirane od strane Regionalnih jedinica održavanje Hrvatskih željeznica, a temelje se na vizualnoj procjeni i terenskom iskustvu osoba koje obilaze željezničku prugu. Kada se govori o najadekvatnijem bodovnom modelu, svakako treba uzeti u obzir prepoznate „nedostatke“ za svaki set podataka (poglavlje 8.4.).
- Kao najadekvatniji bodovni model odabran je onaj koji uključuje vrednovanje sljedećih parametara:
 - za inženjerskogeološke značajke: *Izraženost*, *Maksimalna veličina bloka (b)*, *Dominantna veličina bloka (a)* i značajke određenog tipa odrona za najkritičniji tip odrona te *Broj tipova odrona* i *Okršenost*;
 - za klimatske značajke: *Oborine i temperatura* i *Voda*;
 - za geometrijske značajke: *Visina (b)*, *Nagib (a)*, *Udaljenost* i *Razvedenost*.

Verifikacija bodovnog modela pokazala je kako se, kad se uzmu u obzir sva tri seta podataka korištenih za verifikaciju, samo 2 % segmenata razlikuje između klase kosine i klase parametra verifikacije za maksimalne tri kategorije klasa, a najviše segmenata, 44 %, nalazi se unutar iste kategorije klasa.

- Eksponencijalni bodovni sustav kojim su klasama svakog pojedinog parametra pridružene vrijednosti bodova 3-9-27-81 pokazao se kao optimalan (Slika 8-1). Na temelju njega dobivena je jasna diferencijacija ukupnog broja bodova. Uz to, za bodovanje parametra

Visina korištena je kontinuirana funkcija s rasponom vrijednosti bodova 1-100, što se pokazalo značajnim, posebno za bodove dodijeljene vrijednostima parametra koje se nalaze na granicama definirane III. i IV. klase.

- Klasifikacija kosina prema ugroženosti od odrona modificirana je na način da uzima u obzir klase prema ukupnom broju bodova i klase prema U-P odnosu.

Klase prema ukupnom broju bodova definirane su na temelju 25, 50 i 75 % vrijednosti maksimalnog dobivenog ukupnog broja bodova. U sklopu poglavlja 8.2. opravdano je linearno razgraničavanje klasa prema ukupnom broju bodova iako se vrednovanje pojedinih parametara temelji na eksponencijalnom bodovanju.

Klase prema U-P odnosu temelje se na odnosu broja bodova parametara uzroka i broja bodova parametara posljedica (izražen preko % maksimalnog dobivenog broja bodova pojedine skupine parametara). Pri tome su kao parametri uzroka definirani oni iz skupine inženjerskogeoloških i klimatskih značajki, a kao parametri posljedice oni iz skupine geometrijskih značajki.

- Imajući u vidu razrađenu metodologiju klasifikacije i klase predložene preliminarne procjene, rezultat klasifikacije kosina prema ugroženosti od odrona predstavljaju četiri sljedeće klase:
 - A: klasa vrlo visoke ugroženosti od odrona; vrlo velika vjerojatnost pojave odrona kod kojeg će odlomljeni materijal vrlo vjerojatno dosegnuti prugu; vrlo visok prioritet sanacije;
 - B: klasa visoke ugroženosti od odrona; velika vjerojatnost pojave odrona kod kojeg će odlomljeni materijal vjerojatno dosegnuti prugu; visok prioritet sanacije;
 - C: klasa srednje ugroženosti od odrona; postoji mogućnost pojave odrona kod kojega odlomljeni materijal može dosegnuti prugu; srednji prioritet sanacije;
 - D: klasa niske ugroženosti od odrona, postoji mogućnost pojave odrona kod kojega odlomljeni materijal vjerojatno neće dosegnuti prugu, nizak prioritet sanacije.

U slučaju pojave odrona za kosinu bi trebalo provesti reklasifikaciju.

- Uzorak na kojem je provedeno istraživanje (366 segmenata) dovoljno je veliko te se smatra reprezentativnim za kosine izvedene u karbonatnim stijenama Hrvatske. Stoga se

definirane granice klasa mogu koristiti u budućim istraživanjima za područje Krških Dinarida. One se prema rezultatima ordinalne logističke regresije, koja je određena odvojeno za tri dominantna tipa odrona, može definirati njihovom srednjom vrijednosti kao:

- klasa A s ukupnim brojem bodova > 518 ,
 - klasa B s ukupnim brojem bodova 319-518,
 - klasa C s ukupnim brojem bodova 182-319,
 - klasa D s ukupnim brojem bodova < 182 .
- Statističke analize (linearna i logistička regresija) korištene su u radu sa ciljem određivanja onih parametara koji statistički značajno utječu na procjenu ugroženosti od odrona te optimizacije bodovnog modela.

Na temelju dobivenih rezultata može se konstatirati kako se regresijske metode mogu koristiti za određivanje statistički značajnih parametara. Pri tome je prepoznato nekoliko stavki koje utječu na rezultate analiza (poglavlje 8.3.). Stoga, u njihovoj interpretaciji treba biti oprezan i posebno paziti da statistički značaj ne isključi praktični značaj. Iako je u sklopu rada za određivanje statistički značajnih parametara korištena p -vrijednost za interpretaciju veze potrebno je prikazati i mjerilo jakosti veze. Stoga je kod linearne regresije prikazan koeficijent korelacije, a kod logističke regresije omjer šansi.

Provedene logističke regresije dale su, prema razrađenoj metodologiji klasifikacije, logične rezultate. To se očituje u određenim statistički značajnim parametrima koji se razlikuju za klase kosine prema ukupnom broju bodova i klase prema U-P odnosu.

Statističke analize provedene su i za procijenjenu ugroženost pruge od odrona. Budući je ona dobivena na temelju bodovnog modela koji je verifikacijom odabran kao najadekvatniji model, može se pretpostaviti kako indirektno statistički značajni parametri utječu i na mogućnost pojave odrona i ugroženost željezničke pruge. To su: *Visina*, *Nagib*, *Razvedenost* za sva tri tipa odrona, *Udaljenost*, *Izraženost*, *Maksimalna veličina bloka* i *Dominantna veličina bloka* za prevrtanje i osipavanje, *Voda* i *Zijev diskontinuiteta* za ravni i klinasti slom, *Okršenost* za osipavanje.

- U sklopu rada predložena je tablica za objektivnije provođenje Preliminarne procjene (Tablica 8.4). Njom su definirane četiri klase (A-D) na temelju umnoška bodova dodijeljenih

procijenjenim vrijednostima dviju značajki - mogućnosti pojave odrona i dostizanju odlomljenog materijala do željezničke pruge. Dodatna, peta klasa (E) definira kosine kod kojih nema mogućnosti pojave odrona i kod kojih je procijenjena vrijednost za obje značajke „mala“. Ove kosine isključuju se iz detaljne procjene.

- Kao glavni nedostatci sustava prepoznati su:
 - subjektivnost kod vrednovanja parametara;
 - nedovoljni broj podataka o pojavama odrona, koji bi omogućili pouzdaniju verifikaciju bodovnog modela;
 - jednako vrednovanje svih parametara.

Temeljem svega iznesenog može se konstatirati kako su potvrđene sve hipoteze koje su iznesene u uvodnom dijelu doktorskog rada.

Prikazana ili slična metodologija koja uključuje proaktivni pristup u određivanju prioritetnih lokacija za sanaciju na područjima koja su ugrožena odronima te učinkovito i ekonomski opravdano korištenje resursa, u Hrvatskoj se do sada nije primjenjivala. Stoga je razvoj sustava za procjenu ugroženosti od odrona, prilagođen značajkama karbonatne stijenske mase i značajkama kosina na istraživanom području, prvi korak ka sustavnom upravljanju hazardima i rizicima povezanih s odronima. Kako *razvoj* podrazumijeva „poprimanje sve savršenijih, potpunijih i bolje prilagođenih oblika kod pojava i stvari koje se s vremenom usavršavaju“ (Anić, 1998), tako je za prikazani sustav moguća dorada i prilagodba prema podacima višegodišnjeg sustavnog praćenja pojave odrona, te u konačnici razrada njegove primjene. Ovaj rad predstavlja dobru podlogu za buduća istraživanja, u koja se mogu uklopiti mogući nedostatci i ograničenja. Iznesene preporuke za sustavno praćenje pojave odrona kroz dulji vremenski period omogućile bi kvalitetniju verifikaciju definiranih klasa kosina prema ugroženosti od odrona kao i utvrđivanje ključnih uzroka same pojave na području istraživanja.

AGRESTI, A. (2007): An introduction to categorical data analysis. 2nd edition. John Wiley & Sons, Inc., Hoboken - New Jersey - USA.

AKBARI, A., YAHAYA, F.BM., AZAMIRAD, M., FANODI, M. (2014): Landslide Susceptibility Mapping Using Logistic Regression Analysis and GIS Tools. EJGE, 19: 1687-1696.

ALLISON, P. (2012): Logistic Regression Using SAS: Theory and application. 2nd edition. SAS Institute Inc., Cary - North Carolina - USA.

ANIĆ, V. (1998): Rječnik hrvatskoga jezika. 3., prošireno izdanje. Novi Liber, Zagreb - Hrvatska.

ARBANAS, Ž., GROŠIĆ, M., UDOVIČ, D., MIHALIĆ, S. (2012): Rockfall Hazard Analyses and Rockfall Protection along the Adriatic Coast of Croatia. Journal of Civil Engineering and Architecture, 6 (3): 344-345.

AYALEW, L. & YAMAGISHI, H. (2005): The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan. Geomorphology, 65: 15-31.

BARTON, N.R., LIEN, R., LUNDE, J. (1974): Engineering classification of rock masses for the design of tunnel support. Rock Mechanics, 6 (4): 189-239.

BATEMAN, V. (2003): Development of a Database to Manage Rockfall Hazard: The Tennessee Rockfall Hazard Database. Proceeding of Transportation Research Board Annual Meeting. Washington DC - USA.

BAUER, M. & NEUMANN, P. (2011): A Guide to Processing Rock-fall Hazard from Field Data. VOGT, N., SCHUPPENER, B., STRAUB, D., BRAU, G. (ur.): Proceedings of 3rd International Symposium on Geotechnical Safety and Risk. 2.-3. lipnja, Munich - Germany. Bundesanstalt für Wasserbau, 149-156.

BELL, F.G. (2002): Geological hazards: Their assessment, avoidance and mitigation. Taylor & Francis e-Library.

BENAC, Č. (2013): Rječnik pojmova u primijenjenoj geologiji i geološkom inženjerstvu. Udžbenici Sveučilišta u Rijeci, Rijeka - Hrvatska.

BERENSON, M.L., LEVINE, D.M., KREHBIEL, T.C. (2012): Basic Business Statistics: Concepts and Applications. 12th edition. Pearson Education, Inc., Upper Saddle River - New Jersey - USA.

BERTIĆ, I., LAMPEK PAVČNIK, I., RADOVINOVIĆ, R. (2001): Satelitski atlas Hrvatske, 1:100.000. Naklada Ljevak i GISDATA, Zagreb - Hrvatska.

BIENIAWSKI, Z.T. (1989): Engineering Rock Mass Classifications: A Complete Manual for Engineers and Geologists in Mining, Civil and Petroleum Engineering. John Wiley & Sons, Inc., New York - USA.

BLAŠKOVIĆ, I. (1998): The Two Stages of Structural Formation of the Coastal Belt of the External Dinarides. *Geologia Croatica*, 51 (1): 75-89.

BRAWNER, C.O. & WYLLIE, D.C. (1975): Rock slope stability on railway projects. Proceeding of American Railway Engineering Association Regional Meeting, Vancouver - Canada.

BUDETTA, P. (2004): Assessment of rockfall risk along roads. *Natural Hazards and Earth System Sciences*, 4: 71-81.

BUDETTA, P. & NAPPI, M. (2013): Comparison between qualitative rockfall risk rating systems for a road affected by high traffic intensity. *Natural Hazards and Earth System Sciences*, 13: 1643-1653.

CHADDOCK, R.E. (1925): Principles and methods of statistics. Houghton Mifflin Company, The Riverside Press, Cambridge - England.

CHAU, K.T., WONG, R.H.C., LIU, J., LEE, C.F. (2003): Rockfall Hazard Analysis for Hong Kong Based on Rockfall Inventory. *Rock Mechanics and Rock Engineering*, 36 (5): 383-408.

- CODY, R. (2011): SAS Statistics by Example. SAS Institute Inc., Cary - North Carolina - USA.
- CORO, D., GALGARO, A., FONTANA, A., CARTON, A. (2015): A regional rockfall database: the Eastern Alps test site. *Environmental Earth Sciences*, 74 (2): 1731-1742.
- CRUDEN, D.M. (1991): A simple definition of a landslide. *Bulletin of the International Association of Engineering Geology*, 43: 27-29.
- DAS, I., SAHOO, S., VAN WESTEN, C., STEIN, A., HACK, R. (2010): Landslide susceptibility assessment using logistic regression and its comparison with a rock mass classification system, along a road section in the northern Himalayas (India). *Geomorphology*, 114: 627-637.
- DELONCA, A., GUNZBURGER, Y., VERDEL, T. (2014): Statistical correlation between meteorological and rockfall databases. *Natural Hazards and Earth System Sciences*, 14: 1953-1964.
- DIKAU, R. (2006): Mass movement. GOUDIE, A.S. (ur.): *Encyclopedia of Geomorphology*. Taylor & Francis e-Library, 1, 644-653.
- DORREN, L.K.A. (2003): A review of rockfall mechanics and modelling approaches. *Progress in Physical Geography*, 27 (1): 69-87.
- DRAGIČEVIĆ, I. & VELIĆ, I. (2002): The Northeastern Margin of the Adriatic Carbonate Platform. *Geologia Croatica*, 55 (2): 185-232.
- ĐUROVIĆ, B., RIBIČIČ, M., MIKOŠ, M. (2005): RHMD postopek analize potencialne ogroženosti zaradi odlomne nevarnosti. *Geologija*, 48 (1): 33-51.
- FELL, R., HO, K.K.S., LACASSE, S., LEROI, E. (2005): A framework for landslide risk assessment and management. HUNGR, O., FELL, R., COUTURE, R. (ur.): *Proceedings of the International Conference on Landslide Risk Management*, 31. svibnja-3. lipnja, Vancouver - Canada, 3-25.
- FRANKLIN, J.A., WOOD, D.F., SENIOR, S.A., BLAIR, J.A., WRIGHT, J. (2013): RHON: Ontario Rockfall Hazard Rating System - Field Procedures Manual. Materials Engineering and Research Office, MERO-043.

GAJIĆ-ČAPKA, M., PERČEC-TADIĆ, M., PATARČIĆ, M. (2003): Digitalna godišnja oborinska karta Hrvatske. Hrvatski meteorološki časopis, 38: 21-33.

GOODMAN, R.E. & KIEFFER, D.S. (2000): Behavior of Rock in Slopes. Journal of Geotechnical and Geoenvironmental Engineering, 126 (8): 675-684.

GRIMANI, I., ŠUŠNJAR, M., BUKOVAC, J., MILAN, A., NIKLER, L., CRNOLATAC, I., ŠIKIĆ, D., BLAŠKOVIĆ, I. (1973): Osnovna geološka karta SFRJ 1:100.000, Tumač za list Crikvenica L33-102. Institut za geološka istraživanja, Zagreb, Savezni geološki zavod, Beograd.

GULAM, V. (2012): Erozija ogolina u flišu središnje Istre. Doktorski rad, Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet, Zagreb - Hrvatska.

HACK, R. (2002): An evaluation of slope stability classification. DINIS DA GAMA, C. & RIBEIRA E SOUSA, L. (ur.): Proceedings, ISRM EUROCK'2002, 25.-28. studenog, Funchal - Portugal, Publ. Sociedade Portuguesa de Geotecnia, 3-32.

HERAK, M., BAHUN, S., MAGDALENIĆ, A. (1969): Pozitivni i negativni utjecaji na razvoj krša u Hrvatskoj. Krš Jugoslavije, 6: 45-78.

HGI (2009): Geološka karta Republike Hrvatske 1:300.000. Hrvatski geološki institut, Zagreb - Hrvatska.

HOEK, E. (1994): Strength of rock and rock masses. ISRM News Journal, 2 (2): 4-16.

HOSMER, D.W. & LEMESHOW, S. (2000): Applied Logistic Regression. 2nd edition, John Wiley & Sons, Inc., New York - USA.

HUANG, S.L., DARROW, M.M., CALVIN, P. (2009): Unstable slope management program: Background Research and Program Inception. Final Report.

ILAKOVAC, V. (2009): Testiranje statističkih hipoteza i neke zamke. Biochemia Medica, 19 (1): 10-16.

ISO 14689-1 (2003): Geotechnical investigation and testing - Identification and classification of rock - Part 1: Identification and description. International Organization for Standardization, 1-16.

ISRM (1975): Terminology. Commission on Terminology, Symbols, and Graphic Representation.

JABOYEDOFF, M., OPPIKOFER, T., ABELLAN, A., DERRON, M.H., LOYE, A., METZGER, R., PEDRAZZINI, A. (2012): Use of LIDAR in landslide investigations: a review. *Natural Hazards*, 61: 5-28.

JAMIČIĆ, D., PRELOGOVIĆ, E., TOMLIJENović, B. (1995): Folding and deformational style in overthrust structures on Krk Island. ROSSAMANITH, H.P. (ur.): Proceedings of the 2nd International conference on The mechanics of Jointed and Faulted Rock - MJFR-2, 10.-14. travnja, Wien - Austria, 359-362.

KLEINBAUM, D.G. & KLEIN, M. (2010): Logistic Regression: A self-Learning Text. 3rd edition, Springer, New York - USA.

LATO, M., HUTCHINSON, J., DIEDERICH, M., BALL, D., HARRAP, R. (2009): Engineering monitoring of rockfall hazards along transportation corridors: using mobile terrestrial LiDAR. *Natural Hazards and Earth System Sciences*, 9: 935-946.

LEYLAND, R. & PAIGE-GREEN, P. (2011): A simple slope hazard management system for the South African primary road network. 8th International Conference on Managing Pavement Assets, ICMPO22, 15.-19. studenog, Santiago - Chile.

LIBRIĆ, L. (2014): Upravljanje rizicima kod stijenskih odrona. MAROVIĆ, I. & SUŠANJ, I. (ur.): Zajednički temelji. 2. skup mladih istraživača iz područja građevinarstva i srodnih tehničkih znanosti, 24.-26. rujna, Zbornik sažetaka, Rijeka - Hrvatska. Građevinski fakultet, Rijeka, 38-39.

LI, Z.H., HUANG, H.W., YIN, J. (2007): Risk Assessment of Rockfall Hazards on Highways. Proceedings of the 1st International Symposium on geotechnical Safety & Risk - ISGSR2007, 18.-25. listopada, Shangai - China, 687-696.

MAERZ, N.H., KASSEBAUM, T., BOYKO, K., OTOO, J. (2015): Evaluation of Rock Fall Hazards Using Lidar Technology. Journal of Civil Engineering and Architecture, 9: 80-89.

MAERZ, N.H. & YOUSSEF, A. (2004): Development of a Highway Rock Cut Rating System For Missouri Highways. Final Report, RDT 04-009, University of Missouri-Rolla.

MARINOS, P. & HOEK, E. (2000): GSI: a geologically friendly tool for rock mass strength estimation. Proceedings of the GeoEng2000 at the International conference on geotechnical and geological engineering, 20.-24. studenog, Melbourne - Australia, 1422-1446.

MAULDON, M., DRUMM, E., DUNNE, W.M., BATEMAN, V., ROSE, B., KIM, M. (2007): Rockfall Management System for Tennessee. Final Project Report, The University of Tennessee, Department of Civil and Environmental Engineering.

MCCULLAGH, P. (1980): Regression Models for Ordinal Data. Journal of the Royal Statistical Society, Series B (Methodological), 42 (2): 109-142.

MORALES, T., URIARTE, J.A., URIBE-ETXEBARRIA, G., IBARRA, V. (2005): Rockfall hazard risk evaluation system for slopes of the Basque Country (northern Spain). International symposium Geoline, 23.- 25. svibnja, Lyon - France.

NYSDOT - New York State Department of Transportation (2007): Rock slope rating procedure, Geotechnical engineering manual. Geotechnical Engineering Bureau, GEM-15, New York - USA.

NICHOL, D. (2006): Rockfall geohazard assessment and protection measures on the highway network, North Wales. IAEG, Paper number 320.

NOVOSEL, T., TUŠAR, Z., MULABDIĆ, M., GARAŠIĆ, M., KORAŽIJA, S. (1980): Ocjena stabilnosti kosina u zasjecima (usjecima) građenih od karbonatnih stijena. 5. simpozij jugoslavenskog društva za mehaniku stijena i podzemne radove, 27.-30. listopada, Zbornik radova, 1: 185-192.

PACK, R.T. & BOIE, K. (2002): Utah Rockfall Hazards Inventory - Phase I. UT 03.01, Utah State University, Department of Civil and Environmental Engineering.

PALMA, B., PARISE, M., REICHENBACH, P., GUZZETTI, F. (2012): Rockfall hazard assessment along a road in the Sorrento Peninsula, Campania, southern Italy. *Natural Hazards*, 61: 187-201.

PALMSTROM, A. (2005): Measurements of and Correlations between Block Size and Rock Quality Designation (RQD). *Tunnels and Underground Space Technology*, 20: 362-377.

PAPPALARDO, G., MINEO, S., RAPISARDA, F. (2013): Rockfall hazard assessment along a road on Peloritani Mounts (northeastern Sicily, Italy). *Natural Hazards and Earth System Sciences*, 1: 7167-7191.

PENG, C.J. & SO, T-S.H. (2002): Logistic Regression Analysis and Reporting: A Primer. *Understanding Statistics*, 1 (1): 31-70.

PEŠEVSKI, I., JOVANOVSKI, M., GUY, M., O'HARE, N. (2011): Rockfall hazard assessment for access road to dam „Sveta Petka“ using rockfall hazard rating system (RHRS). *Geologica Macedonica*, 24 (1-2): 11-20.

PFEIFFER, T. & HIGGINS, J.D. (1990): Rockfall Hazard Analysis Using the Colorado Rockfall Simulation Program. *Transportation research Record*, National Research Council, 1288: 117-126, (iz Russell et al., 2005).

PIERSON, L.A. (1991): The Rockfall Hazard Rating System. Final Report, FHWA-OR-GT-92-05, Oregon State Highway Division, Engineering Geology Group.

PIERSON, L.A. & VAN VICKLE, R. (1989): Report on the Shakedown Test of Oregon's Rockfall Hazard Rating System. Report, FHWA-OR-EG-89-01, Oregon State Highway Division.

PIERSON, L.A. & VAN VICKLE, R. (1993): Rockfall Hazard Rating System - Participants' Manual. NHI Course No. 130220, FHWA-SA-93-057, SNI International Resources, Inc.

POLLAK, D. (2007): Utjecaj trošenja karbonatnih stijenskih masa na njihova inženjerskogeološka svojstva. Doktorski rad, Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet, Zagreb - Hrvatska.

POLLAK, D., NAVRATIL, D., NOVOSEL, T. (2013): Specific aspects of engineering-geological models in Croatian karst. *Geologia Croatica*, 66 (3): 219-232.

POLLAK, D., VUIĆ, V., MITROVIĆ, G. (2005): Inženjerskogeološke značajke područja tunela "Grič". VELIĆ, I., VLAHOVIĆ, I., BIONDIĆ, R. (ur.): 3. hrvatski geološki kongres, 29. rujna - 1. listopada, Opatija - Hrvatska, Knjiga sažetaka, Hrvatski geološki institut, 231-232.

PRELOGOVIĆ, E., BLAŠKOVIĆ, I., CVIJANOVIĆ, D., SKOKO, D., ALJINOVIĆ, B. (1981): Seizmotektonske značajke vinodolskog područja. *Geološki vjesnik*, 33: 75-93.

RITCHIE, A.M. (1963): Evaluation of rockfall and its control. *Highway Research Board Record*, 17: 13-28 (iz Russell et al., 2008).

ROCSCIENCE INC. (2010): RocFall 4.0 - Risk analysis of falling rocks on steep slopes. Toronto - Canada.

ROJE-BONACCI, T., MIŠČEVIĆ, P., ŠTEVANIĆ, D. (2009): Rock-slides on road cuttings in the Dinaric karst of Croatia: processes and factors. *Environmental Geology*, 58 (2): 359-369.

RUMSEY, D. (2009): *Statistics II for Dummies*. Wiley Publishing, Inc., Indianapolis - Indiana - USA.

RUSSELL, C.P., SANTI, P., HIGGINS, J.D. (2008): Modifications and statistical analysis of the Colorado rockfall hazard rating system. Final Report, CDOT-2008-7, Colorado School of Mines.

SANTI, P.M., RUSSELL, C.P., HIGGINS, J.D., SPRIET, J.I. (2009): Modification and statistical analysis of the Colorado Rockfall Hazard Rating System. *Engineering Geology*, 104: 55–65.

SARKAR, S., KANUNGO, D.P., KUMAR, S. (2012): Rock Mass Classification and Slope Stability Assessment of Road Cut Slopes in Garhwal Himalaya, India. *Geotechnical and Geological Engineering*, 30 (4): 827-840.

SAROGLOU, H., MARINOS, V., MARINOS, P., TSIAMBAOS, G. (2012): Rockfall hazard and risk assessment: an example from high promontory at the historical site of Monemvasia, Greece. *Natural Hazards and Earth System Sciences*, 12: 1823-1836.

SAS INSTITUTE INC. (2003): SAS/STAT® Software: SAS University Edition. Cary - North Carolina - USA. URL: <http://www.sas.com>. [24.08.2015.]

SAS INSTITUTE INC. (2014): SAS/STAT® 13.2 User's Guide. SAS Institute Inc., Cary - North Carolina - USA.

SAS INSTITUTE INC. (2016): Statistics I - Introduction to ANOVA, Regression and Logistic Regression (e-course), URL: <https://support.sas.com/edu/OLTRN/ECST131/index.htm>. [13.09.2016.]

SHIRZADI, A., SARO, L., JOO, O.H., CHAPI, K. (2012): A GIS-based logistic regression model in rock-fall susceptibility mapping along a mountainous road: Salavat Abad case study, Kurdistan, Iran. *Natural Hazards*, 64: 1639-1656.

SI-QIAO, Y., SHANGQING, G., ZHUAN-YUN, Y., HUI, L. (2014): A Rating System for Road Slope Rockfall Hazards. *EJGE*: 4489-4499.

SONMEZ, H. & ULUSAY, R. (1999): Modifications to the geological strength index (GSI) and their applicability to stability of slopes. *International Journal of Rock Mechanics and Mining Sciences*, 36: 743-760.

STOKES, M.E., DAVIS, C.S., KOCH, G.G. (2012): *Categorical Data Analysis Using SAS*. 3rd edition. SAS institute Inc., Cary - North Carolina - USA.

ŠUŠNJAR, M., BUKOVAC, J., NIKLER, L., CRNOLATAC, I., MILAN, A., ŠIKIĆ, D., GRIMANI, I., VULIĆ, Ž., BLAŠKOVIĆ, I. (1970): *Osnovna geološka karta SFRJ 1:100.000, List Crikvenica L33-102*. Institut za geološka istraživanja, Zagreb, Savezni geološki zavod, Beograd.

TAHERYNIA, M.H., MOHAMMADI, M., AJALLOEIAN, R. (2014): Assessment of Slope Instability and Risk Analysis of Road Cut Slopes in Lashotor Pass, Iran. *Journal of Geological Research*, ID 763598.

TIŠLIAR, J. (1994): *Sedimentne stijene*. Školska knjiga, Zagreb - Hrvatska.

VANDEWATER, C.J., DUNNE, W.M., MAULDON, M., DRUMM, E.C., BATEMAN, V. (2005): Classifying and Assessing the Geologic Contribution to Rockfall Hazard. *Environmental & Engineering Geoscience*, XI (2): 141-154.

VARNES, D.J. (1978): Slope movement types and processes. SCHUSTER, R.L. & KRIZEK, R.J. (ur.): *Landslides: Analysis and Control*. TRB Special Report, 176, 11-33.

VELIĆ, I. & SOKAČ, B. (1982): Osnovna geološka karta SFRJ 1:100.000, List Ogulin L33-103. Geološki zavod, Zagreb, Savezni geološki institut, Beograd.

Velić, I., Sokač, B., Šćavničar, B. (1982): Osnovna geološka karta SFRJ 1:100.000, Tumač za list Ogulin L33-103. Geološki zavod, Zagreb, Savezni geološki institut, Beograd.

VELIĆ, I., VLAHOVIĆ, I., MATIČEC, D. (2002): Depositional sequences and paleogeography of the Adriatic carbonate platform. *Mem. Soc. Geol. It.*, 57: 141-151.

VLAHOVIĆ, I., TIŠLIJAR, J., VELIĆ, I., MATIČEC, D. (2002): The Karst Dinarides are Composed of Relics of a Single Mesozoic Platform: Facts and Consequences. *Geologia Croatica*, 55 (2): 171-183.

VLAHOVIĆ, I., TIŠLIJAR, J., VELIĆ, I., MATIČEC, D. (2005): Evolution of the Adriatic Carbonate Platform: Palaeogeography, main events and depositional dynamics. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 220: 333-360.

WALTHAM, A.C. & FOOKES, P.G. (2003): Engineering classification of karst ground conditions. *Quarterly Journal of Engineering Geology and Hydrogeology*, 36: 101-118.

WP/WLI - INTERNATIONAL GEOTECHNICAL SOCIETIES' UNESCO WORKING PARTY FOR WORLD LANDSLIDE INVENTORY (1993): Multilingual landslide glossary, BiTech Publisher Ltd., Richmond - Virginia - USA.

WYLLIE, D.C. (1987): Rock slope inventory system. *Proceedings, Federal Highway Administration Rockfall Mitigation Seminar, FHWA, Portland - Oregon - USA*.

WYLLIE, D.C. & MAH, C.W. (2005): *Rock slope engineering: civil and mining*. 4th edition. Taylor & Francis e-Library.

YOUSSEF, A.M. & MAERZ, N.H. (2009): Slope Stability Hazard Assessment and Mitigation Methodology Along Eastern Desert Aswan-Cairo Highway, Egypt. *Journal of King Abdulaziz University Earth Sciences*, 20 (2): 161-179.

YOUSSEF, A.M. & MAERZ, N.H. (2012): Development, justification and verification of a rock fall hazard rating system. *Bulletin of Engineering Geology and the Environment*, 71: 171-186.

YOUSSEF, A.M., MAERZ, N.H., AL-OTAIBI, A.A. (2012): Stability of Rock Slopes along Raidah Escarpment Road, Asir Area, Kingdom of Saudi Arabia. *Journal of Geography and Geology*, 4 (2): 48-70.

YOUSSEF, A.M. , PRADHAN, B., GABER, A.F.D., BUCHROITHNER, M.F. (2009): Geomorphological hazard analysis along the Egyptian Red Sea coast between Safaga and Quseir. *Natural Hazards and Earth System Sciences*, 9: 751-766.

ZANINOVIĆ, K., GAJIĆ-ČAPKA, M., PERČEC TADIĆ, M., VUČETIĆ, M., MILKOVIĆ, J., BAJIĆ, A., CINDRIĆ, K., CVITAN, L., KATUŠIN, Z., KAUČIĆ, D., LIKSO, T., LONČAR, E., LONČAR, Ž., MIHAJLOVIĆ, D., PANDŽIĆ, K., PATARČIĆ, M., SRNEC, L., VUČETIĆ, V. (2008): *Klimatski atlas Hrvatske 1961-1990, 1971-2000*. Državni hidrometeorološki zavod, Zagreb - Hrvatska.

ZANINOVIĆ, K., SRNEC, L., PERČEC TADIĆ, M. (2004): Digitalna godišnja temperaturna karta Hrvatske. *Hrvatski meteorološki časopis*, 39: 51-58.

Iris Bostjančić rođena je 28. travnja 1980. godine u Rijeci. Osnovnu školu pohađa u Matuljima, a srednjoškolsko obrazovanje završava u Pazinskom kolegiju – klasičnoj gimnaziji. U Zagrebu, 1998. godine, upisuje studij geologije na Rudarsko-geološko-naftnom fakultetu. Pod mentorstvom dr.sc. Brune Tomljenovića 2006. godine brani diplomski rad pod naslovom „Seizmotektonska aktivnost u zoni rasjeda Ilirska Bistrica-Vinodol-Senj“. Od završetka studija do 2009. zaposlena je u Agenciji za zaštitu okoliša, gdje radi kao stručni suradnik. 2009. godine zapošljava se kao znanstveni novak na projekt Osnovne inženjerskogeološke karte Republike Hrvatske, u Zavodu za hidrogeologiju i inženjersku geologiju Hrvatskog geološkog instituta. Poslijediplomski doktorski studij na Rudarsko-geološko-naftnom fakultetu, smjer Geološko inženjerstvo, upisuje 2010. godine.

Znanstveni i stručni interesi vezani su joj za inženjersku geologiju, ponajviše za egzogenetske procese i geološke hazarde vezane za karbonatnu stijensku masu.

Članica je Hrvatskog geološkog društva, Hrvatskog geotehničkog društva, Međunarodnog društva za inženjersku geologiju (International Association for Engineering Geology and the Environment), te Međunarodnog društva za mehaniku stijena (International Society for Rock Mechanics).

Popis objavljenih radova

Znanstveni radovi u zbornicima:

BOSTJANČIĆ, I., POLLAK, D., PODOLSZKI, L., GULAM V. (2011): The geological setting of the sinkholes in bare Croatian karst. LAVEROV, N.P., OSIPOV, V.I. (eds.): Environmental Geosciences and Engineering Survey for Territory Protection and Population Safety. Abstract to Proceedings of the International conference EngeoPro-2011, 6.-8. rujna, Moscow - Russia, 60-61.

BOSTJANČIĆ, I., GULAM, V., PODOLSZKI, L., BURIĆ, H. (2010): Razrada gustoća ponikava krških područja u sklopu izrade OIGK. HORVAT, M. (ur.): 4. hrvatski geološki kongres, 14.-15. listopada, Šibenik - Hrvatska. Knjiga sažetaka, Hrvatski geološki institut, Zagreb, 322-323.

TOMLJENović, B., HERAK, M., HERAK, D., KRALJ, K., PRELOGOVIĆ, E., BOSTJANČIĆ, I., MATOŠ, B. (2009): Active tectonics, seismicity and seismogenic sources of the Adriatic coastal and offshore region of Croatia. SLEJKO, D., REBEZ, A. (eds.): 28 Convegno Nazionale - Riassunti Estesi delle Comunicazioni, 16.-19. studenoga, Trieste - Italy. Stella Arti Grafice, Trieste, 133-136.

Kontakt:

Hrvatski geološki institut

Zavod za hidrogeologiju i inženjersku geologiju

Sachsova 2, 10000 Zagreb, Hrvatska

Tel: +385 1 6160 701


e-mail: iris.bostjancic@hgi-cgs.hr

PRILOG 1.

Frekvencije definiranih klasa svih klasifikacijskih parametara i izmjerene vrijednosti pojedinih parametara za sve segmente istraživanih kosina (366).


Značajke pojedinog tipa odrona odnose se na najkritičniji tip odrona (RSKS - ravninski i klinasti slom (74), DT - diferencijalno trošenje (6), O - osipavanje (184)).

Izraženost moguće pojave odrona (Izraženost)



I: < 10 %; II: 10-20 %; III: 20-30 %; IV: > 30 %


Maksimalna veličina bloka



(a) I: < 0,2 dm³; II: 0,2-10 dm³; III: 10-200 dm³; IV: > 200 dm³

(b) I: < 20 cm; II: 20-60 cm; III: 60-200 cm; IV: > 200 cm


Dominantna veličina bloka



(a) I: $< 0,2 \text{ dm}^3$; II: $0,2\text{-}10 \text{ dm}^3$; III: $10\text{-}200 \text{ dm}^3$; IV: $> 200 \text{ dm}^3$


(b) I: $< 20 \text{ cm}$; II: $20\text{-}60 \text{ cm}$; III: $60\text{-}200 \text{ cm}$; IV: $> 200 \text{ cm}$

RSKS - Nagib diskontinuiteta




I: $< 20^\circ$; II: $20\text{-}40^\circ$; III: $40\text{-}60^\circ$; IV: $> 60^\circ$

RSKS - Hrapavost diskontinuiteta




I: valovito-hrapavo; II: valovito-glatko; III: ravno-hrapavo; IV: ravno-glatko

RSKS - Zijev diskontinuiteta




I: zatvoreni; II: mm dimenzija; III: cm dimenzija; IV: dm dimenzija

RSKS - Ispuna diskontinuiteta




I: nema; II: prevlaka (< 1 mm); III: tvrda (> 1 mm); IV: meka (> 1 mm)

DT - Nekompetentni slojevi




I: < 2 sloja, < 15 cm; II: > 2 sloja, < 15 cm; III: < 2 sloja, > 15 cm; IV: > 2 sloja, > 15 cm

O - Oblik bloka




I: pločast; II: nepravilan; III: ekvidimenzionalan; IV: zaobljen

Okršenost




I: nema; II: rijetko; III: srednje; IV: učestalo

Voda na kosini (Voda)




I: suho; II: vlažno; III: kapanje; IV: tečenje

Broj tipova odrona




I: 1; II: 2; III: 3; IV: > 3

Srednja godišnja količina oborina i srednja godišnja temperatura (Oborine i temperatura)




I: < 2000 mm, > 9 °C; II: < 2000 mm, < 9 °C; III: > 2000 mm, > 9 °C; IV: > 2000 mm, < 9 °C

Visina potencijalnog odrona (Visina)




Visina (a)




I: < 6 m; II: 6-11 m; III: 11-16 m; IV: > 16 m

Nagib kosine (Nagib)




Nagib (a)




I: < 60°; II: 60-70°; III: 70-80°; IV: > 80°

Nagib (b)




I: 0-25°, 87-90°; II: 25-45°, 70-82°; III: 55-70°; IV: 45-55°, 82-87°

Udaljenost kosine




Zaštitni jarak




I: nema jarka; II: ima jarka

Udaljenost kosine i zaštitni jarak (Udaljenost)



I: > 5 m; II: 3-5 m, ima jarka; III: 3-5 m, nema jarka; IV: < 3 m

Razvedenost kosine (Razvedenost)



I: blage kosine ili kosine bez varijacija; II: male varijacije (< 0,6 m); III: srednje varijacije (0,6 - 1,8 m); IV: značajne varijacije (> 1,8 m)