Metodologija izrade karata klizišta korištenjem digitalnoga modela terena visoke rezolucije u podsljemenskoj zoni Grada Zagreba

Bernat Gazibara, Sanja

Doctoral thesis / Disertacija

2019

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:169:398183

Rights / Prava: Attribution-NonCommercial-NoDerivatives 4.0 International/Imenovanje-Nekomercijalno-Bez prerada 4.0 međunarodna

Download date / Datum preuzimanja: **2024-04-18**

Repository / Repozitorij:

Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb

Sveučilište u Zagrebu

Rudarsko-geološko-naftni fakultet

Sanja Bernat Gazibara

METODOLOGIJA IZRADE KARATA KLIZIŠTA KORIŠTENJEM DIGITALNOGA MODELA TERENA VISOKE REZOLUCIJE U PODSLJEMENSKOJ ZONI GRADA ZAGREBA

DOKTORSKI RAD

Zagreb, 2019.

Sveučilište u Zagrebu

Rudarsko-geološko-naftni fakultet

Sanja Bernat Gazibara

METODOLOGIJA IZRADE KARATA KLIZIŠTA KORIŠTENJEM DIGITALNOGA MODELA TERENA VISOKE REZOLUCIJE U PODSLJEMENSKOJ ZONI GRADA ZAGREBA

DOKTORSKI RAD

Mentor:
Prof. dr. sc. Snježana Mihalić Arbanas

Zagreb, 2019.

University of Zagreb

Faculty of Mining, Geology and Petroleum Engineering

Sanja Bernat Gazibara

METHODOLOGY FOR LANDSLIDE MAPPING USING HIGH RESOLUTION DIGITAL ELEVATION MODEL IN THE PODSLJEME AREA (CITY OF ZAGREB)

DOCTORAL DISSERTATION

Supervisor:
Prof. Snježana Mihalić Arbanas, PhD

Zagreb, 2019.

ZAHVALA

Zahvaljujem mentorici prof.dr.sc. Snježani Mihalić Arbanas koja mi je kao jedna od voditeljica hrvatsko-japanskog projekta "Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje posljedica klizanja i poplava u Hrvatskoj" omogućila ovo doktorsko istraživanje. Bez njezinog rada i zalaganja ne bi bilo podataka korištenih u ovom istraživanju. Snježana, hvala na prilici koju si mi pružila, povjerenju, mentorstvu, prijateljstvu i svemu što si me do sada naučila. Hvala ti što si uvijek vjerovala da mogu sve što zamislim.

Zahvaljujem članovima povjerenstva dr.sc. Marku Komcu, doc.dr.sc. Martinu Krkaču i doc.dr.sc. Anji Vrbaški na korekcijama i sugestijama prilikom recenzije doktorskog rada koje su uvelike doprinijele njegovoj kvaliteti.

Hvala mojim kolegama i prijateljima, Martinu i Marinu, za brojne diskusije, sugestije, savjete i jutarnje kave u kantini koje su znatno doprinijele ovom radu. Hvala vam što ste uvijek bili uz mene i sva moja raspoloženja.

Hvala mojoj Petri na prijateljstvu i beskonačno dugim telefonskim razgovorima. Da nije bilo tebe nikada ne bih toliko raspravljala, razmišljala i kontemplirala o klizištima.

Veliko hvala mojoj obitelji na neupitnoj potpori i prijateljima na pozitivnoj energiji koju su mi pružili za vrijeme izrade doktorskog rada. Mama i tata, zaista cijenim sve što ste napravili za mene i vama posvećujem ovaj rad.

I na kraju, najveće hvala mom suprugu, na beskrajnom strpljenju, razumijevanju, bezuvjetnoj ljubavi i potpori koju si mi pružio tijekom svih ovih godina. Gogi, hvala ti što me svaki dan inspiriraš i motiviraš da budem najbolja verzija sebe.

SAŽETAK

U okviru disertacije prikazani su rezultati doktorskog istraživanja čija svrha je bila uspostavljanje metodologije za izradu karata klizišta primjenom tehnologije laserskog skeniranja (LiDAR). Osnovna prednost LiDAR-skih podataka u odnosu na ostale metode daljinskih istraživanja je izrada digitalnog modela terena (DMT) bez vegetacije i vrlo visoke rezolucije (<2 m) koji omogućava identifikaciju i kartiranje malih i plitkih klizišta na područjima pod gustom vegetacijom, kakvo je područje podsljemenske zone u Gradu Zagrebu. Za područje (ukupne površine 180 km^2) provedeno je lasersko skeniranje iz zraka u prosincu 2013. godine, nakon događaja masovnog pokretanja klizišta uslijed niza ekstremnih oborinskih događaja, čime je omogućena izrada DMT-a s reprezentativnim brojem (re)aktiviranih klizišta. Pojedinačni rezultati doktorskog istraživanja provedenog na pilot području površine 21 km^2, postignuti u okviru razvoja metodologije za izradu karata klizišta korištenjem LiDAR tehnologije su: digitalni modeli terena bez vegetacije rezolucije 0,3x0,3 m i 1x1 m optimalni za vizualno i automatizirano kartiranje klizišta; detaljan i potpun inventar klizišta izrađen vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a; definirane granične vrijednosti morfometrijskih karata izvedenih iz LiDAR DMT-a koje ukazuju na nepravilnu morfologiju klizišta te omogućavaju automatizirano kartiranje klizišta; pikselno orijentiran model za automatizirano kartiranje klizišta na temelju morfometrijskih parametara izvedenih iz LiDAR DMT-a; tri karte podložnosti na klizanje dobivene analizom preduvjeta klizanja i karata inventara klizišta izrađenih na temelju vizualne interpretacije i automatiziranog kartiranja LiDAR DMT-a; i doprinos poznavanju prostorne raspodjele klizišta te preduvjeta koji utječu na pojavu klizišta u podsljemenskoj zoni Grada Zagreba. Najvažnije nove spoznaje o značajkama klizišta na istraživanom području se odnose na pouzdane podatke o karakterističnoj veličini klizišta (u rasponu od 43 do 8.064 m^2, najučestalija površina klizišta 400 m^2), broju i gustoći klizišta (702 kartirana klizišta, prosječne gustoće 33,3 klizišta/km^2) i prostornoj raspodjeli klizišta. S obzirom na visoku točnost izrađenih karata klizišta, zaključeno je da metodologija razvijena za automatizirano kartiranje klizišta na temelju morfometrijskih parametara omogućava izradu pouzdanih prognostičkih karata hazarda klizanja, na terenima istih ili sličnih inženjerskogeoloških uvjeta.

Ključne riječi: klizište, LiDAR, vizualna interpretacija, digitalni model terena, model za automatizirano kartiranje klizišta, inventar klizišta, karta podložnosti na klizanje, podsljemenska zona Grada Zagreba

ABSTRACT

In the framework of the doctoral thesis, methodology for landslide mapping using LiDAR (Light Detection and Ranging) technology was established, encompassing inventory mapping and derivation of prognostic susceptibility maps. Airborne laser scanning (ALS) allows generation of bare-earth digital terrain model (DTM) optimal for identification and mapping of small and shallow landslides under dense vegetation. Acquisition of the LiDAR data for the Podsljeme area (180 km^2) in the City of Zagreb was performed in December 2013, following the extreme precipitation period in winter 2012/2013 that caused multiple occurrences of regional landslides (MORLE). The first result of the doctoral research is high-resolution DTM optimal for mapping of targeted landslides, generated from a point cloud based on suitable interpolation method and spatial resolution (0,3x0,3 m and 1x1 m). A series of topographic derivative datasets were generated from the LiDAR DTM for landslide mapping that was performed for the pilot area of 21 km^2, which represents 12 % of the hilly Podsljeme area in the Zagreb City. Landslide inventory maps for the pilot area were prepared using two different methods: visual identification of landslides on LiDAR DTM derivatives and automated mapping based on morphometric characteristics of landslide areas compared to non-landslide areas. The second phase of research involved visual interpretation of three LiDAR DTM derivative maps (hillshade, slope and contours) with a spatial resolution of 0,3 x 0,3 m which resulted with inventory map containing 702 landslide polygons in the pilot area (21 km^2). Seventy-five percent of the landslides in inventory have an area between 150 and 2000 m^2 while the area of the smallest identified landslide is 43 m^2. Around 10 % of visually identified landslides were additionally checked and evaluated in the field, while the whole inventory map for the pilot area was compared with conventionally prepared historical landslide inventory maps. A comparison of landslide inventories and the frequency–area distribution of visually interpreted landslides proves that LiDAR DTM enables preparation of detailed and complete landslide inventory maps (after MORLE) in the Podsljeme area. In the third phase of research, the quantitative geomorphological analysis on visually interpreted landslides was performed to define the topographic signature of landslide morphology using statistical parameters. In soil-covered areas, such as the Podsljeme area, landslides are generally characterized by a different morphometric values, i.e., higher surface roughness compared to the surrounding landslide-free areas. Based on defined morphological parameters which indicate hummocky landslide morphology in the test area (10.5 km^2), the pixel-based model for landslide mapping was developed. Verification showed that landslides and unstable slopes can be predicted with an

accuracy of 70 % and it can be concluded that developed model allows recognition and characterization of morphologic properties of forested small and shallow landslides on soil-covered hillslopes. In the last phase of the study, visually and automatically prepared landslide inventories were used to perform the landslide susceptibility maps. Landslide causal factors analysis and susceptibility assessment was done using bivariate statistical method and comparison of three landslide susceptibility maps were performed due to the area under the receiver operating characteristic (ROC) curves. The final landslide susceptibility map, using automatically prepared landslide inventory as input, resulted with high prediction rate (AUC=83 %), due to validation with visually interpreted landslides. It can be concluded that the model developed for automated landslide mapping is a useful tool for fast and cost-efficient production of reliable landslide susceptibility maps. Therefore, the methodology established for landslide mapping using LiDAR technology has practical implication in landslide risk reduction.

Keywords: landslides, LiDAR, visual landslide mapping based on LiDAR DTM, automated landslide mapping based on LiDAR DEM, landslide inventory maps, landslide susceptibility mapping, Podsljeme area, City of Zagreb, Croatia

SADRŽAJ

1 UVOD 1

1.1 Svrha i ciljevi istraživanja 4

1.2 Struktura disertacije 7

2 TEORIJSKE OSNOVE 10

2.1 Pojave klizišta i inventari klizišta 10

2.2 Pregled metoda istraživanja i kartiranja inventara klizišta 16

2.3 Lasersko skeniranje iz zraka i izrada LiDAR DMT-a 20

2.4 Identifikacija i kartiranje klizišta vizualnom interpretacijom LiDAR DMT-a 25

2.5 Automatizirano kartiranje klizišta na temelju morfometrijskih parametara izvedenih iz LiDAR DMT-a 28

2.6 Karte podložnosti na klizanje 32

3 PODRUČJE ISTRAŽIVANJA 36

3.1 Geomorfološke značajke istraživanog područja 38

3.2 Geološka građa istraživanog područja 42

3.3 Hidrološke značajke istraživanog područja 49

3.4 Meteorološke značajke istraživanog područja 51

3.5 Korištenje zemljišta na istraživanom području 54

3.6 Aktivni geomorfološki procesi 56

3.7 Postojeće karte klizišta na području podsljemenske zone Grada Zagreba 59

3.7.1 Karta klizišta objavljena 1967. godine 59

3.7.2 Karta klizišta objavljena 1979. godine 60

3.7.3 Karta klizišta objavljena 2007. godine 62

3.7.4 Karte klizišta objavljena 2014. godine 63

4 METODE ISTRAŽIVANJA 64

4.1 Metode interpolacije i prostorna rezolucija LiDAR DMT-a 64

4.2 Vizualna identifikacija i kartiranje klizišta na LiDAR DMT-u 70

4.3 Metode usporedbe karata inventara klizišta 74

4.4 Automatizirano kartiranje klizišta primjenom LiDAR DMT-a 75

4.5 Izrada karte podložnosti na klizanje primjenom bivarijantne statističke metode 78

5 ULAZNI PODACI 84

5.1 Gustoća oblaka točaka dobivenog laserskim skeniranjem iz zraka 85

5.2 Izrada LiDAR DMT-a visoke rezolucije 86

5.3 Morfometrijske karte izvedene iz LiDAR DMT-a za vizualnu identifikaciju i kartiranje klizišta 89

5.3.1 Karta osjenčanog reljefa 89

5.3.2 Karta nagiba terena 90

5.3.3 Karta slojnica 90
5.4 Morfometrijske karte izvedene iz LiDAR DMT-a za automatizirano kartiranje klizišta 91
5.4.1 Karte nadmorskih visina 93
5.4.2 Karte osjenčanosti terena 95
5.4.3 Karte nagiba terena 97
5.4.4 Karte slojnica 102
5.4.5 Karte zakrivljenosti terena 102
5.4.6 Karte hrapavosti terena 110
5.4.7 Karte vlažnosti terena 117
5.4.8 Karta raščlanjenosti terena 118
6 INVENTAR KLIZIŠTA DOBIVEN VIZUALNOM INTERPRETACIJOM LiDAR DMT-a .. 121
6.1 Značajke inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a 121
6.2 Terenska provjera inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a 126
6.3 Usporedba inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a s postojećim inventarima klizišta 130
6.3.1 Analiza statističkih parametara inventara i učestalosti klizišta 130
6.3.2 Analiza geografskog položaja klizišta 133
6.3.3 Analiza gustoće klizišta 135
7 MODEL ZA AUTOMATIZIRANO KARTIRANJE KLIZIŠTA NA TEMELJU LiDAR DMT-a 137
7.1 Analiza morfometrijskih karata i odabir predikcijskih karata 139
7.1.1 Morfometrijske karte nadmorskih visina 140
7.1.2 Morfometrijske karte osjenčanosti terena 142
7.1.3 Morfometrijske karte nagiba terena 145
7.1.4 Morfometrijske karte gustoće slojnica 151
7.1.5 Morfometrijske karte zakrivljenosti terena 152
7.1.6 Morfometrijske karte hrapavosti terena 160
7.1.7 Morfometrijske karte vlažnosti terena 165
7.1.8 Morfometrijska karta raščlanjenosti terena 166
7.2 Zbrajanje predikcijskih karata i izrada konačne karte inventara klizišta 168
7.3 Verifikacija modela za automatizirano kartiranje klizišta 176
8 VALIDACIJA MODELA ZA AUTOMATIZIRANO KARTIRANJE KLIZIŠTA 182
8.1 Analiza relativnog utjecaja preduvjeta klizanja 184
8.1.1 Geomorfološki preduvjeti klizanja 185
8.1.2 Geološki preduvjeti klizanja 189
8.1.3 Hidrološki preduvjeti klizanja 194
8.1.4 Antropogeni preduvjeti klizanja 196

8.2 Karte podložnosti na klizanje 199
9 DISKUSIJA 211
9.1 Izrada optimalnog LiDAR DMT-a za kartiranje klizišta i priprema morfometrijskih karata za kartiranje klizišta 211
9.2 Vizualna interpretacija klizišta na LiDAR DMT-u 215
9.3 Model za automatizirano kartiranje klizišta na temelju morfometrijskih parametara 219
9.4 Primjena karata inventara klizišta dobivenih vizualnim interpretacijom i automatiziranim kartiranjem LiDAR DMT-a za izradu karata podložnosti na klizanje 226
10 ZAKLJUČAK 231
LITERATURA
ŽIVOTOPIS AUTORA
Popis objavljenih radova

POPIS SLIKA

Slika 2.1 Terminologija vezana za opis klizišta (WP/WLI, 1993b): (a) dijelovi klizišta; (b) dimenzije klizišta. 12
Slika 2.2 Uzročnici (faktori) klizanja (modificirano prema Popescu, 2002). 13
Slika 2.3 Prikaz oblaka točaka dobivenog laserskim skeniranjem kosine iznad grada Omiša.. 21
Slika 2.4 Osnovne komponente ALS sustava i princip određivanja prostornih koordinata (modificirano prema Gajski, 2007). 23
Slika 2.5 Dijagram toka izrade DMT-a iz podataka dobivenih laserskim skeniranjem iz zraka. 24
Slika 2.6 Primjeri morfometrijskih karata korištenih za izradu inventara klizišta (Amundsen et al., 2010): (a) karta osjenčanosti reljefa; (b) karta nagiba terena; (c); karta zakrivljenosti; (d) karta slojnica ekvidistance 2 ft=0,61 cm. 27
Slika 2.7 Primjeri izraženosti morfologije klizišta na karti osjenčanosti terena: (a) jasno izražena morfologija klizišta (Slaughter et al., 2017); (b) slabo izražena morfologija klizišta (Crawford et al., 2014)..... 27
Slika 2.8 Metode procjene podložnosti na klizanje (prema Corominas et al., 2013)..... 34
Slika 3.1 Geografski položaj istraživanog područja na DMT-u rezolucije 20x20 m..... 37
Slika 3.2 Geografski prikaz pilot područja (21 km^2) na digitalnom ortofoto snimku iz 2011. godine (DGU-Geoportal, 2018). 38
Slika 3.3 Skica morfostrukturne građe istraživanog područja na poprečnom presjeku orijentacije SZ-JI (prema Bognar, 1994)..... 40
Slika 3.4 Prikaz područja istraživanja i pilot područja u Gradu Zagrebu na DMT-u: a) raspodjela nadmorskih visina; (b) raspodjela nagiba terena. 40
Slika 3.5 Geomorfološke značajke šireg istraživanog područja u Gradu Zagrebu s obzirom na : (a) hipsometrijske zone; (b) vertikalnu raščlanjenost reljefa. 42
Slika 3.6 Litostratigrafske značajke istraživanog područja i prikaz prostorne zastupljenosti pojedinih naslaga prema OGK M 1:100.000, list Zagreb (Šikić et al., 1972) i list Ivanić-Grad (Basch, 1976). .. 44
Slika 3.7 Hidrografska mreža na području istraživanja i pilot području. Stalni i povremeni vodotoci digitalizirani su s Hrvatske osnovne karte M 1:5.000. 50
Slika 3.8 Drenažna mreža i slivovi u podsljemenskoj zoni Grada Zagreba (180 km^2) i na pilot području (21 km^2) izdvojeni preliminarnom analizom LiDAR DMT-a..... 51
Slika 3.9 Srednje mjesečne oborine na postaji Zagreb-Grič za razdoblje 1862.-2018. godine. 52
Slika 3.10 Mjesečni oborinski percentili za sjevernu Hrvatsku, određeni na temelju vremenskog razdoblja 1961.-1991. godina za (DHMZ, 2013): a) siječanj 2013. godine; b) veljaču 2013. godine; c) ožujak 2013. godine. 53
Slika 3.11 Podaci o dnevnoj oborini, kumulativnoj oborini i broju klizišta aktiviranih tijekom siječnja, veljače i ožujka 2013. godine u podsljemenskoj zoni Grada Zagreba (Bernat et al., 2014b). 54
Slika 3.12 Analiza oborina na meteorološkoj postaji Zagreb-Grič: (a) mjesečne oborine; (b) tromjesečne kumulativne oborine. Plavom bojom su prikazane prosječne oborine za razdoblje 1862.-2018. godine, a crvenom bojom su prikazane oborine iz 2013. godine (Bernat et al., 2014b). 54
Slika 3.13 Tromjesečne kumulativne oborine za ožujak za razdoblje 1862.-2013. godina (Bernat et al., 2014b)..... 54
Slika 3.14 Stvarno korištenje zemljišta i izgrađenost istraživanog područja i pilot područja (Gradski ured za strategijsko planiranje i razvoj Grada, 2011)..... 56
Slika 3.15 Zone inženjerskogeoloških uvjeta prema Jurak et al. (2008). 58
Slika 3.16 Isječak karata klizišta iz studije Inženjerska geologija Zagreb sjever i jug (Šikić, 1967): (a) inženjerskogeološka karta s prikazom klizišta, zona nestabilnosti i erozije, inženjerskogeoloških jedinica izdvojenih s obzirom na litološke značajke stijena i tala i zoniranje područja s obzirom na nagib terena; (b) karta podložnosti na klizanje sa zonama i granicama klizišta..... 61

Slika 3.17 Isječak karata klizišta iz studije „Litološka obrada i kategorizacija terena prema stabilnosti tla obronaka Medvednice na području grada Zagreba“ (Polak et al., 1979): (a) litološka karta s prikazom klizišta i drugih aktivnih geomorfoloških procesa; (b) karta zoniranja terena prema podložnosti klizanju (točke - II. kategorija, uvjetno stabilne padine; vertikalne linije – III. kategorija, uvjetno nestabilne padine). 62
Slika 3.18 Isječak „Detaljne inženjerskogeološke karte Podsljemenske urbanizirane zone“ originalnog mjerila 1:5000 (Miklin et al., 2007). 63
Slika 3.19 Sintezna karta procijenjene relativne opasnosti od klizišta prema stereomodelima iz 1964. i 1998. godine za područje istraživanja na južnim obroncima Medvednice (Podolszki, 2014). 64
Slika 4.1 Primjer interpolacije oblaka točaka primjenom metode prirodnih susjeda: (a)Voronijevi poligoni; (b) Deulaunayeva triangulacija; (c) središte Deulaunayevog trokuta; (d) definiranje novog poligona primjenom Voronoijeve metode; (e) lokalne koordinate; (f) ponderiranje lokalnih koordinata. 67
Slika 4.2 Primjer klizišta identificiranih i kartiranih na izvedenim morfometrijskih kartama: (a) prozirna karta nagiba na karti osjenčanog reljefa sa slojnicama ekvidistancije 1m; (b) karta osjenčanosti terena; (c) karta nagiba terena; (d) karta slojnica ekvidistancije 1 m. 71
Slika 4.3 Primjer vidljivosti klizišta na DOF snimku iz 2012. godine. 72
Slika 4.4 Procjena pouzdanosti identifikacije klizišta: (a) pouzdano identificirano klizište; (b) nepouzdano identificirana (pretpostavljena) klizišta. 73
Slika 4.5 Procjena preciznosti kartiranja klizišta: (a) primjer visoke preciznosti; (b) primjer srednje preciznosti; (c) primjer niske preciznosti. 74
Slika 4.6 Shematski prikaz raspodjele površina klizišta: (a) primjer potpunog inventara klizišta; (b) primjer nepotpunog inventara klizišta. 75
Slika 4.7 Primjer učestalosti vrijednosti izvedene morfometrijske karte na područjima zahvaćenim klizanjem (crvena linija) i područjima bez klizišta (zelena linija). 78
Slika 4.8 Primjer određivanja vjerojatnosti *a posteriori* primjenom WoE modela. 81
Slika 4.9 Pojednostavljeni dijagram toka izrade karte podložnosti na klizanje primjenom bivarijantne statističke metode (prema Van Westen et al., 2002). 82
Slika 5.1 Pokrivenost podsljemenske zone Grada Zagreba (180 km^2) s LAS podacima (crni poligoni) i bez LAS podataka (sivo obojani poligoni) te položaj pilot područja površine 21 km^2 (crveni poligon). 85
Slika 5.2 Oblak točaka (točke klasificirane kao klasa 2) dobiven laserskim skeniranjem u prosincu 2013. godine, prikazan na digitalnom ortofoto snimku. 86
Slika 5.3 Prostorna rezolucija DMT-a na primjeru klizišta u ulici Vrhovec dimenzija 50x35 m: a) granica klizišta na digitalnom ortofoto snimku iz 2011. godine; b) DMT rezolucije 2 m; c) DMT rezolucije 1 m; d) DMT rezolucije 0,5 m; e) DMT rezolucije 0,3 m; f) DMT rezolucije 0,15 m. 88
Slika 5.4 Usporedba LiDAR DMT-a rezolucije 0,3x0,3 m dobivenih različitim metodama interpolacije: (a) metoda inverznih udaljenosti (alat *IDW*); (b) metoda ANUDEM – (alat *Topo to Raster*); (c) metoda prirodnih susjeda (alat *Natural Neighbor*); (d) kriginig metoda (alat *Kriging*)..... 89
Slika 5.5 Karta osjenčanosti terena iluminacije 315°/45° dijela pilot područja u podsljemenskoj zoni Grada Zagreba. 90
Slika 5.6 Karta nagiba terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba. 91
Slika 5.7 Karta slojnica ekvidistancije 1 m dijela pilot područja u podsljemenskoj zoni Grada Zagreba. 92
Slika 5.8 Položaj objekata i prometnica na pilot području u podsljemenskoj zoni Grada Zagreba. Na uvećanom detalju prikazan je primjer položaja klizišta u odnosu na zone širine 1, 3 i 5 m od građevina i prometnica. 93
Slika 5.9 Primjer morfometrijske karte raspona nadmorskih visina izvedene primjenom žarišne statistike iz LiDAR DMT-a dijela pilot područja u podsljemenskoj zoni Grada Zagreba. 95
Slika 5.10 Primjer morfometrijske karte standardne devijacije nadmorskih visina izvedene primjenom žarišne statistike iz LiDAR DMT-a dijela pilot područja u podsljemenskoj zoni Grada Zagreba. 95

Slika 5.11 Morfometrijske karte osjenčanosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta raspona osjenčanosti terena dobivena kružnim prozorom radijusa 3 m; (b) karta standardne devijacije osjenčanosti terena dobivena kvadratnim prozorom dimenzija 3x3 m. 97
Slika 5.12 Morfometrijske karte nagiba terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta raspona nagiba terena dobivena kvadratnim prozorom dimenzija 3x3 m; (b) karta standardne devijacije nagiba terena dobivena kružnim prozorom radijusa 3 m. 99
Slika 5.13 Morfometrijske karte nagiba terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta relativnog položaja na padini dobivena kvadratnim prozorom dimenzija 3x3 m; (b) karta druge derivacije nagiba terena. 101
Slika 5.14 Morfometrijske karte indeksa položaja padine dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta položaja izvedena metodom *COS*; (b) karta položaja izvedena metodom *TRASP*. 102
Slika 5.15 Morfometrijska karta gustoće slojnica dijela pilot područja u podsljemenskoj zoni Grada Zagreba dobivena kružnim prozorom radijusa 3 m 103
Slika 5.16 Morfometrijska karta zakrivljenosti dijela pilot područja u podsljemenskoj zoni Grada Zagreba dobivena kvadratnim prozorom veličine 3x3 m. 105
Slika 5.17 Morfometrijske karte zakrivljenosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta raspona zakrivljenosti terena dobivena kružnim prozorom radijusa 5 m; (b) karta standardne devijacije nagiba zakrivljenosti dobivena kvadratnim prozorom dimenzija 3x3 m. 106
Slika 5.18 Morfometrijske karte zakrivljenosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) planarna zakrivljenost terena; (b) profilna zakrivljenost terena. 108
Slika 5.19 Morfometrijske karte planarne zakrivljenosti dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) raspon planarne zakrivljenosti dobivene kružnim prozorom radijusa 5 m; (b) standardna devijacija planarne zakrivljenosti terena dobivena kvadratnim prozorom dimenzija 5x5 m. 109
Slika 5.20 Morfometrijske karte profilne zakrivljenosti dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) raspon profilne zakrivljenosti dobivene kružnim prozorom radijusa 3 m; (b) standardna devijacija profilne zakrivljenosti terena dobivena kvadratnim prozorom dimenzija 9x9 m. 110
Slika 5.21 Morfometrijska karta hrapavosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba prema Riley et al. (1999) dobivena kvadratnim prozorom dimenzija 3x3 m. 112
Slika 5.22 Morfometrijska karta relativnog topografskog položaja terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba dobivena kvadratnim prozorom dimenzija 5x5 m. 113
Slika 5.23 Morfometrijska karta hrapavosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba na temelju standardne devijacije nadmorske visine dobivena kružnim prozorom radijusa 3 m. 115
Slika 5.24 Morfometrijska karta hrapavosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba izvedena prema Nellemann i Fry (1995) dobivena kvadratnim prozorom dimenzija 3x3 m. 116
Slika 5.25 Morfometrijska karta omjera 3D i 2D površine terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba. 117
Slika 5.26 Grupa morfometrijskih karata vlažnosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta vlažnosti izvedena na temelju indeksa vlažnosti terena; (b) karta osunčanosti terena. 119
Slika 5.27 Morfometrijska karta raščlanjenosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba izvedena prema (Evans et al., 1972) dobivena kvadratnim prozorom dimenzija 3x3 m. 120
Slika 6.1 Usporedni prikaz dijela pilot područja na: (a) DOF-u i (b) na kombinaciji karata koja se sastoji od karte nagiba terena, karte osjenčanog terena i karte slojnica ekvidistancije 1 m na kojojima su prikazane interpretirane granice klizišta. 122

Slika 6.2 Inventar klizišta cijelog pilot područja (površine 21 km^2) izrađen vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT kojima je identificirano ukupno 702 klizišta. Karta inventara klizišta prikazana je na DOF-u iz 2012. godine originalnog mjerila 1:5.000. 123
Slika 6.3 Primjer dva tipa stila aktivnosti klizanja na pilot području (21 km^2): (a) sukcesivna klizišta; (b) pojedinačna klizišta. 124
Slika 6.4 Prikaz pouzdano i nepouzdano identificiranih klizišta na pilot području s obzirom na preciznost kartiranja. 125
Slika 6.5 Histogram učestalosti površine 702 klizišta sadržana u inventaru klizišta pilot područja dobivenom vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a: (a) prikaz učestalosti veličine površine klizišta po razredima od 100 m^2; (b) prikaz učestalosti po razredima veličine površine klizišta u log-log mjerilu. 126
Slika 6.6 Prostorna raspodjela terenski provjerenih klizišta na pilot području (21 km^2). 127
Slika 6.7 Klasifikacija terenski provjerenih klizišta s obzirom na pouzdanost vizualne identifikacije na LiDAR DMT-u. 128
Slika 6.8 Usporedan prikaz vidljivosti pojedinih klizišta na terenu i na morfometrijskim kartama izvedenim iz LiDAR DMT-a: (a) klizište u Ulici Črnomerec iza kbr. 111 (svibanj 2014. godine); (b) klizište u Istarskoj ulici ispred kbr. 60 (rujan 2014. godine); (c) klizište u ulici Zamorski Breg iza kbr. 12c (svibanj 2014. godine). 129
Slika 6.9 Usporedan prikaz vidljivosti pojedinih klizišta na terenu i na morfometrijskim karatama izvedenim iz LiDAR DMT-a: (a) klizište između ulica Trsje i Bijenik (svibanj 2014. god.); (b) klizište uz potok Črnomerec (siječanj 2018. god.); (c) klizište u Ulici Črnomerec kbr. 117 (siječanj 2018. god.) 130
Slika 6.10 Usporedba granica klizišta iz povijesnih inventara klizišta (Polak et al., 1979; Miklin et al., 2007) s granicama klizišta iz inventara dobivenog interpretacijom LiDAR DMT-a. Granice klizišta prikazane su na karti osjenčanosti terena, rezolucije 0,3x0,3 m. 132
Slika 6.11 Histogrami učestalosti površina klizišta za tri karte inventara na pilot području (21 km^2): (a) inventar klizišta iz 1979. godine (Polak et al., 1979); (b) inventar klizišta iz 2007. godine (Miklin et al.,2007); (c) inventar klizišta dobiven vizualnom interpretacijom LiDAR DMT-a iz 2013. godine. 133
Slika 6.12 Usporedba indeksa pogreške, E i indeksa podudarnosti, M za zone širine 1, 2, 5, 10 i 20 m oko klizišta u inventarima iz 1979., 2007. i 2013. godine na pilot području površine 21 km^2. 135
Slika 6.13 Karte gustoća klizišta za pilot područje (21 km^2) izrađene na temelje tri inventara klizišta: (a) inventara iz 1979. godine; (b) inventara iz 2007. godine; (c) inventara iz 2013. godine. 137
Slika 7.1 Obuhvat područja za treniranje modela i područja za verifikaciju modela za automatizirano kartiranje klizišta na pilot području ukupne površine 21 km^2. 138
Slika 7.2 Dijagram toka analiza provedenih za izradu model za automatizirano kartiranje klizišta na temelju morfometrijskih karata izvedenih iz LiDAR DMT-a. 139
Slika 7.3 Raspodjela učestalosti vrijednosti standardne devijacije nadmorske visine dobivene kvadratnim prozorom veličine 3x3 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 142
Slika 7.4 Raspodjela učestalosti vrijednosti raspona nadmorske visine dobivene kružnim prozorom radijusa 5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 142
Slika 7.5 Preklop karata morfometrijskih parametara nadmorske visine s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) standardna devijacija nadmorske visine (std_DMT_fr3); i (b) raspon nadmorske visine (rng_DMT_fc5). 143
Slika 7.6 Raspodjela učestalosti vrijednosti standardne devijacije osjenčanosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 144
Slika 7.7 Raspodjela učestalosti vrijednosti raspona osjenčanosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 145
Slika 7.8 Preklop karata morfometrijskih parametara osjenčanosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) standardna devijacija osjenčanosti terena (std_hill_fr5); i (b) raspon osjenčanosti terena (rng_hill_fr5). 146

Slika 7.9 Raspodjela učestalosti vrijednosti nagiba na terenu bez klizišta i terenu zahvaćenom klizanjem. 148
Slika 7.10 Raspodjela učestalosti vrijednosti standardne devijacije nagiba terena dobivene kružnim prozorom radijusa 5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 148
Slika 7.11 Raspodjela učestalosti vrijednosti raspona nagiba terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 148
Slika 7.12 Raspodjela učestalosti vrijednosti relativnog nagiba terena dobivenog kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 149
Slika 7.13 Raspodjela učestalosti vrijednosti druge derivacije nagiba na terenu bez klizišta i terenu zahvaćenom klizanjem. 149
Slika 7.14 Raspodjela učestalosti vrijednosti indeksa položaja dobivenog SIN metodom na terenu bez klizišta i terenu zahvaćenom klizanjem. 149
Slika 7.15 Preklop karata morfometrijskih parametara nagiba terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) nagib terena (slp); (b) standardna devijacija nagiba terena (std_slp_fr5); (c) raspon nagiba terena (rng_slp_fr5); (d) relativan nagib terena (sp_fr5); (e) druge derivacije nagiba terena (slp_2nd); (f) indeksa položaja dobivena SIN metodom (sat_sin). 151
Slika 7.16 Raspodjela učestalosti vrijednosti gustoća slojnica dobivenih kružnim prozorom veličine 9 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 152
Slika 7.17 Preklop karte morfometrijskog parametra gustoće slojnica (con_1m_r9m) s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a. .. 153
Slika 7.18 Raspodjela učestalosti vrijednosti zakrivljenosti terena dobivene kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 156
Slika 7.19 Raspodjela učestalosti vrijednosti standardne devijacije zakrivljenosti terena dobivene kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 156
Slika 7.20 Raspodjela učestalosti vrijednosti raspona zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 156
Slika 7.21 Raspodjela učestalosti vrijednosti planarne zakrivljenosti terena na terenu bez klizišta i terenu zahvaćenom klizanjem. 157
Slika 7.22 Raspodjela učestalosti vrijednosti standardne devijacije planarne zakrivljenosti terena dobivene kružnim prozorom radijusa 3 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 157
Slika 7.23 Raspodjela učestalosti vrijednosti raspona planarne zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5 m terenu bez klizišta i terenu zahvaćenom klizanjem. 157
Slika 7.24 Raspodjela učestalosti vrijednosti profilne zakrivljenosti terena na terenu bez klizišta i terenu zahvaćenom klizanjem. 158
Slika 7.25 Raspodjela učestalosti vrijednosti standardne devijacije profilne zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 158
Slika 7.26 Raspodjela učestalosti vrijednosti raspona profilne zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5m na terenu bez klizišta i terenu zahvaćenom klizanjem. 158
Slika 7.27 Preklop karata morfometrijskih parametara zakrivljenosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) zakrivljenost terena (crv_fr9) (b) standardna devijacija zakrivljenosti terena (std_crv_fr9); (c) raspon zakrivljenosti terena (rng_crv_fr5); (d) planarna zakrivljenost terena (cplan); (e) standardna devijacija planarne zakrivljenosti terena (std_cplan_fc3); (f) raspon planarne zakrivljenosti terena (rng_cplan_fr5)..... 160
Slika 7.28 Preklop karata morfometrijskih parametara zakrivljenosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) profilna zakrivljenost terena (cprf) (b) standardna devijacija profilne zakrivljenosti terena (std_cprf_fr5); (c) raspon profilne zakrivljenosti terena (rng_cprf_fr5). 161

Slika 7.29 Raspodjela učestalosti vrijednosti hrapavosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 163
Slika 7.30 Raspodjela učestalosti vrijednosti relativnog položaja terena dobivenog kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 163
Slika 7.31 Raspodjela učestalosti vrijednosti hrapavosti terena Ascione et al. (2008) dobivena kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 163
Slika 7.32 Raspodjela učestalosti vrijednosti indeksa hrapavosti terena dobivene kružnim prozorom radijusa 3 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 164
Slika 7.33 Raspodjela učestalosti vrijednosti omjera 3D i 2D površine terena na terenu bez klizišta i terenu zahvaćenom klizanjem. 164
Slika 7.34 Preklop karata morfometrijskih parametara hrapavosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) hrapavost terena (rgh_fr5) (b) relativan položaj terena (rtp_fr5); (c) hrapavost terena prema Ascione et al. (2008) (rgh_a_fr9); (d) indeks hrapavosti terena (tri_ril_fc3); (e) omjer 3D i 2D površine terena (sar). 165
Slika 7.35 Raspodjela učestalosti vrijednosti indeksa vlažnosti na terenu bez klizišta i terenu zahvaćenom klizanjem. 166
Slika 7.36 Raspodjela učestalosti vrijednosti indeksa osunčanosti na terenu bez klizišta i terenu zahvaćenom klizanjem. 166
Slika 7.37 Preklop karata morfometrijskih parametara vlažnosti terena i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) vlažnost terena (cti); (b) osunčanost terena (hli). 167
Slika 7.38 Raspodjela učestalosti vrijednosti raščlanjenosti terena dobivene kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem. 168
Slika 7.39 Preklop karte morfometrijskog parametara raščlanjenosti terena (diss_fr9) i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a. 169
Slika 7.40 Karta klizišta izrađena na osnovi zbroja svih predikcijskih karata: (a) karta za testno područje površine 10,5 km^2 i prikaz raspodjele učestalosti vrijednosti zbroja predikcijskih karata s obzirom na broj ćelija; (b) i (c) usporedba s vizualno kartiranim klizištima. 172
Slika 7.41 Prikaz parametara točnosti karata inventara klizišta reklasificiranih s obzirom na različite granične vrijednosti zbroja predikcijskih karata. 173
Slika 7.42 Konačna karta klizišta izrađena na osnovi zbroja svih predikcijskih karata i reklasificirana s obzirom na graničnu vrijednost 26: (a) karta za testno područje površine 10,5 km^2 s prikazom točaka klasificiranih kao klizišta; (b) i (c) usporedba automatizirano kartiranih klizišta s vizualno kartiranim klizištima. 174
Slika 7.43 Vrijednost parametara točnosti za svaki korak *stepwise* metode kombiniranja predikcijskih karata. 175
Slika 7.44 Konačna karta inventara klizišta izrađena na osnovi *stepwise* metode kombiniranja predikcijskih karata: (a) karta za testno područje površine 10,5 km^2 s prikazom točaka klasificiranih kao klizišta; (b) i (c) usporedba automatizirano kartiranih klizišta s vizualno kartiranim klizištima. 176
Slika 7.45 Usporedba karata inventara automatizirano i vizualno kartiranih klizišta na području za testiranje modela (10,5 km^2) i verifikaciju modela. (10,5 km^2). 178
Slika 7.46 Usporedba parametara točnosti karte inventara automatizirano kartiranih klizišta s obzirom na koncentrično uvećavanim granicama vizualno kartiranih klizištima u širinama 0,25, 0,5, 1, 2, 5 i 10 m oko vizualno kartiranih klizišta na području za verifikaciju modela (10,5 km^2). 179
Slika 7.47 Usporedan prikaz karte inventara automatizirano kartiranih klizišta s: (a) zonama širine 0,25 m, 0,5 m, 1 m, 2 m, 5 m i 10 m oko vizualno kartiranih klizišta; (b) vizualno kartiranim nestabilnim padinama. 179
Slika 7.48 Usporedba inventara automatizirano kartiranih klizišta s vizualnom kartiranim klizištima i nestabilnim padinama na području za verifikaciju modela (10,5 km^2). 180
Slika 7.49 Broj točaka klasificiranih kao klizišta modelom za automatizirano kartiranje klizišta unutar granica vizualno kartiranih klizišta. 181

Slika 7.50 Učestalost predviđenih i nepredviđenih vizualno kartiranih klizišta modelom za automatizirano kartiranje klizišta s obzirom na pouzdanost vizualne identifikacije klizišta na LiDAR DMT-u. 182
Slika 7.51 Učestalost vizualno kartiranih klizišta koja su predviđena ili nepredviđena modelom za automatizirano kartiranje klizišta s obzirom na površinu klizišta. 182
Slika 8.1 Shematski prikaz izrade karata podložnosti na klizanje na pilot području (21 km^2) podsljemenske zone Grada Zagreba 184
Slika 8.2 Karta nadmorskih visina na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 186
Slika 8.3 Karta nagiba visina na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 187
Slika 8.4 Karta orijentacije padina na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 189
Slika 8.5 Karta stratigrafskih jedinica na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 191
Slika 8.6 Karta udaljenosti od geoloških granica na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 193
Slika 8.7 Karta udaljenosti od rasjeda na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 194
Slika 8.8 Karta udaljenosti od drenažne mreže na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 196
Slika 8.9 Karta stvarnog korištenje zemljišta na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 197
Slika 8.10 Karta udaljenosti od građevina i prometnica na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta. 198
Slika 8.11 Karte podložnosti na klizanje izrađene na temelju potpunog inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a: (a) prostorna raspodjela i učestalost vrijednosti podložnosti na klizanje na temelju površina vizualno kartiranih klizišta; (b) prostorna raspodjela i učestalost vrijednosti podložnosti na klizanje na temelju broja vizualno kartiranih klizišta. 201
Slika 8.12 Karta podložnosti na klizanje izrađena na temelju inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta iz LiDAR DMT-a. 202
Slika 8.13 ROC krivulje za tri karte podložnosti na klizanje izvedenih na temelju površina klizišta dobivenih vizualnom interpretacijom LiDAR DMT-a, broja klizišta dobivenih vizualnom interpretacijom LiDAR DMT-a i inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta. 203
Slika 8.14 Verifikacija karte podložnosti na klizanje izvedene na temelju automatizirano kartiranih klizišta s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. ROC krivulje prikazuju verifikaciju za testno područje i područje verifikacije na pilot području (21 km^2). 204
Slika 8.15 Usporedba karata podložnosti na klizanje klasificiranih na stabilne i nestabilne padine: (a) karta podložnosti izrađena na temelju površina vizualno kartiranih klizišta; (b) karta podložnosti izrađena na temelju broja vizualno kartiranih klizišta; (c) karta podložnosti izrađena na temelju automatizirano kartiranih klizišta. 205
Slika 8.16 Klasifikacija podložnosti na klizanje s obzirom na granične vrijednosti kumulativnih površina ili broja klizišta. 207
Slika 8.17 Karta podložnosti na klizanje (21 km^2) izrađena na temelju površina vizualno kartiranih klizišta iz potpunog inventara klizišta. 208
Slika 8.18 Karta podložnosti na klizanje (21 km^2) izrađena na temelju broja vizualno kartiranih klizišta iz potpunog inventara klizišta. 209
Slika 8.19 Karta podložnosti na klizanje (21 km^2) izrađena na temelju klizišta dobivenih pomoću modela za automatizirano kartiranje klizišta. 210

POPIS TABLICA

Tablica 2.1 Terminologija za opis klizišta s obzirom na dubinu, površinu i volumen klizišta. 12
Tablica 2.2 Prikaz tehnika za izradu inventara klizišta (prema van Westen et al., 2008). 19
Tablica 2.3 ASPRS standard za klasifikaciju oblaka točaka dobivenog laserskim skeniranjem (ASPRS, 2013). 24
Tablica 2.4 Pregled postojeće literature o vizualnoj identifikaciji i kartiranju klizišta primjenom LiDAR DMT-a s navedenom lokacijom područja istraživanja, rezolucijom korištenog DMT-a, korištenim morfometrijskim kartama i primijenjenom metodom kartiranja. 28
Tablica 2.5 Pregled postojeće literature o automatiziranom kartiranju klizišta primjenom LiDAR DMT-a s navedenom lokacijom i površinom istraživanog područja, rezolucijom korištenog DMT-a, korištenim morfometrijskim kartama i primijenjenom metodom kartiranja. 31
Tablica 2.6 Pregled najčešće korištenih faktorskih karata za procjenu podložnosti na klizanje s obzirom na mjerilo istraživanja (prema Soeters & van Westen, 1996). 35
Tablica 3.1 Klasifikacija padina s obzirom na nagib padine i dominantne geomorfološke procese (IGU, 1968) na istraživanom području (180 km^2) i pilot području (21 km^2). 41
Tablica 3.2 Korelacija kronostratigrafskih, neformalnih litostratigrafskih i biostratigrafskih jedinica istraživanog područja s prikazom zastupljenosti površina. 49
Tablica 3.3 Popis meteoroloških postaja i srednjih godišnjih oborina na području podsljemenske zone Grada Zagreba. 52
Tablica 3.4 Stvarno korištenje zemljišta u podsljemenskoj zoni Grada Zagreba (180 km^2). 56
Tablica 3.5 Stvarno korištenje zemljišta na pilot području (21 km^2). 57
Tablica 3.6 Kriteriji za kartiranje i klasifikaciju klizišta u studiji „*Litološka obrada i kategorizacija terena prema stabilnosti tla obronaka Medvednice na području grada Zagreba*“ iz 1979. godine. 62
Tablica 4.1 Stupanj pouzdanosti kartiranja klizišta na morfometrijskim kartama izvedenim iz DMT-a. 72
Tablica 4.2 Stupanj preciznosti kartiranja klizišta na morfometrijskim kartama izvedenim iz DMT-a. 73
Tablica 4.3 Klasifikacija točnosti karata podložnosti s obzirom na AUC vrijednost 84
Tablica 5.1 Srednja gustoća točaka i prosječna udaljenost točaka za pilot područje. 86
Tablica 5.2 Prosječna gustoća uzorkovanja ovisno o namjeni zemljišta. 87
Tablica 5.3 Površine zona različitih širina oko građevina i prometnica na pilot području. 94
Tablica 5.4 Vrste i broj izvedenih morfometrijskih karata za automatizirano kartiranje klizišta po glavnim grupama karata. 94
Tablica 5.5 Vrste i broj izvedenih morfometrijskih karata raspona nadmorskih visina 95
Tablica 5.6 Vrste i broj izvedenih morfometrijskih karata standardne devijacije nadmorskih visina.. 96
Tablica 5.7 Vrste i broj izvedenih morfometrijskih karata raspona osjenčanosti terena. 97
Tablica 5.8 Vrste i broj izvedenih morfometrijskih karata standardne devijacije osjenčanosti terena. 97
Tablica 5.9 Vrste i broj izvedenih morfometrijskih karata nagiba terena. 98
Tablica 5.10 Vrste i broj izvedenih morfometrijskih karata raspona nagiba terena. 99
Tablica 5.11 Vrste i broj izvedenih morfometrijskih karata standardne devijacije nagiba terena. 99
Tablica 5.12 Vrste i broj izvedenih morfometrijskih karata relativnog položaja padine. 100
Tablica 5.13 Vrste i broj izvedenih morfometrijskih karata transformacije nagiba i orijentacije terena. 102
Tablica 5.14 Vrste i broj izvedenih morfometrijskih karata gustoće slojnica. 103
Tablica 5.15 Vrste i broj izvedenih morfometrijskih karata zakrivljenosti terena. 105
Tablica 5.16 Vrste i broj izvedenih morfometrijskih karata ukupne zakrivljenosti terena. 106
Tablica 5.17 Vrste i broj izvedenih morfometrijskih karata raspona zakrivljenosti terena. 107
Tablica 5.18 Vrste i broj izvedenih morfometrijskih karata standardne devijacije zakrivljenosti terena. 107

Tablica 5.19 Vrste i broj izvedenih morfometrijskih karata planarne i profilne zakrivljenosti terena. 108
Tablica 5.20 Vrste i broj izvedenih morfometrijskih karata raspona planarne zakrivljenosti terena. 109
Tablica 5.21 Vrste i broj izvedenih morfometrijskih karata standardne devijacije planarne zakrivljenosti terena. 109
Tablica 5.22 Vrste i broj izvedenih morfometrijskih karata raspona profilne zakrivljenosti terena. . 111
Tablica 5.23 Vrste i broj izvedenih morfometrijskih karata standardne devijacije profilne zakrivljenosti terena. 111
Tablica 5.24 Vrste i broj izvedenih morfometrijskih karata hrapavosti terena. 112
Tablica 5.25 Vrste i broj izvedenih morfometrijskih karata hrapavosti terena prema Riley et al. (1999). 113
Tablica 5.26 Vrste i broj izvedenih morfometrijskih karata relativnog topografskog položaja. 114
Tablica 5.27 Vrste i broj izvedenih morfometrijskih karata hrapavosti terena prema Ascione et al. (2008). 115
Tablica 5.28 Vrste i broj izvedenih morfometrijskih karata indeksa hrapavosti terena. 116
Tablica 5.29 Vrste i broj izvedenih morfometrijskih karata omjera 3D i 2D površine terena. 117
Tablica 5.30 Vrste i broj izvedenih morfometrijskih karata vlažnosti terena. 118
Tablica 5.31 Vrste i broj izvedenih morfometrijskih karata vlažnosti terena. 119
Tablica 5.32 Vrste i broj izvedenih morfometrijskih karata raščlanjenosti terena. 121
Tablica 6.1 Usporedba statističkih značajki inventara klizišta iz 2013. godine s dostupnim povijesnim inventarima klizišta iz 1979. i 2007. godine. 132
Tablica 6.2 Analiza kartografske podudarnosti inventara klizišta iz 1979., 2007. i 2013. godine na pilot području površine 21 km^2. 134
Tablica 6.3 Usporedba učestalosti stabilnih i nestabilnih padina dobivenih na temelju karata gustoća klizišta za inventare klizišta iz 1979., 2007. i 2013. godine. 137
Tablica 7.1 Grupe i podgrupe morfometrijskih karata izvedenih iz LiDAR DMT-a rezolucije 1x1 m. 140
Tablica 7.2 Granične vrijednosti i indeks podudarnosti morfometrijske grupe karata nadmorske visine. 141
Tablica 7.3 Granične vrijednosti morfometrijske grupe karata osjenčanosti terena. 144
Tablica 7.4 Granične vrijednosti grupe morfometrijskih karata nagiba terena. 147
Tablica 7.5 Granične vrijednosti morfometrijskih karata gustoće slojnica. 152
Tablica 7.6 Granične vrijednosti grupe morfometrijskih karata zakrivljenosti terena. 154
Tablica 7.7 Granične vrijednosti grupe morfometrijskih karata hrapavosti terena. 162
Tablica 7.8 Granične vrijednosti grupe morfometrijskih karata vlažnosti. 166
Tablica 7.9 Granične vrijednosti morfometrijskih karata raščlanjenosti terena. 168
Tablica 7.10 Predikcijske karte modela za automatizirano kartiranje klizišta s navedenim graničnim vrijednostima i stupnjem kartografske podudarnosti s vizualno kartiranim klizištima. 170
Tablica 8.1 Preduvjeti klizanja analizirani u svrhu izrade karte podložnosti na klizanje za pilot područje (21 km^2) podsljemenske zone Grada Zagreba. 185
Tablica 8.2 Analiza utjecaja nadmorske visine na pojavu klizišta primjenom WoE modela. 187
Tablica 8.3 Analiza utjecaja nagiba terena na pojavu klizišta primjenom WoE modela. 188
Tablica 8.4 Analiza utjecaja orijentacije padine na pojavu klizišta primjenom WoE modela. 190
Tablica 8.5 Analiza utjecaja litologije na pojavu klizišta primjenom WoE modela. 192
Tablica 8.6 Analiza utjecaja udaljenosti od geoloških granica na pojavu klizišta primjenom WoE modela. 193
Tablica 8.7 Analiza utjecaja udaljenosti od rasjeda na pojavu klizišta primjenom WoE modela. 195
Tablica 8.8 Analiza utjecaja udaljenosti od drenažne mreže na pojavu klizišta primjenom WoE modela. 196
Tablica 8.9 Analiza utjecaja stvarnog korištenja zemljišta na pojavu klizišta primjenom WoE modela. 198

Tablica 8.10 Analiza utjecaja udaljenosti od građevina i prometnica na pojavu klizišta primjenom WoE modela. 199
Tablica 8.11 Usporedba površine stabilnih i nestabilnih padina na kartama podložnosti na klizanje izvedenih na temelju vizualno i automatizirano kartiranih inventara klizišta. 205
Tablica 8.12 Usporedba kartografskog preklapanja karata podložnosti na klizanje dobivenih na temelju vizualno kartiranih klizišta, poligoni (KP1) i točke (KP2), i karte podložnosti dobivene na temelju automatizirano kartiranih klizišta (KP3). 206
Tablica 8.13 Usporedba karata podložnosti na klizanje dobivenih na temelju vizualno i automatizirano kartiranih inventara klizišta s obzirom na površine klasa podložnosti. 211

1 UVOD

Prema Cruden (1991) klizanje je proces gibanja mase stijena ili tla niz padinu, a pojava koja pri tome nastaje se naziva klizište. Klizišta su najčešće aktivirana prirodnim uzročnicima, poput intenzivnih oborina ili potresa, ali mogu nastati i kao posljedica ljudskih djelatnosti (Popescu, 2002; Guzzetti, 2006; Clague i Roberts, 2012), odnosno građenja, poljoprivrednih radova te nekontroliranog uklanjanja vegetacijskog pokrova. Procesi klizanja predstavljaju veliki problem u gotovo svim dijelovima svijeta (Brabb i Harrod, 1989), jer uzrokuju izravne ili neizravne ekonomske i/ili socijalne gubitke na privatnim i/ili javnim dobrima. Izravne štete nastaju u trenutku aktiviranja klizišta, oštećivanjem materijalne imovine i ljudskim gubicima (smrt ili povreda) unutar granica prostiranja klizišta. Neizravne štete se iskazuju kroz dulje vremensko razdoblje, odnosno kroz smanjenje vrijednosti nekretnina u ugroženim područjima, gubitkom produktivnosti zbog oštećenja na dobrima ili prekidom prometa, smanjenjem produktivnost prouzročenom smrću ljudi, ozljedama ili psihološkim traumama i, konačno, troškovima sanacije šteta. Održivo upravljanje prostorom na bilo kojoj razini je otežano, gotovo i nemoguće, bez poznavanja svih vrsta geohazardnih procesa i njihove prostorne raspodjele na nekom području, odnosno bez sustavnog evidentiranja pojava koje nastaju kao posljedica njihovog odvijanja (Bell, 2003; Clague i Roberts, 2012). Istraživanje klizišta i procjena opasnosti od klizanja u domeni je geoznanosti, a konačni rezultati su karte postojećih klizišta i prognostičke karte koje su informacija za širok spektar korisnika, najčešće iz domene lokalne, regionalne i nacionalne uprave. Prognostičke karte hazarda klizanja nastaju kao rezultat prostornih analiza, ali za njihovu izradu nužni se detaljni i potpuni inventari klizišta (Glade, 2001; van Westen et al., 2008). Smanjenje posljedica od rizika klizanja moguće je izradom niza karata klizišta koje trebaju biti korištene prilikom izdavanja dozvola i definiranja uvjeta građenja te implementirane kroz sustav prostornog planiranja u prostorne planove i planiranje namjene zemljišta. U regijama u kojima postoje područja izrazito podložna na klizanje te je evidentiran veliki broj klizišta, nužno je provoditi praćenje i istraživanje oborinskih uvjeta koji dovode do pojave novih ili reaktiviranja postojećih klizišta. Mjere za ublažavanje posljedica u ovom slučaju su interventne mjere upozoravanja i evakuacije ljudi koje se provode kroz sustav civilne zaštite, na način da se uvode sustavi ranog upozoravanja koji se aktiviraju u slučaju prekoračenja zadanih kritičnih vrijednosti oborina na područjima za koje je određen visoki rizik od (re)aktiviranja klizišta. Za sve navedene mjere ublažavanja posljedica od klizanja, preduvjet

su detaljni i potpuni inventari klizišta te izrada pouzdanih prognostičkih karata hazarda klizanja (Mihalić Arbanas & Arbanas, 2014).

U posljednjih petnaestak godina sve je češća primjena daljinskih istraživanja za izradu karata klizišta. Daljinska istraživanja (*engl. remote sensing*) definirana su kao znanost o prikupljanju podataka o površini Zemlje bez kontakta s površinom (Levin, 1999). Za kartiranje klizišta najčešće se primjenjuju tehnologija laserskog skeniranja (LiDAR, engl. *Light Detection and Ranging*) iz zraka, satelitske optičke i radarske snimke (Jaboyedoff et al., 2012). Jedan od glavnih razloga je što metode daljinskih istraživanja omogućavaju dobivanje 3D informacija o površini terena s visokom preciznosti i prostornom rezolucijom. Prednost LiDAR-skih podataka u odnosu na ostale metode daljinskih istraživanja je izrada digitalnog modela terena (DMT) bez vegetacije i vrlo visoke rezolucije (<2 m) koje omogućavaju identifikaciju i kartiranje klizišta na područjima pod gustom vegetacijom (Chigira et al., 2004; Van den Eeckhaut et al., 2007; Razak et al., 2011). Dosadašnja primjena LiDAR tehnologije u izradi karata inventara klizišta najčešće se temeljila na vizualnoj interpretaciji različitih morfometrijskih karata izvedenih iz LiDAR DMT-a (Ardizzone et al., 2007; Schulz et al., 2007; Van Den Eeckhaut et al. 2007; Mihalić et al., 2013). Iako je vizualna interpretacija LiDAR DMT-a te avionskih i satelitskih stereoparova u svrhu izrade inventara klizišta brža, točnija i učinkovitija od konvencionalnog terenskog geomorfološkog kartiranja (Haugerud et al., 2003; Schulz, 2004; Booth et al., 2009; Razak et al., 2011), i dalje je to dugotrajan proces te je zbog toga često kartiranje klizišta ograničeno na područja manje površine. Iz navedenog razloga, u posljednjih nekoliko godina razvijaju se modeli za automatizirano kartiranje klizišta na temelju spektralnih svojstava ili nadmorskih visina, ovisno o korištenoj metodi daljinskih istraživanja (Van Westen et al., 2008).

U Hrvatskoj se daljinske metode istraživanja u svrhu detaljnog kartiranja klizišta primjenjuju tek unatrag nekoliko godina, a razvijene su u okviru hrvatsko-japanskog SATREPS F2008 projekta (Mihalić & Arbanas, 2013; Arbanas et al., 2017). Toševski, 2018 i Đomlija, 2018 prvi su primijenili LiDAR tehnologiju za izradu karata klizišta na području Vinodolske udoline- Osim toga, jednostavne kartografske baze podataka o klizištima u upotrebi su samo za područje podsljemenske zone Grada Zagreba, površine 180 km^2 i za područje Slavonskog Broda, površine 10 km^2 (Miklin et al., 2012). Sve do sada izrađene karte klizišta (Šikić, 1967; Polak et al., 1979; Miklin et al., 2007; Podolzski, 2014) izrađene su primjenom konvencionalnih metoda kartiranja klizišta, a to su terensko geomorfološko kartiranje i vizualna interpretacija stereoparova avionskih snimki. Unatoč dugogodišnjem istraživanju klizišta i izrada karata

klizišta, glavni problem u postojećoj prakse upravljanja rizikom od klizanja u Gradu Zagrebu je nedostatak detaljnog i potpunog inventara klizišta kao i nedostatak prognostičkih karata hazarda klizanja (Mihalić, 1998; Mihalić Arbanas et al., 2013). Analiza prostorne raspodjele površina klizišta provedena od strane Podolszkog (2014) pokazala je da dva povijesna inventara klizišta iz 1967. godine (Šikić, 1967) i 2007. godine (Miklin et al., 2007) sadrže nedosljedne i nepouzdane podatke o klizištima zbog podcijenjenog broja klizišta i precijenjenih površina kartiranih klizišta.

S obzirom na dosadašnja istraživanja klizišta koja su detaljnije opisana u radovima Jurak et al. (2008) i Mihalić Arbanas et al. (2012), može se zaključiti da je područje podsljemenske zone Grada Zagreba izrazito podložno na klizanje te da su klizišta posljedica geološke građe, karakterističnog reljefa te intenzivne urbanizacije u posljednjih 40-ak godina (Mihalić Arbanas et al., 2016). Klizišta uglavnom nastaju na granici između površinskih naslaga i matične stijene, a mnoga su poznata klizišta nastala na geološkoj granici između pleistocenskih i gornjopontskih naslaga (Jurak et al., 1998). Oborine i otapanje snježnog pokrivača glavni su pokretači (inicijatori) klizišta u Gradu Zagrebu, što je dokazano time da se većina klizišta (re)aktivirala u mjesecima kada je količina oborina bila viša od prosječne mjesečne oborine (Bernat Gazibara et al. 2014a). Kao posljedica klimatskih promjena, u posljednjih nekoliko godina sve je češća masovna pojava klizišta (Bernat Gazibara et al. 2017), poznata u svjetskoj literaturi kao tzv. višestruki regionalni događaji klizišta (engl. *multiple-occurrence regional landslide events*, *MORLE*) prema Crozier (2005). Tijekom zime 2012./2013. godine ekstremne hidrometeorološke prilike su na području sjeverozapadne Hrvatske uzrokovale (re)aktiviranje više od 900 klizišta na području Krapinsko-zagorske županije, Varaždinske županije, Grada Zagreba, Karlovačke županije, Međimurske i Zagrebačke županije (Bernat et al., 2014a), dok je na području kontinentalne Hrvatske u ožujku 2018. godine registrirano aktiviranje više od 100 klizišta. Sve češći MORLE, odnosno aktiviranje velikog broja klizišta u kratkom kontinuiranom vremenskom intervalu u Hrvatskoj, iziskuje sustavno prikupljanje podataka o aktiviranim klizištima te uspostavljanje nacionalne baze podataka o klizištima. Također, nužna je izrada karata inventara klizišta i prognostičkih karata hazarda, kao podloga za definiranje mjera ublažavanja posljedica klizanja kroz sustav prostornog planiranja. Pri tome izradi karata klizišta u detaljnom mjerilu mora prethoditi analiza hazarda klizanja u nacionalnom i regionalnom mjerilu da bi se definirala prioritetna područja na kojima postoji najveći rizik od klizanja (Mihalić Arbanas et al., 2018).

1.1 Svrha i ciljevi istraživanja

Svrha istraživanja provedenog u okviru disertacije je uspostava metodologije za izradu karata klizišta korištenjem LiDAR tehnologije. Lasersko skeniranje predmetnog područja istraživanja, odnosno podsljemenske zone Grada Zagreba (180 km^2) provedeno je nakon MORLE događaja tijekom kojega je aktiviran veliki broj klizišta u zimi 2012./2013. godine na području cijele SZ Hrvatske (Bernat Gazibara et al., 2014a,b). Predmet istraživanja ovog rada je izrada optimalnog LiDAR DMT-a visoke rezolucije i izvedenih morfometrijskih karata na temelju kojih je moguće izraditi detaljne i potpune inventare klizišta za pilot područje u podsljemenskoj zoni Grada Zagreba (površine 21 km^2). Pri izradi karata inventara klizišta iz LiDAR DMT-a visoke rezolucije primijenjene su i uspoređene dvije metode, a to su metoda vizualne interpretacije morfometrijskih karata izvedenih iz LiDAR DMT-a te metoda automatiziranog kartiranja klizišta izradom modela koji se temelji na statističkim analizama izvedenih morfometrijskih karata. Također, analizirana je mogućnost primjene izvedenih inventara klizišta za izradu prognostičkih karata hazarda klizanja. Ovako definirano istraživanje zasniva se na sljedećim hipotezama:

1. Vizualna interpretacija morfometrijskih karata izvedenih iz digitalnog modela terena visoke rezolucije omogućava točnu identifikaciju i precizno kartiranje malih i plitkih klizišta u detaljnom mjerilu na područjima prekrivenim gustom vegetacijom kao što je podsljemenska zona Grada Zagreba.
2. Digitalni model terena visoke rezolucije, dobiven laserskim skeniranjem iz zraka nakon pokretanja velikog broja klizišta, omogućava izradu detaljnog i potpunog inventara klizišta.
3. Morfometrijski parametri reljefa imaju različitu raspodjelu vrijednosti unutar granica klizišta i u odnosu na okolni teren bez klizišta što omogućava automatizirano kartiranje klizišta.
4. Karta inventara klizišta dobivena automatiziranim kartiranjem klizišta na temelju morfometrijskih parametara omogućava izradu prognostičkih karata klizišta.

Iz navedenog proizlaze slijedeći ciljevi istraživanja:

1. Izrada digitalnog modela terena visoke rezolucije optimalnog za kartiranje malih i plitkih klizišta.

2. Izrada detaljnog i potpunog inventara klizišta vizualnom interpretacijom digitalnog modela terena visoke rezolucije koji se može koristiti kao podloga za izradu prognostičkih karata hazarda klizanja.
3. Definiranje morfometrijskih parametara i graničnih vrijednosti na temelju kojih je moguće izraditi model za automatizirano kartiranje klizišta.
4. Izrada modela za automatizirano kartiranje klizišta na temelju morfometrijskih parametara dobivenih iz digitalnog modela terena visoke rezolucije.
5. Utvrditi prostornu raspodjelu klizišta na pilot području i odrediti preduvjete klizanja u podsljemenskoj zoni Grada Zagreba.
6. Izrada karata podložnosti klizanja na temelju karata inventara klizišta dobivenih vizualnom interpretacijom digitalnog modela terena i automatiziranim kartiranjem digitalnog modela terena.

Lasersko skeniranje provedeno je u prosincu 2013. godine u okviru znanstvenog hrvatsko-japanskog SATREPS FY2008 projekta „Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje rizika klizanja i bujica u Hrvatskoj“. U svrhu ostvarivanja zadanih ciljeva, na području podsljemenske zone Grada Zagreba (180 km^2) definirano je pilot područje površine 21 km^2 na kojemu su provedena sva istraživanja u okviru doktorske disertacije. Na početku istraživanja provedena je analiza gustoće oblaka točaka dobivenog laserskim skeniranjem podsljemenske zone Grada Zagreba te su primijenjene različite metode interpolacije za izradu DMT-a. Izrada optimalnog LiDAR DMT-a za identifikaciju i kartiranje klizišta uključuje izbor odgovarajuće rezolucije DMT-a, koja će omogućiti precizno i pouzdano kartiranje klizišta svih veličina na istraživanom području, te izbor metode interpolacije o kojoj ovisi izraženost morfologije klizišta na izvedenim morfometrijskim kartama. Izradom morfometrijskih karta iz LiDAR DMT-a rezolucije 0,3x0,3 m i 1x1 m izvedene su podloge za vizualnu identifikaciju i kartiranje klizišta kao i ulazni podaci za izradu modela za automatizirano kartiranje klizišta.

Vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a rezolucije 0,3x0,3 m izrađen je detaljan i potpun inventar klizišta što je potvrđeno raspodjelom površina klizišta na pilot području te procjenom pouzdanosti i preciznosti svakog iskartiranog klizišta. Na temelju provedenih analiza dokazane su prve dvije hipoteze: (1) vizualna interpretacija morfometrijskih karata izvedenih iz digitalnog modela terena visoke rezolucije omogućava točnu identifikaciju i precizno kartiranje malih i plitkih klizišta u detaljnom mjerilu na područjima prekrivenim gustom vegetacijom kao što je podsljemenska zona Grada Zagreba, te

(2) digitalni model terena visoke rezolucije, dobiven laserskim skeniranjem iz zraka nakon pokretanja velikog broja klizišta (MORLE događaja), omogućava izradu detaljnog i potpunog inventara klizišta.

Iz LiDAR DMT-a rezolucije 1x1 m izvedeno je ukupno 127 morfometrijskih karata koje se mogu podijeliti u osam glavnih grupa, a to su karte nadmorskih visina, karte osjenčanosti terena, karte nagiba terena, karte slojnica, karte zakrivljenosti terena, karte hrapavosti terena, karte vlažnosti i karte raščlanjenosti terena. Za potrebe izrade modela za automatizirano kartiranje klizišta, pilot područje (21 km^2) podijeljeno je na testno područje (10,5 km^2) i područje za verifikaciju modela (10,5 km^2). Statistička analiza izvedenih morfometrijskih karata na testnom području ukazala je na različitu raspodjelu morfometrijskih vrijednosti unutar granica klizišta i na okolnom području koje nije zahvaćeno procesom klizanja. S obzirom na preliminarne analize, uspostavljena je hipoteza 3, kojom je pretpostavljeno da morfometrijski parametri terena imaju različitu raspodjelu vrijednosti unutar granica klizišta i u odnosu na okolni teren bez klizišta što omogućava automatizirano kartiranje klizišta. Određivanjem graničnih vrijednosti morfometrijskih parametara i analizom točnosti koja je provedena metodom kartografskog preklapanja, definirane su predikcijske karte čijim zbrajanjem je izrađen model za automatizirano kartiranje klizišta. Metoda razvijena za automatizirano kartiranje klizišta može se klasificirati kao pikselno orijentirana metoda koja se temelji na nadziranoj klasifikaciji graničnih vrijednosti morfometrijskih karata izvedenih iz LiDAR DMT-a.

Verifikacijom modela za automatizirano kartiranje klizišta na preostalom dijelu pilot područja (10,5 km^2) potvrđena je hipoteza 3, te je postavljena hipoteza 4 koja ujedno predstavlja konačni cilj istraživanja. Hipoteza 4 pretpostavlja da karta inventara klizišta dobivena automatiziranim kartiranjem klizišta na temelju morfometrijskih parametara omogućava izradu prognostičkih karata klizišta. U tu svrhu izvedene su karte podložnosti na klizanje na temelju karte inventara klizišta dobivene vizualnom interpretacijom LiDAR DMT-a, kao i karte podložnosti na temelju karte inventara klizišta dobivene modelom za automatizirano kartiranje klizišta. Utjecaj pojedinih preduvjeta klizanja analiziran je primjenom bivarijantne statističke metode. Karta podložnosti na klizanje izvedena na temelju automatizirano kartiranih klizišta uspoređena je s kartom inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a na temelju ROC krivulje. S obzirom na visoku točnost izvedene karte podložnosti na klizanje, može se zaključiti da model razvijen za automatizirano kartiranje klizišta na temelju morfometrijskih parametara omogućava izradu pouzdanih prognostičkih karata hazarda klizanja.

1.2 Struktura disertacije

U prvom poglavlju (Uvod) opisan je značaj predmetnog istraživanja u odnosu na relevantne znanstvene spoznaje i potreba za ovom vrstom istraživanja, s naglaskom na praktičnu primjenu rezultata istraživanja za izradu različitih vrsta karata klizišta za ublažavanje rizika od klizanja, te su definirani svrha, hipoteze i ciljevi istraživanja, a ukratko je opisana i struktura disertacije.

U drugom poglavlju (Teorijske osnove) iznesen je pregled teorijskih osnova na kojima se zasniva istraživanje provedeno u okviru disertacije. Ukratko je navedena terminologija za opis klizišta te su opisane vrste inventara klizišta i njihove osnovne značajke. U nastavku je dan pregled postojećih metoda istraživanja i kartiranja pojava klizišta, te je opširnije opisana LiDAR tehnologija, odnosno postupak laserskog skeniranja iz zraka i izrada digitalnih modela terena iz oblaka točaka. U zasebnim poglavljima, sustavno i sažeto su opisana dosadašnja istraživanja u identifikaciji i kartiranju klizišta primjenom metode vizualne interpretacije LiDAR DMT-a i automatiziranog kartiranja klizišta na temelju morfometrijskih parametara izvedenih iz LiDAR DMT-a. Na kraju poglavlja navedene su glavne značajke karata podložnosti na klizanje te su ukratko opisane metode i ulazni podaci koji se koriste za procjenu podložnosti na klizanje.

U trećem poglavlju (Područje istraživanja) definiran je geografski položaj pilot područja površine 21 km^2 u podsljemenskoj zoni Grada Zagreba te su opisane geomorfološke, geološke, hidrološke i meteorološke značajke te namjena zemljišta šireg istraživanog područja. U nastavku su opisani inženjerskogeološki uvjeti i aktivni geomorfološki procesi karakteristični za područje Grada Zagreba. Također, ukratko su opisani postojeći inventari klizišta na području podsljemenske zone Grada Zagreba s navedenim obuhvatima istraživanja, primijenjenim metodama kartiranja klizišta i statističkim značajkama inventara, kao što su ukupna površina klizišta i srednja gustoća klizišta na istraživanom području.

U četvrtom poglavlju (Metode istraživanja) opisane su metode interpolacije primijenjene za izradu LiDAR DMT-a visoke rezolucije, metoda izrade inventara klizišta vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a te statističke analize na temelju kojih je izrađen model za automatizirano kartiranje klizišta. U nastavku poglavlja opisane su i metode primijenjene za usporedbu inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a s postojećim inventarima klizišta. Također, sažeto je opisana i primijenjena metoda bivarijantne statističke analize primijenjena za izradu karata podložnosti na klizanje, odnosno na temelju koje je analizirana mogućnost primjene inventara klizišta

dobivenog modelom za automatizirano kartiranje za izradu prognostičkih karata hazarda klizanja.

U petom poglavlju (Ulazni podaci) analizirane su karakteristike oblaka točaka dobivenog laserskim skeniranjem iz zraka te su uspoređeni izvedeni LiDAR DMT-i za pilot područje površine 21 km^2 rezolucije 0,3x0,3 m i 1x1 m dobiveni različitim metodama interpolacije. U nastavku poglavlja prikazane su metode primijenjene za izradu morfometrijskih karata izvedenih iz LiDAR DMT-a koje predstavljaju podlogu za vizualnu interpretaciju klizišta i ulazni podatak za izradu modela za automatizirano kartiranje klizišta.

U šestom poglavlju (Inventar klizišta dobiven vizualnom interpretacijom LiDAR DMT-a) prikazani su rezultati vizualne interpretacije morfometrijskih parametara izvedenih iz LiDAR DMT-a. U ovom poglavlju su prikazane značajke inventara klizišta, odnosno klizišta kartiranih na pilot području površine 21 km^2. Dobiveni inventar klizišta provjeren je inženjerskogeološkom prospekcijom dijela kartiranih klizišta te je uspoređen s dostupnim povijesnim inventarima klizišta.

U sedmom poglavlju (Model za automatizirano kartiranje klizišta na temelju LiDAR DMT-a) opisan je razvoj modela za automatizirano kartiranje klizišta iz LiDAR DMT-a. Prvi korak izrade modela za automatizirano kartiranje klizišta je statistička analiza izvedenih morfometrijska karata s obzirom na vizualno kartirana klizišta na testnom području površine 10,5 km^2 te definiranje morfometrijskih parametara. Drugi korak izrade modela je primjena različitih metoda zbrajanja predikcijskih karata i reklasifikacija konačne karte inventara klizišta. Karta inventara klizišta dobivena modelom za automatizirano kartiranje klizišta verificirana je na preostalom dijelu pilot područja površine 10,5 km^2.

U osmom poglavlju (Validacija modela za automatizirano kartiranje klizišta) analizirani su preduvjeti klizanja, odnosno kvantificiran je utjecaj pojedinih klasa faktorskih karata na pojavu klizanja na pilot području (21 km^2) u podsljemenskoj zoni Grada Zagreba na temelju inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a i inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta. Primjenom bivarijantne statističke metode izvedene su karte podložnosti na klizanje koje su potom uspoređene na temelju ROC krivulja. Usporedbom izvedenih karata podložnosti na klizanje analizirana je mogućnost primjene automatizirano kartiranih klizišta za izradu prognostičkih karata hazarda klizanja.

U devetom poglavlju (Diskusija) iznesen je kritički osvrt na ostvarene rezultate istraživanja, i to prvenstveno na one koji se odnose na potvrdu hipoteza disertacije. Raspravlja se o

učinkovitosti i ograničenjima primijenjene metode vizualne interpretacije digitalnog modela reljefa visoke rezolucije za kartiranje klizišta na području podsljemenske zone Grada Zagreba. Također, raspravlja se o rezultatima statističkih analiza i modelu razvijenom za automatizirano kartiranje klizišta s naglaskom na točnost dobivenih rezultata i ograničenja razvijene metode te mogućnost daljnje primjene.

U desetom poglavlju (Zaključak) izneseni su svi zaključci koji su proizašli iz rezultata istraživanja i njihove interpretacije. Posebno su istaknuti ostvareni znanstveni doprinosi, metodološki doprinosi u kartiranju klizišta te doprinosi kao prilog poznavanju pojave klizišta i preduvjeta klizanja u podsljemenskoj zoni Grada Zagreba.

2 TEORIJSKE OSNOVE

Sadržaj ovog poglavlja ima za cilj definirati osnovne pojmove vezane za pojavu i klasifikaciju klizišta te ukratko opisati metode i tehnike koje se danas koriste za izradu karata klizišta. Inventar klizišta je prva u nizu karata klizišta koju je potrebno izraditi kako bi se uvidjela prostorna distribucija i tipovi klizišta na nekom području, istražili preduvjeti i inicijatori klizanja, a sve u svrhu izrade karata podložnosti, hazarda i rizika od klizanja. Jedna od najčešće korištenih metoda daljinskih istraživanja za izradu inventara klizišta je lasersko skeniranje iz zraka, te je ukratko objašnjena sama tehnologija i postupak obrade oblaka točaka. Osim vizualne interpretacije klizišta na LiDAR DMT-u, u posljednjih nekoliko godina razvijaju se modeli za automatizirano kartiranje klizišta, a sve u svrhu bržeg i učinkovitijeg kartiranja klizišta na većem području. Uz pregled postojećih metoda za vizualno i automatizirano kartiranje klizišta primjenom LiDAR DMT-a, ukratko su navedene i teorijske osnove izrade karata podložnosti na klizanje.

2.1 Pojave klizišta i inventari klizišta

Cruden (1991) razlikuje pet osnovnih mehanizama klizanja, a to su klizanje (u užem smislu), tečenje, odronjavanje, prevrtanje i razmicanje (Varnes, 1978; Cruden & Varnes, 1996; Hungr et al., 2001; Hungr et al., 2014). Nomenklaturu za klasifikaciju tipova klizišta definirao je Varnes (1978), a temelji se na različitim mehanizmima pokreta i vrsti materijala (stijena, debris, tlo). Dopunu Varnesove klasifikacije klizišta objavili su Hungr et al. (2014). Radna skupina Međunarodnog udruženja geotehničara, sponzorirana od strane UNESCO-a (*International Geotechnical Society's UNESCO Working Party on World Landslide Inventory*), izdala je seriju priručnika s uputama za izradu Svjetskog inventara klizišta (WP/WLI 1990, 1991, 1993a, 1993b, 1994, 1995). Navedeni priručnici sadrže korisnu metodologiju za izradu izvješća o klizištima, te opis uzroka klizanja, aktivnosti klizišta i brzine gibanja.

Gibanje klizišta na padini rezultira stvaranjem zone usijedanja koja predstavlja područje klizišta sniženo u odnosno na originalnu površinu terena te nastankom zone akumulacije, odnosno područja klizišta izdignutog u odnosu na originalnu površinu terena. Glavni dijelovi klizišta su glavna pukotina, bokovi i stopa klizišta, kojima je ujedno definirana i granica klizišta na površini terena, te ploha sloma, odnosno klizna ploha koja predstavlja granicu između pokrenutog i nepokrenutog materijala u podzemlju. Svi dijelovi klizišta prikazani su na slici 2.1a, a dimenzije klizište na slici 2.1b. Prilikom opisa klizišta vrlo često se definira i dubina, površina i volumen klizišta, a terminologija za opis navedenih značajki dana je u tablici 2.1.

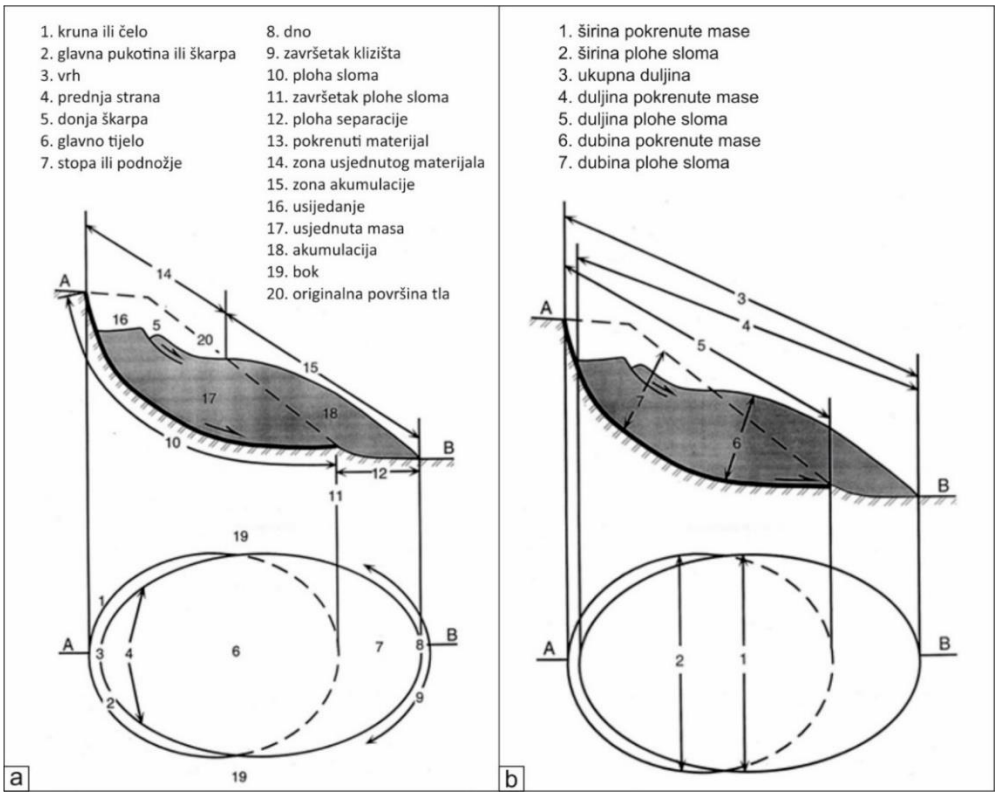

Slika 2.1 Terminologija vezana za opis klizišta (WP/WLI, 1993b): (a) dijelovi klizišta; (b) dimenzije klizišta.

Tablica 2.1 Terminologija za opis klizišta s obzirom na dubinu, površinu i volumen klizišta.

Klasifikacija klizišta s obzirom na dubinu do klizne plohe (IPL, 2013)		
klasa	dubina klizišta	opis
1	< 1 m	površinsko
2	1-5 m	plitko
3	5-20 m	srednje plitko
4	20-50 m	srednje duboko
5	50-100 m	duboko
6	100-500 m	vrlo duboko
7	>500 m	ekstremno duboko
Klasifikacija klizišta s obzirom na površinu (van Schalkwayk i Thomas, 1991)		
klasa	površina klizišta	opis
1	$0,01 – 10^1$ m^2	vrlo mala
2	10^1-10^3 m^2	mala
3	10^3-10^5 m^2	srednje veliko
4	10^5-10^6 m^2	veliko
5	> 10^6 m^2	vrlo veliko
Klasifikacija klizišta s obzirom na volumen klizišta (IPL, 2013)		
klasa	volumen klizišta	opis
1	< 10^3 m^3	vrlo mali
2	10^3-10^4 m^3	mali
3	10^4-10^5 m^3	umjereno mali
4	10^5-10^6 m^3	mjereno velik
5	10^6-10^7 m^3	velik
6	10^7-10^8 m^3	vrlo velik
7	> 10^8 m^3	ekstremno velik

Uzročnici (faktori) klizanja se mogu klasificirati na preduvjete klizanja, koji padinu čine podložnom na klizanje, odnosno dovode padinu u stanje granične ravnoteže, i inicijatore klizanja, koji padinu iz granično stabilnog stanja dovode u aktivno nestabilno stanje, odnosno iniciraju pokretanje klizišta (slika 2.2). Najčešće je pokretanje klizišta inicirano samo jednim procesom, dok je predisponirano brojnim preduvjetima i procesima. Klizanje mogu inicirati intenzivne i/ili dugotrajne oborine ili naglo otapanje snijega koji uzrokuju saturaciju padine i povećanje razine podzemne vode, nagli pad razine vode u vodotocima nakon poplava, podizanje razine vode u akumulacijama, ili erozija padine uzrokovana porastom razine vode u vodotocima i jezerima. Osim navedenih fizičkih procesa, klizanje mogu inicirati i potresi. U posljednjih nekoliko desetljeća, osobito u urbanim sredinama, mnoga klizišta su posljedica antropogenih aktivnosti, kao što su: iskopi na padini ili u njezinoj nožici, opterećenje padine ili njezinih vršnih dijelova, loše održavanje drenažnih sustava, procjeđivanje iz komunalne infrastrukture (npr. kanalizacije, vodovoda), odstranjivanje vegetacije (odšumljavanje), odlagališta rahlog otpada te umjetne vibracije (zbog prometa, teških strojeva itd.).

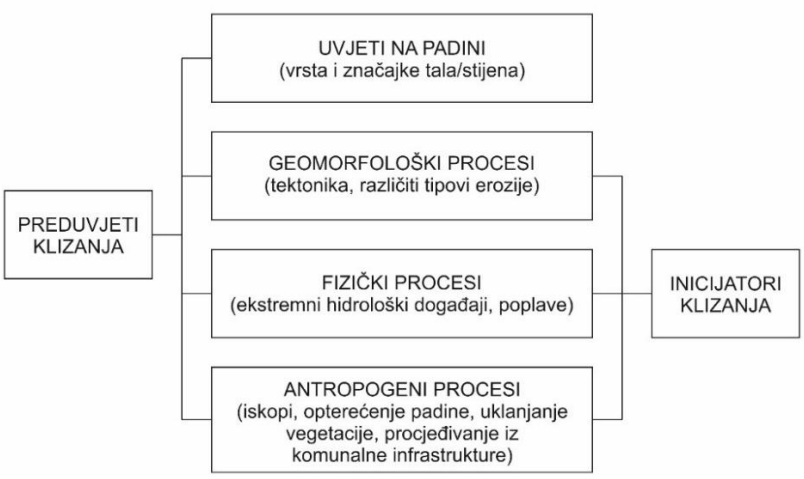

Slika 2.2 Uzročnici (faktori) klizanja (modificirano prema Popescu, 2002).

Prema Guzzetti et al. (2000) karte klizišta se mogu podijeli na tri skupine: inventari klizišta (engl. *landslide inventory map*), karte gustoće klizišta (engl. *landlide density maps*) i karte hazarda klizanja (engl. *landslide hazard maps*). Inventari klizišta prikazuju područja na kojima se dogodilo klizanje (Pašek, 1975; Hansen, 1984; McCalpin, 1984; Wieczorek, 1984; Guzzetti et al., 2000), karte gustoće klizišta prikazuju prostornu distribuciju klizišta (DeGraff, 1985), a karte hazarda predstavljaju prognozne karte koje prikazuju stupanj podložnosti, hazarda ili rizika od klizanja na nekom području (Corominas et al., 2013).

Prema Highland i Bobrowsky (2008) inventari mogu biti: (i) jednostavni, ukoliko prikazuju samo prostorni položaj klizišta, odnosno granicu klizišta na površini terena ili; (ii) detaljni gdje je svako klizište okontureno, te je za njega opisan tip pokreta, aktivnost, brzina gibanja, geološka starost naslaga, dubina klizanja i materijali koji su zahvaćeni klizanjem, a na karti je prikazana glavna pukotina, zona usijedanja i zona akumulacije.

Klizišta su najčešće izolirane pojave koji ne moraju biti veliki površinom, ali se mogu pojaviti u velikom broju na nekom području, odnosno mogu biti gusto raspoređene. Za razliku od drugih geohazarada, kao što su potresi i poplave, izrada inventara klizišta je zahtjevan postupak. Naime, popunjavanje baze o klizištima uključuje kartiranje i opis jednog po jednog klizišta kroz vrlo dugačko vremenske razdoblje, a to u većini zemalja radi više državnih agencija nadležnih za upravljanje određenim dobrima koja su ugrožena klizištima. Na primjer, arhiviranje podataka o klizištima koja ugrožavaju prometnice je u nadležnosti nekoliko agencija zaduženih za upravljanje cestama na državnoj ili na lokalnoj razini, koje izrađuju baze podataka klizišta samo s podacima o klizištima uz prometnice iz svoje nadležnosti. Novinski članci i različite arhive najčešće zabilježe samo ona klizišta koja su uzrokovala veću materijalnu štetu ili ljudske gubitke. Sveučilišta i instituti provode projekte vezane za izradu detaljnih inventara klizišta na nekom području ali te karte klizišta se rijetko sustavno dopunjavaju nakon isteka projekata. Identifikacija i kartiranje klizišta na avionskim ili satelitskim snimkama omogućava izradu potpunih inventara za različita vremenska razdoblja Guzzetti et al. (2012), ovisno o raspoloživim snimkama. Nedostatak ovih inventara, je što je je točan datum aktiviranja svakog pojedinog klizišta i dalje nepoznat, a samim time je i nemoguće povezati pojave klizišta i procese klizanja s događajem koji ih je inicirao (npr. oborinski događaj). Kako bi se izradile pouzdane karte klizišta za procjenu podložnosti, hazarda i rizika od klizanja, nužno je izraditi inventar koji je potpun, i prostorno i vremenski (Glade, 2001; van Westen et al., 2008), odnosno koji sadrži lokaciju i datum aktiviranja svih klizišta koja su se aktivirala u nekom vremenskom razdoblju.

Prilikom izrade inventara klizišta, kartirana klizišta se najčešće klasificiraju prema klasifikacijama iz Varnes (1978), WP/WLI (1990), i Cruden & Varnes (1996), Hungr et al., 2014 ili prema pojednostavljenim verzijama navedenih klasifikacija. Klizišta se vrlo često za potrebe karata inventara klizišta klasificiraju kao plitka (engl. *shallow landslides*) ili duboka klizišta (engl. *deep-seated landslides*), ovisno tipu klizanja i procijenjenom volumenu. Procjena volumena klizišta je često vrlo problematična (Brunetti et al., 2009) i procjenjuje se s obzirom na tip klizanja, te morfologiju i geometriju zone akumulacije i zone depresije. Prilikom

kartiranja velikih, dubokih klizišta, vrlo često se čelo klizišta ili zone depresije, kartiraju odvojeno od pokrenutog dijela klizišta ili zone akumulacije. Starost klizišta, stanje aktivnosti, dubina i brzina klizanja se mogu procijeniti iz mehanizma gibanja, morfoloških karakteristika klizišta te izraženosti klizišta na snimku (npr. avionski ili satelitski snimci, karta osjenčanog reljefa izvedena iz digitalnog modela), lokalnih litoloških i strukturnih značajka, te iz datuma snimka (Antonini et al., 2002; Fiorucci et al., 2011). Starost klizišta se najčešće opisuje relativno, odnosno pojmovima recentna, stara i vrlo stara klizišta s obzirom na izraženost klizišta na snimcima (McCalpin, 1984; Petschko et al., 2015). Iako, recentna klizišta na umjetnim i poljoprivrednim površinama, vrlo često uslijed građevinskih zahvata ili obrađivanja zemljišta ne moraju imati karakterističnu morfologiju klizišta i izraženost na snimcima (Bell et al., 2012).

Prema Guzzetti et al. (2012) prilikom izrade inventara klizišta usvajaju se slijedeće pretpostavke: (a) klizišta ostavljaju vidljive morfološke oblike na površini terena koji se mogu prepoznati terenskim kartiranjem, ili interpretacijom avionskih stereoparova, satelitskih snimaka ili digitalnog modela terena; (b) morfološki oblik klizišta ovisi o mehanizmu klizanja (npr. odron, tečenje, klizanje, kompleksno klizanje itd.) i brzini klizanja, a općenito govoreći, isti mehanizam klizanja rezultirat će sličnim morfološkim oblikom; (c) klizišta se ne pojavljuju nasumično, već su rezultat fizičkih procesa i svojstva materijala koji uvjetuju stabilnost padine; (d) za klizišta se može usvojiti načelo "prošlost i sadašnjost su ključ budućnosti" (Varnes, 1984).

Karte inventara klasificiraju se s obzirom na mjerilo i metodu kartiranja (Guzzetti et al., 2000; Galli et al., 2008). Inventari sitnog mjerila, tzv. sinoptički inventari (> 1:200.000) izrađuju se na temelju podataka o klizištima dobivenih iz stručne i znanstvene literature, javnih ustanova, novina, tehničke dokumentacije ili intervjuiranjem stručnjaka za klizišta (Reichenbach et al., 1998; Salvati et al., 2009), iako postoje i primjeri inventara klizišta sitnog mjerila izrađenih vizualnom interpretacijom avionskih snimaka (Cardinali et al., 1990). Inventari srednjeg mjerila (1:25.000-1:200.000) najčešće se izrađuju interpretacijom avionskih snimaka mjerila 1:60.000 do 10.000, korištenjem povijesnih podataka i terenskom provjerama (Cardinali et al., 2001; Duman et al., 2005). Inventari krupnog mjerila (<1:25.000) izrađuju se najčešće za manja područja interpretacijom avionskih snimaka mjerila 1:20.000 ili krupnijih, satelitskih snimaka ili digitalnih modela terena visoke rezolucije, te opsežnim terenskim kartiranjem (Van Den Eeckhaut et al., 2007; Fiorucci et al., 2011). S obzirom na metodu kartiranja, inventari mogu biti klasificirani kao arhivski inventari, ukoliko prikazuju podatke o klizištima prikupljene iz literature, novina ili drugih arhivskih izvora i geomorfološki inventari ako su izrađeni

primjenom metode terenskog kartiranja ili neke od metoda daljinskih istraživanja (Guzzetti et al., 2012). Geomorfološki inventari mogu biti povijesni (prikazuju klizišta aktivirana u posljednjih deset, stotinu ili tisuću godina), inventari pojedinog događaja (prikazuju klizišta aktivirana npr. potresom, oborinskim događajem i sl.), sezonski (prikazuje klizišta aktivirana tijekom jedne sezone) ili inventari određenog vremenskog razdoblja (prikazuju klizišta aktivirana tijekom nekoliko sezona ili godina). U povijesnim geomorfološkim inventarima, starost klizišta je opisana relativno, kao recentno, staro ili vrlo staro klizište, dok je za inventare pojedinog događaja i sezonske inventare starost klizišta određena s obzirom na događaj koji je aktivirao klizišta. Starost klizišta u inventarima određenog vremenskog razdoblja određena je s obzirom na događaje koji su aktivirali klizišta ili starost snimaka na temelju kojih su klizišta identificirana i kartirana.

Kvaliteta inventara klizišta, odnosno točnost karata nije jasno definirana i ne postoje standardi kvalitete (Galli et al., 2008), ali ona se može iskazati kao cjelovitost, odnosno potpunost inventara (engl. *completeness of the inventory map*) te kao geografska i tematska ispravnost podataka prikazanih na karti. Potpunost inventara se odnosi na omjer klizišta prikazanih u inventaru i stvarnog broja (u većini slučajeva nepoznat broj) klizišta na nekom području, a najčešće je povezana s površinom najmanjih klizišta koja nisu konzistentno kartirana u okviru inventara (Guzzetti et al., 2012). Geografska točnost podrazumijeva podudarnost između grafičke prezentacije granice klizišta u inventaru i položaja, veličine i oblika istog klizišta na terenu (Santangelo et al., 2010), dok se tematska točnost odnosi na niz dodatnih informacija kojima je pojedino klizište opisano (npr. mehanizmu klizanja, procijenjena starost, dubina klizanja itd.) Osim navedenog, točnost inventara klizišta ovisi o slijedećim faktorima: (i) mjerilu, datumu i kvaliteti avionskog snimka, ili rezoluciji digitalnog modela terena, ili karakteristikama satelitskog snimka; (ii) vrsti, mjerilu i kvaliteti podloge koja se koristi za prikaz karte klizišta; (iii) alatu koji se koristi prilikom analize i interpretacije snimaka, uključujući stereoskope i računalne programe za 3D vizualizaciju; (iv) vještini i iskustvu osobe koja interpretira klizišta. Van Den Eeckhaut et al. (2005) utvrdili su kako poznavanje klizišta na istraživanom području i iskustvo kartiranja klizišta na karti osjenčanog reljefa izvedenoj iz digitalnog modela utječe na potpunost i točnost konačnog inventara klizišta.

Prilikom detaljnih istraživanja, klizišta se najčešće kartiraju kao poligoni, odnosno istraživač na terenu ili na snimku visoke rezolucije identificira pojedine dijelove klizišta te s obzirom na izraženu morfologiju interpretira granicu klizišta. Za potrebe karte inventara koje se koriste za analizu podložnosti na klizanje, klizišta se vrlo često kartiraju kao točka, npr. točka u središtu

klizišta ili na glavnoj pukotini (Atkinson et al. 1998; Beguería 2006; Van Den Eeckhaut et al. 2006; Felicísimo et al. 2012). Petschko et al. (2015) kartirali su klizišta vizualnom interpretacijom LiDAR DMT-a, te su utvrdili kako je iscrtavanjem poligona moguće iskartirati područje površine 518 km^2 po istraživaču u mjesec dana, odnosno 17 km^2 u jednom danu, a ukoliko se klizišta kartiraju samo jednom točkom moguće je iskartirati 1.382 km^2 po istraživaču u mjesec dana, odnosno 46 km^2 u jednom danu. Prednost kartiranja klizišta samo točkom je mnogostruko veća brzina kartiranja, odnosno moguće je iskartirati višestruko veća područja u relativnom kratkom vremenskom razdoblju, no nedostatak ovakvog pristupa je da se ne uzima u obzir doseg klizišta prilikom izrade karte podložnosti na klizanje.

2.2 Pregled metoda istraživanja i kartiranja inventara klizišta

Karte inventara klizišta mogu se izraditi korištenjem različitih tehnika, a izbor ovisi o namjeni karte klizišta, veličini istraživanog područja, mjerilu dostupnih topografskih podloga, zatim o mjerilu, rezoluciji i svojstvima dostupnih snimaka, vještini i iskustvu istraživača, ali i o raspoloživim financijskim sredstvima. Podloge dobivene daljinskim metodama istraživanja koje se najčešće primjenjuju prilikom izrade inventara klizišta su avionske snimke, optičke, termalne i mikrovalne radarske snimke te podaci dobiveni laserskim skeniranjem (Van Westen et al., 2008; Guzzetti et al., 2012; Scaioni et al., 2014.).

Metode istraživanja koje se primjenjuju za izradu karte inventara klizišta prikazane su u tablici 2.2, a mogu se podijeliti na nekoliko grupa (Van Westen et al., 2008; Guzzetti et al., 2012): (i) vizualna interpretacija snimaka (ii), (polu)automatizirana klasifikacija snimaka na temelju spektralnih svojstava, (iii) (polu)automatizirana klasifikacija snimaka na temelju topografskih svojstava, (iv) terenske metode istraživanja, (vi) prikupljanje povijesnih podataka, (vii) metode datiranja starosti klizišta, (viii) monitoring klizišta.

U praksi, interpretacija avionskih stereoparova je i dalje vrlo često korištena metoda za kartiranje klizišta (Guzzetti et al., 2012). Vizualna interpretacija klizišta na stereoskopskim snimcima zahtjeva visoku rezoluciju snimaka (Metternicht et al., 2005). Optički snimci rezolucije veće od 3 m (npr. SPOT, LANDSAT, ASTER, IRS-1D), kao i SAR (engl. *synthetic aperture radar*) snimci (RADARSAT, ERS, JERS, ENVISAT) pokazali su se vrlo korisni prilikom identifikacije velikih klizišta, za kartiranje granica pojedinačnih klizišta (Singhroy, 2005), ali ne i za kartiranje klizišta na većem području. Vizualna interpretacija klizišta pomoću digitalnog modela terena bez vegetacije dobivenog laserskim skeniranjem (skraćeno LiDAR

DMT) najčešće se provodi na karti osjenčanog reljefa koja omogućava detaljno kartiranje klizišta. Nekoliko istraživača usporedilo je inventar klizišta dobiven vizualnom interpretacijom klizišta na LiDAR DMT-u i inventare klizišta dobivene terenskim kartiranjem ili vizualnom interpretacijom avionskih stereoparova (Haugerud et al., 2003; Chigira et al., 2004; Schulz, 2004; Booth et al., 2009; Razak et al., 2011) te su ustvrdili kako je LiDAR DMT vrlo učinkovit i precizan alat za izradu potpunih inventara klizišta.

U posljednjih nekoliko godina razvijaju se modeli za automatizirano kartiranje klizišta na temelju spektralnih svojstava ili nadmorskih visina, ovisno o primijenjenoj metodi daljinskih istraživanja. Automatizirano kartiranje klizišta se provodi s obzirom na slijedeće karakteristike (Van Westen et al., 2008): (i) poremećena vegetacija ili odsustvo vegetacijskog pokrova s obzirom na okolni teren je glavno obilježje na temelju kojega se identificiraju klizišta na multi-spektralnim snimkama (Fernandez et al., 2008; Martha et al., 2010; Hölbling et al., 2015); (ii) karakteristike nagiba terena, odnosno lokalne promjene u nagibu, te konkavne pojave i karakteristični prekidi mogu ukazivati na klizište (Kasai et al., 2009); (iii) karakteristike površine, kao što su deformacijske strukture, vlačne pukotine, strma morfologija, konkavne i konveksne pojave, te povišena hrapavost terena omogućavaju prepoznavanje morfologije klizišta (Berti et al., 2012); (iv) karakteristike površinske drenažne mreže, kao što su poremećena drenažna mreža, zone povećane vlažnosti i lokalne promjene u vlažnosti, mogu ukazivati na klizišta na radarskim ili termalnim snimcima.

Terensko kartiranje omogućava visoku točnost ukoliko se prilikom kartiranja koristi GPS, ali ono nije primjenjivo na nepristupačnim terenima (npr. strmi tereni obrasli gustom vegetacijom), a uz to je vremenski zahtjevno i samim time skupo.

Arhivska istraživanja, metode datiranja i monitoring klizišta nisu primarne metode za identifikaciju i kartiranje klizišta za potrebe izrade inventara klizišta, ali omogućavaju prikupljanje korisnih podataka o kartiranim klizištima. Arhivska istraživanja omogućavaju nadopunjavanje inventara s povijesnim podacima kao što su datum aktiviranja klizišta, rezultati provedenih detaljnih istraživanja, broj žrtava, procijenjena šteta koju je klizište uzrokovalo, itd. Izravne i neizravne metode datiranja se koriste za određivanje relativne ili apsolutne starosti pojedinih klizišta, ali i za određivanje aktivnosti klizišta u prošlosti (npr. određivanje aktivnosti klizišta pomoću godova (Malik i Witsuba, 2012). Monitoring klizišta omogućava praćenje aktivnosti klizišta u realnom vremenu (Mihalić Arbanas i Arbanas, 2014), izradu prognostičkih modela (Krkač et al., 2017) i uspostavu sustava za rano upozoravanje.

Tablica 2.2 Prikaz tehnika za izradu inventara klizišta (prema van Westen et al., 2008).

Grupa	Tehnika	Opis	Mjerilo*			
			Regionalno	Srednje	Krupno	Detaljno
vizualna interpretacija snimaka	stereoparovi avionskih snimaka	vizualna interpretacija analognih ili digitalnih snimaka iz jednog ili više vremenskih razdoblja	S	V	V	V
	satelitske snimke visoke rezolucije	vizualna interpretacija analognih ili digitalnih, monoskopskih ili stereoskopskih snimaka iz jednog ili više vremenskih razdoblja	S	V	V	V
	osjenčana karta reljefa izvedena iz LiDAR DMT-a	vizualna interpretacija digitalnih snimaka terena bez vegetacije iz jednog ili više vremenskih razdoblja	N	S	V	V
	radarske snimke	vizualna interpretacija digitalnih snimaka iz jednog vremenskog razdoblja	N	S	S	S
(polu)automatizirano kartiranje na temelju spektralnih svojstava	avionske snimke	segmentacija snimaka, granične vrijednosti	S	V	V	V
	multi spektralne snimke srednje rezolucije	pikselna ili objektno orijentirana klasifikacija snimaka iz jednog vremenskog razdoblja	V	V	V	S
		pikselna ili objektno orijentirana klasifikacija snimaka iz više vremenskih razdoblja	V	V	V	S
	optički i radarski podaci	pikselno ili objektno orijentirana klasifikacija fuzije snimaka ili multisenzor snimaka	S	S	S	S
(polu)automatizirano kartiranje na temelju nadmorskih visina	InSAR (engl. Interferometric Synthetic-Aperture Radar)	analiza aktivnosti i gibanja klizišta primjenom InSAR tehnologije - radarska interferometrija na većim područjima	S	S	S	S
		analiza aktivnosti i gibanja klizišta primjenom PSInSAR (engl. *Persistent Scatterer Interferometric Synthetic-Aperture Radar*) tehnologije na urbaniziranim područjima	V	V	V	V
	LiDAR	preklapanje LiDAR DMT-a iz različitih vremenskih razdoblja	N	N	S	V
	fotogrametrija	preklapanje DMT-a dobivenih iz avionskih ili satelitskih snimaka visoke rezolucije iz različitih vremenskih razdoblja	N	S	V	V
terenske metode istraživanja	terensko kartiranje	geomorfološko kartiranje	S	V	V	V
		geomorfološko kartiranje korištenjem mobilnog GIS-a i GPS-a za prikupljanje atributa baze klizišta	N	V	V	V

Nastavak **tablice 2.2** Prikaz tehnika za izradu inventara klizišta (prema van Westen et al., 2008)

Grupa	Tehnika	Opis	Mjerilo*			
			Regionalno	Srednje	Krupno	Detaljno
arhivska istraživanja	intervjui	korištenje upitnika i organizacija radionica	N	S	V	V
	novinski članci	proučavanje starih novinskih članaka, knjiga i drugih arhiva	V	V	V	V
	organizacije za održavanje prometnica	informacije iz dnevnika održavanja prometnica s mogućim napomenama o uzročnicima klizanja	N	S	V	V
	vatrogasci/policija	pretraživanje pojava klizanja na temelju službenih zapisnika	N	S	V	V
metode datiranja za klizišta	izravne metode datiranja	određivanje starosti klizišta primjenom dendrokronologije, metode datiranja pomoću radioaktivnog izotopa ugljika itd.	N	N	N	S
	neizravne metode datiranja	određivanje starosti klizišta primjenom palinološke analize i drugih neizravnih metoda datiranja	N	N	N	V
monitoring klizišta	ekstenzometri	praćenje gibanja klizišta korištenjem ekstenzometara, površinskih tiltmetara, inklinometara i piezometara	-	-	N	V
	geodetska mjerenja	analiza aktivnosti usporedbom klasičnih geodetskih mjerenja, redovito ponavljanje mjerenja	-	-	N	V
	GPS	analiza aktivnosti usporedbom GPS mjerenja, redovito ponavljanje mjerenja	-	-	N	V
	totalna stanica	analiza aktivnosti usporedbom teodolitnih mjerenja, redovito ponavljanje mjerenja	-	-	N	V
	terestrički InSAR	analiza aktivnosti preklapanjem oblaka točaka dobivenog terestričkog InSAR-a, redovito ponavljanje mjerenja	-	-	N	V
	terestrički LiDAR	analiza aktivnosti preklapanjem oblaka točaka dobivenog terestričkim LiDAR-om, redovito ponavljanje mjerenja	-	-	N	V

*Stupanj primjenjivosti svake tehnike na pojedino mjerilo istraživanja: V-visok stupanj primjenjivosti, S-srednji stupanj primjenjivosti, N-nizak stupanj primjenjivosti.

2.3 Lasersko skeniranje iz zraka i izrada LiDAR DMT-a

Tehnologija laserskog skeniranja je potpuno automatiziran, aktivan, optičko-mehanički postupak prikupljanja prostornih podataka dostupnih s određenih točaka snimanja. LiDAR (engl. *Light Detection and Ranging*) je skraćenica koja se koristi za 3D lasersko skeniranje, odnosno postupak snimanja objekata korištenjem preciznog uređaja, laserskog skenera koji radi na principu odašiljanja laserskih zraka prema objektu te mjeri njihovu refleksiju od objekta. LASER (engl. *Light Amplification by Stimulated Emission of Radiation*) je naziv za optičku napravu koja emitira koherentni snop fotona. Laserska zraka odaslana iz mjernog instrumenta kreće se brzinom svjetlosti te se reflektira od objekta snimanja i vraća natrag do mjernog instrumenta. Kombinacija izmjerene udaljenosti i kuta s određenog stajališta daje koordinate tražene točke u 3D prostoru. Rezultat ovakvog načina snimanja je skup trodimenzionalnih XYZ točaka koji se naziva oblak točaka (engl. *point cloud*). Primjer oblaka točaka prikazan je na slici 2.3. Rezolucija snimanja definira se kao prostorna udaljenost između susjednih snimljenih točaka unutar oblaka točaka pa je s današnjim laserskim skenerima moguće dobiti točke koje su međusobno udaljene samo jedan milimetar (Golek et al., 2012). Osim 3D koordinata točaka objekta, laserskim skeniranjem dobiva se i amplituda povratnog laserskog signala, odnosno intenzitet signala. Svaka boja reflektira lasersku zraku drugačijim intenzitetom, tako da npr., bijela mat boja daje 80-postotni povratak signala, siva mat boja 40-postotni povratak signala, dok crna mat boja daje 5-postotni povratak signala. Uz intenzitet signala, laserski skeneri mogu prikupiti RGB (engl. *Red Green Blue*) komponentu za svaku točku koja se dobije integriranjem unutarnje ili vanjske kamere. Na temelju kalibracije i orijentacije kamere te njezinog položaja u odnosu na skener, slikovni zapis kamere upotrebljava se kako bi se svakoj izmjerenoj točki dodijelila RGB vrijednost.

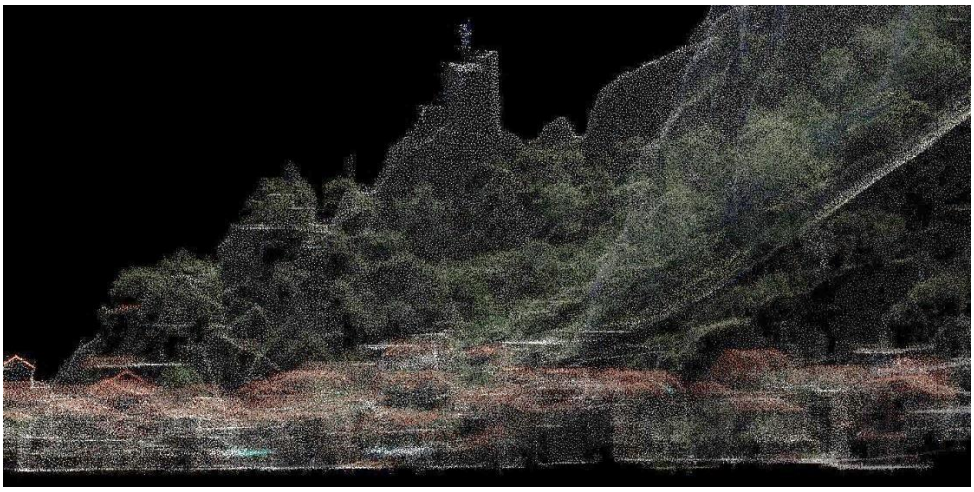

Slika 2.3 Prikaz oblaka točaka dobivenog laserskim skeniranjem kosine iznad grada Omiša.

Tehnologija prostornog skeniranja dijeli se na lasersko skeniranje sa zemlje (engl. *Terrestrial Laser Scanning, TLS*) i lasersko skeniranje iz zraka (engl. *Airborne Laser Scanning, ALS*). Princip laserskog skeniranja iz zraka je da se područje koje je predmet izmjere nadlijeće avionom ili nekom drugom letjelicom, koja s donje strane ima pričvršćen skener (Gajski, 2007). Ovisno o vidnom kutu skenera (engl. *Field of View, FOV*) i visini leta tijekom jednog preleta moguće je izmjeriti pojas odgovarajuće širine, tj. jedan niz. Uobičajena visina leta aviona prilikom laserskog skeniranja je oko 900 m. Cijelo se područje prema potrebi nadlijeće više puta kako bi se snimilo s potrebnim brojem nizova. Između nizova se ostavlja preklop da se osigura prekrivanje cjelokupnog područja izmjere i izjednačenje svih nizova visinski i položajno.

Prostorne koordinate svake izmjerene točke određuju se polarnom metodom (slika 2.4). Prostorni položaj pola skenera određuje se pomoću inercijalnog mjernog sustava (engl. *Inertial Measuring Unit - IMU*) koji je integriran u laserski skener (LS). IMU mjeri kutne komponente (ω, φ, κ) referentne osi LS $(\overrightarrow{r_{LS}})$ u prostoru. Otklon laserske zrake od referentne osi laserskog skenera određuje uređaj za skeniranje i time je definirano hvatište i smjer vektora $\vec{r}_{LS}$, a duljina se mjeri laserskim daljinomjerom. Budući da je laserski skener smješten na donjoj stani letjelice , a GPS antena mora biti na gornjoj strani, potrebno je odrediti i vektor $\vec{r}_{CAL}$, čije hvatište je u centru GPS antene, a vrh u polu skenera. ALS sustav se sastoji od tri komponente, GPS-a, IMU-a i laserskog skenera, s time da su GPS i IMU kod većine proizvođača integrirani u tzv. POS (engl. *Position and Orientation System*), a čime je omogućeno izravno georeferenciranje mjerenih podataka. Laserski skener se sastoji od impulsnog lasera, mehanizma za skeniranje i prijemnog senzora sa sklopom za mjerenje vremena putovanja laserskog impulsa. Današnji laseri odašilju impulse vrlo visoke frekvencije (do 250.000 impulsa u sekundi). Mehanizam za skeniranje otklanja lasersku zraku od referentne osi laserskog skenera tako da se omogući izmjera što šireg područja sa što gušćim rasporedom točaka u jednom preletu. Plošno prekrivanje terena omogućavaju različite konstrukcije skenera, a najčešće se upotrebljavaju skeneri s njišućim zrcalom, skener s rotirajućom prizmom i skener s optičkim vlaknima (Gajski, 2007). Laserska zraka se divergira od 0,3 do 2 mrad (Wehr i Luhr, 1999) što omogućava da dio laserskih zraka prođe kroz vegetaciju do terena i reflektira se natrag do senzora. Količina reflektiranog zračenja ovisi o intenzitetu laserskih zraka, kutu skeniranja te stupnju refleksije skeniranih objekata. Kod tamnih površina (npr. lava, svježi asfalt) prijemni senzor će zabilježiti vrlo mali broj reflektiranih zraka, dok je kod mirnih vodenih površina moguća totalna refleksija.

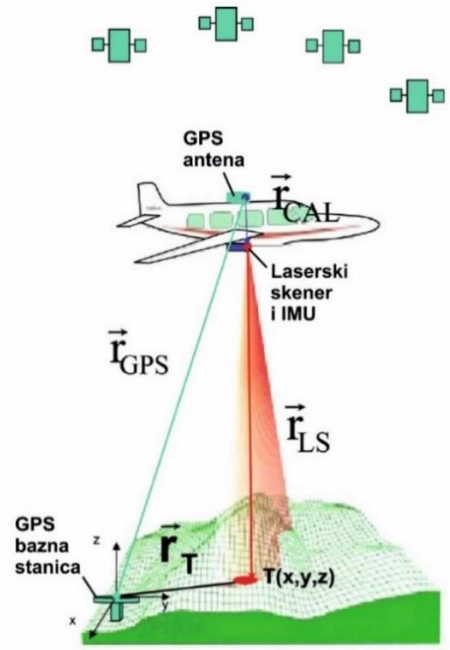

Slika 2.4 Osnovne komponente ALS sustava i princip određivanja prostornih koordinata (modificirano prema Gajski, 2007).

Tijekom leta, podaci se na svakom od senzora prikupljaju zasebno, najčešće u tzv. sirovom formatu. Objedinjavanje mjerenih podataka se stoga radi nakon leta i obuhvaća izravno georeferenciranje mjerenih podataka, izjednačenje nizova i kalibraciju ALS sustava, segmentaciju oblaka točaka, odnosno grupiranje prema geometrijskim karakteristikama. Podaci se nakon toga klasificiraju i filtriraju te na kraju, ukoliko je potrebno prorjeđuju (engl. *data thinning*).

Prethodna detaljna obrada LiDAR podataka je nužna kako bi se postigla određena razina kvalitete prije korištenja u posebne svrhe, kao što je izrada digitalnog modela terena za potrebe kartiranja klizišta. Dobivanje površine Zemlje (engl. *bare earth*) je jedan od ciljeva tijekom obrade LiDAR podataka. Digitalni model reljefa (DMR) upotrebljava se kao općeniti izraz za sve modele, digitalni model terena (DMT) najčešće se odnosi na fizičku površinu Zemlje (visinu stvarne površine), dok digitalni model površine (DMP) opisuje gornju plohu koja uključuje i visine vegetacije, izgrađenih i ostalih objekata na površini Zemlje. DMP stoga opisuje visine fizičke površine jedino u područjima gdje nema vegetacije i drugih objekata (Maune, 2007). Točnost DMT-a dobivenog laserskim skeniranjem ovisi o (Montealegre et al., 2015): 1) parametrima koji su uvjetovani vrstom skenera i postavkama samog leta, npr. uvjeti korištenja skenera, modela laserskog skenera, visine i brzine leta; 2) parametrima Zemljine površine, npr. topografije i pokrova zemljišta; i 3) klasifikaciji i filtriranju oblaka točaka, metodama interpolacije i rezoluciji. Postupak izrade digitalnog modela terena iz oblaka točaka

dobivenog laserskim skeniranjem iz zraka prikazan je dijagramom toka na slici 2.5. Obrada oblaka točaka uključuje klasifikaciju i filtriranje točaka dobivenih refleksijom laserskih zraka od objekata i površine terena. Klasifikacija oblaka točaka podrazumijeva razvrstavanje snimljenih točaka u klase (razrede) koje su uspostavljene i definirane od strane Američkog društva za fotogrametriju i daljinska istraživanja (engl. *The American Society for Photogrammetry & Remote Sensing, ASPRS*). Klase definirane ASPRS standardom navedene su u tablici 2.3.

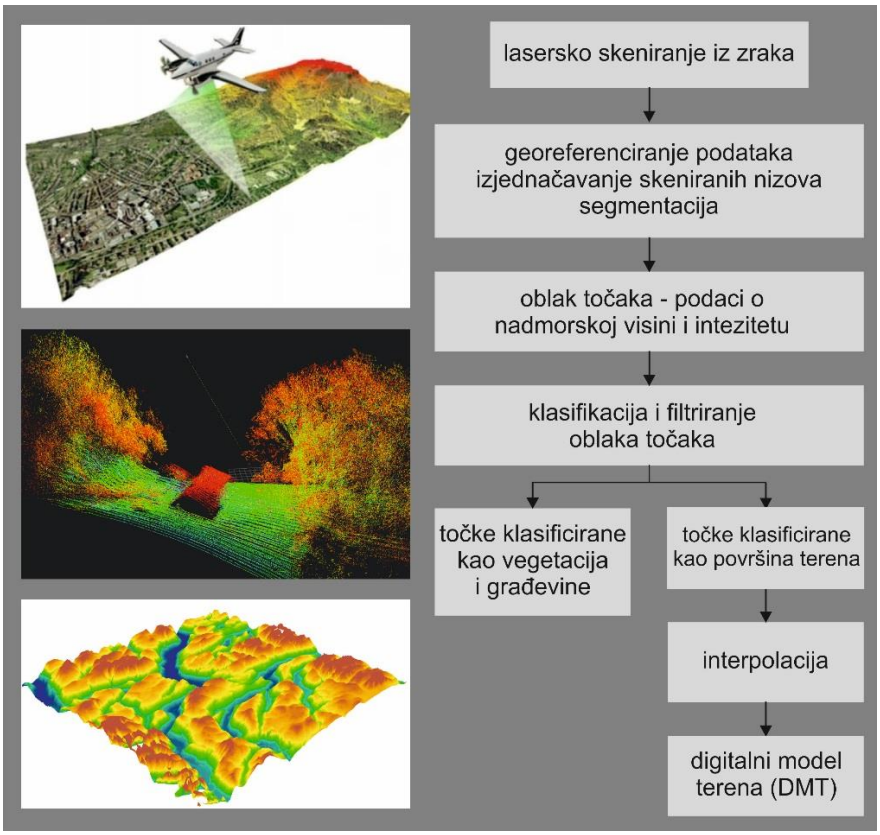

Slika 2.5 Dijagram toka izrade DMT-a iz podataka dobivenih laserskim skeniranjem iz zraka.

Tablica 2.3 ASPRS standard za klasifikaciju oblaka točaka dobivenog laserskim skeniranjem (ASPRS, 2013).

Klasa	Značenje
0	ne klasificira se
1	neklasificirano
2	teren
3	niska vegetacija
4	srednja vegetacija
5	visoka vegetacija
6	građevine
7	šumovi
8	karakteristične točke
9	vodene površine
10	rezervirano za ASPRS definiciju
11	rezervirano za ASPRS definiciju
12	točke koje se preklapaju (u slučaju spajanja dva ili više oblaka točaka)
13-31	rezervirano za ASPRS definiciju

Programi za filtriranje i klasifikaciju oblaka točaka zasnivaju se na usporedbi skeniranih točaka sa susjednim točkama (engl. *local neighbourhood*) u oblaku. Osnovni parametri koji se koriste kako bi se klasificirao oblak točaka su visinska razlika (Axelsson, 2000), kut nagiba (Vosselman, 2000), površinska zakrivljenost (Evans & Hudak, 2007) i intenzitet (Bao et al., 2008). Na primjer, točka je klasificirana kao teren, klasa 2 prema ASPRS standardu, ukoliko vrijednost parametra za skeniranu točku ne prelazi zadanu graničnu vrijednost u odnosu na okolne točke. Prilikom postupka filtriranja i klasifikacije oblaka točaka najveći problem predstavljaju guste šume na strmim terenima (Kobler et al., 2007, Bao et al., 2008). Razak et al. (2013) su utvrdili kako različite metode filtriranja, klasifikacije i interpolacije oblaka točaka utječu na točnost DMT-a, ali i na izraženost morfologije klizišta na DMT-u. Naime, prilikom interpolacije oblaka točaka najčešće se primjenjuju metode koje validacijom DMT-a s geodetski izmjerenim točkama imaju najmanju srednju kvadratnu pogrešku, no te metode najčešće ne daju najoptimalniji DMT za identifikaciju i kartiranje klizišta. Prema Razak et al. (2013) najoptimalniji DMT za identifikaciju i kartiranje klizišta daje metoda inverzne udaljenosti (engl. *inverse distance weighting*, *IDW*), dok su Chu et al. (2014) utvrdili kako DMT-a dobiveni kriging i TIN metodama interpolacije omogućavaju najpreciznije kartiranje glavne pukotine.

2.4 Identifikacija i kartiranje klizišta vizualnom interpretacijom LiDAR DMT-a

Tipovi klizišta koji se najčešće identificiraju i kartiraju na LiDAR DMT-u visoke rezolucije su velika rotacijska i kompleksna klizišta (Haugerud et al., 2003; Glenn et al., 2006; Van Den Eeckhaut et al., 2007; Booth et al., 2009; Kasai et al., 2009), plitka i duboka klizišta (Chigira et al., 2004; Ardizzone et al., 2007; Van den Eeckhaut et al., 2007; Kasai et al., 2009) te debritni tokovi (Haugerud et al., 2003). Kartiranje klizišta se pokazalo učinkovito na obrađenim površinama (Ardizzone et al., 2007) i šumskim područjima (Chigira et al., 2004; Van den Eeckhaut et al., 2007; Razak et al., 2011), ali i za identificiranje relativno starih klizišta (Haugerud et al., 2003; Chigira et al., 2004; Schulz, 2004, 2007; Van den Eeckhaut et al., 2007; Booth et al., 2009; Kasai et al., 2009) i recentnih klizišta (Chigira et al., 2004; Ardizzone et al., 2007). U okviru svojih disertacija Toševski (2018) i Đomlija (2018) primijenili su LiDAR DMT visoke rezolucije za kartiranje klizišta u Republici Hrvatskoj te su utvrdili kako je LiDAR DMT također pouzdan za kartiranje više različitih vrsta aktivnih geomorfoloških procesa na području Vinodolske udoline. Đomlija (2018) je izradila detaljan povijesni inventar različitih tipova klizišta, kojim su obuhvaćene pojave nastale procesima klizanja, tečenja, odronjavanja i prevrtanja, te inventar pojava erozije pri čemu je kartirana linijska, mješovita i plošna erozija.

Pregledom postojeće literature (tablica 2.4) može se zaključiti da je rezolucija DMT-a korištenih za identifikaciju i kartiranje klizišta prije desetak godina iznosila od 2 do 5 m (Ardizzone et al., 2007; Schulz et al., 2007; Van Den Eeckhaut et al., 2007), te da se s razvojem tehnologije laserskog skeniranja povećava, u posljednjih nekoliko godina najčešće se koristi DMT rezolucije od 1 m, pa sve do 0,3 m (Amundsen et al., 2010; Borkowski et al., 2011; Bell et al., 2012; Tarolli et al., 2012; Gorsevski et al., 2016; Petschko et al., 2015). Pomoću alata u GIS (engl. *Geographic Information System*) programima, iz digitalnog modela reljefa bez vegetacije mogu se izraditi mnogobrojne morfometrijske karte koje se koriste prilikom vizualne identifikacije i kartiranja klizišta. Najčešće korištene morfometrijske karte (slika 2.6) su karta osjenčanog reljefa, karta nagiba i karta izohipsi ekvidistancije 1 ili 2 m (Ardizzone et al., 2007; Schulz et al., 2007; Van Den Eeckhaut et al., 2007; Gorsevski et al., 2015; Petschko et al., 2015). Pomoć pri identifikaciji klizišta su i topografski profili (Schulz et al., 2007; McKenna et al., 2008), te karta zakrivljenosti (Amundsen et al., 2010; Miner et al., 2010), karta hrapavosti, karta orijentacije padine, karta vlažnosti terena i karta akumulacije toka (Miner et al., 2010). Identifikacija klizišta temelji se na prepoznavanju karakteristične morfologije klizišta, odnosno pojedinih dijelova klizišta kao što su glavna pukotina, konkavna zona depresije, te konveksna stopa klizišta. U okviru doktorske disertacije Đomlija (2018) je klasificirala morfometrijske

karata izvedene iz LiDAR DMT-a prema učinkovitosti za kartiranje pojedinih dijelova klizišta i to s obzirom na relativan stupanj izraženosti morfologije dijelova klizišta. Na primjer, karta profilne zakrivljenosti terena, karta topografske hrapavosti i karta nagiba su najučinkovitije za kartiranje čela vrlo jasno izraženih klizišta (Đomlija, 2018). Morfologija klizišta može biti jasno izražena ukoliko se radi o relativno recentnoj pojavi klizanja (slika 2.7a), i slabo izražena ako je klizište relativno staro ili ako je površina klizišta izmijenjena uslijed antropogenih aktivnosti, kao što su poljoprivreda, iskopavanje, nasipavanje, sanacija klizišta i sl. (slika 2.7b).

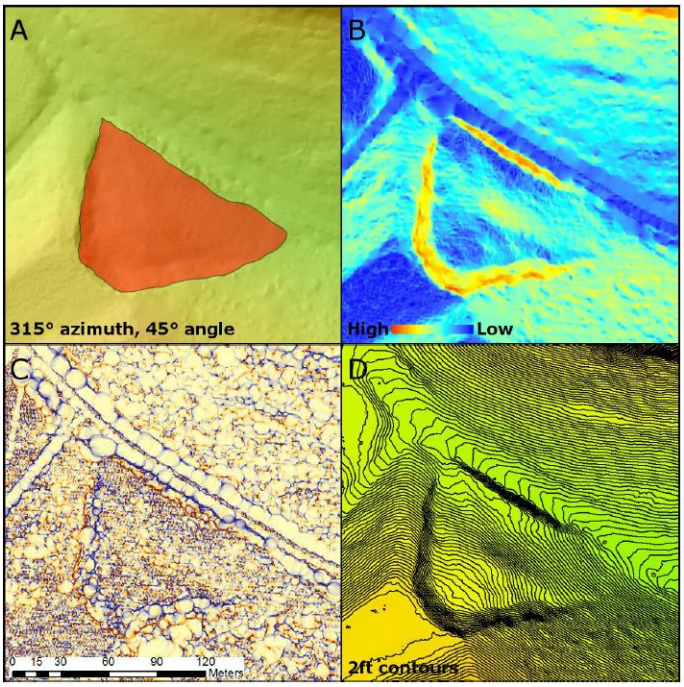

Slika 2.6 Primjeri morfometrijskih karata korištenih za izradu inventara klizišta (Amundsen et al., 2010): (a) karta osjenčanosti reljefa; (b) karta nagiba terena; (c); karta zakrivljenosti; (d) karta slojnica ekvidistance 2 ft=0,61 cm.

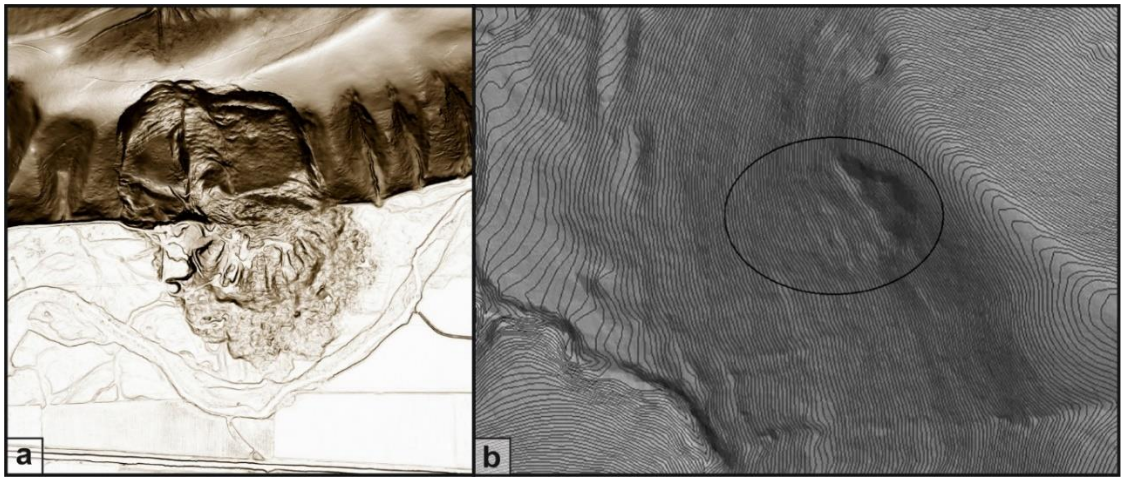

Slika 2.7 Primjeri izraženosti morfologije klizišta na karti osjenčanosti terena: (a) jasno izražena morfologija klizišta (Slaughter et al., 2017); (b) slabo izražena morfologija klizišta (Crawford et al., 2014).

Tablica 2.4 Pregled postojeće literature o vizualnoj identifikaciji i kartiranju klizišta primjenom LiDAR DMT-a s navedenom lokacijom područja istraživanja, rezolucijom korištenog DMT-a, korištenim morfometrijskim kartama i primijenjenom metodom kartiranja.

Autor	Istraživano područje	Rezolucija DMT-a	Morfometrijske karte
Ardizzone et al. (2007)	Umbria (Italija)	2 m	karta osjenčanog terena karta slojnica karta nagiba terena
Schulz (2007)	Seattle, Washington (SAD)	1,8 m	karta osjenčanog terena karta slojnica karta nagiba terena topografski profili
Van Den Eeckhaut et al. (2007)	Flemish Ardennes (Belgija)	5 m	karta osjenčanog terena karta izolinija
McKenna et al. (2008)	Kitsap County, Washington (SAD)	2 m	karta osjenčanog terena karta slojnica karta nagiba terena topografski profili
Amundsen et al. (2010)	Ohio i Northern Kentucky (SAD)	0,762 m	karta osjenčanog terena karta zakrivljenost terena karta slojnica karta nagiba terena
Miner et al. (2010)	Australija	1, 2, 5 m	karta osjenčanog terena karta profilne i planarne zakrivljenost terena karta nagiba terena karta orijentacije padine karta akumulacije toka karta vlažnosti karta hrapavosti terena
Borkowski et al. (2011)	Roznow Lake, Polish Carpathians (Poljska)	0,5 m	karta osjenčanog terena
Razak et al. (2011)	Barcelonnette Basin (Francuska)	0,25 – 6 m	karta raščlanjenosti terena
Van Den Eeckhaut et al. (2011)	Flemish Ardennes (Belgija)	2 m	karta osjenčanog terena karta slojnica
Bell et al. (2012)	Swabian Alb (Njemačka), Lower Austria (Austrija)	1 m	karta osjenčanog terena
Burns et al. (2012)	Lane, Lincoln, i Benton County (Oregon, SAD)	1 m	karta osjenčanog terena karta nagiba terena
Crawford et al. (2014)	Kenton i Campbell Counties, Kentucky (SAD)	1 m	karta osjenčanog terena karta slojnica
Petschko et al. (2015)	Amstetten, Baden i Waidhofen/Ybbs (Austrija)	1 m	karta osjenčanog terena karta slojnica karta nagiba terena
Toševski et al. (2018)	Vinodolska udolina	1 m	karta osjenčanog terena karta slojnica karta nagiba terena
Đomlija et al. (2018)	Vinodolska udolina	1 m	karta osjenčanog reljefa karta nagiba terena karta orijentacije padine karta slojnica karta hrapavosti terena karta planarne zakrivljenosti terena karta profilne zakrivljenosti terena karta inteziteta toka karta akumulacije toka

2.5 Automatizirano kartiranje klizišta na temelju morfometrijskih parametara izvedenih iz LiDAR DMT-a

U posljednjih petnaestak godina razvijaju se algoritmi za automatizirano kartiranje klizišta na temelju spektralnih podataka (Blaschke, 2010 i reference navedene u radu) i podataka o nadmorskim visinama (Tarolli et al., 2012; Berti et al., 2013; Li et al., 2015). Satelitske snimke omogućavaju automatizirano kartiranje samo recentnih klizišta koja su pokretanjem uzrokovala uništavanje ili oštećenje vegetacijskog pokrova. Suprotno tome, kartiranje klizišta na LiDAR DMT omogućava kartiranje recentnih, ali i relativno starih klizišta na svim terenima bez obzira na namjenu zemljišta (Van Den Eeckhaut et al., 2012). Iz toga razloga sve su češći modeli koji se temelje na automatiziranom kartiranju klizišta na temelju spektralnih i morfometrijskih parametara (Lu et al., 2011; Rau et al., 2012). Termin (polu)automatizirano kartiranje klizišta bi bio prikladniji zbog toga što proces kartiranja klizišta nije u potpunosti automatiziran, već je automatizirana samo klasifikacija izvedenih morfometrijskih karata s obzirom na granične vrijednosti definirane prethodnim statističkim analizama. Zbog jednostavnosti izražavanja, u disertaciji će se koristiti termin automatizirano kartiranje klizišta.

Automatizirano kartiranje klizišta provodi se pomoću pikselno orijentiranih analiza (engl. *pixsel based analysis*) i objektno orijentiranih analiza (engl. *object based analysis*). Pikselno orijentiranom metodom analiziraju se morfometrijske vrijednosti svakog pojedinog piksela (ćelije) na izvedenim morfometrijskim kartama LiDAR DMT-a (Berti et al., 2013), odnosno promjene u nadmorskoj visini svakog pojedinog piksela (ćelije) ukoliko se radi usporedba dviju generacija LiDAR DMT-a (Palenzuela et al., 2015). Primjenom objektno orijentirane analize prvo se provodi segmentacija rastera uzimajući u obzir morfometrijska svojstva DMT-a, tijekom koje se izvedene morfometrijske karte dijele u određeni broj homogenih skupina piksela, tzv. segmenata (Van Den Eeckhaut et al., 2012). Na taj način se izvedeni segmenti morfometrijskog parametra analiziraju umjesto pojedinih piksela te se klasificiraju na temelju definiranih graničnih vrijednosti, npr. na područja zahvaćena klizanjem i na područja bez klizišta. Većina pikselno i objektno orijentiranih metoda razvijene su za potrebe automatiziranog kartiranja pokrova ili namjene zemljišta iz satelitskih snimaka. Pregled metoda analize rasterskih snimaka i mogućnost primjene dana je u Hussain et al. (2013) i drugim referencama navedenim u ovom radu.

Kod pikselno orijentirane metode svaki piksel klasificiran je kao klizište ili teren bez klizišta ovisno o graničnoj vrijednosti morfometrijskog parametra. Granične vrijednosti određuju se

nekom od metoda klasifikacije u daljinskim istraživanjima (Paine i Kiser, 2012), a to mogu biti nadzirane klasifikacije (engl. *supervised classifications*) i nenadzirane klasifikacije (engl. un*supervised classifications*). Nadzirana klasifikacija se temelji na ideji da korisnik definira uzorak piksela na temelju kojeg algoritam klasificira sve preostale piksele nekog rastera u prethodno definirani broj klasa. Uzorci za treniranje algoritma te vrijednosti odstupanja pojedinih klasa definirane su iskustveno od strane korisnika. Nenadzirane klasifikacije provode se nekim od programa za analizu rastera bez prethodno definiranih uzoraka za pojedine klase. Korisnik definira u koliki broj klasa treba grupirati vrijednosti pojedinih piksela te koji od postojećih algoritama klasifikacije želi primijeniti za predmetnu analizu.

Primjenom objektno orijentirane analize, proces kartiranja klizišta bliži je ljudskoj percepciji identifikacije i kartiranja klizišta vizualnom interpretacijom LiDAR DMT-a, jer segmentirani uzorci predstavljaju stvarne prostorne jedinice, na LiDAR DMT-u odgovarajuće rezolucije (Goodchild et al., 2007). Prema Van Den Eeckhaut et al. (2012) objektno orijentirana metoda automatiziranog kartiranja klizišta se sastoji od nekoliko koraka: (1) karakterizacija morfometrijskih vrijednosti glavnih pukotina i područja zahvaćenih klizanjem primjenom metode strojnog učenja; (2) segmentacija terena na temelju morfometrijskih parametara; (3) klasifikacija segmenata i definiranje granica klizišta; (4) agregacija više segmenata klasificiranih kao klizište u jednu morfološku cjelinu (posebno za svaku glavnu pukotinu, odnosno klizište); (5) zaglađivanje (engl. *smoothing*) dobivenih poligona klizišta, ispuna nepotpunih poligona klizišta i uklanjanje izoliranih segmenata. Nedostatak objektno orijentirane analize je relativno složen proces automatiziranog kartiranja klizišta, odnosno veliki broj koraka tijekom modeliranja te zbog toga metoda nije primjenjiva za kartiranje različitih tipova klizišta na većim područjima (Van Den Eeckhaut et al., 2012), osobito na područjima sa složenom geološkom građom.

Prvi modeli za automatizirano kartiranje iz LiDAR DMT-a primjenjivani su samo za karakterizaciju morfologije i aktivnosti velikih pojedinačnih klizišta (McKean & Roering, 2004; Glenn et al., 2006), a kasnije su kartirana i veća područja, površine do 50 km^2 (Van Den Eeckhaut et al., 2012). Modeli za automatizirano kartiranje klizišta u lokalnom ili regionalnom mjerilu su većinom usmjereni na kartiranje morfologije velikih i dubokih klizišta (Booth et al., 2009; Van Den Eeckhaut et al., 2012) ili kartiranju nestabilnih padina (Booth et al., 2009; Berti et al., 2013). Pregled postojeće literature o automatiziranom kartiranju klizišta primjenom LiDAR DMT-a dan je u tablici 2.5.

Tablica 2.5 Pregled postojeće literature o automatiziranom kartiranju klizišta primjenom LiDAR DMT-a s navedenom lokacijom i površinom istraživanog područja, rezolucijom korištenog DMT-a, korištenim morfometrijskim kartama i primijenjenom metodom kartiranja.

Autor	Istraživano područje	Površina	Rezolucija DMT-a	Morfometrijske karte	Metoda kartiranja	Rezultat
McKean i Roering (2004)	klizište Coringa, Novi Zeland	pojedinačno klizište (0,5 km^2)	1,5-10 m	hrapavost terena	pikselno orijentirana metoda – analiza graničnih vrijednosti	karakterizacija morfologije i aktivnosti klizišta
Glenn et al. (2006)	klizište Salmon Falls, Idaho (SAD)	dva sukcesivna klizišta (1 km^2)	5 m	hrapavost terena, nagib terena	pikselno orijentirana metoda – analiza semivariograma i fraktalna analiza	karakterizacija morfologije i aktivnosti klizišta
Booth et al. (2009)	planina Tualatin, Ohio i Puget Sound, Washington (SAD)	cca 10 km^2	1,8 m	2D diskretna Fourier transfomracija (2D DFT) 2D kontinuirana transformacija valnih duljina(2D CWT)	pikselno orijentirana metoda – analiza valnih duljina	karta nestabilnih padina, nisu kartirane granice pojedinačnih klizišta
Kasai et al. (2009)	planina Kii (Japan)	5 km^2	1 m	hrapavost terena, nagib terena	pikselno orijentirana metoda – analiza graničnih vrijednosti	karakterizacija morfologije klizišta
Rau et al. (2012)	dolina Shismen (Tajvan)	33 km^2	1 m	normalizirani DMT, hrapavost terena, nagib terena avionski snimak	pikselno orijentirana metoda – analiza graničnih vrijednosti, agregacija točkastih podataka o klizištima u poligone	inventar klizišta, granice klizišta su prikazane poligonima
Van Den Eeckhaut et al. (2012)	Flemish Ardennes (Belgija)	50 km^2	2 m	nagib terena planarna zakrivljenost terena raščlanjenost terena hrapavost terena raščlanjenost terena drenažna mreža	objektno orijentirana metoda – analiza graničnih vrijednosti	inventar klizišta, granice klizišta su prikazane poligonima
Tarolli et al. (2012)	bazen Rio Cordon (Italija)	0,2 km^2	0,5 m	zakrivljenost terena	pikselno orijentirana metoda – analiza graničnih vrijednosti	kartirani linijski elementi koji predstavljaju krune klizišta i granice jaruga
Berti et al. (2013)	Bologna (Italija)	20 km^2	1 m	hrapavost terena	pikselno orijentirana metoda – analiza graničnih vrijednosti	karta stabilnih i nestabilnih padina

Nastavak tablice 2.5.

Autor	Istraživano područje	Površina	Rezolucija DMT-a	Morfometrijske karte	Metoda kartiranja	Rezultat
Gorsevski et al. (2015)	Ohio (SAD)	133,6 km^2	0,762 m	nagib terena, zakrivljenost terena, indeks vlažnosti, osunčanost terena, akumulacija toka	objektno orijentirana metoda – primjena umjetne neuronske mreže	karta podložnosti na klizanje – neposredno kartiranje klizišta
Leshchinsky et al. (2015)	klizište Oso, Washington i pilot područje u Oregonu (SAD)	14 km^2	1 m	slojnice	numerička metoda	inventar klizišta, granice klizišta su prikazane poligonima
Li et al. (2015)	Shazhenxi, provincija Zigui (Kina)	21,6 km^2	3 m	nagib terena orijentacija padine hrapavost terena	pikselno i objektno orijentirana metoda – primjena metode strojnog učenja i metode slučajnih šuma	inventar klizišta, granice klizišta su prikazane poligonima
Palenzuela et al. (2015)	Guadalfeo basin (Španjolska)	234 km^2	3 m	nadmorska visina	pikselno orijentirana metoda - usporedba dviju generacija LiDAR DMT-a	inventar klizišta, granice klizišta su prikazane poligonima
Pawluszek (2018)	dva klizišta u Poljskoj	pojedinačno klizište (0,37 km^2 i 0,12 km^2)	1 m	nagib terena orijentacija padine planarna zakrivljenost terena profilna zakrivljenost terena hrapavost terena karta omjera 3D i 2D površine terena karta vlažnosti terena	pikselno orijentirana metoda - analiza svojstvenih komponenti (engl. *Principal Component Analysis , PCA*)	karakterizacija morfologije i aktivnosti klizišta

2.6 Karte podložnosti na klizanje

Prognostičke karte klizišta podrazumijevaju zoniranje istraživanog područja na homogene prostorne jedinice klasificirane s obzirom na opasnost od klizanja, odnosno stvarni ili potencijalni stupanj podložnosti, hazarda ili rizika od klizanja (Van Westen et al., 2005). Prve kvalitativne metode procjene opasnosti od klizišta razvijene su početkom 70-tih godina prošlog stoljeća, a najpoznatiji primjeri su Brabb et al. (1972) i Kienholz (1978). Kvantitativne metode zoniranja razvijaju u kasnim 80-tim, a najviše tijekom 90-tih godina prošlog stoljeća (Brand, 1988; Wong i Ho, 1998). Podložnost na klizanje može se definirati kao prostorna vjerojatnost klizanja (nastanka ili reaktivacije pojave klizišta) za unaprijed definirane preduvjete klizanja (Guzzetti et al., 1999). Glavne pretpostavke kod zoniranja podložnosti na klizanje su (Varnes i IAEG 1984; Hutchinson, 1995 preuzeto iz Aleotti i Chowdhury, 1999): (a) klizišta će se u budućnosti aktivirati zbog istih geoloških, geomorfoloških, hidrogeoloških i klimatskih preduvjeta kao i u prošlosti; (b) pojava klizišta uvjetovana je preduvjetima klizanja koje je moguće identificirati i klasificirati; (c) stupanj podložnosti je moguće procijeniti različitim kvalitativnim i kvantitativnim metodama; (d) svi tipovi nestabilnosti na padinama se mogu identificirati i klasificirati. Za procjenu podložnosti na klizanje primjenjuju se heurističke, statističke i determinističke metode, a detaljniji pregled i opis postojećih metoda (slika 2.8) dan je u Soeters i Van Westen (1996), Carrara et al. (1999), Guzzetti et al. (1999), Aleotti i Chowdhury (1999), Dai et al. (2002), Chacon et al. (2006) i Fell et al. (2008a,b). Karte podložnosti ne daju informaciju o veličini aktiviranih klizišta i vremenskoj vjerojatnosti pojave klizišta, odnosno "kada" i "koliko često" će se klizišta aktivirati (Guzzetti et al., 2005).

Odabir metode za procjenu podložnosti na klizanje ovisi o mjerilu i namjeni konačne karte ali i dostupnim podacima o klizištima i preduvjetima klizanja na istraživanom području. Na primjer, karte podložnosti na klizanje u nacionalnom (<1:250.000) i regionalnom mjerilu (1:250.000-25.000) ne iziskuju kartiranje klizišta i izradu inventara klizišta (Corominas et al., 2013) te se zbog toga najčešće primjenjuju heurističke metode procjene podložnosti na klizanje, a rezultat je kvalitativna procjena podložnosti. Statističke metode procjene podložnosti na klizanje najčešće se koriste za područja veličine 10-10.000 km^2, odnosno za karte lokalnog mjerila (1:5.000 do 1:25.000), a rezultat je kvantitativna procjena prostorne vjerojatnosti. Deterministčke metode koriste se za zoniranje podložnosti na klizanje za pojedinačne lokacije ili manja područja (<10 km^2), a temelje se na podacima dobivenim detaljnim inženjerskogeološkim i geotehničkim istraživanjima.

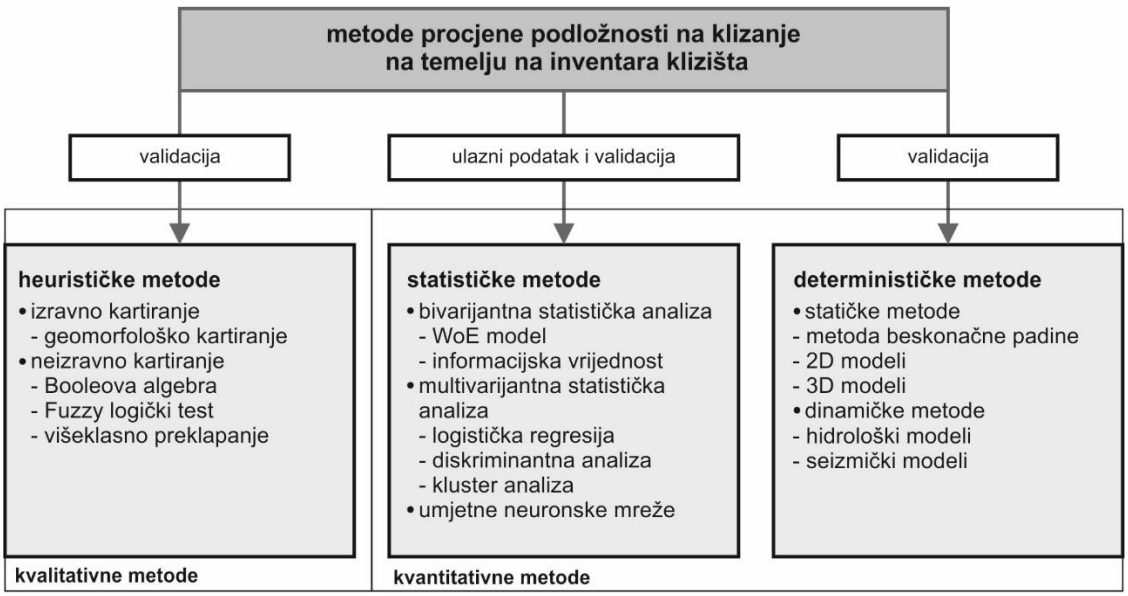

Slika 2.8 Metode procjene podložnosti na klizanje (prema Corominas et al., 2013).

Ulazni podaci za analizu podložnosti na klizanje primjenom statističkih modela su inventar klizišta, koji predstavlja zavisnu varijablu, i preduvjeti klizanja, odnosno faktorske karte klizanja, koje predstavljaju nezavisne varijable. Faktorske karte klizanja mogu se podijeliti na karte izvedene iz DMT-a (nagib terena, orijentacija padine, zakrivljenost terena itd.), karte izrađene na temelju geoloških, inženjerskogeoloških, hidroloških i geomorfoloških podataka i karte izvedene iz karata namjene ili pokrova zemljišta (tablica 2.6). Najznačajniji faktori klizanja su najčešće litologija i nagib terena (Komac, 2006; 2012). Statističke analize se mogu provoditi po različitim prostornim jedinicama, a osnovna podjela je na pravilne ćelije, geomorfološke jedinice, jedinice definirane s obzirom na granice slivova ili padina te jedinice jedinstvenih uvjeta (van Westen et al., 1993).

Najčešće korištene statističke metode su bivarijantna statistička analiza, multivarijantna statistička analiza i umjetne neuronske mreže (Corominas et al., 2013). Kako bi se iz ulaznih podataka izradila karta podložnosti na klizanje primjenom bivarijantne statističke metode potrebno je provesti slijedeće korake (Aleotti i Chowdhury, 1999): (a) odabir i priprema relevantnih faktora klizanja i podjela u odgovarajući broj klasa; (b) izrada karte inventara klizišta; (c) preklapanje karte klizišta sa svakom od faktorskih karata; (d) određivanje gustoće klizišta za svaku klasu faktorskih karata i definiranje težinskih vrijednosti; (e) dodjeljivanje težinskih vrijednosti klasama faktorskih karata; i (f) preklapanje težinskih karata i izrada konačne karte podložnosti na klizanje. Najpoznatije i najkorištenije bivarijantne statističke metode su metoda informacijske vrijednosti, WoE model (engl. *Weight of Evidence Model*), Bayesova teorija odlučivanja, Dempster-Shafer metoda i fuzzy-logički test (Corominas et al.,

2013). Prednost bivarijantne statističke metode je analiza i definiranje faktora klizanja ili kombinacije faktora klizanja koji relativno najviše utječu na pojavu klizišta. Nedostatak analize je što ne uzima u obzir međuzavisnost faktora klizanja, no ovakva analiza obavezna je prije provođenja multivarijantnih statističkih analiza kako bi se točno definirali faktori klizanja, odnosno preduvjeti klizanja koji utječu na pokretanja klizišta na nekom području. Multivarijantna statistička analiza provodi se na temelju zavisne varijable (pojava klizišta) i serije nezavisnih varijabli (faktori klizanja). Za svaku prostornu jedinicu određuje se prisustvo ili odsustvo klizišta, a rezultat je matrica koja se analizira višestrukom linearnom regresijom, diskriminantnom analizom, metodom slučajnih šuma ili nekom od metoda strojnog učenja.

Tablica 2.6 Pregled najčešće korištenih faktorskih karata za procjenu podložnosti na klizanje s obzirom na mjerilo istraživanja (prema Soeters & van Westen, 1996).

Grupa	Faktorska karta	Mjerilo			
		Regionalno	Srednje	Krupno	Detaljno
digitalni model terena	nagib terena	N	V	V	V
	orijentacija padine	V	V	V	V
	duljina/oblik padine	S	V	V	V
	smjer toka	N	S	V	V
	akumulacija toka	N	S	V	V
	raščlanjenost reljefa	V	S	N	N
	gustoća drenažne mreže	V	S	N	N
geološka građa	vrsta stijene	V	V	V	V
	trošenje	N	S	V	V
	orijentacija diskontinuiteta	N	S	V	V
	strukturni elementi	V	V	V	V
	udaljenost od rasjeda	V	V	V	V
tlo	vrsta inženjerskog tla	S	S	V	V
	debljina pokrivača	N	S	V	V
	fizičko-mehanička svojstva (granulometrijski sastav, kohezija, kut unutarnjeg trenja itd.)	N	S	V	V
	hidrogeološka svojstva (poroznost, propusnost, transmitivnost itd.)	N	N	V	V
hidrologija	razina podzemne vode	N	N	S	V
	vlažnost tla	N	V	S	V
	hidrološke značajke (evapotranspiracija, infiltracija, površinsko otjecanje itd.)	S	V	V	V
	udaljenost od vodotoka	V	S	V	N
geomorfologija	strukturne jedinice	V	S	N	N
	geomorfološke jedinice	V	V	N	N
namjena zemljišta	namjena zemljišta	V	V	S	N
	promjene u korištenju zemljišta	S	V	V	V
	vegetacijski pokrov	N	S	V	V
	udaljenost od prometnica	S	V	V	V
	udaljenost od objekata	S	V	V	V

*Stupanj primjenjivosti faktorskih karata na različita mjerila istraživanja: V-visok stupanj primjenjivosti, S-srednji stupanj primjenjivosti, N-nizak stupanj primjenjivosti.

Glavne pretpostavke kvantitativnih statističkih metoda su da se klizišta na cijelom istraživanom području pojavljuju unutar istih kombinacija faktorskih karata i da su različiti tipovi klizišta (npr. plitka i duboka klizišta) uvjetovani istim faktorima klizanja (Corominas et al., 2013). Također, nepoznavanje istraživanog područja, odnosno nedostatak znanja o različitim tipovima klizišta i procesima na istraživanom području, utječe na odabir relevantnih faktora klizanja i konačnu procjenu podložnosti na klizanje. Kvaliteta izvedene karte podložnosti na klizanje ponajviše ovisi o kvaliteti ulaznih podataka, odnosno o prostornoj rezoluciji i točnosti faktorskih karata te potpunosti i točnosti karte inventara klizišta (Ardizzone et al., 2002). Od svih podataka koje karta inventara klizišta može sadržavati, prostorna točnost klizišta je minimalni i najvažniji zahtjev tijekom kartiranja klizišta (Aleotti & Chowdhury 1999; Fell et al., 2008a,b; Malamud et al., 2004). S obzirom na to da klizišta u inventaru mogu biti prikazana točkom ili poligonom, Simon et al. (2017) su proveli istraživanje u kojoj mjeri vrsta prikaza klizišta (točkom ili poligonom) utječe na procjenu podložnosti te su utvrdili kako karta podložnosti na klizanje dobivena na temelju gustoće broja klizišta ima veću točnost od karte podložnosti dobivene gustoćom površina klizišta. Također, Petschko et al. (2013) utvrdili su kako je točnost karata podložnosti na klizanje neznatno viša ukoliko se u statističkim analizama koriste točke unutar granica klizišta umjesto točaka prikazanih na glavnoj pukotini.

3 PODRUČJE ISTRAŽIVANJA

Šire istraživano područje obuhvaća brežuljkasti dio jugoistočnih padina planine Medvednice na području Grada Zagreba. Planina Medvednica je okružena naplavnim riječnim dolinama Save, Krapine i Lonje te se proteže od Podsuseda na jugozapadu do Donjeg i Gornjeg Orešja na sjeveroistoku, u približnoj duljini od 42 km i širini od 9 km u najširem dijelu. Administrativne granice Grada Zagreb obuhvaćaju hrbat Medvednice na sjeveru, Savsku nizinu u središnjem dijelu te Vukomeričke Gorice na jugu. Površina Grada Zagreba je 641 km^2, a obuhvaća uže gradsko područje (veličine 220 km^2) i 70 drugih naselja. Prema popisu stanovništva iz 2011. godine na području Grada Zagreba živi 792.875 stanovnika (DZS, 2011), a prosječna gustoća je 1232 stanovnika/km^2. U Gradu Zagrebu se jugoistočne padine Medvednice nazivaju još i podsljemenska zona, a u disertaciji se pod ovim pojmom podrazumijeva područje površine 180 km^2 ograničeno prometnicama Aleja Bologne-Ilica-Maksimirska cesta-Avenija Dubrava-Varaždinska ulica na jugu, naseljem Podsused na zapadu, naseljem Blaškovec na istoku, dok je sjeverna granica definirana po južnoj granici Parka prirode Medvednica, odnosno geološkom granicom između pred-neogenskih i neogenskih naslaga. Na ovaj način izdvojeno je područje unutar administrativne granice Grada Zagreba izgrađeno od neogenskih i kvartarnih naslaga. Pilot područje za koje su izrađene karte klizišta nalazi se u zapadnom dijelu podsljemenske zone Grada Zagreba i ukupne je površine 21 km^2 (slika 3.1).

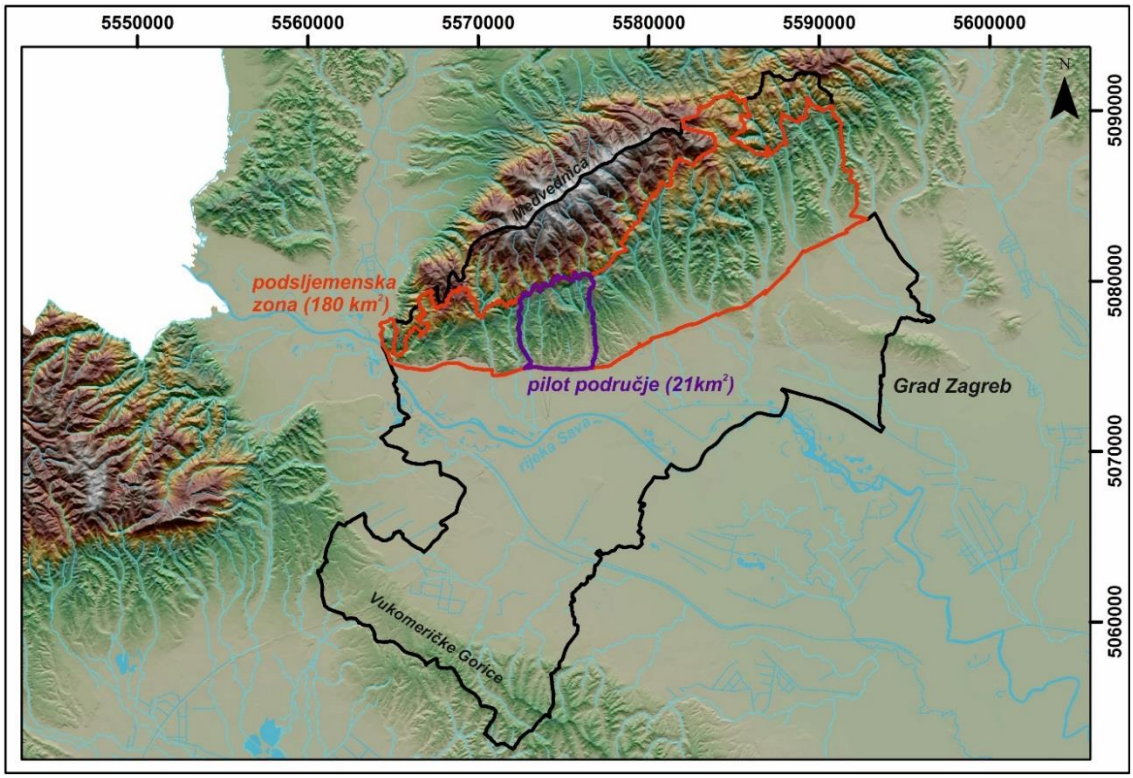

Slika 3.1 Geografski položaj istraživanog područja na DMT-u rezolucije 20x20 m.

Pilot područje obuhvaća dijelove gradskih četvrti Črnomerec, Gornji Grad-Medveščak i Podsljeme, odnosno ograničeno je Kvaternikovom ulicom i ulicom Mikulići na zapadu, Ilicom na jugu, ulicom Stjepana Babonića, ulicom Horvatovac te Mirogojem na istoku i Parkom prirode Medvednica na sjeveru. Prema stvarnom korištenju zemljišta Grada Zagreba na pilot području se nalazi oko 7.400 stambenih, gospodarskih, kulturno-povijesnih, vjerskih i ostalih objekata posebne namjene, a živi oko 38.000 stanovnika (DZS, 2011), odnosno prosječna gustoća stanovnika je 1840 st./km^2. S obzirom na navedene podatke može se zaključiti da se radi o relativno gusto naseljenom području Grada Zagreba (slika 3.2).

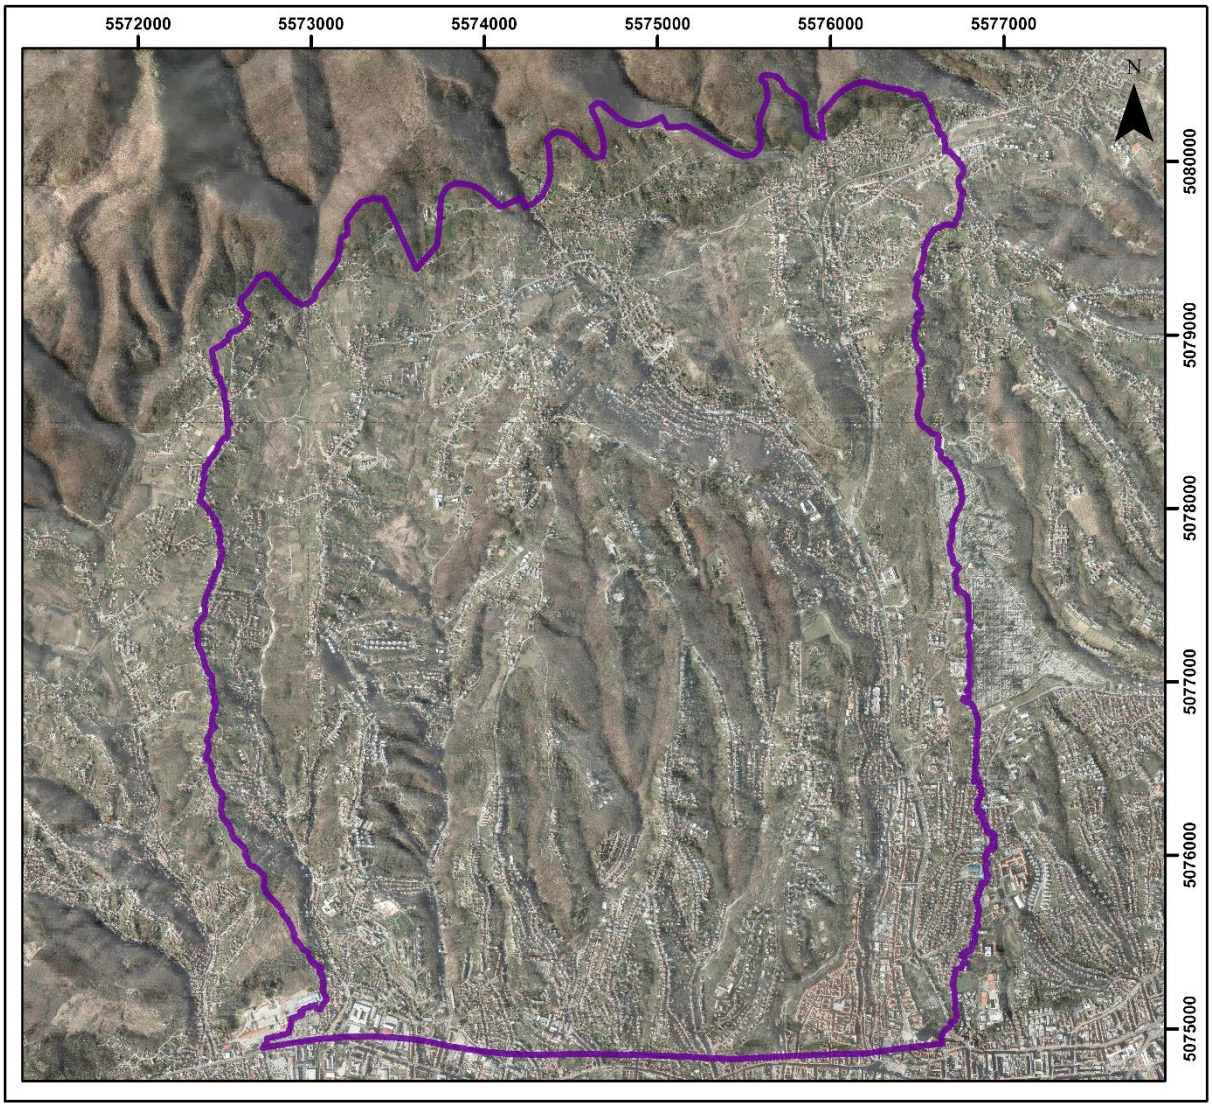

Slika 3.2 Geografski prikaz pilot područja (21 km^2) na digitalnom ortofoto snimku iz 2011. godine (DGU-Geoportal, 2018).

3.1 Geomorfološke značajke istraživanog područja

Grad Zagreb se nalazi na granici dviju velikih strukturnih cjelina Panonskog bazena, makrogeomorfološke regije gorsko-zavalsko područje SZ Hrvatske i zavale SZ Hrvatske. Gorsko-zavalsko područje SZ Hrvatske dijeli se na tri subgeomorfološke regije, Gorski hrbat Medvednice te SZ i JI predgorsku stepenicu (Bognar, 2001). Zavala SZ Hrvatske sastoji od dviju mezogeografskih regija pod nazivom nizina rijeke Save i Vukomeričke gorice sa zavalom Crna Mlaka. Geotektonski položaj Grada Zagreba znatno je utjecao na složen geomorfološki razvoj reljefa što je vidljivo po recentnoj dinamici reljefa te morfostrukturnim i morfogenetskim obilježjima. S obzirom da je pilot područje (21 km^2) dio veće geomorfološke cjeline pod nazivom JI predgorska stepenica Medvednice, u nastavku poglavlja bit će opisano šire istraživano područje, odnosno cijelo područje podsljemenske zone Grada Zagreba. Razlog tome je mogućnost primjene rezultata istraživanja s pilot područja na cijelo područje istraživanja, odnosno podsljemensku zonu Grada Zagreba (180 km^2) zbog sličnih geomorfoloških, geoloških i hidroloških uvjeta te stupnja izgrađenosti.

JI predgorska stepenica predstavlja denudacijsko-akumulacijsku strukturu u kojoj prevladavaju padinski i fluviodenudacijski geomorfološki procesi (Bognar, 1992). Predgorske stepenice se mogu definirati kao brežuljkaste reljefne jedinice koje se vežu uz gorske hrptove (slika 3.3) te su tipično rebrastog oblika s karakterističnom smjenom usporednih hrptova i potočnih dolina (Bognar, 1994). U geomorfološkom smislu predgorske stepenice predstavljaju glacise (franc. *blaga kosina*), a morfogenezom su usko povezani s razvojem susjednih gora i procesima pedimentacije[1]. Razvoj predgorskih stepenica i subomontane udoline[2] vezan je za aktivnost padinskih i eolskih procesa za vrijeme suhih i hladnih faza pliocena i pleistocena.

Najniža vrijednost nadmorske visine u podsljemenskoj zoni Grada Zagreba iznosi 114 m n.m., najviša vrijednost 631 m n.m., dok je prosječna visina oko 230 m n.m. Na istraživanom području (ukupne površine 180 km^2) najveći dio terena, 79 km^2 ili 44,1 %, nalazi se na nadmorskim visinama 100-200 m n.m., zatim 67 km^2 ili 37,3 % je na nadmorskim visinama 200-300 m n.m., te je 25 km^2 ili 13,9 % na nadmorskim visinama 300-400 m n.m (slika 3.4). Iznad 400 m n.m. je 8,4 km^2 ili 4,7 % istraživanog područja. Na pilot području (ukupne površine

[1] Pedimentacija, međusobno paralelno unazadno pomicanje gorske padinske fasade u uvjetima suho-tople i suho-hladne klime, pod utjecajem mehaničkog trošenja i padinskih procesa. U slučaju glacisa radi se o blagim kosinama koje su nastale u podnožju gora spajanjem bujičnih naplavina i deluvijalnog materijala (spiranje).
[2] Submontana udolina, formira se na kontaktu gorskih masiva i predgorske stepenice. Budući da greben ima strmije padine, površinske vode i bujice formiraju udolinu, a kasnijim padinskim procesima udolina se ispuni bujičnim i deluvijalnim materijalom s padina grebena.

21 km^2) najveću površinu (11,1 km^2 ili 52,6 % pilot područja) zauzima teren nadmorske visine 200-300 m n.m., dok teren s nadmorskom visinom 100-200 m n.m. zauzima 8,6 km^2 ili 40,8 % pilot područja (slika 3.4a). Iznad 300 m n.m. nalazi se 1,4 km^2 ili 6,6 % pilot područja.

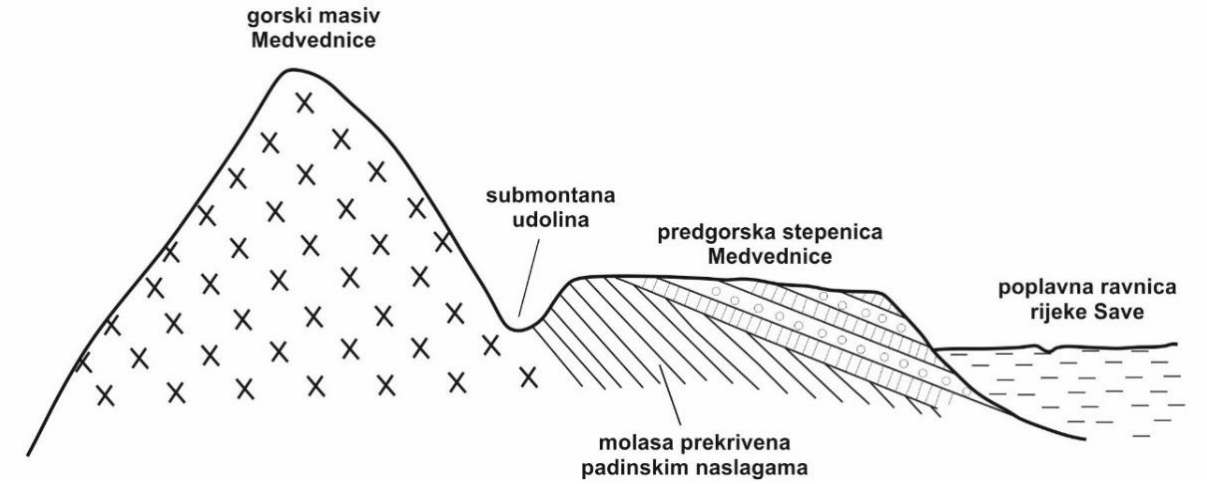

Slika 3.3 Skica morfostrukturne građe istraživanog područja na poprečnom presjeku orijentacije SZ-JI (prema Bognar, 1994).

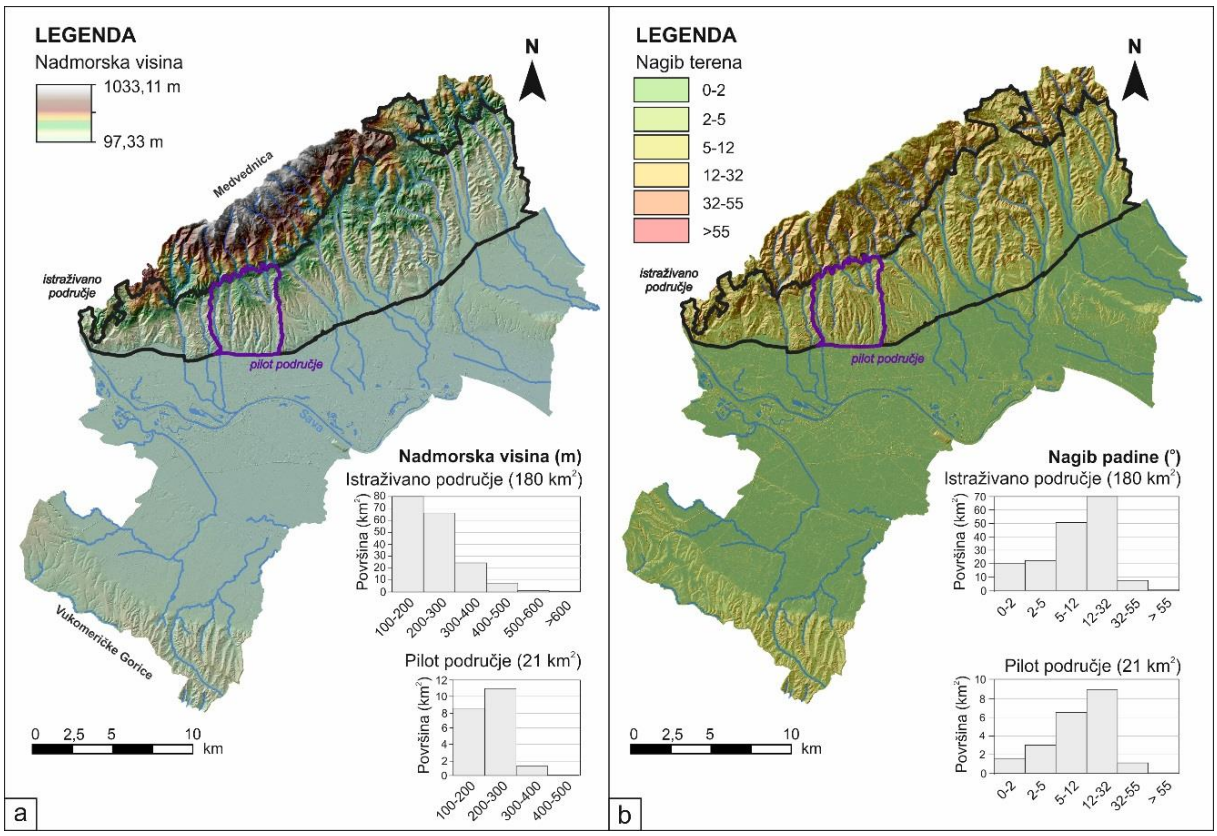

Slika 3.4 Prikaz područja istraživanja i pilot područja u Gradu Zagrebu na DMT-u: a) raspodjela nadmorskih visina; (b) raspodjela nagiba terena.

Analizom nagiba padina (slika 3.4b) ustanovljeno je da najveću površinu (79,4 km^2 ili 44,2 % istraživanog područja) zauzimaju jako nagnuti tereni nagiba 12–32°. Slijede, tereni nagiba 5–12° (50,8 km^2 ili 28,2 % područja istraživanja), blago nagnuti tereni nagiba 2-5° (23,4 km^2 ili 13,1 % područja istraživanja) i ravnice nagiba 0-2° (19,1 km^2 ili 10,6 % područja istraživanja). Znatno manje su zastupljeni vrlo strmi tereni nagiba 32-55° (7 km^2 ili 3,9 % istraživanog područja), dok strmci nagiba >55° nisu zastupljeni na istraživanom području. Unutar pilot područja raspodjela nagiba padina (slika 3.4b) je slična kao na cijelom istraživanom području, jer dominiraju jako nagnuti tereni, odnosno tereni nagiba 12-32° (9,1 km^2 ili 43,2 % pilot područja) i nagnuti tereni nagiba 5-12° (6,6 km^2 ili 31,3 % pilot područja). International Geographic Union, IGU (1968) definirala je dominantne geomorfološke procese s obzirom na prosječan nagib padina i prema navedenoj klasifikaciji više od 85% istraživanog područja podložno je klizanju i eroziji tla (tablica 3.1).

Tablica 3.1 Klasifikacija padina s obzirom na nagib padine i dominantne geomorfološke procese (IGU, 1968) na istraživanom području (180 km^2) i pilot području (21 km^2).

Klasa nagiba	Kategorija nagiba padine	Dominantni geomorfološki procesi	Istraživano područje (180 km^2)		Pilot područje (21km^2)	
			Površina (km^2)	Površina (%)	Površina (km^2)	Površina (%)
0-2	ravnica	Gibanje masa se ne zapažaju. Intenzitet spiranja minimalan.	19,1	10,6%	1,5	7,0%
2-5	blago nagnuti tereni	Spiranje slabo izraženo. Erozija tla i pojave klizanja mogu biti značajne	23,5	13,1%	3,0	14,0%
5-12	nagnuti tereni	Pojačano spiranje i gibanje masa. Do izražaja dolazi klizanje i tečenje materijala. Teren ugrožen erozijom.	50,8	28,2%	6,6	31,3%
12-32	jako nagnuti tereni	Spiranje je intenzivno. Veoma snažna erozija. Teren jako ugrožen erozijom i pojavom gibanje masa.	79,4	44,2%	31,3	43,2%
32-55	vrlo strmi tereni	Dominira odnošenje materijala. Akumulirani materijal se mjestimično zadržava (tanki pokrivač). Padine su stjenovite i ogoljene.	7,0	3,9%	43,2	4,5%
>55	strmci, litice	Dominira osipavanje i urušavanje.	0,0	0,0%	4,5	0,0%

Prema klasifikaciji hipsometrijskih zona (Bognar, 1996) na području podsljemenske zone Grada Zagreba prevladava brežuljkasti krajolik (200-500 m n.m.) s 99,8 km^2 ili 55,5 % i nizine (<200 m n.m.) sa 79,3 km^2 ili 44,1 % istraživanog područja, dok je sredogorje (500-1500 m n.m.) zastupljeno sa samo 0,7 km^2 ili 0,4 % istraživanog područja (slika 3.4a). Vertikalna raščlanjenost istraživanog područja prikazana je na slika 3.4b, a prosječna vertikalna raščlanjenost cijelog prostora podsljemenske zone iznosi 193,5 m/km^2. Prema klasifikaciji

vertikalne raščlanjenosti Gams et al. (1981; iz Bognar, 1992) proizlazi da je 88,4 % istraživanog područja umjereno raščlanjen teren (100-300 m/km^2), a 11,6 % područja je izrazito raščlanjen reljef (300-800 m/km^2). Na pilot području (21 km^2) prevladavaju brežuljkasti krajolik s umjereno raščlanjenim reljefom i nizinski krajolik sa slabo raščlanjenim reljefom.

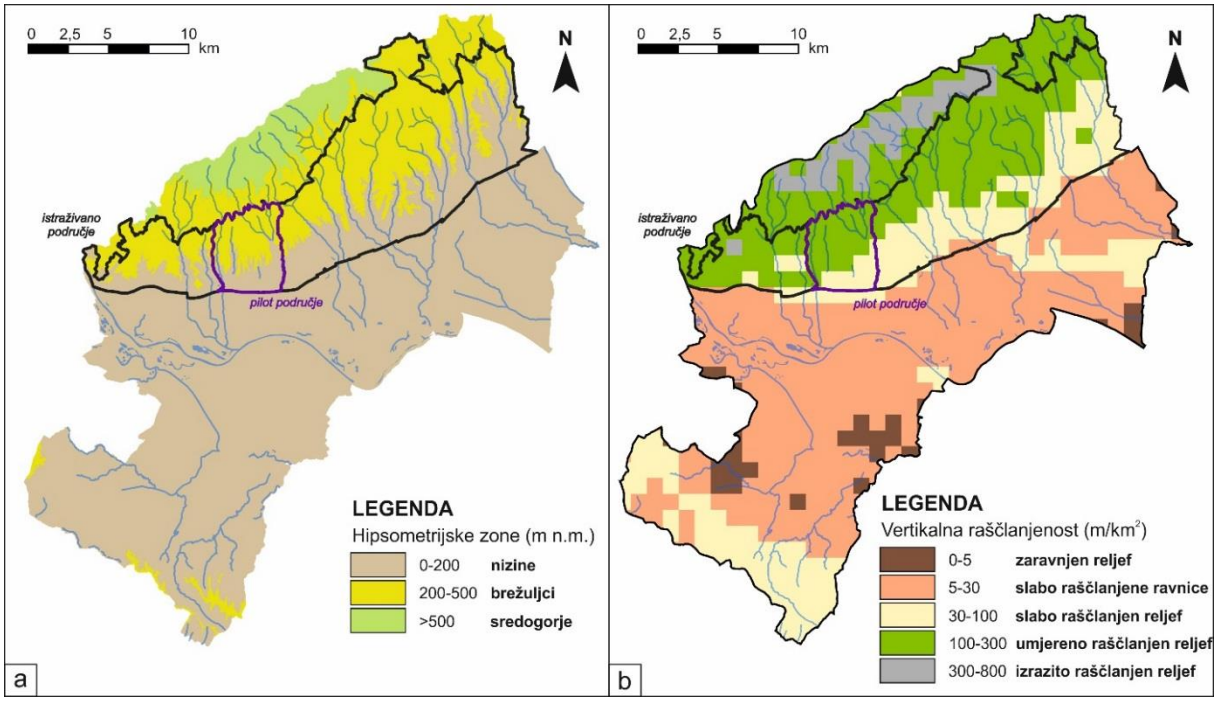

Slika 3.5 Geomorfološke značajke šireg istraživanog područja u Gradu Zagrebu s obzirom na : (a) hipsometrijske zone; (b) vertikalnu raščlanjenost reljefa.

3.2 Geološka građa istraživanog područja

Sjeverna Hrvatska u geološkom smislu predstavlja južni rub nekadašnjega Panonskoga mora, kojeg Žumberak i Petrova gora zatvaraju s juga, a Medvednica i slavonske planine zapravo su panonski otočni arhipelag. Zbog svog položaja, središnji kristalinski dio jezgre Medvednice obrubljen je mlađim neogenskim naslagama koje su istaložene tijekom različitih faza razvoja Panonskog bazena (Royden 1988; Rögl, 1988; Magyar et al., 1999; Pavelić, 2002; Kovačić, 2004; Grizelj, 2008). Prema Matenco i Radivojević (2012) Panonski bazenski sustav pripada skupini zalučnih bazena (engl. *back-arc basins*) koji je nastao kao posljedica kolizije Afričke i Euroazijske ploče, odnosno subdukcijom i konvergencijom Apulijske mikroploče pod Dinaride početkom miocena (otnang). Detaljna geološka građa šireg istraživanog područja te prostorna distribucija naslaga na površini terena (slika 3.6) prikazana je na Osnovnoj geološkoj karti (OGK) M 1:100.000 list Zagreb (Šikić et al., 1979) i list Ivanić-Grad (Basch, 1976). Najstarije naslage na istraživanom području pripadaju paleozoiku, a najmlađe kvartaru. Iz slike 3.6 i tablice 3.2 vidljivo je da se na najvećem dijelu površine podsljemenske zone Grada Zagreba nalaze naslage gornjeg miocena s 63,29 km^2 ili 35,19 % istraživanog područja; zatim naslage pliocenske i pleistocenske starosti s 43,98 km^2 ili 24,5 % istraživanog područja; naslage srednjeg miocena s 31,78 km^2 ili 17,67 % istraživanog područja; kvartarne naslage, odnosno aluvij recentnih tokova s 20,64 km^2 ili 11,5 % istraživanog područja; te donjomiocenske naslage s 19,61 km^2 ili 10,9 % istraživanog područja.

Na pilot području prevladavaju naslage pliokvartara (7,8 km^2 ili 36,9 % pilot područja) i gornjeg ponta (6,2 km^2 ili 29,2 % pilot područja), dok su u jednakom omjeru zastupljene naslage pleistocena (1,9 km^2 ili 9,0 % pilot područja), donjeg ponta (1,8 km^2 ili 8,6 % pilot područja) i gornjeg panona (1,8 km^2 ili 8,4 % pilot područja). Nešto manje su zastupljene naslage gornjeg badena (0,7 km^2 ili 3,2 % pilot područja), proluvijalne naslage (0,5 km^2 ili 2,4 % pilot područja) i aluvijalne naslage (0,3 km^2 ili 1,6 % pilot područja). Manje od 1% pilot područja prekrivaju naslage donjeg panon, silur-karbona i sarmata.

U daljnjem tekstu ukratko su opisane sve naslage na području podsljemenske zone Grada Zagreba, od najstarijih prema najmlađim. Naslage koje zauzimaju najmanju površinu istraživanog područja (0,54 km^2 ili 0,3 %), a to su naslage predneogenske starosti, odnosno trijaski dolomiti i paleozojski metamorfiti, nisu opisivane zbog male zastupljenosti.

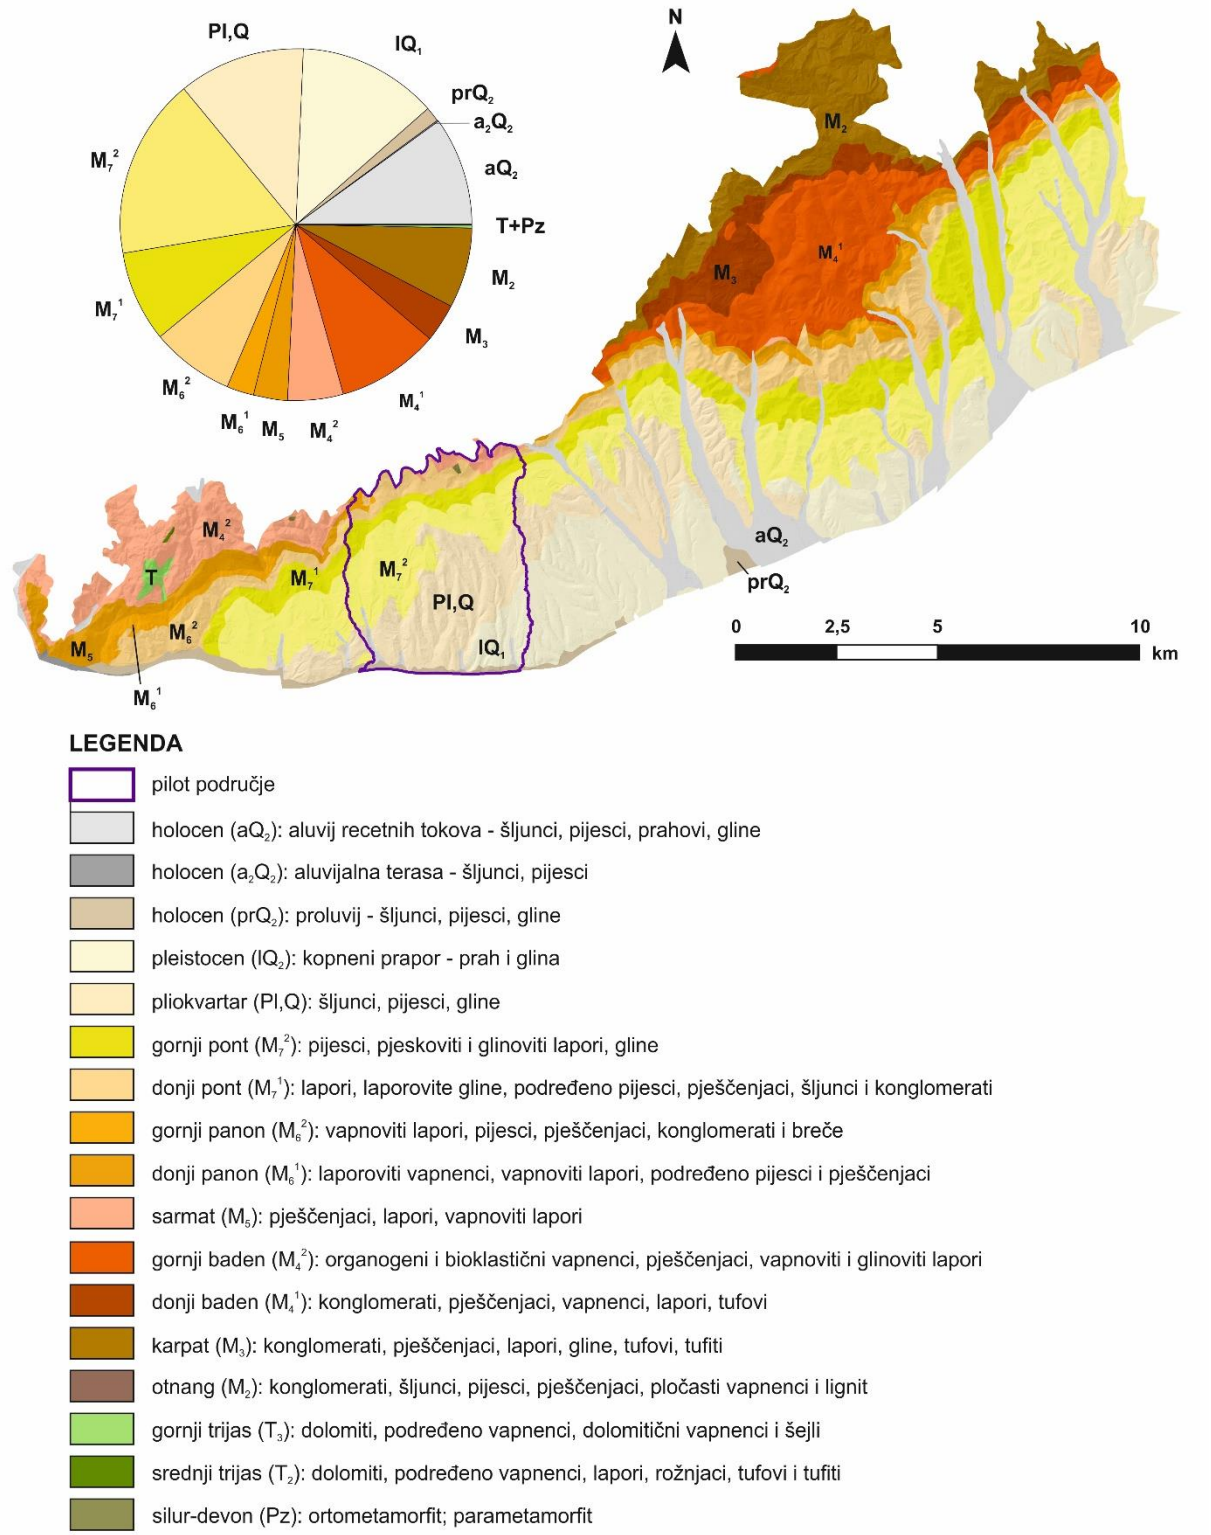

Slika 3.6 Litostratigrafske značajke istraživanog područja i prikaz prostorne zastupljenosti pojedinih naslaga prema OGK M 1:100.000, list Zagreb (Šikić et al., 1972) i list Ivanić-Grad (Basch, 1976).

Neogenske naslage na području sjeverozapadne Hrvatske pripadaju prostoru centralnog Parathetysa. Najmanja debljina neogenskih sedimenata je uz rubove otočnih gora kao što je Medvednica. Tijekom donjeg miocena unutar panonskog bazenskog sustava mogu se razlikovati dva bazena različitih taložnih karakteristika, bazen Hrvatskog Zagorja i Sjevernohrvatski bazen.

Na prostoru Sjevernohrvatskog bazena u starijem otnangu (M_2) prisutni su riječni klastiti (breče, konglomerati, pješčenjaci, prahovi i gline), a u mlađem otnangu (M_2) prisutni su jezerski klastiti (siltiti, lapori, pješčenjaci, kongomerati, te rjeđe vapnenci i piroklastiti). Naslage otnanga diskordantno leže na starijim stijenama podloge, pretežito paleozoika, a debljina im ne prelazi 100 m.

U karpatu dolazi do transgresije uzrokovane povišenjem globalne morske razine, a time i izrazitim otvaranjem marinske veze Parathetysa s južnim krakom Thetysa (budućim Sredozemljem) čime nastaje jedinstveni taložni prostor panonskog bazenskog sustava. Sedimenti karpatske starosti (M_3) leže na slatkovodnim naslagama otnanga. Priobalni i plitkovodni marinski sedimenti se sastoje od zelenkasto i smeđastosivo obojenih, pjeskovitih, prahovitih i glinovitih lapora sa slabo izraženom slojevitošću. Sedimenti se genetski mogu podijeliti na naslage nastale kao rezultat intenzivne organske aktivnosti (sadrže visok udio $CaCO_3$) i na klastične naslage s prisustvom terigenog materijala. U vršnom dijelu prelaze u pijeske, a sadržavaju i manje leće šljunka i petromiktnih konglomerata. Debljina karpatskih naslaga je između 150 i 300 m.

Sedimenti donjeg badena (M_4^1) otkriveni su duž jugoistočnih padina Medvednice. U donjem badenu obnovljena je marinska transgresija, započeta tijekom karpata (Šikić, 1995). Za donjobadenske naslage je svojstveno da se pretežito sastoje od vapnenačkih stijena, odnosno da u sastavu sedimenata prevladava vapnenačka komponenta. U starijem dijelu se izmjenjuju vapnenački, dijelom konglomeratični pješčenjaci, bioklastični vapnenci (litavci), laporoviti vapnenci i lapori, a u mlađem dijelu uglavnom su zastupljeni kalcitni lapori s učestalim tankim proslojcima i ulošcima vapnenačkih pješčenjaka i bioklastičnih vapnenaca. Debljina donjobadenskih naslaga iznosi 470 m.

Početkom gornjeg badena počelo je maksimalno širenje marinske transgresije i more je prekrilo šire područje sjeverozapadne Hrvatske (Vrsaljko et al., 2006). Gornjobadenski sedimenti (M_4^2) su poznati po raznolikosti litofacijesa i mnogo fosilnih ostataka. Bazni, transgresivni dio naslaga, najčešće se sastoji od tanjeg slijeda breča i konglomerata. Najrasprostranjeniji su

priobalni i općenito plitkovodni vapnenački sedimenti, predstavljeni bioklastičnim vapnencima (litavcima) do biokalkarenitima. Kao bočni, ili nešto mlađi ekvivalenti plitkovodnih naslaga, s postupnim prijelazima, u relativno dubljim sredinama taložili su se glinoviti i pjeskoviti lapori. U najmlađem dijelu gornjobadenskih naslaga, na prijalazu u sarmat, osobit je facijes sivih i žućkastosivih, tankopločastih do laminiranih lapora. Debljina gornjobadenskih naslaga varira između 100 i 250 m.

Na prijelazu badena u sarmat, zbog tektonskih pokreta na širem Parathetysu, nastao je opće poznati prekid s Thetysom. Nastupila je izolacija Parathetysa uz smanjenje i postupno oslađivanje dotadašnjeg marinskog bazena, a posljedica je regresivni ciklus sedimentacije s taloženjem marinsko-brakičnih do brakičnih sedimenata (Vrsaljko et al., 2006). U većem dijelu Medvednice, sarmatske naslage se sastoje od izmjene klastita, i to pješčenjaka, manje ili više pjeskovitih, prahovith, glinovitih ili dijatomejskih lapora, laporovitih vapnenaca te tankih proslojaka pijeska i ugljevitih glina. Naslage su vrlo dobro uslojene, odnosno laminirane, što je svojstveno za sarmat.

Posljednjih nekoliko desetljeća podjela gornjomiocenskih naslaga zasnivala se na biostratigrafskim jedinicama, pri čemi je donji panon bio predstavljen s Croatica naslagama, gornji panon s Banatica naslagama, donji pont s Abichi naslagama i gornji pont s Rhomboidea naslagama. Međutim, prema istraživanjima Magyar i Geary (2012) početak ponta nije isti u pojedinim dijelovima Panonskog bazena, te su Mandić et al. (2015) predložili izbacivanje ponta kao regionalne kronostratigrafske jedinice unutar gornjeg miocena. No, zbog uvriježenog izjednačavanja kronostratigrafskih s biostratigrafskim jedinicama u tablici 3.2 i daljnjem tekstu disertacije i dalje se koriste nazivi donji/gornji pont i donji/gornji panon.

Na prijelazu iz srednjeg u gornji miocen pojačan je intenzitet tektonskih pokreta (Pavelić, 2002), Parathetys se raspada u odvojene manje bazene i oblikuje se Panonski bazen. Sedimenti su taloženi iz suspenzije karbonatnog glinovitog mulja u brakičnoj sredini niskog saliniteta te uvjetima tople klime i slabog donosa klastičnog materijala s kopna (Kovačić, 2004). Na padinama Medvednice, donjopanonski sedimenti (M_6^1) leže konkordantno na sarmatskim naslagama te pripadaju neformalnoj litostratigrafskoj jedinici *"Croatica"* i njenom bočnom ekvivalentu jedinici *"Ozalj"*. Biostratigrafski, naslage donjeg panona odgovaraju Croatica naslagama koje su predstavljene facijesom laporovitih vapnenaca i lapora u međusobnoj izmjeni, pri čemu se udio laporovite komponente smanjuje s povećanjem dubinom. Debljina donjopanonskih naslaga ne prelazi 80 m.

Gornjopanonski sedimenti (M_6^2), odnosno Banatica naslage uglavnom su se kontinuirano taložile na donjopanonskim naslagama, osim i u priobalnim predjelima gdje ingresivno leže na starijoj podlozi (područje Mikulići-Bačun). Banatica naslage odgovaraju neformalnoj litostratigrafskoj jedinici *"Medvedski Breg"* te se pretežito sastoje od svijetlosivih i žućkastosivih lapora, unutar koji se uz postupni pad karbonatne komponente, mogu pratiti prijelazi od uslojenih vapnenačkih lapora u baznom dijelu do glinovitih lapora u najmlađem dijelu. Na području s transgresivnim obilježjima (područje Podsused-Markuševac) česta je pojava proslojaka krupnozrnastih terigenih klasitita koji se sastoje od pijeska, pješčenjaka, šljunaka i slabo povezanih konglomerata (Šikić et al., 1979). Ovisno o području, debljina gornjopanonskih naslaga je između 150 i 300 m.

Donjopontske naslage (M_7^1) taložene su u mirnijoj i nešto dubljoj kaspibrakičnoj sredini te leže kontinuirano na gornjopanonske lapore. Naslage donjeg ponta koje se nalaze na istraživanom području pripadaju neformalnoj litostratigrafskoj jedinici *"Medvedski breg"* i *"Andraševac"* te su korelativne s Abichi naslagama. Najveći dio naslaga se sastoji od slabouslojenih, manje ili više glinovitih lapora, a u mlađem dijelu glinovito-prahovitih lapora i glina. Prema mineralnom sastavu sastoje se od izmjene glinovitih vapnenaca i kalcitičnih glina. Često se izmjenjuju sa sitnim do vrlo sitnim pijescima koji su prema vrhu sve učestaliji. Prevladavajuća boja ovih sedimenata je siva do zelenosiva, a debljina iznosi između 80 i 150 m.

Gornjopontski sedimenti (M_7^2) kontinurano su taloženi na donjopontskim sedimentima u sredini s kaspibrakičnim obilježjima. Naslage gornjeg ponta pripadaju neformalnim litostratigrafskim jedinicama *"Andraševac"* i *"Hum Zabočki"*, te su prema litološkim i paleontološkim karakteristikama istovjetne s Rhomboidea naslagama. U starijem dijelu se sastoje od glinovito-pjeskovitih lapora i glina, koje u mlađem dijelu prelaze u slabo vezane do nevezane glinovite pijeske i prahove (Šikić, 1995). Pijesci su sive, žućkastosive, plavičastosive i hrđastosmeđe boje. Debljina gornjopontskih naslaga je u rasponu od 100 do 400 m.

Pliocenske (Pl) i pliokvartarne naslage (Pl,Q) su unutar istraživanog područja na OGK listovima Zagreb (Šikić et al., 1972) i Ivanić-Grad (Basch, 1976) izdvojene kao jedna jedinica. Pliocenski sedimenti (Pl) nisu izdvojeni na površini terena unutar istraživanog područja, ali su dokazane plitko ispod površine na klizištu Črešnjevac (Višić, 2015) gdje je analizom zajednice teških minerala utvrđeno da uzorci dobiveni istraživačkim bušenjem predstavljaju sedimente neformalne litostratigrafske jedinice *"Pluska"*, odnosno da su taloženi na prijelazu iz najmlađeg miocena u pliocen. Pliocenski sedimenti korelativni su s Paludinskim naslagama, a litološki predstavljaju izmjenu gline, praha, pijeska i podređeno sitnozrnastog šljunka. Naslage

pliokvartara (Pl,Q) su slatkovodni fluvijalno-jezerski sedimenti koji leže diskordantno na različitim članovima neogena, mezozika i paleozoika. Ove naslage pripadaju neformalnoj litostratigrafskoj jedinici *"Bistra"*. Izrazito su heterogenog sastava i sastoje se od šljunaka, pijesaka, prahova i glina. Šljunci su nevezane stijene sastavljene od nesortiranih, slabo zaobljenih valutica zelenog škriljavaca, metamorfoziranih vapnenaca te odlomaka kvarca i rožnjaka, promjera 1-10 cm. Šljunčani horizonti uloženi su u obliku leće u pjeskovito-prahovitom materijalu. Šarena boja sedimenta ovisi o sadržaju limonita ili organske tvari, a debljina pliokvartarnih naslaga iznosi oko 150 m.

Pod kopnenim beskarbonatnim praporom (lQ_1) izdvojeni su sedimenti lesnog podrijetla koji su pod utjecajem atmosferilija i djelomično podzemnih voda pretrpjeli pedogenetske promjene (Basch, 1980). Tijekom pleistocenskih glacijacija na cijelom istraživanom području taložene su velike količine prapora koje su tijekom interglacijacija i holocena erodirane i pretaložene. Kopneni beskarbonatni les je žute, sivožute ili žutosmeđe boje sa svijetlim proslojcima gline te vrlo čestim limonitnim ili manganskim konkrecijama. Debljina prapornog sedimenta iznosi oko 20 m.

Proluvijalne naslage (prQ_2) predstavljaju naplavine nekadašnjih bujičnih tokova, a sastoje se od krupnozrnastih zaobljenih šljunaka i kršja s pijeskom i glinom (Šikić et al., 1979). Debljina ovih naslaga ne prelazi 10 m.

Aluvij srednje terase (a_2Q_2) su naslage druge savske terase koje se pojavljuju samo u rubnim južnim dijelovima istraživanog područja. Naslage se sastoje od krupnozrnastih šljunaka i pijesaka, a debljina iznosi od 10 do 20 m (Šikić et al., 1979).

Aluvij recentnih tokova (aQ_2) izdvojen je samo u većim potočnim dolinama, a sastoji se uglavnom od šljunaka i pijesaka. Maksimalna debljina ovih naslaga iznosi 10 m.

Tablica 3.2 Korelacija kronostratigrafskih, neformalnih litostratigrafskih i biostratigrafskih jedinica istraživanog područja s prikazom zastupljenosti površina.

STRAT. JED.		KRONOSTRAT. JED.		PALEO-GEOG.	DEBLJINA	NEFORMALNE LITOSTRAT. JED.		BIOSTRAT. JED.	LITOLOGIJA	POVRŠINA	
										(km2)	(%)
KVARTAR	HOLO-CEN	aluvij recetnih tokova, aQ2		Sava, recentni potoci	10 m				šljunak, pijesak	17,93	9,97 %
		aluvijalna terasa, a2Q2			10-20 m				šljunak, pijesak	0,24	0,13 %
		proluvij, prQ2			10 m				krupnozrnasti šljunak sa pijeskom i glinom	2,47	1,38 %
	PLEIS-TOCEN	kopneni prapor, lQ1			20 m				prah, glina	23,09	12,86 %
	PLEIS-TOCEN	pliokvartar, Pl,Q		Slavonski bazen	150 m	"Bistra"			šljunak, pijesak, prah, glina	20,89	11,64 %
NEOGEN	PLIOCEN	pliocen, Pl				"Cernik"		Paludinske naslage			
	MIOCEN	gornji miocen*	gornji pont, M72*	Panonski bazen	100-400 m	"Pluska"		Rhomboidea naslage	glinovito-pjeskoviti lapor, glina, glinoviti pijesak, prah	30,05	16,71 %
						"Hum Zabočki"					
			donji pont, M71		80-150 m	"Andraševac"		Abichi naslage	glinoviti lapor, glinovito-prahoviti lapor i glina	14,95	8,31 %
						"Medvedski Breg"					
			gornji panon, M62		150-300 m			Banatica naslage	vapnenački lapor, glinoviti lapor	13,80	7,67 %
			donji panon, M61		80 m	"Croatica"	"Ozalj"	Croatica naslage	laporoviti vapnenac, lapor	4,49	2,50 %
		srednji miocen	sarmat, M5	Parathethys	40 m				pješčenjak, pjeskoviti, prahoviti, glinoviti ili dijatomejski lapor, laporoviti vapnenaci	5,60	3,11 %
			gornji baden, M42	Parathetys/ Thetys	100-250 m				bioklastični vapnenci (litavci), biokalkareniti, lapor	9,17	5,10 %
			donji baden, M41		80 m				vapnenački pješčenjaci, bioklastični vapnenci (litavci), laporoviti vapnenci i lapori	17,01	9,46 %
		donji miocen	karpat, M3		470 m				pjeskoviti, prahoviti i glinoviti lapor	6,24	3,47 %
			otnang, M2	Sjeverno-hrvatski bazen/ Parathetys/ Thetys	100 m				izmjene konglomerata, šljunaka, krupnozrnastih pijesaka i pješčenjaka	13,37	7,43 %
PREDNEOGEN					-	-		-	trijaski dolomiti; paleozojski metamorfiti	0,54	0,30 %

*Prema Madnić et al. (2015) pont više nije regionalna kronostratigrafska jedinica unutar gornjeg miocena.

3.3 Hidrološke značajke istraživanog područja

Potoci na južnim i jugoistočnim padinama planine Medvednice čine gustu razgranatu hidrografsku mrežu (slika 3.7) koja pripada slivu rijeke Save. U središnjem dijelu južnih padina Medvednice javlja se oko 60 izvora koji potom oblikuju brojne potoke izrazito brdskog tipa, sa strmim gornjim tokom i položenim donjim tokom (Andabaka et al. 2011). S obronaka Medvednice u rijeku Savu utječe ukupno 23 potoka, a u rijeku Krapinu osam potoka. Veći potoci na pilot području su Črnomerec, Kuniščak, Jelenovac, Zelengaj, Gračanski potok i Ribnjak. Potoci na području podsljemenske zone Grada Zagreba nazivaju se još i "Zagrebački potoci", a zajedničko obilježje svih vodotoka je bujični vodni režim, erozija, te značajne količine taloga. Na slici 3.7 prikazana je hidrografska mreža pilot područja i istraživanog područja, odnosno svi stalni i povremeni vodotoci na površini terena, digitalizirani s Hrvatske osnovne karte M 1:5.000. Veći dio vodotoka, ili dijelova vodotoka koji protječe kroz donji dio pilot područja, odnosno središte grada, je kanaliziran i zatvoren te se ulijevaju u gradsku kanalizaciju, a potom u rijeku Savu.

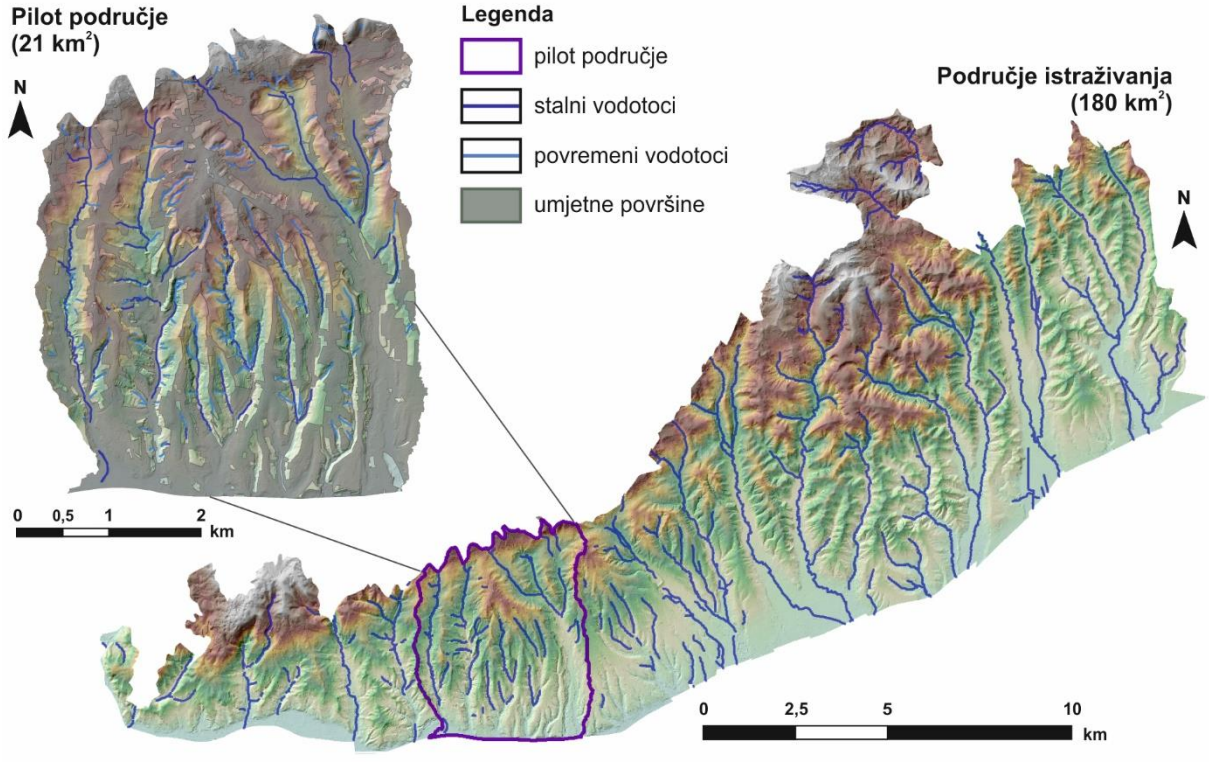

Slika 3.7 Hidrografska mreža na području istraživanja i pilot području. Stalni i povremeni vodotoci digitalizirani su s Hrvatske osnovne karte M 1:5.000.

Drenažna mreža, a zatim i slivovi na području istraživanja definirani su preliminarnom analizom u *ArcGIS-u 10.0* pomoću skupine alata *Hidrology* (slika 3.8). Veličina slivova u zapadnom dijelu istraživanog područja je manja (0,02-6,5 km^2) od slivova u istočnom dijelu (0,15-25,7 km^2). Prema obliku slivovi su duguljastog oblika, što znači da je koncentracija toka spora, intenzitet slab, a otjecanje dugotrajno. S obzirom na prostiranje slivova, definiran je obuhvat pilot područja (slika 3.8) koje obuhvaća šest slivova veličine 0,8 do 6,5 km^2 i desetak manjih slivova površine manje od 0,3 km^2.

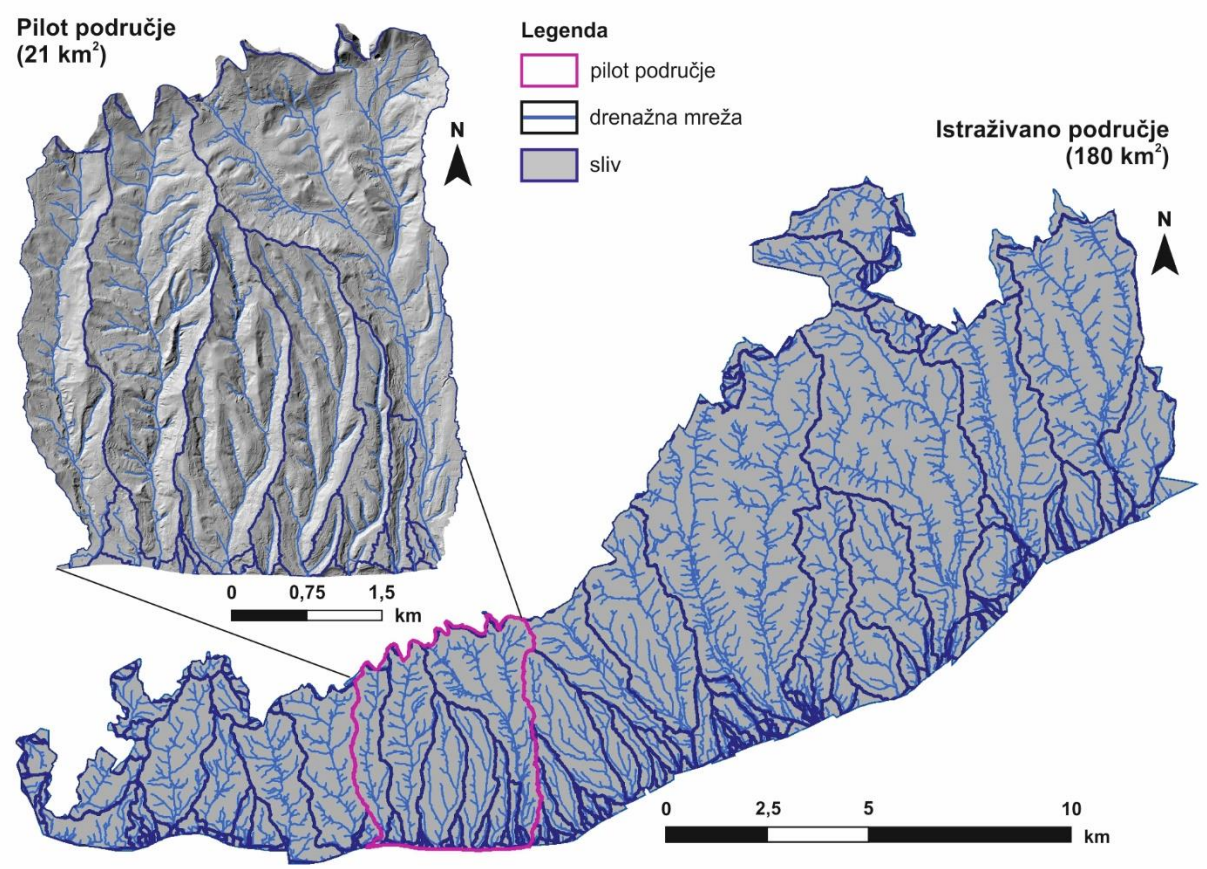

Slika 3.8 Drenažna mreža i slivovi u podsljemenskoj zoni Grada Zagreba (180 km^2) i na pilot području (21 km^2) izdvojeni preliminarnom analizom LiDAR DMT-a.

3.4 Meteorološke značajke istraživanog područja

Grad Zagreb se nalazi u predjelu s umjerenom kontinentalnom klimom, koju karakteriziraju oštre i hladne zime te izrazito topla i suha ljeta. Prema Zaninović et al. (2008) za sjeverozapadni dio Hrvatske karakterističan je tip godišnjeg hoda u kojem najmanje oborine ima u hladnom dijelu godine (listopad do ožujak). Na slici 3.9 prikazane su prosječne mjesečne oborine na postaji Zagreb-Grič za razdoblje 1862.-2016. godine. Najniže mjesečne oborine su tijekom veljače, dok je glavni maksimum tijekom kolovoza, a sporedni u listopadu. U kontinentalnom dijelu Hrvatske, najveće godišnje maksimalne dnevne količine oborine su tijekom ljeta (lipanj, srpanj, kolovoz) ili krajem jeseni (studeni).

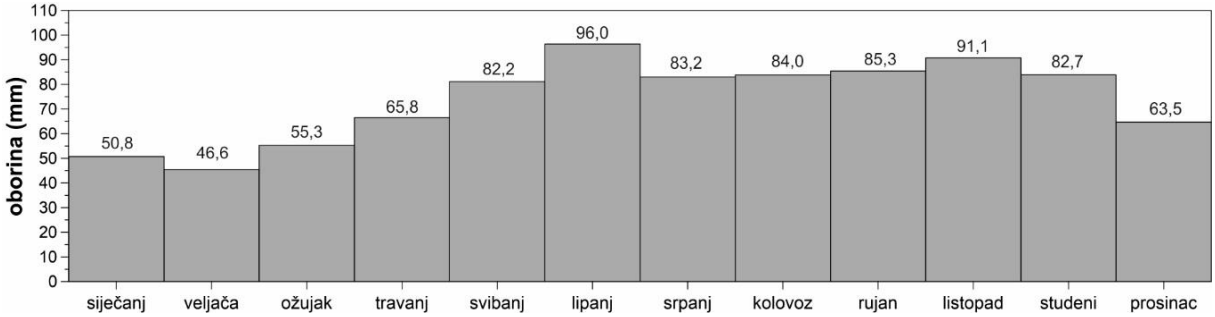

Slika 3.9 Srednje mjesečne oborine na postaji Zagreb-Grič za razdoblje 1862.-2018. godine.

Na području podsljemenske zone nalazi se ukupno šest meteoroloških postaja: Zagreb-Grič, Maksimir, Bijenik, Šestine, Markuševac i Čučerje. Općenite informacije o meteorološkim postajama i srednjim godišnjim oborinama prikazane su u tablici 3.3. Najniža srednja godišnja oborina je u nizinskom dijelu grada Zagreba zabilježena na meteorološkoj postaji Maksimir (849,7 mm), a najviša na postaji Šestine (942,3 mm). Postaja s najdužim mjerenjem je meteorološka postaja Zagreb-Grič (od 1862. godine do danas).

Tablica 3.3 Popis meteoroloških postaja i srednjih godišnjih oborina na području podsljemenske zone Grada Zagreba.

Meteorološka postaja	Koordinate			Srednja godišnja oborina (mm)	Dužina mjerenja (god.)
	x	y	z		
Zagreb-Grič	45°48’	15°58’	157	883,6	156
Zagreb-Maksimir	45°49’	16°02’	123	849,7	69
Zagreb-Bijenik	45°50’	15°57’	220	875,7	27
Zagreb-Šestine	45°51’	15°57’	291	942,3	27
Zagreb-Markuševac	45°52’	16°01’	240	932,1	27
Čučerje	45°53’	16°03’	246	911,2	16

Oborine i otapanje snježnog pokrivača, odnosno duga oborinska razdoblja ili kratkotrajne oborine visokog intenziteta, su glavni pokretači (inicijatori) klizišta u Gradu Zagrebu, što se može zaključiti iz činjenice da se većina klizišta (re)aktivirala u mjesecima kada je količina oborina bila viša od prosječne mjesečne oborine (Bernat Gazibara et al. 2017). Prema raspodjeli percentila za zimu 2012./2013. (slika 3.10) oborinske prilike na području sjeverozapadne Hrvatske opisane su kao ekstremno kišne (>98 percentila) i vrlo kišne (91-98 percentila). Posljedica prethodno opisanih oborinskih prilika bila je (re)aktiviranje više od 900 klizišta na području Krapinsko-zagorske županije, Varaždinske županije, Grada Zagreba, Karlovačke županije, Međimurske županije i Zagrebačke županije (Bernat et al., 2014a).

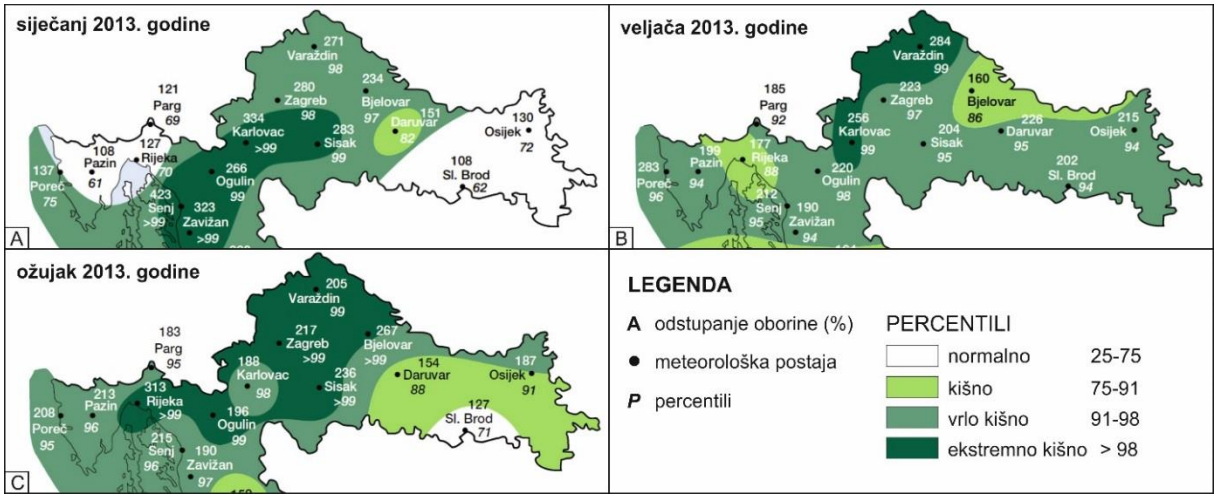

Slika 3.10 Mjesečni oborinski percentili za sjevernu Hrvatsku, određeni na temelju vremenskog razdoblja 1961.-1991. godina za (DHMZ, 2013): a) siječanj 2013. godine; b) veljaču 2013. godine; c) ožujak 2013. godine.

U istom razdoblju, od 14. siječnja do 5. travnja 2013. godine u Gradu Zagrebu je na meteorološkoj postaji Zagreb-Grič zabilježeno više 390 mm oborine, što znači da je u 82 dana palo 46 % srednje godišnje oborine. U navedenom razdoblju značajnije količine oborine zabilježene su od 14. do 25. siječnja, od 3. veljače do 2. ožujka i od 9. ožujka do 7. travnja 2013. godine (slika 3.11). Na istoj slici prikazani su datumi aktiviranja 55 klizišta prijavljenih Uredu za upravljanje u hitnim situacijama Grada Zagreba i područnim uredima Državne uprave za zaštitu i spašavanje (DUZS). U istom razdoblju mjesečne i tromjesečne oborine za siječanj, veljaču i ožujak 2013. godine (slika 3.12) bile su dva do tri puta veće nego srednje mjesečne i tromjesečne oborine za razdoblje od 1862. do 2018. godine (Bernat et al., 2014b). Analizom tromjesečnih kumulativnih oborina za ožujak 2013. godine (slika 3.13) utvrđeno je da se radi o najvišoj vrijednosti (378,7 mm) izmjerenoj na meteorološkoj postaji Zagreb-Grič u razdoblju od 1862. do 2013. godine (Bernat et al., 2014b).

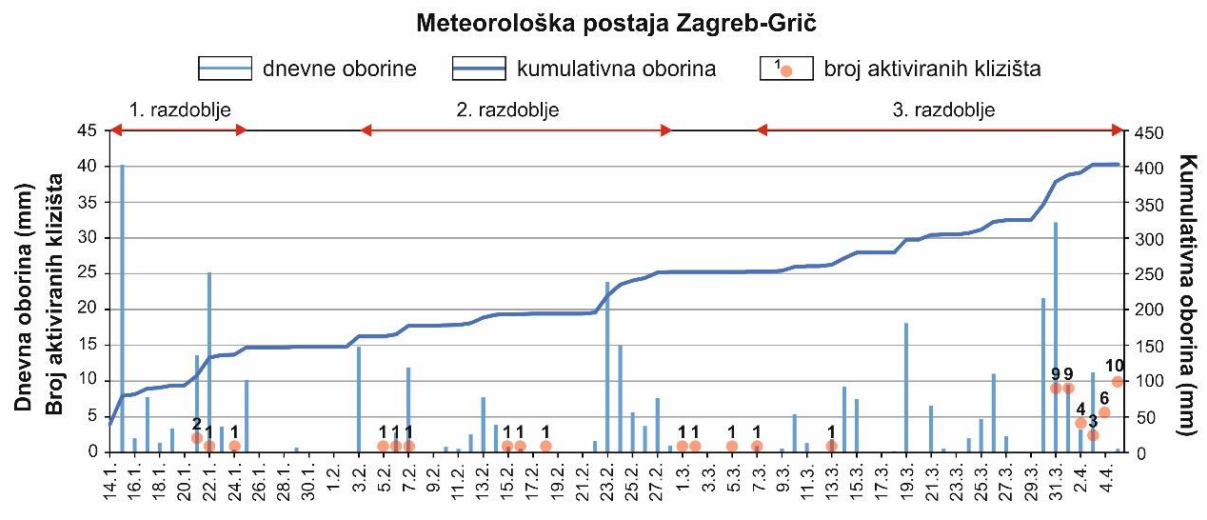

Slika 3.11 Podaci o dnevnoj oborini, kumulativnoj oborini i broju klizišta aktiviranih tijekom siječnja, veljače i ožujka 2013. godine u podsljemenskoj zoni Grada Zagreba (Bernat et al., 2014b).

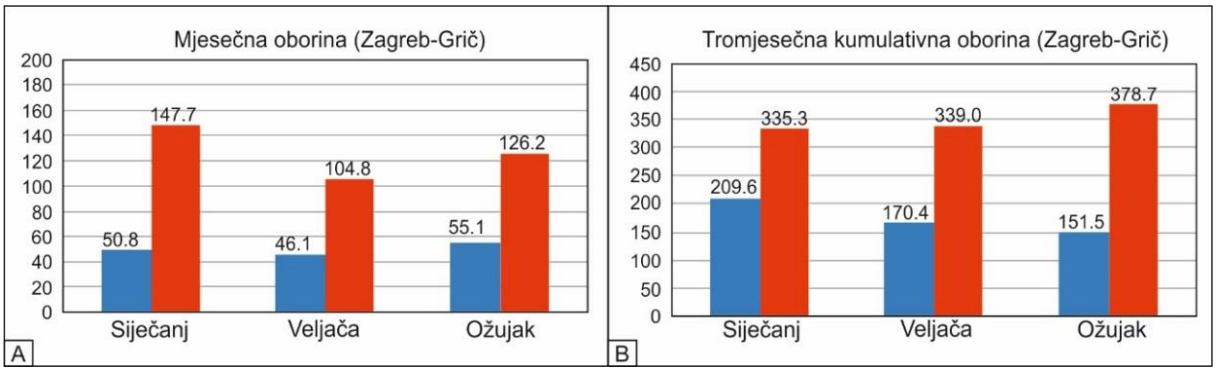

Slika 3.12 Analiza oborina na meteorološkoj postaji Zagreb-Grič: (a) mjesečne oborine; (b) tromjesečne kumulativne oborine. Plavom bojom su prikazane prosječne oborine za razdoblje 1862.-2018. godine, a crvenom bojom su prikazane oborine iz 2013. godine (Bernat et al., 2014b).

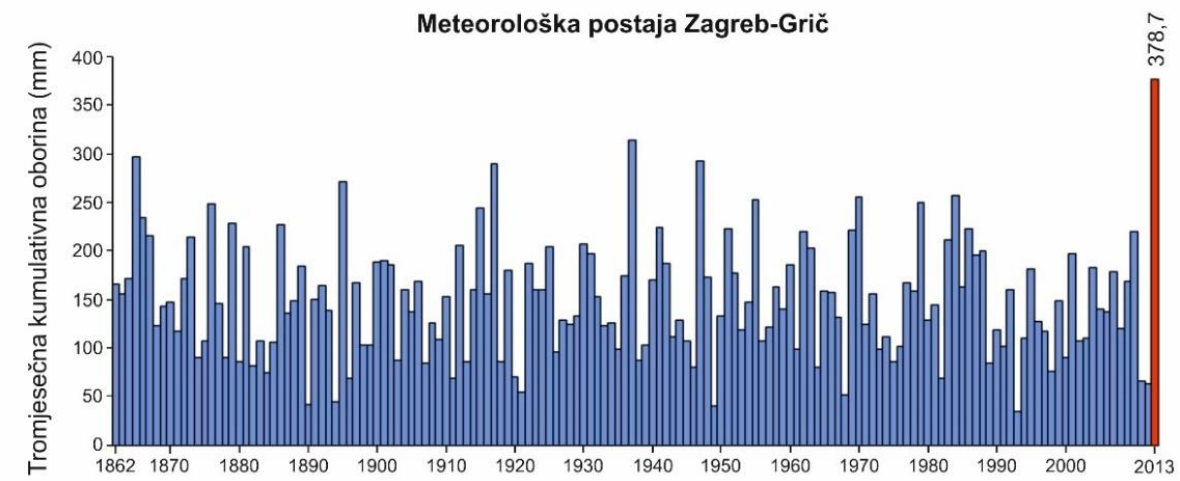

Slika 3.13 Tromjesečne kumulativne oborine za ožujak za razdoblje 1862.-2013. godina (Bernat et al., 2014b).

3.5 Korištenje zemljišta na istraživanom području

Urbani razvoj Grada Zagreba posljednjih četrdesetak godina određivan je nizom urbanističkih planova. Prema Generalnom urbanističkom planu grada Zagreba iz 2016. godine (GUP, 2016) te njegovim izmjenama i dopunama iz 2017. godine (GUP, 2017) smanjene su granice za urbani rast grada, ukazujući time na vrijednost neizgrađenog prostora i potrebu konsolidiranja grada. Neke od mjera za konsolidaciju urbanog područja su poticanje progušćivanja izgrađenog područja, rehabilitacija sagrađene urbane sredine, očuvanje i uređivanje neizgrađenih prostora. Sve navedene mjere mogu imati negativan utjecaj na pojavu klizišta ukoliko se karte klizište ne koristite u postupku izrade karata i dokumenata vezanih za prostorno uređenje.

Područje podsljemenske zone prvobitno je korišteno za poljoprivredne djelatnosti, a s razvojem grada postalo je atraktivno za naseljavanje. Urbanizacija podsljemenske zone Grada Zagreba započela je prije približno 50-ak godina. Dominantni procesi u promjeni zemljišnog pokrova sjeverne Hrvatske od 1981.-2011. godine su prirodna sukcesija (promjena poljoprivrednog zemljišta u prirodnu vegetaciju), intenzifikacija (promjena iz prirodne vegetacije u poljoprivredno zemljište) i izgradnja na poljoprivrednim površinama i prirodnoj vegetaciji (Pavlek, 2016). Prema stvarnom korištenju zemljišta Grada Zagreba iz 2011. godine (slika 3.14) najveću površinu na istraživanom području zauzimaju poljoprivredne površine sa 72,70 km^2 ili 40,5 %, zatim šume s 58,36 km^2 ili 32,5 %, dok umjetne površine zauzimaju 47,8 km^2 ili 26,6% područja istraživanja (tablica 3.4). Od umjetnih površina, najzastupljenija je stambena i mješovita namjena s 34,29 km^2, promet s 4,19 km^2 te javne zelene i javne društvene površine s 2,9 km^2 i 2,65 km^2. Vodene površine zauzimaju svega 0,63 km^2, odnosno 0,4 % područja istraživanja. Stvarno korištenje zemljišta na pilot području (21 km^2) prikazano je tablici 3.5, a najzastupljenije su umjetne površine (11,7 km^2 ili 55,5 % pilot područja), dok su šume (4,7 km^2 ili 22,3 % pilot područja) i poljoprivredne površine (4,6 km^2 ili 21,7 % pilot područja) zastupljene u sličnim omjerima. Vodene površine na pilot području zastupljene su sa 0,11 km^2 (0,5 % pilot područja).

S obzirom na izgrađenost, malo manje od 25 % podsljemenske zone Grada Zagreba (42,4 km^2) i 50 % pilot područja (10,4 km^2) je pretežito izgrađeno. Na slici 3.14 prikazana je prostorna raspodjela izgrađenosti iz 2011. godine te se može zaključiti kako su umjetne površine i veći stupanj izgrađenosti dominantno zastupljeni u zapadnom dijelu istraživanog područja, odnosno unutar granice GUP-a grada Zagreba. Također, površina šuma i poljoprivrednih površina, a time i zona manje izgrađenosti se u zapadnom dijelu grada povećava od juga prema sjeveru.

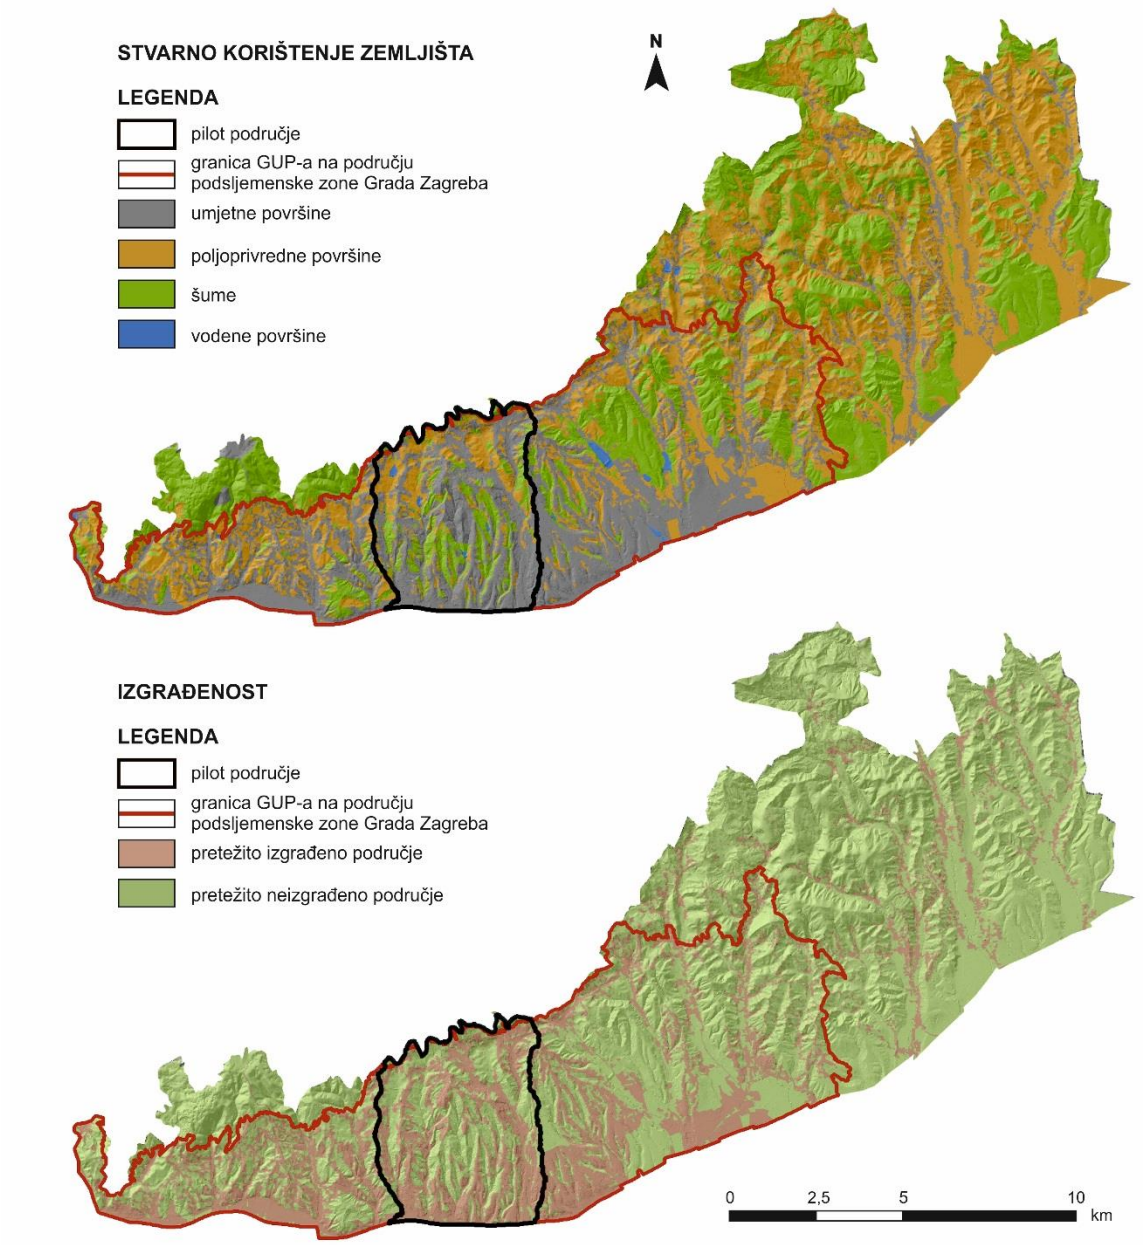

Slika 3.14 Stvarno korištenje zemljišta i izgrađenost istraživanog područja i pilot područja (Gradski ured za strategijsko planiranje i razvoj Grada, 2011).

Tablica 3.4 Stvarno korištenje zemljišta u podsljemenskoj zoni Grada Zagreba (180 km^2).

	Tipovi stvarnog korištenja zemljišta	Površina (km^2)	Glavne skupine stvarnog korištenja	Površina (km^2)	Površina (%)
1	gospodarska	1,09	umjetne površine	47,80	26,6
2	groblje	1,43			
3	javna i društvena	2,65			
4	javne zelene	2,90			
5	komunalna	0,21			
6	posebna	0,11			
7	promet	4,19			
8	sport i rekreacija	0,94			
9	stambena i mješovita	34,29			
10	poljoprivredna, neuređeno, ostalo	72,70	poljoprivredne površine	72,70	40,5
11	šume	58,36	šume	58,36	32,5
12	vode	0,63	vodene površine	0,63	0,4

Tablica 3.5 Stvarno korištenje zemljišta na pilot području (21 km^2).

	Tipovi stvarnog korištenja zemljišta	Površina (km^2)	Glavne skupine stvarnog korištenja	Površina (km^2)	Površina (%)
1	gospodarska	0,09	umjetne površine	11,72	55,5
2	groblje	0,08			
3	javna i društvena	0,85			
4	javne zelene	1,21			
5	komunalna	0,04			
6	posebna	0,11			
7	promet	1,17			
8	sport i rekreacija	0,05			
9	stambena i mješovita	8,10			
10	poljoprivredna, neuređeno, ostalo	4,57	poljoprivredne površine	4,57	21,7
11	šume	4,71	šume	4,71	22,3
12	vode	0,11	vodene površine	0,11	0,5

3.6 Aktivni geomorfološki procesi

Na području Grada Zagreba razlikuju se četiri zone različitih inženjerskogeoloških uvjeta: gorje Medvednice, južni obronci Medvednice, ravničarsko područje uz rijeku Savu i brdovito područje Vukomeričkih gorica. Zone se razlikuju s obzirom na geomorfološke značajke i geološku građu što se odražava na karakteristične oblike reljefa, svojstva materijala i aktivne geomorfološke procese u pojedinim zonama (Jurak i Mihalić, 1995; Jurak et al., 1998; 2008; Mihalić Arbanas et al., 2012). Slika 3.15 prikazuje Grad Zagreb i širu okolicu podijeljenu na glavne zone inženjerskogeoloških uvjeta (označene rimskim brojevima I, II, III i IV) i podzone unutar zona II i III (označene slovima a, b i c). Rezultati analize zastupljenosti geoloških jedinica, nagiba terena i pokrova zemljišta u pojedinim zonama opisani su u radu Mihalić Arbanas et al. (2012). Proces klizanja i s njime povezane pojave klizišta na području Grada Zagreba prisutni su u zonama I, II i IV. Budući da se područje podsljemenske zone Grada Zagreba nalazi unutar zona I i II, u nastavku će biti ukratko opisane samo navedene inženjerskogeološke zone.

Zona I, odnosno "Gorska jezgra Medvednice" je dominantno izgrađena (oko 77 %) od predneogenskih stijena (sedimentne, metamorfne i magmatske stijene), a manjim dijelom (oko 23 %) od sedimentnih stijena donjeg i srednjeg miocena (M_2-M_5). Debljina površinskih naslaga je relativno tanka i sastoji se od deluvija, koluvija i eluvija. Najveći dio ove zone nalazi se unutar granica Parka prirode Medvednica, gdje je pokrov je dominantno šuma (92 %). Oko 60 % područja ove zone je nagiba u rasponu 12-48°. Od aktivnih geomorfoloških procesa mogu se identificirati klizišta i linijska erozija prouzročena bujičnim tokovima. S obzirom na mehanizam klizanja, pojavljuju se plitka klizišta koja uglavnom nastaju na granici pokrivača i

matične stijene ili u zasjecima cesta, te odroni stijene na prirodnim liticama i umjetnim strmim pokosima (uz ceste i u kamenolomima).

Zona IIa originalno je nazvana „Medvedničko prigorje/podsljemenska urbanizirana zona – periklinarno položene mlađe naslage (neogenske i starije kvartarne)“. U sjeverozapadnom dijelu zone na površini terena se nalaze gornjomiocenske naslage panonske i pontske starosti (M_6-M_7), koje se uglavnom sastoje od uslojenih sitnozrnastih tala i lapora, a u jugozapadnom dijelu se nalaze kvartarne naslage, koje se sastoje od sitnozrnastih i krupnozrnastih tala. U zoni IIa dominiraju tla i mjestimično tvrdo tlo-meka stijena (lapor) koje predstavljaju matičnu stijenu, a površinske naslage se sastoje od deluvijalnih, koluvijalnih i eluvijalnih naslaga. S obzirom da je najveći dio ove zone unutar granice naselja grada Zagreba, dominantni pokrov u zoni IIa su tzv. umjetne površine (74 % površine zone). Oko 54 % područja zone su padine nagiba u rasponu 6-24°, na kojima postoji potencijalna opasnost od klizanja i linijske erozije prouzročene bujičnim tokovima. Klizišta uglavnom nastaju na granici između površinskih naslaga i matične stijene, a mnoga poznata klizišta nastala na geološkoj granici između pleistocenskih i gornjopontskih naslaga.

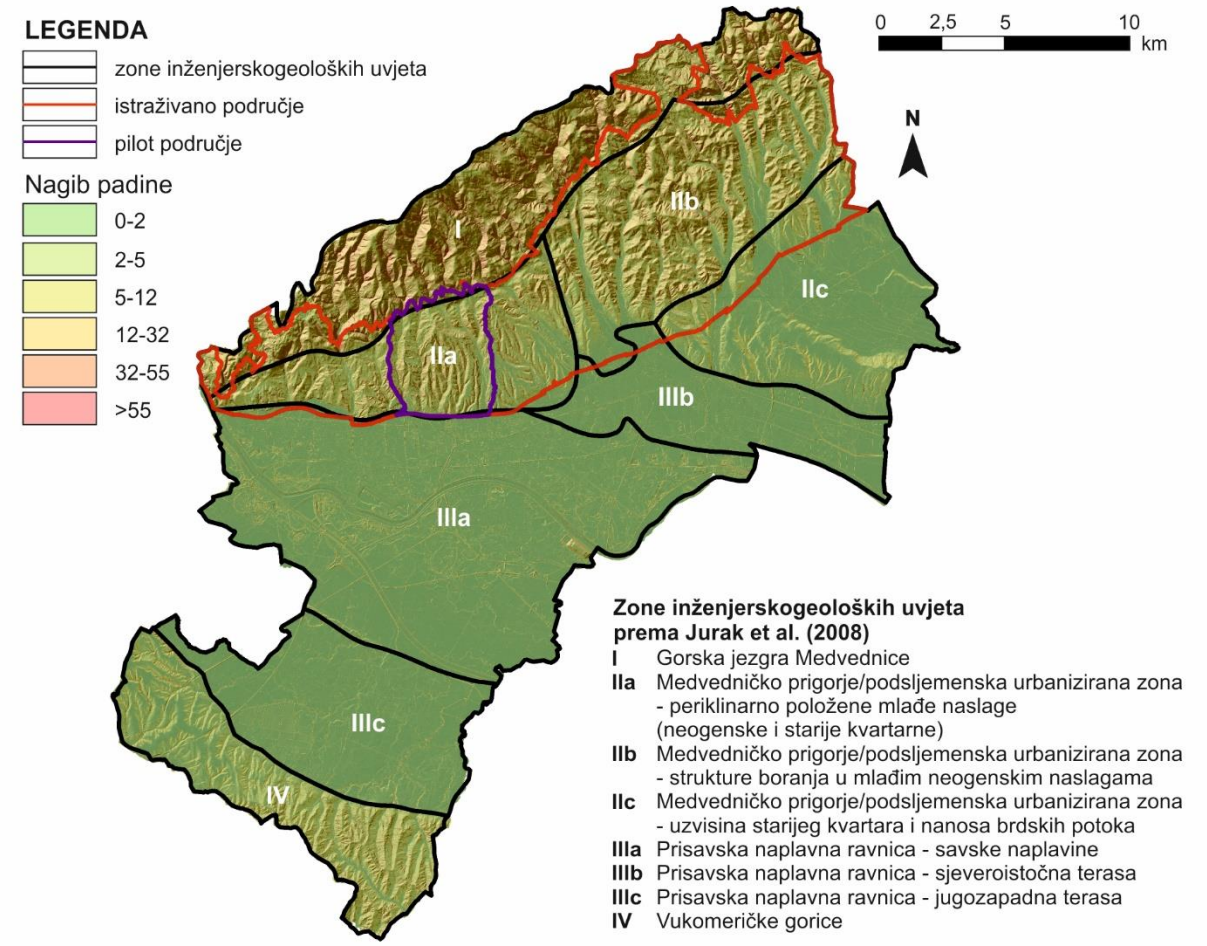

Slika 3.15 Zone inženjerskogeoloških uvjeta prema Jurak et al. (2008).

Zona IIb predstavlja „Medvedničko prigorje/podsljemenska urbanizirana zona – strukture boranja u mlađim neogenskim naslagama“. Ova zona izgrađena je od sljedećih gornjomiocenskih naslaga: naslage panonske i pontske starosti (M_6-M_7) koje se sastoje od sitnozrnastih tala i mekih lapora; srednjomiocenske naslage starosti otnang do sarmat (M_2-M_5) koje se uglavnom sastoje od vapnenaca i lapora; te kvartarne naslage pleistocenske i holocenske starosti (Q_1-Q_2) koje se sastoje od sitnozrnastih i krupnozrnastih tala. U zoni IIb podjednako su zastupljena inženjerska tla i tvrdo tlo-meka stijena (lapor) koji predstavljaju matičnu stijenu, a relativno tanke površinske naslage se sastoje od deluvijalnih, koluvijalnih i eluvijalnih naslaga. S obzirom da je samo manji dio ove zone unutar granice naselja grada Zagreba, dominantni pokrov u zoni IIb je poljoprivredno zemljište (57 % površine zone), a slijede umjetne površine sa 17 % površine zone. Oko 54 % područja ove zone su padine nagiba u rasponu 12-48°, na kojima postoji potencijalna opasnost od klizanja i linijske erozije prouzročene bujičnim tokovima. Kao i u zoni IIa, klizišta uglavnom nastaju na granici matične stijene i površinskih naslaga, te su također poznata mnoga klizišta nastala na geološkoj granici između gornjopontskih i pleistocenskih naslaga.

Zona IIc originalno je nazvana „Medvedničko prigorje/podsljemenska urbanizirana zona – uzvisina starijeg kvartara i nanosa brdskih potoka“. Zona je dominantno izgrađena od kvartarnih inženjerskih tala, a relativno tanke površinske naslage se sastoje od deluvijalnih, koluvijalnih i eluvijalnih naslaga. S obzirom da se ova zona gotovo u potpunosti nalazi izvan granice naselja grada Zagreba, dominantni pokrov je poljoprivredno zemljište (oko 52 % površine zone), a oko 15 % zauzimaju umjetne površine. Oko 77 % područja ove zone je nagiba manjeg od 3°, zbog čega je mogućnost pojave klizišta ograničena na svega 23 % površine.

Istraživano područje obuhvaća zone IIa i IIb, odnosno zonu "Medvedničko prigorje/podsljemenska urbanizirana zona – periklinarno položene mlađe naslage (neogenske i starije kvartarne)" i zonu "Medvedničko prigorje/Podsljemenska urbanizirana zona – strukture boranja u mlađim neogenskim naslagama" te rubne dijelove zone I ("Gorska jezgra Medvednice") te zone IIc ("Medvedničko prigorje/Podsljemenska urbanizirana zona – uzvisina starijeg kvartara i nanosa brdskih potoka") i IIIb ("Prisavska naplavna ravnica – savske naplavine"). Pilot područje se nalazi u središnjem dijelu zone IIa - "Medvedničko prigorje/Podsljemenska urbanizirana zona – periklinarno položene mlađe naslage (neogenske i starije kvartarne)".

3.7 Postojeće karte klizišta na području podsljemenske zone Grada Zagreba

Na području Grada Zagreba u posljednjih 50-ak godina izrađena su četiri inventara klizišta i to u okviru sljedećih studija ili istraživanja:

1. Studija *„Inženjerska geologija Zagreb – sjever i jug“* (Šikić, 1967);

2. Studija *„Litološka obrada i kategorizacija terena prema stabilnosti“* (Polak et al., 1979);

3. Studija *„Detaljna inženjerskogeološka karta Podsljemenske urbanizirane zone u mjerilu 1:5.000, DIGK – Faza I“* (Miklin et al., 2007); i

4. Doktorska disertacija *„Stereoskopska analiza klizišta i relativne opasnosti od klizanja na južnim obroncima Medvednice“* (Podolzski, 2014).

U slijedećim poglavljima ukratko su opisane navedene karte klizišta.

3.7.1 Karta klizišta objavljena 1967. godine

Sustavno prikupljanje podataka o klizištima započelo je u okviru studije *„Regionalna inženjerskogeološka istraživanja Zagreba i šire okolice“* (Magdalenić, 1966). Istraživanja je provodio Institut za geološka istraživanja u Zagrebu u razdoblju 1963.-1966. godine. Cilj studije je bio dati pregled geoloških, inženjerskogeoloških, hidrogeoloških i morfoloških značajki u svrhu izrade niza karata za planiranje detaljnijih istraživanja pojedinih lokacija za potrebe gradnje. Pod istim nazivom, 1968. godine objavljena je studija u pet knjiga (Šikić i Urumović, 1968) u okviru koje su objavljene inženjerskogeološka karta u mjerilu 1:100.000 (slika 3.16a) i karta podložnosti klizanju u mjerilu 1:100.000 (slika 3.16b). Na karti podložnosti klizanju u mjerilu 1:100.000 izdvojene su četiri zone prema sljedećim kriterijima: vrsti stijena/inženjerskih tala, broju registriranih klizišta, te morfološkim i hidrološkim karakteristikama. Knjiga 5 studije Šikić i Urumović (1968) sadrži popis od 187 klizišta za list Zagreb (u mjerilu 1:100.000). Lokacije klizišta nisu definirane koordinatama, tako da ih danas nije moguće smjestiti u prostoru, a karte iz navedene studije nisu sačuvane.

Sinteza istraživanja provedenih u razdoblju od 1963. do 1968. godine te interpretacija sakupljenih podataka objavljena je i u studiji pod nazivom *„Inženjerska geologija Zagreb sjever i jug“* (Šikić, 1967). U sklopu studije iz 1967. godine su izrađene hidrogeološke karte, inženjerskogeološke karte i karte podložnosti klizanju u mjerilu 1:10.000. Za područje Zagreb sjever očuvana je većina listova inženjerskogeološke karte i karte podložnosti klizanju, dok karte iz studije Zagreb jug nisu sačuvane. Inventar klizišta izrađen je na temelju terenskog

kartiranja na topografskim podlogama mjerila 1:10.000, a obuhvaća područje površine oko 125 km^2. Klizišta su klasificirana kao aktivna, umirena, fosilna klizišta i odroni. Na kartama su mjestimično prikazana pojedinačna klizišta, a pretežito su izdvajane zone opisane kao nestabilne padine s aktivnim klizištima, nestabilne padine s umirenim ili fosilnim klizištima, nestabilne padine i odroni. Ukupno je evidentirano 535 pojedinačnih pojava i zona klizišta, a relativna gustoća klizišta iznosi 4,3 klizišta/km^2. Površina kartiranih klizišta je u rasponu 607 do 506.932 m^2, a najbrojnija klizišta u inventaru su površine između 5.000 i 6.000 m^2. Osim klizišta, na kartama su prikazane i pojave, odnosno područja, intenzivne linijske erozije, tj. pojave jaružanja.

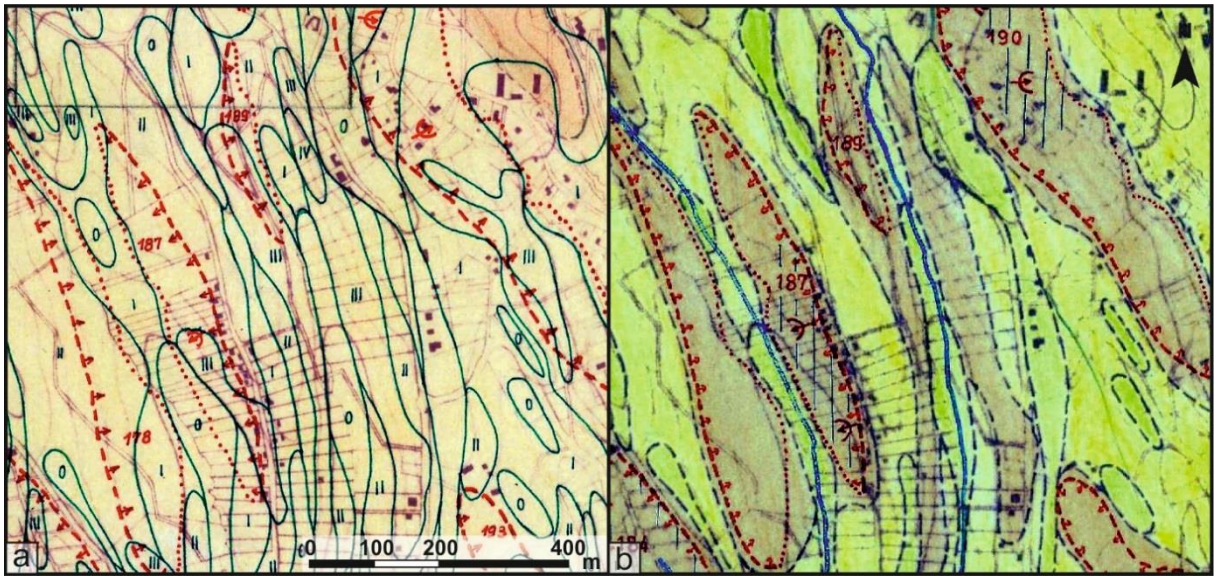

Slika 3.16 Isječak karata klizišta iz studije Inženjerska geologija Zagreb sjever i jug (Šikić, 1967): (a) inženjerskogeološka karta s prikazom klizišta, zona nestabilnosti i erozije, inženjerskogeoloških jedinica izdvojenih s obzirom na litološke značajke stijena i tala i zoniranje područja s obzirom na nagib terena; (b) karta podložnosti na klizanje sa zonama i granicama klizišta.

3.7.2 Karta klizišta objavljena 1979. godine

Studiju „*Litološka obrada i kategorizacija terena prema stabilnosti tla obronaka Medvednice na području grada Zagreba"* izradila je 1979. godine. tvrtka Geotehnika-Geoxpert d.o.o. U okviru studije izrađene su dvije karte klizišta mjerila 1:10.000: (1) litološka karta s prikazom klizišta i drugih aktivnih geomorfoloških procesa (slika 3.17a); i (2) karta zoniranja terena prema podložnosti klizanju (slika 3.17b).

Inventar klizišta obuhvaća područje površine 105 km^2, a izrađen je terenskim kartiranjem, primjenom daljinskih istraživanja te interpretacijom postojećih podataka o klizištima. Pojave klizišta ucrtane su na topografsku podlogu mjerila 1:10.000, a klizišta su klasificirana kao: aktivna klizišta, umirena klizišta, puzišta i odroni. Osim navedenih aktivnih geomorfoloških

procesa, na karti su prikazani i bujični tokovi, umjetni iskopi, nasipi, deponije, siparišta i močvarna područja. Prema navedenim kriterijima u ovom inventaru je registrirano ukupno 1.019 pojava, od kojih je 812 klizišta (406 aktivna klizišta, 294 umirena klizišta, 112 pojava puzanja) i 58 siparišta kartiranih na temelju kriterija u tablici 3.6. Ukupna površina klizišta je 2,44 km^2, odnosno 2,32 % površine područja istraživanja, a relativna gustoća klizišta je 9,7 klizišta/km^2. Površina kartiranih klizišta je u rasponu 454 do 289.501 m^2, a najbrojnija klizišta u inventaru su površine između 4.000 i 5.000 m^2.

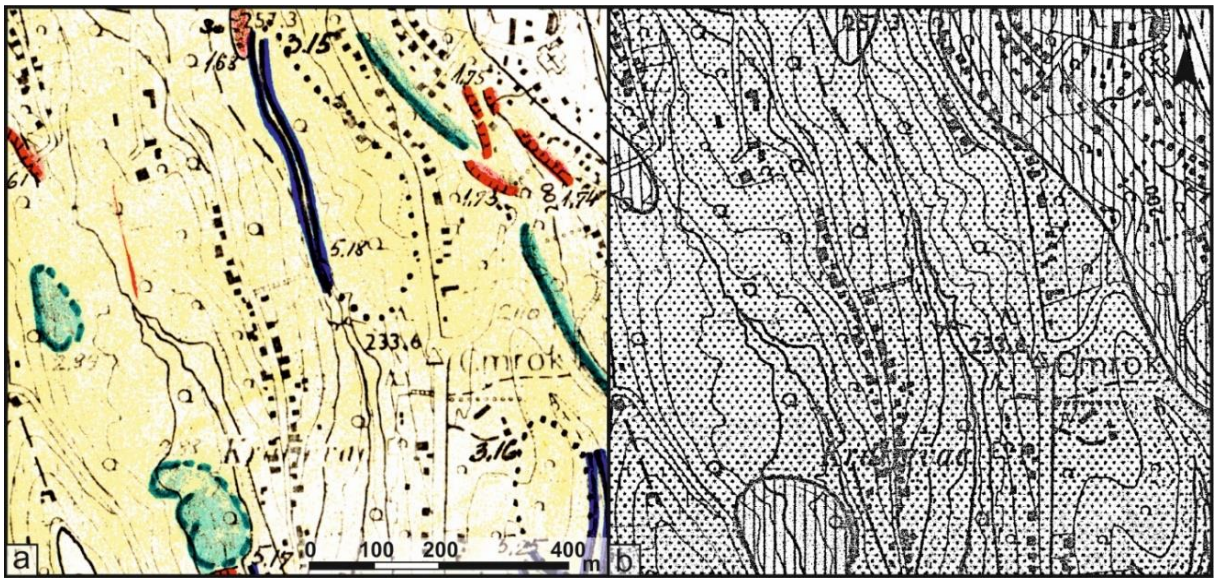

Slika 3.17 Isječak karata klizišta iz studije „Litološka obrada i kategorizacija terena prema stabilnosti tla obronaka Medvednice na području grada Zagreba“ (Polak et al., 1979): (a) litološka karta s prikazom klizišta i drugih aktivnih geomorfoloških procesa; (b) karta zoniranja terena prema podložnosti klizanju (točke - II. kategorija, uvjetno stabilne padine; vertikalne linije – III. kategorija, uvjetno nestabilne padine).

Tablica 3.6 Kriteriji za kartiranje i klasifikaciju klizišta u studiji „*Litološka obrada i kategorizacija terena prema stabilnosti tla obronaka Medvednice na području grada Zagreba*“ iz 1979. godine.

Vrsta klizišta	Opis
Aktivna klizišta	Prepoznatljiva su po amfiteatralnom (školjkastom) obliku gornjeg dijela klizišta s vidljivim svježim pukotinama bez vegetacije, glavnoj pukotini u obliku ožiljka, blatnom toku, zoni akumulacije u donjem dijelu klizišta, udubljenjima površine terena s akumulacijama vode na površini, nepravilnoj topografiji površine pokrenute mase klizišta, deformiranim stablima (tzv. "pijana" šuma) ili osušenim stablima. Kao aktivna su označena i ona klizišta za koja se zna da su bila aktivna proteklih 10 godina, iako se na njima ne primjećuju svi navedeni znakovi.
Umirena klizišta	Prepoznatljiva su po amfiteatralnom (školjkastom) obliku klizišta s granicama obraslim travom, nepravilnoj topografiji površine pokrenute mase s ispupčenjima i uleknućima širine 2-5 m, nepravilnih nagiba, udubljenjima s akumuliranom vodom. Kod umirenih klizišta obično je jedan dio klizišta nejasan ili čak sasvim erodiran i to većinom nožični.
Puzanje	Dijelovi padina na kojima granice klizišta nisu bile vidljive ili su bile nejasne, a topografija površine terena ukazuje na nestabilnost, ali do sloma materijala nije došlo, te su prisutni brojni pokazatelji malih lokalnih pomaka. Puzanja obično obuhvaćaju čitavu padinu ili dvije susjedne padine.
Odroni	Karakterizirani granicama koje su vrlo izdužene u smjeru kretanja materijala, glavna pukotina je relativno visoka, nagib kosine je vrlo strm. Odroni su registrirani u stijenskoj masi ili u tlu.

3.7.3 Karta klizišta objavljena 2007. godine

Hrvatski geološki institut (HGI) je 2007. godine izradio kartu inventara klizišta (slika 3.18) nazvanu „*Detaljna inženjerskogeološka karta Podsljemenske urbanizirane zone u mjerilu 1:5.000, DIGK – Faza I*“ (Miklin et al., 2007). Obuhvat karte klizišta iz 2007. godine je 175 km^2. U okviru terenskog kartiranja registrirana su i klizišta i nestabilne padine pri čemu je izdvojeno ukupno 707 pojava. U obrascima klizišta se nalaze podaci o klizištima, kao što su opis lokacije, tip klizišta i vrsta materijala u klizanju, dimenzije klizišta, geomorfologija padine, uzroci pojave, kinematika klizišta, štete i provedene mjere sanacije. Ukupno 707 registriranih pojava klasificirano je na sljedeći način: 538 klizišta, 11 puzišta do klizišta, 15 klizišta do tecišta, 14 odrona, 114 puzišta i 15 pojava nedefiniranog tipa. Za 706 klizišta definiran je stupanj aktivnosti i to na sljedeći način: 265 aktivnih klizišta, 244 umirenih klizišta, 13 stabiliziranih klizišta, 184 potencijalnih klizišta ili klizišta u početnim fazama razvoja. Na većem dijelu područja obuhvata studije registrirane su nestabilne zone kojima je obuhvaćeno više klizišta tj. na više lokacija nisu određene granice pojedinačnih klizišta, nego veće zone, interpretirane kao nestabilne. Granice pojedinih klizišta izdvojene su uglavnom za klizišta za koja postoje podaci u geotehničkim izvještajima. Ukupna površina klizišta je 20,23 km^2, a zauzima 11,56 % površine područja istraživanja s relativnom gustoćom klizišta od 4,0 klizišta/km^2. Površina kartiranih klizišta je u rasponu 284 do 927.168 m^2, a najbrojnija klizišta u inventaru su površine oko 9.000 m^2.

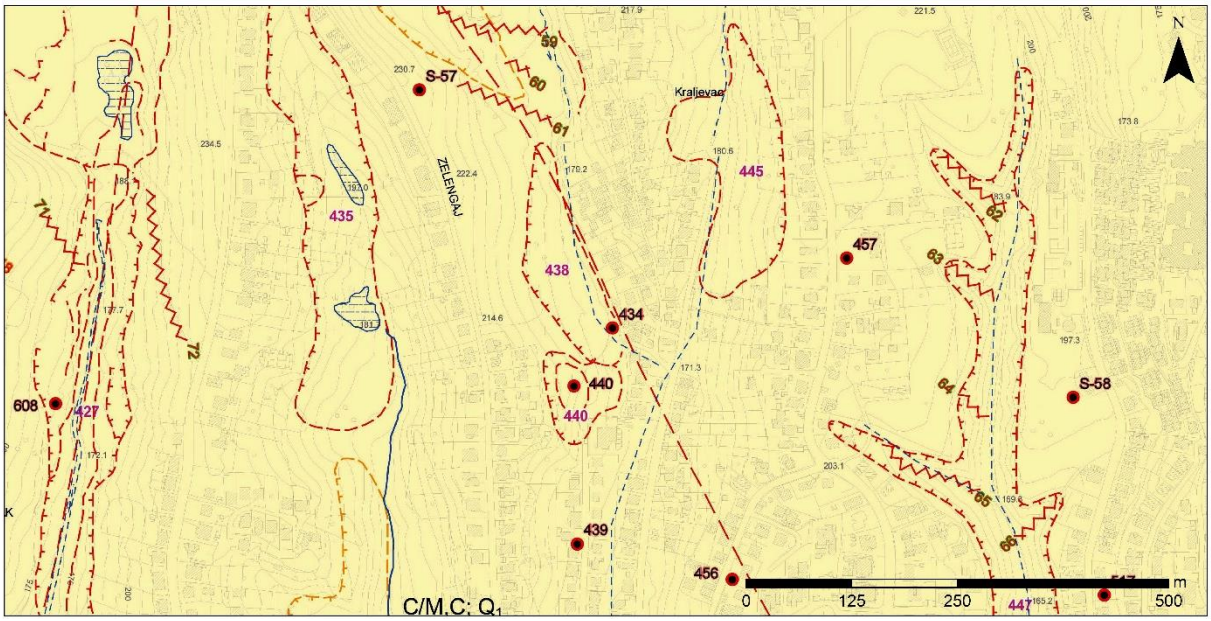

Slika 3.18 Isječak „Detaljne inženjerskogeološke karte Podsljemenske urbanizirane zone“ originalnog mjerila 1:5000 (Miklin et al., 2007).

3.7.4 Karte klizišta objavljena 2014. godine

U okviru doktorske disertacije pod nazivom *„Stereoskopska analiza klizišta i relativne opasnosti od klizanja na južnim obroncima Medvednice“* (Podolszki, 2014) izrađena su dva inventara klizišta (slika 3.19) na temelju vizualne analize stereoparova avionskih snimki iz 1964. godine mjerila 1:8.000 i iz 1998. godine mjerila 1:20.000. Identificirana klizišta su na temelju analitičkog hijerarhijskog procesa (AHP) klasificirana s obzirom na pouzdanost identifikacije i prema mogućnosti daljnjeg razvoja klizišta. Također, iz rezultata istraživanja vidljiv je vrlo velik utjecaj erozijskog djelovanja vodotoka i antropogen utjecaj na stvaranje i razvoj klizišta. Inventar klizišta izrađen na temelju stereomodela iz 1964. godine obuhvaća područje površine 54,14 km^2 i sadrži ukupno 963 klizišta. Ukupna površina klizišta prema stereomodelu iz 1964. godine je 2,05 km^2, odnosno 3,8 % površine područja istraživanja, dok je relativna gustoća klizišta 17,8 klizišta/km^2. Površina kartiranih klizišta na steremodelu iz 1964. godine je u rasponu 78 do 281.886 m^2, a najbrojnija su klizišta površine oko 1.000 m^2. Inventar klizišta izrađen na temelju stereomodela iz 1998. godine obuhvaća područje površine 99,79 km^2 i sadrži ukupno 1.229 klizišta. Ukupna površina klizišta prema stereomodelu iz 1998. godine je 7,28 km^2, odnosno 7,3 % površine područja istraživanja, a relativna gustoća klizišta je 12,3 klizišta/km^2. Površina kartiranih klizišta na steremodelu iz 1998. godine je u rasponu 103 do 276.643 m^2, a najbrojnija klizišta u inventaru su površine oko 5.000 m^2.

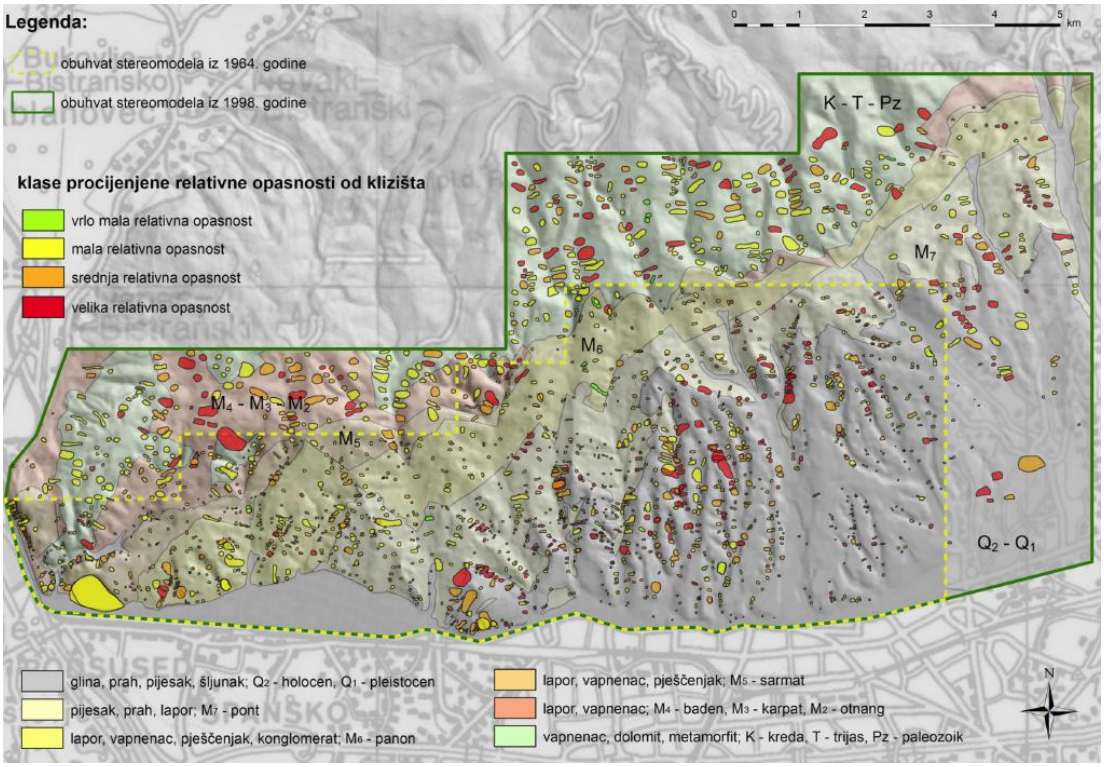

Slika 3.19 Sintezna karta procijenjene relativne opasnosti od klizišta prema stereomodelima iz 1964. i 1998. godine za područje istraživanja na južnim obroncima Medvednice (Podolszki, 2014).

4 METODE ISTRAŽIVANJA

U ovom poglavlju opisane su metode interpolacije primijenjene za izradu LiDAR DMT-a visoke rezolucije, metoda izrade inventara klizišta vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a te statističke analize i metode primijenjene za izradu modela za automatizirano kartiranje klizišta na temelju morfometrijskih parametara. U nastavku su ukratko opisane i metode primijenjene za usporedbu inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a s postojećim inventarima klizišta. Na kraju je opisana metoda bivarijantne statističke analize kojom je analizirana mogućnost primjene inventara klizišta dobivenog automatiziranim kartiranjem za izradu karte podložnosti na klizanje.

4.1 Metode interpolacije i prostorna rezolucija LiDAR DMT-a

Nakon laserskog skeniranja iz zraka slijedi postupak filtriranja i klasifikacije oblaka točaka te primjena neke od postojećih metoda interpolacije za izradu DMT-a visoke rezolucije. Za izradu DMT-a bez vegetacije koriste se samo točke klasificirane kao teren, odnosno površina Zemlje. Interpolacija je postupak računanja nove vrijednosti koja se nalazi između dviju ili više poznatih vrijednosti. Iznos dobiven interpolacijom nikada ne prelazi interval određen točkama između kojih se računa, a vrijednosti dobivene interpolacijom svrstavaju se u područje mogućega (Malvić, 2008). Za prikaz digitalnog modela terena koristi se 2.5D prikaz terena, a to može biti nepravilna mreža trokuta (engl. *triangulated irregular network - TIN*) i rasterski model, odnosno rešetka ili matrica položaja s visinama (GRID). Rasterski prikaz DMT-a je mnogo češći jer omogućava različite morfometrijske analize, za razliku od TIN-a za koji ne postoje razvijeni algoritmi za često korištene operacije prilikom prostornih analiza. Prema jednoj od podjela interpolacijskih metoda, razlikuju se determinističke metode koje koriste matematičke funkcije za izračunavanje nepoznatih vrijednosti na temelju vrijednosti izmjerenih podataka, i geostatističke ili stohastičke metode koje koriste statistička svojstava i metode prostorne autokorelacije između podataka i trendova površine. Često korištene determinističke metode interpolacije su metoda inverzne udaljenosti (engl. *inverse distance weighting*, IDW), metoda prirodnih susjeda (engl. *natural neighbor*), ANUDEM (engl. *Australian National University DEM*) ili metoda *Topo to Raster* (alat u *ArcGIS Toolbox-u*). Najpoznatija geostatistička metoda interpolacije je kriging (engl. *kriging*).

Metoda inverznih udaljenosti je jedna od najčešće korištenih metoda interpolacije jer ne zahtjeva opsežna znanja i donošenje složenih odluka kod izbora parametara (Mitas i Mitasova, 1999). Metoda se temelji na pretpostavci da izmjerene točke koje su udaljenije od lokacije za

koju se procjenjuje vrijednost imaju manji utjecaj na istu. Nepoznate vrijednosti procjenjuju se na temelju vrijednosti okolnih izmjerenih točaka. Opća formula inverzne udaljenosti je (Li i Heap, 2008):

$$z(s_0) = \sum_{i=1}^{N} \lambda_i Z(s_i) \quad (1)$$

gdje je:

$z(s_0)$ – predviđena vrijednost na lokaciji s_0,

N – broj izmjerenih točaka oko lokacije predviđanja,

λ_i – ponderi (težinski koeficijenti) dodijeljeni pojedinim izmjerenim točkama,

$Z(s_i)$ – vrijednosti određene na lokaciji s_i.

Određenom broju izmjerenih točaka unutar definiranog radijusa dodjeljuju se ponderi (težinski koeficijenti), koji su definirani kao:

$$\lambda_i = \frac{\frac{1}{d_i^p}}{\sum_{i=1}^{N} \frac{1}{d_i^p}} \quad (2)$$

gdje je:

d_i – udaljenost između izmjerenih vrijednosti i točke čija vrijednost se procjenjuje,

N – broj izmjerenih točaka koje se koriste za procjenu,

p – eksponent udaljenosti.

Glavni faktor koji utječe na točnost izlaznih rezultata je eksponent udaljenosti koji je proizvoljan, no najčešće se uzima vrijednost dva koja se naziva i inverzni kvadrat udaljenosti (Luo et al., 2007). Kod metode inverzne udaljenosti se ne može dogoditi da procijenjena vrijednost bude manja od minimalne i veća od maksimalne vrijednosti okolnih izmjerenih točaka koje se koriste u proračunu.

Metoda prirodnih susjeda je metoda ponderiranog prosjeka kojom se procjenjuje vrijednost pomoću lokalnih koordinata prirodnog susjeda na temelju Voronoijevih poligona (slika 4.1a). Svaki Voronoijev poligon izgrađen je od dijelova trokuta koji proizlaze iz Deulaunayeve triangulacije, pri čemu centroidi poligona predstavljaju vrhove trokuta (slika 4.1b). Da bi se

odredila lokalna koordinata procjenjivane vrijednosti p_v, potrebno je poznavati broj točaka i površinu svih poligona u mreži. Princip rada metode prikazan je na slici 4.1c, za područje Voronoijeve nepravilne mreže privremeno se odredi točka *P* u središtu Deulaunayevog trokuta. To rezultira promjenom u mreži, točnije stvaranjem novog poligona koji je nastao Voronoijevom metodom (slika 4.1d). On se preklapa sa starom mrežom, pri čemu novi poligon prividno sadržava više dijelova starijih poligona koji imaju različite površine (slika 4.1e). Kod određivanja pondera vrijedi pravilo da se većem poligonu pridodaje veći težinski koeficijent i obrnuto. (slika 4.1f), a zbroj koeficijenata mora iznositi jedan.

ANUDEM je interpolacijska metoda posebno dizajnirana za stvaranje hidrološki točnog digitalnog modela reljefa, a temelji se na algoritmu ANUDEM kojeg je razvio Hutchinson (1989). Algoritam uzima u obzir nagle promjene na površini modela, kao što su grebeni, jaruge, potoci itd. U metodi se koristi Gauss-Seidkerova iterativna metoda izračuna koja je optimizirana da bude računski učinkovita kao lokalna interpolacijska metoda (npr. inverzna udaljenost), međutim bez gubljenja površinskog kontinuiteta koji je karakterističan za globalne interpolacijske metode (Childs, 2004). Pomoću ove metode uklanjanju se sve lažne lokalne erozijske baze (udubljenja) u izlaznom modelu, jer algoritam pretpostavlja da su sva udubljenja pogreške s obzirom da je njihova pojavnost u prirodi vrlo rijetka (Goodchild i Mark, 1987). Algoritam ne uklanja udubljenja koja imaju visinske razlike više nego što ih korisnik definira vertikalnom tolerancijom (zadana vrijednost je obično pola ekvidistance).

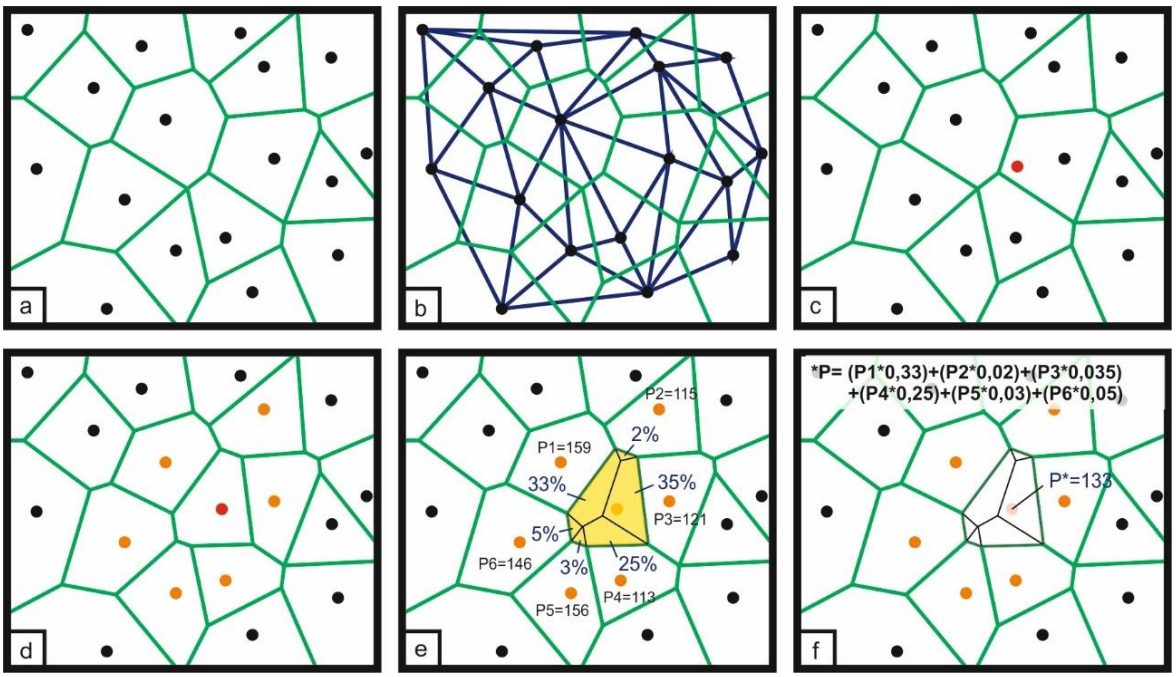

Slika 4.1 Primjer interpolacije oblaka točaka primjenom metode prirodnih susjeda: (a)Voronijevi poligoni; (b) Deulaunayeva triangulacija; (c) središte Deulaunayevog trokuta; (d) definiranje novog poligona primjenom Voronoijeve metode; (e) lokalne koordinate; (f) ponderiranje lokalnih koordinata.

Kriging je geostatistička interpolacijska metoda svrstana u kategoriju najboljeg linearnog nepristranog procjenitelja (Skoien et al., 2005; Kleijnen, 2007). Smatra se najzahtjevnijom i najčešće korištenom metodom interpolacije, za čije je pravilno i uspješno korištenje potrebno opsežno znanje. Za razliku od inverzne udaljenosti u kojoj težinski koeficijent ovisi o udaljenosti, u metodi kriging težinski koeficijent ovisi o udaljenosti i prostornom odnosu između izmjerenih točaka koje utječu na točku za koju se procjenjuje vrijednost. Najznačajnije svojstvo kriginga je da mjerene veličine zadržava kao nepromjenjive, što znači da izravno uključuje izvorni skup podataka koji se u procesu interpolacije neće mijenjati (Pribičević et al., 2007; Medved et al., 2010). Kriging metoda je postupak kojem prethodi modeliranje (analiza) semivariograma, odnosno određivanje prostorne varijabilnosti točaka, udaljenosti i smjera (Bezzi i Vitti, 2005). Variogram je osnovno sredstvo vrednovanja i kvantificiranja prostorne zavisnosti odabrane varijable u prostoru (Malvić i Gaćeša, 2006). U praksi, variogram predstavlja prosjek kvadrata razlika dviju vrijednosti računatih kao funkcije udaljenosti tih vrijednosti (Medak et al., 2008).

Prilikom interpolacije digitalnog modela terena iz oblaka točaka dobivenog laserskim skeniranjem vrlo je važna prostorna rezolucija modela, odnosno veličina piksela. Odgovarajuća veličina piksela ovisi o gustoći prikupljenih podataka, složenosti terena (vertikalnoj raščlanjenosti) i primjeni. Gustoća uzorkovanja ili gustoća oblaka točaka predstavlja broj snimljenih točaka po metru kvadratnom te značajno utječe na točnost DMT-a visoke rezolucije dobivenog laserskim skeniranjem (Heritage et al., 2009; Chu et al., 2014). Chu et al. (2014) su analizirali utjecaj gustoće uzorkovanja oblaka točaka na mogućnost identifikacije čeonih pukotina te su zaključili da gustoća uzorkovanja ponajviše ovisi o namjeni zemljišta. Na primjer, u gustim šumama je broj reflektiranih zraka s površine Zemlje znatno manji, a to izravno utječe na točnost DMT-a. Općenito, što se više točaka prikupi laserskim skeniranjem iz zraka to će digitalni model reljefa istraživanog područja biti reprezentativniji. No, gustoća uzorkovanja prilikom laserskog skeniranja je često ograničena i visinom leta i frekvencijom lasera, što ovisi o raspoloživim financijskim sredstvima i vrsti laserskog skenera.

Prema Hengl (2006) reprezentativna prostorna rezolucija DMT-a interpoliranog iz oblaka točaka se može odrediti pomoću metode kartografskog pravila (engl. *cartographic concept*), metode gustoće točaka (engl. *inspection density*) te metode prosječnih najkraćih udaljenosti između dviju točaka (engl. *average spacing between the closest point pairs*).

Prema Vink (1975) najmanja vidljiva površina (engl. *minimum legible delineation, MLD*) koja se prikazuje na karti, neovisno o mjerilu karte, iznosi 0,25 cm^2. Rossiter (2003) predlaže da su

četiri piksela ekvivalent najmanjoj vidljivoj površini. Prema tome odgovarajuća veličina ćelije (piksela) se može procijeniti iz mjerila (engl. *scale number, SN*):

$$p \leq \sqrt{\frac{MLD}{4}} = \frac{\sqrt{SN^2 \cdot 0{,}000025}}{2} = SN \cdot 0{,}0025 \tag{3}$$

gdje je:

p – veličina ćelije (piksela),

MLD – najmanja vidljiva površina na karti,

SN – mjerilo karte.

Odgovarajuća veličina piksela se može odrediti i preko veličine najmanjeg objekta kojeg želimo kartirati (Hengl, 2006). Ako je definirano da minimalno četiri piksela čine najmanji objekt te da minimalno dva piksela predstavljaju izduženi objekt, matematički se to može izraziti na slijedeći način:

$$p \leq \begin{cases} \frac{\sqrt{a_{MLD}}}{4} \; ako\; je\; S < 3 \\ \frac{w_{MLD}}{2} \; ako\; je\; S \; > 3 \end{cases} \tag{4}$$

gdje je:

a_{MLD} – površina najmanjeg objekta,

w_{MLD} – širina izduženog objekta,

S – indeks oblika (engl. *shape index*).

Indeks oblika se može opisati slijedećim izrazom:

$$S = \frac{P}{2 \cdot r \cdot \pi}, \qquad r = \sqrt{\frac{a}{\pi}} \tag{5}$$

gdje je:

P – opseg objekta,

a – površina objekta,

r – radijus kruga koji ima istu površinu kao i promatrani objekt.

DMT se dobiva interpolacijom oblaka točaka, a kako bi model terena bio reprezentativan nužna je podjednaka gustoća točaka po jedinici površine, koja se još naziva i kontrola gustoće (engl. inspection density). Preporučena veličina piksela prema metodi kontrole gustoće određuje se prema jednadžbi (Hengl, 2006):

$$p = 0{,}25 \cdot \sqrt{\frac{A}{N}} \tag{6}$$

gdje je

N – broj izmjerenih točaka,

A – je površina istraživanog područja.

Rezolucija DEM-a može se odrediti i na temelju Nyquist-ovog koncepta frekvencije (Shannon, 1949) prema kojem bi veličina piksela trebala biti polovica srednje najkraće udaljenosti između dvije točke (Hengl, 2006):

$$p \leq \frac{\overline{h_{ij}}}{2} \tag{7}$$

gdje je:

h_{ij} – srednja udaljenost između dviju najbližih točaka (engl. *average spacing between the closest point pairs*).

4.2 Vizualna identifikacija i kartiranje klizišta na LiDAR DMT-u

Vizualna identifikacija i kartiranje klizišta na pilot području površine 21 km^2 provedeno je interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a snimljenog u prosincu 2013. godine. LiDAR DMT visoke rezolucije i izvedene morfometrijske karte omogućavaju vrlo točno, odnosno precizno i pouzdano kartiranje klizišta u detaljnom mjerilu (Petschko et al., 2015), osobito na područjima prekrivenim gustom vegetacijom (Van den Eeckhaut et al., 2007), kao što je podsljemenska zona Grada Zagreba (Mihalić et al., 2011).

Morfometrijske karte korištene prilikom vizualne identifikacije klizišta na pilot području u podsljemenskoj zoni Grada Zagreba izrađene su u *ArcGIS-u 10.0* iz digitalnog modela terena rezolucije 0,3x0,3 m. Za identifikaciju morfologije klizišta korištene su tri morfometrijske karte (slika 4.2), a to su karta osjenčanog reljefa (engl. *hillshade map*), karta nagiba terena (engl. *slope map*) i karta slojnica ekvidistancije 0,5 m (engl. *conture map*). U poglavlju 5.3 dan je kratki opis pojedinih morfometrijskih karata, metode njihove izrade te primjena izvedenih karata prilikom identifikacije i kartiranja klizišta.

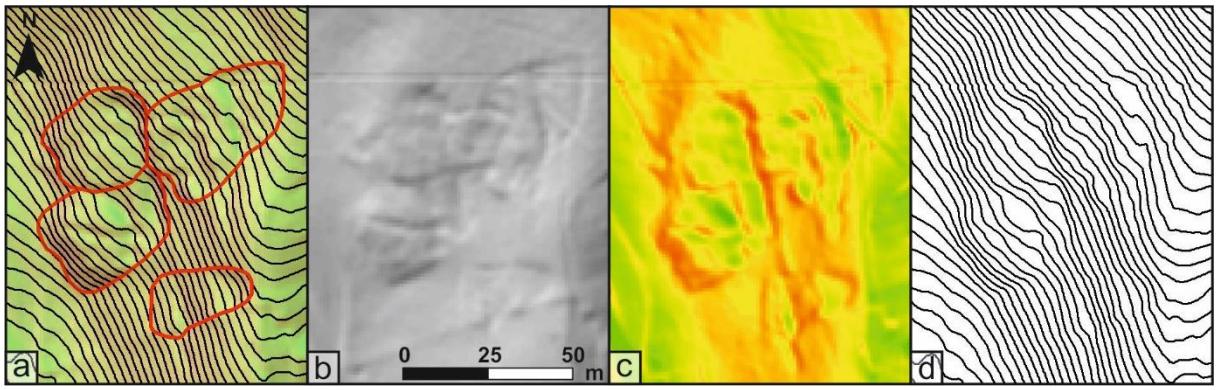

Slika 4.2 Primjer klizišta identificiranih i kartiranih na izvedenim morfometrijskih kartama: (a) prozirna karta nagiba na karti osjenčanog reljefa sa slojnicama ekvidistancije 1m; (b) karta osjenčanosti terena; (c) karta nagiba terena; (d) karta slojnica ekvidistancije 1 m.

Osim izvedenih morfometrijskih karata, prilikom vizualne identifikacije i kartiranja klizišta na pilot području površine 21 km^2 korištene su ortofoto (DOF) snimke iz 2012. godine (slika 4.3) i Google Earth satelitske snimke iz rujna 2012. i kolovoza 2013. godine. Avionske i satelitske snimke pilot područja korištene su kako bi se provjerilo da li su pojedini morfološki oblici nastali antropogenim zahvatom u okolišu, npr. nasipi uz prometnice i građevine ili odlagališta otpada mogu imati sličnu morfologiju kao i klizišta na morfometrijskim kartama izvedenim iz LiDAR DMT-a. Satelitske snimke iz razdoblja prije i poslije zime 2012./2013. godine, u kojemu je registrirana pojava više od 50 klizišta (Bernat et al., 2014b), nisu omogućile izradu sezonskog inventara klizišta. Naime, klizišta nisu vidljiva na satelitskim snimkama zbog

vegetacije, a vidljivost malih klizišta (<400 m^2) nije moguća zbog niske rezolucije same snimke.

Slika 4.3 Primjer vidljivosti klizišta na DOF snimku iz 2012. godine.

Klizišta su identificirana na temelju strme, konkavne glavne pukotine, zatim nožice klizišta karakterističnog konveksnog oblika te nepravilne morfologije samog klizišta koji su bili vidljivi na različitim kombinacijama morfometrijskih karata izvedenih iz LiDAR DMT-a (slika 4.2). Za svako klizište opisana je pouzdanost, odnosno stupanj sigurnosti da identificirana pojava predstavlja klizište. U tablici 4.1 definirana su dva stupnja pouzdanosti klizišta s obzirom na vidljivost/očuvanost glavnih dijelova klizišta (zone depresije i zone akumulacije) te same morfologije klizišta (slika 4.4). Kartiranje klizišta provedeno je u mjerilu 1:100 radi iscrtavanja što preciznijih granica klizišta. Preciznost iscrtavanja klizišta ovisi o izraženosti morfologije klizišta i relativnoj starosti klizišta. S obzirom na navedeno, za svako identificirano klizište određen je stupanj preciznosti kartiranja (slika 4.5). U tablici 4.2 definirana su tri stupnja preciznosti kartiranja klizišta s obzirom na izraženost morfologije klizišta.

Tablica 4.1 Stupanj pouzdanosti kartiranja klizišta na morfometrijskim kartama izvedenim iz DMT-a.

Pouzdanost	Opis
pouzdano	kartirana pojava je subjektivno definirana kao pouzdano identificirano klizište na temelju jasno izraženih dijelova i morfologije klizišta na izvedenim morfometrijskim kartama
nepouzdano	kartirana pojava je subjektivno definirana kao nepouzdano identificirano (pretpostavljeno) klizište na temelju slabo izraženih dijelova i morfologije klizišta na izvedenim morfometrijskim kartama, ili izostanka određenih dijelova klizišta (akumulacije) zbog erozije, sanacije klizišta ili drugih antropogenih zahvata u okolišu

Tablica 4.2 Stupanj preciznosti kartiranja klizišta na morfometrijskim kartama izvedenim iz DMT-a.

Preciznost	Opis
visoka	granica klizišta kartirana je s visokom preciznošću na temelju jasno izražene čeone pukotine, nožice i bokova klizišta
srednja	granica klizišta kartirana je sa srednjom preciznošću na temelju čeone pukotine i nožice klizišta, dok su bokovi klizišta slabije izraženi
niska	granica klizišta kartirana je s niskom preciznošću, odnosno pretpostavljena je na temelju zone depresije i zone akumulacije, glavna pukotina, bokovi i nožica klizišta nisu jasno izraženi

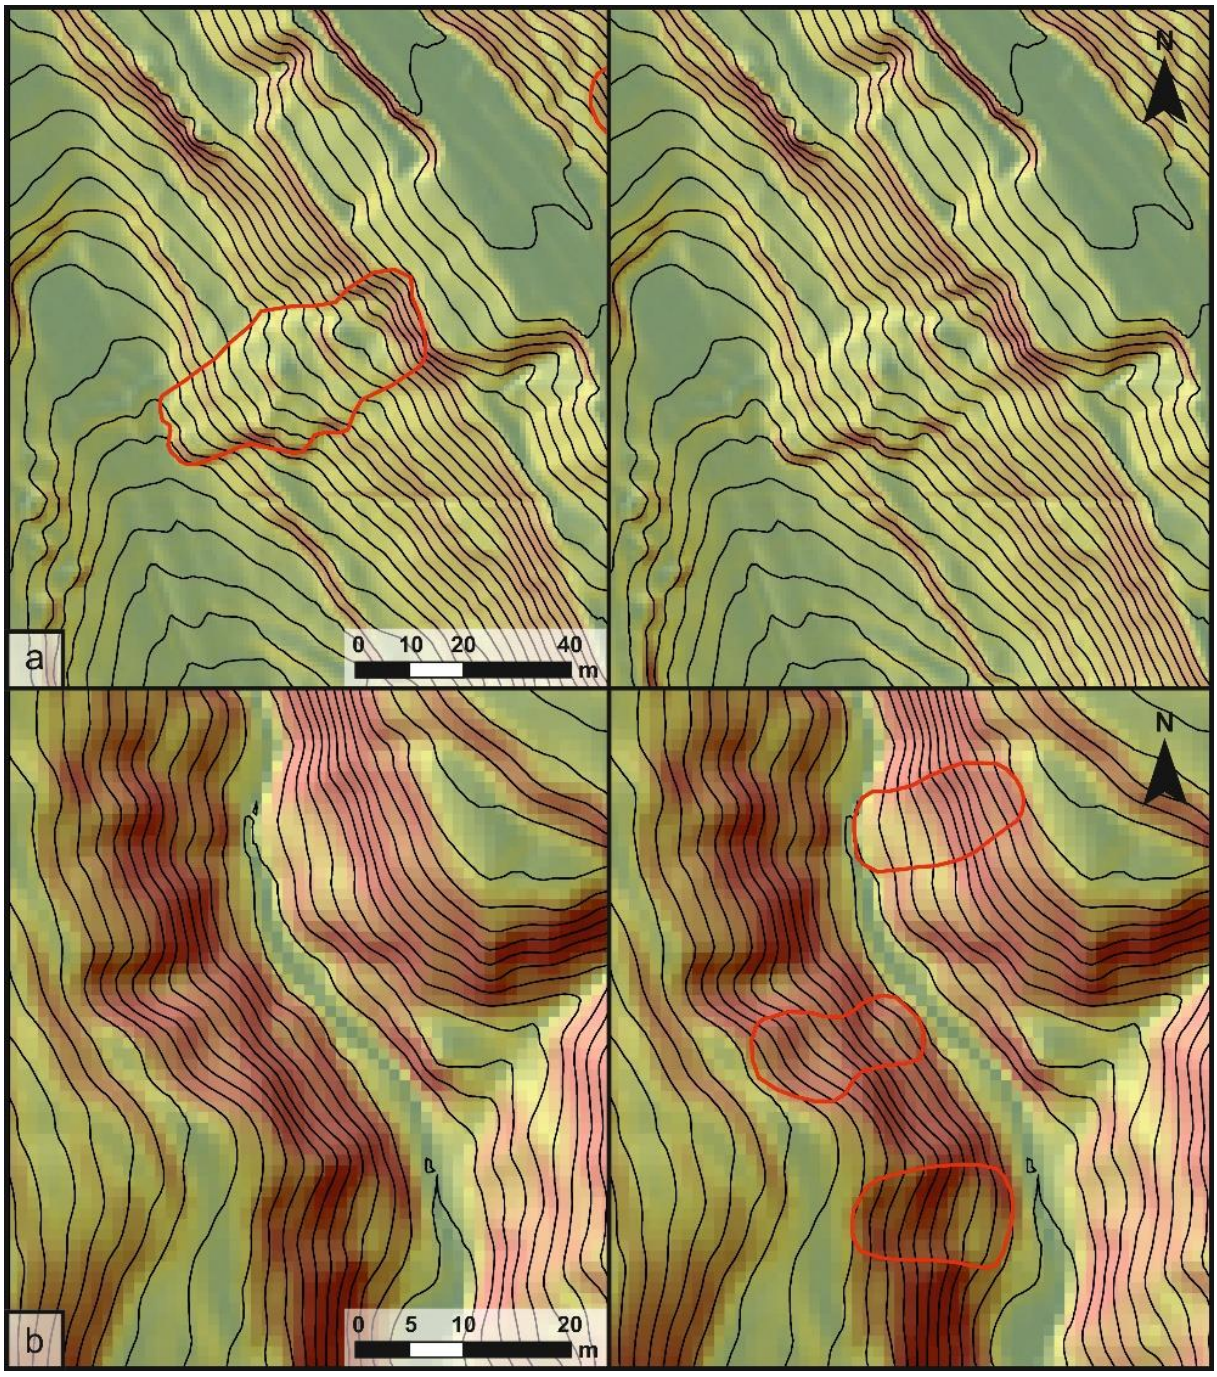

Slika 4.4 Procjena pouzdanosti identifikacije klizišta: (a) pouzdano identificirano klizište; (b) nepouzdano identificirana (pretpostavljena) klizišta.

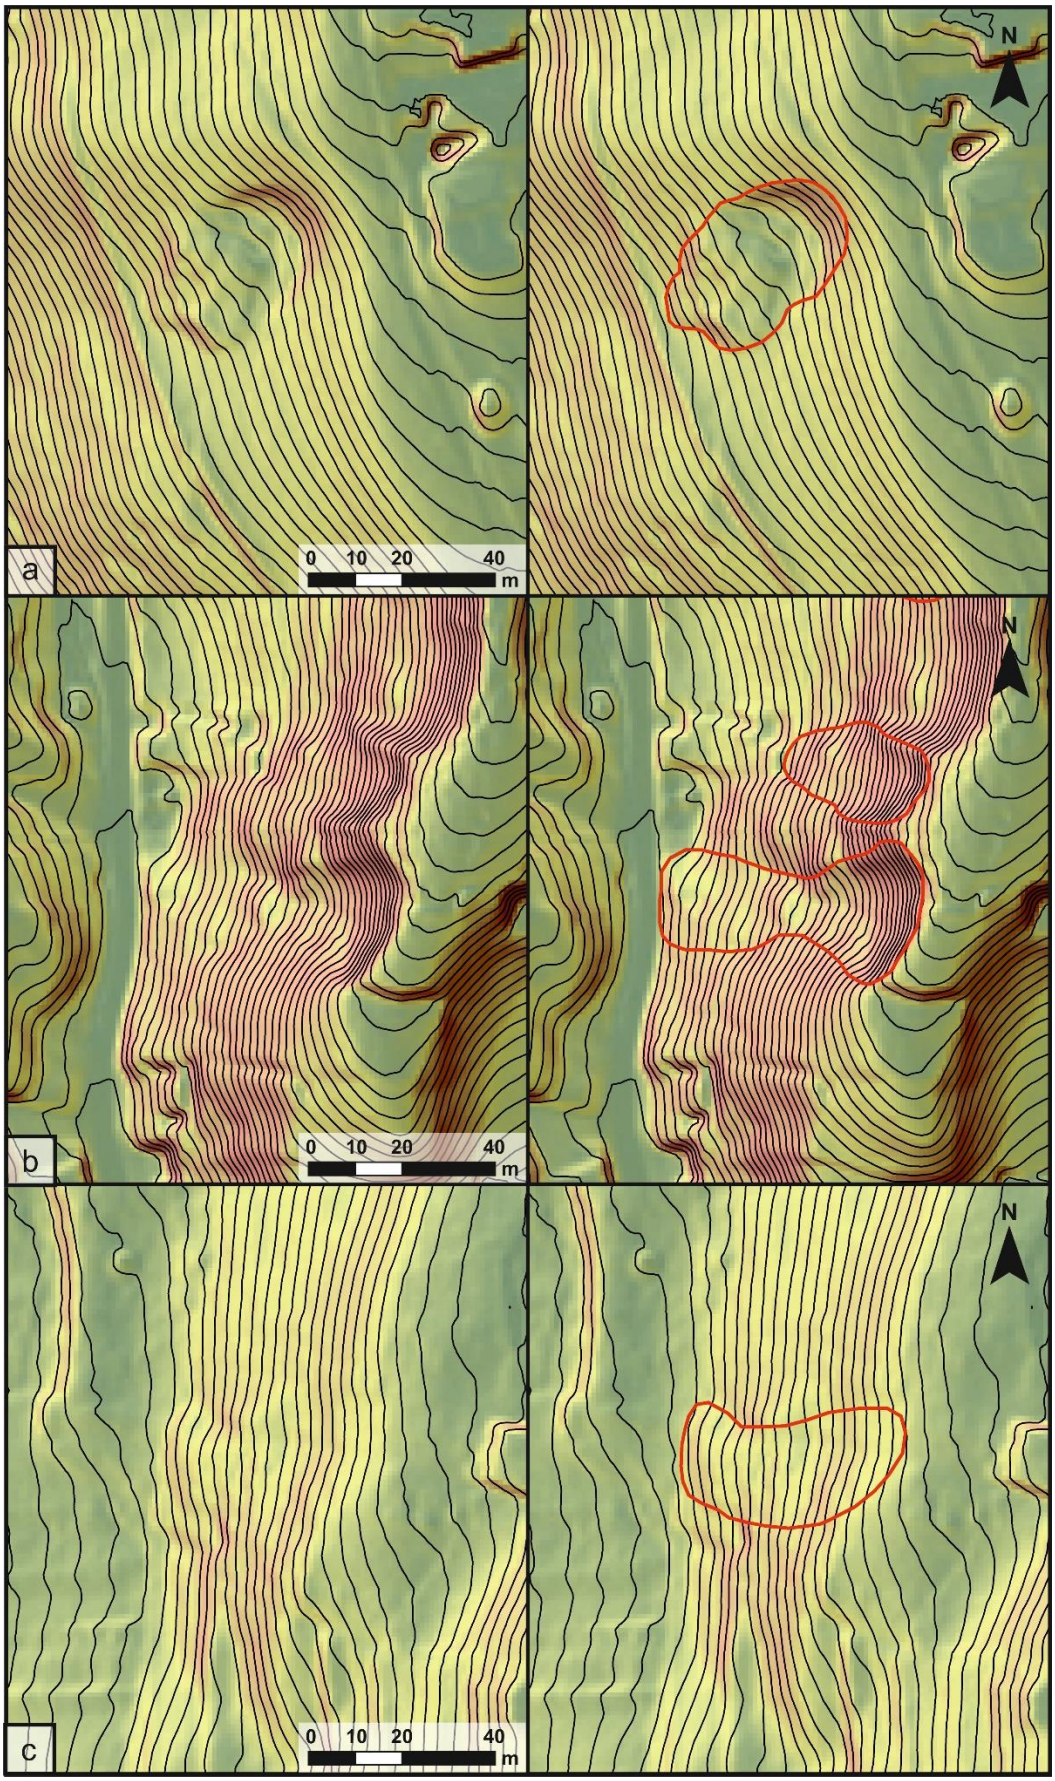

Slika 4.5 Procjena preciznosti kartiranja klizišta: (a) primjer visoke preciznosti; (b) primjer srednje preciznosti; (c) primjer niske preciznosti.

4.3 Metode usporedbe karata inventara klizišta

Metode usporedbe karata inventara klizišta temelje se na usporedbi statističkih značajki karata inventara klizišta i raspodjele veličine klizišta (Malamud et al., 2004) , stupnju kartografskog preklapanja granica klizišta dvaju inventara (Carrara et al., 1992) i kartama gustoća klizišta izvedenih na temelju različitih inventara klizišta (Guzzetti et al., 2000).

Prva metoda usporedbe karata inventara klizišta temelji se na raspodjeli veličine klizišta na analiziranom području te na karakterističnim parametrima za svaki inventar klizišta, kao što su ukupan broj klizišta na analiziranom području, ukupna površina klizišta, gustoća klizišta, najmanja i najveća površina klizišta i sl. Raspodjela veličina klizišta na analiziranom području omogućava verifikaciju pouzdanosti i potpunosti karte inventara klizišta (Malamud et al., 2004). Potpuni inventari klizišta okarakterizirani su s normalnom, odnosno Gaussovom raspodjelom veličina klizišta koja se sastoji od rastućeg i padajućeg dijela krivulje (slika 4.6). Prijelaz između rastućeg u padajući dio krivulje raspodjele ukazuje na razliku između malih te srednjih i velikih klizišta. Najčešće povijesni geomorfološki inventari ne sadrže manja klizišta, zbog toga što su geomorfološke karakteristike malih klizišta mnogo češće izgube tijekom vremena zbog rasta vegetacije, procesa erozije ili antropogenog utjecaja na okoliš (Bell et al., 2012).

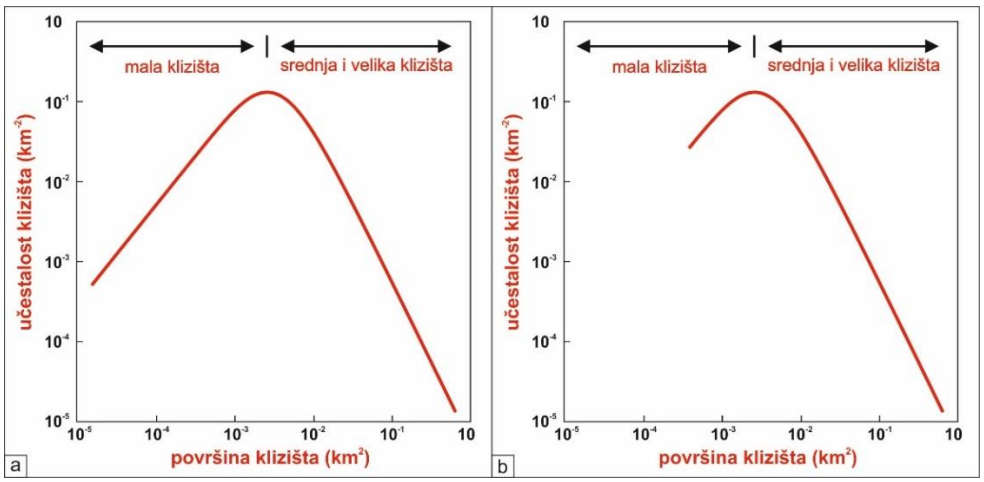

Slika 4.6 Shematski prikaz raspodjele površina klizišta: (a) primjer potpunog inventara klizišta; (b) primjer nepotpunog inventara klizišta.

Druga metoda usporedbe različitih karata inventara klizišta temelji se na određivanju stupnja kartografskog preklapanja, odnosno ne preklapanja granica klizišta dvaju inventara. Metodu je predložio Carrara et al. (1992), a temelji se na određivanju indeksa ne preklapanja, odnosno pogreške, *E* koji je definiran kao omjer površine simetrične razlike i površine unije dvaju inventara klizišta:

$$E = \frac{P(S_1 \cup S_2) - P(S_1 \cap S_2)}{P(S_1 \cup S_2)} \quad , 0 \leq E \leq 1 \tag{8}$$

gdje je:

A_1 – ukupna površina prvog inventara klizišta u km^2,

A_2 – ukupna površina drugog inventara klizišta u km^2.

Prema jednadžbi (8), indeks podudarnosti karata, *M* može se izraziti kao:

$$E = 1 - \frac{P(S_1 \cap S_2)}{P(S_1 \cup S_2)} \quad , M = \frac{P(S_1 \cap S_2)}{P(S_1 \cup S_2)}, 0 \leq M \leq 1 \tag{9}$$

Ukoliko dvije karte inventara klizišta imaju oblikom iste granice klizišta na istim geografskim položajima onda će vrijednost indeksa podudaranja biti maksimalna, a vrijednost indeksa ne podudaranja minimalna (*M*=1; *E*=0).

Treća metoda usporedbe temelji se na prostornoj raspodjeli klizišta u kartama inventara. Kako bi se provela ova usporedba, područje istraživanja podijeljeno je na jedinice jedinstvenih morfoloških uvjeta (engl. *slope units*) koje se s obzirom na nagib i orijentaciju padine razlikuju od okolnih jedinca (Guzzetti et al., 2000). Za pilot područje (21 km^2) podjela terena na morfološke jedinice izvedena je polu-automatizirano, jer su granice jedinica vizualno interpretirane na temelju drenažne mreže i hrptova brda dobivenih iz DMT-a rezolucije 5x5 m pomoću alata *Flow accumulation* i *Basin* u *ArcGIS-u 10.0*. Za svaku morfološku jedinicu izračunat je udio površine klizišta, a rezultat je karta gustoće klizišta koja daje uvid u prostornu raspodjelu klizišta na cijelom istraživanom području. Također, brojni autori smatraju da se karte gustoća klizišta mogu koristiti za relativnu procjenu podložnosti na klizanje (Guzzetti et al., 2000; Bulut et al., 2000)

4.4 Automatizirano kartiranje klizišta primjenom LiDAR DMT-a

Modeli za automatizirano kartiranje klizišta primjenom LiDAR DMT-a temelje se na različitim izvedenim morfometrijskim kartama, a najčešće su to karte nagiba terena (Glenn et al., 2006; Kasai et al., 2009, Rau et al., 2012; Van Den Eeckhaut et al., 2012; Gorsevski et al., 2015), karte hrapavosti terena (McKean i Roering, 2004; Glenn et al., 2006; Kasai et al., 2009, Rau et al., 2012; Van Den Eeckhaut et al., 2012; Berti et al., 2013; Li et al., 2015) i karte zakrivljenosti terena (Tarolli et al., 2012; Van Den Eeckhaut et al., 2012; Gorsevski et al., 2015). Pojedini

autori primijenili su i druge morfometrijske karte, kao što su karte vlažnosti i osunčanosti terena (Gorsevski et al., 2015; Pawluszek, 2018) te karta omjera 3D i 2D površine terena (Pawluszek, 2018). Osim morfometrijskih karata koje su različiti autori primijenili za izradu modela za automatizirano kartiranje klizišta, u ovom istraživanju su analizirane i druge vrste morfometrijskih karata koje do sada nisu bile primjenjivane za tu namjenu, kao na primjer karta gustoće slojnica i karta osjenčanosti terena. Također, osim različitih vrsta morfometrijskih karata, primijenjene su različite metode izrade pojedine vrste morfometrijskih karata, na primjer za izvođenje karata hrapavosti terena primijenjeno je pet različitih metoda. Prilikom izrade pojedinih morfometrijskih karata primijenjena je žarišna statistika te su karte izvedene s obzirom na različite oblike prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija). Iz LiDAR DMT-a rezolucije 1x1 m izveden je cijeli niz morfometrijskih karata koje se mogu podijeliti u osam glavnih grupa, a to su karte nadmorskih visina, karte osjenčanosti terena, karte nagiba terena, karte slojnica, karte zakrivljenosti terena, karte hrapavosti terena, karte vlažnosti i karte raščlanjenosti terena. U poglavlju 5.4. su detaljnije opisane primijenjene metode za izvođenje morfometrijskih karata za automatizirano kartiranje klizišta.

Najjednostavniji način klasifikacije izvedenih morfometrijskih karata u karte morfometrijskih parametara koji ukazuju na morfologiju klizišta, tzv. predikcijske karte je na temelju graničnih vrijednosti (Berti et al., 2013). Granične vrijednosti izvedenih morfometrijskih karata koje ukazuju na pojavu klizišta određene su na temelju krivulja raspodjele morfometrijske vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem (slika 4.7). Raspon morfometrijskog parametra koji ukazuje na pojavu klizišta sastoji se od stvarno pozitivno (SP) identificiranih područja zahvaćenih klizanjem i lažno pozitivno (LP) identificiranih područja koja imaju slične morfometrijske karakteristike kao i područja zahvaćena klizanjem, ali se ne mora raditi o području zahvaćenom klizanjem. Suprotno tome, raspon morfometrijskog parametra koji ukazuje na teren bez klizišta sastoji se od stvarno negativno (SN) identificiranog područja bez klizišta i lažno negativno (LN) identificiranog područja koje ima slične morfometrijske karakteristike kao i teren bez klizišta. Za svaku od izvedenih morfometrijskih karata određena je granična vrijednost morfometrijskog parametara te je provedena analiza točnosti usporedbom s pouzdanim i potpunim inventarom klizišta. Karte morfometrijskih parametara klizišta uspoređene su s inventarom klizišta dobivenim vizualnom interpretacijom LiDAR DMT-a na temelju metode kartografskog preklapanja (Carrara et al., 1992). Iz svake podgrupe izvedenih morfometrijskih karata, parametar s najvišim indeksom podudarnosti korišten je kao predikcijska karta za automatizirano kartiranje klizišta.

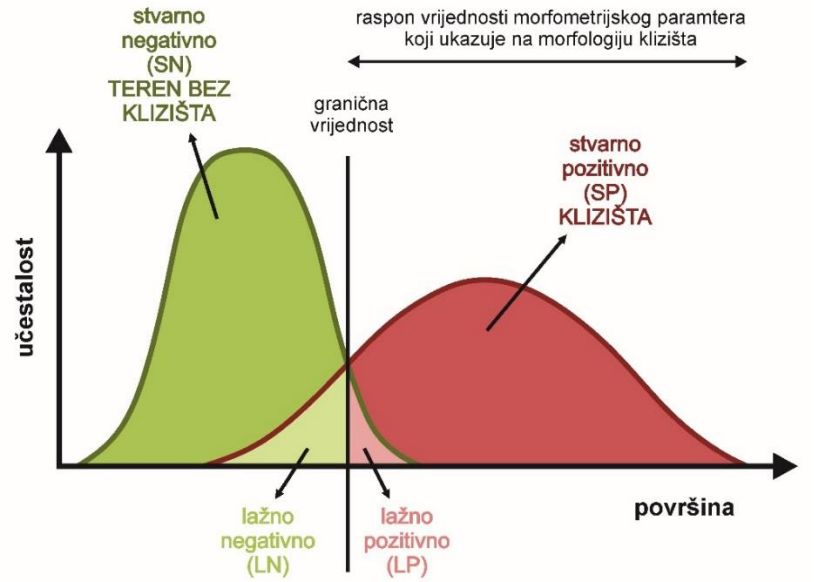

Slika 4.7 Primjer učestalosti vrijednosti izvedene morfometrijske karte na područjima zahvaćenim klizanjem (crvena linija) i područjima bez klizišta (zelena linija).

Drugi korak prilikom automatiziranog kartiranja klizišta je kombinacija predikcijskih karata, koja je provedena primjenom dviju metoda zbrajanja vrijednosti predikcijskih karata. Prva metoda izrade karte klizišta uključuje zbrajanje vrijednosti svih predikcijskih karata, te reklasifikaciju dobivene karte klizišta s obzirom na definirane granične vrijednosti zbroja svih predikcijskih karata. Druga metoda se temelji na kombinaciji zbrajanja vrijednosti odabranih predikcijskih karata, pri čemu je izbor proveden prema metodi kombinacije (engl. *stepwise map combination*) koju su van Westen et al. (1993) primijenili za izradu karte podložnosti na klizanje. S obzirom na indeks podudarnosti, jedna po jedna predikcijska karta se zbraja te se analizira utjecaj svake pojedine predikcijske karte na model za automatizirano kartiranje klizišta, odnosno na konačan rezultat. Ako pojedina predikcijska karta znatno povećava udio točno klasificiranih klizišta ili se udio površine netočno klasificiranih klizišta smanjuje, onda se predikcijska karta prihvaća i analizira se utjecaj slijedeće predikcijske karte. Suprotno tome, ukoliko pojedina predikcijska karta znatno utječe na smanjenje postotka točno klasificiranih klizišta ili se postotak udio površine netočno klasificiranih klizišta povećava, ta predikcijska karta se odbacuje. Konačan rezultat obje metode zbrajanja predikcijskih karata je rasterska karta koja prikazuje ćelije klasificirane kao klizišta, odnosno vektorska karta točaka čija morfologija ukazuje na pojavu klizišta.

4.5 Izrada karte podložnosti na klizanje primjenom bivarijantne statističke metode

Karta podložnosti na klizanje izrađena je primjenom bivarijantne statističke analize koja podrazumijeva analizu jedne zavisne varijable, u ovom slučaju su to postojeće pojave klizišta, i jedne nezavisne varijable, odnosno jednog od preduvjeta klizanja. Analiza se temelji na pretpostavci da su pojedine faktorske karte klizanja međusobno nezavisne, te da se utjecaj pojedinih preduvjeta klizanja može kvantificirati na temelju gustoća klizišta u svakoj od klasa faktorskih karata. Gustoća klizišta se pri tome može izraziti kao gustoća površine klizišta (engl. *area density*) koja predstavlja omjer površine klizišta i površine analiziranog područja, ili kao gustoća broja klizišta (engl. *number density*), odnosno omjer broja klizišta i površine analiziranog područja. Bivarijantnu statističku analizu moguće je provesti s obzirom na različito definirane prostorne jedinice (pravilne kvadratne ćelije, geomorfološke jedinice, jedinice definirane s obzirom na nagib i orijentaciju padine, jedinice jedinstvenih uvjeta), a u ovom radu analiza je provedena s obzirom na pravilne ćelije dimenzije 1x1 m. Podložnost na klizanje može se kvantificirati primjenom različitih metoda bivarijantne statistike, a u ovom radu primijenjen je model težinskih faktora (engl. *Weights-of-Evidence model, WOE model*) razvijen je u Kanadskom geološkom institutu (Agterberg et al., 1990; Bonham-Carter et al., 1989) za potrebe izrade karata potencijala mineralnih sirovina. Sabto (1991) je prvi primijenio metodu za analizu hazarda klizanja. Prvi korak u analizi je određivanje vjerojatnosti *a priori* (engl. *prior probability*), odnosno vjerojatnost događaja/pojave klizišta (S) neovisno o razmatranju uzroka, a koja je definirana kao:

$$P_{pr} = \frac{N_{kliz}}{N_{uk}} \tag{10}$$

gdje je:

P_{pr} – vjerojatnost *a priori* (engl. *prior probability*),

N_{kliz} – broj klizišta ili površina klizišta,

N_{uk} – površina istraživanog područja.

Pojava klizišta može se izraziti i kao odnos dviju varijabli (engl. *odds*):

$$O_{pr} = \frac{P_{pr}}{1 - P_{pr}} = \frac{N_{kliz}}{N_{uk} - N_{kliz}} \tag{11}$$

Uslijed prisustva određenih preduvjeta klizanja/faktora (B) iskazuje se vjerojatnost *a posteriori* (engl. *posterior probability*). Statistička povezanost između svake pojedine klase faktora i klizišta izračunava se preklapanjem karte klizišta s kartom faktora klizanja (slika 4.8). Na temelju vjerojatnosti a posteriori, Bonham-Carter et al. (1989) definirali su pozitivni i negativni par težina (W_i^+ i W_i^-):

$$W_i^+ = log_e \frac{P\{B_i|S\}}{P\{B_i|\bar{S}\}} = log_e \frac{\frac{B_i \cap S}{B_i \cap S + \overline{B_i} \cap S}}{\frac{B_i \cap \bar{S}}{B_i \cap \bar{S} + \overline{B_i} \cap \bar{S}}} \tag{12}$$

i

$$W_i^- = log_e \frac{P\{\overline{B_i}|S\}}{P\{\overline{B_i}|\bar{S}\}} = log_e \frac{\frac{\overline{B_i} \cap S}{B_i \cap S + \overline{B_i} \cap S}}{\frac{\overline{B_i} \cap \bar{S}}{B_i \cap \bar{S} + \overline{B_i} \cap \bar{S}}} \tag{13}$$

gdje je:

B_i – prisustvo potencijalne klase faktora klizanja,

$\overline{B_i}$ – odsustvo potencijalne klase faktora klizanja,

S – prisustvo klizišta,

$\bar{S}$ – odsustvo klizišta,

$B_i \cap S$ – klizišta u klasi faktora klizanja,

$\overline{B_i} \cap S$ – klizišta izvan klase faktora klizanja,

$B_i \cap \bar{S}$ – bez klizišta u klasi faktora klizanja,

$\overline{B_i} \cap \bar{S}$ – bez klizišta izvan klase faktora klizanja.

Pojednostavljeno, pozitivan i negativan par težina možemo izraziti opisno kao:

$$W_i^+ = log_e \frac{\frac{klizišta\ u\ klasi}{ukupno\ klizišta}}{\frac{bez\ klizišta\ u\ klasi}{ukupno\ bez\ klizišta}} \tag{14}$$

i

$$W_i^- = log_e \frac{\frac{klizišta\ izvan\ klase}{ukupno\ klizišta}}{\frac{bez\ klizišta\ izvan\ klase}{ukupno\ bez\ klizišta}} \quad (15)$$

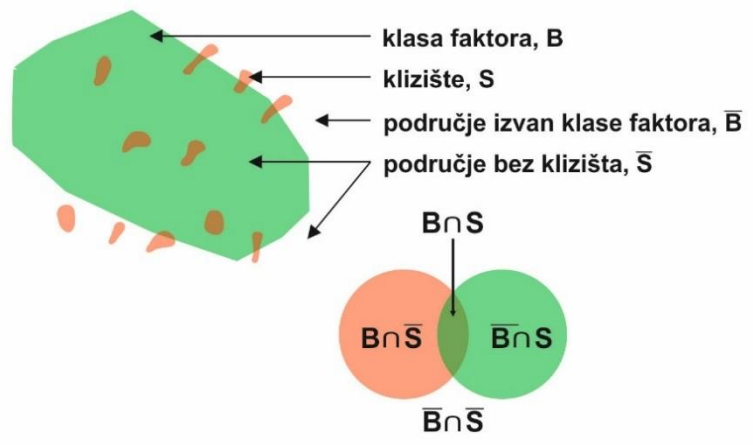

Slika 4.8 Primjer određivanja vjerojatnosti *a posteriori* primjenom WoE modela.

Pozitivnom težinom (W_i^+) se izražava vjerojatnost klizišta uz postojanje faktora klizanja, a negativnom težinom (W_i^-) se izražava vjerojatnost pojave klizišta kada ne postoji određeni faktor klizanja, odnosno predstavlja mjeru negativne povezanosti između dviju varijabli. Parovi težina se računaju za svaku klasu faktora klizanja te je prilikom definiranja faktorskih karata potrebno odrediti granične vrijednosti klasa, odnosno gdje prestaje utjecaj faktora klizanja na pojavu klizišta.

Kontrast (engl. *contrast*) predstavlja mjeru prostorne povezanosti, a definiran je kao razlika između pozitivne (W_i^+) i negativne težine (W_i^-):

$$C = W_i^+ - W_i^- \quad (16)$$

Vrijednost kontrasta je za pozitivne prostorne povezanosti pozitivna, a za negativne povezanosti je negativna. Osim kontrasta, Neuhäuser et al. (2012) predlažu izračun i studentovog kontrasta (Cs) koji predstavlja omjer kontrasta i njegove standardne devijacije, a opisuje značajnost kontrasta za svaku klasu faktora klizanja. Kontrast (C) i studentov kontrast (Cs) koriste se prilikom definiranja graničnih vrijednosti klasa faktora klizanja te se kontinuirani podaci (nagib terena ili udaljenost od prometnice) mogu poopćiti (generalizirati) na način da se smanji broj klasa ovisno o njihovom utjecaju. Broj klasa unutar faktorskih karata klizanja posebno je važan prilikom provedbe analize po prostornim jedinicama kao što su jedince jedinstvenih uvjeta, za razliku od prostorne analize po ćelijama kada nije potrebno

smanjivati broj klasa unutar pojedinih faktora klizanja. Općenito, maksimalna vrijednost kontrasta (C) daje graničnu vrijednost pri kojoj je točnost predviđanja određene klase maksimalna (Bonham-Carter, 2002). Na osnovi ovog pravila, kontrast (C) se koristi za odabir granica klasa za klasificiranje kontinuiranih setova podataka u manji broj klasa. U slučaju klasa s malim površinama i s malim brojem klizišta, nepouzdanost težina je velika, a posljedica toga je da je kontrast *(C)* beznačajan. U tom slučaju studentov kontrast *(Cs)* se koristi za određivanje graničnih vrijednosti naknadne klasifikacije ili reklasifikacije (Bonham-Carter et al., 1989).

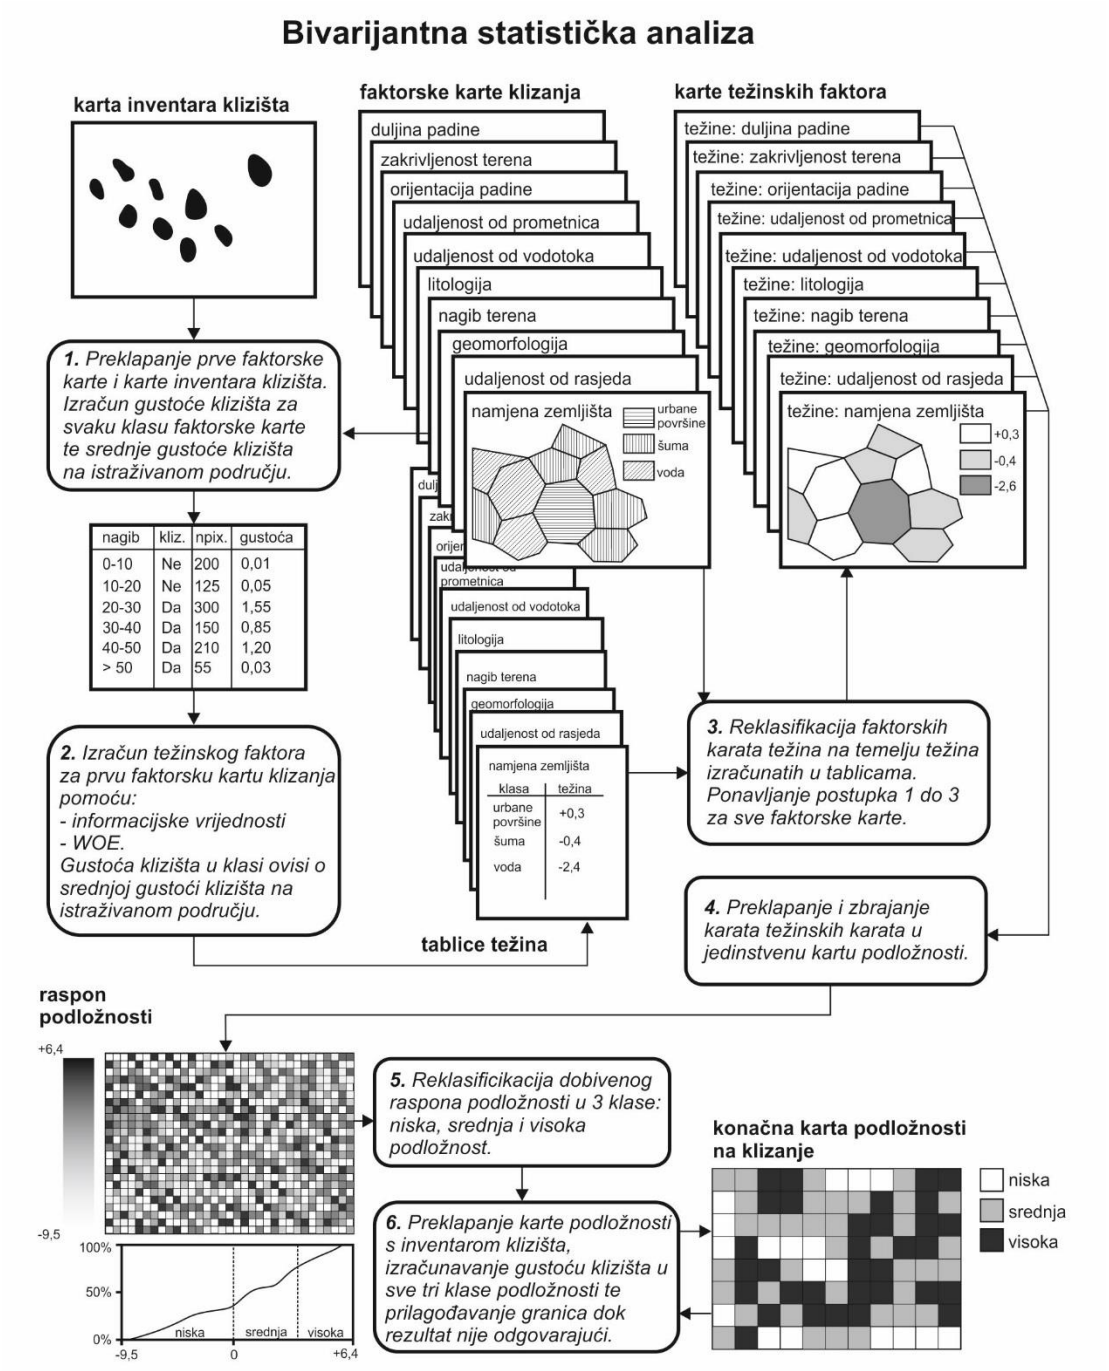

Slika 4.9 Pojednostavljeni dijagram toka izrade karte podložnosti na klizanje primjenom bivarijantne statističke metode (prema Van Westen et al., 2002).

Glavna pretpostavka kod bivarijantne statističke analize je nezavisnost faktorskih karata klizanja. Kako bi se provjerila nezavisnost varijabli provodi se test usporedbe (engl. *parwise test*) svih parova faktorskih karata klizanja (Bonham-Carter et al., 1989). Test se provodi na način da se po dvije faktorske karte preklope u svim mogućim kombinacijama. Dobivena karta preklopa dviju faktorskih karata se potom preklapa s kartom inventara klizišta. Vjerojatnost *a posteriori* pojave klizišta na preklopu dvije faktorske karte klizanja (B_1 i B_2) može se izraziti:

$$P\{S|B_1 \cap B_2\} = \frac{P\{B_1 \cap B_2|S\}P\{S\}}{P\{B_1 \cap B_2|S\}P\{S\} + P\{B_1 \cap B_2|\bar{S}\}P\{\bar{S}\}} \tag{17}$$

S – prisustvo klizišta,

$\bar{S}$ – odsustvo klizišta,

B_1 – prisustvo faktora klizanja 1,

B_2 – prisustvo faktora klizanja 2.

Ukoliko su faktori klizanja B_1 i B_2 međusobno nezavisni s obzirom na pojavu klizišta, onda vrijedi slijedeći izraz:

$$P\{B_1 \cap B_2|S\} = P\{B_1|S\}P\{B_1\} \tag{18}$$

te se izraz 18 može pojednostaviti na slijedeći način:

$$P\{S|B_1 \cap B_2\} = P\{S\}\frac{P\{B_1|S\}P\{B_2|S\}}{P\{B_1\}P\{B_2\}} \tag{19}$$

Nakon provjere nezavisnosti analiziranih faktora (preduvjeta) klizanja, definiranja granica klasa faktorskih karata klizanja i izračuna pozitivne (W_i^+) i negativne (W_i^-) težine za svaku od klasa, potrebno je izračunati i ukupnu težinu (W_{uk}), koja je definirana kao zbroj pozitivne težine klase i zbroja negativnih težina preostalih klasa faktora klizanja:

$$w_{uk}^i = W_i^+ + \sum_{\substack{j=1 \\ j \neq i}}^{n} W_i^- \tag{20}$$

gdje je:

W_i^+- pozitivna težina klase faktora klizanja,

W_i^-- negativna težina klase faktora klizanja.

Izvedena karta vrijednosti ukupne težine (W_{uk}) predstavlja kartu podložnosti na klizanje, pri čemu vrijednosti manje od nule ukazuju na stabilne dijelove terena, a pozitivne vrijednosti na nestabilne dijelove terena. Usporedba točnosti karata podložnosti na klizanje provedena je pomoću mjera senzitivnosti (stvarno pozitivne stope) i specifičnosti (stvarno negativne stope), odnosno pomoću ROC krivulja koje predstavljaju grafički prikaz senzitivnosti u odnosu na 1-specifičnost, tj. lažno pozitivnu stopu. Mjera za određivanje točnosti testa pomoću ROC krivulje je površina ispod krivulje ili AUC vrijednosti (Green & Swets, 1966), gdje površina od 1 odgovara idealnom testu, dok površina od 0,5 odgovara slučajnom testu (tablica 4.3). Najčešće se na početnom setu podataka o klizištima, koji se koristi prilikom analize faktora klizanja odredi set klizišta za treniranje modela i set klizišta za validaciju modela. Ukoliko ROC krivulju izvedemo na temelju seta klizišta koji je korišten za statističku analizu preduvjeta klizanja, onda se radi o stopi točnosti (engl. *success rate*) karte podložnosti na klizanje. ROC krivulja izvedena s obzirom na set klizišta za validaciju modela prikazuje stopu predikcije (engl. *prediction rate*) karte podložnosti na klizanje.

Tablica 4.3 Klasifikacija točnosti karata podložnosti s obzirom na AUC vrijednost

AUC vrijednost	Ocjena točnosti
90-100	vrlo visoka
80-90	visoka
70-80	srednja
60-70	niska
50-60	vrlo niska

Karte podložnosti na klizanje reklasificirane su s obzirom na četiri klase podložnosti na klizanje, a to su: (1) stabilni tereni; (2) tereni s niskom podložnosti na klizanje, odnosno uvjetno stabilne padine; (3) tereni sa srednjom podložnosti na klizanje, odnosno uvjetno nestabilne padine; i (4) tereni s visokom podložnosti na klizanje, odnosno nestabilne padine na kojima postoje prethodno identificirana klizišta. Granične vrijednosti klasa podložnosti na klizanje definirane su na temelju AUC vrijednosti, odnosno graničnim vrijednostima na ROC krivulji.

5 ULAZNI PODACI

Lasersko skeniranje iz zraka podsljemenske zone Grada Zagreba (180 km^2) provedeno je 12.12. i 24.12.2013. godine od strane tvrtke Geofoto d.o.o. Laserski skener korišten za prikupljanje podataka u ovom istraživanju ima učestalost mjerenja od 266.000 Hz kod kuta mjerenja od oko 60°. Prilikom obrade oblaka točaka utvrđena je horizontalna točnost od 8 cm i vertikalna točnost od 4 cm. Nizovi su skenirani iz dva smjera, azimuta 55° i 235°. Tijekom skeniranja zbog kvara na skeneru došlo je do gubitka dijela podataka, te za područje površine 5,9 km^2 (slika 5.1) nije moguće izraditi DMT. Tvrtka Geofoto d.o.o. provela je geokodiranje, klasifikaciju i filtraciju oblaka točaka. Oblak točaka isporučen je u obliku LAS datoteka, a zbog lakšeg i bržeg korištenja, podijeljen je na ukupno 578 listova (dimenzija središnjih listova je 750x500 m).

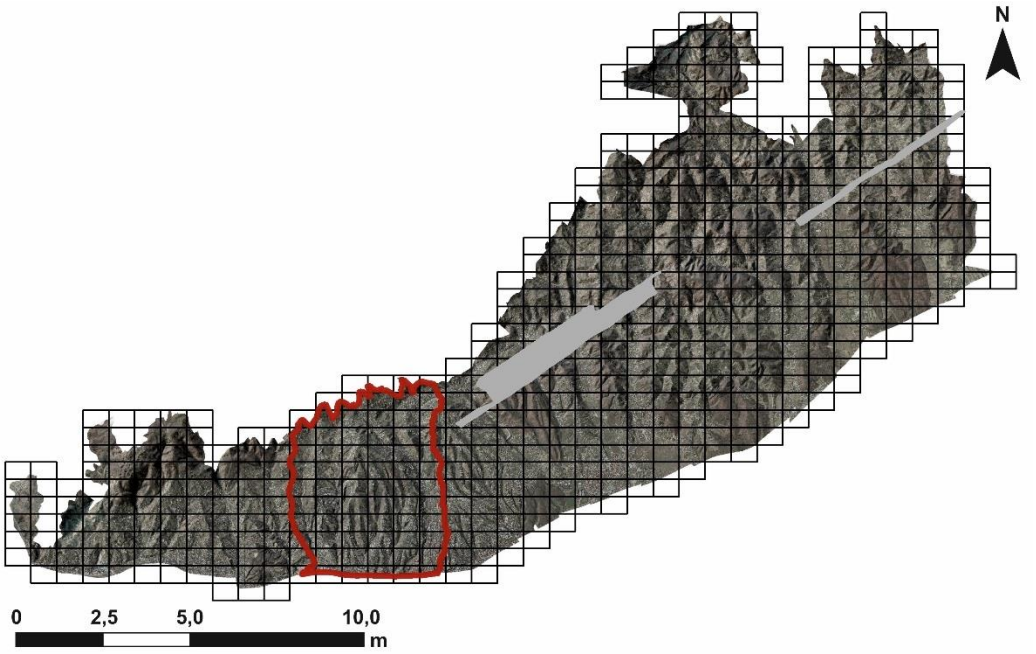

Slika 5.1 Pokrivenost podsljemenske zone Grada Zagreba (180 km^2) s LAS podacima (crni poligoni) i bez LAS podataka (sivo obojani poligoni) te položaj pilot područja površine 21 km^2 (crveni poligon).

Karakteristike oblaka točaka dobivenog laserskim skeniranjem iz zraka te izrada digitalnog modela terena za pilot područje opisana je u poglavljima 5.1 i 5.2. Kvaliteta, odnosno rezolucija DMT-a ovisi o točnosti, gustoći i distribuciji točaka u oblaku točaka te primijenjenoj metodi interpolacije. Odabirom odgovarajuće metode interpolacije izvedena su dva DMT-a rezolucije 0,3x0,3 m i 1x1 m, oba optimalna za kartiranje malih i plitkih klizišta u podsljemenskoj zoni Grada Zagreba. Iz LiDAR DMT-a rezolucije 0,3x0,3 m izvedene su tri morfometrijske karte za vizualnu identifikaciju i kartiranje klizišta, a iz LIDAR DMT-a rezolucije 1x1 m izvedeno je ukupno 127 morfometrijskih karata koje su analizirane u svrhu izrade modela za automatizirano kartiranje klizišta.

5.1 Gustoća oblaka točaka dobivenog laserskim skeniranjem iz zraka

Prilikom izrade digitalnog modela reljefa bez vegetacije korištene su samo točke iz oblaka klasificirane kao klasa 2 (slika 5.2), odnosno prema ASPRS-ovoj definiciji klasificirane kao teren. U tablici 5.1 prikazan je ukupan broj točaka na 80 listova unutar pilot područja (21 km^2) te broj točaka u klasi 1 (ne klasificirano) i klasi 2 (točke terena). Prosječna gustoća oblaka točaka je 12,46 točaka/m^2, dok prosječna udaljenost između točaka iznosi 0,30 m. Od ukupnog broja točaka dobivenih laserskim skeniranjem njih malo manje od 28 % čine točke terena, dok su sve ostale točke odbijene od objekata i vegetacije. Gustoća točaka nakon što se ukloni vegetacija je 3,61 točke/m^2, odnosno prosječna udaljenost između točaka je 0,56 m.

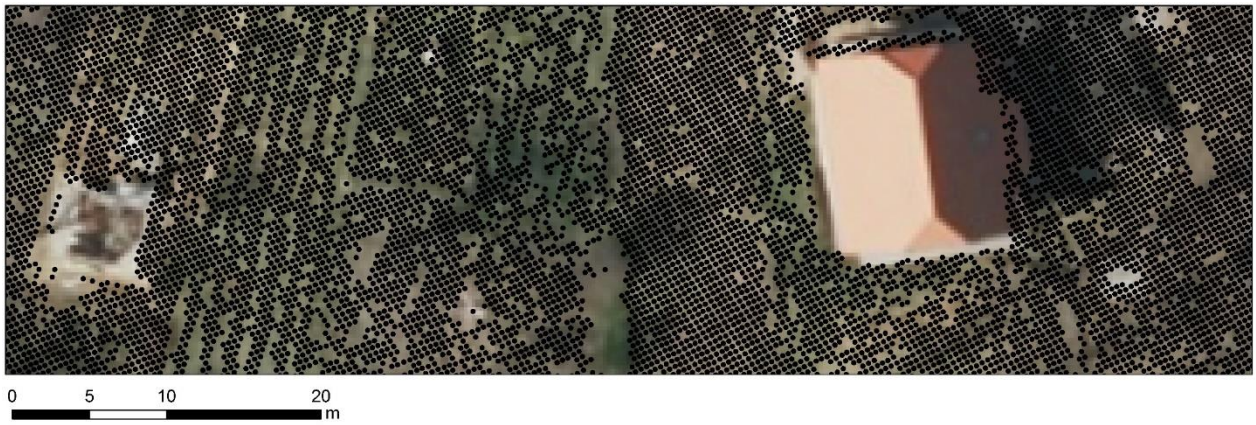

Slika 5.2 Oblak točaka (točke klasificirane kao klasa 2) dobiven laserskim skeniranjem u prosincu 2013. godine, prikazan na digitalnom ortofoto snimku.

Tablica 5.1 Srednja gustoća točaka i prosječna udaljenost točaka za pilot područje.

	klasa 1 (neklasificirano)	klasa 2 (teren)	sve klase
broj točaka u oblaku točaka	262.937.691	100.557.291	363.494.982
udio klasa	72,3 %	27,7 %	100 %
srednja gustoća oblaka točaka	-	3,61 točaka/m^2	12,46 točaka/m^2
prosječna udaljenost između točaka	-	0,56 m	0,30 m

U tablici 5.2 prikazana je gustoća uzorkovanja s obzirom na različite namjene zemljišta, te je vidljivo kako je gustoća uzorkovanja na pilot području heterogena. Najveća gustoća točaka je u klasi poljoprivredne površine (4,29 točke/m^2) koja prekriva malo više od 22 % pilot područja. Klasa šume prekrivaju ukupno 22,2 % pilot područja, a gustoća točaka je manja za 12 % od gustoće točaka na poljoprivrednim površinama (3,78 točaka/m^2). Najmanju gustoću točaka (3,27 točaka/m^2) imaju umjetne površine koje čine 55,5 % pilot područja.

Tablica 5.2 Prosječna gustoća uzorkovanja ovisno o namjeni zemljišta.

Namjena zemljišta	Površina klase (km^2)	Udio klase (%)	Gustoća (točke/m^2)
umjetne površine	11,7	55,5	3,27
poljoprivredne površine	4,7	22,3	4,29
šume	4,7	22,3	3,78

5.2 Izrada LiDAR DMT-a visoke rezolucije

Prema Rossiter (2003) prostorna rezolucija DMT-a, odnosno odgovarajuća veličina piksela DMT-a za interpretaciju klizišta može se procijeniti iz mjerila kartiranja. Budući da je za vizualnu interpretaciju klizišta na pilot području odgovarajuće mjerilo od 1:100 do 1:500 m, proizlazi da je odgovarajuća veličina piksela od 0,25 do 1,25 m. S obzirom na površinu najmanjeg klizišta registriranog u podsljemenskoj zoni Grada Zagreba, a koja je u ovom slučaju veličina najmanjeg kartiranog objekta (Hengl, 2006) i iznosi oko 5x5 m (površine približno 20 m^2), rezolucija digitalnog modela terena treba biti najmanje 1x1 m.

Digitalni model terena izrađuje se nekom od metoda interpolacije oblaka točaka, a da bi bio reprezentativan nužna je podjednaka gustoća točaka po jedinici površine. Za pilot područje površine 21,1 km^2 oblak točaka sadrži ukupno 76.264.211 točaka, te preporučena veličina piksela iznosi 0,13 m prema metodi kontrole gustoće (Hengl, 2006). S obzirom da gustoća točaka nije podjednaka u svim dijelovima skeniranog područja, odnosno ovisi o namjeni zemljišta (tablica 5.2) rezolucija DMT-a se može odrediti i prema Nyquist-ovom konceptu frekvencije (Shannon, 1949) prema kojem bi veličina piksela trebala biti polovica srednje najkraće udaljenosti između dvije točke (Hengl, 2006). Prosječna udaljenost između dviju točaka na 80 listova koji prekrivaju pilot područje iznosi 0,56 m, te bi prema tome preporučena veličina piksela bila 0,30 m.

Za pilot područje površine 21 km^2 izrađen je DMT rezolucije 2 m, 1 m, 0,5 m, 0,3 m i 0,15 m (slika 5.3). Na kartama osjenčanog terena prikazano je kako se na DMT-u vidi klizište u ulici Vrhovec, dimenzija 50x35 m, što je nedvojbeno ilustracija zavisnosti preciznosti identifikacije granica klizišta ovisi o rezoluciji DMT-a. Na DMT-u rezolucije 2 m klizište je slabije izraženo, odnosno nije jasno vidljiva granica klizišta, zbog čega je moguće iscrtati samo približnu granicu klizišta na temelju morfologije terena. Na DMT-u rezolucije 1 m moguće je preciznije definirati granicu klizišta, dok je na DMT-u rezolucije 0,5 m, 0,3 m i 0,15 m moguće s velikom preciznošću iscrtati granicu klizišta.

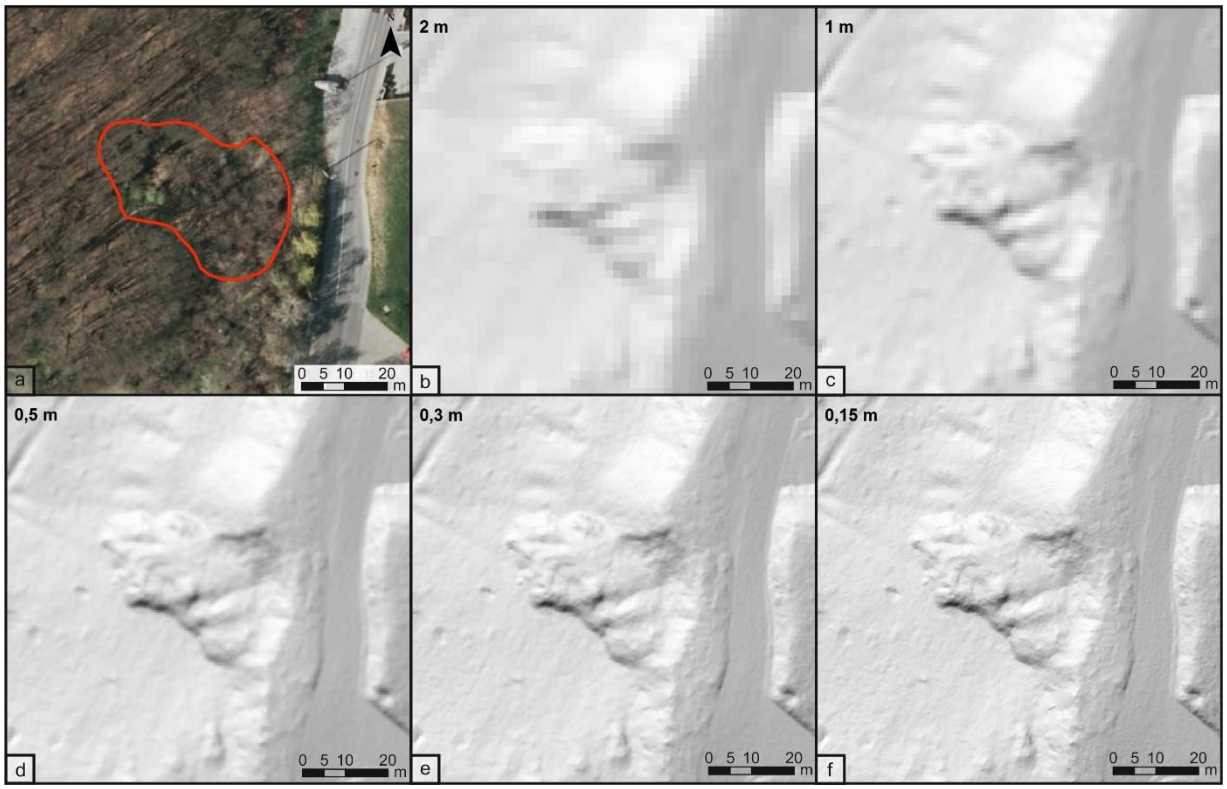

Slika 5.3 Prostorna rezolucija DMT-a na primjeru klizišta u ulici Vrhovec dimenzija 50x35 m: a) granica klizišta na digitalnom ortofoto snimku iz 2011. godine; b) DMT rezolucije 2 m; c) DMT rezolucije 1 m; d) DMT rezolucije 0,5 m; e) DMT rezolucije 0,3 m; f) DMT rezolucije 0,15 m.

Prilikom izrade DMT-a rezolucije 0,3x0,3 m korištene su metode interpolacije dostupne u ekstenziji *Spatial Analyst* (grupa alata *Interpolation*) u *ArcGISU-u 10.0.*, a to su metoda inverznih udaljenosti (alat *IDW*), metoda prirodnih susjeda (alat *Natural Neighbor*), metoda ANUDEM (alat *Topo to Raster*) i metoda kriging (alat *Kriging*). Interpolacijski parametri za svaku od korištenih metoda interpolacije prikazanih na Slika 5.4. automatski su optimizirani pomoću ekstenzije *Geostatistic Analyst*.

Usporedba točnosti primijenjenih metoda interpolacije najčešće se provodi pomoću statističkih metoda, kao što su usporedba reziduala ili unakrsna validacija, ili jednostavna usporedba dobivenih volumena. Za postupak identifikacije i za kartiranje klizišta prostorna točnost samog DMT-a nije od presudne važnosti, jer sva četiri dobivena modela terena jednako vjerno prikazuju reljef. Slika 5.4 prikazuje usporedbu izraženosti morfologije klizišta na DMT-u dobivenom različitim metodama interpolacije. Metoda inverznih udaljenosti daje najmanje "zaglađen" model, odnosno najizraženiji reljef te granicu i morfologiju klizišta, dok je metoda ANUDEM daje najlošiji rezultat, odnosno "zaglađeniji" DMT, bez jasno izražene granice klizišta kao na ostala tri modela. Vizualnom procjenom dobivenih DMT-a može se zaključiti kako su metode prirodnih susjeda i kriginga dale vrlo slične rezultate.

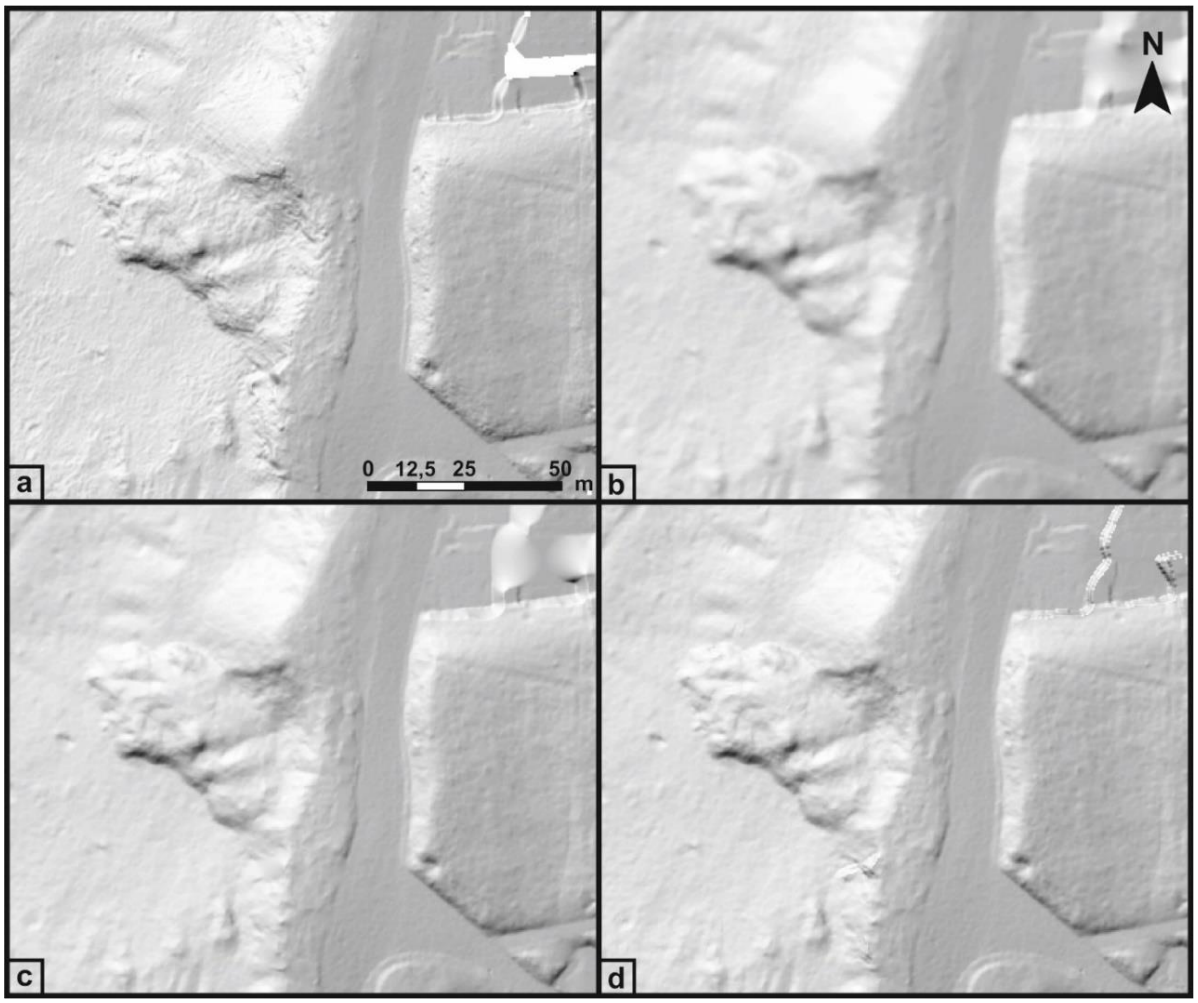

Slika 5.4 Usporedba LiDAR DMT-a rezolucije 0,3x0,3 m dobivenih različitim metodama interpolacije: (a) metoda inverznih udaljenosti (alat *IDW*); (b) metoda ANUDEM – (alat *Topo to Raster*); (c) metoda prirodnih susjeda (alat *Natural Neighbor*); (d) kriginig metoda (alat *Kriging*).

5.3 Morfometrijske karte izvedene iz LiDAR DMT-a za vizualnu identifikaciju i kartiranje klizišta

Morfometrijske karte korištene prilikom vizualne identifikacije klizišta na pilot području u podsljemenskoj zoni Grada Zagreba izrađene su u računalnom programu *ArcGIS-u 10.0* iz LiDAR DMT-a rezolucije 0,3x0,3 m. Za identifikaciju morfologije klizišta korištene su tri morfometrijske karte: karta osjenčanog reljefa (engl. *hillshade map*), karta nagiba terena (engl. *slope map*) i karta slojnica ekvidistancije 0,5 m (engl. *conture map*). U slijedećim poglavljima dan je kratki opis pojedinih morfometrijskih karata, metoda njihove izrade te primjena izvedenih karata prilikom vizualne identifikacije i kartiranja klizišta.

5.3.1 Karta osjenčanog reljefa

Karta osjenčanog reljefa (slika 5.5) predstavlja pseudo-trodimenzionalni prikaz površine terena koji se koristi za vizualnu interpretaciju morfoloških karakteristika (Guzzetti et al., 2012). Karta osjenčanosti izvedena je pomoću ekstenzije *Spatial Analyst* (alata *Hillshade*) pri čemu se simuliraju uvjeti iluminacije definirane azimutom položaja sunca u rasponu od 0° do 360° i kutom upada sunčevih zraka u rasponu od 0° do 90°. Svaka ćelija rastera poprima određenu vrijednost osvijetljenosti površine (0 do 255), ovisno o izravnoj izloženosti površine zadanim uvjetima iluminacije (Jenness, 2007). Iz DMT-a su izvedene tri karte osjenčanosti reljefa s različitim kombinacijama parametara iluminacije (45°/45°, 135°/45° i 315°/45°) kako bi se izbjegle sjene na padinama, odnosno da se osigura dobra vidljivost padina različitih orijentacija i omogućilo precizno iscrtavanje granice klizišta (Schulz, 2004, Đomlija, 2018).

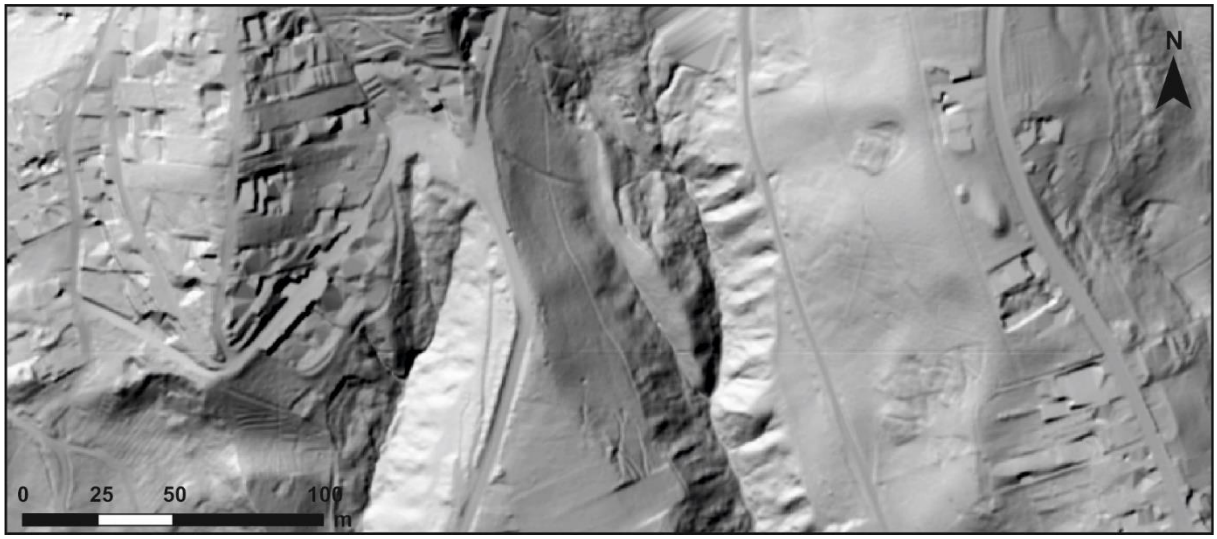

Slika 5.5 Karta osjenčanosti terena iluminacije 315°/45° dijela pilot područja u podsljemenskoj zoni Grada Zagreba.

5.3.2 Karta nagiba terena

Nagib terena se često smatra najvažnijim morfometrijskim parametrom koji se koristi za učinkovitije analiziranje i opisivanje reljefa. Karta nagiba terena (slika 5.6) izvedena je pomoću ekstenzije *Spatial Analyst* (alata *Slope*) te prikazuje prostornu distribuciju vrijednosti kutova nagiba u rasponu od 0° do 90°. Općenito, funkcija nagiba uklapa x-y plohu i z-vrijednost unutar područja od 3x3 ćelija, te različitim metodama za istu (središnju) ćeliju i osam susjednih ćelija računa vrijednost nagiba. Karta nagiba, osim što omogućava identifikaciju i klasifikaciju terena različitog nagiba, omogućava i identificiranje manjih promjena u reljefu, kao što su strmiji dijelovi klizišta, glavna pukotina, bokovi klizišta i nožica klizišta (Ardizzone et al., 2007, Amundsen et al., 2010; Mihalić et al., 2013, Đomlija, 2018).

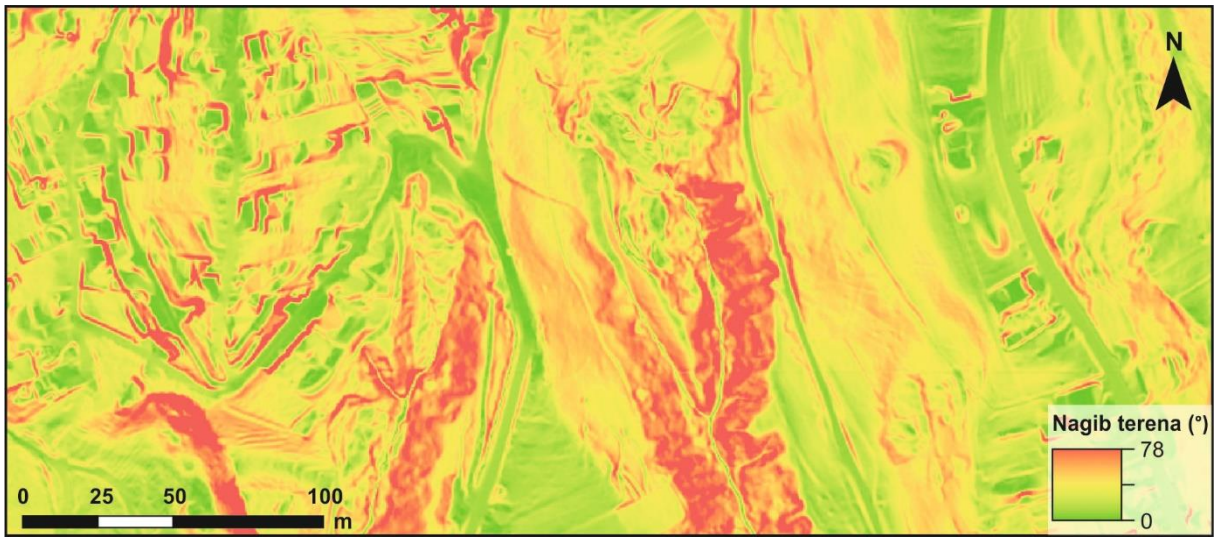

Slika 5.6 Karta nagiba terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba.

5.3.3 Karta slojnica

Karta slojnica (slika 5.7) izvedena je s ekvidistancijom od 0,5 m i 1 m pomoću alata *Contour*. Prema brojnim autorima, karta slojnica je vrlo značajna prilikom kartiranja granice klizišta, osobito u kombinaciji s kartom osjenčanog reljefa i kartom nagiba (Ardizzone et al., 2007; Van Den Eeckhaut et al., 2005; McKenna et al., 2008; Amundsen et al., 2010; Mihalić et al., 2013, Đomlija, 2018). Slojnice omogućavaju pouzdaniju identifikaciju reljefnih oblika, kao što su klizišta, jer jasno odražavaju specifične konveksne i konkavne dijelove terena, te na taj način ukazuju na zonu depresije i na zonu akumulacije. Kod aktivnih i relativno nedavno aktiviranih klizišta, moguće je vrlo precizno iscrtati granicu klizišta zbog karakterističnih "oštrih lomova" slojnica. Također, nepravilnost i nezaglađenost slojnica može ukazivati na nepravilnu morfologiju akumulacije klizišta.

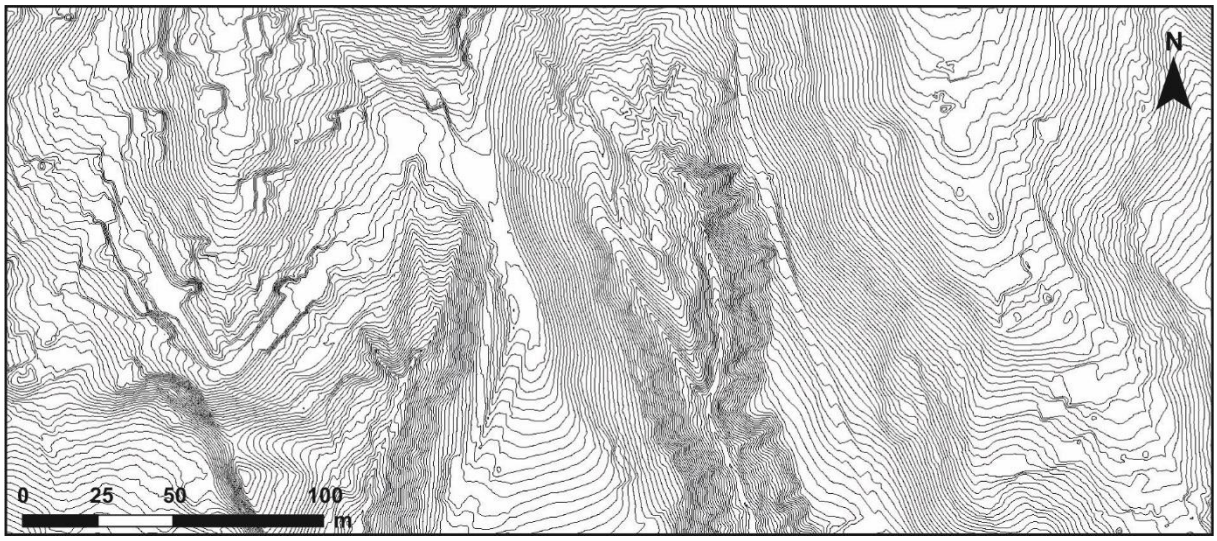

Slika 5.7 Karta slojnica ekvidistancije 1 m dijela pilot područja u podsljemenskoj zoni Grada Zagreba.

5.4 Morfometrijske karte izvedene iz LiDAR DMT-a za automatizirano kartiranje klizišta

Morfometrijske karte korištene za definiranje modela za automatizirano kartiranje klizišta na pilot području u podsljemenskoj zoni Grada Zagreba izrađene su u računalnom programu *ArcGIS-u 10.0* iz digitalnog modela terena rezolucije 1x1 m. DMT je izrađen iz oblaka točaka iz kojega su uklonjeni svi objekti, jer skenirane točke na mjestu objekata nisu klasificirane kao teren. Osim toga, prije izrade svih morfometrijskih karata, za koje je pretpostavljeno da se mogu koristiti za automatizirano kartiranje klizišta, iz LiDAR DMT-a je dodatno uklonjen dio površine unutar zone širine 3 m oko građevina i prometnica (slika 5.8). Razlog tomu je što su analize morfometrijskih parametara ukazale na to da lineamenti nastali kao posljedica interpolacije oblaka točaka na rubnim područjima oko građevina i na rubnom području uz prometnice imaju slične ili iste morfometrijske parametre kao i područja zahvaćena procesom klizanja. U tablici 5.3 prikazane su površine zona različitih širina oko građevina i prometnica te površine analiziranog područja i klizišta nakon izrezivanja LiDAR DMT-a. Zonom širine 3 m oko građevina i prometnica (površine 6,4 km^2) zahvaćeno je ukupno 110 klizišta, odnosno 15,6% od ukupnog broja kartiranih klizišta, a površina klizišta koja je uklonjena iz daljnjih analiza je svega 0,9% od ukupne površine klizišta. Pri tome niti jedno od 110 zahvaćenih klizišta nije cijelom površinom u zoni širine 3m oko građevina i prometnica, već samo manjim dijelom (slika 5.8). Nakon uklanjanja zone širine 3 m oko građevina i prometnica, površina analiziranog pilot područja je 14,8 km^2.

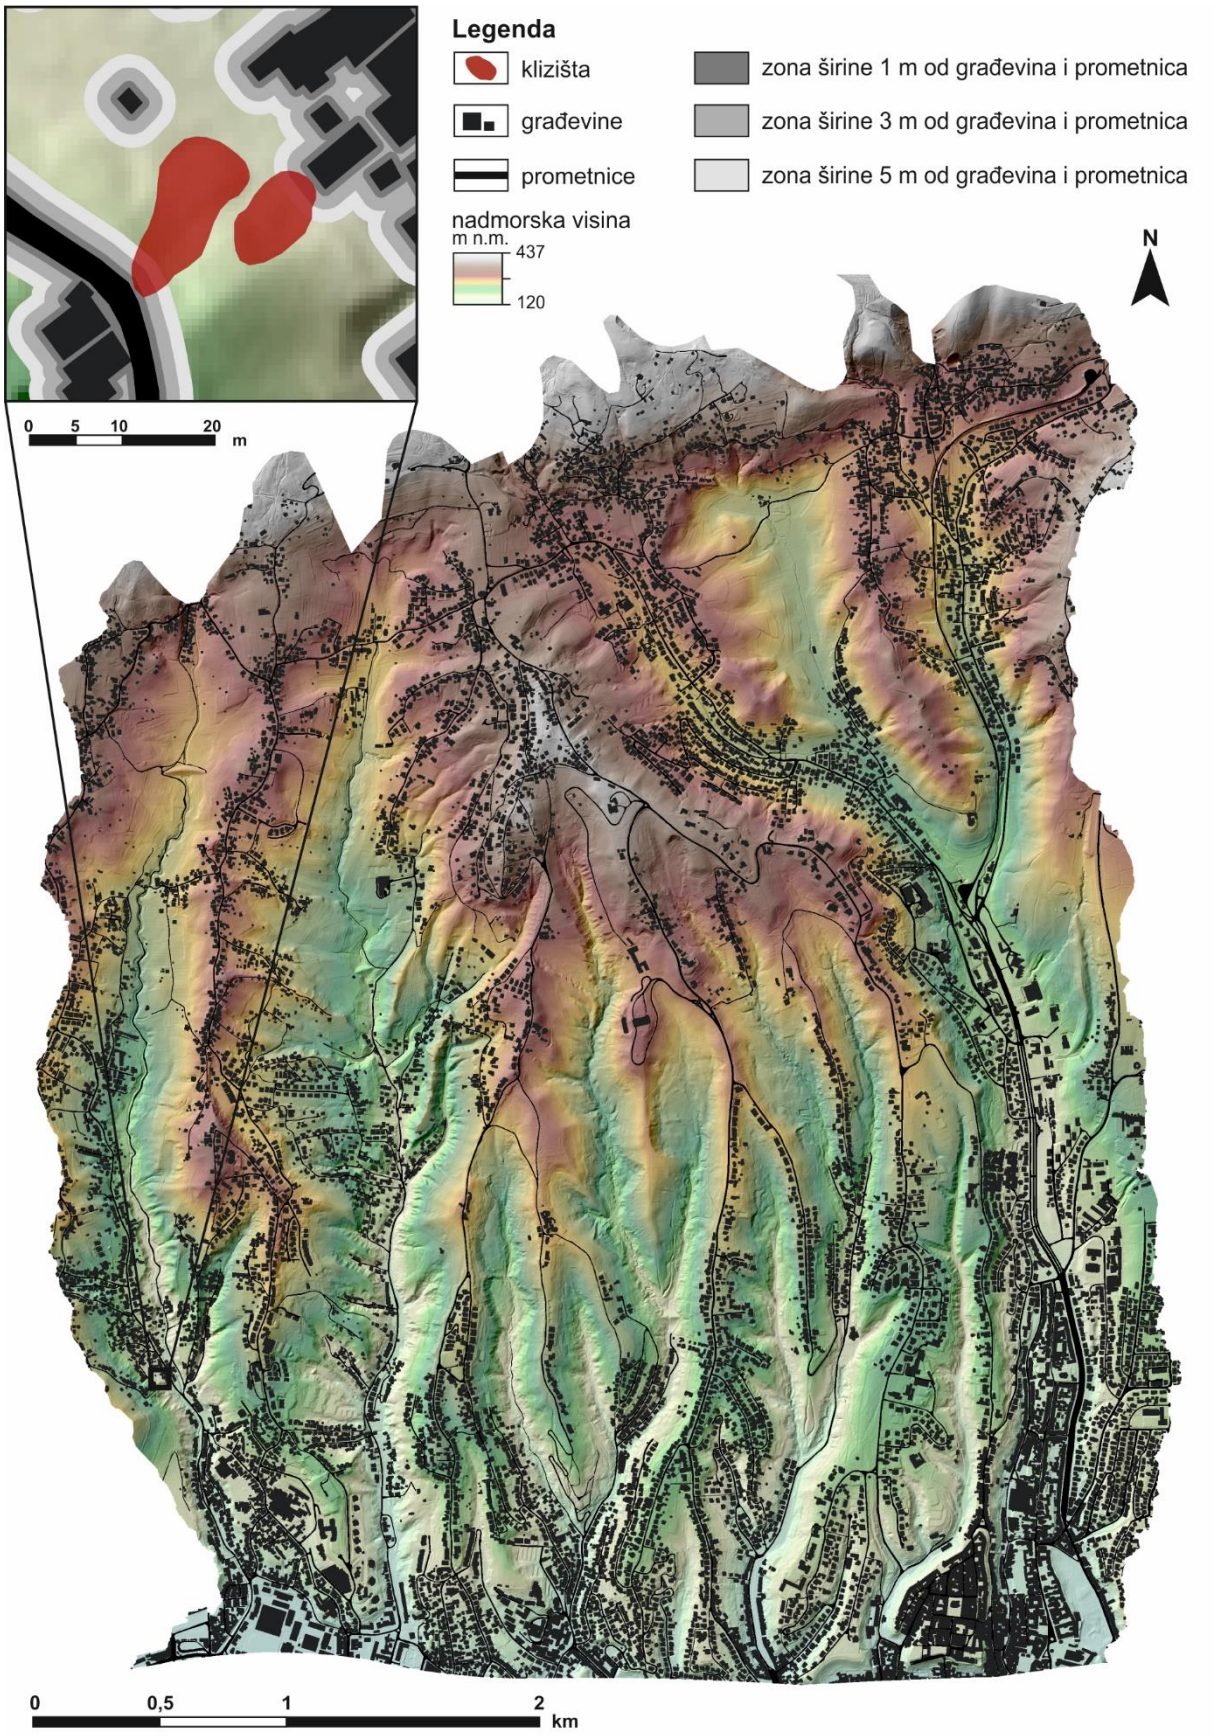

Slika 5.8 Položaj objekata i prometnica na pilot području u podsljemenskoj zoni Grada Zagreba. Na uvećanom detalju prikazan je primjer položaja klizišta u odnosu na zone širine 1, 3 i 5 m od građevina i prometnica.

Tablica 5.3 Površine zona različitih širina oko građevina i prometnica na pilot području.

	Površina zone		Površina analiziranog područja		Klizišta zahvaćenih zonom		Površina klizišta zahvaćenih zonom	
	km^2	%	km^2	%	broj	%	m^2	%
zona širine 1m	4,4	20,6	16,8	79,4	77	11	1867	0,4
zona širine 3 m	6,4	30,1	14,8	62,9	110	15,7	4997	0,9
zona širine 5 m	7,9	37,5	13,2	62,5	136	19,4	9890	1,8

Iz LiDAR DMT-a rezolucije 1x1 m ukupno je izvedeno 127 različitih morfometrijskih karata koje se mogu podijeliti u osam glavnih grupa, a to su karte nadmorskih visina, karte osjenčanosti terena, karte nagiba terena, karte slojnica, karte zakrivljenosti terena, karte hrapavosti terena, karte vlažnosti i karte raščlanjenosti terena (tablica 5.4). U slijedećim poglavljima ukratko su opisane metode izrade morfometrijskih karata po glavnim grupama.

Tablica 5.4 Vrste i broj izvedenih morfometrijskih karata za automatizirano kartiranje klizišta po glavnim grupama karata.

br.	naziv grupe morfometrijskih karata	broj morfometrijskih karata
1	karte nadmorskih visina	12
2	karte osjenčanosti terena	12
3	karte nagiba terena	23
4	karte slojnica terena	3
5	karte zakrivljenosti terena	44
6	karte hrapavosti terena	25
7	karte vlažnosti terena	2
8	karte raščlanjenosti terena	6
ukupno:		127

5.4.1 Karte nadmorskih visina

Primjenom alata za žarišnu statistiku iz LIDAR DMT-a rezolucije 1x1 m izvedene su dvije vrste morfometrijskih karata nadmorskih visina, a to su karte raspona vrijednosti nadmorskih visina i karte standardne devijacije nadmorskih visina. Prilikom izrade morfometrijskih karata nadmorske visine primijenjeni su različiti oblici prozora (krug i kvadrat) i različite veličine prozora (3x3, 5x5 i 9x9 ćelija). Karta raspona nadmorskih visina za promatranu (središnju) ćeliju daje vrijednost najveće razlike vrijednosti nadmorskih visina između središnje ćelije i okolnih ćelija za npr. prozora oblika kvadrata i veličine 3x3 ćelije (slika 5.9). Kod karte standardne devijacije nadmorskih visina za promatranu (središnju) ćeliju izračunata je standardna devijacija od vrijednosti nadmorskih visina u npr. prozoru oblika kruga i radijusa tri ćelije (slika 5.10). Primjenom žarišne statistike dobiveno je ukupno šest karata raspona vrijednosti nadmorske visine (tablica 5.5) i šest karata standardne devijacije nadmorskih visina (tablica 5.6).

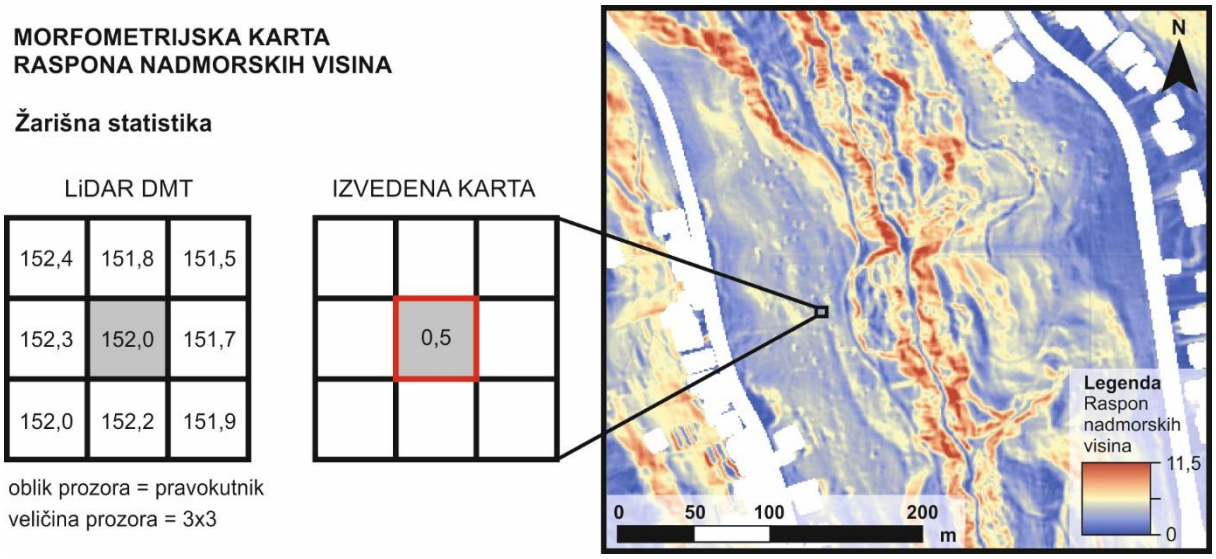

Slika 5.9 Primjer morfometrijske karte raspona nadmorskih visina izvedene primjenom žarišne statistike iz LiDAR DMT-a dijela pilot područja u podsljemenskoj zoni Grada Zagreba.

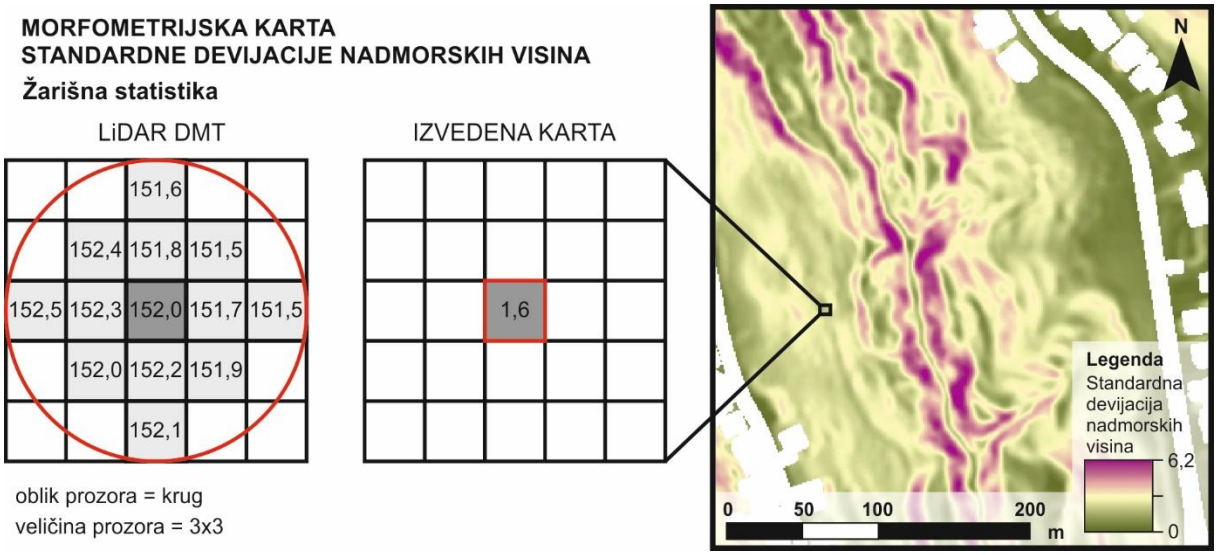

Slika 5.10 Primjer morfometrijske karte standardne devijacije nadmorskih visina izvedene primjenom žarišne statistike iz LiDAR DMT-a dijela pilot područja u podsljemenskoj zoni Grada Zagreba.

Tablica 5.5 Vrste i broj izvedenih morfometrijskih karata raspona nadmorskih visina

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1 m	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	rng_DMT_fr3	karta raspona vrijednosti nadmorske visine u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	rng_DMT_fr5	karta raspona vrijednosti nadmorske visine u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	rng_DMT_fr9	karta raspona vrijednosti nadmorske visine u kvadratu dimenzija 9x9 m
LiDAR DMT 1 m	Focal Statistics	oblik prozora = krug; veličina prozora = 3x3	rng_DMT_fc3	karta raspona vrijednosti nadmorske visine u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5x5	rng_DMT_fc5	karta raspona vrijednosti nadmorske visine u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9x9	rng_DMT_fc9	karta raspona vrijednosti nadmorske visine u krugu radijusa 9 m

Tablica 5.6 Vrste i broj izvedenih morfometrijskih karata standardne devijacije nadmorskih visina

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1 m	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	std_DMT_fr3	karta standardne devijacije nadmorske visine u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	std_DMT_fr5	karta standardne devijacije nadmorske visine u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	std_DMT_fr9	karta standardne devijacije nadmorske visine u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	std_DMT_fc3	karta standardne devijacije nadmorske visine u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	std_DMT_fc5	karta standardne devijacije nadmorske visine u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	std_DMT_fc9	karta standardne devijacije nadmorske visine u krugu radijusa 9 m

5.4.2 Karte osjenčanosti terena

Primjenom alata za žarišnu statistiku u *ArcGIS-u 10.0*. iz karte osjenčanosti terena iluminacije 315°/45° i rezolucije 1x1 m izvedene su dvije vrste morfometrijskih karata, karte raspona vrijednosti osjenčanosti terena i karte standardne devijacije osjenčanosti terena. Kartu standardne devijacije osjenčanosti terena za automatizirano kartiranje klizišta prvi su koristili Pawłuszek i Borkowski (2016). Prilikom izrade morfometrijskih karata osjenčanosti terena primijenjeni su različiti oblici prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija). Karta raspona osjenčanosti terena (slika 5.11a) za svaku promatranu (središnju) ćeliju daje vrijednost najvećeg raspona vrijednosti osjenčanosti središnje ćelije i okolnih ćelija u npr. prozoru oblika kvadrata veličine 3x3 ćelije. Kod karte standardne devijacije osjenčanosti terena (slika 5.11b) za promatranu (središnju) ćeliju izračunata je standardna devijacija od vrijednosti osjenčanosti u npr. prozoru oblika kruga i radijusa tri ćelije. Primjenom žarišne statistike dobiveno je ukupno šest karata raspona vrijednosti osjenčanosti terena (tablica 5.7) i šest karata standardne devijacije osjenčanosti terena (tablica 5.8).

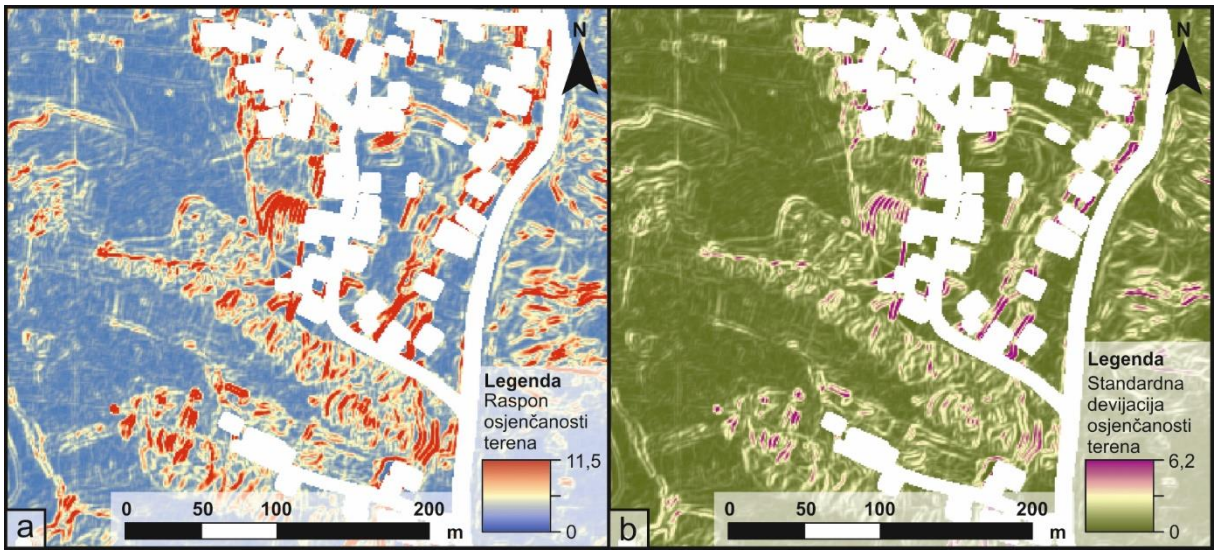

Slika 5.11 Morfometrijske karte osjenčanosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta raspona osjenčanosti terena dobivena kružnim prozorom radijusa 3 m; (b) karta standardne devijacije osjenčanosti terena dobivena kvadratnim prozorom dimenzija 3x3 m.

Tablica 5.7 Vrste i broj izvedenih morfometrijskih karata raspona osjenčanosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta osjenčanosti terena 315°/45°	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	rng_hill_fr3	karta raspona vrijednosti osjenčanosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	rng_hill_fr5	karta raspona vrijednosti osjenčanosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	rng_hill_fr9	karta raspona vrijednosti osjenčanosti terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3x3	rng_hill_fc3	karta raspona vrijednosti osjenčanosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5x5	rng_hill_fc5	karta raspona vrijednosti osjenčanosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9x9	rng_hill_fc9	karta raspona vrijednosti osjenčanosti terena u krugu radijusa 9 m

Tablica 5.8 Vrste i broj izvedenih morfometrijskih karata standardne devijacije osjenčanosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta osjenčanosti terena 315°/45°	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	std_hill_fr3	karta standardne devijacije osjenčanosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	std _hill_fr5	karta standardne devijacije osjenčanosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	std _hill_fr9	karta standardne devijacije osjenčanosti terena u kvadratu dimenzija 9x9 m

Nastavak tablice 5.8.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta osjenčanosti terena 315°/45°	Focal Statistics	oblik prozora = krug; veličina prozora = 3	std _hill_fc3	karta standardne devijacije osjenčanosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	std _hill_fc5	karta standardne devijacije osjenčanosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	std _hill_fc9	karta standardne devijacije osjenčanosti terena u krugu radijusa 9 m

5.4.3 Karte nagiba terena

Grupu morfometrijskih karata nagiba terena čine ukupno 23 karte koje se mogu podijeliti na kartu nagiba terena, karte raspona nagiba terena, karte standardne devijacije nagiba terena, karte relativnog položaja na padini (engl. *slope position map*) i karta druge derivacije nagiba terena (tablica 5.9).

Tablica 5.9 Vrste i broj izvedenih morfometrijskih karata nagiba terena.

Br.	Naziv podgrupe morfometrijskih karata	Broj morfometrijskih karata
1	karta nagiba terena	1
2	karte raspona nagiba terena	6
3	karte standardne devijacije nagiba terena	6
4	karte relativnog nagiba terena	6
5	karta druge derivacije nagiba terena	1
6	karta indeksa položaja	3
ukupno:		23

Karta nagiba terena (slika 5.6b) izvedena je iz LiDAR DMT-a pomoću ekstenzije *Spatial Analyst* (alata *Slope*) te prikazuje prostornu distribuciju vrijednosti kutova nagiba u rasponu od 0° do 90°. Karte raspona nagiba terena i karte standardne devijacije nagiba terena izvedene su iz karte nagiba terena primjenom alata žarišne statistike. Prilikom izrade morfometrijskih karata nagiba terena primijenjeni su različiti oblici prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija). Karta raspona nagiba terena (slika 5.12a) za svaku promatranu (središnju) ćeliju daje vrijednost najvećeg raspona vrijednosti nagiba središnje ćelije i okolnih ćelija npr. u prozoru oblika kvadrata veličine 3x3 ćelije. Kod karte standardne devijacije nagiba terena (slika 5.12b) za promatranu (središnju) ćeliju izračunata je standardna devijacija od vrijednosti nagiba terena u npr. prozoru oblika kruga radijusa tri ćelije. Primjenom žarišne statistike dobiveno je ukupno šest karata raspona vrijednosti nagiba terena (tablica 5.10) i šest karata standardne devijacije nagiba terena (tablica 5.11).

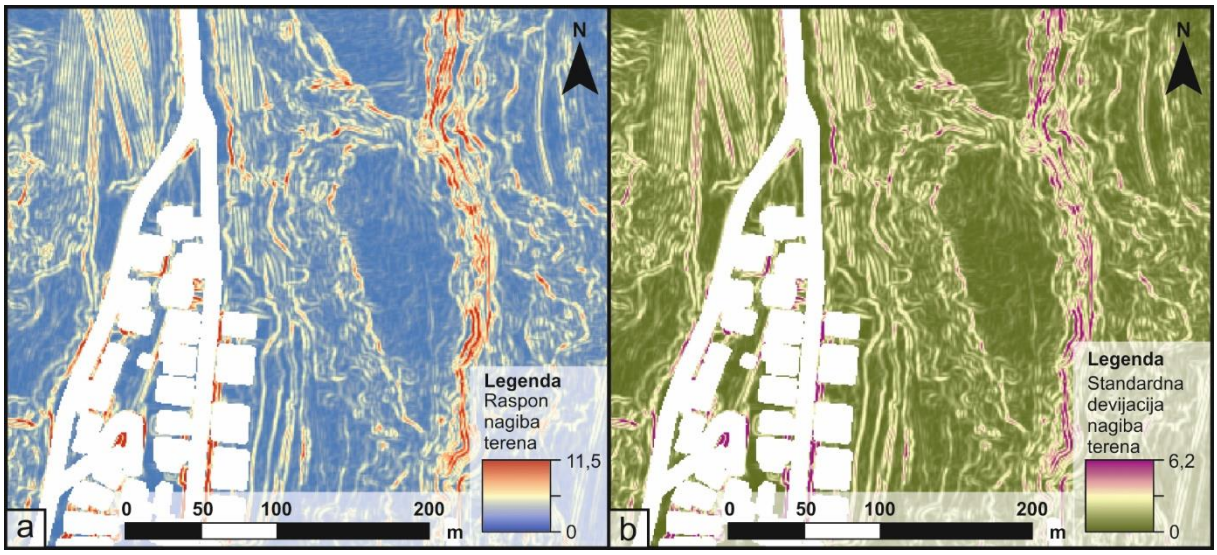

Slika 5.12 Morfometrijske karte nagiba terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta raspona nagiba terena dobivena kvadratnim prozorom dimenzija 3x3 m; (b) karta standardne devijacije nagiba terena dobivena kružnim prozorom radijusa 3 m.

Tablica 5.10 Vrste i broj izvedenih morfometrijskih karata raspona nagiba terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta nagiba terena	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	rng_slp_fr3	karta raspona vrijednosti nagiba terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	rng_slp_fr5	karta raspona vrijednosti nagiba terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	rng_slp_fr9	karta raspona vrijednosti nagiba terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3x3	rng_slp_fc3	karta raspona vrijednosti nagiba terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5x5	rng_slp_fc5	karta raspona vrijednosti nagiba terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9x9	rng_slp_fc9	karta raspona vrijednosti nagiba terena u krugu radijusa 9 m

Tablica 5.11 Vrste i broj izvedenih morfometrijskih karata standardne devijacije nagiba terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta nagiba terena	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	std_slp_fr3	karta standardne devijacije nagiba terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	std _slp_fr5	karta standardne devijacije nagiba terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	std _slp_fr9	karta standardne devijacije nagiba terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	std _slp_fc3	karta standardne devijacije nagiba terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	std _slp_fc5	karta standardne devijacije nagiba terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	std _slp_fc9	karta standardne devijacije nagiba terena u krugu radijusa 9 m

Karte relativnog položaja na padini (engl. *slope position map*) izvedene su iz LiDAR DMT-a pomoću *ArcGIS Toolbox-a* pod nazivom *Geomorphometry and Gradient Metrics* (Evans et al. 2014) i alata *Slope position*. Karta relativnog položaja na padini (De Reu et al., 2013; Guisan et al., 1999) prikazuje položaj središnje ćelije u odnosu na susjedne ćelije na način da pozitivne vrijednosti ukazuju na to da je središnja ćelija smještena na višoj nadmorskoj visini od srednje nadmorske visine susjednih ćelija, dok negativne vrijednosti ukazuju da je središnja točka smještena niže od srednje vrijednosti nadmorskih visina susjednih točaka. Prilikom izrade morfometrijskih karata primijenjeni su različiti oblici prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija) te je ukupno dobiveno 6 karata relativnog nagiba terena (tablica 5.12 i slika 5.13a).

Tablica 5.12 Vrste i broj izvedenih morfometrijskih karata relativnog položaja padine.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1 m	Slope position, GGM Toolbox	oblik prozora = kvadrat; veličina prozora = 3x3	std_slp_fr3	karta relativnog položaja dobivena kvadratnim prozorom dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	std_slp_fr5	karta relativnog položaja dobivena kvadratnim prozorom dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	std_slp_fr9	karta relativnog položaja dobivena kvadratnim prozorom dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	std_slp_fc3	karta relativnog položaja dobivena kružnim prozorom radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	std_slp_fc5	karta relativnog položaja dobivena kružnim prozorom radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	std_slp_fc9	karta relativnog položaja dobivena kružnim prozorom radijusa 9 m

Karta druge derivacije nagiba terena (engl. *2nd derivate of slope*) izvedena je iz LiDAR DMT-a pomoću *ArcGIS Toolbox-a* pod nazivom *Geomorphometry and Gradient Metrics* (Evans et al. 2014) i alata *Slope (2nd derivate)*. Izvedena morfometrijska karta prikazuje drugu derivaciju karte nagiba terena (slika 5.13b).

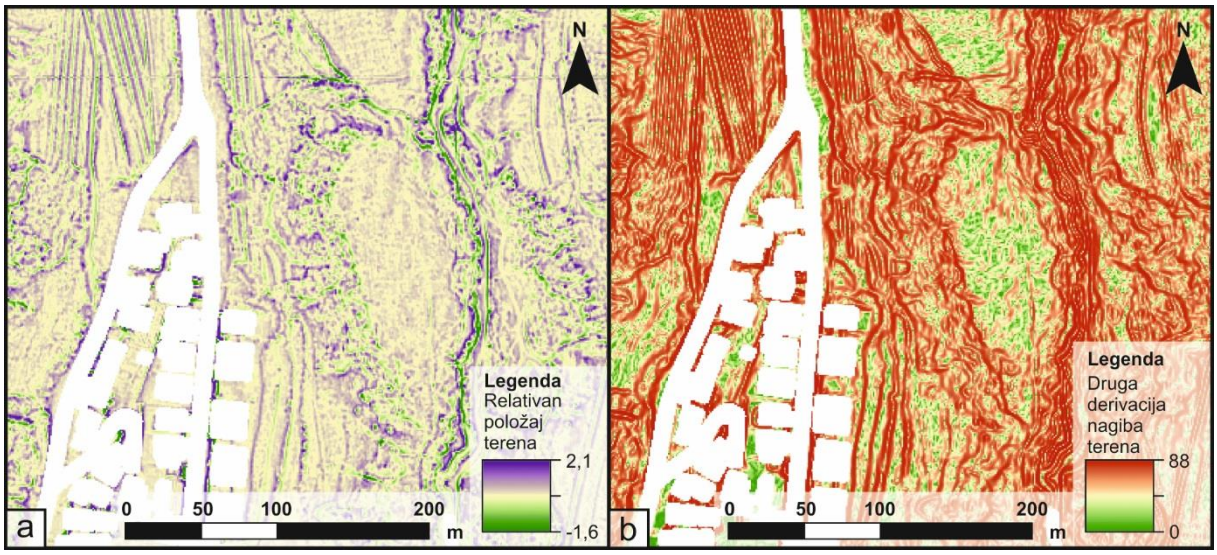

Slika 5.13 Morfometrijske karte nagiba terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta relativnog položaja na padini dobivena kvadratnim prozorom dimenzija 3x3 m; (b) karta druge derivacije nagiba terena.

Indeks položaja (engl. s*ite index*) je izraz koji opisuje utjecaj orijentacije padine, nagib padine i tipa staništa za rast drveća, a razvio ga je Stage (1976). Za morfometrijske analize koristi se modificirani izraz indeksa položaja koji ovisi samo o orijentaciji i nagibu padine. Indeks položaja izveden je iz LiDAR DMT-a pomoću *ArcGIS Toolbox-a* pod nazivom *Geomorphometry and Gradient Metrics* (Evans et al. 2014) i alata *Slope/Aspect Transformations* (tablica 5.13). Karta indeksa položaja izvedena je modifikacijom dviju metoda *SIN* i *COS* koje je prethodno razvio Stage (1976) i metode *TRASP* (engl. *topographic radiation aspect index*) autora Roberts i Cooper (1989). Kod metoda *SIN* i *COS* (slika 5.14a) glavna pretpostavka je da se maksimalne vrijednosti u sjeverozapadnom kvadrantu i minimalne vrijednosti u jugozapadnom kvadrantu mogu izraziti empirijskim izrazom:

$$sat_{cos} = \theta \cos(\alpha) \tag{21}$$

$$sat_{sin} = \theta \sin(\alpha) \tag{22}$$

pri čemu je θ nagib padine izražen kao postotak, a α je orijentacija padine izražena kao azimut u stupnjevima. Za padine nagiba od 0 do 100%, funkcija daje linearnu vrijednosti od -1,01 do 1,01, pri čemu padine s nagibom većim od 100% imaju vrijednost 1,01, dok zaravnjenim dijelovima terena nisu dodijeljene vrijednosti (engl. *No data*).

Kod *TRASP* metode (slika 5.14b) orijentacija nagiba terena je transformirana u vrijednost 0 za padine orijentirane prema sjever-sjeverozapadu (najčešće najvlažnije i najhladnije padine), i vrijednost 1 za padine orijentirane prema jug-jugozapadu. Rezultat je izvedena morfometrijska karta s vrijednostima između 0 i 1 (Roberts i Cooper, 1989), a vrijednost ćelije definirana je kao:

$$trasp = \frac{1 - cos\left(\left(\frac{\pi}{180}\right)(\alpha - 30)\right)}{2} \tag{23}$$

pri čemu je α, orijentacija padine izražena kao azimut u stupnjevima.

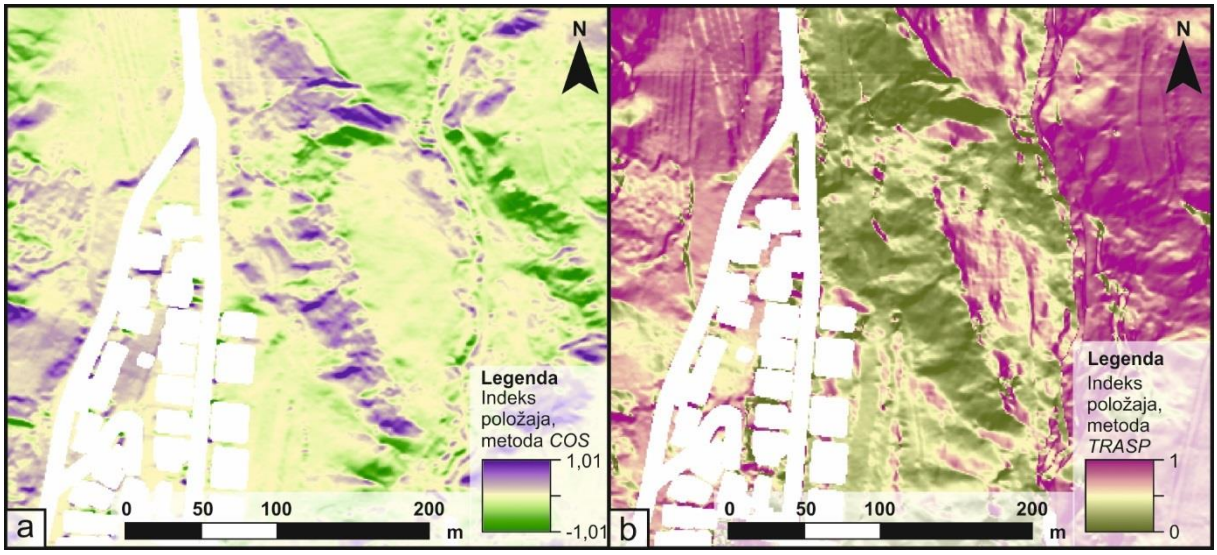

Slika 5.14 Morfometrijske karte indeksa položaja padine dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta položaja izvedena metodom *COS*; (b) karta položaja izvedena metodom *TRASP*.

Tablica 5.13 Vrste i broj izvedenih morfometrijskih karata transformacije nagiba i orijentacije terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1m	Slope/Aspect Transformations, GGM Toolbox	metoda SIN	sat_sin	karta transformacije nagiba i orijentacije terena izvedena pomoću metode SIN
		metoda COS	sat_cos	karta transformacije nagiba i orijentacije terena izvedena pomoću metode COS
		metoda TRASP	sat_trasp	karta transformacije nagiba i orijentacije terena izvedena pomoću metode TRASP

5.4.4 Karte slojnica

Karte gustoće slojnica (slika 5.15) izvedene su iz karte slojnica ekvidistancije 1 m pomoću alata *Kernel density* te prikazuju gustoću slojnica s obzirom na različiti radijus prozora (3, 5 i 9 ćelija) (tablica 5.14).

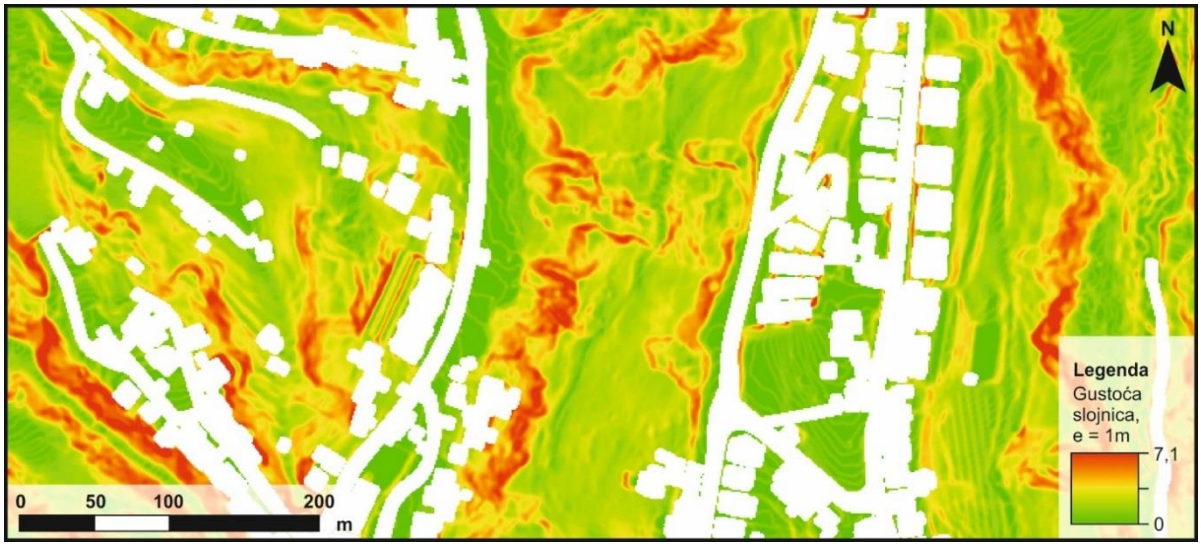

Slika 5.15 Morfometrijska karta gustoće slojnica dijela pilot područja u podsljemenskoj zoni Grada Zagreba dobivena kružnim prozorom radijusa 3 m .

Tablica 5.14 Vrste i broj izvedenih morfometrijskih karata gustoće slojnica.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta slojnica ekvidistancije 1 m	Kernel density	veličina prozora = 3 m	con_1m_r3m	karta gustoće slojnica dobivena kružnim prozorom radijusa 3 m
		veličina prozora = 5 m	con_1m_r5m	karta gustoće slojnica dobivena kružnim prozorom radijusa 5 m
		veličina prozora = 9 m	con_1m_r9m	karta gustoće slojnica dobivena kružnim prozorom radijusa 9 m

5.4.5 Karte zakrivljenosti terena

Zakrivljenost terena ukazuje na vrstu i intenzitet procesa koji djeluju na promjene u morfologiji padine ili njezinih dijelova. Matematički gledano, zakrivljenost se definira kao odstupanje geometrijskog objekta od ravnine. Zakrivljenost kružnice je inverzna radijusu same kružnice, odnosno izražava se jednadžbom k=1/r. S porastom radijusa kružnice, smanjuje se zakrivljenost i obratno. Zakrivljenost predstavlja koeficijent odstupanja krivulje od pravca čija je zakrivljenost nula. Najčešće se zakrivljenost računa s obzirom na prozor 3x3 ćelije pri čemu je zakrivljenost jednaka drugoj derivaciji visinskih vrijednosti DMT-a (Evans,1972), a vrijednost zakrivljenosti u svakoj ćeliji definirana je polinomom četvrtog stupnja:

$$Z = Ax^2y^2 + Bx^2y + Cxy^2 + Dx^2 + Ey^2 + Fxy + Gx + Hy + I \qquad (24)$$

gdje je:

$A = [(Z1 + Z3 + Z7 + Z9) / 4 - (Z2 + Z4 + Z6 + Z8) / 2 + Z5] / L^4$

$B = [(Z1 + Z3 - Z7 - Z9) /4 - (Z2 - Z8) /2] / L^3$

$C = [(-Z1 + Z3 - Z7 + Z9) /4 + (Z4 - Z6)] /2] / L^3$

$D = [(Z4 + Z6) /2 - Z5] / L^2$

$E = [(Z2 + Z8) /2 - Z5] / L^2$

$F = (-Z1 + Z3 + Z7 - Z9) / 4L^2$

$G = (-Z4 + Z6) / 2L$

$H = (Z2 - Z8) / 2L$

$I = Z5$

gdje su Z1, Z2, Z3, Z4, Z5, Z6, Z7, Z8 i Z9 vrijednosti nadmorskih visina u kvadratu dimenzija 3x3 ćelije, x i y su relativne koordinate, a L je veličina ćelije.

Osim ukupne zakrivljenosti, razlikuju se još i profilna i planarna zakrivljenost. Kod profilne zakrivljenosti, zakrivljenost padine se promatra u smjeru njezina nagiba. Negativna vrijednost profilne zakrivljenosti ukazuje na konveksni uzdužni profil padine, a pozitivna vrijednost na konkavni profil, dok vrijednost nula označava linearnu (pravocrtnu) padinu. Profilna zakrivljenost utječe na brzinu otjecanja vode, odnosno na brzinu kretanja koluvija niz padinu. Planarna zakrivljenosti se promatra u smjeru okomitom na smjer nagiba padine, a pozitivne vrijednost ukazuju na konveksni oblik padine, negativne vrijednosti na konkavni oblik, dok nulta vrijednost ukazuje na linearnu (pravocrtnu) padinu. Općenito, karte zakrivljenosti terena su vrlo koristan alat za identifikaciju dijelova klizišta koje karakterizira određeni tip zakrivljenosti površine, kao što je konveksan oblik stope klizišta ili konkavan oblik čela klizišta (Amundsen et al. 2010).

Grupu morfometrijskih karata zakrivljenosti terena čini ukupno 44 karte koje se mogu podijeliti na 9 podgrupa, a to su karte zakrivljenosti terena, karte raspona vrijednosti zakrivljenosti terena, karte standardne devijacije zakrivljenosti terena, karte profilne zakrivljenosti terena, karte raspona vrijednosti profilne zakrivljenosti terena, karte standardne devijacije profilne zakrivljenosti terena, karte planarne zakrivljenosti terena, karte raspona vrijednosti planarne zakrivljenosti terena, karte standardne devijacije planarne zakrivljenosti terena (tablica 5.15).

Tablica 5.15 Vrste i broj izvedenih morfometrijskih karata zakrivljenosti terena.

Br.	Naziv podgrupe morfometrijskih karata	Broj morfometrijskih karata
1	karte ukupne zakrivljenosti terena	6
2	karte raspona vrijednosti ukupne zakrivljenosti terena	6
3	karte standardne devijacije ukupne zakrivljenosti terena	6
4	karte profilne zakrivljenosti terena	1
5	karte raspona vrijednosti profilne zakrivljenosti terena	6
6	karte standardne devijacije profilne zakrivljenosti terena	6
7	karte planarne zakrivljenosti terena	1
8	karte raspona vrijednosti planarne zakrivljenosti terena	6
9	karte standardne devijacije planarne zakrivljenosti terena	6
ukupno:		44

Karte ukupne zakrivljenosti terena izvedene su iz LiDAR DMT-a rezolucije 1 m pomoću alata *Curvature* u *Geomorphometry and Gradient Metrics Toolbox-u* (Evans et al. 2014). Alat omogućava izračun zakrivljenosti terena (slika 5.16) s obzirom na različite oblike i veličine prozora, te je ukupno izvedeno šest morfometrijskih karata zakrivljenosti terena s kružnim i kvadratnim oblikom prozora i veličinom prozora od 3x3, 5x5 i 9x9 ćelija (tablica 5.16).

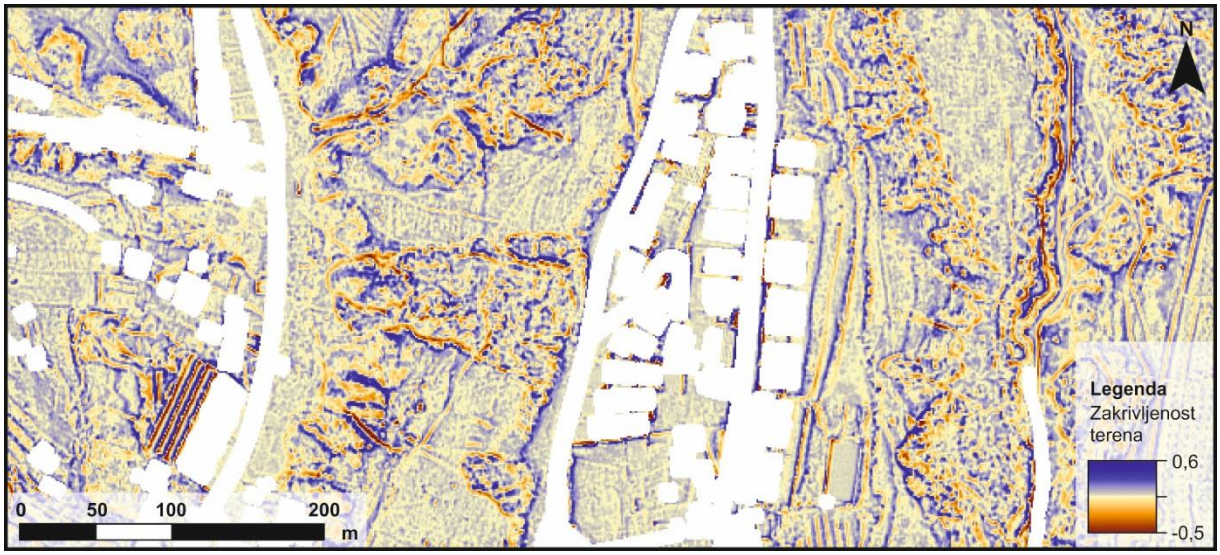

Slika 5.16 Morfometrijska karta zakrivljenosti dijela pilot područja u podsljemenskoj zoni Grada Zagreba dobivena kvadratnim prozorom veličine 3x3 m.

Tablica 5.16 Vrste i broj izvedenih morfometrijskih karata ukupne zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1m	Curvature, *GGM Toolbox*	oblik prozora = kvadrat; veličina prozora = 3x3	crv_fr3	karta zakrivljenosti terena dobivena kvadratnim prozorom dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	crv_fr5	karta zakrivljenosti terena dobivena kvadratnim prozorom dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	crv_fr9	karta zakrivljenosti terena dobivena kvadratnim prozorom dimenzija 5x5 m
		oblik prozora = krug; veličina prozora = 3	crv_fc3	karta zakrivljenosti terena dobivena kružnim prozorom radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	crv_fc5	karta zakrivljenosti terena dobivena kružnim prozorom radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	crv_fc9	karta zakrivljenosti terena dobivena kružnim prozorom radijusa 9 m

Primjenom alata žarišne statistike iz karte zakrivljenosti terena dobivene kvadratnim prozorom dimenzija 3x3 m izvedene su dvije vrste morfometrijskih karata, karte raspona vrijednosti zakrivljenosti terena i karte standardne devijacije zakrivljenosti terena. Prilikom izrade morfometrijskih karata primijenjeni su različiti oblici prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija). Karta raspona zakrivljenosti terena (slika 5.17a) za svaku promatranu (središnju) ćeliju daje vrijednost najvećeg raspona vrijednosti zakrivljenosti središnje ćelije i okolnih ćelija u npr. prozoru oblika kvadrata veličine 3x3 ćelije. Kod karte standardne devijacije zakrivljenosti terena (slika 5.17b) za promatranu (središnju) ćeliju je izračunata standardna devijacija od vrijednosti zakrivljenosti u npr. prozoru oblika kruga radijusa tri ćelije. Primjenom žarišne statistike dobiveno je ukupno šest karata raspona vrijednosti zakrivljenosti terena (tablica 5.17) i šest karata standardne devijacije zakrivljenosti terena (tablica 5.18).

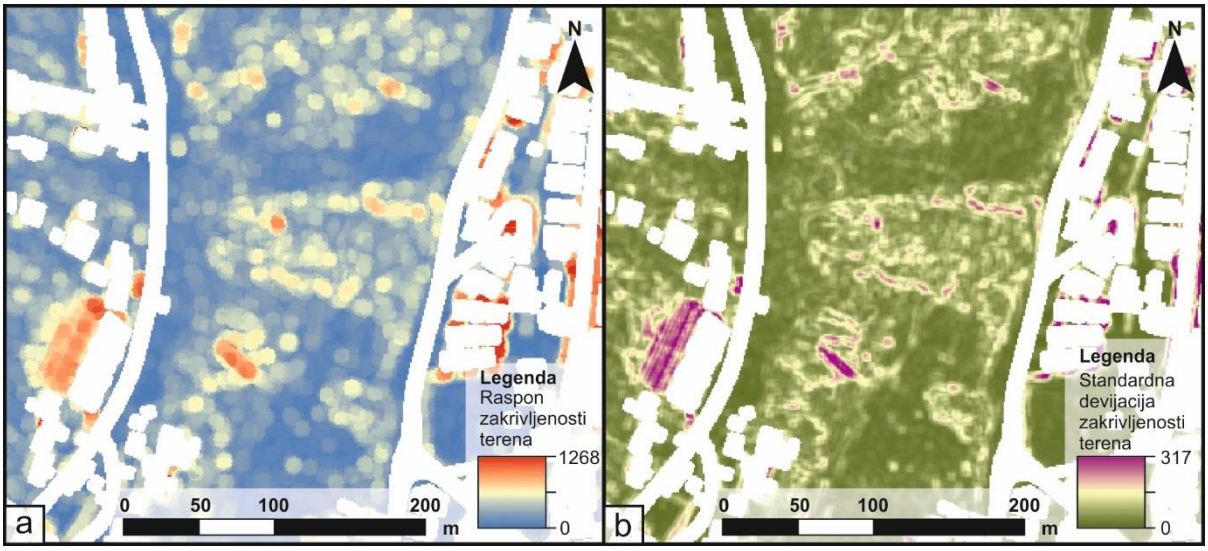

Slika 5.17 Morfometrijske karte zakrivljenosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta raspona zakrivljenosti terena dobivena kružnim prozorom radijusa 5 m; (b) karta standardne devijacije nagiba zakrivljenosti dobivena kvadratnim prozorom dimenzija 3x3 m.

Tablica 5.17 Vrste i broj izvedenih morfometrijskih karata raspona zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta zakrivljenosti terena (crv_fr3)	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	rng_crv_fr3	karta raspona vrijednosti zakrivljenosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	rng_crv_fr5	karta raspona vrijednosti zakrivljenosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	rng_crv_fr9	karta raspona vrijednosti zakrivljenosti terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	rng_crv_fc3	karta raspona vrijednosti zakrivljenosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	rng_crv_fc5	karta raspona vrijednosti zakrivljenosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	rng_crv_fc9	karta raspona vrijednosti zakrivljenosti terena u krugu radijusa 9 m

Tablica 5.18 Vrste i broj izvedenih morfometrijskih karata standardne devijacije zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta zakrivljenosti terena (crv_fr3)	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	std_crv_fr3	karta standardne devijacije vrijednosti zakrivljenosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	std_crv_fr5	karta standardne devijacije vrijednosti zakrivljenosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	std_crv_fr9	karta standardne devijacije zakrivljenosti terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	std_crv_fc3	karta standardne devijacije vrijednosti zakrivljenosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	std_crv_fc5	karta standardne devijacije vrijednosti zakrivljenosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	std_crv_fc9	karta standardne devijacije vrijednosti zakrivljenosti terena u krugu radijusa 9 m

Primjenom alata *Curvature* iz LiDAR DMT-a izvedene su dvije vrste morfometrijskih karata, karta planarne zakrivljenosti terena i karta profilne zakrivljenosti terena. Alat *Curvature* izračunava vrijednosti planarne i profilne zakrvljenosti terena s obzirom na prozor oblika kvadrata dimenzija 3x3 m (slika 5.18 i tablica 5.19)

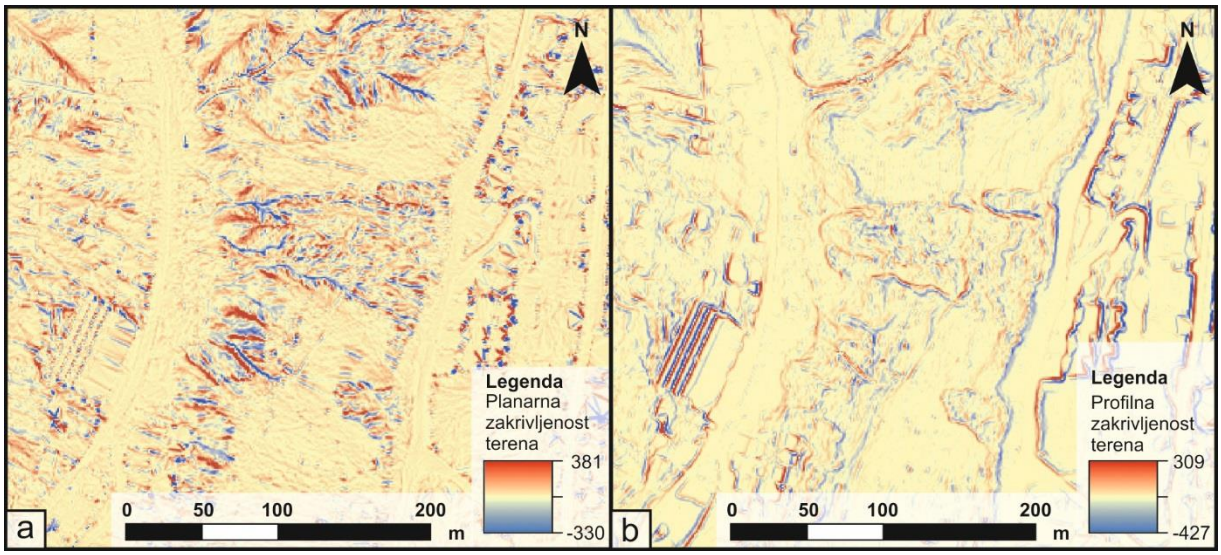

Slika 5.18 Morfometrijske karte zakrivljenosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) planarna zakrivljenost terena; (b) profilna zakrivljenost terena.

Tablica 5.19 Vrste i broj izvedenih morfometrijskih karata planarne i profilne zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1m	Curvature	-	cplan	karta planarne zakrivljenosti terena
		-	cprf	karta profilne zakrivljenosti terena

Primjenom alata žarišne statistike iz karte planarne zakrivljenosti terena izvedene su dvije vrste morfometrijskih karata, karte raspona vrijednosti planarne zakrivljenosti terena i karte standardne devijacije planarne zakrivljenosti terena. Prilikom izrade morfometrijskih karata primijenjeni su različiti oblici prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija). Karta raspona planarne zakrivljenosti terena (slika 5.19a) za svaku promatranu (središnju) ćeliju daje vrijednost najvećeg raspona vrijednosti planarne zakrivljenosti središnje ćelije i okolnih ćelija u npr. prozoru oblika kvadrata veličine 3x3 ćelije. Kod karte standardne devijacije planarne zakrivljenosti terena (slika 5.19b) za promatranu (središnju) ćeliju izračunata je standardna devijacija od vrijednosti planarne zakrivljenosti u npr. prozoru oblika kruga radijusa tri ćelije. Primjenom žarišne statistike dobiveno je ukupno šest karata raspona vrijednosti planarne zakrivljenosti terena (tablica 5.20) i šest karata standardne devijacije planarne zakrivljenosti terena (tablica 5.21).

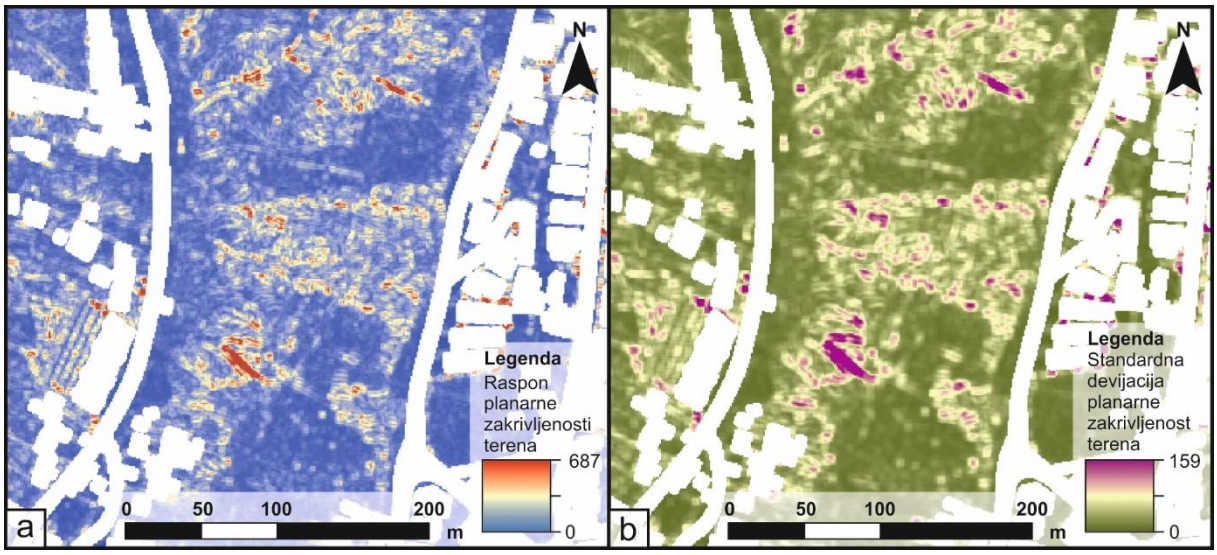

Slika 5.19 Morfometrijske karte planarne zakrivljenosti dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) raspon planarne zakrivljenosti dobivene kružnim prozorom radijusa 5 m; (b) standardna devijacija planarne zakrivljenosti terena dobivena kvadratnim prozorom dimenzija 5x5 m.

Tablica 5.20 Vrste i broj izvedenih morfometrijskih karata raspona planarne zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta planarne zakrivljenosti terena	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	rng_cplan_fr3	karta raspona vrijednosti planarne zakrivljenosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	rng_ cplan _fr5	karta raspona vrijednosti planarne zakrivljenosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	rng_ cplan _fr9	karta raspona vrijednosti planarne zakrivljenosti terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	rng_ cplan _fc3	karta raspona vrijednosti planarne zakrivljenosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	rng_ cplan _fc5	karta raspona vrijednosti planarne zakrivljenosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	rng_ cplan _fc9	karta raspona vrijednosti planarne zakrivljenosti terena u krugu radijusa 9 m

Tablica 5.21 Vrste i broj izvedenih morfometrijskih karata standardne devijacije planarne zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta planarne zakrivljenosti terena	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	std_cplan_fr3	karta standardne devijacije vrijednosti planarne zakrivljenosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	std_ cplan _fr5	karta standardne devijacije vrijednosti planarne zakrivljenosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	std_ cplan _fr9	karta standardne devijacije vrijednosti planarne zakrivljenosti terena u kvadratu dimenzija 9x9 m

Nastavak **tablice 5.21**

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta planarne zakrivljenosti terena	Focal Statistics	oblik prozora = krug; veličina prozora = 3	std_ cplan _fc3	karta standardne devijacije vrijednosti planarne zakrivljenosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	std_ cplan _fc5	karta standardne devijacije vrijednosti planarne zakrivljenosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	std_ cplan _fc9	karta standardne devijacije vrijednosti planarne zakrivljenosti terena u krugu radijusa 9 m

Primjenom alata žarišne statistike iz karte profilne zakrivljenosti terena izvedene su dvije vrste morfometrijskih karata, karte raspona vrijednosti profilne zakrivljenosti terena i karte standardne devijacije profilne zakrivljenosti terena. Prilikom izrade morfometrijskih karata primijenjeni su različiti oblici prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija). Karta raspona profilne zakrivljenosti terena (slika 5.20a) za svaku promatranu (središnju) ćeliju daje vrijednost najvećeg raspona vrijednosti profilne zakrivljenosti središnje ćelije i okolnih ćelija u npr. prozoru oblika kvadrata veličine 3x3 ćelije. Kod karte standardne devijacije profilne zakrivljenosti terena (slika 5.20b) za promatranu (središnju) izračunata je standardna devijacija od vrijednosti planarne zakrivljenosti u npr. prozoru oblika kruga radijusa tri ćelije. Primjenom žarišne statistike dobiveno je ukupno šest karata raspona vrijednosti profilne zakrivljenosti terena (tablica 5.22) i šest karata standardne devijacije profilne zakrivljenosti terena (tablica 5.23).

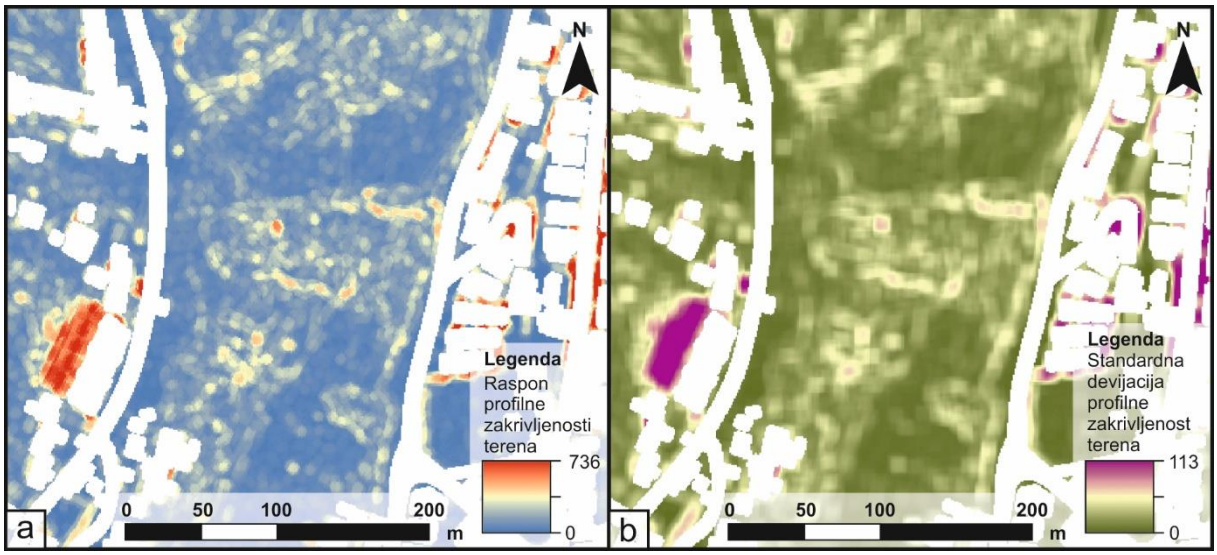

Slika 5.20 Morfometrijske karte profilne zakrivljenosti dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) raspon profilne zakrivljenosti dobivene kružnim prozorom radijusa 3 m; (b) standardna devijacija profilne zakrivljenosti terena dobivena kvadratnim prozorom dimenzija 9x9 m.

Tablica 5.22 Vrste i broj izvedenih morfometrijskih karata raspona profilne zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta profilne zakrivljenosti terena	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	rng_cprf_fr3	karta raspona vrijednosti profilne zakrivljenosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	rng_cprf_fr5	karta raspona vrijednosti profilne zakrivljenosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	rng_cprf_fr9	karta raspona vrijednosti profilne zakrivljenosti terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	rng_cprf_fc3	karta raspona vrijednosti profilne zakrivljenosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	rng_cprf_fc5	karta raspona vrijednosti profilne zakrivljenosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	rng_cprf_fc9	karta raspona vrijednosti profilne zakrivljenosti terena u krugu radijusa 9 m

Tablica 5.23 Vrste i broj izvedenih morfometrijskih karata standardne devijacije profilne zakrivljenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta profilne zakrivljenosti terena	Focal Statistics	oblik prozora = kvadrat; veličina prozora = 3x3	std_cprf_fr3	karta standardne devijacije vrijednosti zakrivljenosti terena u kvadratu dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	std_cprf_fr5	karta standardne devijacije vrijednosti zakrivljenosti terena u kvadratu dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	std_cprf_fr9	karta standardne devijacije zakrivljenosti terena u kvadratu dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	std_cprf_fc3	karta standardne devijacije vrijednosti zakrivljenosti terena u krugu radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	std_cprf_fc5	karta standardne devijacije vrijednosti zakrivljenosti terena u krugu radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	std_cprf_fc9	karta standardne devijacije vrijednosti zakrivljenosti terena u krugu radijusa 9 m

5.4.6 Karte hrapavosti terena

Grupu morfometrijskih karata hrapavosti terena čini ukupno 25 karata koje se mogu podijeliti na karte hrapavosti terena, karte relativnog topografskog položaja, karte standardne devijacije nadmorske visine prema Ascione et al. (2008), karte indeksa hrapavosti terena i kartu omjera 3D i 2D površine terena (tablica 5.24).

Tablica 5.24 Vrste i broj izvedenih morfometrijskih karata hrapavosti terena.

Br.	Naziv podgrupe morfometrijskih karata	Broj morfometrijskih karata
1	karta hrapavosti terena	6
2	karte relativnog topografskog položaja	6
3	karte standardne devijacije nadmorske visine terena	6
4	karte indeksa hrapavosti terena	6
5	karta omjera 3D i 2D površine terena	1
UKUPNO:		25

Karte hrapavosti terena izvedene su iz LiDAR DMT-a rezolucije 1 m pomoću alata *Roughness* u *Geomorphometry and Gradient Metrics Toolbox-u* (Evans et al., 2014). Hrapavost terena (RGH) u alatu *Roughness* definirana je prema Riley et al. (1999) kao korijen između sume kvadrata razlike središnje ćelije prozora te u slučaju prozora veličine 3x3 ćelije, 8 susjednih ćelija :

$$RGH = ((Z5 - Z1)^2 + (Z5 - Z2)^2 + (Z5 - Z3)^2 + (Z5 - Z4)^2 + (Z5 - Z6)^2 + (Z5 - Z7)^2 + (Z5 - Z8)^2 + (Z5 - Z9)^2)^{\frac{1}{2}} \quad (25)$$

gdje je:

Z5 - središnja ćelija prozora veličine 3x3 ćelije,

Z1, Z2, Z3, Z4, Z6, Z7, Z8, Z9 - susjedne ćelije.

Alat omogućava izračun hrapavosti terena s obzirom na različite oblike i veličine prozora, te je ukupno izvedeno šest morfometrijskih karata hrapavosti terena s kružnim i kvadratnim oblikom prozora i veličinom prozora od 3x3, 5x5 i 9x9 ćelija (slika 5.21 i tablica 5.25).

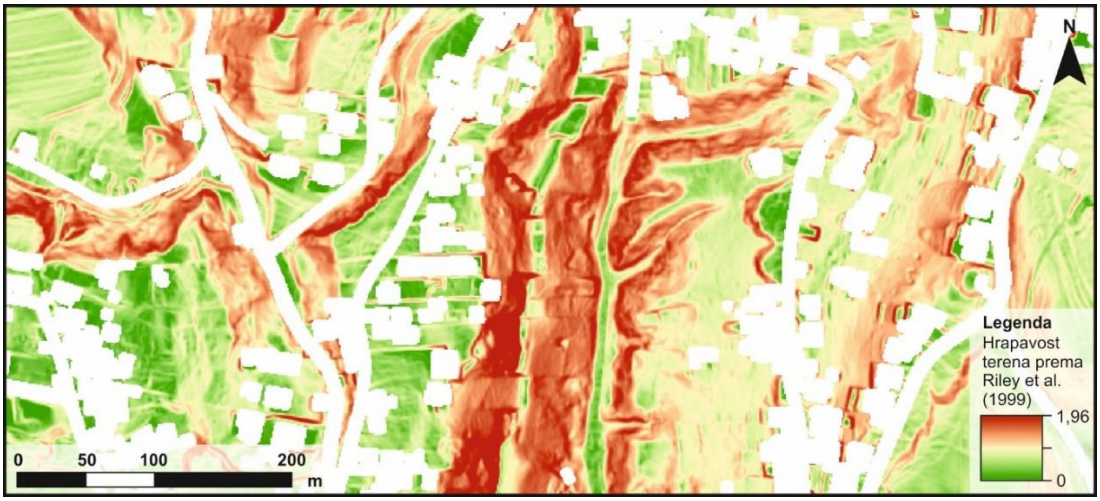

Slika 5.21 Morfometrijska karta hrapavosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba prema Riley et al. (1999) dobivena kvadratnim prozorom dimenzija 3x3 m.

Tablica 5.25 Vrste i broj izvedenih morfometrijskih karata hrapavosti terena prema Riley et al. (1999).

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1 m	Roughness GGM Toolbox	oblik prozora = kvadrat; veličina prozora = 3x3	rgh_fr3	karta hrapavosti terena dobivena kvadratnim prozorom dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	rgh_fr5	karta hrapavosti terena dobivena kvadratnim prozorom dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	rgh_fr9	karta hrapavosti terena dobivena kvadratnim prozorom dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	rgh_fc3	karta hrapavosti terena dobivena kružnim prozorom radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	rgh_fc5	karta hrapavosti terena dobivena kružnim prozorom radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	rgh_fc9	karta hrapavosti terena dobivena kružnim prozorom radijusa 9 m

Indeks relativnog topografskog položaja (engl. *relative topographic position*, RTP) opisuje stupanj hrapavosti terena, a definirao ga je Jenness (2002) slijedećim izrazom:

$$RTP = \frac{meanDMT - minDMT}{maxDMT - minDMT} \tag{26}$$

gdje je:

meanDMT - srednja vrijednost nadmorske visine u kvadratu ili krugu dimenzija 3, 5 ili 9 m,

minDMT - minimalna vrijednost nadmorske visine u kvadratu ili krugu dimenzija 3, 5 ili 9 m,

maxDMT - maksimalna vrijednost nadmorske visine u kvadratu ili krugu dimenzija 3, 5 ili 9 m.

S obzirom na različite oblike i veličine prozora, ukupno je izvedeno šest morfometrijskih karata relativnog topografskog položaja (slika 5.22) kružnim i kvadratnim oblikom i veličinom prozora 3x3, 5x5 i 9x9 ćelija (tablica 5.26).

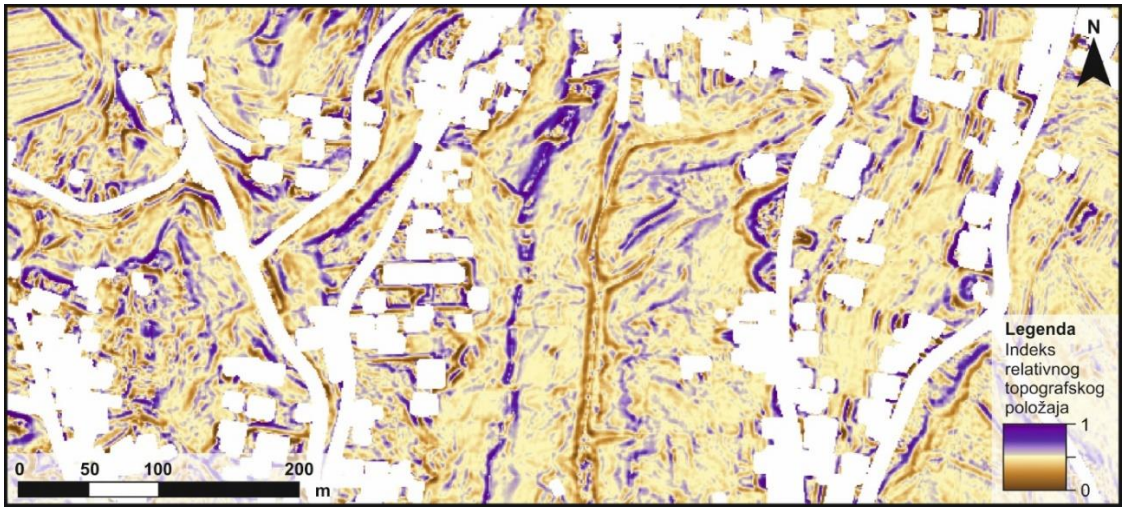

Slika 5.22 Morfometrijska karta relativnog topografskog položaja terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba dobivena kvadratnim prozorom dimenzija 5x5 m.

Tablica 5.26 Vrste i broj izvedenih morfometrijskih karata relativnog topografskog položaja.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT	Raster calculator	(“mean_DMT_fr3” – “min_DMT_fr3”) / (“max_DMT_fr3” – “min_DMT_fr3”)	rtp_fr3	karta relativnog topografskog položaja dobivena kvadratnim prozorom dimenzija 3x3 m
LiDAR DMT	Raster calculator	(“mean_DMT_fr5” – “min_DMT_fr5”) / (“max_DMT_fr5” – “min_DMT_fr5”)	rtp_fr5	karta relativnog topografskog položaja dobivena kvadratnim prozorom dimenzija 5x5 m
LiDAR DMT	Raster calculator	(“mean_DMT_fr9” – “min_DMT_fr9”) / (“max_DMT_fr9” – “min_DMT_fr9”)	rtp_fr9	karta relativnog topografskog položaja dobivena kvadratnim prozorom dimenzija 9x9 m
LiDAR DMT	Raster calculator	(“mean_DMT_fr3” – “min_DMT_fr3”) / (“max_DMT_fr3” – “min_DMT_fr3”)	rtp_fc3	karta relativnog topografskog položaja dobivena kružnim prozorom radijusa 3 m
LiDAR DMT	Raster calculator	(“mean_DMT_fr5” – “min_DMT_fr5”) / (“max_DMT_fr5” – “min_DMT_fr5”)	rtp_fc5	karta relativnog topografskog položaja dobivena kružnim prozorom radijusa 5 m
LiDAR DMT	Raster calculator	(“mean_DMT_fr9” – “min_DMT_fr9”) / (“max_DMT_fr9” – “min_DMT_fr9”)	rtp_fc9	karta relativnog topografskog položaja dobivena kružnim prozorom radijusa 9 m

Jedna od metoda određivanja hrapavosti terena je prema Ascione et al. (2008), a definirana je slijedećim izrazom:

$$rgh_a = \frac{meanDMT - DMT}{rngDMT} \tag{27}$$

gdje je:

meanDMT - srednja vrijednost nadmorske visine u kvadratu ili krugu dimenzija 3, 5 ili 9 m,

DMT - vrijednost nadmorske visine u središnjoj ćeliji kvadranta ili kruga dimenzija 3,5 ili 9 m,

rngDMT - raspon vrijednosti nadmorske visine u kvadrantu ili krugu dimenzija 3, 5 ili 9 m.

S obzirom na različite oblike i veličine prozora izvedeno je ukupno šest morfometrijskih karata hrapavosti (slika 5.23 i tablica 5.27).

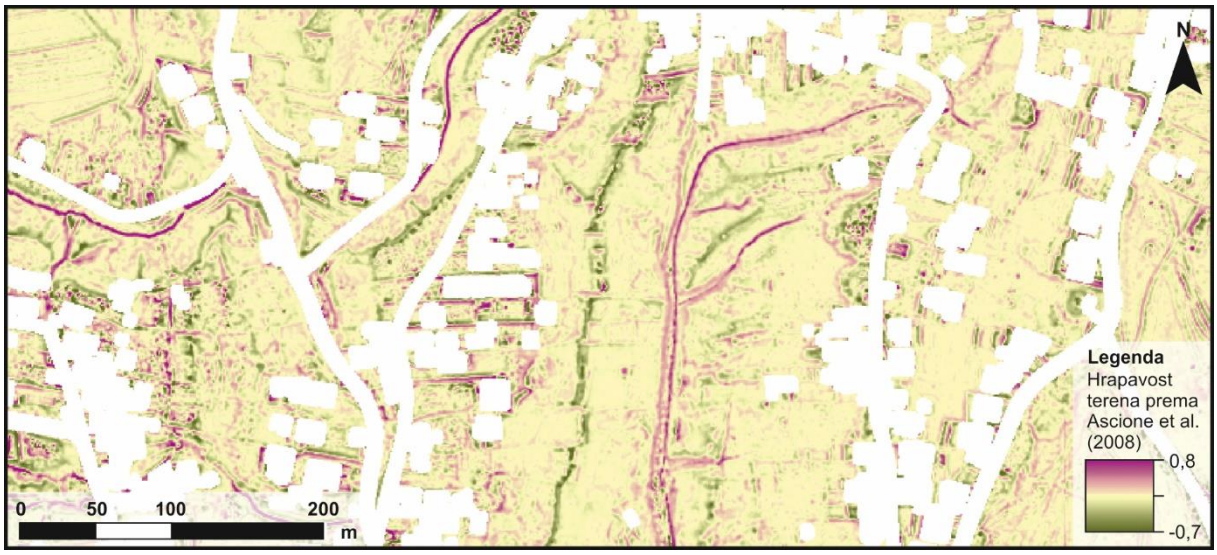

Slika 5.23 Morfometrijska karta hrapavosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba na temelju standardne devijacije nadmorske visine dobivena kružnim prozorom radijusa 3 m.

Tablica 5.27 Vrste i broj izvedenih morfometrijskih karata hrapavosti terena prema Ascione et al. (2008).

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT	Raster calculator	(“mean_DMT_fr3” – “DMT”) / (“rng_DMT_fr3”)	rgh_a_fr3	karta hrapavosti terena prema Ascione et al. (2008) dobivena primjenom pravokutnog prozora dimenzija 3x3 m
		(“mean_DMT_fr5” – “DMT”) / (“rng_DMT_fr5”)	rgh_a_fr5	karta hrapavosti terena prema Ascione et al. (2008) dobivena primjenom pravokutnog prozora dimenzija 5x5 m
		(“mean_DMT_fr9” – “DMT”) / (“rng_DMT_fr9”)	rgh_a_fr9	karta hrapavosti terena prema Ascione et al. (2008) dobivena primjenom pravokutnog prozora dimenzija 9x9 m
		(“mean_DMT_fc3” – “ DMT”) / (“rng_DMT_fc3”)	rgh_a_fc3	karta hrapavosti terena prema Ascione et al. (2008) dobivena primjenom kružnog prozora radijusa 3 m
		(“mean_DMT_fc5” – “DMT”) / (“rng_DMT_fc5”)	rgh_a_fc5	karta hrapavosti terena prema Ascione et al. (2008) dobivena primjenom kružnog prozora radijusa 5 m
		(“mean_DMT_fc9” – “DMT”) / (“rng_DMT_fc9”)	rgh_a_fc9	karta hrapavosti terena prema Ascione et al. (2008) dobivena primjenom kružnog prozora radijusa 9 m

Indeks hrapavosti terena (engl. *terrain ruggedness index*, *TRI*) je metoda za određivanje hrapavosti terena prema Nellemann i Fry (1995), a definirana je slijedećim izrazom:

$$TRI = \sqrt{maxDMT^2 - minDMT^2} \tag{28}$$

pri čemu je *maxDMT* maksimalna vrijednost nadmorske visine u kvadrantu ili krugu dimenzija 3, 5 ili 9 m, a *minDMT* je minimalna vrijednost nadmorske visine u kvadrantu ili krugu dimenzija 3, 5 ili 9 m. S obzirom na različite oblike i veličine prozora, ukupno je izvedeno 6 morfometrijskih karata indeksa hrapavosti terena (slika 5.24) kružnog i kvadratnog oblika i veličine prozora 3x3, 5x5 i 9x9 ćelija (tablica 5.28).

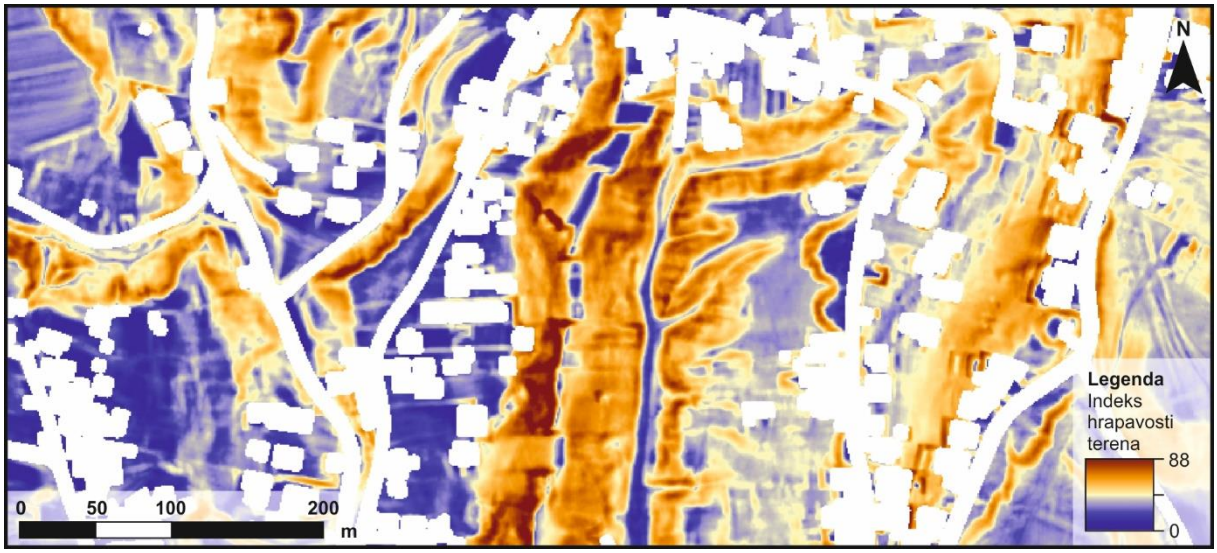

Slika 5.24 Morfometrijska karta hrapavosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba izvedena prema Nellemann i Fry (1995) dobivena kvadratnim prozorom dimenzija 3x3 m.

Tablica 5.28 Vrste i broj izvedenih morfometrijskih karata indeksa hrapavosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT	Raster calculator	SquareRoot(Abs(Square("max_DMT_fr3") - Square("min_DMT_fr3")))	tri_fr3	karta indeksa hrapavosti dobivena kvadratnim prozorom dimenzija 3x3 m
		SquareRoot(Abs(Square("max_DMT_fr5") - Square("min_DMT_fr5")))	tri_fr5	karta indeksa hrapavosti dobivena kvadratnim prozorom dimenzija 5x5 m
		SquareRoot(Abs(Square("max_DMT_fr9") - Square("min_DMT_fr9")))	tri_fr9	karta indeksa hrapavosti dobivena kvadratnim prozorom dimenzija 9x9 m
		SquareRoot(Abs(Square("max_DMT_fc3") - Square("min_DMT_fc3")))	tri_fc3	karta indeksa hrapavosti dobivena kružnim prozorom radijusa 3 m

Nastavak **tablice 5.28**

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT	Raster calculator	SquareRoot(Abs(Square("max_DMT_fc5") - Square("min_DMT_fc5")))	tri_fc5	karta indeksa hrapavosti dobivena kružnim prozorom radijusa 5 m
		SquareRoot(Abs(Square("max_DMT_fc9") - Square("min_DMT_fc9")))	tri_fc9	karta indeksa hrapavosti dobivena kružnim prozorom radijusa 9 m

Karta omjera 3D i 2D površine terena (engl. *Surface/Area Ratio*, *SAR*) je još jedna od metoda za određivanje hrapavosti terena, a definirao ju je Berry (2002) slijedećim izrazom:

$$SAR = \frac{c^2}{\cos\left(slp\left(\frac{\pi}{180}\right)\right)} \tag{29}$$

pri čemu je c veličina ćelije, a slp nagiba terena u stupnjevima izvedena iz LIDAR DMT-a rezolucije 1 m. S obzirom na različite oblike i veličine prozora, ukupno je izvedeno 6 morfometrijskih karata indeksa hrapavosti terena (slika 5.25) kružnog i kvadratnog oblika i veličine prozora 3x3, 5x5 i 9x9 ćelija (tablica 5.29).

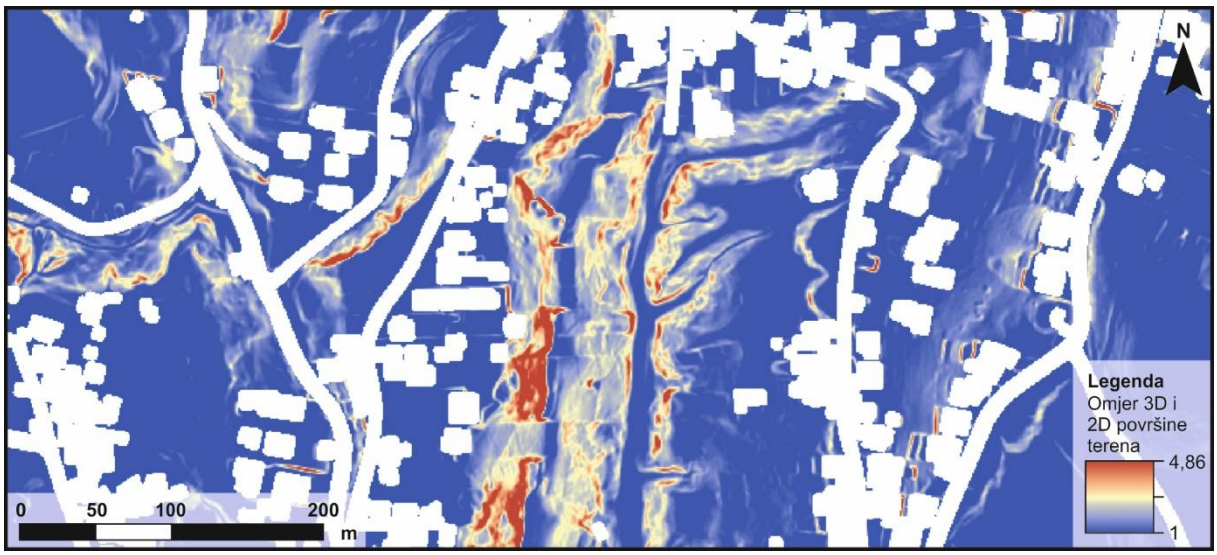

Slika 5.25 Morfometrijska karta omjera 3D i 2D površine terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba.

Tablica 5.29 Vrste i broj izvedenih morfometrijskih karata omjera 3D i 2D površine terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
karta nagiba terena	Raster calculator	1/Cos("slp")	sar	karta hrapavosti na temelju omjera 3D i 2D površine terena

5.4.7 Karte vlažnosti terena

Grupu morfometrijskih karata vlažnosti čine dvije karte, a to su karta vlažnosti terena (engl. *topographic wetness index* ili *compound topographic index*) i karta osunčanosti terena (engl. *heat light index*) (tablica 5.30).

Tablica 5.30 Vrste i broj izvedenih morfometrijskih karata vlažnosti terena.

Br.	Naziv podgrupe morfometrijskih karata	Broj morfometrijskih karata
1	karta vlažnosti terena	1
2	karte osunčanosti terena	1
UKUPNO:		2

Karta vlažnosti terena (slika 5.26a i tablica 5.31) izvedena je na temelju indeksa vlažnosti kojeg su definirali Moore et al. (1993), a predstavlja omjer uzvodnog otjecajnog područja drenažne mreže i nagiba terena:

$$\mathrm{CTI} = \frac{ln\ AS}{\tan(SLP)} \tag{30}$$

$$AS = (AT + 1) * A \tag{31}$$

gdje je:

AS - umnožak vrijednosti akumulacije toka i površine utjecajnog područja,

AT - akumulacija toka,

A - površine utjecajnog područja,

SLP - vrijednost nagiba terena u radijanima.

Karta osunčanosti terena (slika 5.26b i tablica 5.31) izvedena je na temelju indeksa osunčanosti kojeg su definirali McCune i Keon (2002) slijedećim izrazom:

$$\begin{aligned}\mathrm{HLI} = {} & -1{,}467 + 1{,}582\cos LAT * \cos SLP - \cos fASP * \sin SLP * \sin LAT \\ & - 0{,}262\sin LAT * \sin LP + 0{,}607\sin fASP * \sin SLP\end{aligned} \tag{32}$$

gdje je

LAT - geografska širina u radijanima,

SLP nagib terena u radijanima,

fASP, odnosno ASP - orijentacija padine u radijanima izvedena na temelju izraza |180-ASP-225| oko SI-JZ pružanja.

Indeks osunčanosti prema McCune i Keon (2002) temelji se na pretpostavci da je na padinama orijentiranim prema jugozapadu viša temperatura nego na padinama orijentiranim prema jugoistoku, iako je količina radijacije koju primaju jednaka. Iz navedenog razloga su orijentacije padina usmjerene s obzirom na SI-JZ pružanje kako bi padine nagnute prema jugozapadu imale više vrijednosti od padina nagnutih prema sjeveroistoku.

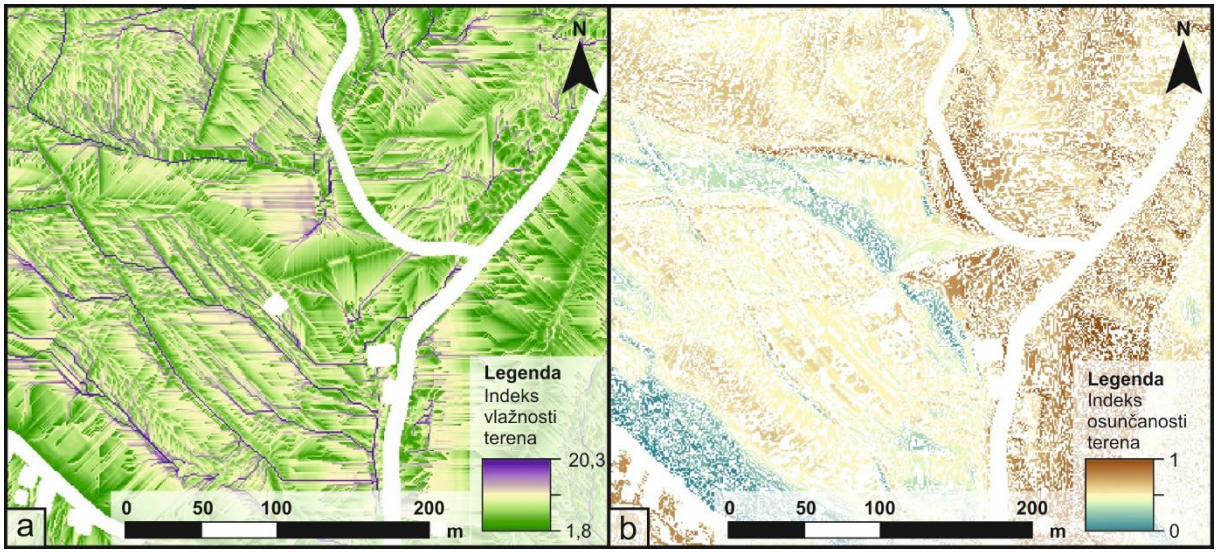

Slika 5.26 Grupa morfometrijskih karata vlažnosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba: (a) karta vlažnosti izvedena na temelju indeksa vlažnosti terena; (b) karta osunčanosti terena.

Tablica 5.31 Vrste i broj izvedenih morfometrijskih karata vlažnosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT	Compound Topographic Indeks GGM Toolbox	-	cti	karta vlažnosti terena
	Heat Light Indeks GGM Toolbox	-	hli	karta osunčanosti terena

5.4.8 Karta raščlanjenosti terena

Grupa karata raščlanjenosti terena (engl. *dissection maps*) izvedene su iz LiDAR DMT-a pomoću *ArcGIS Toolbox-a* pod nazivom *Geomorphometry and Gradient Metrics* (Evans et al., 2014) i alata *Dissection*. Alat izračunava stupanj raščlanjenosti terena (DISS) prema Martonne-ovom modificiranom indeksu raščlanjenosti (Evans et al., 1972):

$$DISS = \frac{DTM - minDTM}{maxDTM - minDTM} \quad (33)$$

gdje je:

DMT - vrijednost promatrane (središnje) ćelije nadmorske visine u kvadrantu ili krugu dimenzija 3, 5 ili 9 m,

minDMT - minimalna vrijednost nadmorske visine u kvadrantu ili krugu dimenzija 3, 5 ili 9 m,

maxDMT - maksimalna vrijednost nadmorske visine u kvadrantu ili krugu dimenzija 3, 5 ili 9 m.

S obzirom na različite oblike i veličine prozora, ukupno je izvedeno 6 morfometrijskih karata raščlanjenosti terena (slika 5.27) kružnog i kvadratnog oblika i veličine prozora 3x3, 5x5 i 9x9 ćelija (tablica 5.32).

Karta raščlanjenosti terena (Evans et al., 1972) najčešće se primjenjuje u regionalnim geomorfološkim analizama, odnosno prilikom analiziranja DMT-a rezolucije veće od 20 m. Raščlanjenost terena izvedena prema Martonne-ovom modificiranom indeksu raščlanjenosti (Evans et al., 1972) vrlo je slična kartama hrapavosti terena izvedenim prema Jenness (2002) i Ascione et al. (2008). S obzirom da se u geomorfologiji karte raščlanjenosti smatraju posebnom vrstom izvedenih morfometrijskih karata, grupa karata raščlanjenosti terena opisana je zasebno, a ne u okviru grupe morfometrijskih karata hrapavosti terena.

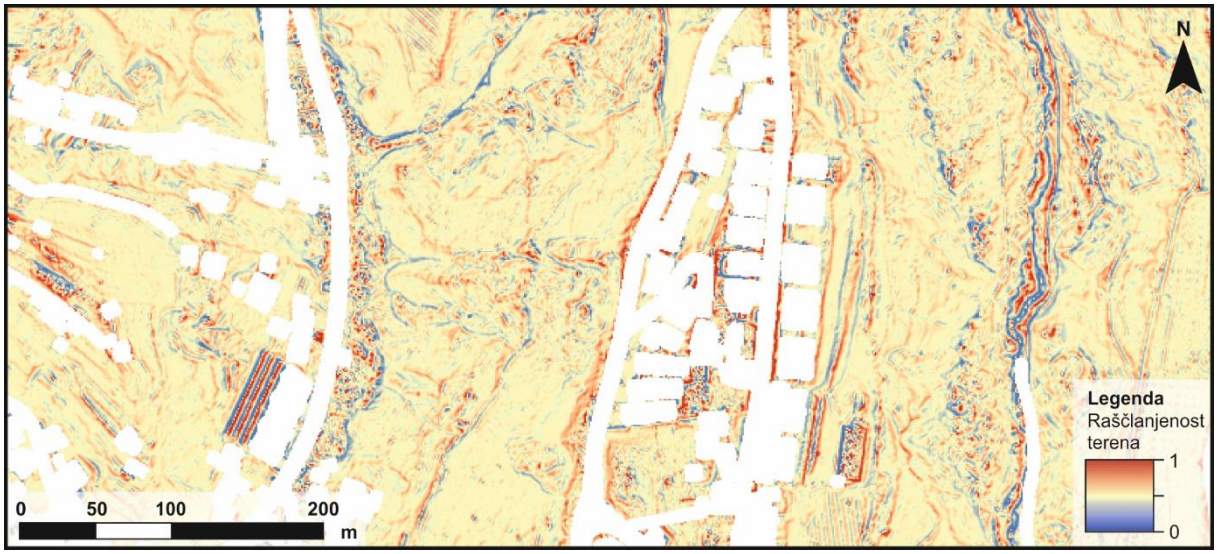

Slika 5.27 Morfometrijska karta raščlanjenosti terena dijela pilot područja u podsljemenskoj zoni Grada Zagreba izvedena prema (Evans et al., 1972) dobivena kvadratnim prozorom dimenzija 3x3 m.

Tablica 5.32 Vrste i broj izvedenih morfometrijskih karata raščlanjenosti terena.

Ulazna karta	GIS alat	Postavke	Oznaka izvedene karte	Opis
LiDAR DMT 1m	Dissection	oblik prozora = kvadrat; veličina prozora = 3x3	diss_fr3	karta raščlanjenosti terena dobivena kvadratnim prozorom dimenzija 3x3 m
		oblik prozora = kvadrat; veličina prozora = 5x5	diss_fr5	karta raščlanjenosti terena dobivena kvadratnim prozorom dimenzija 5x5 m
		oblik prozora = kvadrat; veličina prozora = 9x9	diss_fr9	karta raščlanjenosti terena dobivena kvadratnim prozorom dimenzija 9x9 m
		oblik prozora = krug; veličina prozora = 3	diss_fc3	karta raščlanjenosti terena dobivena kružnim prozorom radijusa 3 m
		oblik prozora = krug; veličina prozora = 5	diss_fc5	karta raščlanjenosti terena dobivena kružnim prozorom radijusa 5 m
		oblik prozora = krug; veličina prozora = 9	diss_fc9	karta raščlanjenosti terena dobivena kružnim prozorom radijusa 9 m

6 INVENTAR KLIZIŠTA DOBIVEN VIZUALNOM INTERPRETACIJOM LiDAR DMT-a

U ovom poglavlju prikazane su značajke inventara klizišta za pilot područje površine 21 km^2 dobivenog vizualnom interpretacijom morfometrijskih karata izvedenih iz DMT-a rezolucije 0,3 x 0,3 m. Inventar klizišta dobiven navedenim daljinskim istraživanjima provjeren je terenskom prospekcijom kartiranog područja. Inventar klizišta dobiven vizualnom interpretacijom LiDAR DMT-a uspoređen je s dostupnim povijesnim inventarima klizišta iz 1979. godine (Polak et al., 1979) i 2007. godine (Miklin et. al., 2007) kako bi se ocijenila potpunost povijesnih inventara klizišta na pilot području podsljemenske zone Grada Zagreba .

6.1 Značajke inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a

Vizualnom interpretacijom morfometrijskih karta izvedenih iz LiDAR DMT-a rezolucije 0,3 x 0,3 m izrađen je inventar klizišta za pilot područje podsljemenske zone Grada Zagreba (21 km^2). Za identifikaciju i kartiranje klizišta korištene su tri izvedene morfometrijske karte, karta osjenčanosti terena, karta nagiba terena i karta slojnica ekvidistancije 0,5 m (slika 6.1). Inventar klizišta se sastoji od ukupno 702 identificirana i iscrtana klizišta čiji je prostorni raspored na pilot području prikazan na slici 6.2.

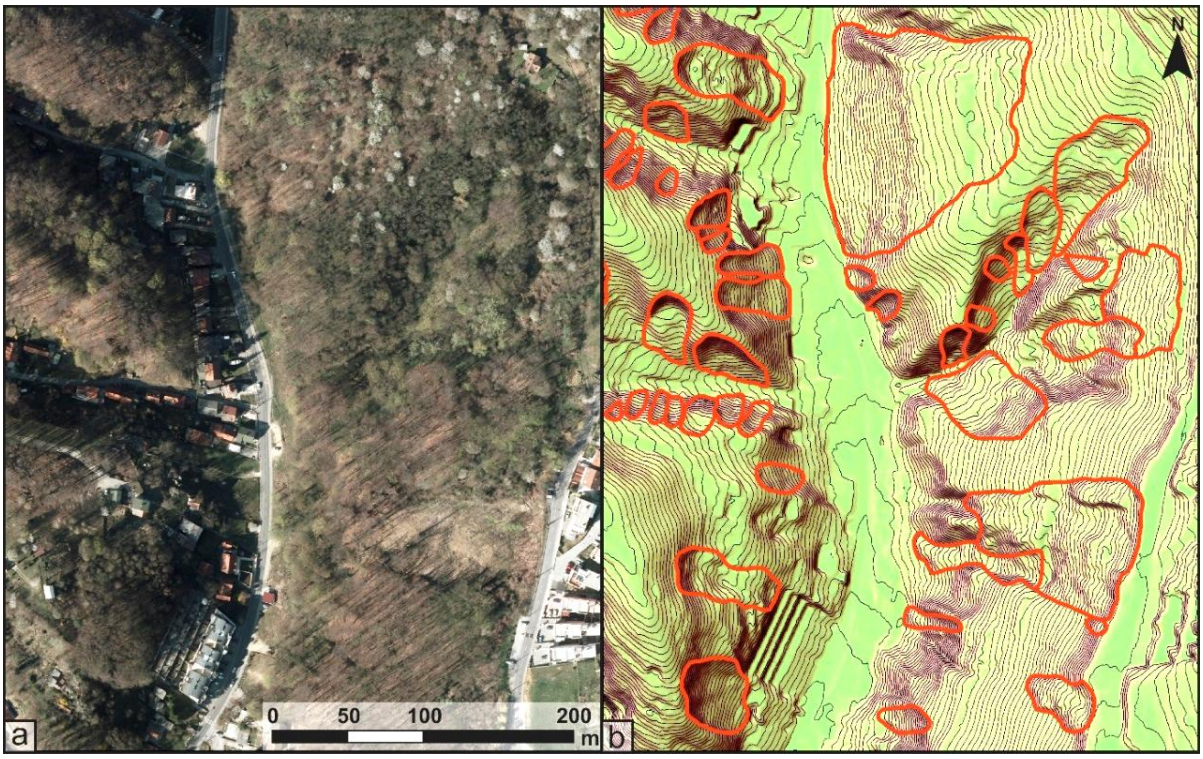

Slika 6.1 Usporedni prikaz dijela pilot područja na: (a) DOF-u i (b) na kombinaciji karata koja se sastoji od karte nagiba terena, karte osjenčanog terena i karte slojnica ekvidistancije 1 m na kojoj su prikazane interpretirane granice klizišta.

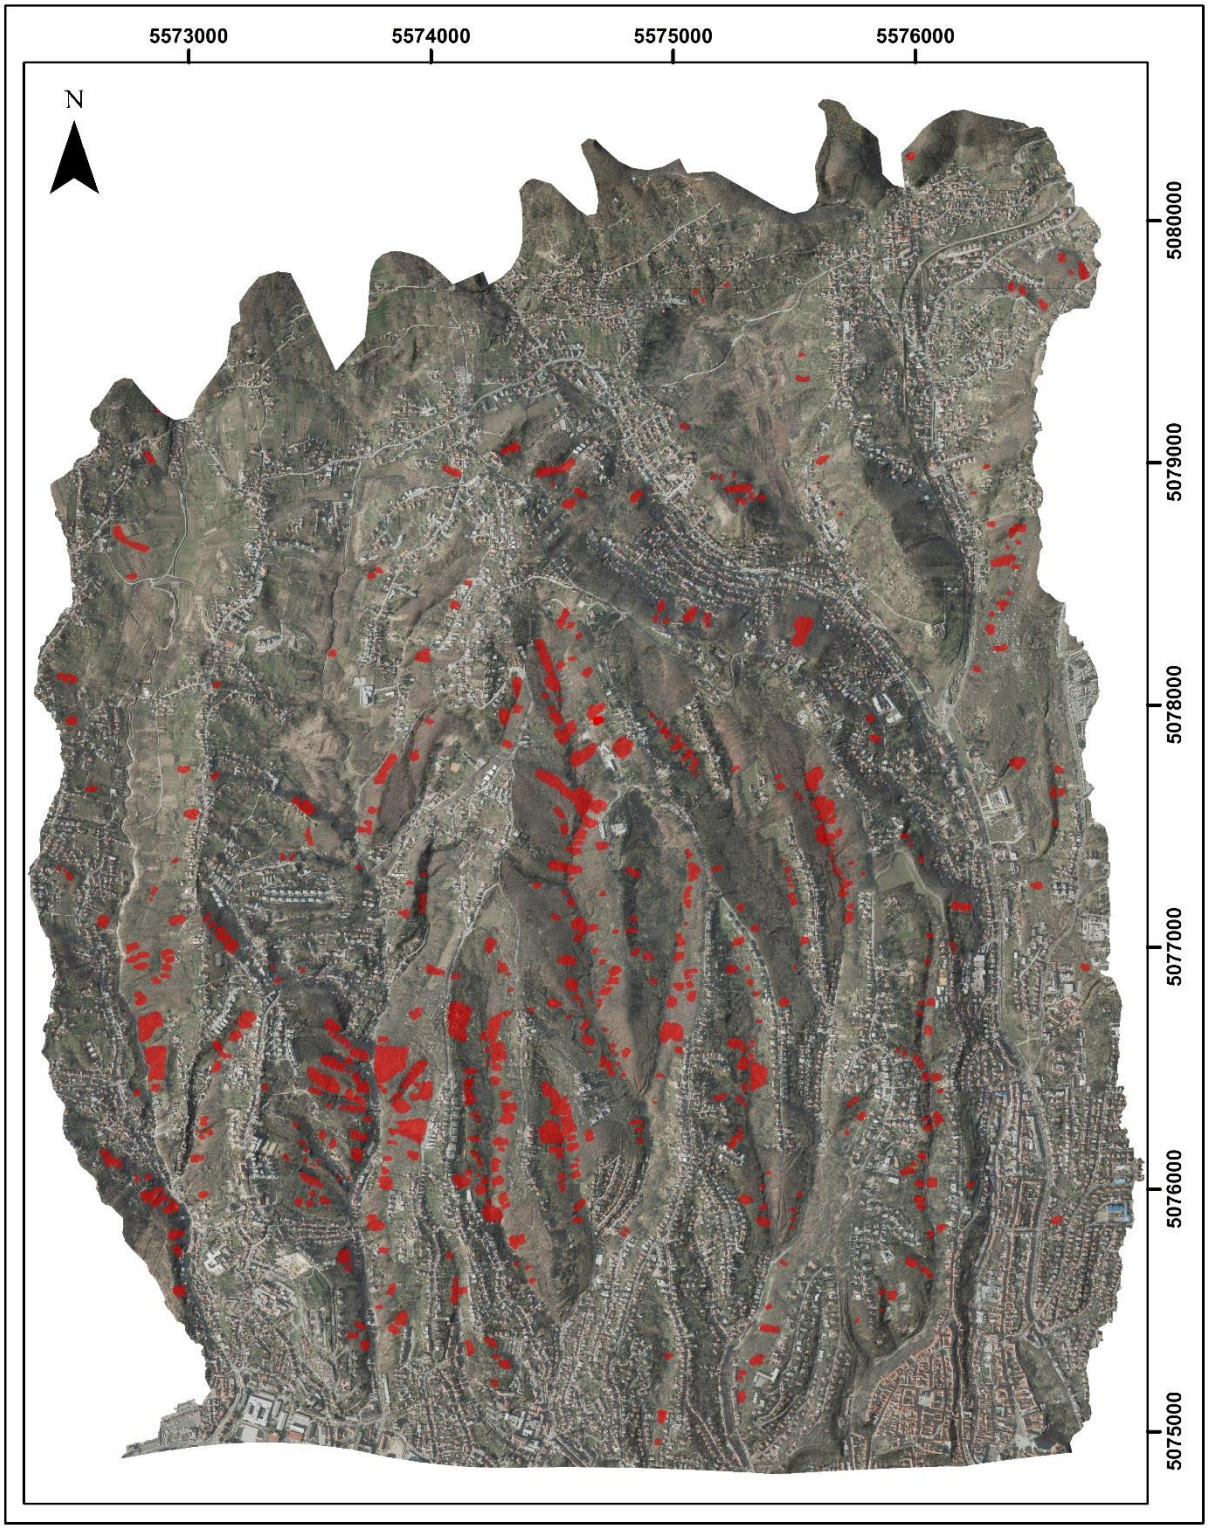

Slika 6.2 Inventar klizišta cijelog pilot područja (površine 21 km^2) izrađen vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT kojima je identificirano ukupno 702 klizišta. Karta inventara klizišta prikazana je na DOF-u iz 2012. godine originalnog mjerila 1:5.000.

S obzirom na izvor podataka i sadržaj koji prikazuje, inventar klizišta za 21 km^2 pilot područja predstavlja geomorfološki povijesni inventar klizišta prema klasifikaciji inventara klizišta Guzzetti et al. (2012). Budući da je kinematika klizanja glavni kriterij za klasifikaciju klizišta (Varnes, 1978; Cruden i Varnes, 1996; Hungr et al., 2014), vizualnom interpretacijom LiDAR DMT-a utvrđeno je da su prema mehanizmu gibanja sve identificirane i kartirane pojave nestabilnosti na padinama nastale isključivo procesom klizanja. Na temelju geološke građe iz koje proizlazi činjenica da je pilot područje dominantno izgrađeno od neogenskih naslaga, te na temelju geometrije klizišta (relativno male i plitke pojave), možemo zaključiti da su to dominantno klizanja tla, prema klasifikaciji klizišta razvijenoj od strane Cruden i Varnes (1996). S obzirom na stil aktivnosti klizanja (WP/WLI, 1993a), koji ukazuje na tip ili kombinaciju tipova gibanja prema njihovom mehanizmu, identificirana su sukcesivna i pojedinačna klizišta. Pri tome se pod sukcesivnim klizištima podrazumijevaju dva ili više susjednih klizišta, istog tipa gibanja, ali po odvojenim plohama sloma i sa zasebnim pokrenutim masama (slika 6.3a), a pod pojedinačnim klizištima, pojedinačna gibanja pokrenutog materijala niz padinu (slika 6.3b). Sukcesivna klizišta prisutna su na strmim (>15°) i relativno kratkim padinama koje predstavljaju bokove jaruga ili dolina. Na slici 6.3a prikazan je primjer sukcesivnih klizišta, te se može zaključiti kako se ovaj tip klizišta odvija na nestabilnim padinama, najčešće s velikom gustoćom klizišta.. Pod pojmom nestabilne padine podrazumijevaju se padine na kojima postoje jasne morfološke značajke koje ukazuju na prošle ili postojeće procese klizanja, ali nisu vidljive jasne granice pojava klizišta, odnosno nije moguće identificirati potpune i precizne granice klizišta u svim dijelovima takvih padina. Također, za opisane padine karakteristična je i pojava linijske i plošne erozije (slika 6.3a)

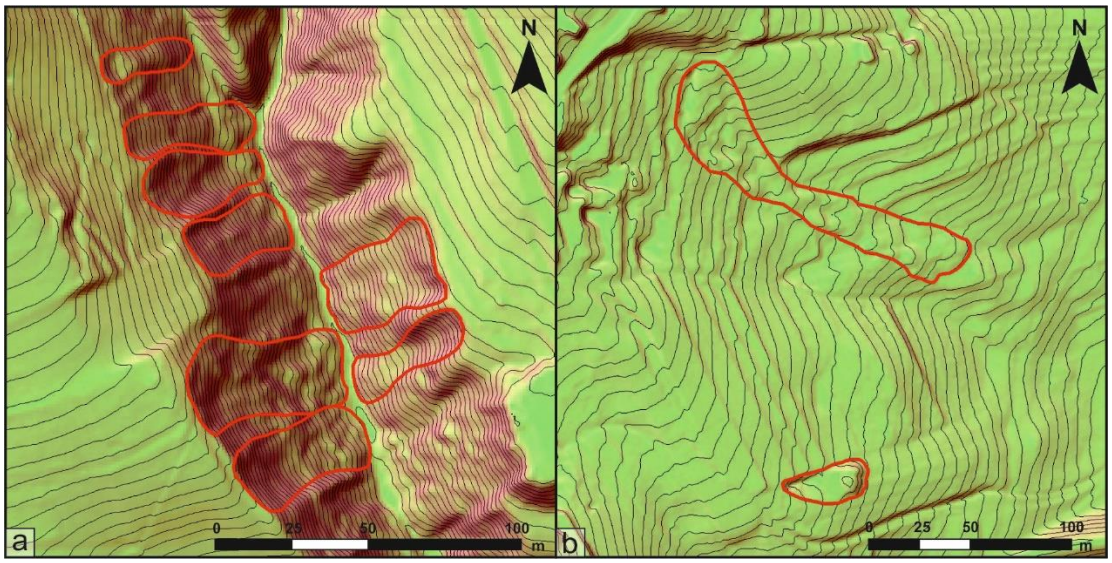

Slika 6.3 Primjer dva tipa stila aktivnosti klizanja na pilot području (21 km^2): (a) sukcesivna klizišta; (b) pojedinačna klizišta.

S obzirom na pouzdanost identifikacije, 455 klizišta (65 %) opisano je kao pouzdano identificirana klizišta, a 247 klizišta (35 %) opisana su kao nepouzdana, odnosno pretpostavljena klizišta. S obzirom na preciznost kartiranja, za 227 klizišta (32 %) procijenjeno je da je granica klizišta iscrtana s visokom preciznošću, za 255 klizišta (36 %) sa srednjom preciznošću, a za 220 klizišta (32 %) s niskom preciznošću. Na slika 6.4 prikazana je raspodjela učestalosti pouzdano i nepouzdano identificiranih klizišta, odnosno pretpostavljenih klizišta, s obzirom na preciznost iscrtane granice klizišta. Može se zaključiti da su pouzdano identificirana klizišta najčešće kartirana s visokom i srednjom preciznošću (68 % od ukupnog broja pouzdano identificiranih klizišta), dok su nepouzdano identificirana (pretpostavljena) klizišta najčešće kartirana niskom preciznošću (58 % od ukupnog broja nepouzdano identificiranih klizišta).

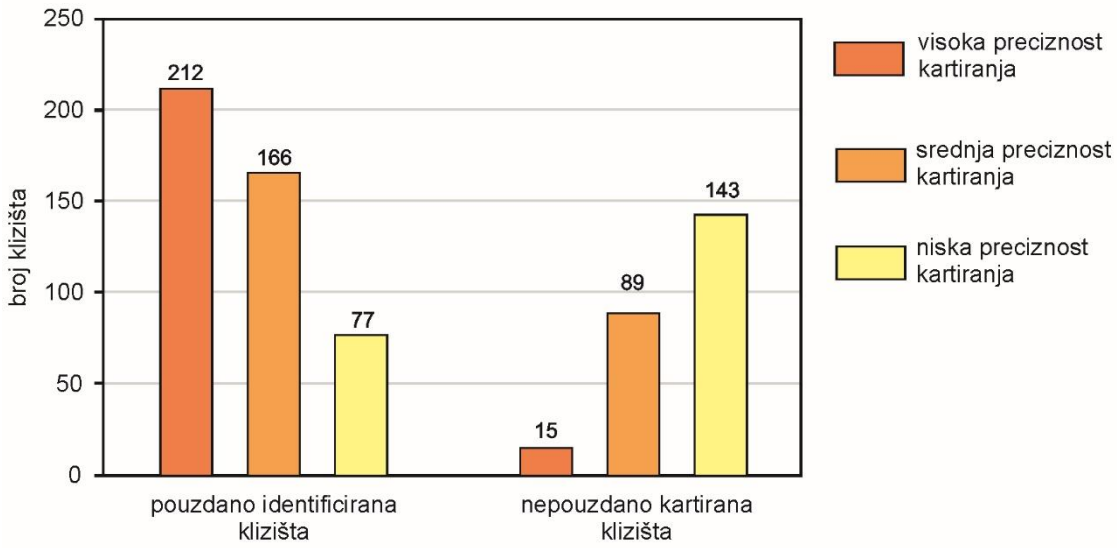

Slika 6.4 Prikaz pouzdano i nepouzdano identificiranih klizišta na pilot području s obzirom na preciznost kartiranja.

Ukupna površina klizišta na pilot području iznosi 0,5 km^2 ili 2,43 % površine pilot područja, dok je srednja gustoća klizišta 33,3 klizišta/km^2. Veličina kartiranih klizišta je od 43 do 8.064 m^2 (sred. vrijed. = 730 m^2, medijan = 427 m^2, stan. dev. = 942 m^2). Najveći broj klizišta je veličine oko 400 m^2, dok je 90 % klizišta veličine između 100 i 2.000 m^2. Raspodjela učestalosti površina kartiranih klizišta (slika 6.5) može se opisati pomoću normalne raspodjele (Malamud et al., 2004). Prijelaz između rastućeg i padajućeg dijela krivulje raspodjele ukazuje na razliku između malih klizišta te srednjih i velikih klizišta. S obzirom na navedeno, na pilot području pozitivan dio krivulje definira mala klizišta, veličine od 43 do 398 m^2 koja od ukupnog broja klizišta u inventaru čine 46,2 %, dok negativan dio krivulje definira srednja i velika klizišta, veličine od 399 do 8.064 m^2, koja čine 53,8 % klizišta u inventaru.

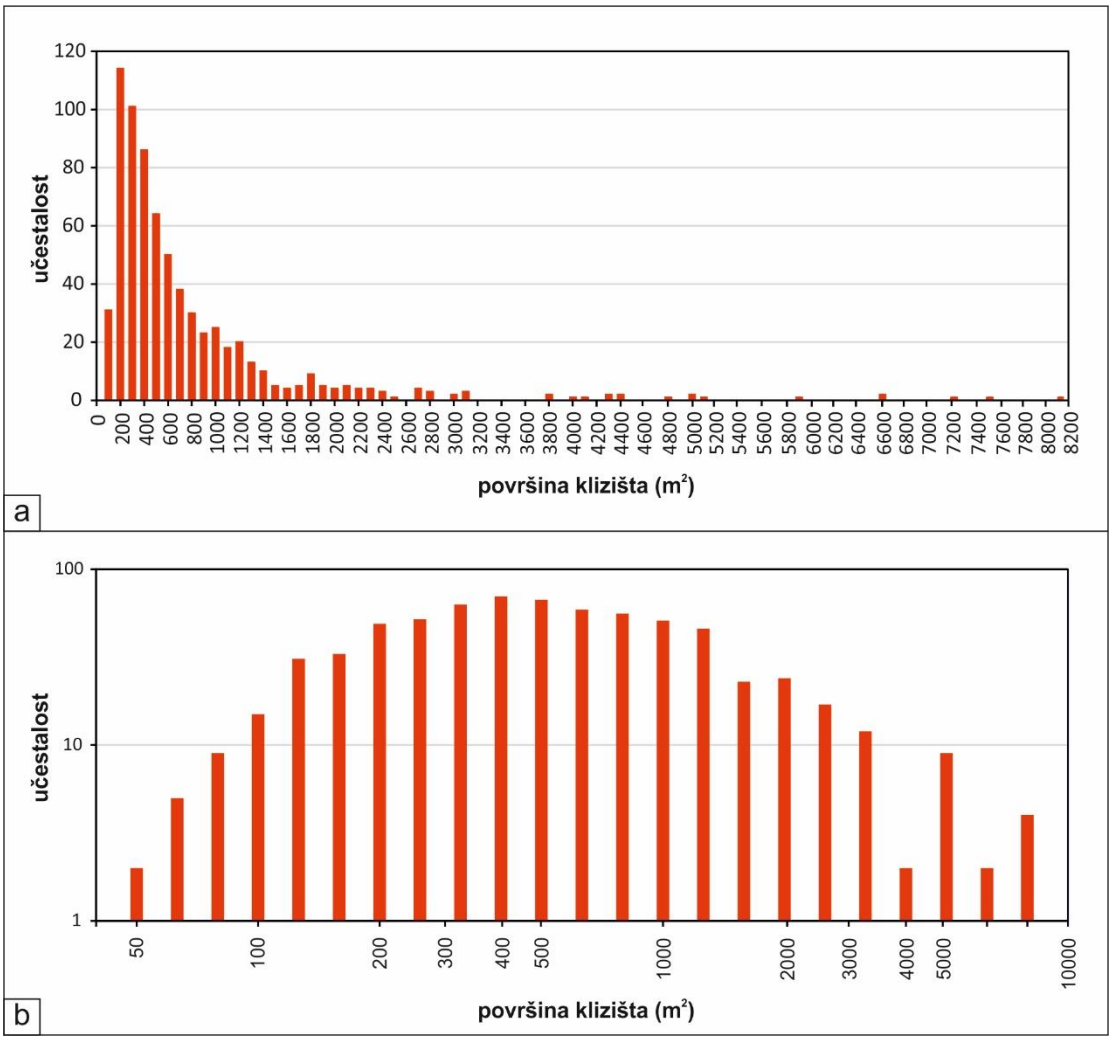

Slika 6.5 Histogram učestalosti površine 702 klizišta sadržana u inventaru klizišta pilot područja dobivenom vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a: (a) prikaz učestalosti veličine površine klizišta po razredima od 100 m^2; (b) prikaz učestalosti po razredima veličine površine klizišta u log-log mjerilu.

6.2 Terenska provjera inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a

Prospekcijsko geomorfološko kartiranje na pilot području (21 km^2) provedeno je u svrhu terenske verifikacije inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a. Preliminarna prospekcija klizišta aktiviranih tijekom zime 2012./2013. godine provedena je u svibnju i rujnu 2014. godine, a tijekom izrade inventara klizišta vizualnom interpretacijom DMT-a, terensko prospekcijsko kartiranje provođeno je prema potrebi zbog provjere rezultata daljinskih istraživanja. Posljednja terenska prospekcija klizišta provedena je tijekom prosinca 2018. i siječnja 2019. godine. Sustavno terensko kartiranje svih klizišta iz inventara nije bilo moguće provesti zbog relativno velike površine cijelog pilot područja, kao i zbog neprohodnosti dijela terena (zapuštena i obrasla zemljišta), odnosno nepristupačnih dijelova terena unutar ograđenih privatnih parcela. Iz navedenog razloga, terenska provjera klizišta provedena je na 10% klizišta u inventaru. Odabir ukupno 70 klizišta za terensku provjeru proveden je slučajnim odabirom u *ArcGIS-u 10.0*, a odabrana klizišta prikazana su na slici 6.6. Površina terenski provjerenih klizišta iznosi od 68 do 5.862 m^2. S obzirom na pouzdanost vizualne identifikacije na LiDAR DMT-u, 39 odabranih klizišta (55 %) klasificirano kao pouzdano identificirane pojave, a 31 odabrano klizište (45%) kao nepouzdano identificirane pojave.

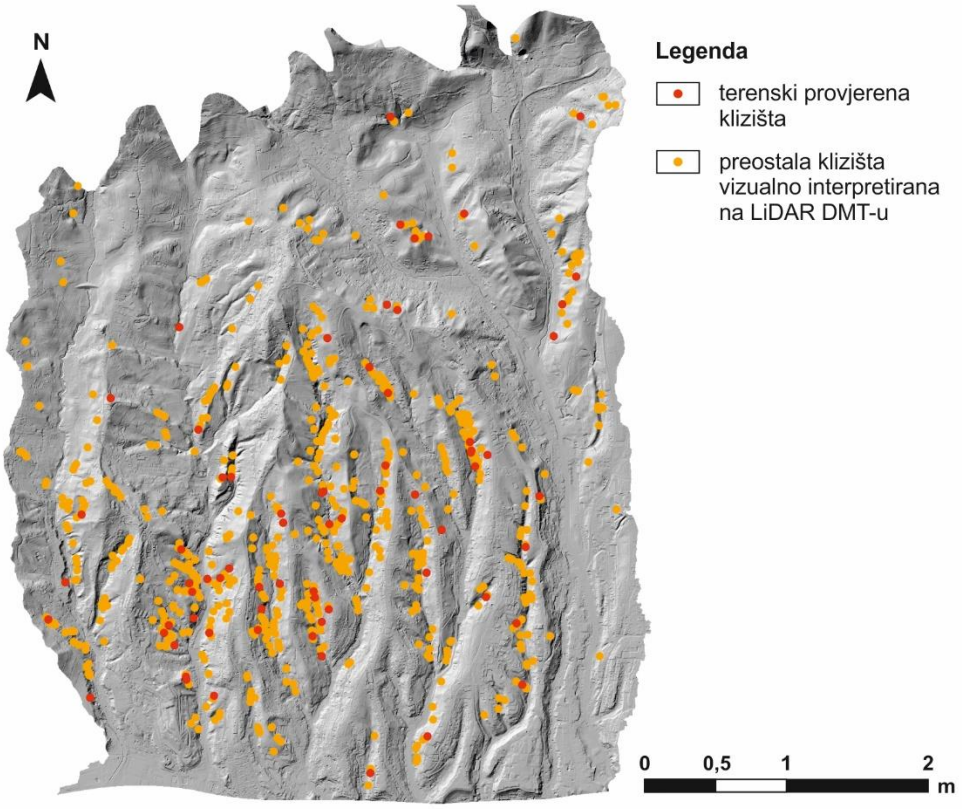

Slika 6.6 Prostorna raspodjela terenski provjerenih klizišta na pilot području (21 km^2).

Prilikom terenskog obilaska, klizišta su identificirana s obzirom na izraženost pojedinih dijelova klizišta, morfologije cijelog klizišta te poremećenosti vegetacijskog pokrova, no detaljno kartiranje granica klizišta nije provedeno u okviru ovog istraživanja. Terenski provjerena klizišta klasificirana su kao: (a) potvrđena klizišta, ako su prilikom terenske prospekcije identificirani pojedini dijelovi klizišta i/ili zona usijedanja i zona akumulacije materijala; (b) pretpostavljena klizišta, ako je prilikom terenske prospekcije utvrđena samo nepravilna morfologija terena i poremećena vegetacija na predmetnom ali nije bilo moguće identificirati dijelove klizišta; te (c) klizišta koja nije bilo moguće potvrditi zbog nepristupačnog terena ili terena obraslog niskom vegetacijom.

S obzirom na prethodno navedenu klasifikaciju terenski provjerenih klizišta, 15 klizišta (21 %) je terenski potvrđeno, 14 klizišta (20 %) je pretpostavljeno s obzirom na nepravilnu morfologiju terena, dok za 41 klizište (59%) nije bilo moguće utvrditi radi li se o terenu zahvaćenom klizanjem zbog nepristupačnosti. Naime, veliko ograničenje prilikom terenske prospekcije odabranih klizišta su bila neprohodna zemljišta obrasla početnim ili degradacijskim razvojnim stadijima šumskih sastojina (makija, garig, šikare, šibljaci i drugo). Također, ako se rezultati terenske provjere usporede s procjenom pouzdanosti vizualno identificiranih klizišta na LiDAR DMT-u, svih 15 klizišta koja su terenski potvrđena klizišta su daljinski pouzdano identificirana klizišta (slika 6.7), dok je 11 terenski pretpostavljenih klizišta daljinski pouzdano identificirano, a samo 3 klizišta su daljinski klasificirana kao nepouzdano identificirane pojave. Od 41 klizišta koje nije bilo moguće potvrditi na nepristupačnom terenu zbog guste makije i šikare, 13 klizišta je pouzdano identificirano na LiDAR DMT-u, a 28 klizišta opisano je kao nepouzdano daljinski vizualno identificirane pojave.

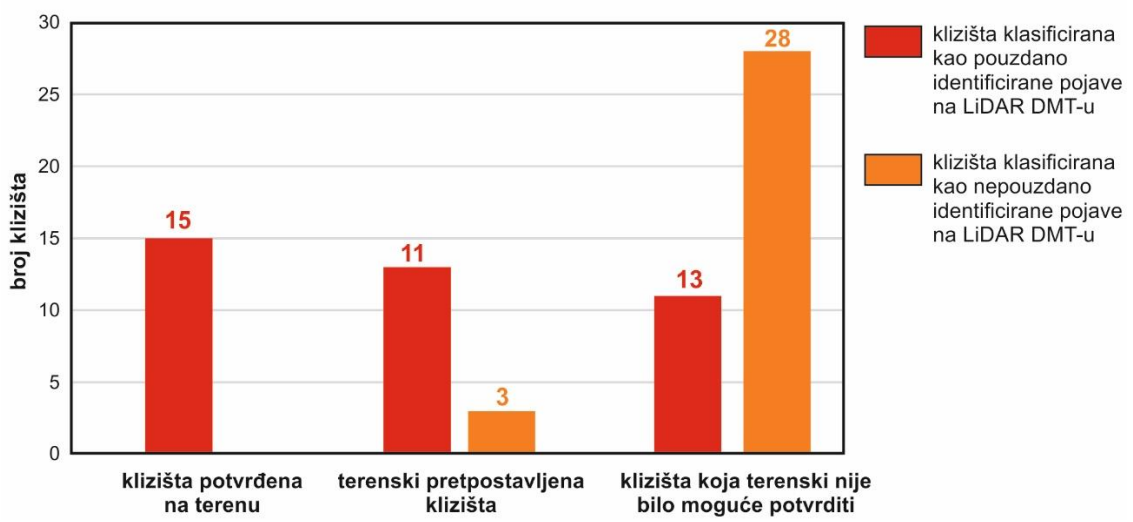

Slika 6.7 Klasifikacija terenski provjerenih klizišta s obzirom na pouzdanost vizualne identifikacije na LiDAR DMT-u.

Na slici 6.8 i 6.9. usporedno je prikazana vidljivost pojedinih klizišta na terenu i morfometrijskim karata izvedenim iz LiDAR DMT-a. Općenito se može zaključiti kako su klizišta koja su terenski potvrđena ili recentno aktivirana klizišta ili se radi o aktivnim klizištima koja imaju očuvano nepravilnu morfologiju karakterisitičnu za klizišta, jasno vidljive pojedine dijelove klizišta (najčešće glavnu pukotinu i čelo klizišta), te vegetaciju poremećenu uslijed procesa klizanja (slika 6.8).

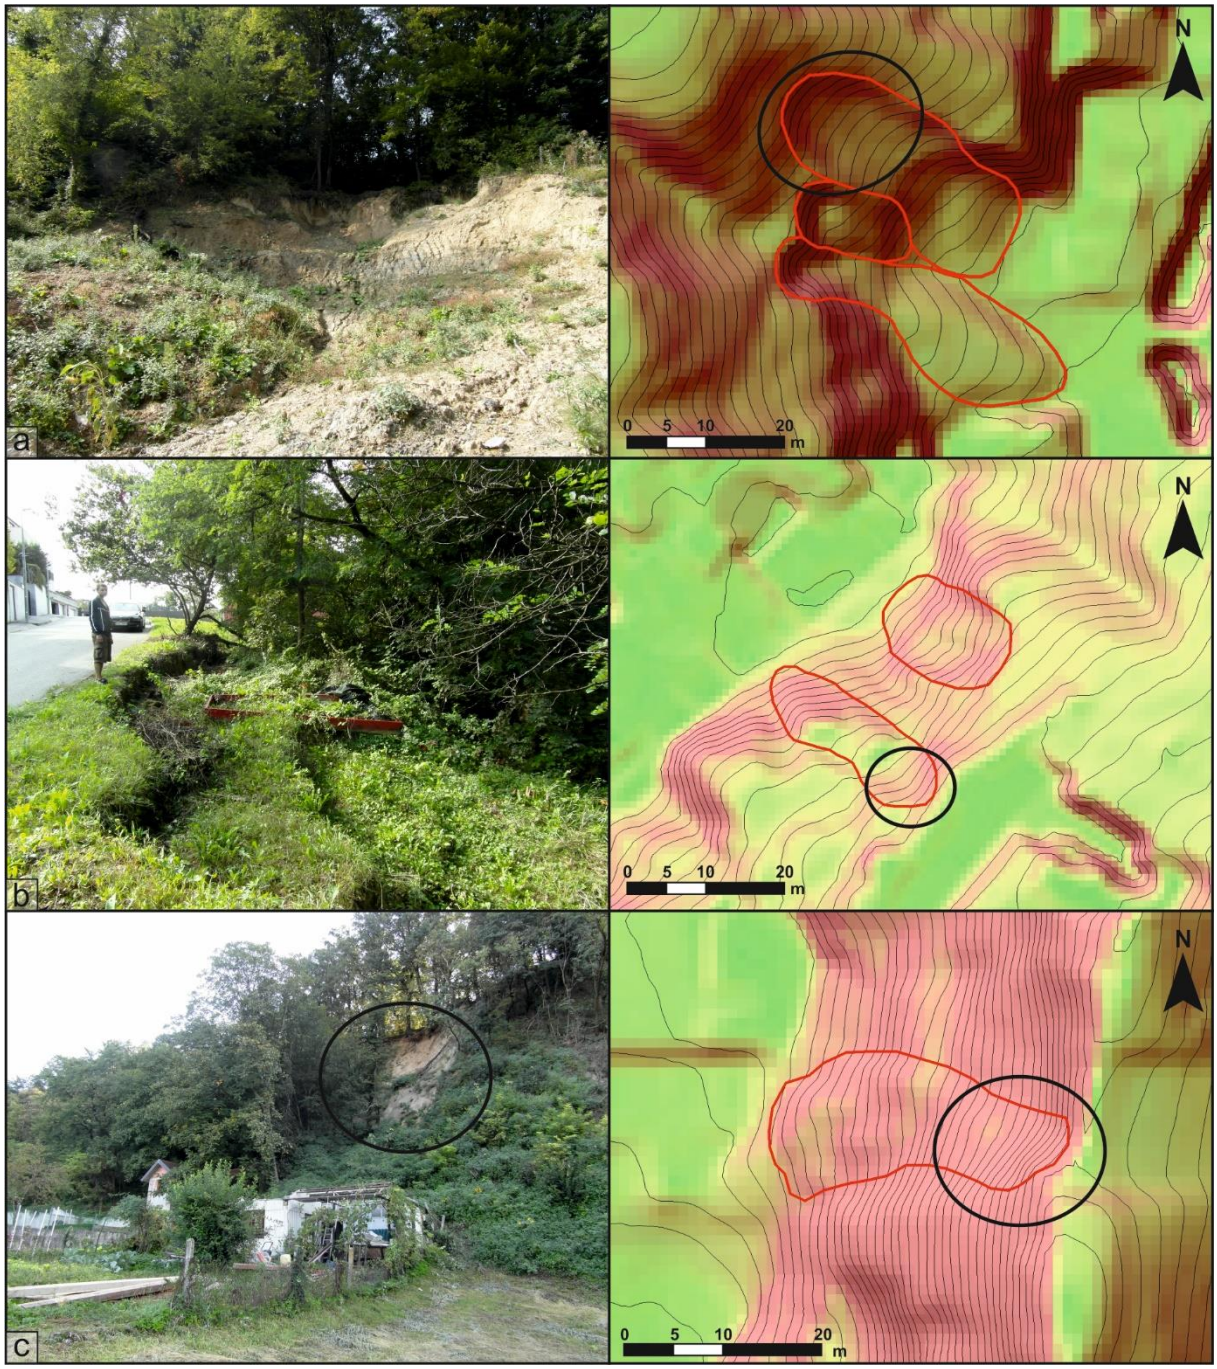

Slika 6.8 Usporedan prikaz vidljivosti pojedinih klizišta na terenu i na morfometrijskim kartama izvedenim iz LiDAR DMT-a: (a) klizište u Ulici Črnomerec iza kbr. 111 (svibanj 2014. godine); (b) klizište u Istarskoj ulici ispred kbr. 60 (rujan 2014. godine); (c) klizište u ulici Zamorski Breg iza kbr. 12c (svibanj 2014. godine).

U mnogim slučajevima klizište je potvrđeno na temelju općih značajki koje su karakteristične za pojave klizanja, kao što su nepravilna morfologija površine terena i "pijano" drveće (slika 6.9a,b), ali specifične dijelove, kao što su granice klizišta, nije bilo moguće točno utvrditi. Međutim, relativno starija klizišta ili površinom manja klizišta kod kojih se dijelovi klizišta relativno brzo unište procesima na padini, imaju još manje izraženu nepravilnu morfologiju te su najčešće obrasla niskom vegetacijom kao što su npr. makija i šikare. U ovim slučajevima terenskom prospekcijom nije bilo moguće potvrditi pojavu klizišta na padini (slika 6.9c).

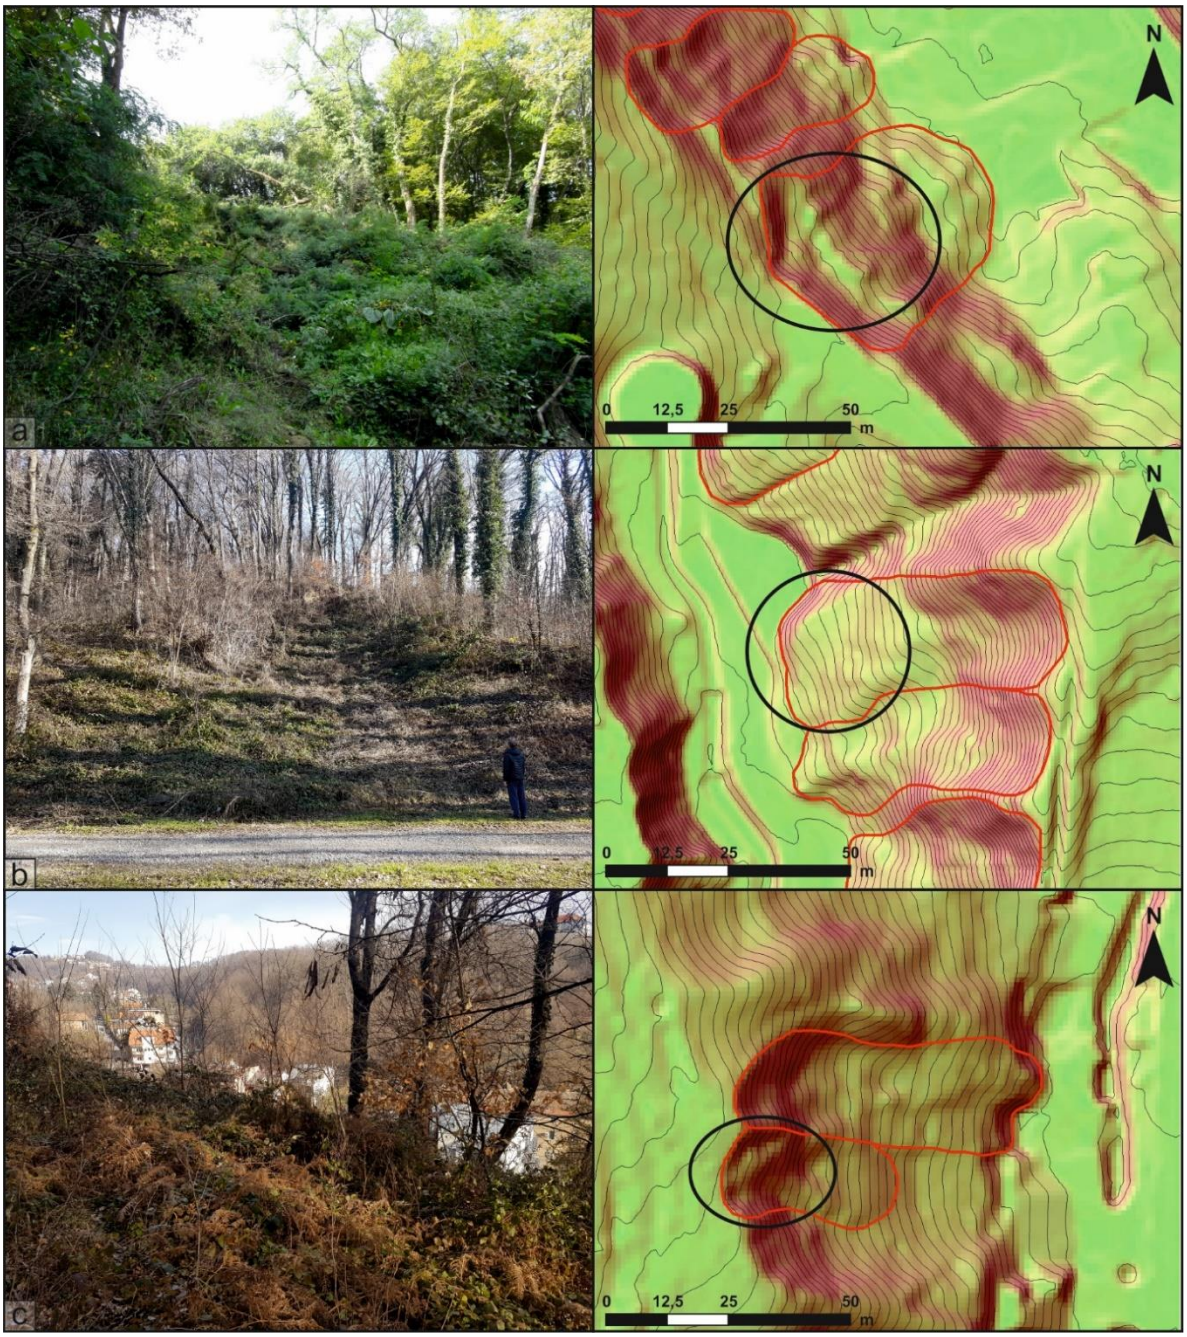

Slika 6.9 Usporedan prikaz vidljivosti pojedinih klizišta na terenu i na morfometrijskim karatama izvedenim iz LiDAR DMT-a: (a) klizište između ulica Trsje i Bijenik (svibanj 2014. god.); (b) klizište uz potok Črnomerec (siječanj 2018. god.); (c) klizište u Ulici Črnomerec kbr. 117 (siječanj 2018. god.).

6.3 Usporedba inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a s postojećim inventarima klizišta

Inventar klizišta dobiven vizualnom interpretacijom LiDAR DMT-a uspoređen je s dostupnim povijesnim inventarima klizišta na pilot području u Gradu Zagrebu, (Polak et al., 1979; Miklin et. al. 2007). Usporedba je obuhvaćala parametre inventara, geografsku točnost, kao i učestalosti klizišta na cijelom istraživanom području. Analiza parametara inventara provedena pomoću tri različite metode koje se temelje na statističkim značajkama inventara klizišta i prostornoj raspodjeli veličine klizišta (Malamud et al., 2004). Geografska točnost je analizirana usporedbom geografskih lokacija svih pojedinih kartiranih klizišta (Carrara et al., 1992), sadržanih u tri inventara koji se međusobno uspoređuju. Prostorna distribucija klizišta analizirana je usporedbom karata gustoća izrađenih na temelju karata inventara klizišta (Guzzetti et al., 2000).

6.3.1 Analiza statističkih parametara inventara i učestalosti klizišta

Inventar klizišta dobiven vizualnom interpretacijom LiDAR DMT-a visoke rezolucije iz 2013. godine uspoređen je s povijesnim inventarima klizišta iz 1979. godine (Polak et al., 1979) i 2007. godine (Miklin et. al. 2007). Inventari klizišta iz 1979. i 2007. godine izrađeni su detaljnim terenskim geomorfološkim kartiranjem te na temelju dostupnih izvještaja i geotehničkih elaborata. Usporedba triju povijesnih inventara klizišta prikazana je na slici 6.10, a statistički podaci za svaki pojedini inventar prikazani su u tablici 6.1. Na pilot području površine 21 km^2, inventari iz 1979. i 2007. godine sadrže oko 160 klizišta dok inventar dobiven vizualnom interpretacijom LiDAR DMT-a ima 702 klizišta, odnosno 4,5 puta više identificiranih i iscrtanih klizišta. Ukupna površina svih klizišta najmanja je kod inventara iz 2013. godine (0,5 km^2 ili 2,43 % pilot područja), a dok je kod inventara iz 1979. godine nešto veća i iznosi (0,61 km^2 ili 2,88 % pilot područja). Najveću ukupnu površinu kartiranih klizišta (3,73 km^2 ili 17,69 % pilot područja) ima inventar iz 2007. godine, a ona je gotovo sedam puta veća od ukupne površine klizišta u inventarima iz 1979. i 2013. godine (tablica 6.1). S obzirom na broj klizišta (ili gustoća klizišta), može se zaključiti da inventar dobiven na temelju LiDAR DMT-a ima 340 % veći broj klizišta po kilometru kvadratnom od broja klizišta iz povijesnih inventara, ali istovremeno i 86 % manju ukupnu površinu klizišta od inventara iz 2007. godine. Najveće kartirano klizište u inventaru iz 2007. godine ima površinu od 317.262 m^2, što je gotovo sedam puta veće od najvećeg klizišta kartiranog u inventaru iz 1979. godine (43.228 m^2), i gotovo 40 puta veće od najvećeg klizišta u inventaru iz 2013. godine (8.064 m^2).

Najmanje kartirano klizište u inventaru iz 2013. godine dimenzija je oko 6x7 m, odnosno površine 43 m^2, što je deset puta manje od najmanjeg klizišta u inventaru iz 1979. godine (467 m^2) i šest puta manje od najmanjeg klizišta u inventaru iz 2007. godine (282 m^2).

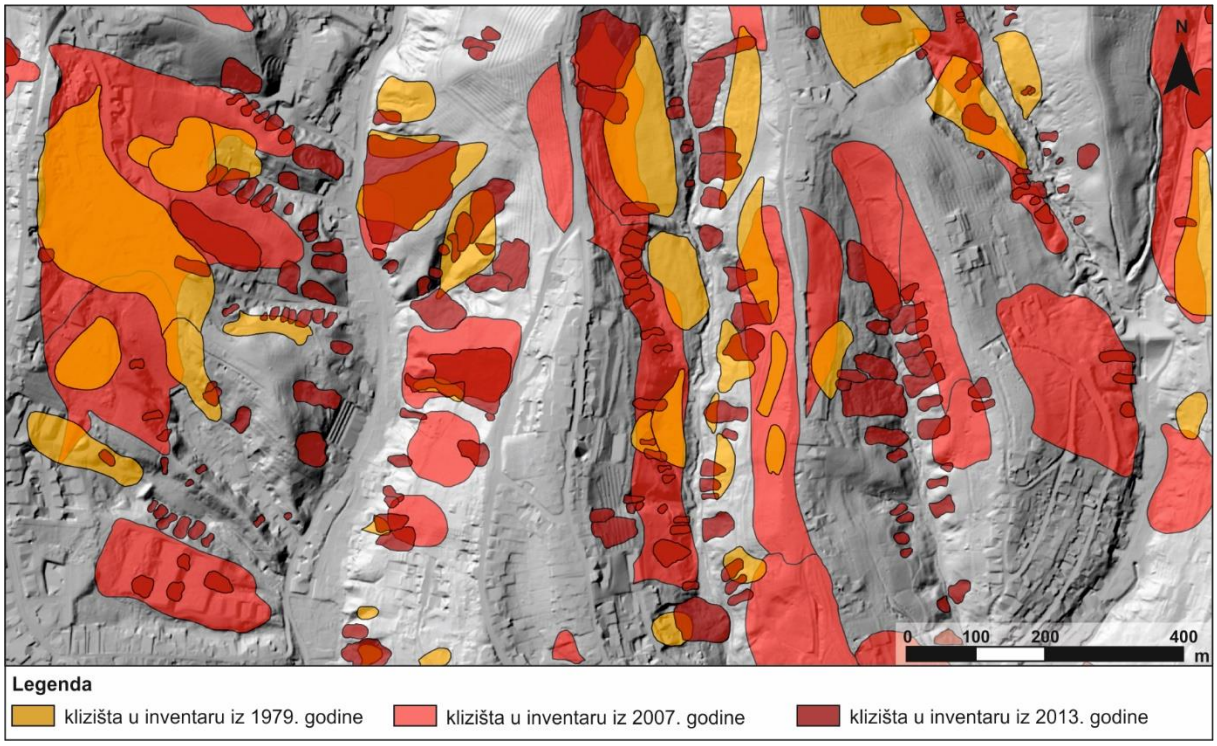

Slika 6.10 Usporedba granica klizišta iz povijesnih inventara klizišta (Polak et al., 1979; Miklin et al., 2007) s granicama klizišta iz inventara dobivenog interpretacijom LiDAR DMT-a. Granice klizišta prikazane su na karti osjenčanosti terena, rezolucije 0,3x0,3 m.

Tablica 6.1 Usporedba statističkih značajki inventara klizišta iz 2013. godine s dostupnim povijesnim inventarima klizišta iz 1979. i 2007. godine.

Inventar	Inventar klizišta iz 1979. godine(Polak et al., 1979)	Inventar klizišta iz 2007. godine (Miklin et al., 2007)	Inventar klizišta iz 2013. godine
broj klizišta	166	159	702
najmanje kartirano klizište (m^2)	467	282	43
srednja veličina klizišta (m^2)	3.666	23.471	730
medijan (m^2)	2.407	11.981	427
standardna devijacija (m^2)	4.446	35.906	942
najveće kartirano klizište (m^2)	43.228	317.262	8.064
površina svih klizišta (km^2)	0,61	3,73	0,51
udio površine klizišta na pilot području (%)	2,88	17,69	2,43
gustoća klizišta (br. klizišta/km^2)	7,9	7,5	33,3

Raspodjela učestalosti površina klizišta na kartama inventara klizišta iz 1979., 2007. i 2013. godine na pilot području prikazana je na slici 6.11. Kao što je već prethodno opisano, inventar klizišta dobiven interpretacijom LiDAR DMT-a ima normalnu distribuciju površina klizišta (slika 6.11c), od 43 m^2 do 8.064 m^2 i može se klasificirati kao detaljan i potpun inventar klizišta prema kriterijima definiranim u Malamud et al. (2004). Inventari iz 1979. i 2007. godine nemaju normalnu distribuciju površina klizišta na pilot području (slika 6.11a,b) i zbog toga se smatraju nepotpunim inventarima klizišta. Glavni razlog nepotpunosti analiziranih povijesnih inventara klizišta je izostanak malih klizišta, odnosno to što prilikom terenskog geomorfološkog kartiranja klizišta 1979. i 2007. godine nisu identificirana i kartirana klizišta manja od 450 m^2, odnosno od 280 km^2. Osim nedostatka kartiranja malih klizišta, u inventaru iz 2007. godine se pojavljuju i površinom vrlo velika klizišta (28 pojava s površinom većom od 30.000 m^2) koja prilikom vizualne interpretacije LiDAR DMT-a nisu identificirana kao klizišta. Sve pojave klizišta na DIGK iz 2007. godine zapravo predstavljaju zone koje su naknadno i nazvane nestabilne padine (Geoportal, 2019).

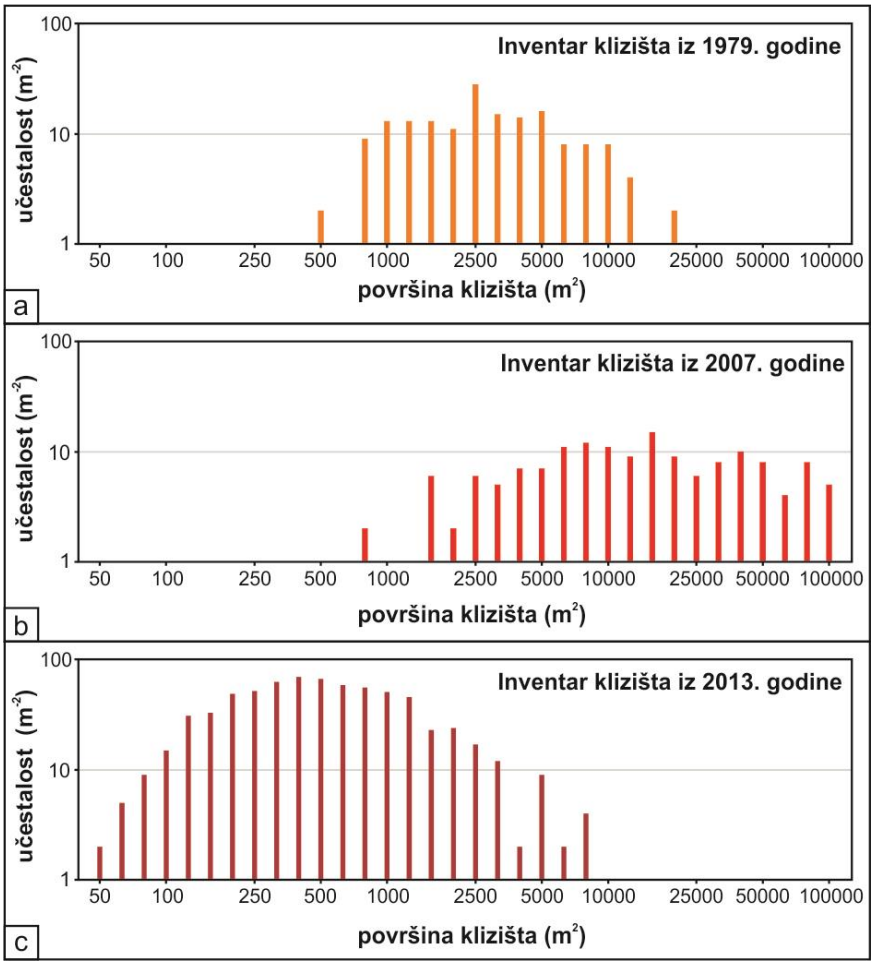

Slika 6.11 Histogrami učestalosti površina klizišta za tri karte inventara na pilot području (21 km^2): (a) inventar klizišta iz 1979. godine (Polak et al., 1979); (b) inventar klizišta iz 2007. godine (Miklin et al.,2007); (c) inventar klizišta dobiven vizualnom interpretacijom LiDAR DMT-a iz 2013. godine.

Prema Galli et al. (2008) najzastupljenija površina klizišta se smanjuje kako se povećava potpunost inventara klizišta. Prema raspodjeli površina klizišta u tri predmetna inventara, inventar klizišta dobiven vizualnom interpretacijom LiDAR DMT-a ima najmanju površinu najzastupljenijeg klizišta (400 m^2). Dostupni povijesni inventari imaju nekoliko puta veću najzastupljeniju površinu klizišta, odnosno u inventaru iz 1979. najzastupljenija su klizišta s površinom od 2.400 m^2, dok su inventaru iz 2007. godine najzastupljenija klizišta površine 12.000 m^2.

6.3.2 Analiza geografskog položaja klizišta

Stupanj prostorne (kartografske) podudarnosti dostupnih povijesnih inventara klizišta iz 1979. i 2007. godine s inventarom klizišta dobivenog interpretacijom LiDAR DMT-a iz 2013. godine izračunat je prema metodi koju je predložio Carrara et al. (1992). Sva tri predmetna inventara klizišta su međusobno preklopljena, kako bi se iz unije i presjeka dvaju inventara odredio indeks podudarnosti, M i indeks nepodudarnosti, odnosno indeks pogreške, E. Rezultati analize kartografske podudarnosti prikazani su u tablici 6.2. Indeks pogreške u sva tri slučaja je vrlo visok (94-96 %), odnosno stupanj podudarnosti je vrlo nizak (6-4 %). Površina zajednička inventarima iz 1979. i 2007. godine, odnosno presjek dvaju inventara je 1%, presjek površina klizišta inventara iz 2007. i 2013. godine je samo 0,22 %, a inventari iz 1979. i 2013. godine podudaraju se samo u 0,9 % ukupne površine klizišta.

Tablica 6.2 Analiza kartografske podudarnosti inventara klizišta iz 1979., 2007. i 2013. godine na pilot području površine 21 km^2.

Usporedba inventara klizišta	Širina zone oko klizišta (m)					
	0 m	1 m	2 m	5 m	10 m	20 m
površina klizišta u inventaru iz 1979. godine (%)	2,8	3,0	3,2	3,8	4,9	7,2
površina klizišta u inventaru iz 2007. godine (%)	17,7	18,1	18,6	20,1	22,5	27,4
inventar iz 1979. ∪ inventar iz 2007. (%)	19,4	20,0	20,6	22,3	25,3	31,1
inventar iz 1979. ∩ inventar iz 2007. (%)	1,1	1,2	1,3	1,6	2,1	3,5
indeks pogreške, E	0,94	0,94	0,94	0,93	0,92	0,89
indeks podudarnosti, M	0,06	0,06	0,06	0,07	0,08	0,11
površina klizišta u inventaru iz 1979. godine (%)	2,8	3,0	3,2	3,8	4,9	7,2
površina klizišta u inventaru iz 2013. godine (%)	2,5	2,9	3,2	4,2	6,0	9,9
inventar iz 1979. ∪ inventar iz 2013. (%)	5,2	5,6	6,1	7,6	10,2	15,5
inventar iz 1979. ∩ inventar iz 2013. (%)	0,2	0,3	0,3	0,4	0,7	1,6
indeks pogreške, E	0,96	0,95	0,95	0,94	0,93	0,90
indeks podudarnosti, M	0,04	0,05	0,05	0,06	0,07	0,10
površina klizišta u inventaru iz 2007. godine (%)	17,7	18,1	18,6	20,1	22,5	27,4
površina klizišta u inventaru iz 2013. godine (%)	2,5	2,9	3,2	4,2	6,0	9,9
inventar iz 2007. ∪ inventar iz 2013. (%)	19,4	20,0	20,7	22,7	26,0	32,5
inventar iz 2007. ∩ inventar iz 2013. (%)	0,9	1,0	1,1	1,6	2,5	4,8
indeks pogreške, E	0,96	0,95	0,95	0,93	0,90	0,85
indeks podudarnosti, M	0,04	0,05	0,05	0,07	0,10	0,15

Inventari klizišta iz 1979. i 2007. godine izrađeni su terenskim geomorfološkim kartiranjem u mjerilu 1:10.000 i 1:5.000. Utjecaj metode kartiranja klizišta na indeks podudarnosti, odnosno utjecaj pogrešaka nastalih uslijed terenskog geomorfološkog kartiranje granica ili pogrešaka zbog neprecizno interpretiranih granica prilikom vizualnog kartiranja klizišta na LiDAR DMT-u na indeks podudarnosti, određen je analizom koncentrično uvećanih klizišta. U ovim analizama kartografske podudarnosti koncentrično su povećane površine klizišta za 1 m, 2 m, 5 m, 10 m i 20 m oko granica klizišta u svim trima inventarima. Naime, prilikom terenskog kartiranja klizišta mogle su nastati pogreške zbog netočno lociranih klizišta na topografskim podlogama. odnosno zbog Nemogućnost korištenja GPS-a u 70-tim godina 20. stoljeća ili nevidljivost granice klizišta na terenu zbog guste vegetacije te pogreške prilikom digitalizacije granica klizišta s terenskih karata, mogući su razlozi za neprecizno lociranje. Rezultati analize utjecaja metode kartiranja na stupanj kartografskog preklapanja svih triju predmetnih inventara klizišta prikazani su u tablici 6.2 i na slici 6.12 te se može zaključiti kako se u sva tri slučaja povećanjem površine klizišta u inventarima, smanjuje indeks pogreške, odnosno povećava indeks podudarnosti. Indeks podudarnosti iznosi 4-15 %. Indeks pogreške u rasponu 85-96 % se može pripisati različitim geomorfološkim interpretacijama prilikom terenskog kartiranja (inventar iz 1979. naspram inventara iz 2007. godine) te različitim metodama kartiranja (inventari iz 1979. i 2007. naspram inventara iz 2013. godine).

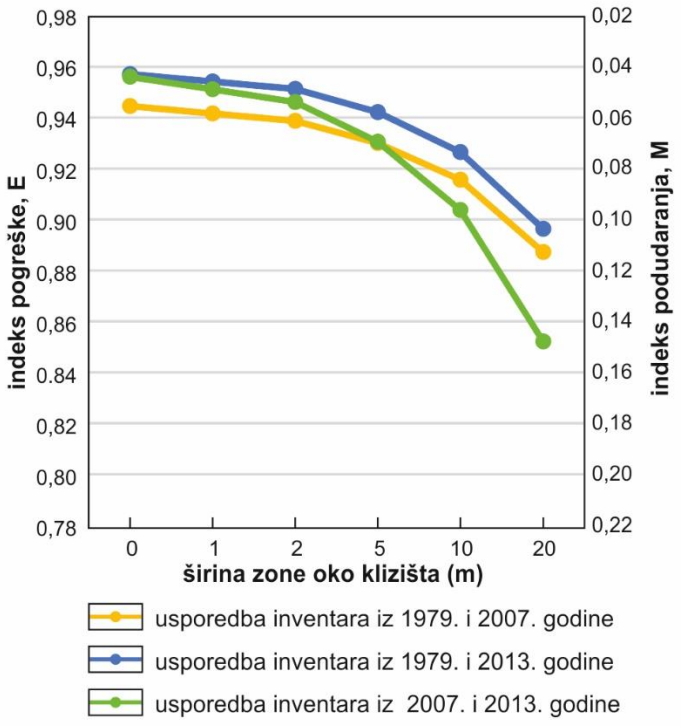

Slika 6.12 Usporedba indeksa pogreške, E i indeksa podudarnosti, M za zone širine 1, 2, 5, 10 i 20 m oko klizišta u inventarima iz 1979., 2007. i 2013. godine na pilot području površine 21 km^2.

6.3.3 Analiza gustoće klizišta

Za potrebe usporedbe prostorne distribucije klizišta na cijelom području inventara, pilot područje (21 km^2) podijeljeno je na 70 prostornih jedinica s obzirom na orijentaciju padina, prema metodi koju su razvili Carrara et al. (1991). Medijan površine kartiranih prostornih jedinica iznosi 18 ha (min.=1 ha, maks.=194 ha, sred. vrijed.=30 ha, std. dev.=35 ha). Za svaki od tri inventara klizišta, iz 1979., 2007. i 2013. godine, izrađena je karta gustoće klizišta, na način da je za svaku kartografsku jedinicu (padinu) određen udio površine klizišta u jedinici. Iz slike 6.13 može se vidjeti da se gustoća klizišta na pojedinim padinama znatno razlikuje za sva tri predmetna inventara, što je i za očekivati s obzirom na velike razlike u površinama kartiranih klizišta, ali i visokom indeksu pogreške odnosno indeksu podudarnosti uspoređivanih inventara. Guzzetti et al. (2000) predlažu da se prostorne jedinice s vrlo malim udjelom površina klizišta (<3 %), odnosno padine s nekoliko malih površinskih klizišta, klasificiraju kao stabilne padine. Međutim, s obzirom na specifičnosti kartografskih jedinica (padina) izdvojenih na pilot području i tri inventara klizišta, definirana je granična vrijednost od 1 % površine klizišta, pri čemu se padine s površinom klizišta manjom od 1 % mogu se smatrati stabilnim. U tablici 6.3 prikazan je broj stabilnih i nestabilnih padina u sva tri predmetna inventara klizišta. Karta gustoće klizišta izrađena na temelju inventara iz 1979. godine ima 40 stabilnih padina (57% od ukupnog broja padina), karta gustoće klizišta izrađena na temelju inventara iz 2007. godine ima najmanje stabilnih padina (20 stabilnih padina ili 29% od ukupnog broja padina), a karta gustoće klizišta izrađena na temelju LiDAR DMT inventara klizišta ima 32 stabilne padine (45 % od ukupnog broja padina). Prema karti gustoće klizišta izrađenoj na temelju inventara iz 2013. godine, 68 % pilot područja ili 14,3 km^2 klasificirano je kao nestabilno, odnosno podložno na klizanje. Prema karti gustoće klizišta izrađenoj na temelju inventara iz 2007. godine pilot područje ima 30 % veću površinu nestabilnih padina (18,7 km^2 ili 88,6 % pilot područja), u odnosu na kartu gustoće izrađenu na temelju inventara klizišta iz 2013. godine. Karta gustoće klizišta izrađene prema inventaru iz 1979. godine ima 13 % manju površinu nestabilnih padina (12,4 km^2 ili 58,7 % pilot područja) u odnosu na kartu gustoće izrađenu na temelju inventara klizišta iz 2013. godine.

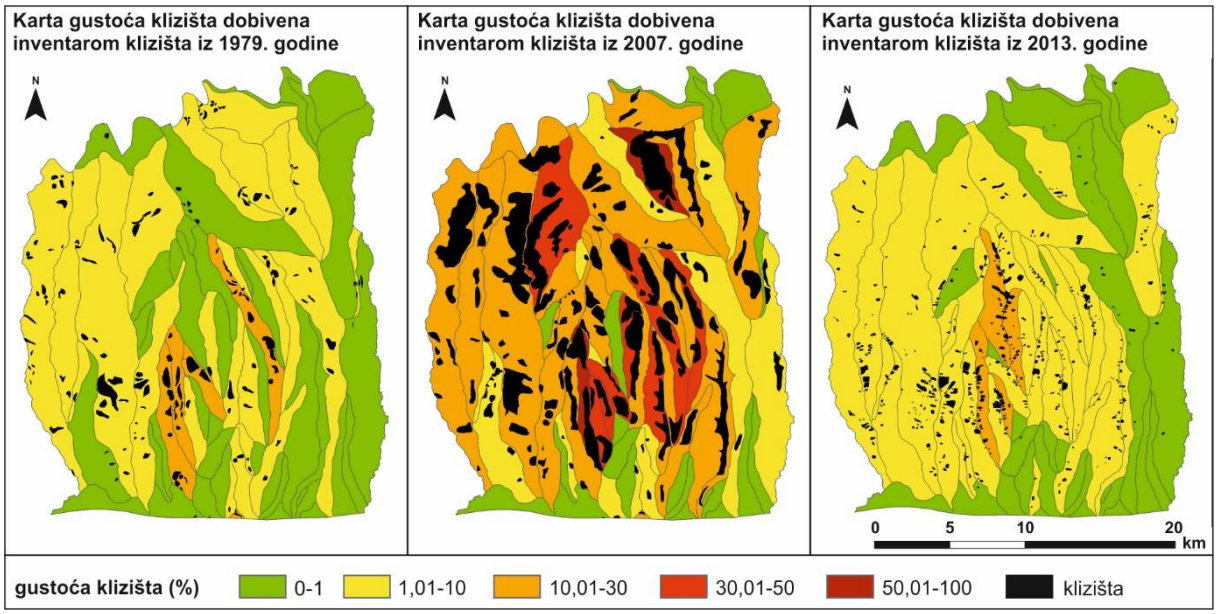

Slika 6.13 Karte gustoća klizišta za pilot područje (21 km^2) izrađene na temelje tri inventara klizišta: (a) inventara iz 1979. godine; (b) inventara iz 2007. godine; (c) inventara iz 2013. godine.

Tablica 6.3 Usporedba učestalosti stabilnih i nestabilnih padina dobivenih na temelju karata gustoća klizišta za inventare klizišta iz 1979., 2007. i 2013. godine.

Inventari klizišta	Broj stabilnih padina	Površina (km^2)	Udio površine (%)	Broj nestabilnih padina	Površina (km^2)	Udio površine (%)
inventar iz 1979. godine	40	8,7	41,3	30	12,4	58,7
inventar iz 2007. godine	21	2,4	11,4	49	18,7	88,6
inventar iz 2013. godine	32	6,8	32,2	38	14,3	67,8

Vizualnom usporedbom izvedenih karata gustoće klizišta po kartografskim jedinicama padina (slika 6.13) može se zaključiti da je najmanja sličnost između karata izvedenih na temelju inventara iz 2007. godine i inventara iz 2013. godine. Karte gustoća klizišta izrađene na temelju inventara iz 1979. i 2013. godine pokazuju malu do srednju gustoću površina klizišta u nestabilnim kartografskim jedinicama na pilot području. Razlog tome su relativno male površine klizišta u oba inventara (ukupna površina klizišta od 0,61 km^2 u inventaru iz 1979. godine i ukupna površina klizišta od 0,51 km^2 u inventaru iz 2013. godine). Karta gustoće klizišta izvedena na temelju inventara iz 2007. godine znatno se razlikuje od preostalih karata gustoća klizišta jer prikazuje vrlo visoke gustoće površina klizišta na pojedinim padinama. U središnjem dijelu pilot područja, gustoća površina klizišta na padinama je veća od 30% što je rezultat površinom vrlo velikih klizišta u inventaru iz 2007. godine, u kojemu se nalazi 28 pojava klizišta s površinom većom od 30.000 m^2.

7 MODEL ZA AUTOMATIZIRANO KARTIRANJE KLIZIŠTA NA TEMELJU LiDAR DMT-a

U ovom poglavlju opisan je razvoj modela za automatizirano kartiranje klizišta na temelju morfometrijska karata izvedenih iz LiDAR DMT-a. Za potrebe izrade modela za automatizirano kartiranje klizišta, pilot područje ukupne površine 21 km^2, podijeljeno je na područje za treniranje modela (10,5 km^2) i područje za verifikaciju modela (10,5 km^2). Na slici 7.1 prikazan je obuhvat područja za treniranje modela (testno područje) na zapadnom dijelu pilot područja i područje za verifikaciju modela na istočnom dijelu pilot područja. Dijagram toka za izradu modela za automatizirano kartiranje klizišta prikazan je na slici 7.2. Prvi korak modeliranja je analiza raspodjele morfometrijskih vrijednosti površine terena unutar granica i izvan granica klizišta te definiranje graničnih vrijednosti morfometrijskih parametara koji ukazuju na morfologiju klizišta. Za analizu morfometrijskih vrijednosti korištena su daljinski vizualno interpretirana klizišta koja se nalaze na testnom području (463 klizišta ili 66 % od ukupnog broja klizišta u inventaru). Drugi korak modeliranja je zbrajanje vrijednosti predikcijskih karata u svrhu izrade inventara automatizirano kartiranih klizišta. Primijenjene su dvije različite metode zbrajanja vrijednosti predikcijskih karata, te su kao rezultat dobivene dvije različite karte inventara klizišta, od kojih je jedna odabrana kao konačna karta inventara klizišta. Izbor konačne karte proveden je na temelju parametara točnosti iskazane za testno područje, čime je također izabran model za automatizirano kartiranje klizišta koji daje najoptimalnije rezultate.

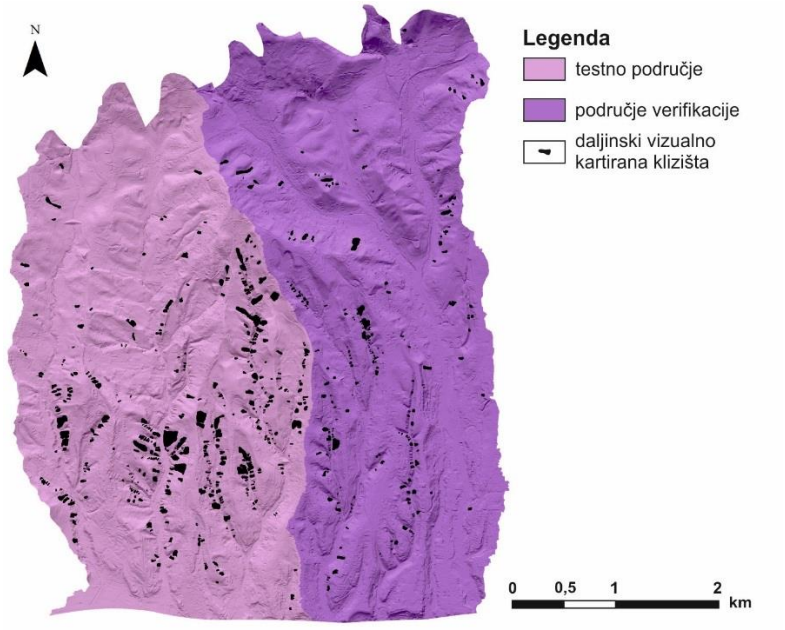

Slika 7.1 Obuhvat područja za treniranje modela i područja za verifikaciju modela za automatizirano kartiranje klizišta na pilot području ukupne površine 21 km^2.

Odabrani model za automatizirano kartiranje klizišta verificiran je na dijelu pilot područja koji nije bio uključen u prethodne analize, odnosno na istočnom dijelu pilot područja površine 10,5 km^2. Usporedba ovako dobivene karte inventara klizišta provedena je s vizualno kartiranim klizištima, te je iskazana kao postotak točno previđenih vizualno kartiranih klizišta i postotka točaka točno klasificiranih kao klizišta, odnosno postotka točaka koje se nalaze unutar granice nestabilnih padina i vizualno kartiranih klizišta.

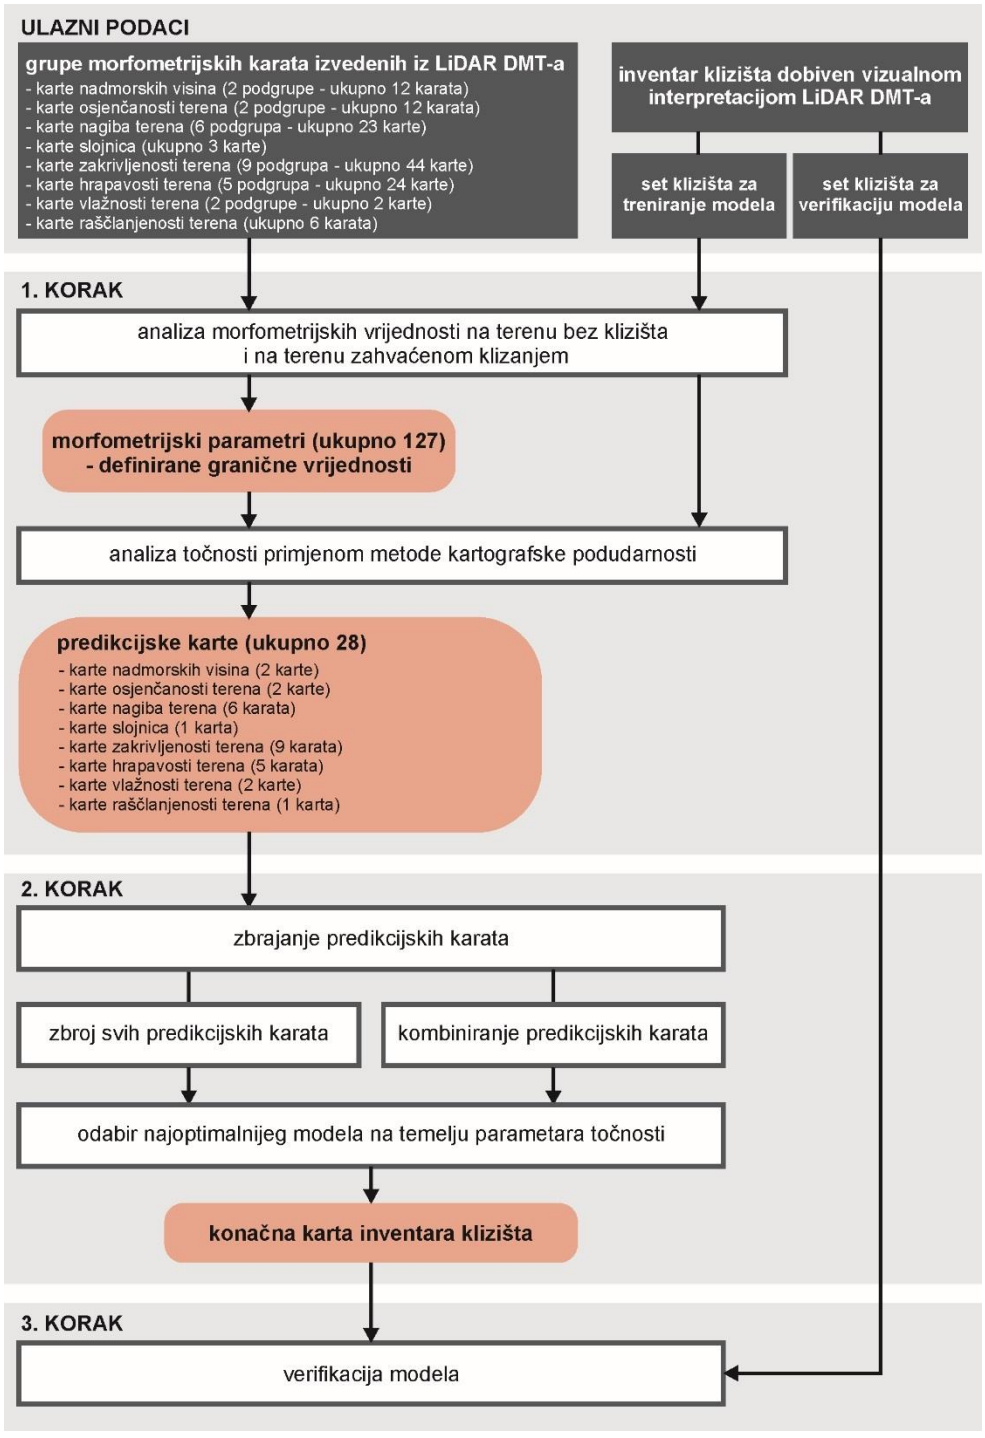

Slika 7.2 Dijagram toka analiza provedenih za izradu model za automatizirano kartiranje klizišta na temelju morfometrijskih karata izvedenih iz LiDAR DMT-a.

7.1 Analiza morfometrijskih karata i odabir predikcijskih karata

U slijedećim poglavljima prikazana je analiza raspodjele morfometrijskih vrijednosti na površini terena unutar granica i izvan granica vizualno interpretiranih klizišta na LiDAR DMT-u za svih osam grupa morfometrijskih karata, odnosno za 127 karata izvedenih iz LiDAR DMT-a (tablica 7.1). Analiza je provedena na dijelu pilot područja za treniranje modela površine 10,5 km^2 (slika 7.1). S obzirom na razliku u učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem definirane su granične vrijednosti morfometrijskih parametara nakon čega je provedena analiza točnosti pomoću indeksa podudarnosti prema metodi Carrara et al. (1992). Iz svake podgrupe izvedenih karata, morfometrijski parametar s najvišim indeksom podudarnosti odabran je kao predikcijska karta koja je korištena kao ulazni podatak u drugom koraku izrade modela za automatizirano kartiranje klizišta.

Tablica 7.1 Grupe i podgrupe morfometrijskih karata izvedenih iz LiDAR DMT-a rezolucije 1x1 m.

Br.	Naziv grupe morfometrijskih karata	Naziv podgrupe morfometrijskih karata	Broj morfometrijskih karata
1	karte nadmorskih visina	karte raspona nadmorskih visina	6
		karte standardne devijacije nadmorskih visina	6
2	karte osjenčanosti terena	karte raspona osjenčanosti visina	6
		karte standardne devijacije osjenčanosti visina	6
3	karte nagiba terena	karta nagiba terena	1
		karte raspona nagiba terena	6
		karte standardne devijacije nagiba terena	6
		karte relativnog nagiba terena	6
		karta druge derivacije nagiba terena	1
		karte indeksa položaja	3
4	karte gustoće slojnica		3
5	karte zakrivljenosti terena	karte ukupne zakrivljenosti terena	6
		karte raspona vrijednosti ukupne zakrivljenosti terena	6
		karte standardne devijacije ukupne zakrivljenosti terena	6
		karte profilne zakrivljenosti terena	1
		karte raspona vrijednosti profilne zakrivljenosti terena	6
		karte standardne devijacije profilne zakrivljenosti terena	6
		karte planarne zakrivljenosti terena	1
		karte raspona vrijednosti planarne zakrivljenosti terena	6
		karte standardne devijacije planarne zakrivljenosti terena	6
6	karte hrapavosti terena	karta hrapavosti terena	6
		karte relativnog topografskog položaja	6
		karte standardne devijacije nadmorske visine terena	6
		karte indeksa hrapavosti terena	6
		karta omjera 3D i 2D površine terena	1
7	karte vlažnosti terena	karta vlažnosti terena	1
		karte osunčanosti terena	1
8	karte raščlanjenosti terena		6

7.1.1 Morfometrijske karte nadmorskih visina

U grupi izvedenih morfometrijskih karata nadmorskih visina ukupno je analizirano šest karata standardne devijacije nadmorske visine i šest karata raspona nadmorske visine izrađenih pomoću prozora za uzorkovanje različitih oblika i veličina. Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za svih 12 izvedenih karata nadmorskih visina prikazana je tablici 7.2. Na slici 7.3 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem na jednoj od izvedenih karata standardne devijacije nadmorske visine, a na slici 7.4 na jednoj od izvedenih karata raspona nadmorske visine.

Tablica 7.2 Granične vrijednosti i indeks podudarnosti morfometrijske grupe karata nadmorske visine.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	standardna devijacija nadmorske visine dobivena kvadratnim prozorom veličine 3x3 m	std_DMT_fr3	0,3-1,1	7,68 %
	standardna devijacija nadmorske visine dobivena kvadratnim prozorom veličine 5x5 m	std_DMT_fr5	0,5-1,8	7,58 %
	standardna devijacija nadmorske visine dobivena kvadratnim prozorom veličine 9x9 m	std_DMT_fr9	0,9-3,1	7,14 %
	standardna devijacija nadmorske visine dobivena kružnim prozorom radijusa 3 m	std_DMT_fc3	0,5-1,9	7,16 %
	standardna devijacija nadmorske visine dobivena kružnim prozorom radijusa 5 m	std_DMT_fc5	0,8-2,9	7,09 %
	standardna devijacija nadmorske visine dobivena kružnim prozorom radijusa 9 m	std_DMT_fc9	1,6-5,6	7,51 %
2	raspon nadmorske visine dobiven kvadratnim prozorom veličine 3x3 m	rng_DMT_fr3	0,75-3,5	6,70 %
	raspon nadmorske visine dobiven kvadratnim prozorom veličine 5x5 m	rng_DMT_fr5	1,5-6,5	6,77 %
	raspon nadmorske visine dobiven kvadratnim prozorom veličine 9x9 m	rng_DMT_fr9	3,5-12,75	7,20 %
	raspon nadmorske visine dobiven kružnim prozorom radijusa 3 m	rng_DMT_fc3	1,75-7,0	6,19 %
	raspon nadmorske visine dobiven kružnim prozorom radijusa 5 m	rng_DMT_fc5	3,25-11	7,50 %
	raspon nadmorske visine dobiven kružnim prozorom radijusa 9 m	rng_DMT_fc9	6-21,5	7,28 %

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti svih 12 izvedenih morfometrijskih karata nadmorskih visina navedeni su u tablici 7.2. Od ukupno šest karata standardne devijacije nadmorske visine najviši indeks podudarnosti ima karta standardne devijacije nadmorske visine

dobivena kvadratnim prozorom veličine 3x3 m (7,68 %), a najniži indeks podudarnosti ima karta standardne devijacije nadmorske visine dobivena kružnim prozorom radijusa 5 m (7,09 %). Analiza podudarnosti pokazala je da od šest karata raspona nadmorske visine najviši indeks podudarnosti ima karta raspona nadmorske visine dobivena kružnim prozorom radijusa 5 m (7,50 %), a najniži indeks podudarnosti ima karta raspona nadmorske visine dobivena kružnim prozorom radijusa 3 m (6,19 %). S obzirom na indeks podudarnosti, karta standardne devijacije nadmorske visine dobivena kvadratnim prozorom dimenzija 3x3 m (std_DMT_fr3) s graničnim vrijednostima 0,3–1,1 m i karta raspona nadmorske visine dobivena kružnim prozorom radijusa 5 m (std_DMT_fc5) s graničnim vrijednosti 3,25–11 m odabrane su kao predikcijske karte za automatizirano kartiranje klizišta. Na slici 7.5 prikazana je prostorna raspodjela vrijednosti morfometrijskih parametara standardne devijacije i raspona nadmorske visine s najvišim indeksom podudarnosti u odnosu na klizišta kartirana vizualnom interpretacijom LIDAR DMT-a.

Slika 7.3 Raspodjela učestalosti vrijednosti standardne devijacije nadmorske visine dobivene kvadratnim prozorom veličine 3x3 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

Slika 7.4 Raspodjela učestalosti vrijednosti raspona nadmorske visine dobivene kružnim prozorom radijusa 5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

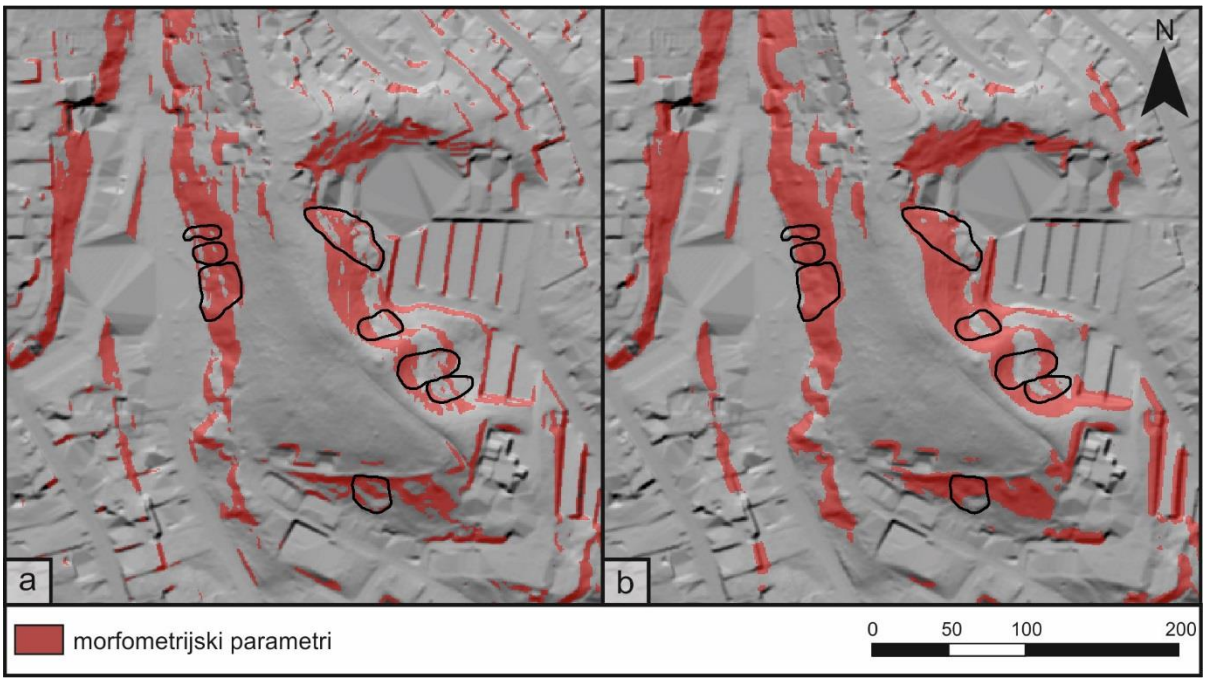

Slika 7.5 Preklop karata morfometrijskih parametara nadmorske visine s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) standardna devijacija nadmorske visine (std_DMT_fr3); i (b) raspon nadmorske visine (rng_DMT_fc5).

7.1.2 Morfometrijske karte osjenčanosti terena

U grupi izvedenih morfometrijskih karata osjenčanosti terena ukupno je analizirano šest karata standardne devijacije osjenčanosti terena i šest karata raspona osjenčanosti terena izrađenih pomoću prozora za uzorkovanje različitih oblika i veličina. Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za svih 12 izvedenih karata osjenčanosti terena prikazana je tablici 7.3. Na slici 7.6 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem na jednoj od izvedenih karata standardne devijacije osjenčanosti terena, a na slici 7.7 na jednoj od izvedenih karata raspona osjenčanosti terena.

Tablica 7.3 Granične vrijednosti morfometrijske grupe karata osjenčanosti terena.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	standardna devijacija osjenčanosti terena dobivena kvadratnim prozorom veličine 3x3 m	std_hill_fr3	4-26	5,70 %
	standardna devijacija osjenčanosti terena dobivena kvadratnim prozorom veličine 5x5 m	std_hill_fr5	6-36	5,82 %
	standardna devijacija osjenčanosti terena dobivena kvadratnim prozorom veličine 9x9 m	std_hill_fr9	6-40	4,90 %
	standardna devijacija osjenčanosti terena dobivena kružnim prozorom radijusa 3 m	std_hill_fc3	4-34	4,89 %
	standardna devijacija osjenčanosti terena dobivena kružnim prozorom radijusa 5 m	std_hill_fc5	5-38	4,67 %
	standardna devijacija osjenčanosti terena dobivena kružnim prozorom radijusa 9 m	std_hill_fc9	12-52	5,41 %
2	raspon osjenčanosti terena dobiven kvadratnim prozorom veličine 3x3 m	rng_hill_fr3	12-82	5,71 %
	raspon osjenčanosti terena dobiven kvadratnim prozorom veličine 5x5 m	rng_hill_fr5	22-118	5,87 %
	raspon osjenčanosti terena dobiven kvadratnim prozorom veličine 9x9 m	rng_hill_fr9	40-150	5,67 %
	raspon osjenčanosti terena dobiven kružnim prozorom radijusa 3 m	rng_hill_fc3	24-122	5,84 %
	raspon osjenčanosti terena dobiven kružnim prozorom radijusa 5 m	rng_hill_fc5	36-140	5,70 %
	raspon osjenčanosti terena dobiven kružnim prozorom radijusa 9 m	rng_hill_fc9	60-174	5,25 %

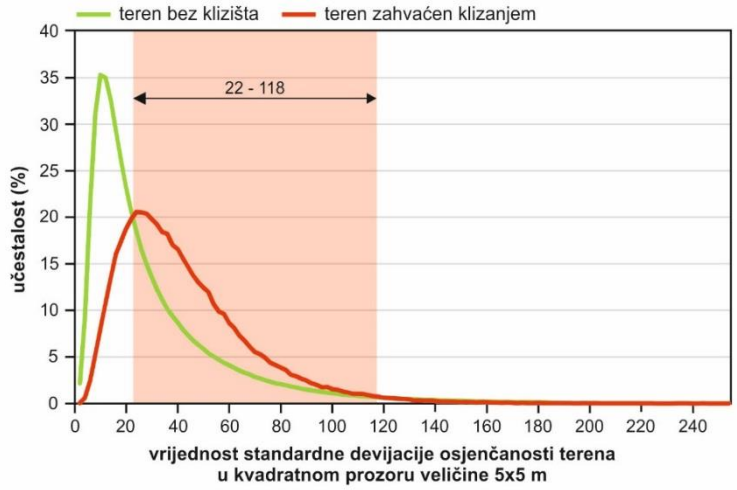

Slika 7.6 Raspodjela učestalosti vrijednosti standardne devijacije osjenčanosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

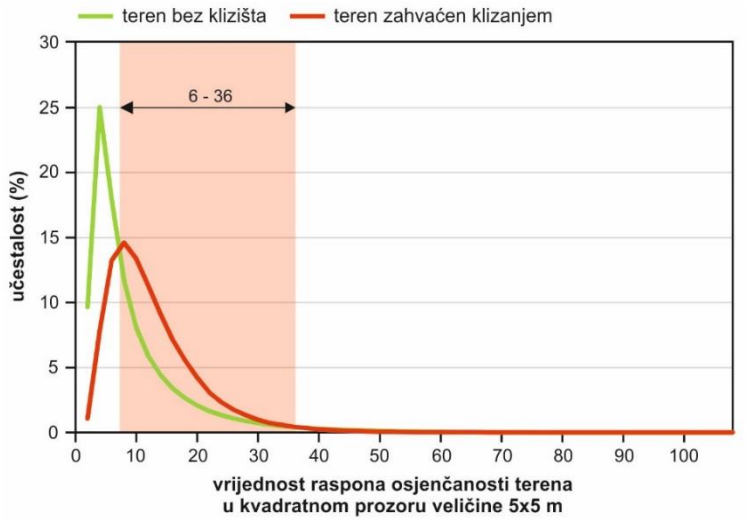

Slika 7.7 Raspodjela učestalosti vrijednosti raspona osjenčanosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti svih 12 izvedenih morfometrijskih karata osjenčanosti terena navedeni su u tablici 7.3. Od ukupno šest karata standardne devijacije osjenčanosti terena najviši indeks podudarnosti ima karata standardne devijacije osjenčanosti terena dobivena kvadratnim prozorom veličine 5x5 m (5,82 %), a najniži indeks podudarnosti ima karta standardne devijacije osjenčanosti terena dobivena kružnim prozorom radijusa 5 m (4,67 %). Analiza podudarnosti pokazala je da od šest karata raspona osjenčanosti terena najviši indeks podudarnosti ima karata raspona osjenčanosti terena dobivena kvadratnim prozorom veličine 5x5 m (5,87%), a najniži indeks podudarnosti ima karta raspona nadmorske visine dobivena kružnim prozorom radijusa 9 m (5,25%). S obzirom na indeks podudarnosti, karta standardne devijacije osjenčanosti terena dobivena kvadratnim prozorom dimenzija 5x5 m (std_hill_fr5) s graničnim vrijednostima 6–36 i karta raspona osjenčanosti terena dobivena kvadratnim prozorom dimenzija 5x5 m (rng_hill_fr5) s graničnim vrijednosti 22–118 odabrane su kao predikcijske karte za automatizirano kartiranje klizišta. Na slici 7.8 prikazana je prostorna raspodjela vrijednosti morfometrijskih parametara standardne devijacije i raspona osjenčanosti s najvišim indeksom podudarnosti u odnosu na klizišta kartirana vizualnom interpretacijom LiDAR DMT-a.

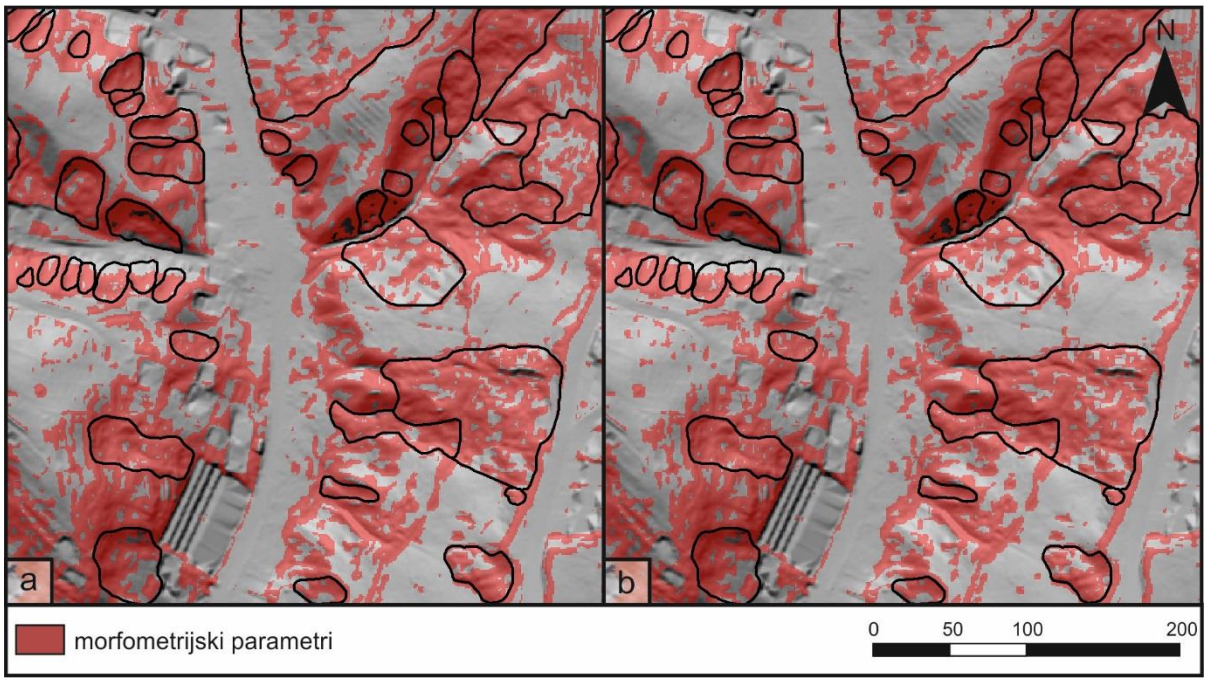

Slika 7.8 Preklop karata morfometrijskih parametara osjenčanosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) standardna devijacija osjenčanosti terena (std_hill_fr5); i (b) raspon osjenčanosti terena (rng_hill_fr5).

7.1.3 Morfometrijske karte nagiba terena

U grupi izvedenih morfometrijskih karata nagiba terena ukupno su analizirane 23 karate: karta nagiba terena, šest karata standardne devijacije nagiba terena, šest karata raspona nagiba terena, šest karata relativnog nagiba terena, karta druge derivacije nagiba terena te tri karte indeksa položaja. Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za sve izvedene karte nagiba terena prikazani su u tablici 7.4. Na slikama od 7.9 do 7.14 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem za svaku od podgrupa morfometrijskih karata nagiba terena.

Tablica 7.4 Granične vrijednosti grupe morfometrijskih karata nagiba terena.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	nagib terena	slp	18-52	7,12 %
2	standardna devijacija nagiba terena dobivena kvadratnim prozorom veličine 3x3 m	std_slp_fr3	1-6,5	5,51 %
	standardna devijacija nagiba terena dobivena kvadratnim prozorom veličine 5x5 m	std_slp_fr5	2-8,5	6,13 %
	standardna devijacija nagiba terena dobivena kvadratnim prozorom veličine 9x9 m	std_slp_fr9	3-10	6,01 %
	standardna devijacija nagiba terena dobivena kružnim prozorom radijusa 3 m	std_slp_fc3	2-8,5	6,06 %
	standardna devijacija nagiba terena dobivena kružnim prozorom radijusa 5 m	std_slp_fc5	3-9,5	6,20 %
	standardna devijacija nagiba terena dobivena kružnim prozorom radijusa 9 m	std_slp_fc9	4-11	5,73 %
3	raspon nagiba terena dobiven kvadratnim prozorom veličine 3x3 m	rng_slp_fr3	3,5-19	5,75 %
	raspon nagiba terena dobiven kvadratnim prozorom veličine 5x5 m	rng_slp_fr5	7-28	6,06 %
	raspon nagiba terena dobiven kvadratnim prozorom veličine 9x9 m	rng_slp_fr9	13,5-40	5,85 %
	raspon nagiba terena dobiven kružnim prozorom radijusa 3 m	rng_slp_fc3	7,5-29,5	5,98 %
	raspon nagiba terena dobiven kružnim prozorom radijusa 5 m	rng_slp_fc5	12,5-38,5	5,93 %
	raspon nagiba terena dobiven kružnim prozorom radijusa 9 m	rng_slp_fc9	22-46	5,75 %
4	relativan nagib terena dobiven kvadratnim prozorom veličine 3x3 m	sp_fr3	-0,15 – -0,05 ; 0,05-0,15	5,46 %
	relativan nagib terena dobiven kvadratnim prozorom veličine 5x5 m	sp_fr5	-0,35 – -0,05 ; 0,05-0,30	6,05 %
	relativan nagib terena dobiven kvadratnim prozorom veličine 9x9 m	sp_fr9	-1,35 – -0,1; 0,3 – 0,85	5,73 %
	relativan nagib terena dobiven kružnim prozorom radijusa 3 m	sp_fc3	-0,4 – -0,05 ; 0,05 – 0,35	5,62 %
	relativan nagib terena dobiven kružnim prozorom radijusa 5 m	sp_fc5	-0,8 – -0,1 ; 0,1 – 0,65	5,56 %
	relativan nagib terena dobiven kružnim prozorom radijusa 9 m	sp_fc9	-1,7 – -0,15 ; 0,35 – 0,8	3,80 %
5	druga derivacija nagiba terena	slp_2nd	53-83	5,64 %
6	indeks položaja dobiven metodom SIN	sat_sin	-1,05 – -0,25; 0,3 – 1,05	7,44 %
	indeks položaja dobiven metodom COS	sat_cos	-1 – -0,25; 0,05 – 1,00	5,38 %
	indeks položaja dobiven metodom TRASP	sat_trans	0 – 0,2 ; 0,55 – 0,85	4,01 %

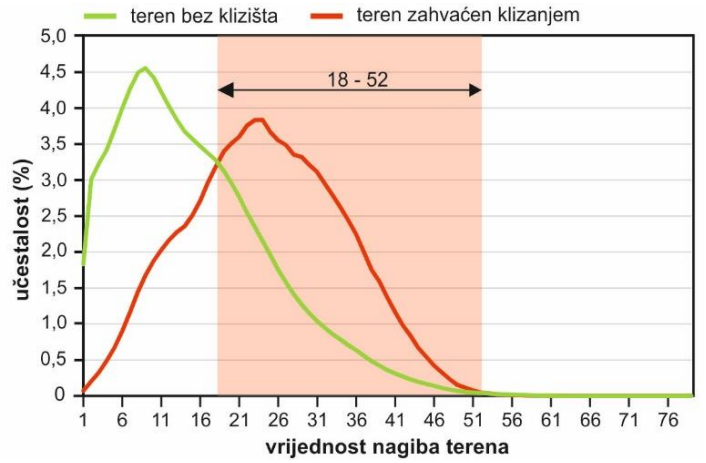

Slika 7.9 Raspodjela učestalosti vrijednosti nagiba na terenu bez klizišta i terenu zahvaćenom klizanjem.

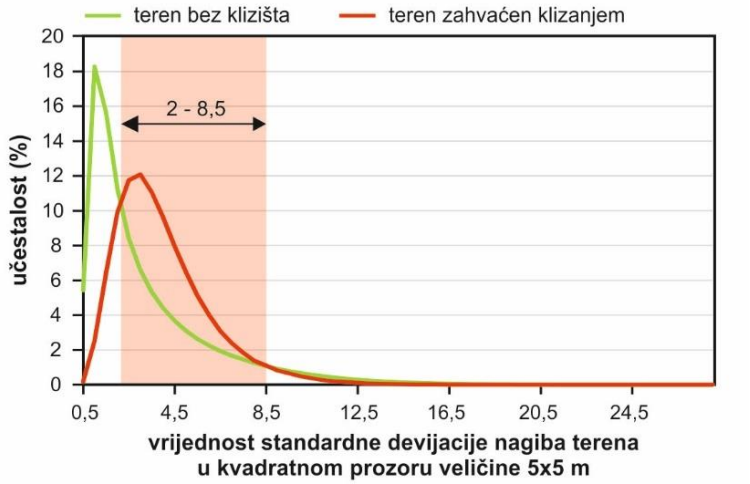

Slika 7.10 Raspodjela učestalosti vrijednosti standardne devijacije nagiba terena dobivene kružnim prozorom radijusa 5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

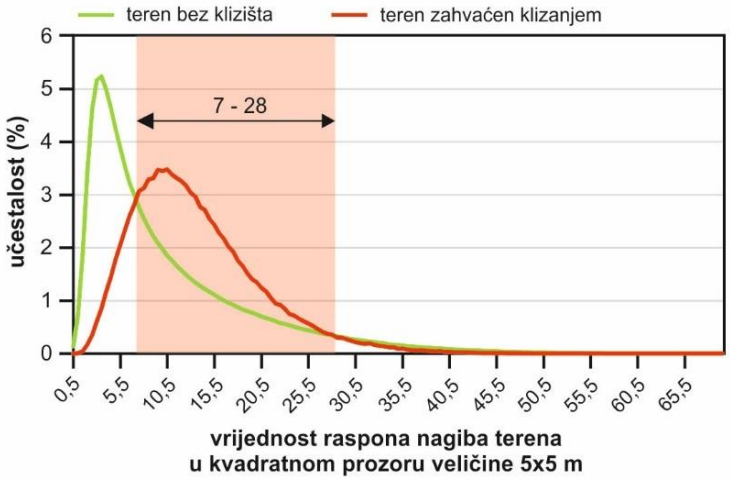

Slika 7.11 Raspodjela učestalosti vrijednosti raspona nagiba terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

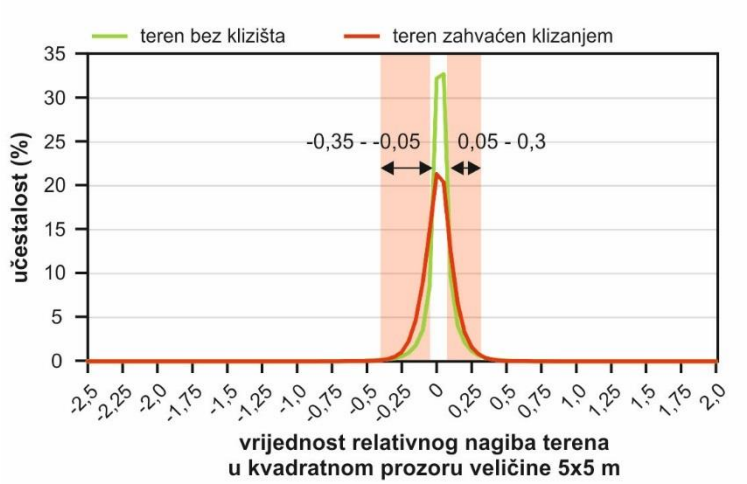

Slika 7.12 Raspodjela učestalosti vrijednosti relativnog nagiba terena dobivenog kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

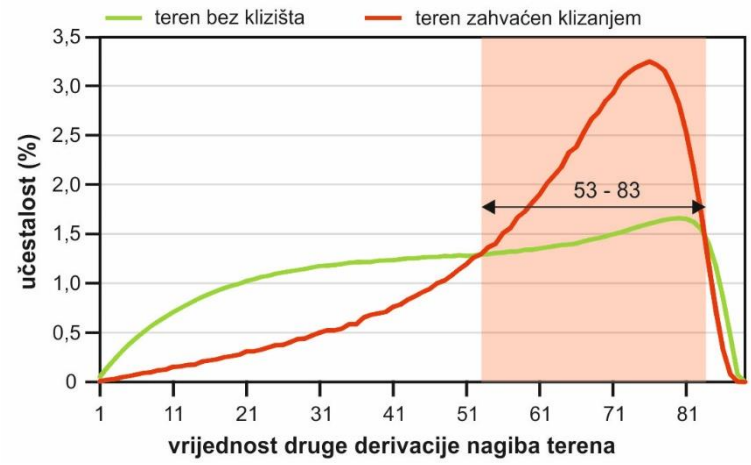

Slika 7.13 Raspodjela učestalosti vrijednosti druge derivacije nagiba na terenu bez klizišta i terenu zahvaćenom klizanjem.

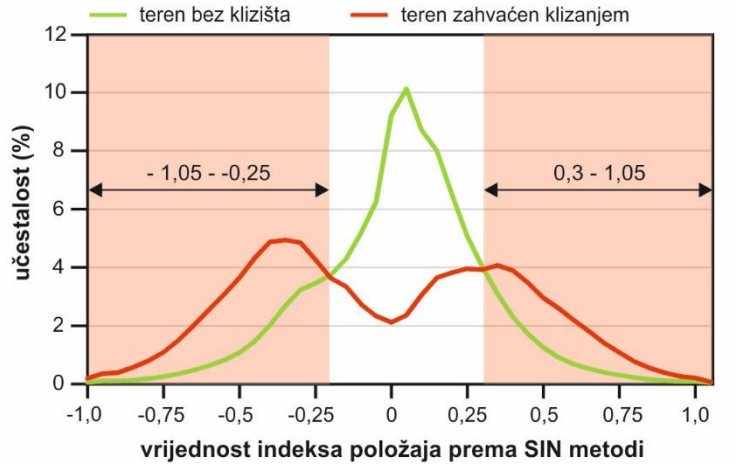

Slika 7.14 Raspodjela učestalosti vrijednosti indeksa položaja dobivenog SIN metodom na terenu bez klizišta i terenu zahvaćenom klizanjem.

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti za sve 23 izvedene morfometrijske karte nagiba terena navedeni su u tablici 7.4. Karta nagiba terena s graničnom vrijednosti 18-52° ima indeks podudarnosti od 7,16 %. Od ukupno šest karata standardne devijacije nagiba terena najviši indeks podudarnosti ima karta standardne devijacije nagiba terena dobivena kružnim prozorom veličine 5x5 m (6,20 %), a najniži indeks podudarnosti ima karta standardne devijacije nagiba terena dobivena kvadratnim prozorom veličine 3x3 m (5,51 %). Analiza podudarnosti pokazala je da od šest karata raspona nagiba terena najviši indeks podudarnosti ima karata raspona nagiba terena dobivena kružnim prozorom radijusa 5 m (6,06 %), a najniži indeks podudarnosti ima karta raspona nadmorske visine dobivena kvadratnim prozorom veličine 3x3 m i kružnim prozorom radijusa 9 m (5,75 %). Od ukupno šest karata relativnog nagiba terena najviši indeks podudarnosti ima karta relativnog nagiba terena dobivena kvadratnim prozorom veličine 5x5 m (6,05 %), a najniži indeks podudarnosti ima karta relativnog nagiba terena dobivena kružnim prozorom radijusa 9 m (3,80 %). Karta druge derivacije nagiba terena s graničnom vrijednosti 53-83° ima indeks podudarnosti od 5,64 %. Od tri karte indeksa položaja, najviši indeks podudarnosti ima karta indeksa položaja dobivena SIN metodom (7,44 %), a najniži indeks podudarnosti ima karta indeksa položaja dobivena TRASP metodom (4,01 %).

S obzirom na indeks podudarnosti, karta nagiba terena s graničnom vrijednosti 18–52° (slp), karta standardne devijacije nagiba terena dobivena kružnim prozorom dimenzija 5x5 m (std_slp_fc5) s graničnim vrijednostima 2–8,5°, karta raspona nagiba terena dobivena kvadratnim prozorom dimenzija 5x5 m (rng_slp_fr5) s graničnim vrijednosti 7–28°, karta relativnog nagiba terena dobivena kvadratnim prozorom veličine 5x5 m (sp_fr5) s graničnom vrijednosti od -0,35 do -0,05° i 0,05–0,30°, karta druge derivacije nagiba terena (slp_2nd) s graničnom vrijednosti 53-83 i karta indeksa položaja dobivena SIN metodom (sat_sin) s graničnom vrijednosti od -1,05 do -0,25 i 0,3–1,05 odabrane su kao predikcijske karte za automatizirano kartiranje klizišta. Na slici 7.15 prikazana je prostorna raspodjela vrijednosti šest morfometrijskih parametara nagiba terena s najvišim indeksom podudarnosti u odnosu na klizišta kartirana vizualnom interpretacijom LiDAR DMT-a.

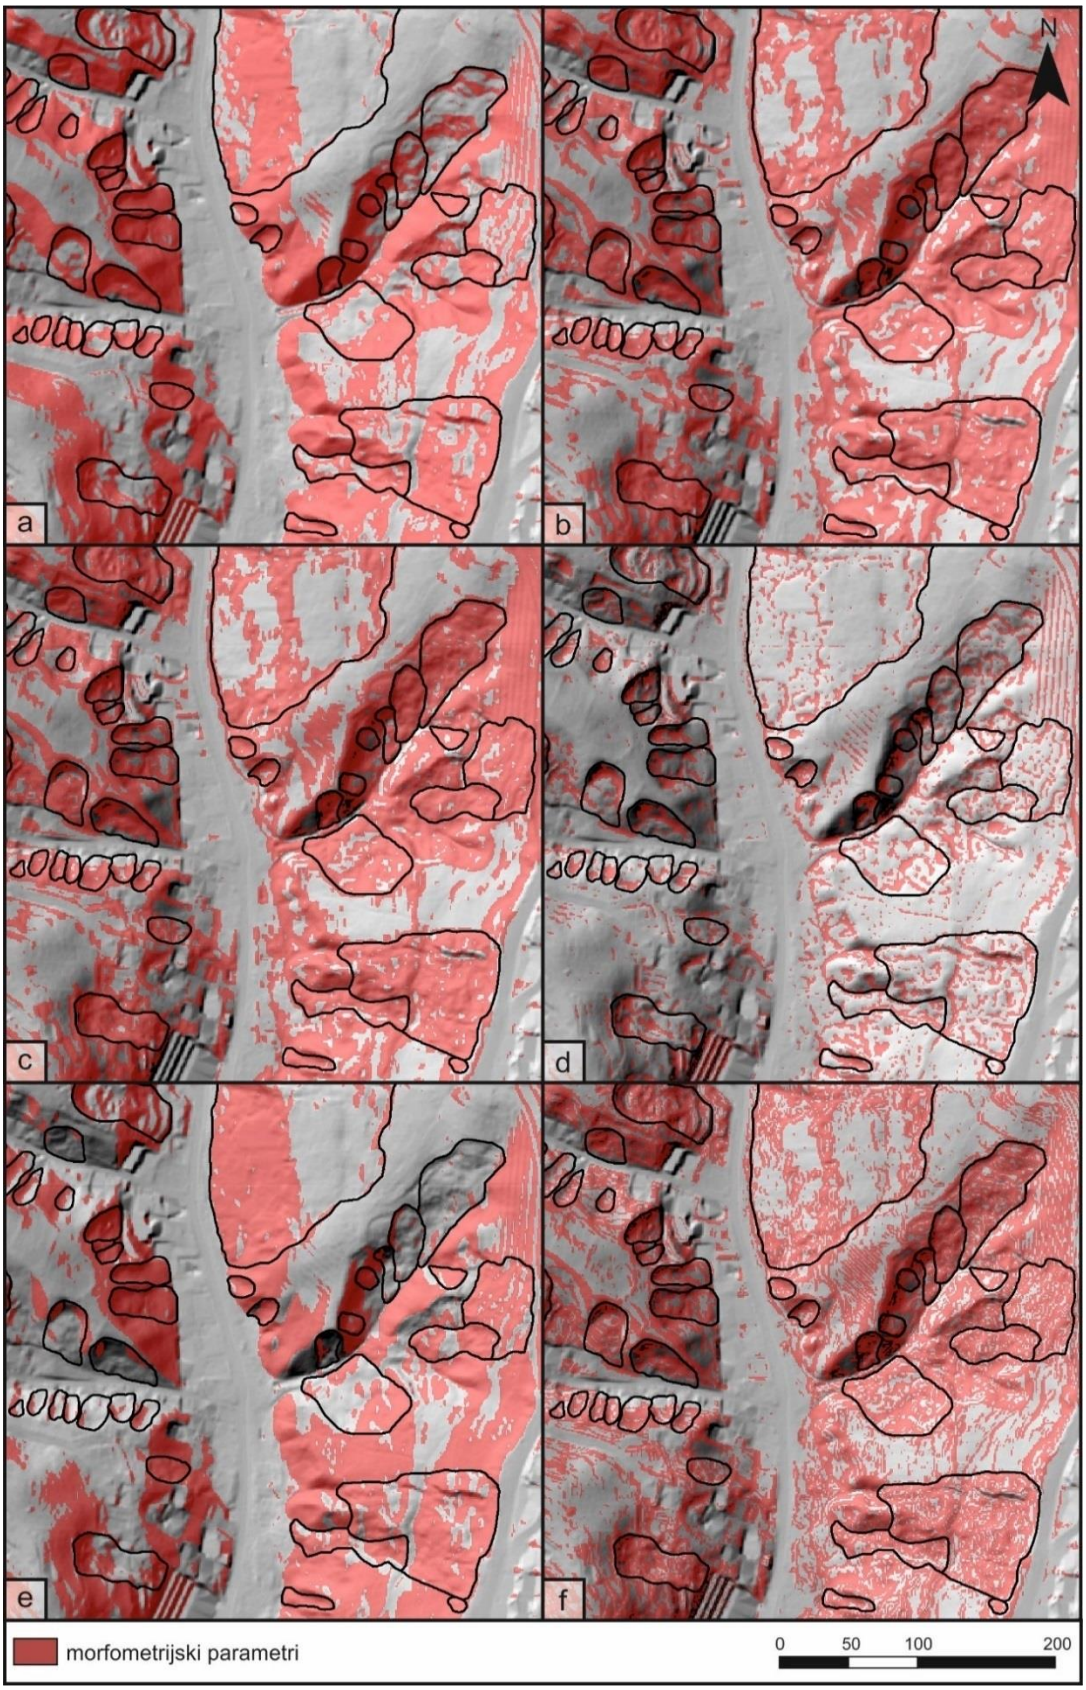

Slika 7.15 Preklop karata morfometrijskih parametara nagiba terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) nagib terena (slp); (b) standardna devijacija nagiba terena (std_slp_fr5); (c) raspon nagiba terena (rng_slp_fr5); (d) relativan nagib terena (sp_fr5); (e) druge derivacije nagiba terena (slp_2nd); (f) indeksa položaja dobivena SIN metodom (sat_sin).

7.1.4 Morfometrijske karte gustoće slojnica

U grupi izvedenih morfometrijskih karata gustoće slojnica ukupno su analizirane tri izvedene karte izrađenih pomoću prozora različite veličine. Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za sve tri izvedene karte gustoće slojnica prikazane su u tablici 7.5. Na slici 7.16 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem na jednoj od izvedenih karata gustoće slojnica.

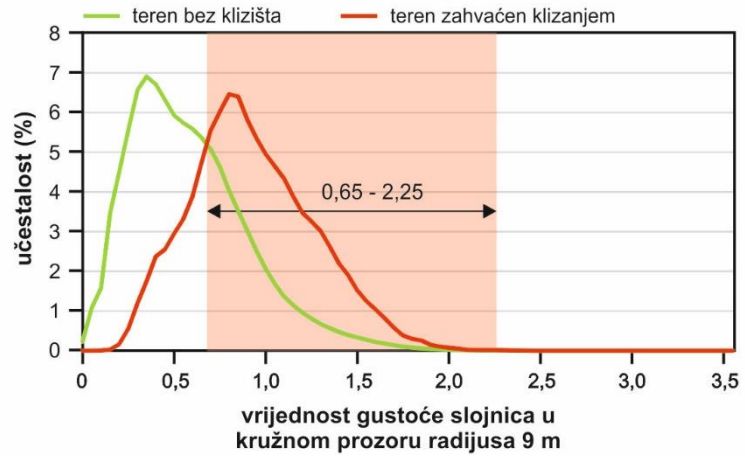

Slika 7.16 Raspodjela učestalosti vrijednosti gustoća slojnica dobivenih kružnim prozorom veličine 9 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

Tablica 7.5 Granične vrijednosti morfometrijskih karata gustoće slojnica.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	gustoća slojnica dobivena kružnim prozorom radijusa 3 m	con_1m_r3m	0,35-1,25	4,17 %
	gustoća slojnica dobivena kružnim prozorom radijusa 5 m	con_1m_r5m	0,65-2,3	7,24 %
	gustoća slojnica dobivena kružnim prozorom radijusa 9 m	con_1m_r9m	0,65-2,25	7,48 %

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti za sve tri izvedene morfometrijske karte gustoće slojnica navedeni su u tablici 7.5. Od ukupno tri karte gustoća slojnica najviši indeks podudarnosti ima karata dobivena kružnim prozorom radijusa 9 m (7,48 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 3 m (4,17 %). Karta gustoće slojnica dobivena kružnim prozorom radijusa 9 m s graničnim vrijednostima 0,65–2,25

odabrana je kao predikcijska karta za automatizirano kartiranje klizišta.. Na slici 7.17 prikazana je prostorna raspodjela vrijednosti morfometrijskih parametara gustoće slojnica s najvišim indeksom podudarnosti u odnosu na klizišta kartirana vizualnom interpretacijom LiDAR DMT-a.

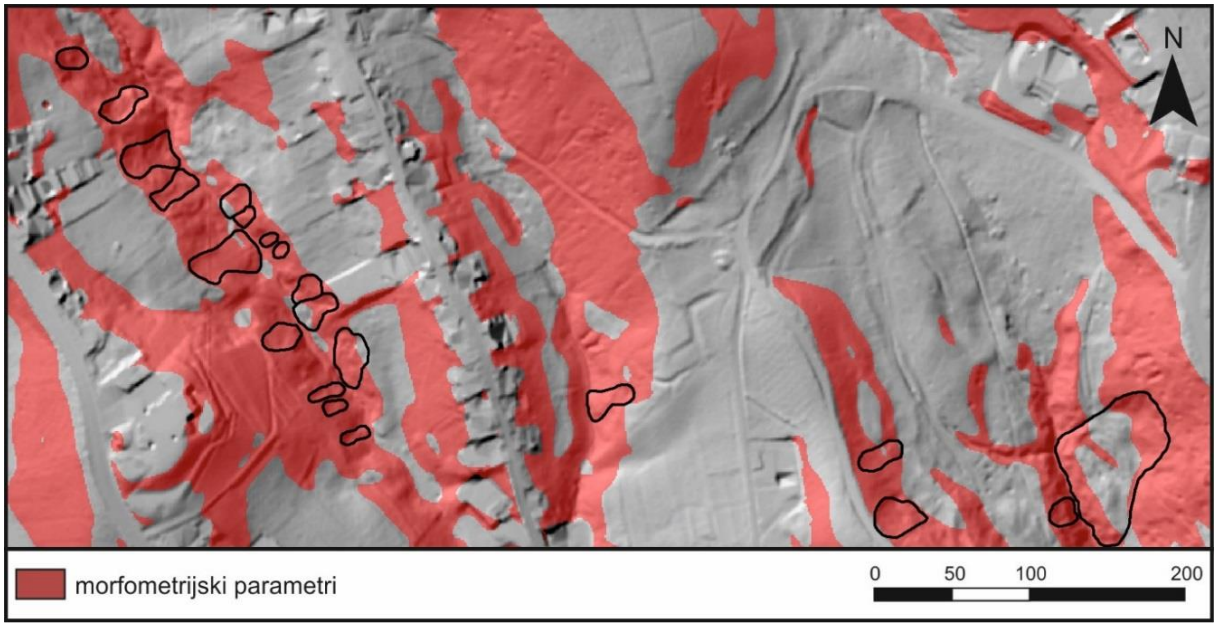

Slika 7.17 Preklop karte morfometrijskog parametra gustoće slojnica (con_1m_r9m) s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a.

7.1.5 Morfometrijske karte zakrivljenosti terena

U grupi izvedenih morfometrijskih karata zakrivljenosti terena ukupno su analizirane 44 karate: šest karata zakrivljenosti terena, šest karata standardne devijacije zakrivljenosti terena, šest karata raspona zakrivljenosti terena, karta planarne zakrivljenosti terena, šest karata standardne devijacije planarne zakrivljenosti terena, šest karata raspona planarne zakrivljenosti terena, karta profilne zakrivljenosti terena, šest karata standardne devijacije profilne zakrivljenosti terena i šest karata raspona profilne zakrivljenosti terena. Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za sve izvedene karte zakrivljenosti terena prikazani su u tablici 7.6. Na slikama 7.18 do 7.26 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem za svaku od podgrupa morfometrijskih karata zakrivljenosti terena.

Tablica 7.6 Granične vrijednosti grupe morfometrijskih karata zakrivljenosti terena.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	zakrivljenost terena dobivena kvadratnim prozorom veličine 3x3 m	crv_fr3	-0,06 - -0,02 ; 0 - 0,2	3,31 %
	zakrivljenost terena dobivena kvadratnim prozorom veličine 5x5 m	crv_fr5	-0,1 - -0,02; 0,02 - 0,1	5,99 %
	zakrivljenost terena dobivena kvadratnim prozorom veličine 9x9 m	crv_fr9	-0,4 - -0,04; 0,6 - 0,22	6,60 %
	zakrivljenost terena dobivena kružnim prozorom radijusa 3 m	crv_fc3	-0,14 - -0,4; 0 - 0,8	3,58 %
	zakrivljenost terena dobivena kružnim prozorom radijusa 5 m	crv_fc5	-0,22 - -0,08; -0,02 - 0,2	3,08 %
	zakrivljenost terena dobivena kružnim prozorom radijusa 9 m	crv_fc9	-0,42 - -0,1; 0,2 - 0,48	4,19 %
2	standardna devijacija zakrivljenosti terena dobivena kvadratnim prozorom veličine 3x3 m	std_crv_fr3	5-25	5,55 %
	standardna devijacija zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m	std_crv_fr5	5-30	5,19 %
	standardna devijacija zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m	std_crv_fr9	10-25	6,84 %
	standardna devijacija zakrivljenosti terena dobivena kružnim prozorom radijusa 3 m	std_crv_fc3	10-30	6,73 %
	standardna devijacija zakrivljenosti terena dobivena kružnim prozorom radijusa 5 m	std_crv_fc5	10-30	6,68 %
	standardna devijacija zakrivljenosti terena dobivena kružnim prozorom radijusa 9 m	std_crv_fc9	10-25	6,27 %
3	raspon zakrivljenosti terena dobiven kvadratnim prozorom veličine 3x3 m	rng_crv_fr3	20-90	5,95 %
	raspon zakrivljenosti terena dobiven kvadratnim prozorom veličine 5x5 m	rng_crv_fr5	30-110	6,27 %
	raspon zakrivljenosti terena dobiven kvadratnim prozorom veličine 9x9 m	rng_crv_fr9	40-140	5,78 %
	raspon zakrivljenosti terena dobiven kružnim prozorom radijusa 3 m	rng_crv_fc3	30-120	6,10 %
	raspon zakrivljenosti terena dobiven kružnim prozorom radijusa 5 m	rng_crv_fc5	40-140	5,96 %
	raspon zakrivljenosti terena dobiven kružnim prozorom radijusa 9 m	rng_crv_fc9	60-150	5,77 %
4	planarna zakrivljenost terena	cplan	-50 - -10; 10-40	6,15 %
5	standardna devijacija planarne zakrivljenosti terena dobivena kvadratnim prozorom veličine 3x3 m	std_cplan_fr3	5-25	6,65 %
	standardna devijacija planarne zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m	std_cplan_fr5	5-25	7,22 %
	standardna devijacija planarne zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m	std_cplan_fr9	5-20	7,12 %
	standardna devijacija planarne zakrivljenosti terena dobivena kružnim prozorom radijusa 3 m	std_cplan_fc3	5-20	7,26 %
	standardna devijacija planarne zakrivljenosti terena dobivena kružnim prozorom radijusa 5 m	std_cplan_fc5	5-25	7,15 %
	standardna devijacija planarne zakrivljenosti terena dobivena kružnim prozorom radijusa 9 m	std_cplan_fc9	10-20	6,59 %

Nastavak **tablice 7.6.**

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
6	raspon planarne zakrivljenosti terena dobiven kvadratnim prozorom veličine 3x3 m	rng_cplan_fr3	10-70	6,10 %
	raspon planarne zakrivljenosti terena dobiven kvadratnim prozorom veličine 5x5 m	rng_cplan_fr5	20-90	6,93 %
	raspon planarne zakrivljenosti terena dobiven kvadratnim prozorom veličine 9x9 m	rng_cplan_fr9	20-90	5,71 %
	raspon planarne zakrivljenosti terena dobiven kružnim prozorom radijusa 3 m	rng_cplan_fc3	20-90	6,88 %
	raspon planarne zakrivljenosti terena dobiven kružnim prozorom radijusa 5 m	rng_cplan_fc5	20-90	5,95 %
	raspon planarne zakrivljenosti terena dobiven kružnim prozorom radijusa 9 m	rng_cplan_fc9	30-100	5,56 %
7	profilna zakrivljenost terena	cprf	-30 - -10; 10-30	5,06 %
8	standardna devijacija profilne zakrivljenosti terena dobivena kvadratnim prozorom veličine 3x3 m	std_cprf_fr3	5-20	5,79 %
	standardna devijacija profilne zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m	std_cprf_fr5	5-20	6,18 %
	standardna devijacija profilne zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m	std_cprf_fr9	5-20	5,87 %
	standardna devijacija profilne zakrivljenosti terena dobivena kružnim prozorom radijusa 3 m	std_cprf_fc3	5-20	6,18 %
	standardna devijacija profilne zakrivljenosti terena dobivena kružnim prozorom radijusa 5 m	std_cprf_fc5	5-20	5,98 %
	standardna devijacija profilne zakrivljenosti terena dobivena kružnim prozorom radijusa 9 m	std_cprf_fc9	5-15	5,55 %
9	raspon profilne zakrivljenosti terena dobiven kvadratnim prozorom veličine 3x3 m	rng_cprf_fr3	10-50	5,62 %
	raspon profilne zakrivljenosti terena dobiven kvadratnim prozorom veličine 5x5 m	rng_cprf_fr5	20-70	6,18 %
	raspon profilne zakrivljenosti terena dobiven kvadratnim prozorom veličine 9x9 m	rng_cprf_fr9	30-90	5,98 %
	raspon profilne zakrivljenosti terena dobiven kružnim prozorom radijusa 3 m	rng_cprf_fc3	20-70	6,15 %
	raspon profilne zakrivljenosti terena dobiven kružnim prozorom radijusa 5 m	rng_cprf_fc5	20-80	5,47 %
	raspon profilne zakrivljenosti terena dobiven kružnim prozorom radijusa 9 m	rng_cprf_fc9	40-100	5,73 %

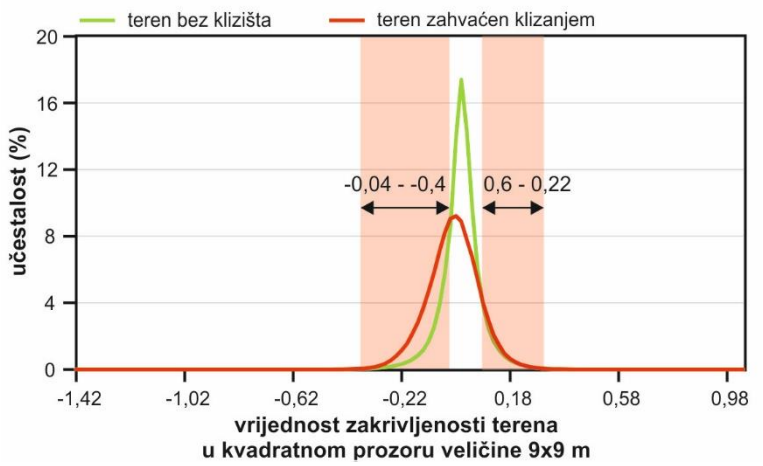

Slika 7.18 Raspodjela učestalosti vrijednosti zakrivljenosti terena dobivene kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

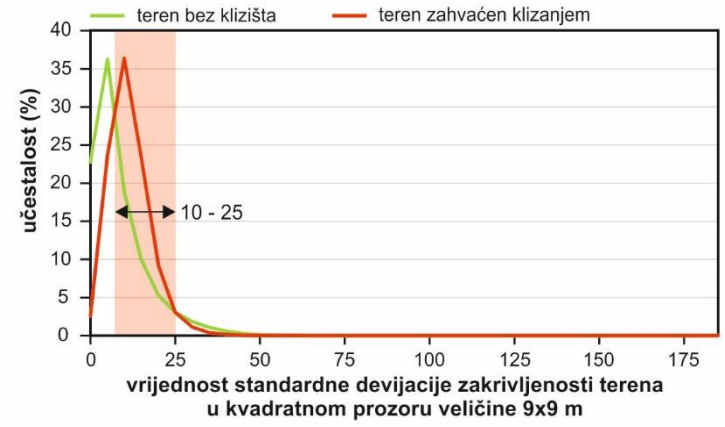

Slika 7.19 Raspodjela učestalosti vrijednosti standardne devijacije zakrivljenosti terena dobivene kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

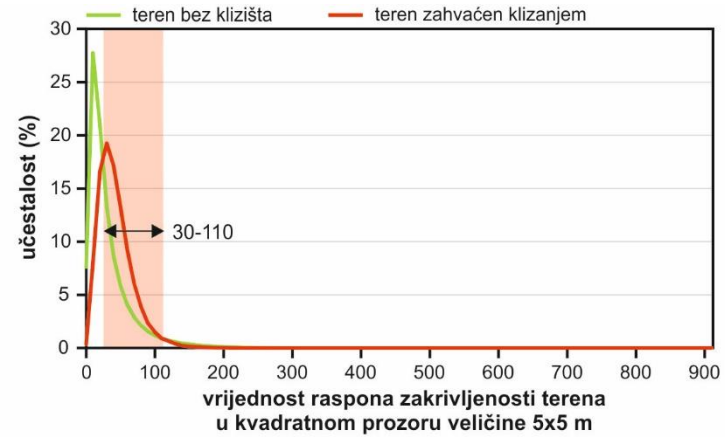

Slika 7.20 Raspodjela učestalosti vrijednosti raspona zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

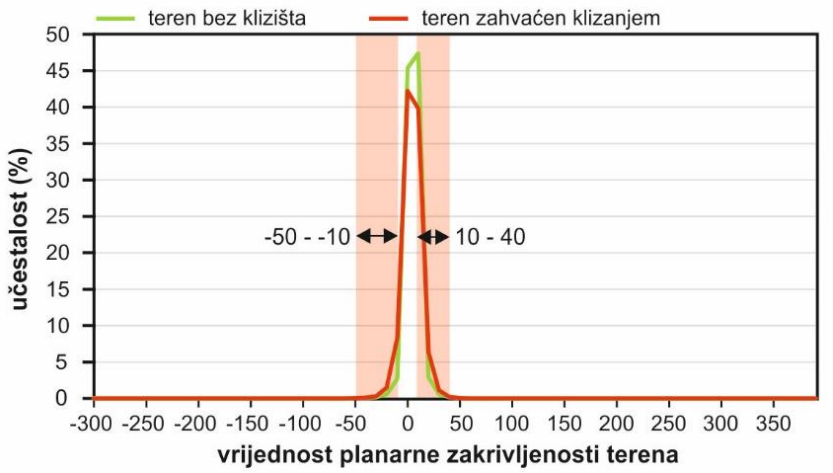

Slika 7.21 Raspodjela učestalosti vrijednosti planarne zakrivljenosti terena na terenu bez klizišta i terenu zahvaćenom klizanjem.

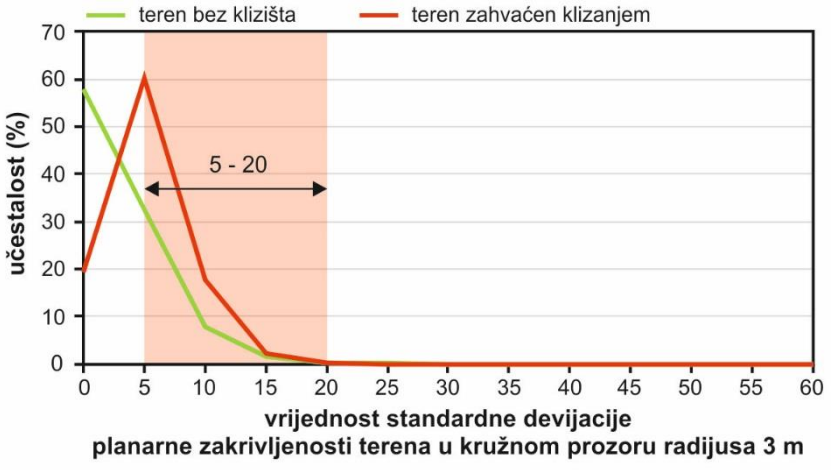

Slika 7.22 Raspodjela učestalosti vrijednosti standardne devijacije planarne zakrivljenosti terena dobivene kružnim prozorom radijusa 3 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

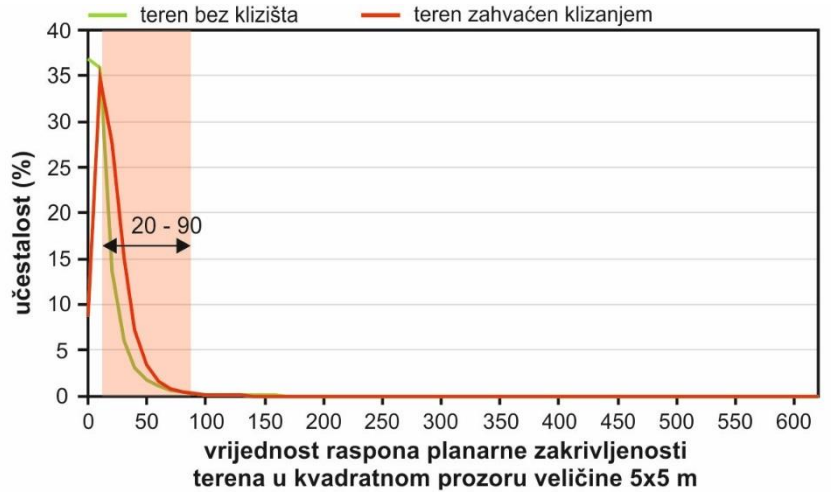

Slika 7.23 Raspodjela učestalosti vrijednosti raspona planarne zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5 m terenu bez klizišta i terenu zahvaćenom klizanjem.

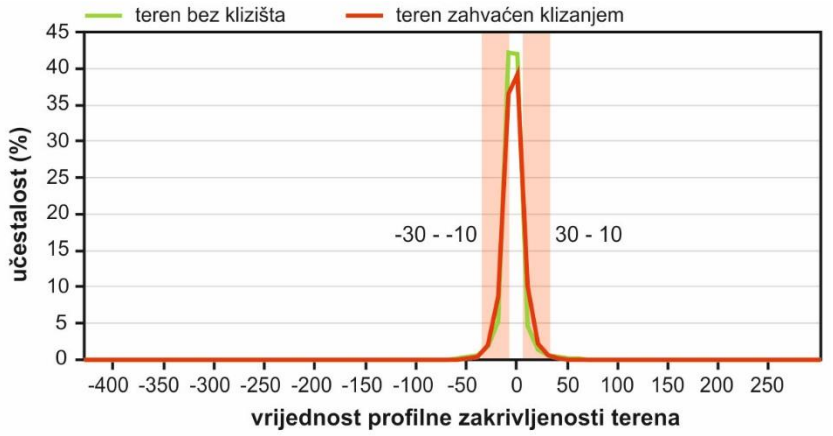

Slika 7.24 Raspodjela učestalosti vrijednosti profilne zakrivljenosti terena na terenu bez klizišta i terenu zahvaćenom klizanjem.

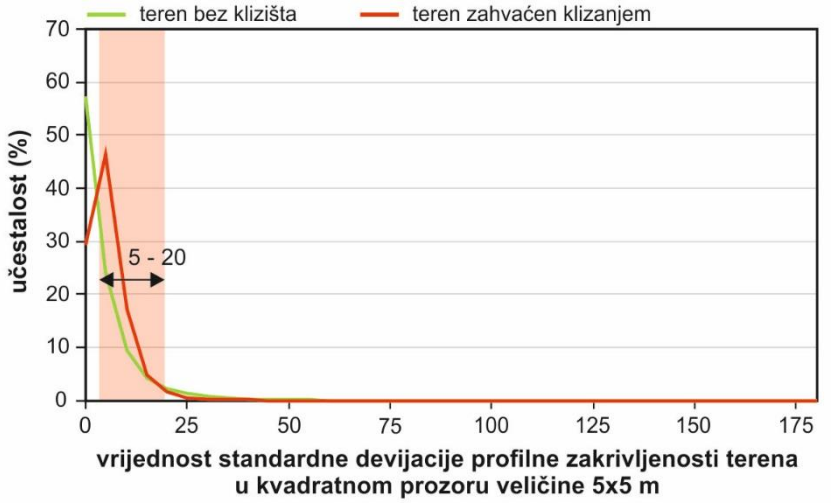

Slika 7.25 Raspodjela učestalosti vrijednosti standardne devijacije profilne zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

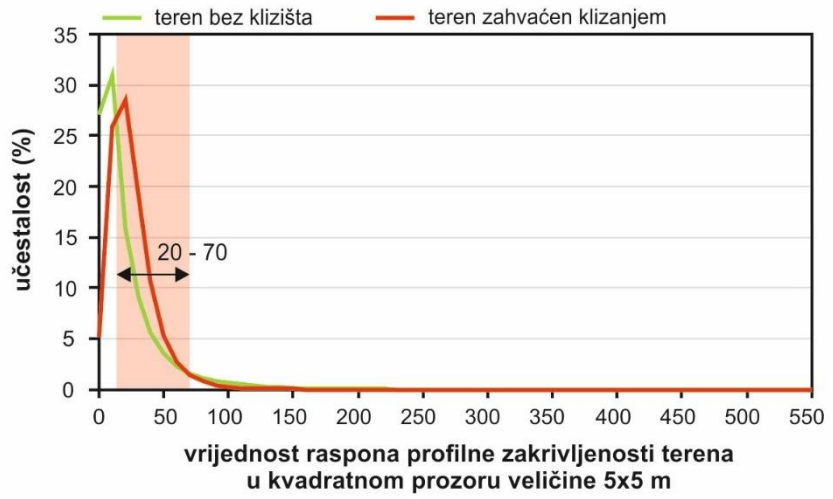

Slika 7.26 Raspodjela učestalosti vrijednosti raspona profilne zakrivljenosti terena dobivene kvadratnim prozorom veličine 5x5m na terenu bez klizišta i terenu zahvaćenom klizanjem.

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti za sve 44 izvedene morfometrijske karte zakrivljenosti terena navedeni su u tablici 7.6. Analizom podudarnosti šest karata zakrivljenosti terena utvrđeno je da najviši indeks podudarnosti ima karata dobivena kvadratnim prozorom veličine 9x9 m (6,60 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 5 m (3,08 %). Od ukupno šest karata standardne devijacije zakrivljenosti terena najviši indeks podudarnosti ima karata standardne devijacije zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m (6,84 %), a najniži indeks podudarnosti ima karta standardne devijacije zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m (5,19 %). Analizom šest karata raspona zakrivljenosti terena utvrđeno je da najviši indeks podudarnosti ima karata raspona zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m (6,27 %), a najniži indeks podudarnosti ima karta raspona zakrivljenosti terena dobivena kružnim prozorom radijusa 10m (5,77 %). Karta planarne zakrivljenosti terena ima indeks podudarnosti od 6,15 %. Od ukupno šest karata standardne devijacije planarne zakrivljenosti terena najviši indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 3 m (7,26 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 10 m (6,59 %). Analizom šest karata raspona planarne zakrivljenosti terena utvrđeno je da najviši indeks podudarnosti ima karta dobivena kvadratnim prozorom veličine 5x5 m (6,93 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 10m (5,56 %). Karta profilne zakrivljenosti terena ima indeks podudarnosti od 5,06 %. Od ukupno šest karata standardne devijacije profilne zakrivljenosti terena najviši indeks podudarnosti ima karata dobivena kvadratnim prozorom veličine 5x5 m (6,18 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 9 m (5,55 %). Analizom podudarnosti šest karata raspona profilne zakrivljenosti terena utvrđeno je da najviši indeks podudarnosti ima karata dobivena kvadratnim prozorom veličine 5x5 m (6,18 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 5 m (5,47 %).

S obzirom na indeks podudarnosti, karta zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m (crv_fr9) s graničnom vrijednosti od -0,4 do -0,04 i 0,6–0,22, karta standardne devijacije zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m (std_crv_fr9) s graničnim vrijednostima 10–25, karta raspona zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m (rng_crv_fr5) s graničnim vrijednostima 30–110, karta planarne zakrivljenosti terena (cplan) s graničnom vrijednosti od -50 do -10 i 10–40, karta standardne

devijacije planarne zakrivljenosti terena dobivena kružnim prozorom radijusa 3 m (std_cplan_fc3) s graničnim vrijednostima 10–25, karta raspona planarne zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m (rng_cplan_fr5) s graničnim vrijednostima 20–90, karta profilne zakrivljenosti terena (cprf) s graničnom vrijednosti od -30 do -10 i 10–30, karta standardne devijacije profilne zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m (std_cprf_fr5) s graničnim vrijednostima 5–20 i karta raspona profilne zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m (rng_cprf_fr5) s graničnim vrijednostima 20–70 odabrane su kao predikcijske karte za automatizirano kartiranje klizišta. Na slikama 7.27 i 7.28 prikazana je prostorna raspodjela vrijednosti devet morfometrijskih parametara zakrivljenosti terena s najvišim indeksom podudarnosti u odnosu na klizišta kartirana vizualnom interpretacijom LiDAR DMT-a.

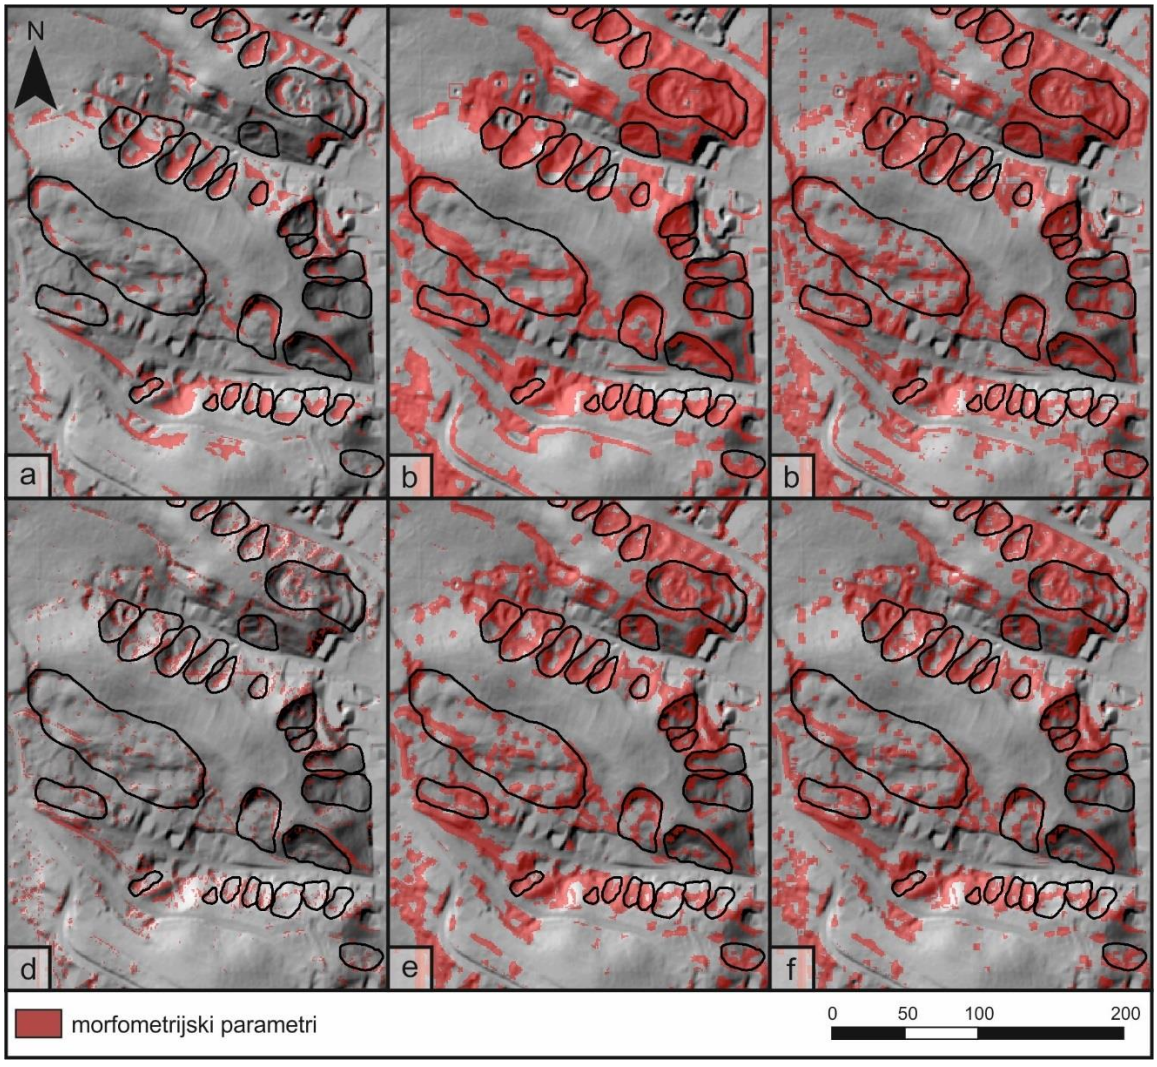

Slika 7.27 Preklop karata morfometrijskih parametara zakrivljenosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) zakrivljenost terena (crv_fr9) (b) standardna devijacija zakrivljenosti terena (std_crv_fr9); (c) raspon zakrivljenosti terena (rng_crv_fr5); (d) planarna zakrivljenost terena (cplan); (e) standardna devijacija planarne zakrivljenosti terena (std_cplan_fc3); (f) raspon planarne zakrivljenosti terena (rng_cplan_fr5).

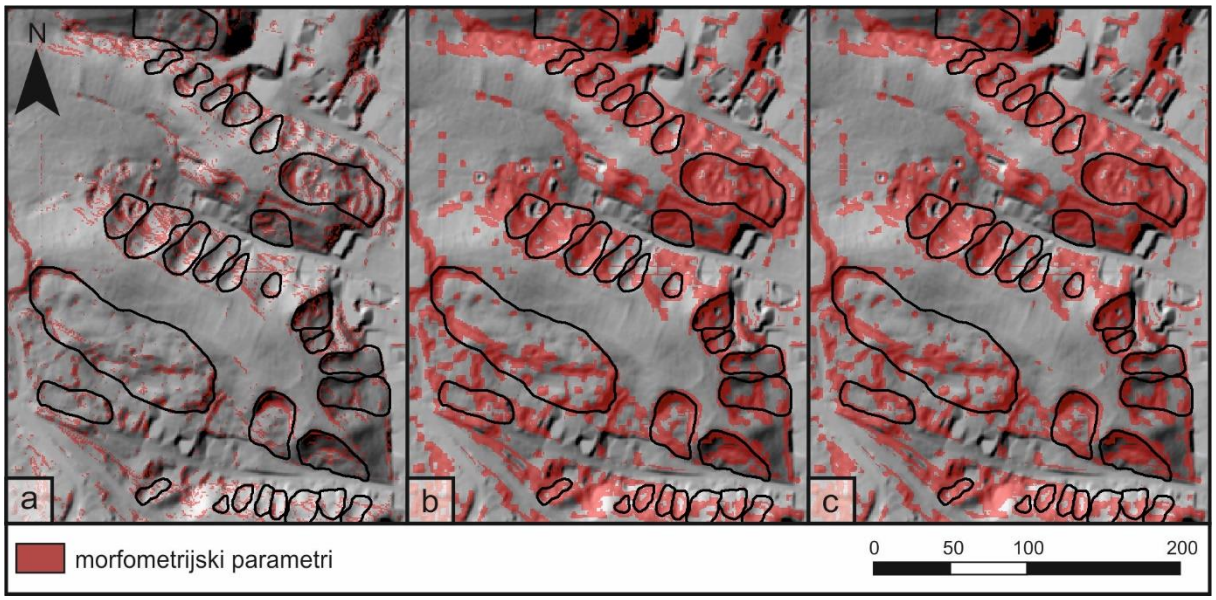

Slika 7.28 Preklop karata morfometrijskih parametara zakrivljenosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) profilna zakrivljenost terena (cprf) (b) standardna devijacija profilne zakrivljenosti terena (std_cprf_fr5); (c) raspon profilne zakrivljenosti terena (rng_cprf_fr5).

7.1.6 Morfometrijske karte hrapavosti terena

U grupi izvedenih morfometrijskih karata hrapavosti terena ukupno je analizirano 25 karata: šest karata hrapavosti terena izvedene prema Riley et al. (1999), šest karata relativnog položaja terena, šest karata standardne devijacije nadmorske visine prema Ascione et al. (2008), šest karata indeksa hrapavosti prema Nellemann i Fry (1995) i karta 3D i 2D omjera terena prema Berry (2002). Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za sve izvedene karte hrapavosti terena prikazani su u tablici 7.7. Na slikama 7.29 do 7.33 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem za svaku od podgrupa morfometrijskih karata hrapavosti terena.

Tablica 7.7 Granične vrijednosti grupe morfometrijskih karata hrapavosti terena.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	hrapavost terena dobivena kvadratnim prozorom veličine 3x3 m	rgh_fr3	0,5-1,05	6,80 %
	hrapavost terena dobivena kvadratnim prozorom veličine 5x5 m	rgh_fr5	0,7-1,35	7,46 %
	hrapavost terena dobivena kvadratnim prozorom veličine 9x9 m	rgh_fr9	0,9-1,75	6,57 %
	hrapavost terena dobivena kružnim prozorom radijusa 3 m	rgh_fc3	0,7-1,4	7,06 %
	hrapavost terena dobivena kružnim prozorom radijusa 5 m	rgh_fc5	0,85-1,65	6,56 %
	hrapavost terena dobivena kružnim prozorom radijusa 9 m	rgh_fc9	1,15-2,3	6,41 %
2	relativan položaj terena dobiven kvadratnim prozorom veličine 3x3 m	rtp_fr3	0,42-0,49; 0,51-0,56	3,94 %
	relativan položaj terena dobiven kvadratnim prozorom veličine 5x5 m	rtp_fr5	0,38-0,48; 0,52-0,59	4,11 %
	relativan položaj terena dobiven kvadratnim prozorom veličine 9x9 m	rtp_fr9	0,35-0,49; 0,52-0,58	4,10 %
	relativan položaj terena dobiven kružnim prozorom radijusa 3 m	rtp_fc3	0,4-0,5; 0,52-0,6	3,99 %
	relativan položaj terena dobiven kružnim prozorom radijusa 5 m	rtp_fc5	0,39-0,48; 0,54-0,6	4,11 %
	relativan položaj terena dobiven kružnim prozorom radijusa 9 m	rtp_fc9	0,35-0,51; 0,53-0,57	4,07 %
3	karta hrapavosti terena prema Ascione et al. (2008) dobivena kvadratnim prozorom veličine 3x3 m	rgh_a_fr3	-0,1 - 0,02	3,57 %
	karta hrapavosti terena prema Ascione et al. (2008) dobivena kvadratnim prozorom veličine 5x5 m	rgh_a_fr5	-0,06 - -0,02; 0,02 - 0,1	4,13 %
	karta hrapavosti terena prema Ascione et al. (2008) dobivena kvadratnim prozorom veličine 9x9 m	rgh_a_fr9	-0,02 - 0,16	4,79 %
	karta hrapavosti terena prema Ascione et al. (2008) dobivena kružnim prozorom radijusa 3 m	rgh_a_fc3	-0,06 - -0,04; 0,02-0,1	4,18 %
	karta hrapavosti terena prema Ascione et al. (2008) dobivena kružnim prozorom radijusa 5 m	rgh_a_fc5	-0,12 - -0,02	3,06 %
	karta hrapavosti terena prema Ascione et al. (2008) dobivena kružnim prozorom radijusa 9 m	rgh_a_fc9	0-0,14	4,54 %
4	indeks hrapavosti terena dobiven kvadratnim prozorom veličine 3x3 m	tri_ril_fr3	17-38,5	5,76 %
	indeks hrapavosti terena dobiven kvadratnim prozorom veličine 5x5 m	tri_ril_fr5	24,5-54	5,86 %
	indeks hrapavosti terena dobiven kvadratnim prozorom veličine 9x9 m	tri_ril_fr9	34,5-77	5,65 %
	indeks hrapavosti terena dobiven kružnim prozorom radijusa 3 m	tri_ril_fc3	26,5-55	5,96 %
	indeks hrapavosti terena dobiven kružnim prozorom radijusa 5 m	tri_ril_fc5	33-69	5,75 %
	indeks hrapavosti terena dobiven kružnim prozorom radijusa 9 m	tri_ril_fc9	45,5-90,5	5,69 %
5	omjer 3D i 2D površine terena	sar	1,1-1,7	8,67 %

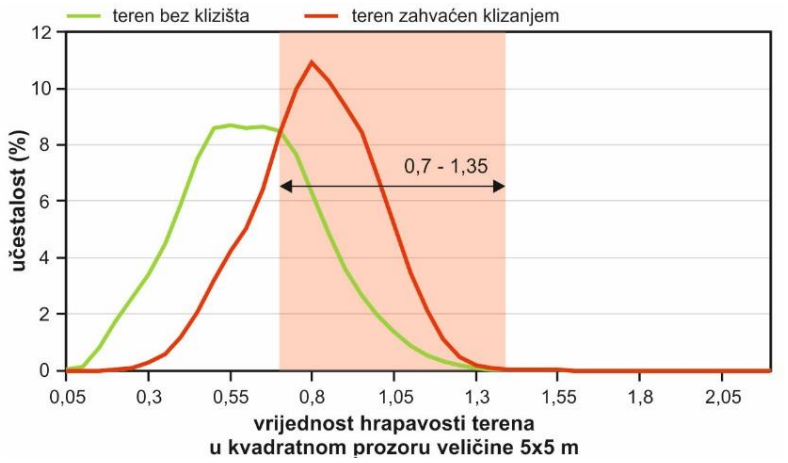

Slika 7.29 Raspodjela učestalosti vrijednosti hrapavosti terena dobivene kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

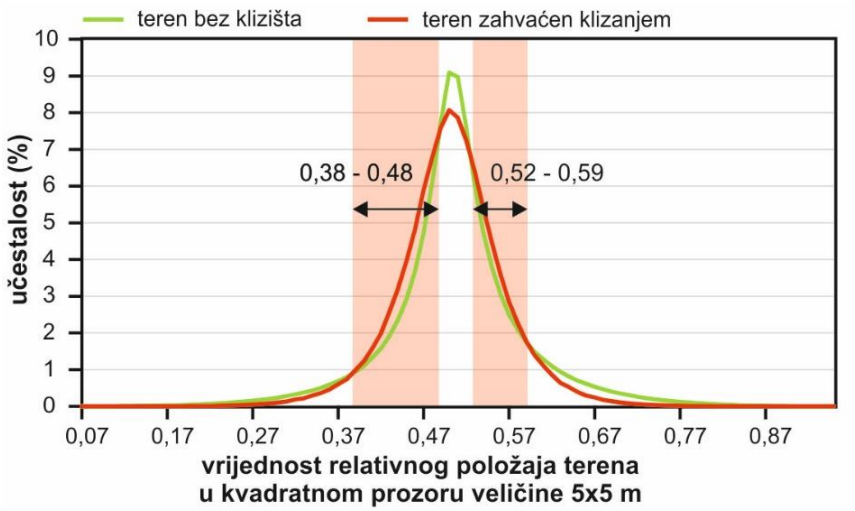

Slika 7.30 Raspodjela učestalosti vrijednosti relativnog položaja terena dobivenog kvadratnim prozorom veličine 5x5 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

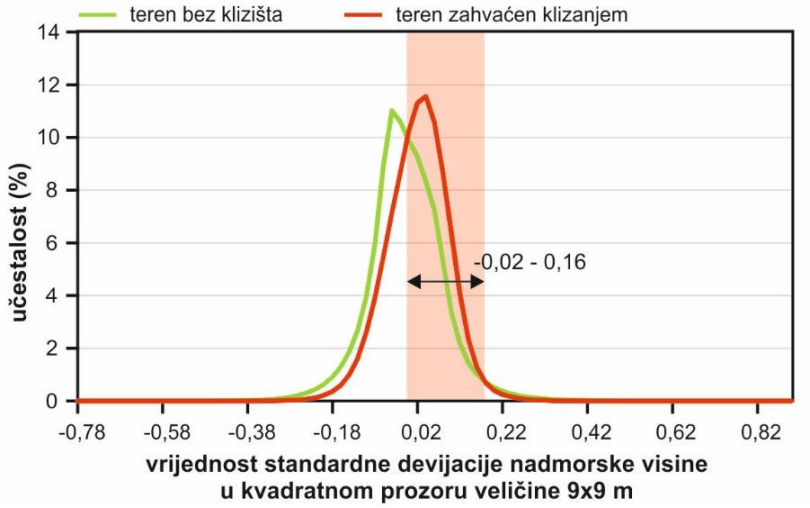

Slika 7.31 Raspodjela učestalosti vrijednosti hrapavosti terena Ascione et al. (2008) dobivena kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

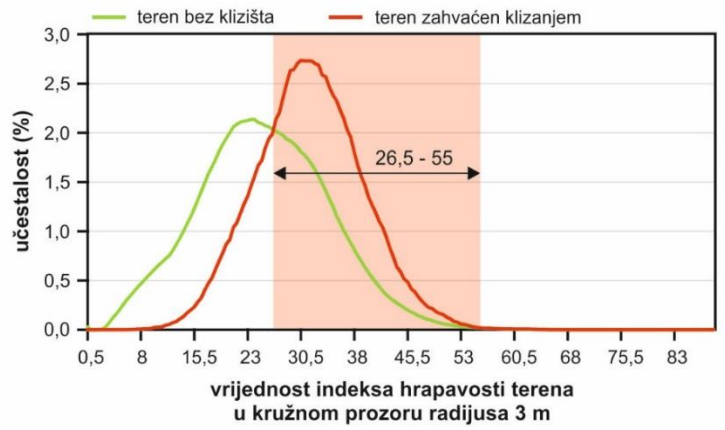

Slika 7.32 Raspodjela učestalosti vrijednosti indeksa hrapavosti terena dobivene kružnim prozorom radijusa 3 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

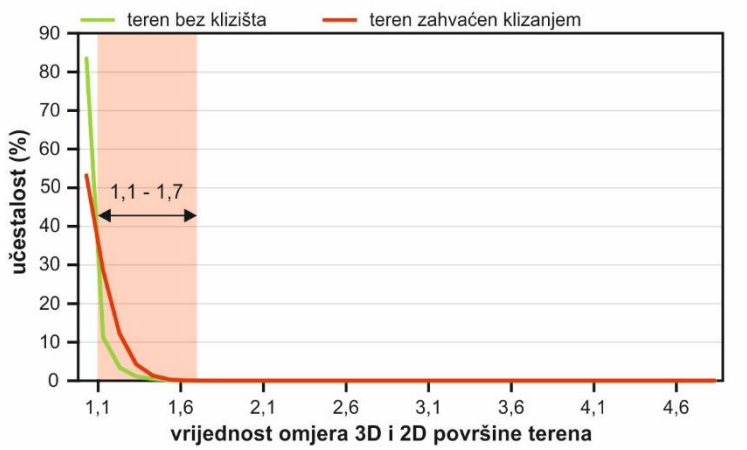

Slika 7.33 Raspodjela učestalosti vrijednosti omjera 3D i 2D površine terena na terenu bez klizišta i terenu zahvaćenom klizanjem.

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti za svih 25 izvedenih morfometrijskih karte hrapavosti terena navedeni su u tablici 7.7. Rezultat analize podudarnosti je da od šest karata hrapavosti terena najviši indeks podudarnosti ima karata dobivena kvadratnim prozorom veličine 5x5 m (7,46 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 10 m (6,41 %). Od ukupno šest karata relativnog položaja terena najviši indeks podudarnosti ima karata dobivena kvadratnim prozorom veličine 5x5 m (4,11 %), a najniži indeks podudarnosti ima karta dobivena kvadratnim prozorom veličine 3x3 m (3,94 %). Analizom šest karata hrapavosti terena prema Ascione et al. (2008) utvrđeno je da najviši indeks podudarnosti ima karata dobivena kvadratnim prozorom veličine 9x9 m (4,79 %), a najniži indeks podudarnosti ima karta dobivena kružnim prozorom radijusa 5 m (3,06 %). Od šest karata indeksa hrapavosti terena najviši indeks podudarnosti ima karata dobivena kružnim

prozorom radijusa 3 m (5,96 %), a najniži indeks podudarnosti ima karta dobivena kvadratnim prozorom veličine 9x9 m (5,65 %). Od svih analiziranih karata u grupi karata hrapavosti terena, karta omjera 3D i 2D površine terena ima najviši indeks podudarnosti (8,67 %) s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a.

S obzirom na indeks podudarnosti, karta hrapavosti terena dobivena kvadratnim prozorom veličine 5x5 m (rgh_fr5) s graničnom vrijednosti od 0,7-1,35, karata relativnog položaja terena dobivena kvadratnim prozorom veličine 5x5 m (rtp_fr5) s graničnim vrijednostima 0,38-0,48 i 0,52-0,59, karta hrapavosti terena prema Ascione et al. (2008) dobivena kvadratnim prozorom veličine 9x9 m (rgh_a_fr9) s graničnim vrijednostima od -0,02 do 0,16, karta indeksa hrapavosti terena dobivena kružnim prozorom radijusa 3 m (tri_ril_fc3) s graničnom vrijednosti 26,5-55 i karta omjera 3D i 2D površine terena (sar) s graničnim vrijednostima 1,1-1,7 odabrane su kao predikcijske karte za automatizirano kartiranje klizišta. Na slici 7.34 prikazana je prostorna raspodjela vrijednosti pet morfometrijskih parametara hrapavosti terena s najvišim indeksom podudarnosti u odnosu na klizišta kartirana vizualnom interpretacijom LiDAR DMT-a.

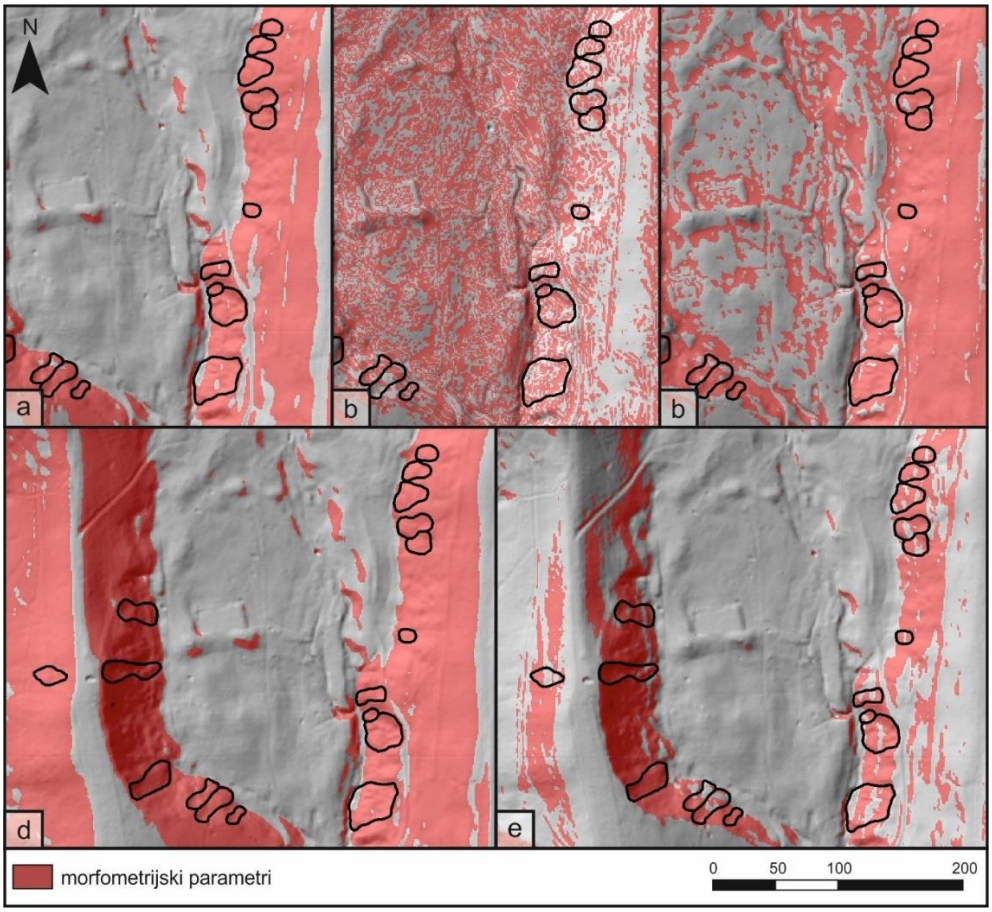

Slika 7.34 Preklop karata morfometrijskih parametara hrapavosti terena s najvišim indeksom podudarnosti i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) hrapavost terena (rgh_fr5) (b) relativan položaj terena (rtp_fr5); (c) hrapavost terena prema Ascione et al. (2008) (rgh_a_fr9); (d) indeks hrapavosti terena (tri_ril_fc3); (e) omjer 3D i 2D površine terena (sar).

7.1.7 Morfometrijske karte vlažnosti terena

U grupi izvedenih morfometrijskih karata vlažnosti terena analizirane su karta vlažnosti terena izvedena prema Moore et al. (1993) i karta osunčanosti terena prema McCune i Keon (2002). Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za obje izvedene karte vlažnosti terena prikazani su u tablici 7.8. Na slikama 7.35 i 7.36 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem na izvedenim kartama vlažnosti i osunčanosti terena.

Tablica 7.8 Granične vrijednosti grupe morfometrijskih karata vlažnosti.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	indeks vlažnosti terena	cti	3-6,5	4,72 %
2	indeks osunčanosti terena	hli	0,2-0,58 ; 0,9 -1,1	7,07 %

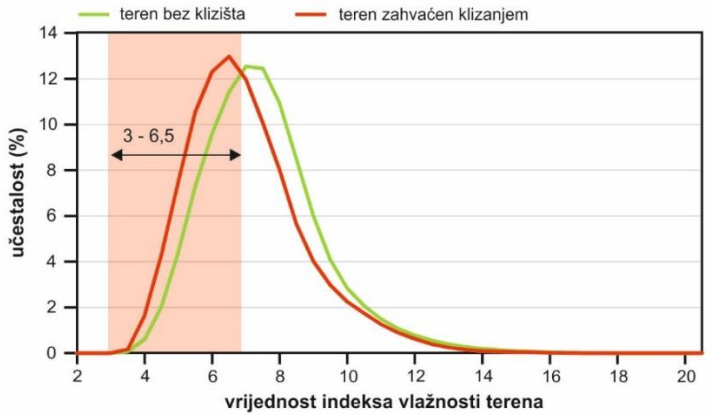

Slika 7.35 Raspodjela učestalosti vrijednosti indeksa vlažnosti na terenu bez klizišta i terenu zahvaćenom klizanjem.

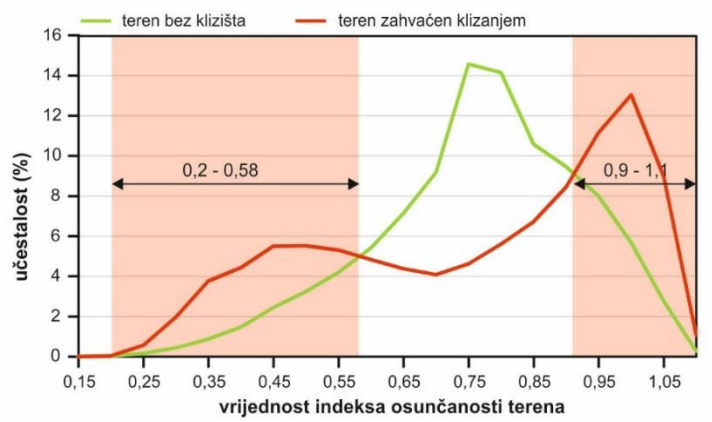

Slika 7.36 Raspodjela učestalosti vrijednosti indeksa osunčanosti na terenu bez klizišta i terenu zahvaćenom klizanjem.

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti za dvije izvedene morfometrijske karte vlažnosti terena navedeni su u tablici 7.8. Analiza podudarnosti pokazala je da od karta vlažnosti terena (cti) s graničnom vrijednosti 3-6,5 ima indeks podudarnosti 4,72 %, a karta osunčanosti terena (hli) s graničnom vrijednosti 0,2-0,58 i 0,9-1,1 ima indeks podudarnosti 7,07 % s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Obje karte iz grupe morfometrijskih karata vlažnosti terena koristit će se kao predikcijske karte za automatizirano kartiranje klizišta. Na slici 7.37 prikazana je prostorna raspodjela vrijednosti dvaju morfometrijskih parametara vlažnosti terena u odnosu na klizišta kartirana vizualnom interpretacijom LiDAR DMT-a.

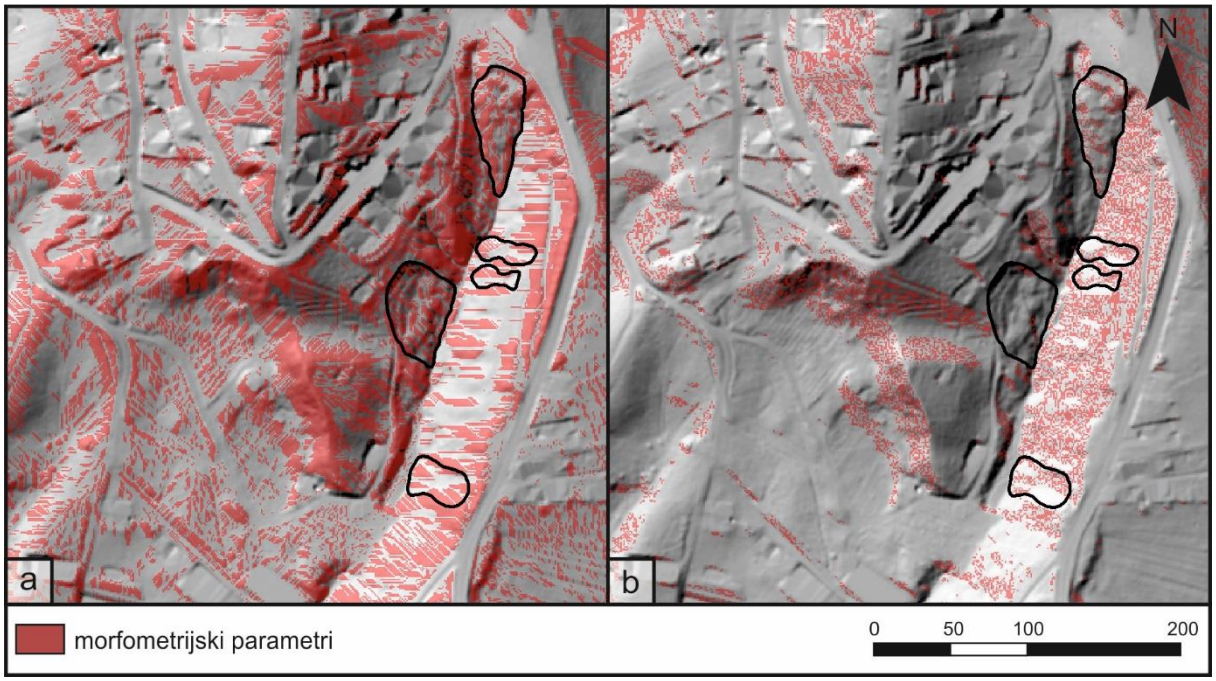

Slika 7.37 Preklop karata morfometrijskih parametara vlažnosti terena i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a: (a) vlažnost terena (cti); (b) osunčanost terena (hli).

7.1.8 Morfometrijska karta raščlanjenosti terena

U grupi izvedenih morfometrijskih karata raščlanjenosti terena analizirano je šest karta izvedenih prema Evans et al., (1972). Rezultati analize raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem, odnosno granične vrijednosti morfometrijskih parametara koje ukazuju na nepravilnu morfologiju klizišta za šest izvedenih karata raščlanjenosti terena prikazani su u tablici 7.9. Na slici 7.38 prikazan je primjer raspodjele učestalosti morfometrijskih vrijednosti na terenu bez klizišta i terenu zahvaćenom klizanjem na izvedenim kartama raščlanjenosti terena.

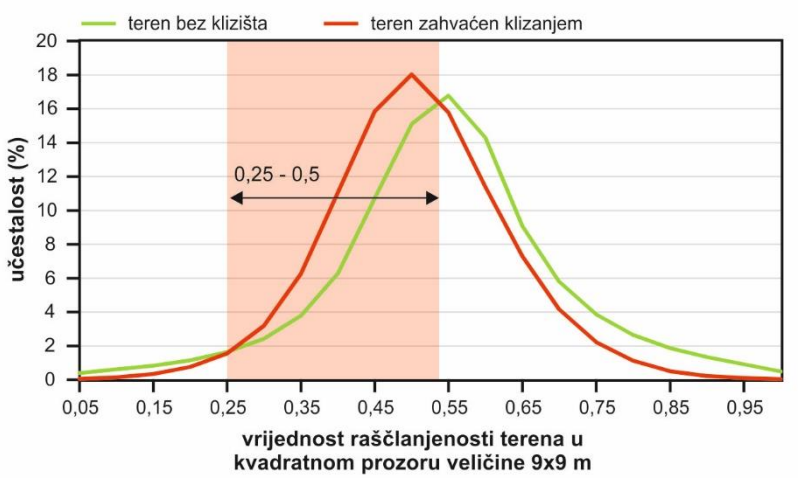

Slika 7.38 Raspodjela učestalosti vrijednosti raščlanjenosti terena dobivene kvadratnim prozorom veličine 9x9 m na terenu bez klizišta i terenu zahvaćenom klizanjem.

Tablica 7.9 Granične vrijednosti morfometrijskih karata raščlanjenosti terena.

Morfometrijske karte		Oznaka karte	Granična vrijednost	Indeks podudarnosti, M
1	raščlanjenost terena dobivena kvadratnim prozorom veličine 3x3 m	diss_fr3	0,35-0,6	3,91 %
	raščlanjenost terena dobivena kvadratnim prozorom veličine 5x5 m	diss_fr5	0,3-0,5 ; 0,55-0,65	4,04 %
	raščlanjenost terena dobivena kvadratnim prozorom veličine 9x9 m	diss_fr9	0,25-0,5	4,83 %
	raščlanjenost terena dobivena kružnim prozorom radijusa 3 m	diss_fc3	0,3-0,5; 0,55-0,65	4,05 %
	raščlanjenost terena dobivena kružnim prozorom radijusa 5 m	diss_fc5	0,3-0,5; 0,55-0,65	4,12 %
	raščlanjenost terena dobivena kružnim prozorom radijusa 9 m	diss_fc9	0,25-0,5	4,54 %

Na temelju definiranih graničnih vrijednosti kreirane su karte morfometrijskih parametara za koje je provedena analiza podudarnosti s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. Indeksi podudarnosti za svih 6 izvedenih morfometrijskih karata raščlanjenosti terena navedeni su u tablici 7.9. Analiza podudarnosti pokazala je da karta raščlanjenosti terena dobivena kvadratnim prozorom veličine 9x9 m ima najviši indeks podudarnosti (4,83 %), a karta dobivena kvadratnim prozorom veličine 3x3 m ima najniži indeks podudarnosti (3,91 %) s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. S obzirom na rezultate analize podudarnosti, kao predikcijska karta za automatizirano kartiranje klizišta koristiti će se karta raščlanjenosti terena dobivena kvadratnim prozorom veličine 9x9 m s graničnom vrijednosti 0,25-0,5 (slika 7.39).

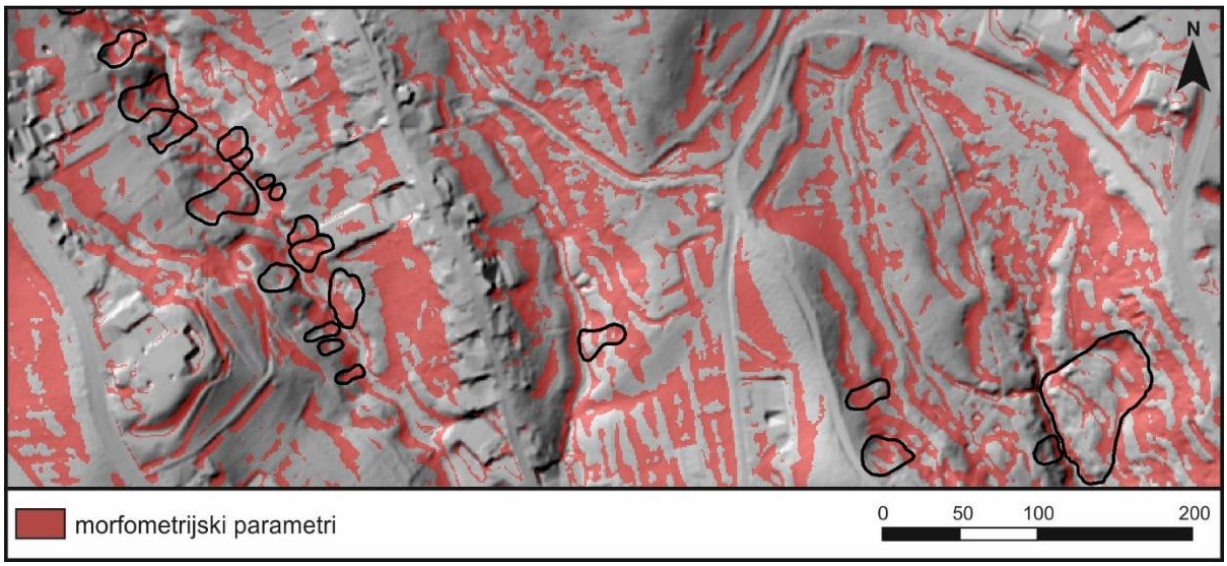

Slika 7.39 Preklop karte morfometrijskog parametara raščlanjenosti terena (diss_fr9) i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a.

7.2 Zbrajanje predikcijskih karata i izrada konačne karte inventara klizišta

Drugi korak izrade modela za automatizirano kartiranje klizišta je zbrajanje predikcijskih karata koje je provedeno primjenom dviju metoda: (a) zbrajanje svih predikcijskih karata i reklasifikacija rezultirajućih vrijednosti radi dobivanja konačne karte inventara klizišta s najvišim parametrima točnosti i (b) kombiniranje predikcijskih karata primjenom *stepwise* metode (van Westen et al., 1993) koje uključuje odabir karata za zbrajanje, njihovo zbrajanje i reklasifikacija. U tablici 7.10 navedeno je svih 28 predikcijskih karata s definiranim graničnim morfometrijskim vrijednostima koje ukazuju na nepravilnu morfologiju klizišta na testnom području površine 10,5 km^2. Analiza preklapanja karata morfometrijskih parametara i vizualno kartiranih klizišta pokazala je da karta omjera 2D i 3D površine terena ponajviše ukazuje na morfologiju klizišta s obzirom na najviši indeks podudarnosti (M=8,67 %). Idući od viših indeksa podudarnosti prema nižima, slijede morfometrijski parametri izvedeni iz karata nadmorskih visina, odnosno standardna devijacija nadmorske visine dobivena kvadratnim prozorom veličine 3x3 m (M=7,68 %) i raspon vrijednosti nadmorske visine dobiven kružnim prozorom radijusa 5 m (M=7,50 %). Druge značajnije predikcijske karte su karta gustoća slojnica ekvidistancije 0,5 m dobivena kružnim prozorom radijusa 10 m (M=7,48 %), karta hrapavosti terena dobivena kvadratnim prozorom veličine 5x5 m izrađena metodom prema Riley et al. (1999) (M=7,46 %) te karta indeksa položaja dobivena SIN metodom (M=7,44 %). Najniži indeks podudarnosti (M<5 %) s vizualno kartiranim klizištima imaju karta raščlanjenost

terena dobivena kružnim prozorom radijusa 10 m (M=4,83 %), karta standardne devijacije nadmorskih visina dobivena kvadratnim prozorom veličine 9x9 m (M=4,79 %), karta indeksa vlažnosti terena (M=4,72 %) i karta relativnog topografskog položaja dobivena kvadratnim prozorom veličine 5x5 m (M=4,11 %).

Tablica 7.10 Predikcijske karte modela za automatizirano kartiranje klizišta s navedenim graničnim vrijednostima i stupnjem kartografske podudarnosti s vizualno kartiranim klizištima.

Br.	Glavna morfometrijska grupa	Predikcijske karte	Oznaka	Granične vrijednosti	Indeks podudarnosti, M
1	karte hrapavosti terena	omjer 3D i 2D površine terena	sar	1,1-1,7	8,67 %
2	karte nadmorskih visina	standardna devijacija nadmorske visine dobivena kvadratnim prozorom veličine 3x3 m	std_DMT_fr3	0,3-1,1	7,68 %
3	karte nadmorskih visina	raspon vrijednosti nadmorske visine dobivena kružnim prozorom radijusa 5 m	rng_DMT_fc5	3,25-11	7,50 %
4	karte slojnica	gustoća slojnica ekvidistancije 0,5 m dobivena kružnim prozorom radijusa 9 m	con_1m_r9m	0,65-2,25	7,48 %
5	karte hrapavosti terena	hrapavost terena dobivena kvadratnim prozorom veličine 5x5 m	rgh_fr5	0,7-1,35	7,46 %
6	karte nagiba terena	indeks položaja dobiven metodom SIN	sat_sin	-1,05 - -0,25; 0,3-1,05	7,44 %
7	karte zakrivljenosti terena	standardna devijacija planarne zakrivljenosti terena dobivena kružnim prozorom radijusa 3 m	std_cplan_fc3	5-20	7,26 %
8	karte nagiba terena	nagib terena	slp	18-52	7,12 %
9	karte vlažnosti terena	indeks osunčanosti terena	hli	0,2-0,58; 0,9 -1,1	7,07 %
10	karte zakrivljenosti terena	raspon vrijednosti planarne zakrivljenosti terena dobiven kvadratnim prozorom veličine 5x5 m	rng_cplan_fr5	20-90	6,93 %
11	karte zakrivljenosti terena	standardna devijacija zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m	std_crv_fr9	10-25	6,84 %
12	karte zakrivljenosti terena	zakrivljenosti terena dobivena kvadratnim prozorom veličine 9x9 m	crv_fr9	-0,4 - -0,04; 0,6 - 0,22	6,60 %
13	karte zakrivljenosti terena	raspon vrijednosti zakrivljenosti terena dobiven kvadratnim prozorom veličine 9x9 m	rng_crv_fr5	30-110	6,27 %
14	karte nagiba terena	standardna devijacija nagiba terena dobivena kružnim prozorom radijusa 5 m	std_slp_fc5	3-9,5	6,20 %
15	karte zakrivljenosti terena	raspon vrijednosti profilne zakrivljenosti terena dobiven kvadratnim prozorom veličine 5x5 m	rng_cprf_fr5	20-70	6,18 %
16	karte zakrivljenosti terena	standardna devijacija profilne zakrivljenosti terena dobivena kvadratnim prozorom veličine 5x5 m	std_cprf_fr5	5-20	6,18 %

Nastavak **tablice 7.10.**

Br.	Glavna morfometrijska grupa	Predikcijske karte	Oznaka	Granične vrijednosti	Indeks podudarnosti, M
17	karte zakrivljenosti terena	planarna zakrivljenost terena	cplan	-50 - -10; 10-40	6,15 %
18	karte nagiba terena	relativan nagib terena dobiven kvadratnim prozorom veličine 9x8 m	sp_fr9	-0,9 - -0,45	6,07%
19	karte nagiba terena	raspon vrijednosti nagiba terena dobiven kvadratnim prozorom veličine 5x5 m	rng_slp_fr5	7-28	6,06 %
20	karte hrapavosti terena	indeks hrapavosti terena dobiven kružnim prozorom radijusa 3 m	tri_ril_fc3	26,5-55	5,96 %
21	karte osjenčanosti terena	raspon vrijednosti osjenčanosti terena dobiven kvadratnim prozorom veličine 5x5 m	rng_hill_fr5	22-118	5,87 %
22	karte osjenčanosti terena	standardna devijacija osjenčanosti terena dobivena kvadratnim prozorom veličine 5x5 m	std_hill_fr5	6-36	5,82 %
23	karte nagiba terena	druga derivacija nagiba terena	slp_2nd	53-83	5,64 %
24	karte zakrivljenosti terena	profilna zakrivljenost terena	cprf	-30 - -10; 10-30	5,06 %
25	karta raščlanjenosti terena	raščlanjenost terena dobivena kružnim prozorom radijusa 9 m	diss_fr9	0,25-0,5	4,83 %
26	karte hrapavosti terena	standardna devijacija nadmorske visine dobivena kvadratnim prozorom veličine 9x9 m	rgh_a_fr9	-0,02 - 0,16	4,79 %
27	karte vlažnosti terena	indeks vlažnosti terena	cti	3-6,5	4,72 %
28	karte hrapavosti terena	relativni topografski položaj dobiven kvadratnim prozorom veličine 5x5 m	rtp_fr5	0,38-0,48; 0,52-0,59	4,11 %

Općenito se može zaključiti kako predikcijske karte izvedene iz grupe karata nadmorskih visina i karte slojnica imaju visok indeks podudarnosti (M>7,5 %), dok morfometrijski parametri izvedeni iz karte osjenčanosti imaju znatno niže kartografsko preklapanje s vizualno kartiranim klizištima (M<5,8 %). Predikacijske karte u grupi karata nagiba terena imaju indeks podudarnosti između 5,6 i 6,2 %, a iznimke su karta indeksa položaja dobivena SIN metodom (M=7,44 %) i karta nagiba terena (M=7,12 %). Predikcijske karte zakrivljenosti terena imaju stopu točnosti 6,15-6,93 %, osim karte standardne devijacije planarne zakrivljenosti terena dobivene kružnim prozorom radijusa 3 m s indeksom podudarnosti od 7,26 % te karte profilne zakrivljenosti terena s vrlo niskim indeksom podudarnosti, M=5,06 %. Od predikcijskih karata hrapavosti terena, karta omjera 3D i 2D površine terena (M=8,67 %) i karta hrapavosti terena dobivena kvadratnim prozorom veličine 5x5 m (M=7,46 %) imaju vrlo visok stupanj kartografskog preklapanja s vizualno kartiranim klizištima, a sve preostale predikcijske karte imaju indeks podudarnosti manji od 6 %.

Primjenom prve metode zbrajanja predikcijskih karata, zbrojene su sve predikcijske karte, bez obzira na stupanj kartografskog preklapanja, odnosno indeks podudarnosti s vizualno kartiranim klizištima. Dobivena karta testnog područja prikazana je na slici 7.40, a vrijednosti zbroja variraju u rasponu od 1 do 28, pri čemu vrijednost 28 označava da svih 28 predikcijskih karata ukazuje na morfologiju karakterističnu za klizišta, a vrijednost 1 da samo jedna predikcijska karta ukazuje na morfologiju klizišta u toj ćeliji.

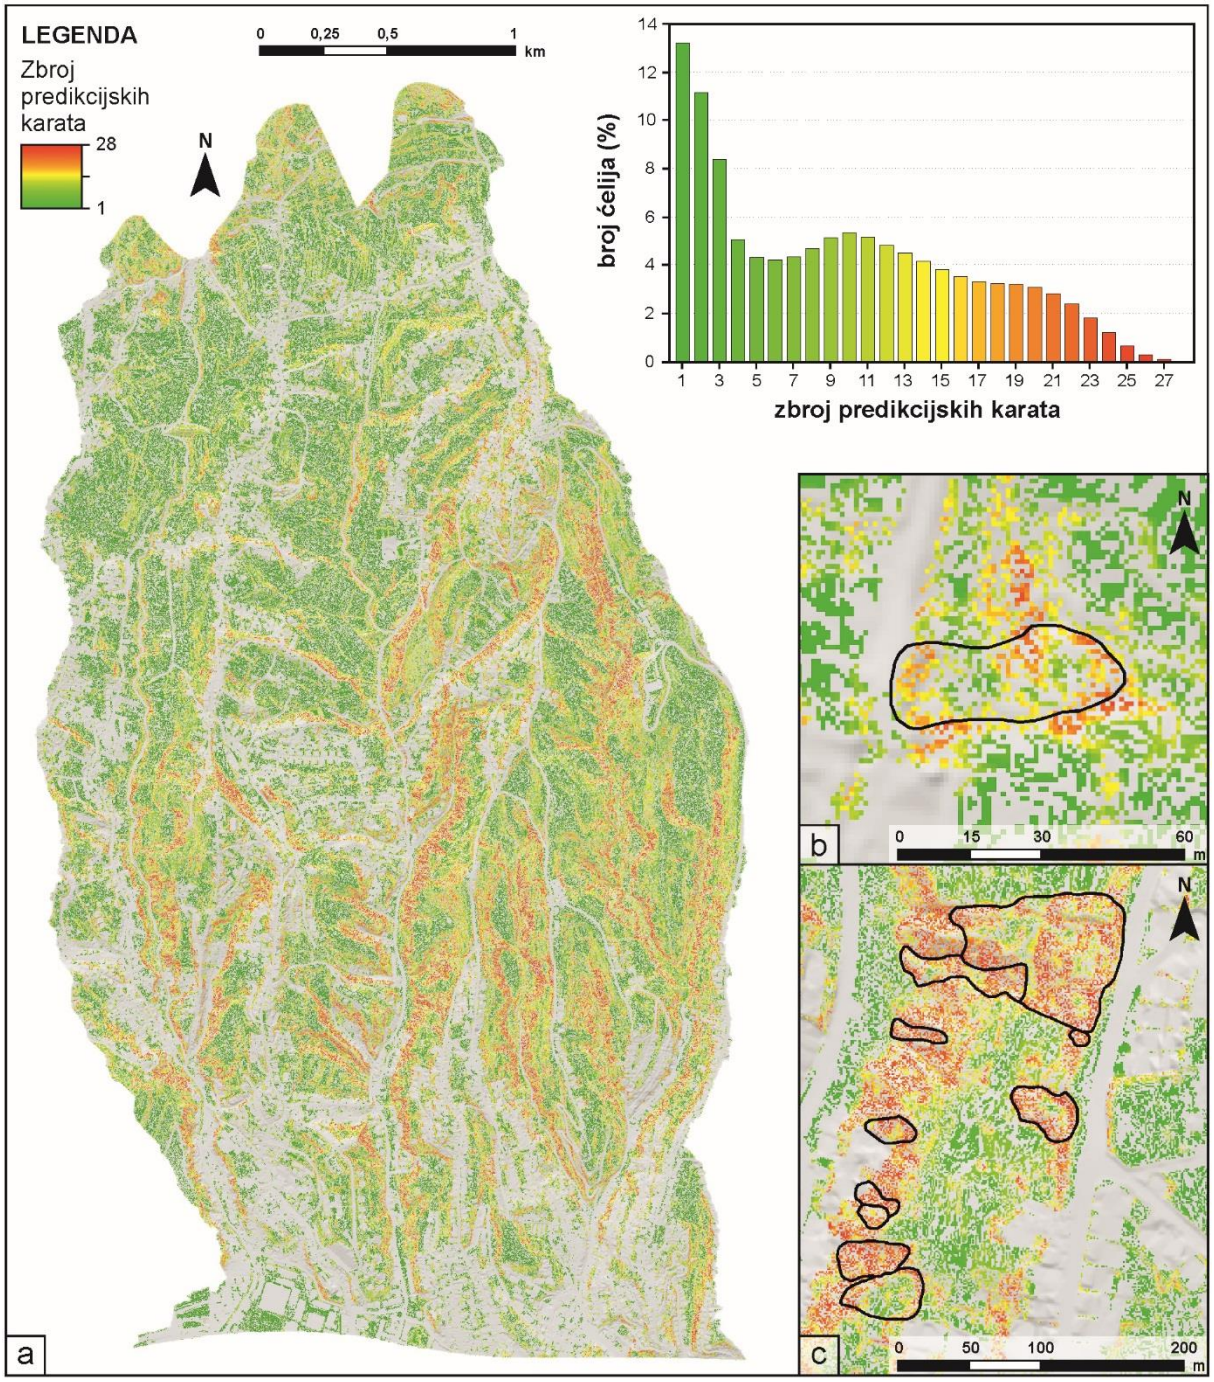

Slika 7.40 Karta klizišta izrađena na osnovi zbroja svih predikcijskih karata: (a) karta za testno područje površine 10,5 km^2 i prikaz raspodjele učestalosti vrijednosti zbroja predikcijskih karata s obzirom na broj ćelija; (b) i (c) usporedba s vizualno kartiranim klizištima.

Konačna karta inventara klizišta dobivena je reklasifikacijom vrijednosti zbroja svih predikcijskih karata koja je provedena za područja sa sumom 27 do 20, pri čemu je za svaku kartu analizirana točnost inventara automatizirano kartiranih klizišta. Najoptimalnija karta inventara odabrana je na osnovi dva parametra točnosti, a to su: (1) udio točaka točno klasificiranih kao klizišta, odnosno točaka klasificiranih kao klizišta unutar granica vizualno kartiranih klizišta; te (2) udio točno predviđenih vizualno kartiranih klizišta. Na slici 7.41 prikazana je varijabilnost parametara točnosti ovisno o odabranim graničnim vrijednostima sume za reklasifikaciju. Može se zaključiti da što je niža granična vrijednost sume, to je veći broj točaka klasificiranih kao klizište i udio točno predviđenih vizualno kartiranih klizišta. Međutim, istovremeno se smanjuje udio točaka točno klasificiranih kao klizišta, odnosno povećava se broj točaka netočno klasificiranih kao klizišta. Stoga je kao najoptimalnija karta inventara automatizirano kartiranih klizišta odabrana karta reklasificirana s obzirom na graničnu vrijednosti 26 (slika 7.42a). Karta inventara sadrži 3813 točaka klasificiranih kao klizišta, od toga se 34,9 % točaka nalazi unutar granica vizualno kartiranih klizišta, a točno je klasificirano 258 klizišta od 436 na testnom području, odnosno 59,2 %. Također, na slici 7.42b i c prikazana je usporedba automatizirano kartiranih klizišta s vizualno kartiranim klizištima.

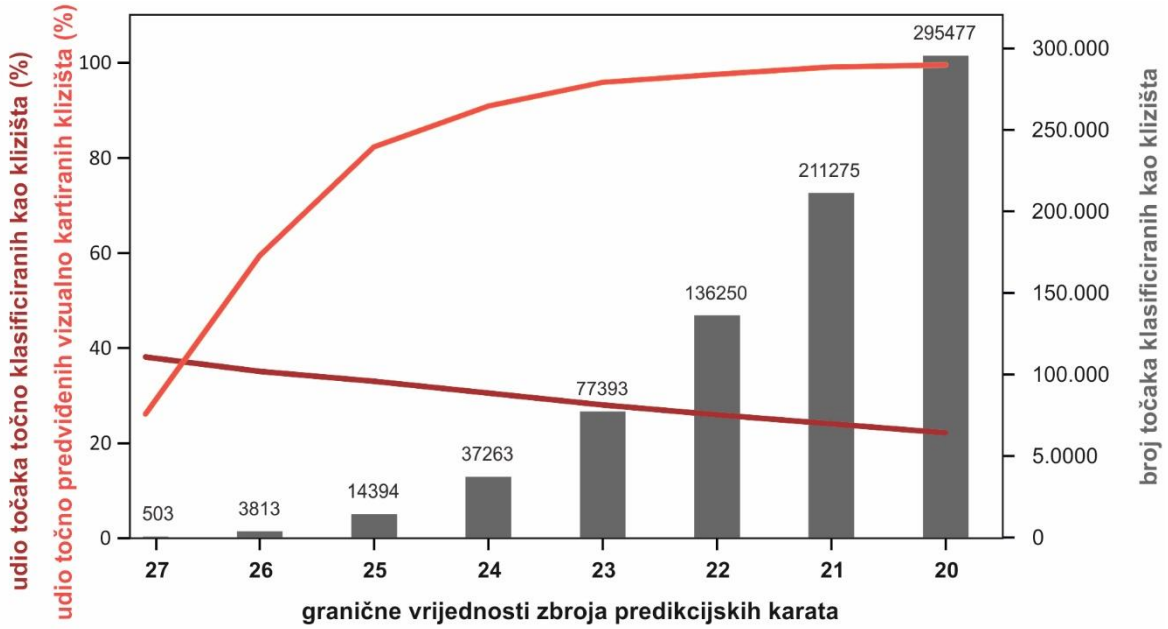

Slika 7.41 Prikaz parametara točnosti karata inventara klizišta reklasificiranih s obzirom na različite granične vrijednosti zbroja predikcijskih karata.

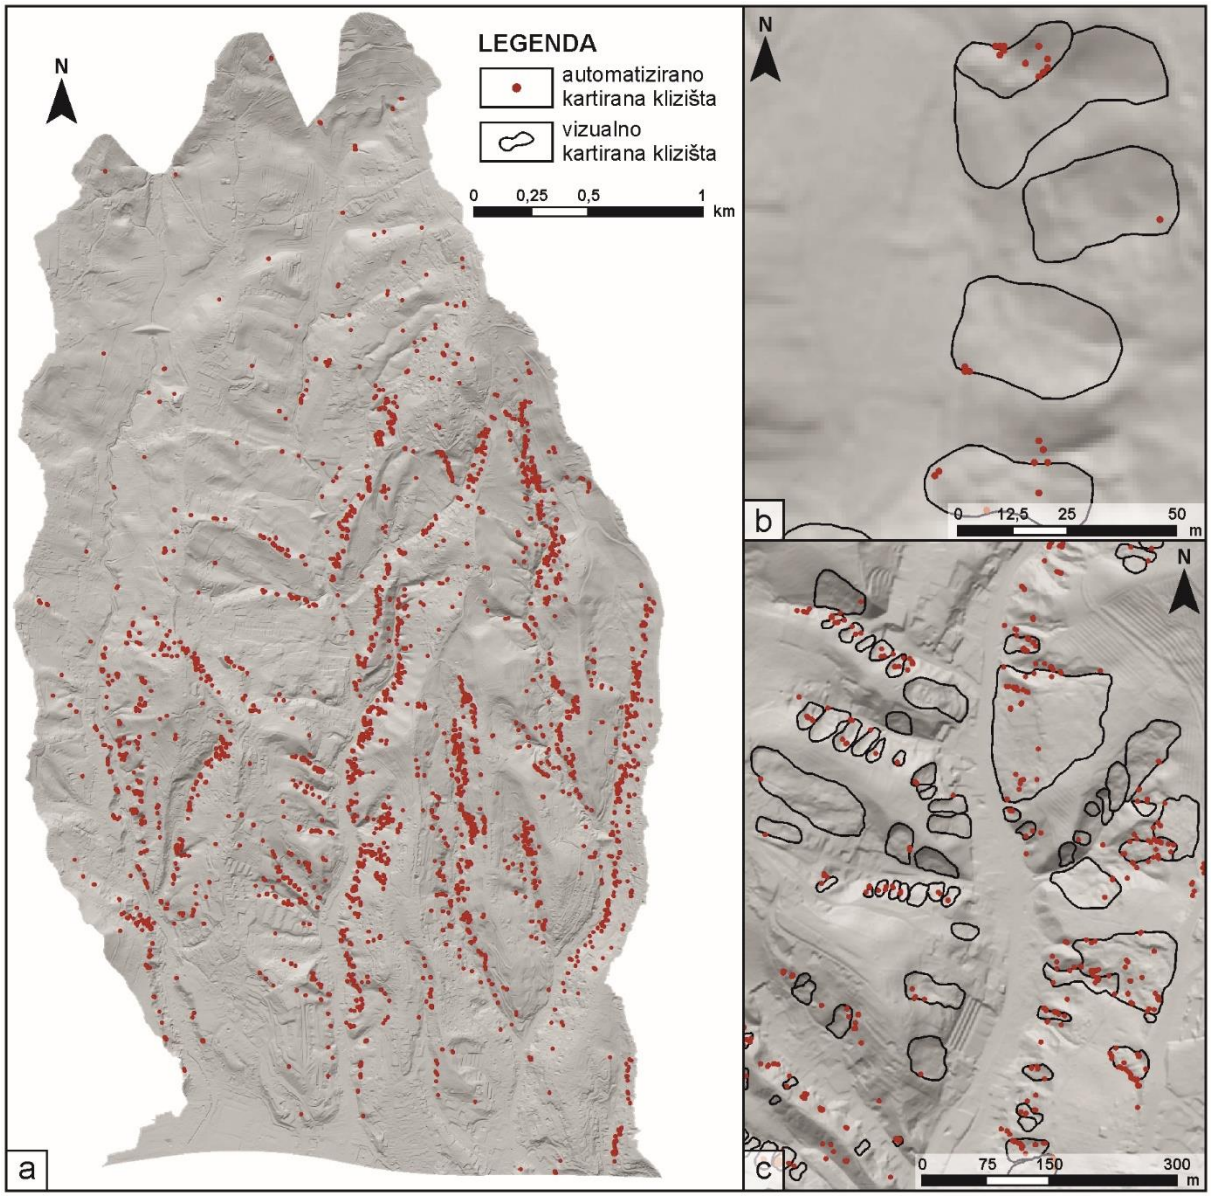

Slika 7.42 Konačna karta klizišta izrađena na osnovi zbroja svih predikcijskih karata i reklasificirana s obzirom na graničnu vrijednost 26: (a) karta za testno područje površine 10,5 km^2 s prikazom točaka klasificiranih kao klizišta; (b) i (c) usporedba automatizirano kartiranih klizišta s vizualno kartiranim klizištima.

Primjenom *stepwise* metode kombiniranja predikcijskih karata (van Westen et al., 1993) također je izrađena karta automatizirano kartiranih klizišta na način da se parametri točnosti određuju za sve kombinacije karata koje nastaju postupnim dodavanjem predikcijskih karata. Drugim riječima, jedna po jedna predikcijska karta se sumira te se analizira utjecaj dodane predikcijske karte na model za automatizirano kartiranje klizišta, odnosno na konačan rezultat, a analiza se provodi pomoću parametara točnosti. Ukoliko pojedina predikcijska karta znatno utječe na smanjenje točno predviđenih vizualno kartiranih klizišta ili se udio točaka netočno klasificiranih kao klizišta znatno povećava, ta predikcijska karta se odbacuje. Suprotno tome,

ako pojedina predikcijska karta znatno utječe na povećanje udjela točaka koje su točno klasificirane kao klizišta i pri tome se udio točno predviđenih vizualno kartiranih klizišta ne umanjuje značajno, onda se predikcijska karta uzima u obzir te se analizira utjecaj slijedeće predikcijske karte. Redoslijed dodavanja i analize predikcijskih karata uvjetovan je indeksom podudarnosti, M. U skladu s tim, prvo su analizirane karte s višim stupnjem kartografskog preklapanja s vizualno kartiranim klizištima. Vrijednosti parametara točnosti dobivene tijekom primjene *stepwise* metode kombiniranja predikcijskih karata prikazane su na slici 7.43.

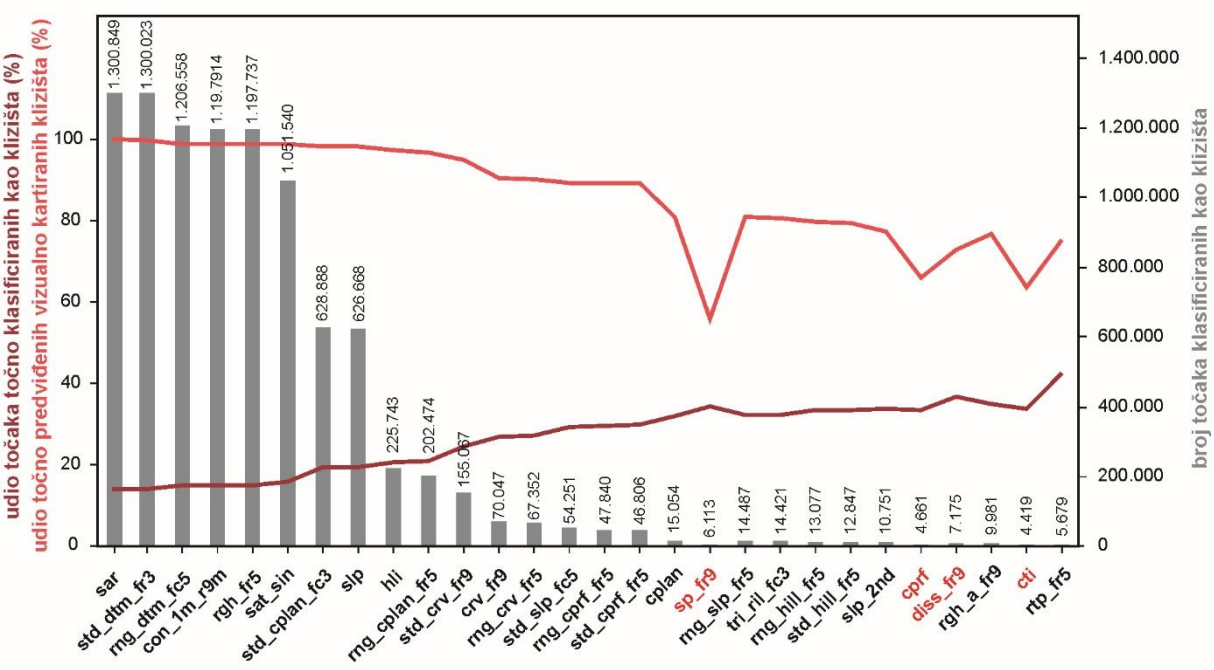

Slika 7.43 Vrijednost parametara točnosti za svaki korak *stepwise* metode kombiniranja predikcijskih karata.

Iz slike 7.43 može se zaključiti da na smanjenje broja točaka klasificiranih kao klizišta te povećanje udjela točaka točno klasificiranih kao klizišta najveći utjecaj imaju karta standardne devijacije planarne zakrivljenosti izvedena na temelju kružnog prozora radijusa 3 m (std_cplan_fc3), karta osunčanosti terena (hli) i karta planarne zakrivljenosti (cplan). Predikcijske karte koje su značajno smanjile udio točno predviđenih vizualno kartiranih klizišta su karta relativnog nagiba terena dobivena kvadratnim prozorom veličine 9x9 m (sp_fr9), karta profilne zakrivljenosti terena (cprf), karta raščlanjenosti terena dobivena kružnim prozorom radijusa 9 m (diss_fr9) i karta vlažnosti terena (cti) te su one odbačene i nisu primijenjene za izradu konačne karte inventara klizišta.

Konačna karta automatizirano kartiranih klizišta izrađena primjenom *stepwise* metode kombiniranja predikcijskih karata prikazana je na slici 7.44a. Karta inventara sadrži 5679 točaka klasificiranih kao klizišta, od toga se 42,2 % točaka nalazi unutar granica vizualno kartiranih klizišta, a točno je klasificirano 343 klizišta od 436 na testnom području, odnosno 74,1 %. Također, na slici 7.44b,c prikazana je usporedba automatizirano kartiranih klizišta s vizualno kartiranim klizištima.

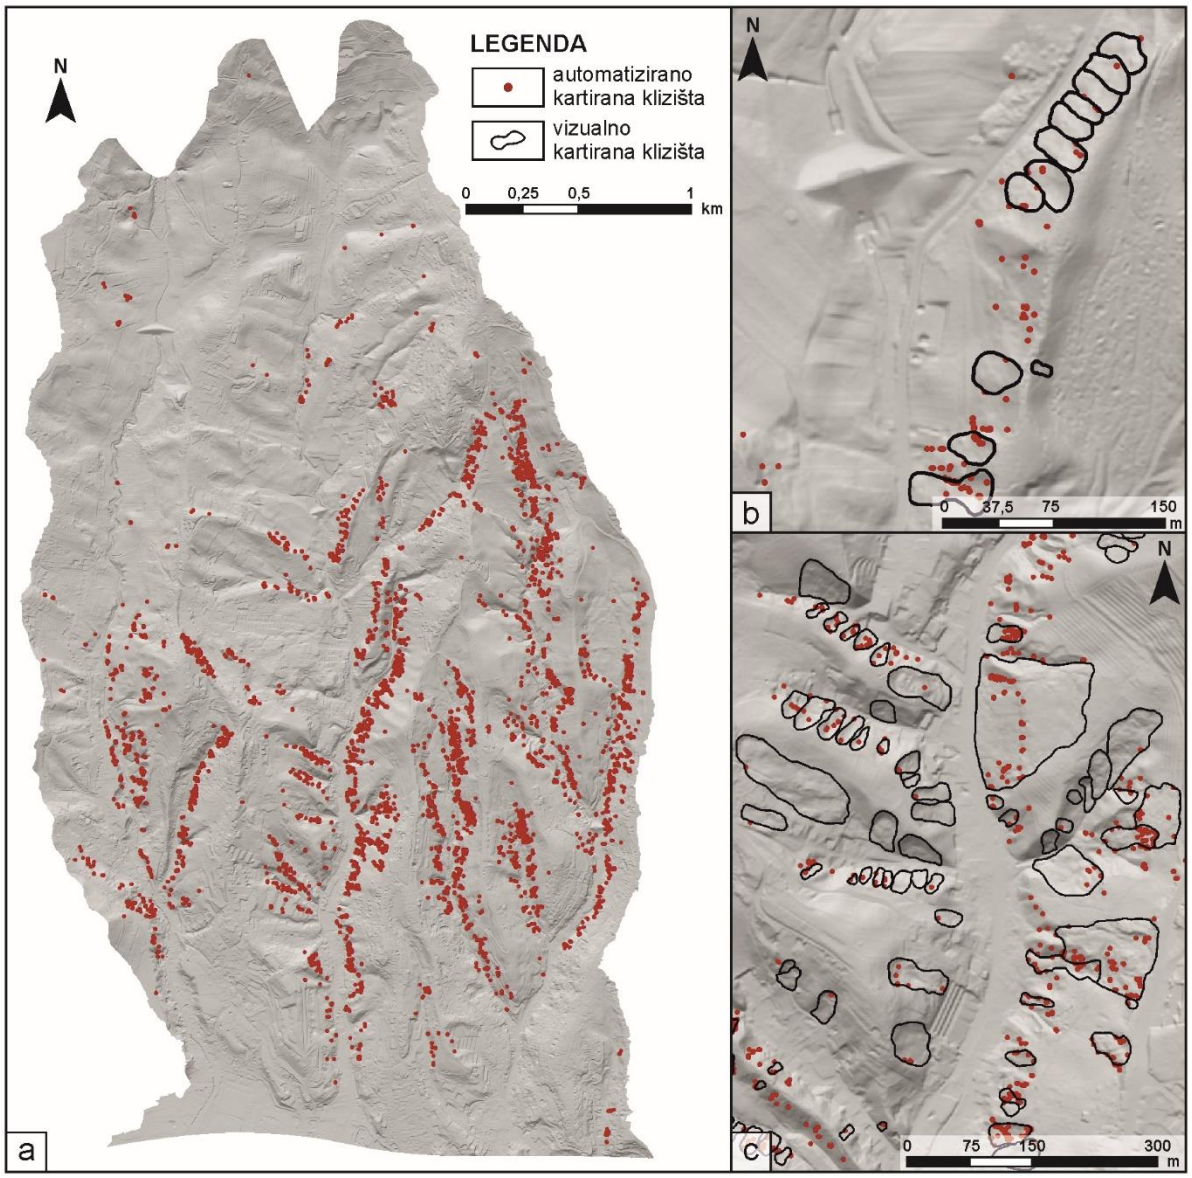

Slika 7.44 Konačna karta inventara klizišta izrađena na osnovi *stepwise* metode kombiniranja predikcijskih karata: (a) karta za testno područje površine 10,5 km^2 s prikazom točaka klasificiranih kao klizišta; (b) i (c) usporedba automatizirano kartiranih klizišta s vizualno kartiranim klizištima.

7.3 Verifikacija modela za automatizirano kartiranje klizišta

Verifikacija modela za automatizirano kartiranje klizišta provedena je na području površine 10,5 km^2 (slika 7.1) na kojem su vizualnom interpretacijom LiDAR DMT-a iskartirane granice za ukupno 239 klizišta. Karta inventara automatizirano kartiranih klizišta za područje verifikacije izrađena je na temelju graničnih vrijednosti morfometrijskih parametara dobivenih analizom vizualno kartiranih klizišta na području za treniranje modela te zbrajanjem 24 predikcijske karate definiranih *stepwise* metodom. Karta inventara sadrži ukupno 2807 točaka klasificiranih kao klizišta, a prostorna raspodjela automatizirano kartiranih klizišta s obzirom na granice vizualno kartiranih klizišta prikazana je na slici 7.45. Automatiziranim kartiranjem klizišta točno je predviđeno 166 klizišta ili 69,6 % od ukupnog broja vizualno kartiranih klizišta na području za verifikaciju modela. Od ukupnog broja točaka, točno je klasificirano 29,3 % točaka, odnosno 823 točke se nalaze unutar granica vizualno kartiranih klizišta. Utjecaj primijenjene metode kartiranja klizišta analiziran je kartografskim preklapanjem automatizirano kartiranih klizišta s koncentrično uvećavanim granicama vizualno kartiranih klizištima i to u širinama 0,25 m, 0,5 m, 1 m, 2 m, 5 m i 10 m oko klizišta (slika 7.46 i 7.47a). Na ovaj način se željelo eliminirati eventualne pogreške nastale tijekom vizualnog kartiranja granica klizišta na izvedenim morfometrijskim kartama. Prema rezultatima analiza podudarnosti s uvećanim klizištima, može se zaključiti da se udio točaka točno klasificiranih kao klizišta povećava s povećavanjem širine zona oko vizualno kartiranih klizišta, a ujedno se povećava i udio točno predviđenih vizualno kartiranih klizišta. Unutar zone širine 1 m oko vizualno kartiranih klizišta nalazi se 34 % točno klasificiranih točaka dobivenih modelom za automatizirano kartiranje klizišta te je točno predviđeno 74,5 % vizualno kartiranih klizišta. Gustoća točaka klasificiranih kao klizišta (slika 7.47b) veća je na nestabilnim padinama, odnosno padinama na kojima postoje jasne morfološke značajke karakteristične za procese klizanja, ali nisu jasno vidljive granice klizišta u svim dijelovima takvih padina. Vizualnom interpretacijom LiDAR DMT-a iscrtane su granice nestabilnih padina (ukupna površina 0,29 km^2 ili 0,03 % područja za verifikaciju modela) koje su prikazane na slici 7.48. Usporedbom površina nestabilnih padina s lokacijama automatizirano kartiranih klizišta, dobiveno je podatak da je 69,6 % točaka točno klasificirano kao klizišta.

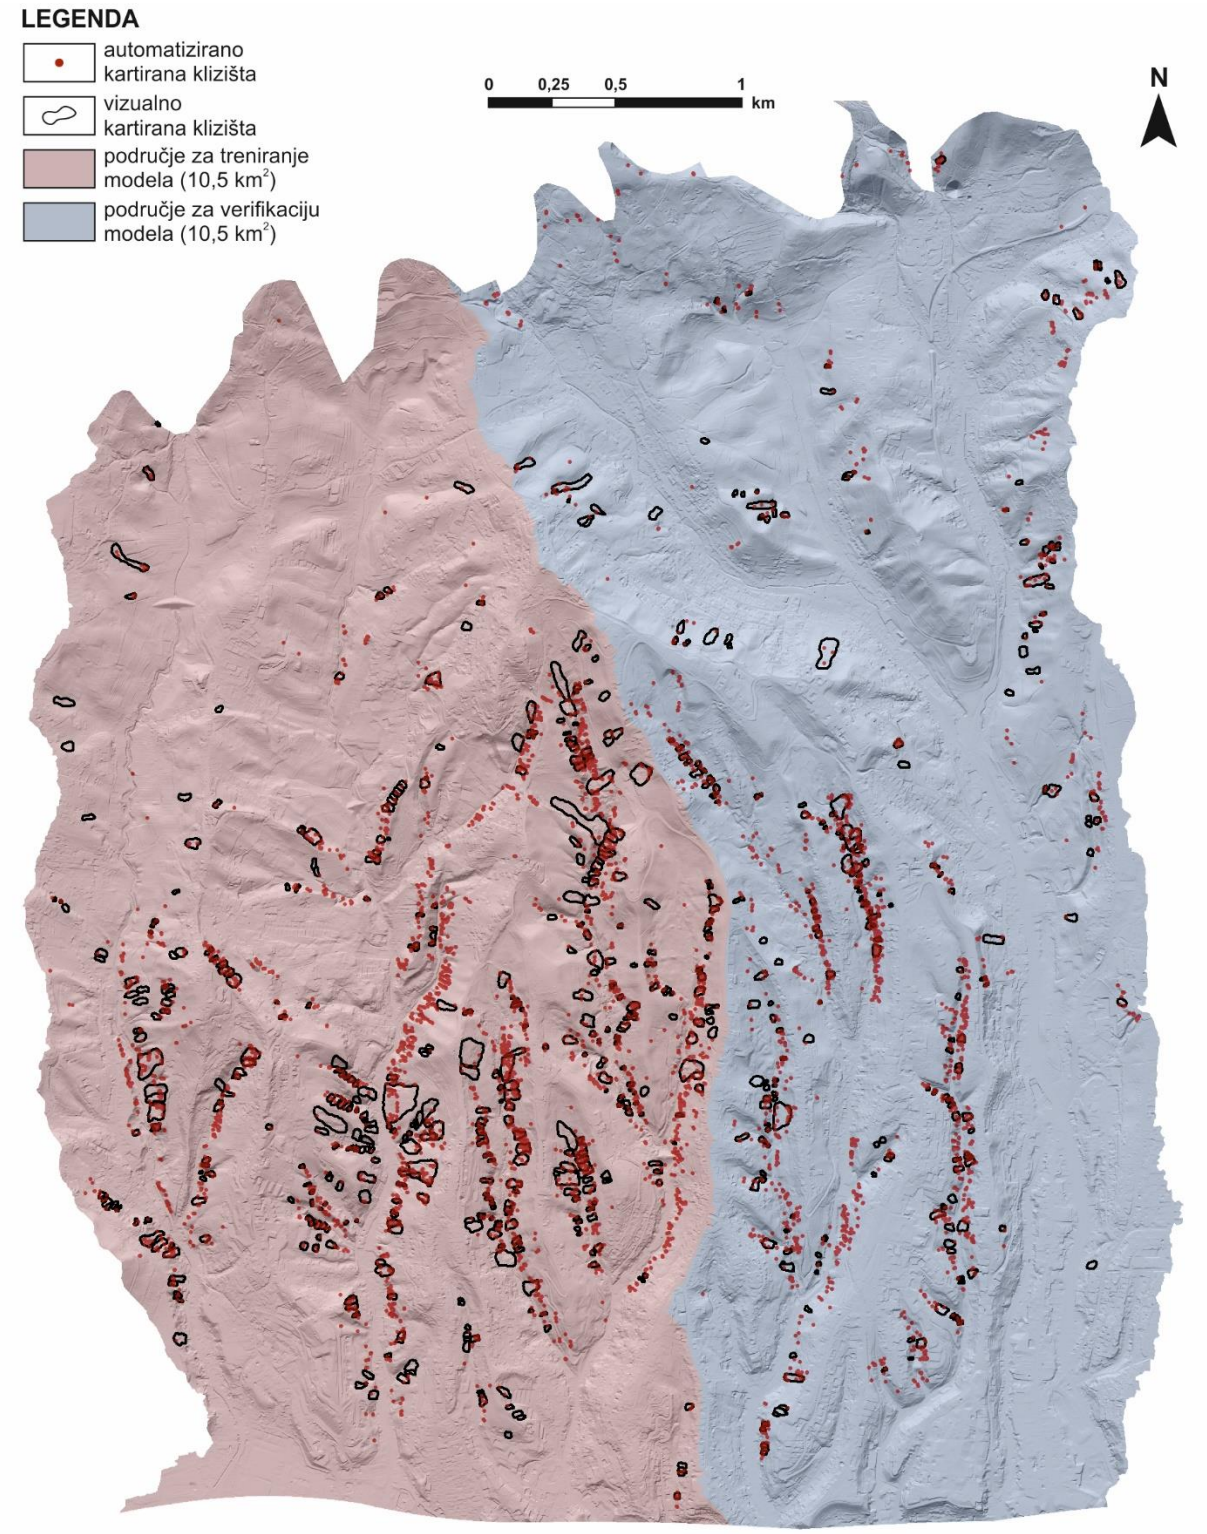

	Broj točaka klasificiranih kao klizišta	Udio točaka točno klasificiranih kao klizišta (%)	Udio točno predviđenih vizualno kartiranih klizišta (%)
područje za treniranje modela (broj vizualno kartiranih klizišta = 463)	5679	42,2 %	74,1 %
područje za verifikaciju modela (broj vizualno kartiranih klizišta = 239)	2807	29,3 %	69,5 %

Slika 7.45 Usporedba karata inventara automatizirano i vizualno kartiranih klizišta na području za testiranje modela (10,5 km^2) i verifikaciju modela. (10,5 km^2).

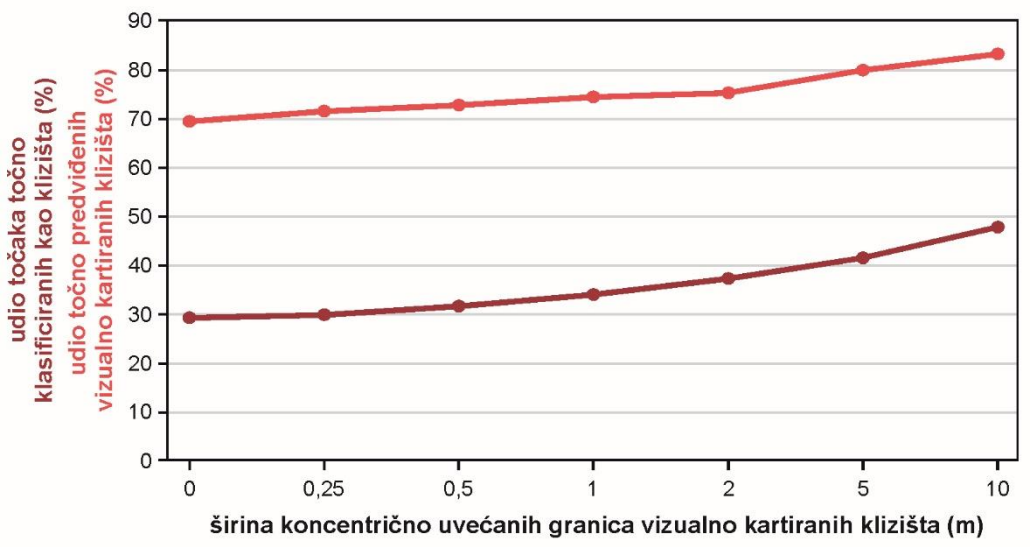

Slika 7.46 Usporedba parametara točnosti karte inventara automatizirano kartiranih klizišta s obzirom na koncentrično uvećavanim granicama vizualno kartiranih klizištima u širinama 0,25, 0,5, 1, 2, 5 i 10 m oko vizualno kartiranih klizišta na području za verifikaciju modela (10,5 km^2).

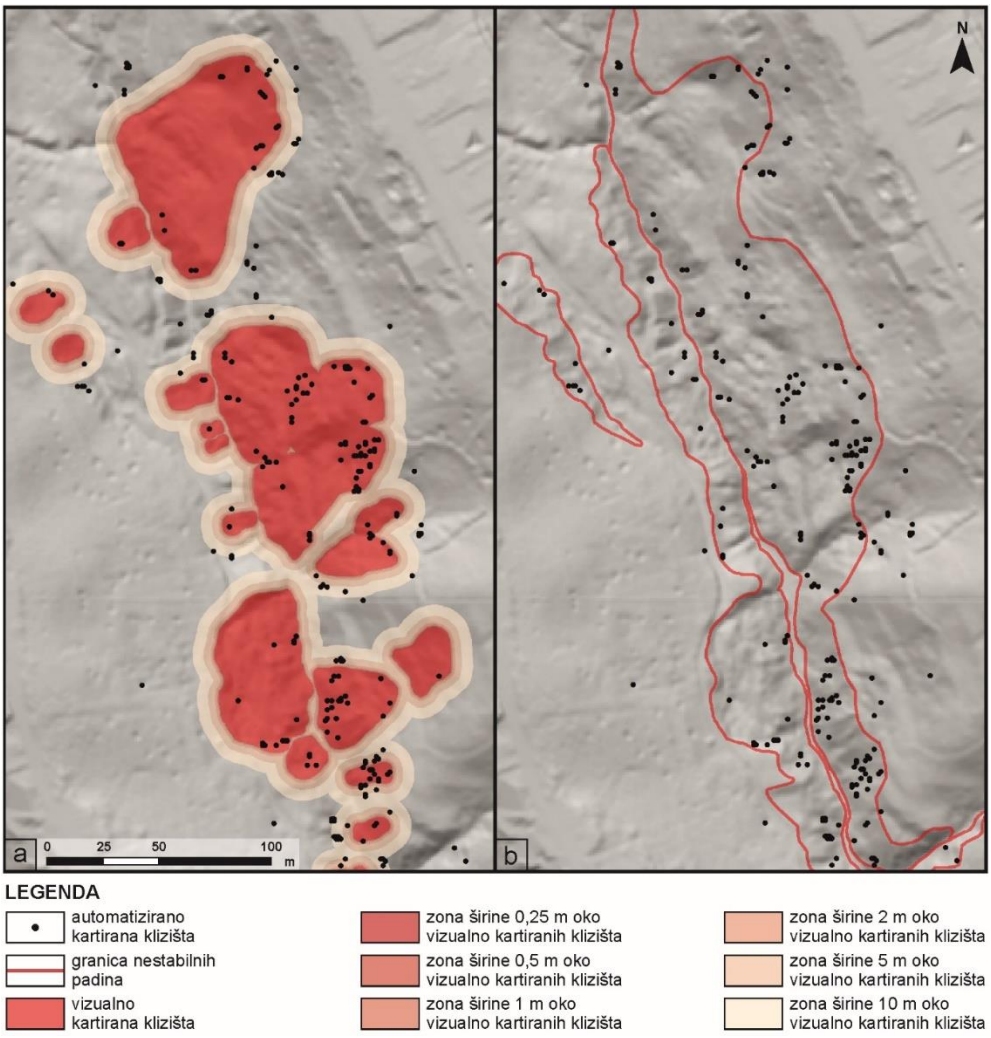

Slika 7.47 Usporedan prikaz karte inventara automatizirano kartiranih klizišta s: (a) zonama širine 0,25 m, 0,5 m, 1 m, 2 m, 5 m i 10 m oko vizualno kartiranih klizišta; (b) vizualno kartiranim nestabilnim padinama.

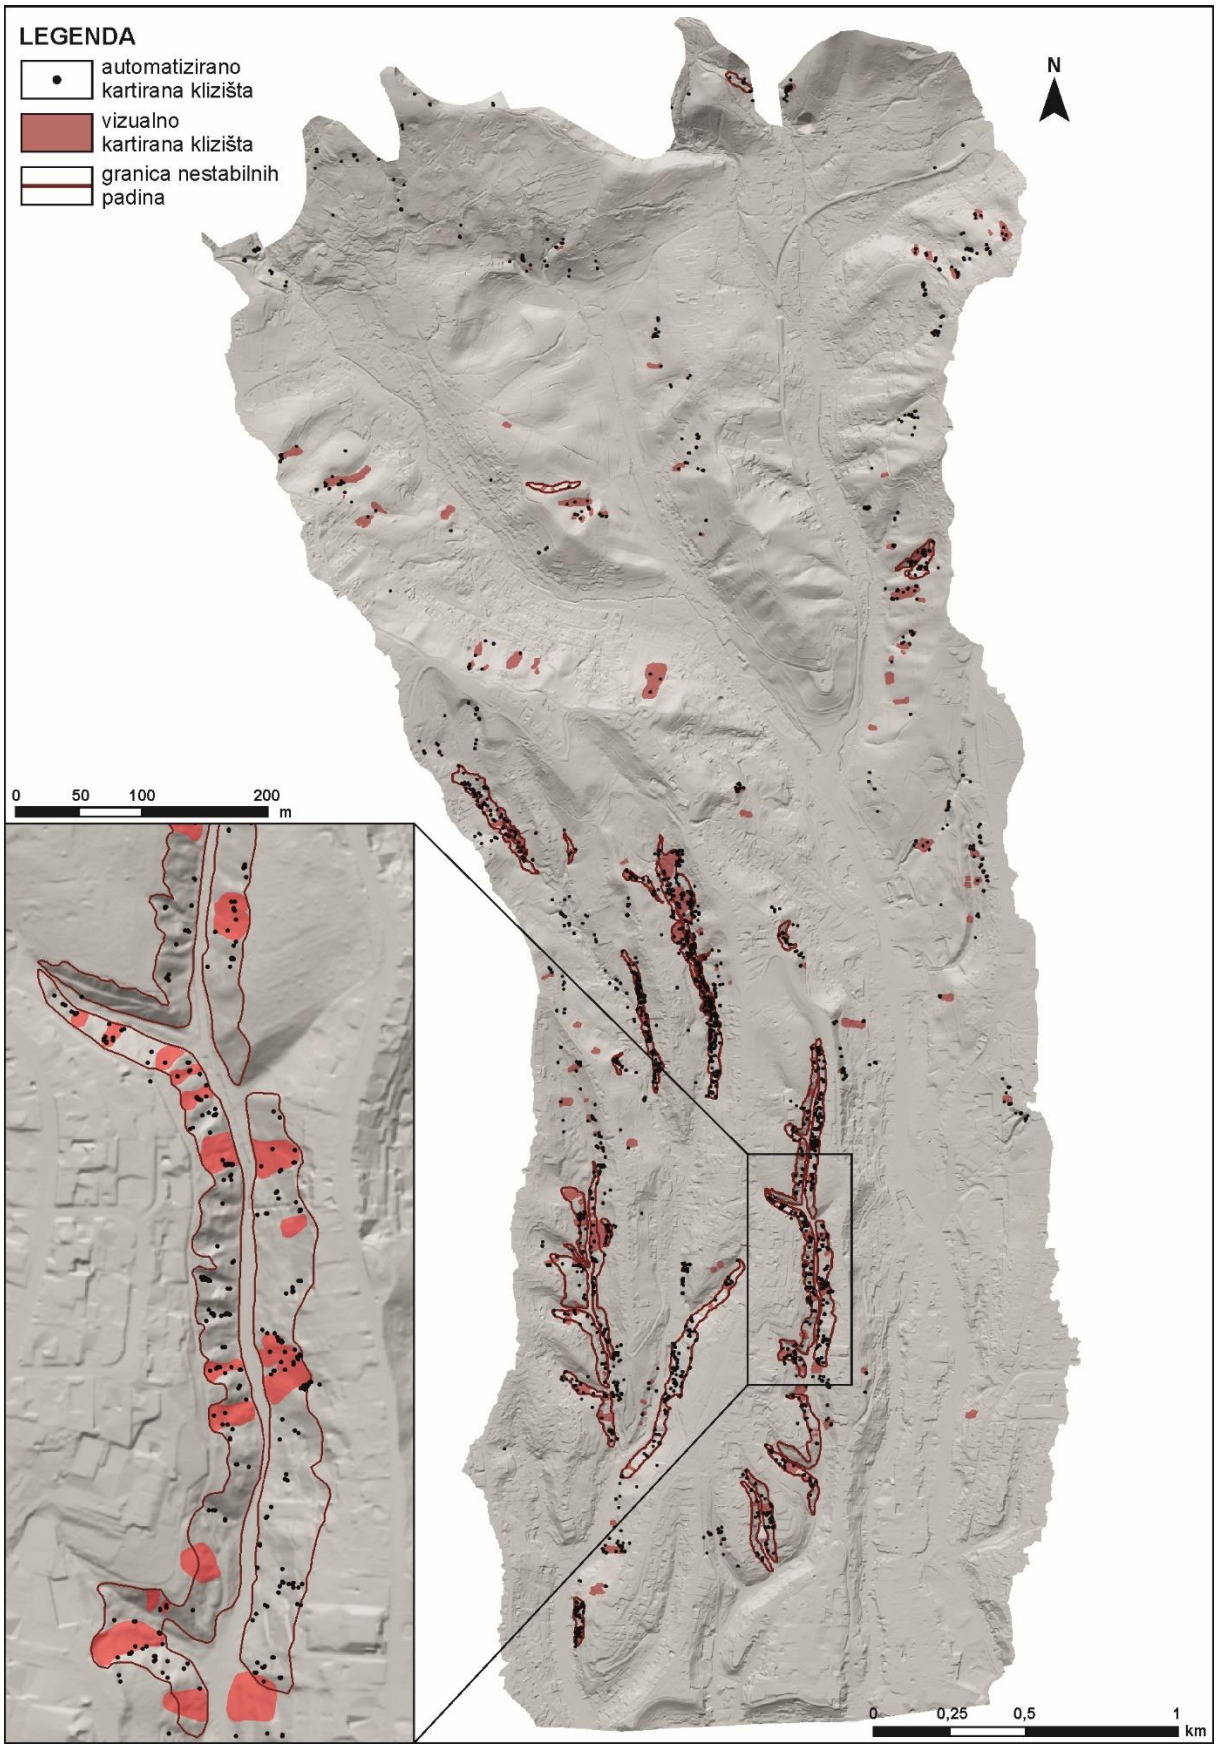

Slika 7.48 Usporedba inventara automatizirano kartiranih klizišta s vizualnom kartiranim klizištima i nestabilnim padinama na području za verifikaciju modela (10,5 km^2).

Na slici 7.49 prikazana je učestalost broja vizualno kartiranih klizišta u odnosu na broj točaka koja ih predviđaju modelom za automatizirano kartiranje klizišta. Najveći broj vizualno kartiranih klizišta predviđen je sa samo jednom točkom (44 klizišta ili 26 % od ukupnog broja predviđenih klizišta), slijede klizišta predviđena s dvije točke (28 klizišta ili 17 % od ukupnog broj predviđenih klizišta) i tri točke (24 klizišta ili 14 % od ukupnog broj predviđenih klizišta). S četiri i više točaka točno je predviđeno ukupno 70 vizualno kartiranih klizišta ili 44 % od ukupnog broja predviđenih klizišta, a s 10 ili više točaka previđeno je 21 klizište ili 13 % od ukupnog broja predviđenih klizišta. Također, na temelju prostornog položaja klizišta koja su klasificirana s četiri ili više točaka (slika 7.49) može se zaključiti da se radi o vizualno kartiranim klizištima koja su nalaze na nestabilnim padinama.

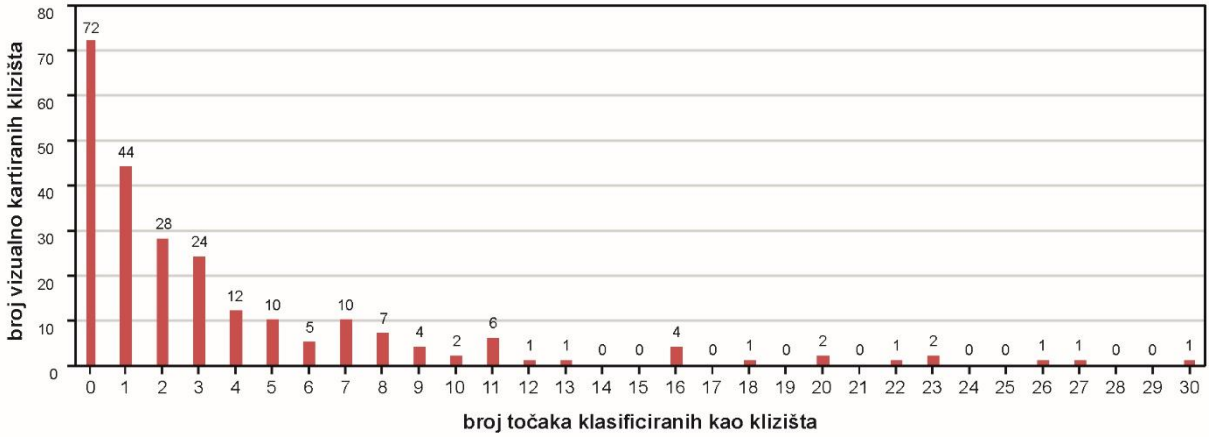

Slika 7.49 Broj točaka klasificiranih kao klizišta modelom za automatizirano kartiranje klizišta unutar granica vizualno kartiranih klizišta.

S obzirom na procjenu pouzdanosti vizualno identificiranih klizišta na LiDAR DMT-u (slika 7.50) 111 pojava ili 66,9 % od ukupnog broja predviđenih vizualno kartiranih klizišta su pouzdano identificirana klizišta, a 55 pojava ili 33,1 % od ukupnog broj predviđenih klizišta su pretpostavljena klizišta, odnosno nepouzdano vizualno interpretirana klizišta. Od vizualno kartiranih klizišta koja nisu predviđena modelom za automatizirano kartiranje klizišta njih 22 ili 30,1 % od ukupnog broja nepredviđenih vizualno kartiranih klizišta je pouzdano identificirano prilikom vizualne interpretacije, a 51 klizište ili 69,9 % od ukupnog broja nepredviđenih klizišta su pretpostavljena klizišta. S obzirom na navedeno, 83 % pouzdano vizualno identificiranih klizišta na području za verifikaciju je uspješno predviđeno modelom za automatizirano kartiranje klizišta, dok gotovo 50 % nepouzdano identificiranih (pretpostavljenih) klizišta nije predviđeno modelom za automatizirano kartiranje klizišta.

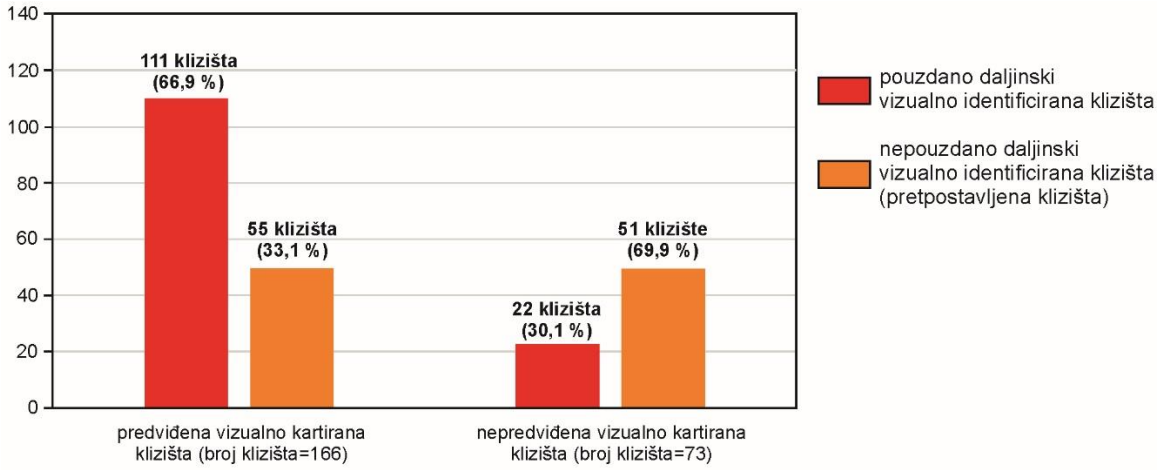

Slika 7.50 Učestalost predviđenih i nepredviđenih vizualno kartiranih klizišta modelom za automatizirano kartiranje klizišta s obzirom na pouzdanost vizualne identifikacije klizišta na LiDAR DMT-u.

Učestalost predviđenih i nepredviđenih vizualno kartiranih klizišta s obzirom na njihovu površinu prikazana je na slici 7.51. Iz prikazane raspodjele površina klizišta se može zaključiti da se s povećanjem površine klizišta povećava udio klizišta točno predviđenih modelom za automatizirano kartiranje klizišta. Na primjer, 85 % vizualno kartiranih klizišta površine 1000-2000 m^2 predviđeno je modelom za automatizirano kartiranje klizišta, dok su sva klizišta površine veće od 2000 m^2 uspješno previđena modelom za automatizirano kartiranje klizišta. Suprotno, nepredviđena vizualno kartirana klizišta su uglavnom površinom manja klizišta. Na primjer, od ukupno 27 vizualno kartiranih klizišta čija površina je manja od 125 m^2, modelom za automatizirano kartiranje klizišta predviđeno je 15 odnosno 55,6 % od ukupnog broja klizišta. Također, iz raspodjele predviđenih vizualno kartiranih klizišta može se zaključiti da je s obzirom na površinu klizišta modelom za automatizirano kartiranje klizišta predviđen reprezentativan uzorak klizišta.

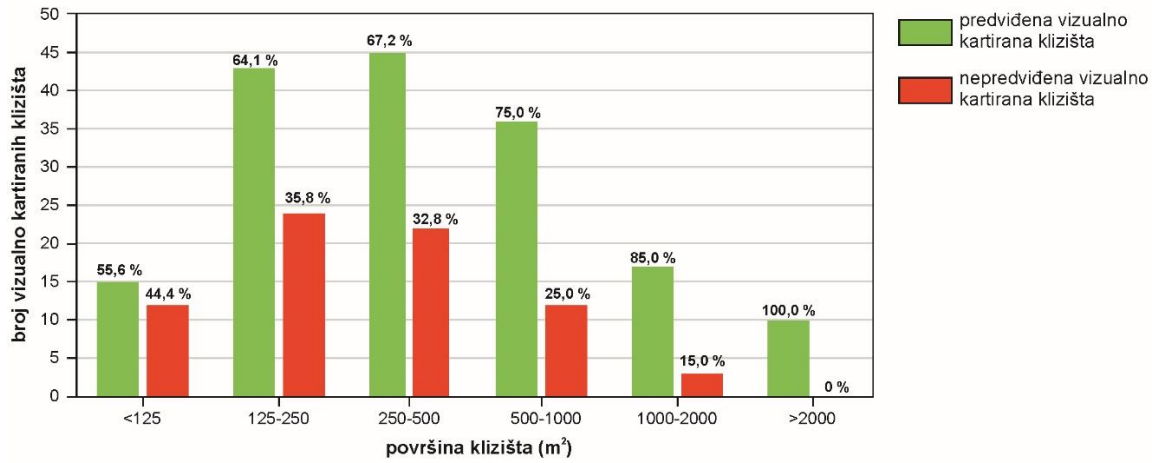

Slika 7.51 Učestalost vizualno kartiranih klizišta koja su predviđena ili nepredviđena modelom za automatizirano kartiranje klizišta s obzirom na površinu klizišta.

8 VALIDACIJA MODELA ZA AUTOMATIZIRANO KARTIRANJE KLIZIŠTA

Model za automatizirano kartiranje klizišta rezultirao je kartom klizišta pilot područja s ukupno 8486 točaka klasificiranih kao klizišta. Validacija razvijenog modela provedena je izradom karte podložnosti na klizanje koja je uspoređena s kartama podložnosti na klizanje izrađenim na osnovi potpunih inventara vizualno kartiranih klizišta. Ovakav način validacije odabran je zbog toga što karte podložnosti na klizanje predstavljaju prve u nizu od karata hazarda klizanja koje se izrađuju na temelju inventara klizanja u kombinaciji s poznatim preduvjetima klizanja. Budući da karte podložnosti na klizanje, kao karte prostorne vjerojatnosti pojave klizišta, iziskuju pouzdane ulazne podatke o klizištima (u obliku inventara), pouzdanost karte podložnosti izrađene na osnovi automatiziranog inventara klizišta je zadovoljavajuća validacija modela u smislu njegove upotrebljivosti za izradu prognostičkih karata.

U slijedećim poglavljima analizirani su preduvjeti klizanja, odnosno kvantificirane su pojedine klase faktorskih karata s obzirom na relativan utjecaj na pojavu klizanja. Analiza je provedena na pilot području (21 km^2) u podsljemenskoj zoni Grada Zagreba na temelju karte inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a (ukupno 702 klizišta) i karte inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta (ukupno 8486 točaka klasificiranih kao klizišta). Primjenom WoE modela (Agterberg et al., 1990; Bonham-Carter et al., 1989) na analiziranim preduvjetima klizanja izrađene su tri karte podložnosti na klizanje: (1) karta podložnosti na klizanje za koju su korištene cijele površine klizišta kartiranih vizualnom interpretacijom LiDAR DMT-a; (2) karta podložnosti na klizanje izvedena na temelju točkastih lokacija klizišta kartiranih vizualnom interpretacijom LiDAR DMT-a; i (3) karta podložnosti na klizanje izrađena na temelju inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta. Utjecaj pojedinih preduvjeta klizanja procijenjen je na temelju WoE modela koji je ukratko opisan u poglavlju 4.5, a pomoću kojega su izračunate težine svih klasa faktora klizanja. Dobivene karte podložnosti na klizanje uspoređene su na temelju ROC krivulja (Green & Swets, 1966). Usporedbom karte podložnosti na klizanje izvedene na temelju automatizirano iskartiranih klizišta s kartama podložnosti na klizanje izvedenih na temelju klizišta dobivenih vizualnom interpretacijom LiDAR DMT-a, provedena je validacija modela za automatizirano kartiranje klizišta iz LiDAR DMT-a. Istovremeno je analizirana i mogućnost primjene automatizirano kartiranih klizišta za izradu prognostičkih karata hazarda klizanja u podsljemenskoj zoni Grada Zagreba. Shematski prikaz analize preduvjeta klizanja i izrada karata podložnosti na klizanje prikazana je na slici 8.1.

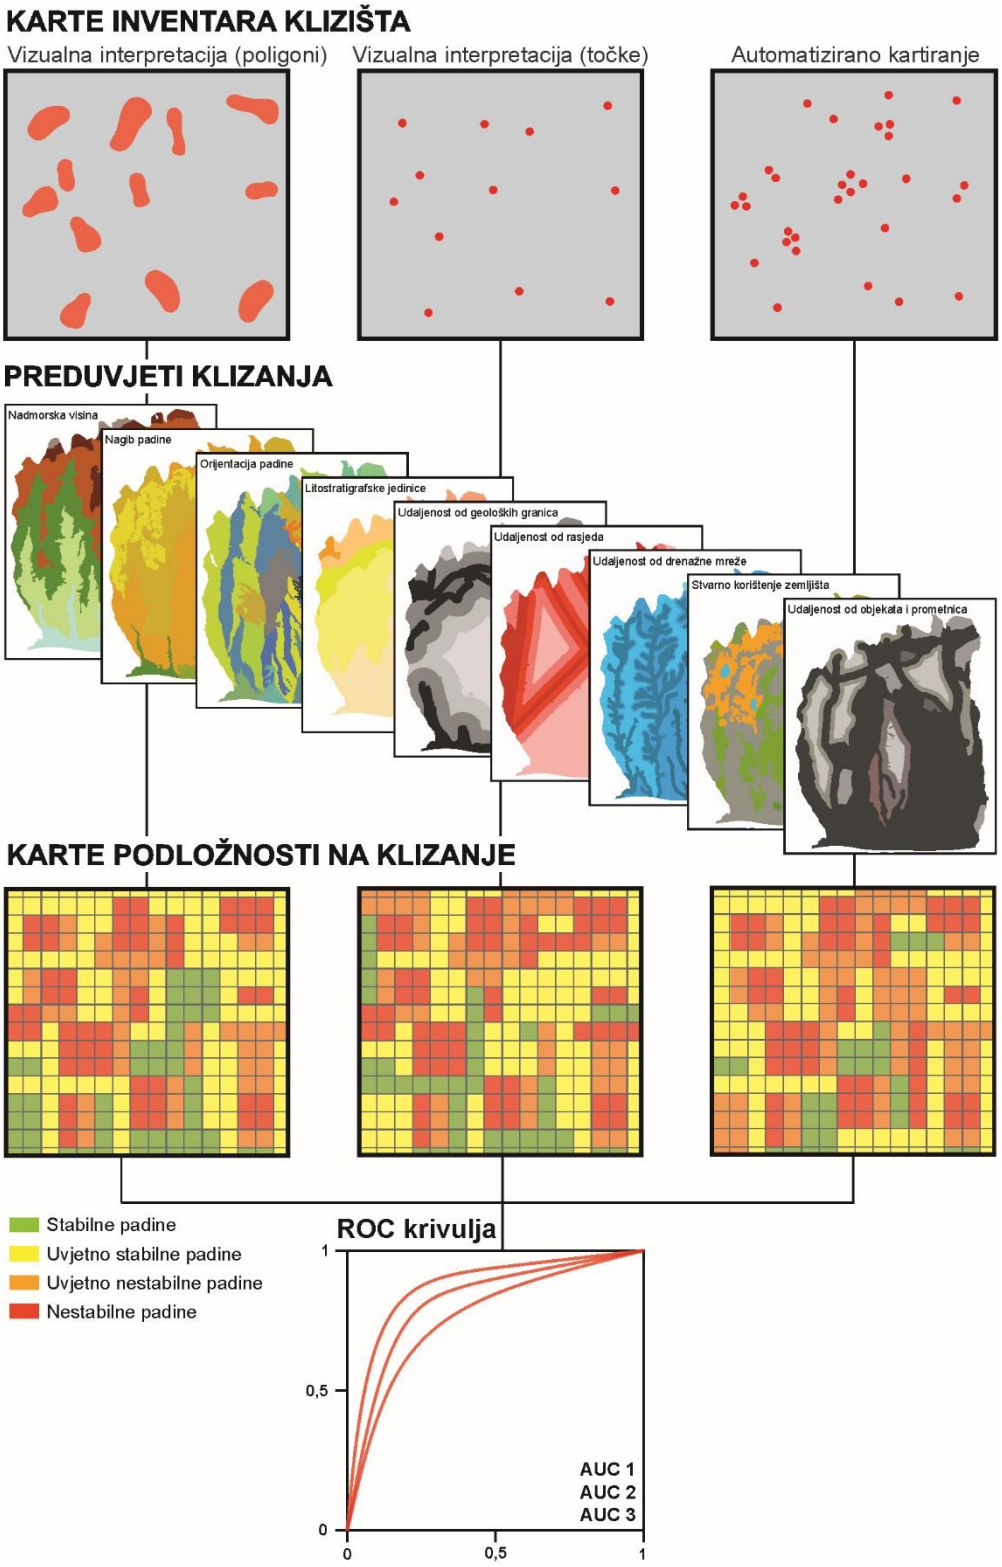

Slika 8.1 Shematski prikaz izrade karata podložnosti na klizanje na pilot području (21 km^2) podsljemenske zone Grada Zagreba

8.1 Analiza relativnog utjecaja preduvjeta klizanja

Klizišta na pilot području (21 km^2), ali i na području cijele podsljemenske zone Grada Zagreba (180 km^2), nastaju kao izravna ili neposredna posljedica inicijatora klizanja (oborine, potresi, antropogeni procesi) na mjestima gdje postoje određeni preduvjeti klizanja (geološka građa, geomorfološke značajke, fizički procesi i antropogeni utjecaj). Analiza preduvjeta klizanja na pilot području provedena je prostornim analizama izvedenih karata koje prikazuju geomorfološke, geološke, hidrološke i antropogene preduvjete klizanja. Svi kartografski ulazni podaci izvedeni su iz: (1) digitalnog modela terena rezolucije 1 x 1 m dobivenog laserskim skeniranjem iz zraka; (2) OGK M 1:100.000, list Zagreb (Šikić et al., 1979); i (3) karte stvarnog korištenja zemljišta Grada Zagreba iz 2011. godine.

Svi analizirani preduvjeti klizanja navedeni su u tablici 8.1. Analiza geomorfoloških preduvjeta klizanja provedena je kao analiza utjecaja pojave klizišta s obzirom na nadmorsku visinu, nagib terena i orijentaciju padina. U okviru analize geoloških preduvjeta klizanja analiziran je utjecaj litološkog sastava i udaljenost od strukturnih elemenata (geoloških granica i rasjeda) na pojavu klizišta. U sklopu analize hidroloških preduvjeta klizanja analiziran je samo odnos drenažne mreže i klizišta, i to kao relativna udaljenost pojava klizišta od površinskih tokova i kanala. Antropogeni preduvjeti klizanja analizirani su preko utjecaja namjene zemljišta na pojavu klizišta i kao odnos građevina (zgrada i prometnica) i pojava klizišta, a pomoću njihove relativne udaljenosti.

Tablica 8.1 Preduvjeti klizanja analizirani u svrhu izrade karte podložnosti na klizanje za pilot područje (21 km^2) podsljemenske zone Grada Zagreba.

Grupa preduvjeta klizanja		Karte preduvjeta klizanja	
1.	geomorfološki preduvjeti klizanja	1.	karta nadmorskih visina
		2.	karta nagiba terena
		3.	karta orijentacije padine
2.	geološki preduvjeti klizanja	4.	karta stratigrafskih jedinica
		5.	karta udaljenosti od normalnih i transgresivnih granica
		6.	karta udaljenosti od rasjeda
3.	hidrološki preduvjeti klizanja	7.	karta udaljenosti od drenažne mreže
4.	antropogeni preduvjeti klizanja	8.	karta stvarnog korištenja zemljišta
		9.	karta udaljenosti od građevina i prometnica

8.1.1 Geomorfološki preduvjeti klizanja

Analiza relativnog utjecaja geomorfoloških značajki na pojavu klizanja provedena je na kartama izvedenim iz DMT-a rezolucije 1x1 m. Pomoću paketa alata *Surface* u *ArcGIS-u 10.0* izvedene su sljedeće geomorfološke faktorske karte: karta nadmorskih visina, karta nagiba terena i karta orijentacije padina.

Karta nadmorskih visina (slika 8.2) pilot područja podijeljena je na sedam klasa: <150 m n.m., 150-200 m n.m., 200-250 m n.m., 250-300 m n.m., 300-350 m n.m., 350-400 m n.m. i više od 400 m n.m. Najveća gustoća vizualno kartiranih klizišta prisutna je u klasama nadmorske visine 150-200 m n.m. (58 klizišta/km^2) i 200-250 m n.m. (34 klizišta/km^2), a nakon toga slijedi klasa nadmorske visine manje od 150 m n.m. i 250-300 m n.m. (13 i 12 klizišta/km^2). U klasi 300-350 m n.m. gustoća vizualno kartiranih klizišta je samo 6 klizišta/km^2, a u klasama iznad 350 m n.m. klizišta nisu identificirana. S obzirom na težinski faktor koji je izračunat na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}) može se zaključiti da na pilot području klasa nadmorske visine 150-200 m n.m ima relativno najveći utjecaj na pojavu klizišta (tablica 8.2).

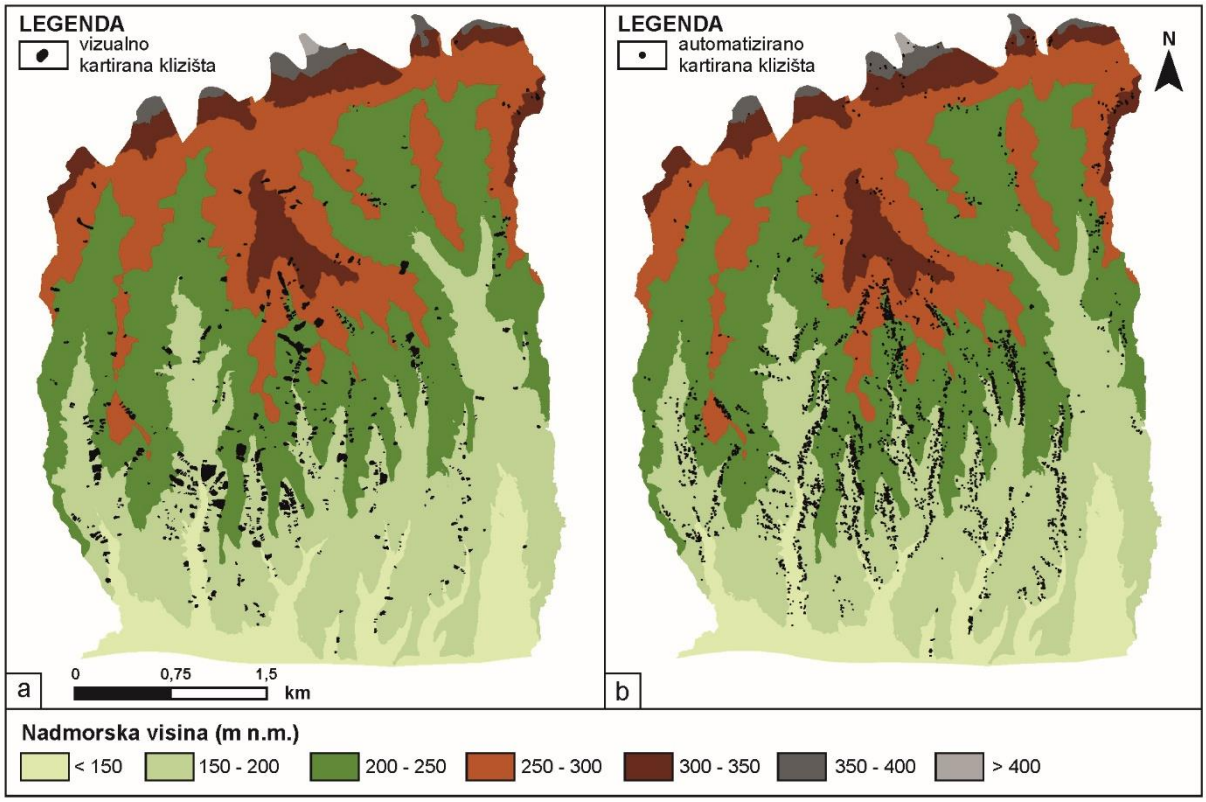

Slika 8.2 Karta nadmorskih visina na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

Tablica 8.2 Analiza utjecaja nadmorske visine na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta ($br./km^2$)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
< 150	2,02	0,02	26	13	277	-1,436	-1,169	-1,337
150 - 200	6,55	0,27	382	58	4963	0,736	0,819	0,948
200 - 250	6,99	0,19	236	34	2552	-0,064	-0,134	-0,334
250 – 300	4,14	0,06	51	12	581	-0,875	-1,293	-1,393
300 - 350	1,18	0,01	7	6	92	-1,973	-2,118	-1,878
350 – 400	0,21	0,00	0	0	20	-1,436	-1,169	-1,653
> 400	0,02	0,00	0	0	1	-1,436	-1,169	-2,302
ukupno:	21,11	0,54	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_t - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

Karta nagiba terena (slika 8.3) pilot područja izvedena je podjelom vrijednosti nagiba u 11 klasa raspona od pet stupnjeva, tako da je prva klasa nagiba terena 0-5°, a posljednja klasa je više od 55°. Najveća gustoća vizualno kartiranih klizišta je u klasama nagiba terena od 15° do 35°, gdje je gustoća klizišta u svakoj od klasa veća od 100 klizišta/km^2. Najmanja gustoća vizualno kartiranih klizišta je u klasama do 0 do 10°, dok u klasi nagiba terena više od 55° nema vizualno identificiranih klizišta.

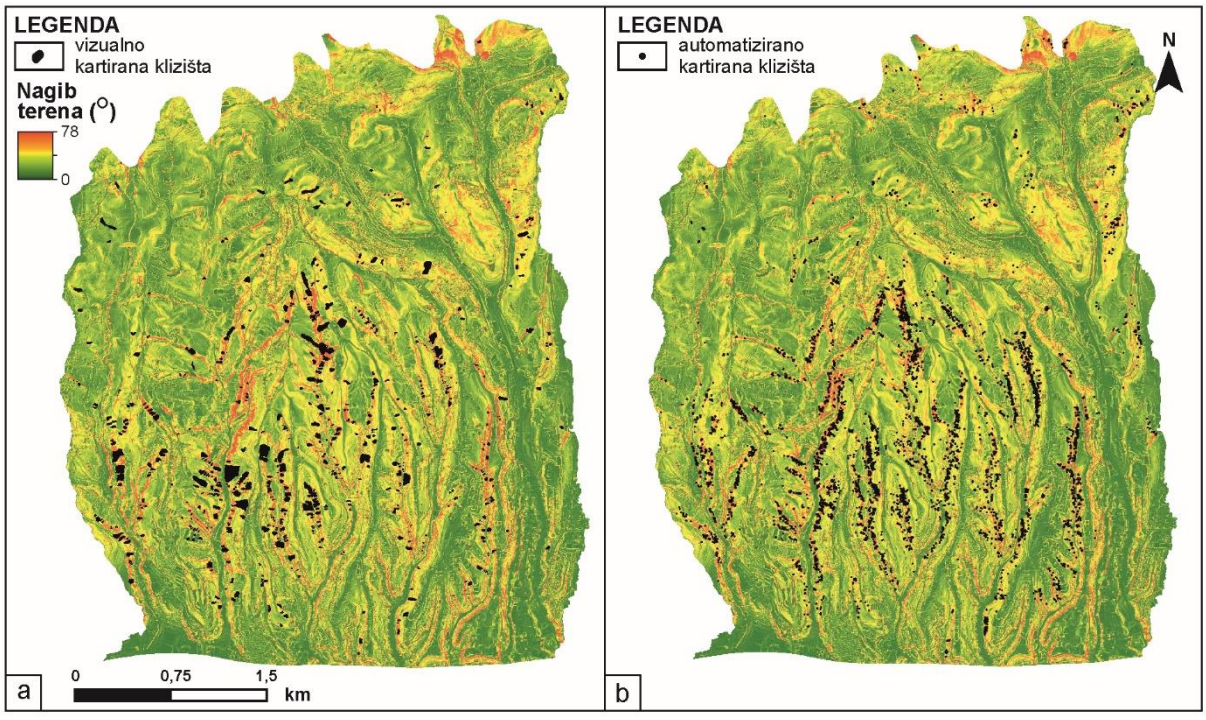

Slika 8.3 Karta nagiba visina na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

U tablici 8.3 prikazani su težinski faktori WoE modela izračunati na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}). S obzirom na težinski faktor koji je izračunat na temelju površina vizualno kartiranih klizišta (w_{plg}), negativan utjecaj na stabilnost padina imaju sve klase s nagibom terena većim 15°, pri čemu relativno najveći utjecaj ima klasa 35-40°. Težinski faktor izračunat s obzirom na broj vizualno kartiranih klizišta (w_{pt}) pokazao je da klase nagiba terena od 15° do 45° imaju negativan utjecaj na stabilnost padina. Prema modelu za automatizirano kartiranje klizišta, negativan utjecaj na stabilnost padina imaju klase nagiba terena 25-50°. U klasama od 0° do 25° te klasi nagiba većoj od 55° ovim modelom je identificiran vrlo mali broj klizišta što se odražava na težinski faktor WoE modela (w_{aut}) kao pozitivan utjecaj na stabilnost padina.

Tablica 8.3 Analiza utjecaja nagiba terena na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta ($br./km^2$)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
0-5°	4,777	0,009	7	1	4	-2,813	-3,366	-6,498
5-10°	4,669	0,038	34	7	8	-1,320	-1,716	-5,775
10-15°	3,661	0,061	68	19	9	-0,484	-0,668	-5,355
15-20°	2,904	0,085	110	38	16	0,191	0,155	-4,504
20-25°	2,099	0,101	138	66	13	0,786	0,798	-4,344
25-30°	1,322	0,091	167	126	2945	1,185	1,545	2,008
30-35°	0,823	0,074	108	131	2040	1,470	1,502	1,988
35-40°	0,479	0,048	53	111	2200	1,536	1,261	2,650
40-45°	0,236	0,022	17	72	1041	1,437	0,305	2,450
45-50°	0,097	0,007	7	72	198	1,074	-3,366	1,583
> 55°	0,048	0,001	0	0	12	0,102	-3,366	-0,535
ukupno:	21,11	0,537	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

Karta orijentacije padina (slika 8.4) izrađena je podjelom pilot područja na devet klasa: zaravnjen teren, sjever, sjeveroistok, istok, jugoistok, jug, jugozapad, zapad i sjeverozapad. Najveća gustoća vizualno kartiranih klizišta je u klasi padina orijentiranih prema sjeveroistoku (71 klizišta/km^2), zatim prema zapadu (57 klizišta/km^2) i sjeverozapadu (47 klizišta/km^2). Najmanja gustoća klizišta je u klasama padina orijentiranih prema jugoistoku (13 klizišta/km^2) i jugu (8 klizišta/km^2), dok na zaravnjenim terenima nisu identificirana klizišta.

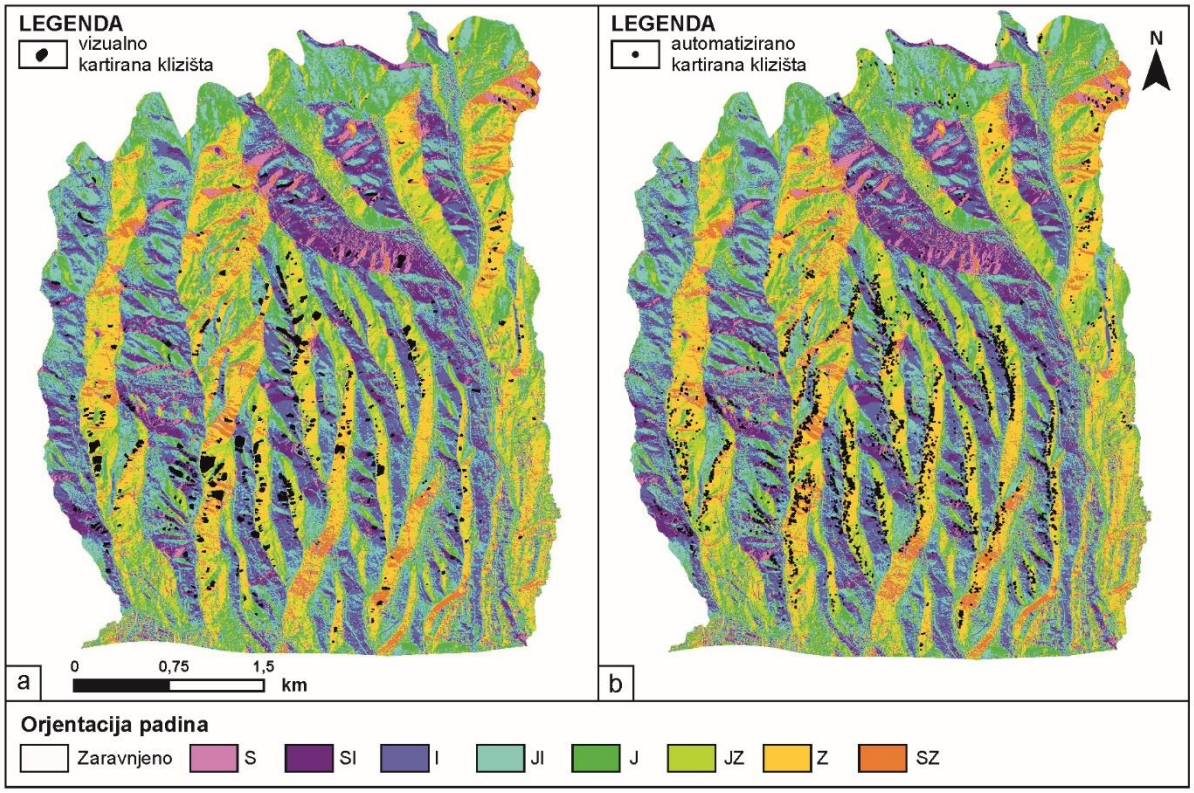

Slika 8.4 Karta orijentacije padina na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

U tablici 8.4 prikazani su težinski faktori WoE modela izračunati na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}). S obzirom na težinski faktor koji je izračunat na temelju površina vizualno kartiranih klizišta (w_{plg}) negativan utjecaj na stabilnost padina na pilot području imaju padine orijentirane prema sjeveru, sjeveroistoku, zapadu i sjeverozapadu, pri čemu je relativno najveći utjecaj padina orijentiranih prema sjeveru. Težinski faktor izračunat s obzirom na broj vizualno kartiranih klizišta (w_{pt}) pokazao je da padine orijentirane prema sjeveroistoku, istoku, zapadu i sjeverozapadu imaju negativan utjecaj na stabilnost padina. Težinski faktori dobiveni modelom za automatizirano kartiranje klizišta (w_{aut}) pokazuju da najveći negativan utjecaj na stabilnost padina ima klasa padina orijentiranih prema zapadu, zbog toga što je u njima identificiran najveći broj klizišta. Osim njih, negativan utjecaj na stabilnost padina također imaju klase padina orijentirane prema sjeveru, sjeveroistoku, jugozapadu i zapadu.

Tablica 8.4 Analiza utjecaja orijentacije padine na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta (br./km^2)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
zaravnjeno	0,000	0,000	0	0	0	-	-	-
S	0,785	0,080	26	33	31	1,473	-0,030	-2,532
SI	1,900	0,073	135	71	1294	0,347	0,853	0,423
I	4,040	0,105	141	35	1052	-0,112	0,035	-0,690
JI	3,469	0,045	46	13	15	-0,896	-1,056	-4,886
J	2,998	0,027	25	8	39	-1,282	-1,526	-3,756
JZ	3,217	0,072	73	23	1602	-0,279	-0,463	0,082
Z	3,546	0,150	201	57	4439	0,525	0,662	1,518
SZ	1,159	0,043	55	47	14	0,307	0,355	-3,736
ukupno:	21,11	0,537	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

8.1.2 Geološki preduvjeti klizanja

Na temelju pretpostavke o utjecaju geoloških preduvjeta na pojavu klizišta na pilot području, iz digitalizirane Osnovne geološke karte M 1:100.000 izvedene su slijedeće geološke faktorske karte: karta stratigrafskih jedinica, karta udaljenosti od geoloških granica i karta udaljenosti od rasjeda. Izdvojene stratigrafske jedinice s OGK-a M1:100.000 list Zagreb (Šikić et al., 1979) predstavljaju osnovnu stijenu, jer podaci o pokrivaču nisu prikazani na ovoj karti. Na osnovi stratigrafskih jedinica, izrađena je karta litoloških jedinica (slika 8.5) koja je korištena za procjenu utjecaja pojedinih vrsta stijena/tala na pojavu klizišta. Na osnovi stratigrafskih jedinica ukupno je definirano 11 klasa: šljunak i pijesak (holocen-aluvij recentnih tokova); šljunak s pijeskom i glinom (holocen-proluvij); prah i glina (pleistocen-kopneni prapor); šljunak, pijesak, prah i glina (pliokvartar); glinoviti pijesak i prah (gornji pont); glinoviti lapor i glina (donji pont); vapnenački i glinoviti lapor (gornji panon); laporoviti vapnenac i lapor (donji panon); pješčenjak i prahoviti (dijatomjeski) lapor (sarmat); bioklastični vapnenac i lapor (gornji baden); i metamorfiti (silur-karbon). Najveća gustoća vizualno kartiranih klizišta je na područjima izgrađenim od pliokvartarnih šljunaka, pijesaka, prahova i glina (56 klizišta/km^2), gornjopontskih glinovito-pjeskovitih lapora, glina i glinovitih pijesaka (35 klizišta/km^2) te aluvijalnih naslaga (30 klizišta/km^2). Slijede pleistocenski kopneni prapori s 12 klizišta/km^2, donjopontski glinoviti lapori s 8 klizišta/km^2, gornjopanonaski vapnenački lapori s 2 klizišta/km^2 i gornjobadenski bioklastični vapnenci s 1 klizištem/km^2. U proluvijalnim naslagama, naslagama donjeg panona i sarmatskim naslagama nisu identificirana klizišta na pilot području.

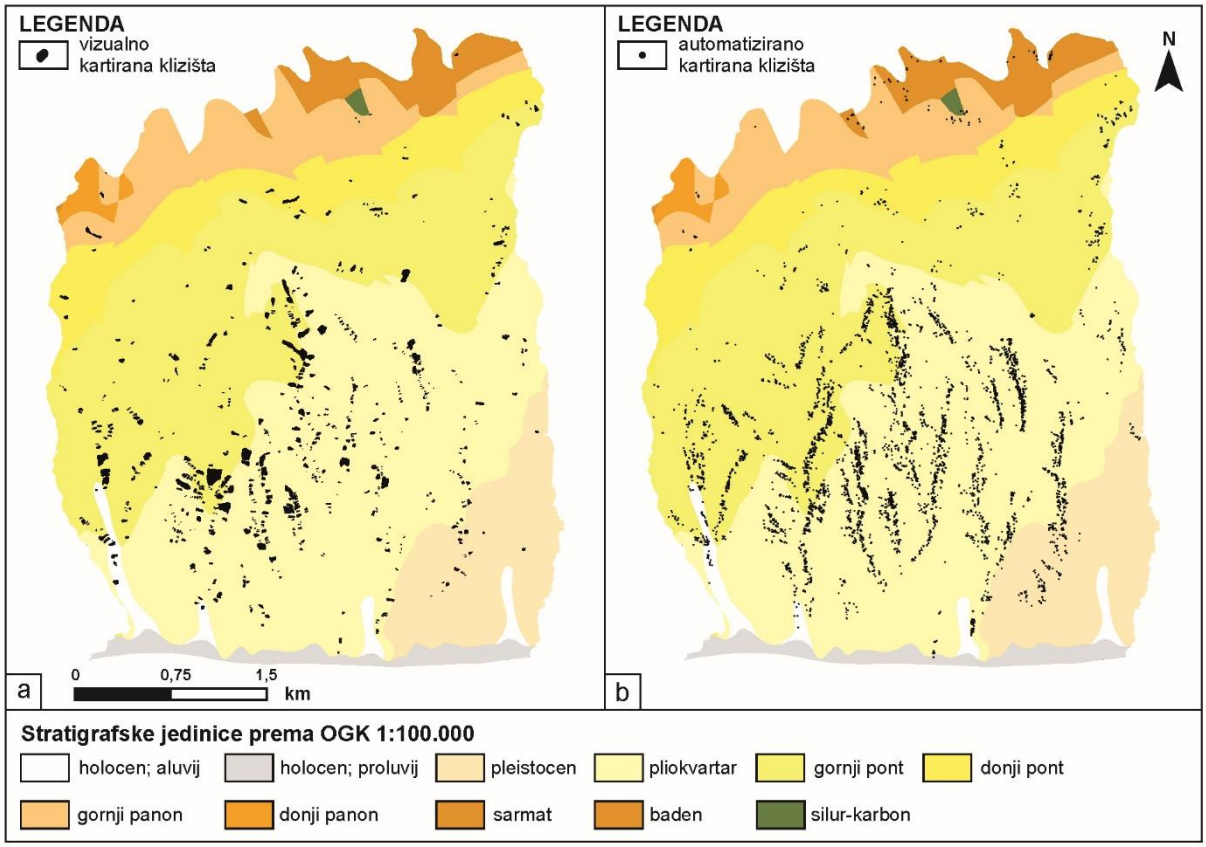

Slika 8.5 Karta stratigrafskih jedinica na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

U tablici 8.5 prikazani su težinski faktori WoE modela izračunati na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}). S obzirom na težinski faktor koji je izračunat na temelju površina vizualno kartiranih klizišta (w_{plg}), negativan utjecaj na stabilnost padina na pilot području imaju dijelovi terena izgrađeni od pliokvartarnih i gornjopontskih naslaga. Prema težinskom faktoru izračunatom na temelju broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}) utjecaj na nestabilnost padina na pilot području imaju samo dijelovi terena izgrađeni od pliokvartarnih naslaga.

Tablica 8.5 Analiza utjecaja litologije na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta ($br./km^2$)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
holocen: aluvij	0,332	0,009	10	30	101	-0,172	-0,343	-0,524
holocen: proluvij	0,499	0,000	0	0	2	-	-	-4,875
pleistocen	1,897	0,012	22	12	290	-1,684	-1,360	-1,269
pliokvartar	7,779	0,297	432	56	5198	0,582	0,765	0,754
gornji pont	6,154	0,198	216	35	2677	0,167	-0,167	-0,129
donji pont	1,815	0,015	15	8	78	-1,365	-1,704	-2,560
gornji panon	1,762	0,006	6	3	50	-2,310	-2,602	-2,975
donji panon	0,160	0,000	0	0	0	-	-	-
donji sarmat	0,003	0,000	0	0	0	-	-	-
gornji baden	0,681	0,001	1	1	84	-3,352	-3,396	-1,448
silur-karbon	0,030	0,000	0	0	6	-3,113	-	-0,940
ukupno:	21,11	0,537	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

Na osnovi digitaliziranih linijskih podataka o normalnim i transgresivnim geološkim granicama s OGK-a M 1:100.000 list Zagreb (Šikić et al., 1979) definirano je 9 klasa udaljenosti od geoloških granica u slijedećim rasponima (slika 8.6): 0-100 m, 100 -200 m, 200-300 m, 300-400 m, 400-500 m, 500-600 m, 600-700 m, 700-800 m i više od 800 m. Najveća gustoća vizualno kartiranih klizišta je u klasi udaljenosti 600-700 m od geološke granice (74 klizišta/km^2), a najmanja u klasi udaljenosti 100-200 m (21 klizište/km^2). Općenito se može zaključiti da se gustoća klizišta povećava s povećanjem udaljenosti od geoloških granica (tablica 8.6).

U tablici 8.6 prikazani su težinski faktori WoE modela izračunati na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}). S obzirom na težinski faktor koji je određen na temelju površina vizualno kartiranih klizišta (w_{plg}) negativan utjecaj na stabilnost padina na pilot području ima klasa udaljenost do 100 m od geoloških granica te klase udaljenosti veće od 300 m od geoloških granica. Prema težinskom faktoru određenom na temelju broja vizualno kartiranih klizišta (w_t) na nestabilnost padina utječu klase udaljenosti veće od 300 m od geoloških granica, a prema težinskom faktoru određenom na temelju broja automatizirano kartiranih klizišta (w_{aut}) klase udaljenosti veće od 200 m od geoloških granica.

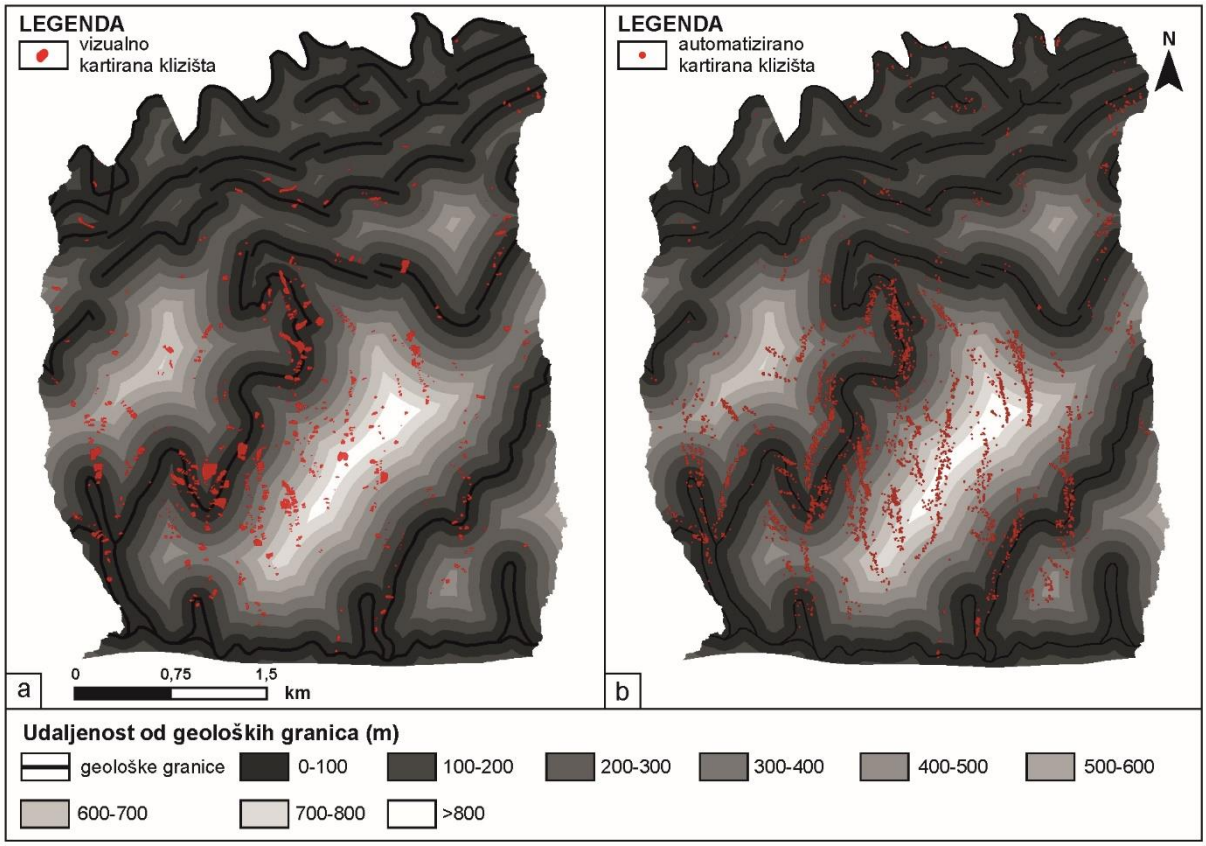

Slika 8.6 Karta udaljenosti od geoloških granica na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

Tablica 8.6 Analiza utjecaja udaljenosti od geoloških granica na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta (br./km^2)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
0-100	7,58	0,20	204	27	2263	0,072	-0,269	-0,382
100-200	4,99	0,09	103	21	1345	-0,396	-0,544	-0,446
200-300	2,91	0,05	76	26	1214	-0,480	-0,230	0,096
300-400	2,08	0,06	93	45	933	0,140	0,380	0,174
400-500	1,36	0,05	79	58	835	0,330	0,655	0,512
500-600	0,93	0,04	59	64	621	0,456	0,735	0,592
600-700	0,67	0,03	49	74	612	0,586	0,880	0,922
700-800	0,41	0,02	27	66	398	0,528	0,754	0,968
> 800	0,20	0,01	12	61	263	0,601	0,664	1,308
ukupno:	21,11	53745,0	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

Za potrebe analize utjecaja rasjeda na pojavu klizišta digitalizirano je ukupno 15 rasjeda s OGK M 1:100.000 list Zagreb. Rasjedi na pilot području generalnog su pružanja SZ-JI i JZ-SI. Na osnovi linijskih podataka o rasjedima definirano je 11 klasa udaljenosti od rasjeda u slijedećim rasponima: 0-100 m, 100-200 m, 200-300 m, 300-400 m, 400-500 m, 500-600 m, 600-700 m, 700-800 m, 800-900 m, 900-1000 m i više od 1000 m. Najveća gustoća vizualno kartiranih klizišta je u klasi udaljenosti od rasjeda 700-800 m (66 klizišta/km^2), a najmanja gustoća je u klasi udaljenosti 0-100 m (16 klizište/km^2). Općenito se može zaključiti da se gustoća klizišta povećava s povećanjem udaljenosti od rasjeda do udaljenosti od 800 m. (tablica 8.7).

U tablici 8.7 prikazani su težinski faktori WoE modela izračunati na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_t) i broja automatizirano kartiranih klizišta (w_{aut}). S obzirom na težinske faktore koji su definirani na temelju površina vizualno kartiranih klizišta (w_{plg}) i broja vizualno kartiranih klizišta (w_{pt}) negativan utjecaj na stabilnost padina na pilot području imaju klase udaljenosti veće od 300 m od rasjeda. Prema težinskom faktoru određenom na temelju broja automatizirano kartiranih klizišta (w_{aut}) također sve klase udaljenosti između 300 m i 1000 m od rasjeda utječu na pojavu klizišta na pilot području.

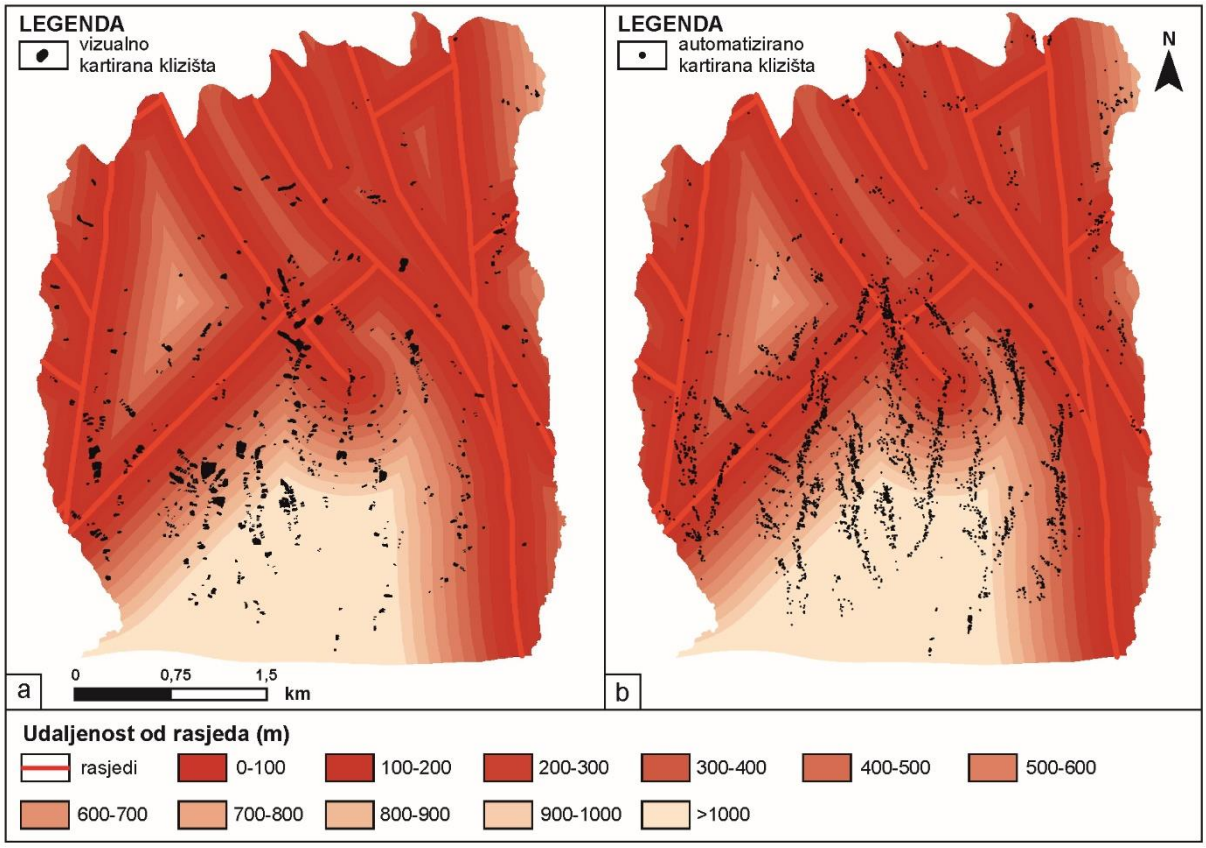

Slika 8.7 Karta udaljenosti od rasjeda na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

Tablica 8.7 Analiza utjecaja udaljenosti od rasjeda na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta ($br./km^2$)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
0-100	4,920	0,067	80	16	1273	-0,744	-0,836	-0,518
100-200	4,064	0,092	94	23	938	-0,129	-0,409	-0,626
200-300	3,011	0,060	78	26	1003	-0,263	-0,262	-0,190
300-400	1,983	0,057	96	48	1131	0,162	0,448	0,420
400-500	1,261	0,049	69	55	762	0,490	0,563	0,466
500-600	0,939	0,041	48	51	493	0,626	0,478	0,307
600-700	0,717	0,037	45	63	422	0,792	0,690	0,423
700-800	0,545	0,027	36	66	536	0,755	0,737	0,961
800-900	0,487	0,018	26	53	485	0,429	0,510	0,968
900-1000	0,471	0,013	21	45	339	0,139	0,325	0,627
>1000	2,717	0,075	109	40	1104	0,124	0,242	0,038
ukupno:	21,11	53745,0	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

8.1.3 Hidrološki preduvjeti klizanja

Drenažna mreža na istraživanom području dobivena je pomoću alata *Hidrology* u *ArcGIS 10.0* iz digitalnog modela reljefa rezolucije 1 m. Na osnovi linijskih podataka koji predstavljaju drenažnu mrežu definirano je 5 klasa udaljenosti od drenažne mreže (slika 8.8): 0-50 m, 50-100 m, 100-150 m, 150-200 m i više od 200 m. Najveća gustoća vizualno kartiranih klizišta je u klasi udaljenosti od drenažne mreže 0-50 m (50 klizišta/km^2), a najmanja gustoća klizišta je u klasu udaljenosti većoj od 200 m od drenažne mreže. Općenito se može zaključiti da se gustoća klizišta smanjuje s povećanjem udaljenosti od drenažne mreže (tablica 8.8).

U tablici 8.8 prikazani su težinski faktori WoE modela izračunati na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}) i može se zaključiti da negativan utjecaj na stabilnost padina na pilot području ima klasa udaljenosti do 50 m od drenažne mreže, te se relativan utjecaj na pojavu klizišta smanjuje s povećanjem udaljenosti od drenažne mreže.

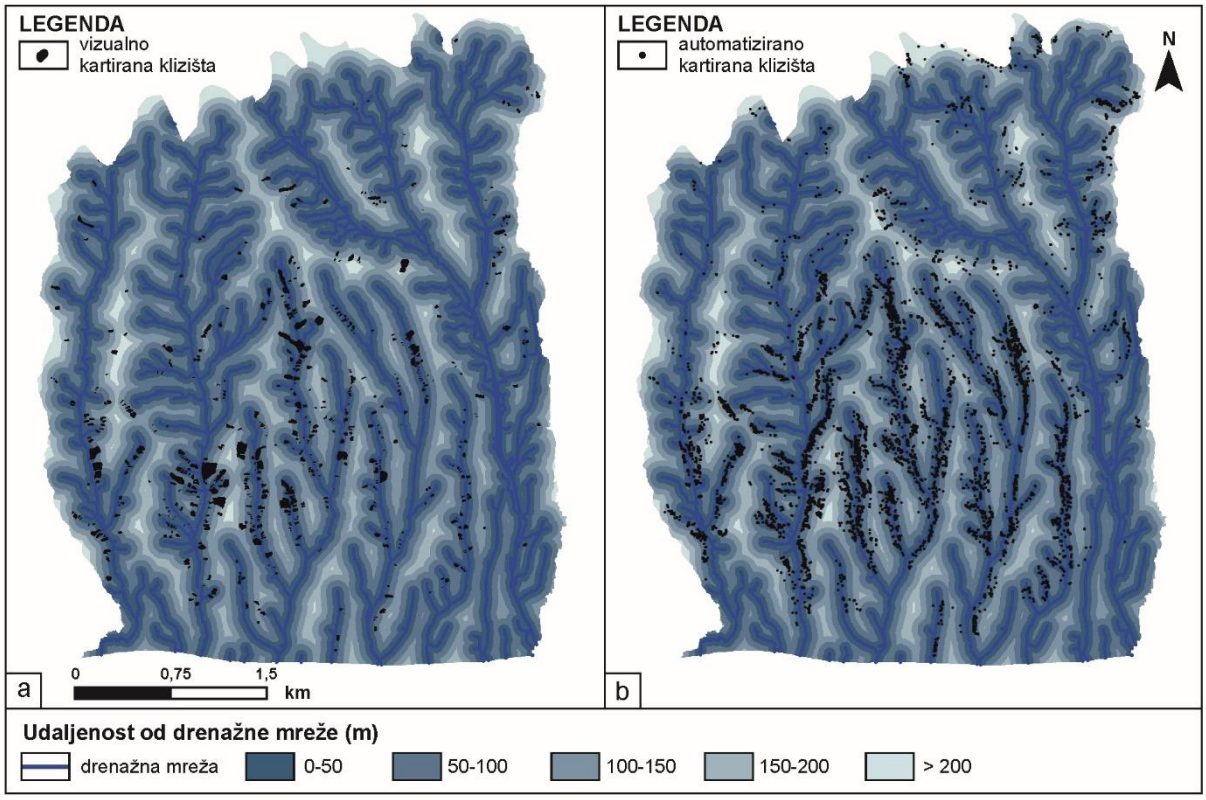

Slika 8.8 Karta udaljenosti od drenažne mreže na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

Tablica 8.8 Analiza utjecaja udaljenosti od drenažne mreže na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta (br./km^2)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
0-50	8,662	0,298	437	50	5644	0,479	0,668	0,780
50-100	6,371	0,158	173	27	2102	-0,155	-0,474	-0,541
100-150	4,007	0,064	74	18	613	-0,685	-0,882	-1,371
150-200	1,657	0,015	17	10	104	-1,220	-1,428	-2,196
> 200	0,417	0,002	1	2	23	-1,817	-2,843	-2,273
ukupno:	21,11	53745,0	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

8.1.4 Antropogeni preduvjeti klizanja

Utjecaj antropogenih faktora na klizanje analiziran je na osnovi karata izvedenih iz stvarnog korištenja zemljišta Grada Zagreba iz 2011. godine. Na temelju pretpostavke o utjecaju antropogenih faktora na pojavu klizišta na pilot području, izvedene su dvije faktorske karte, karta stvarnog korištenja zemljišta i karta udaljenosti od objekata i prometnica.

Karta stvarnog korištenja zemljišta Grada Zagreba iz 2011. godine (slika 8.9) reklasificirana je u četiri klase namjene zemljišta, a to su umjetne površine, poljoprivredne površine, šume i povremene vodene površine. Najveća gustoća klizišta je u klasi šume (104 klizišta/km^2), slijede poljoprivredne površine s 14 klizišta/km^2 i povremene vodene površine s 9 klizišta/km^2. Najmanja gustoća klizišta je na umjetnim površinama s 4 klizišta/km^2. U tablici 8.9 prikazani su težinski faktori WoE modela izračunati na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}) i može se zaključiti da negativan utjecaj na stabilnost padina na pilot području imaju šumska područja.

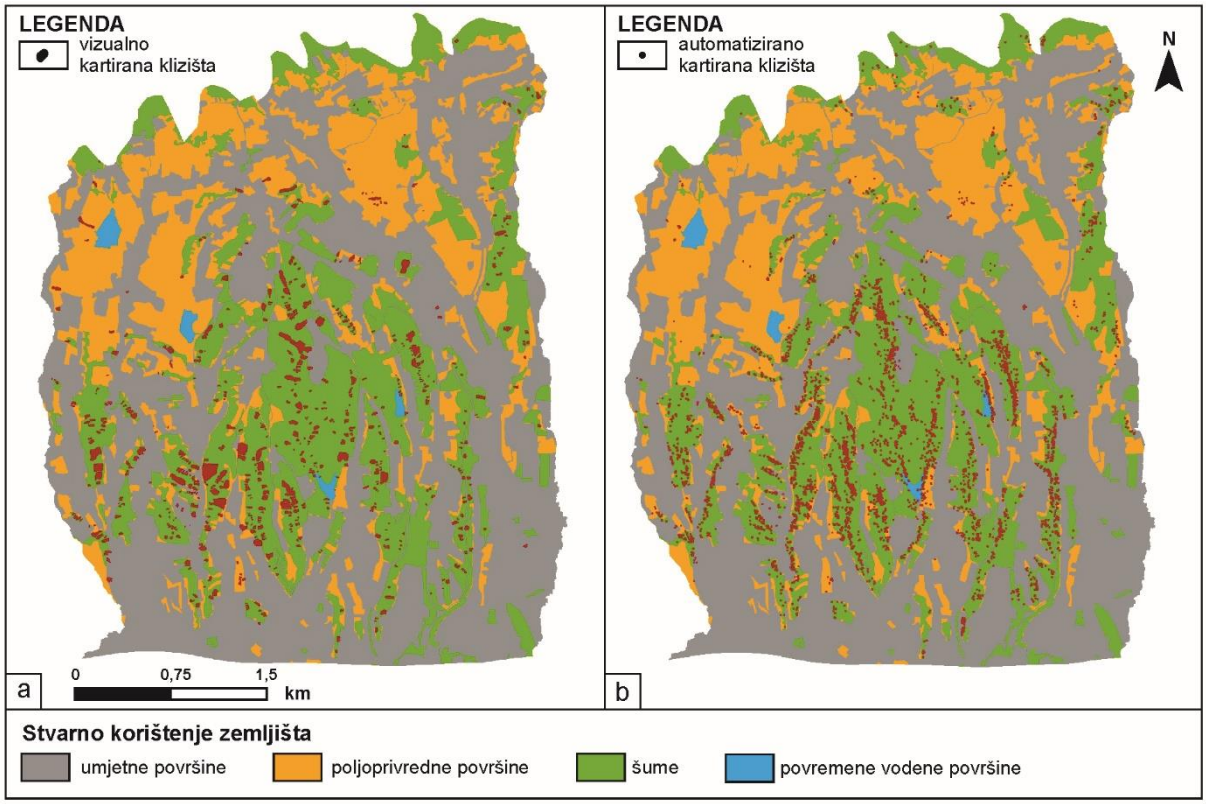

Slika 8.9 Karta stvarnog korištenje zemljišta na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

Tablica 8.9 Analiza utjecaja stvarnog korištenja zemljišta na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta ($br./km^2$)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
umjetne površine	10,507	0,037	38	4	579	-3,322	-3,640	-4,470
poljoprivredne površine	4,571	0,051	66	14	7586	-1,671	-1,768	-2,414
šume	5,924	0,448	597	104	276	1,932	1,891	1,989
vodene površine	0,112	0,001	1	9	45	-2,206	-2,110	-1,089
¸ukupno:	21,11	53745,0	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

Karta udaljenosti od građevina i prometnica (slika 8.10) izrađena je na temelju podloga o stvarnom korištenju zemljišta Grada Zagreba iz 2011. godine te je ukupno definirano šest klasa: 0-10 m, 10-25 m, 25-50 m, 50-75 m, 75-100 m i više od 100 m. Najveća gustoća vizualno kartiranih klizišta na pilot području je u klasi udaljenosti 75-100 m od građevina i prometnica (114 klizišta/km^2), a najmanja u klasi udaljenosti 0-10 m i većoj od 100 m (25 klizišta/km^2 i 23 klizišta/km^2).

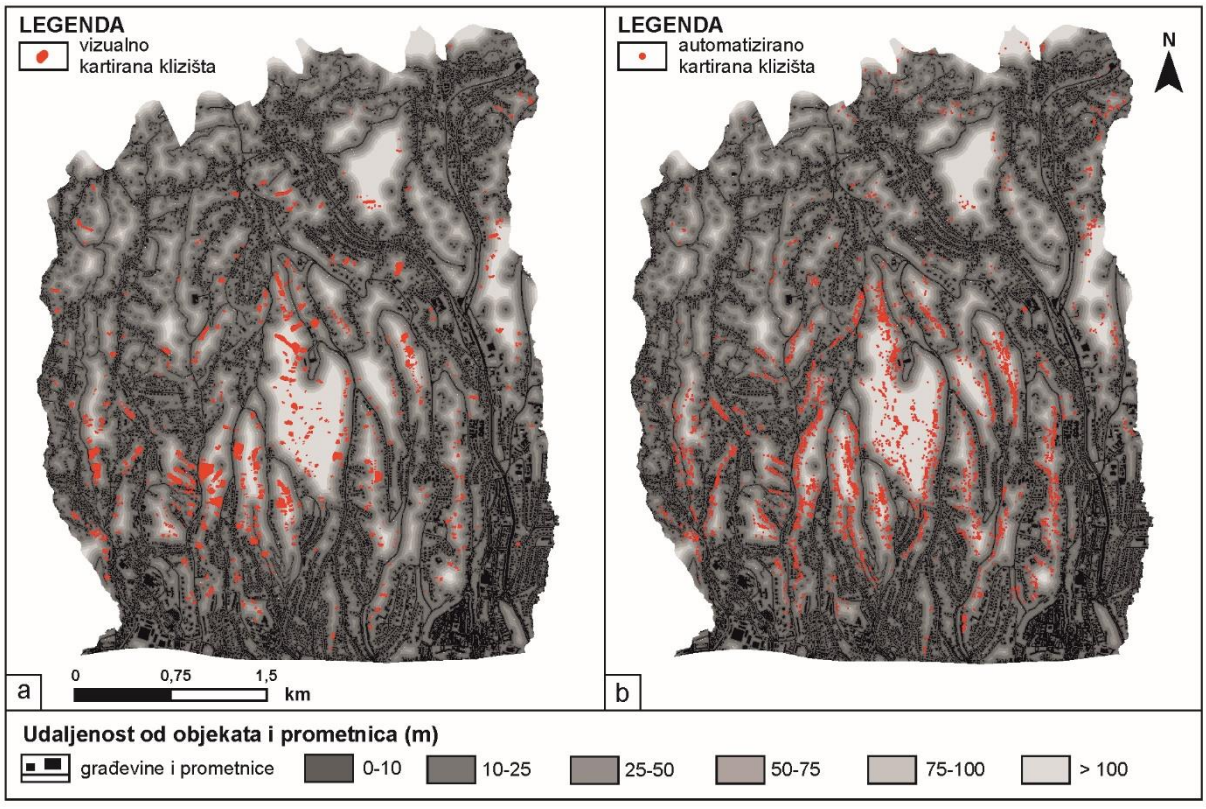

Slika 8.10 Karta udaljenosti od građevina i prometnica na pilot području (21 km^2): (a) vizualno kartirana klizišta; (b) automatizirano kartirana klizišta.

U tablici 8.10 prikazani su težinski faktori WoE modela određeni na temelju površina vizualno kartiranih klizišta (w_{plg}), broja vizualno kartiranih klizišta (w_{pt}) i broja automatizirano kartiranih klizišta (w_{aut}). Može se zaključiti da negativan utjecaj na stabilnost padina na pilot području imaju klase udaljenosti veće od 10 m od građevina i prometnica. S obzirom na broj vizualno kartiranih klizišta (w_{pt}) negativan utjecaj na stabilnost padina imaju klase udaljenosti između 25 i 100 m od građevina i prometnica.

Tablica 8.10 Analiza utjecaja udaljenosti od građevina i prometnica na pojavu klizišta primjenom WoE modela.

Klase faktora klizanja	Površina klase (km^2)	Vizualno kartirana klizišta			Automatizirano kartirana klizišta	Težinski faktor		
		Površina klizišta (km^2)	Broj klizišta	Gustoća klizišta ($br./km^2$)	Broj točaka klasificiranih kao klizišta	w_{plg}*	w_{pt}**	w_{aut}***
0-10	10,411	168057	257	25	3150	-0,670	-0,434	-0,420
10-25	5,516	141860	167	30	2295	0,123	-0,037	0,127
25-50	2,430	89349	116	48	1270	0,550	0,508	0,383
50-75	1,220	55553	71	58	695	0,762	0,694	0,455
75-100	0,611	53861	70	114	629	1,495	1,400	1,068
> 100	0,917	28755	21	23	447	0,335	-0,299	0,283
ukupno:	21,11	53745	702		8486			

* w_{plg} - težinski faktor izračunat na temelju površina vizualno kartiranih klizišta; ** w_{pt} - težinski faktor izračunat na temelju broja vizualno kartiranih klizišta; *** w_{aut} - težinski faktor izračunat na temelju broja automatizirano kartiranih klizišta

8.2 Karte podložnosti na klizanje

Analiza preduvjeta klizanja i izrađeni inventari klizanja omogućili su izradu karata podložnosti na klizanja, koje su prve u nizu prognostičkih karata hazarda klizanja. Izrađene su ukupno tri karte podložnosti na klizanje na osnovi težinskih faktora izračunatih iz gustoća klizišta u tri različita inventara izrađena u okviru ovog rada. Svrha izrade karata podložnosti bila je validacija inventara klizišta, odnosno modela za automatizirano kartiranje klizišta.

Ulazni podaci za izradu svih karata podložnosti bile su težine (w) svih pojedinih klasa faktora klizanja koje predstavljaju relativan utjecaj preduvjeta klizanja, a koje su izračunate u okviru analize preduvjeta klizanja na pilot području (21 km^2). Prema WoE modelu, devet karata težinskih faktora, odnosno karata s definiranim težinama za svaku pojedinu klasu faktora klizanja je zbrojeno kako bi se dobila ukupna težina (w_{uk}), koja predstavlja vrijednost podložnosti na klizanje. Vrijednosti podložnosti na klizanje računate su na temelju površina vizualno kartiranih klizišta (slika 8.11a), broja vizualno kartiranih klizišta (slika 8.11b) i klizišta dobivenih modelom za automatizirano kartiranje klizišta (slika 8.12). Konačna vrijednost podložnosti je iskazana kao vrijednost ukupne težine za svaku ćeliju dimenzija 1x1 m na cijelom pilot području. Kod karata podložnosti na klizanje izrađenih na temelju potpunog inventara vizualno interpretiranih klizišta, konačna vrijednost ukupne težine je od -19,0 do 10,5 za analizirane preduvjete klizanja s obzirom na cjelovite površine klizišta, odnosno -16,5 do 10,0 za analizirane preduvjete samo s obzirom na broj klizišta. Raspodjela učestalosti vrijednosti ukupne težine za obje karte podložnosti izrađene na temelju potpunog inventara vizualno kartiranih klizišta prikazana je na slikama 8.11a i 8.11b. Vrijednost ukupne težine izračunata na temelju automatizirano kartiranih klizišta ima raspon od -25,1 do 12,0, a raspodjela vrijednosti ukupne težine prikazana je na slici 8.12. Vidljivo je da karte podložnosti na klizanje dobivene na osnovi vizualno kartiranih klizištima imaju manji raspon ukupnih težina (w_{uk}) od karte podložnosti na klizanje dobivene na osnovi automatizirano kartiranih klizišta.

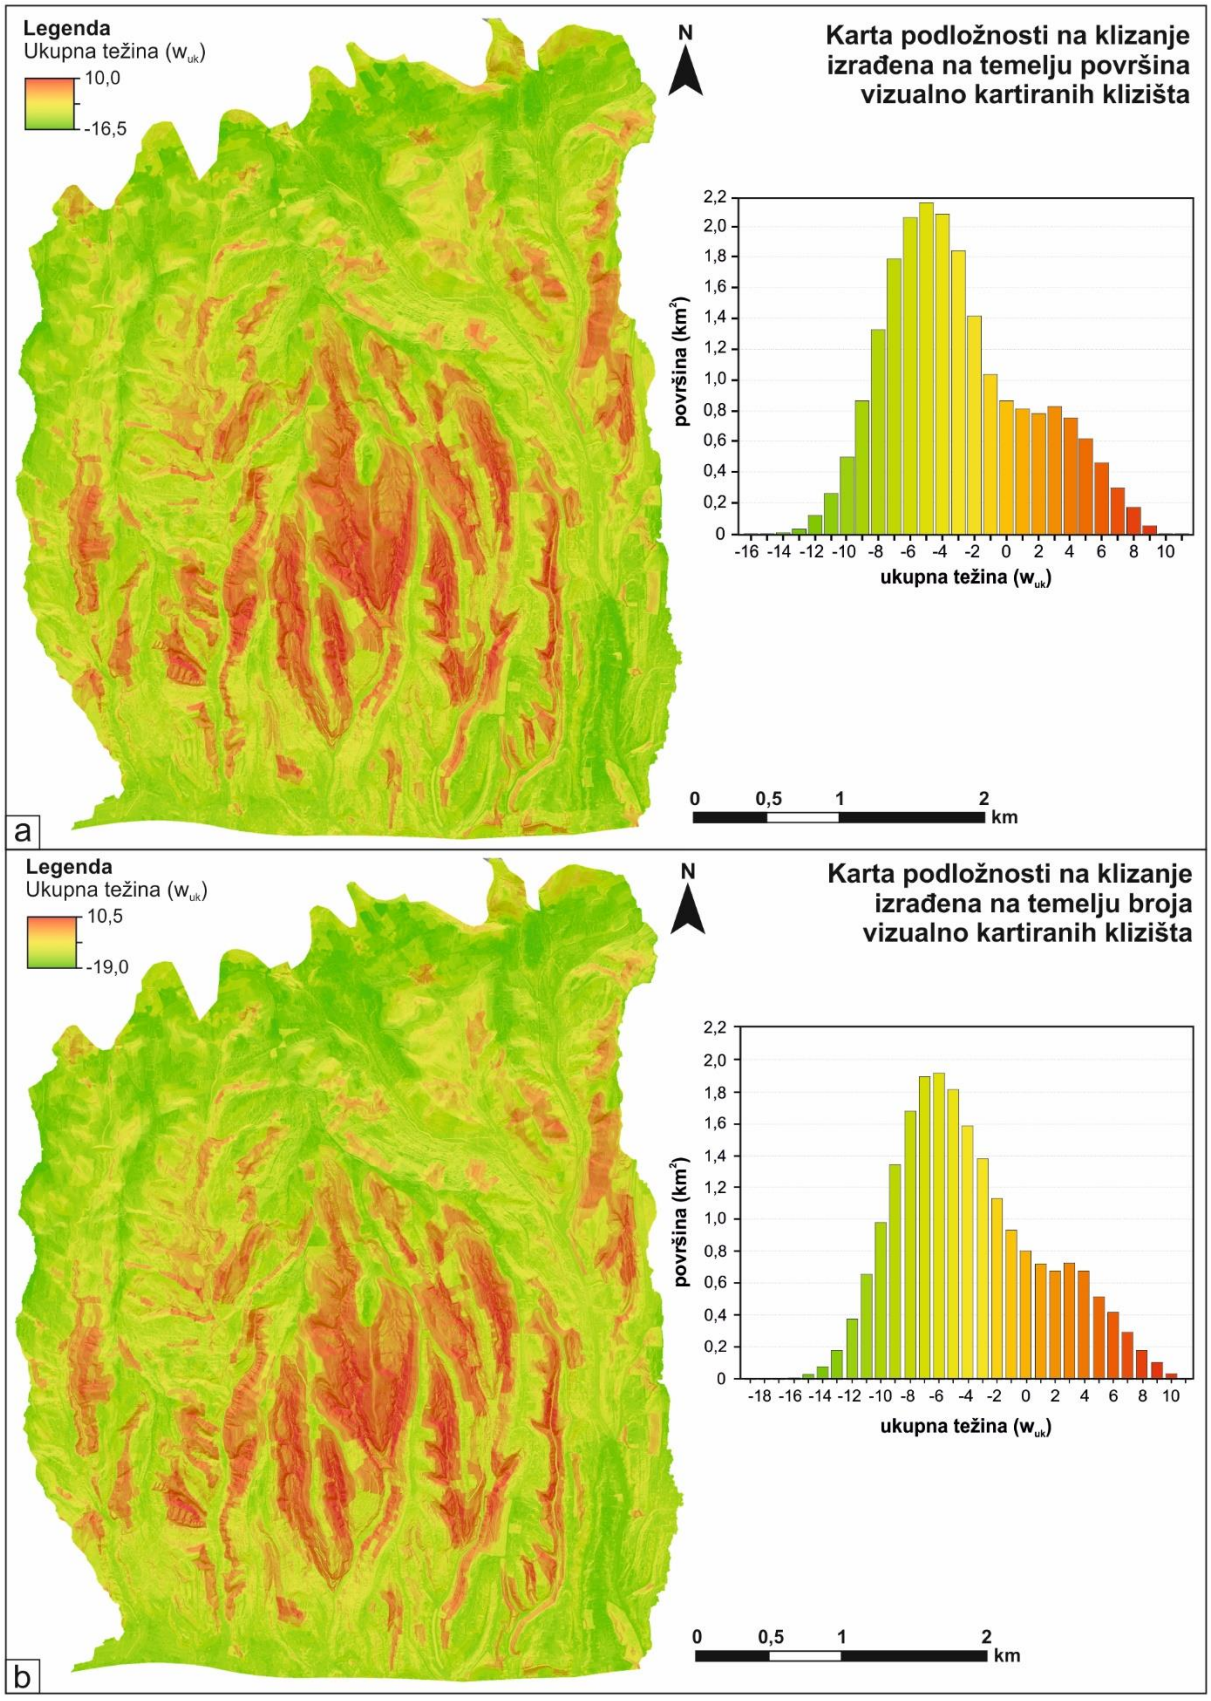

Slika 8.11 Karte podložnosti na klizanje izrađene na temelju potpunog inventara klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a: (a) prostorna raspodjela i učestalost vrijednosti podložnosti na klizanje na temelju površina vizualno kartiranih klizišta; (b) prostorna raspodjela i učestalost vrijednosti podložnosti na klizanje na temelju broja vizualno kartiranih klizišta.

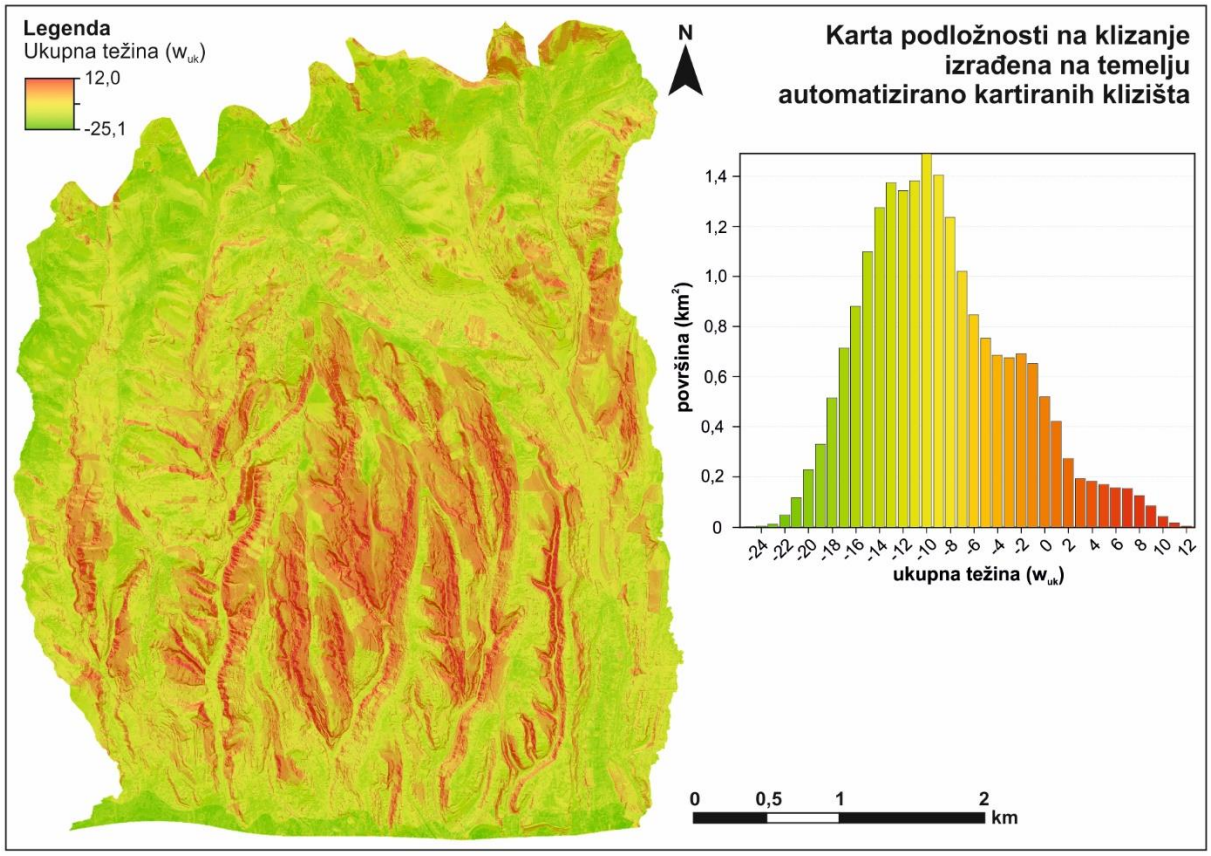

Slika 8.12 Karta podložnosti na klizanje izrađena na temelju inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta iz LiDAR DMT-a.

Analiza točnosti karata podložnosti na klizanje provedena je pomoću ROC krivulja (slika 8.13) koje su konstruirane na način da je na apscisi prikazana kumulativna površina vrijednosti svake od karata podložnosti na klizanje, a na ordinati kumulativna površina, odnosno broj klizišta u inventaru. Analiza točnosti provedena je za cijelo pilot područje površine 21 km^2. Za svaku od karata podložnosti na klizanje konstruirana je ROC krivulja s obzirom na inventar klizišta na temelju kojeg je izvedena. Stopa točnosti karata uspoređena je pomoću AUC vrijednosti, odnosno površine ispod ROC krivulje za svaku od izvedenih karata podložnosti na klizanja. ROC krivulja za karte podložnosti na klizanje izvedene na temelju potpunih inventara vizualno kartiranih klizišta pokazuje da se na 20 % područja visoke podložnosti nalazi 80 % klizišta. U slučaju karte podložnosti na klizanje izvedene na temelju automatizirano kartiranih klizišta, na 20 % područja visoke podložnosti nalazi se gotovo 98 % automatizirano kartiranih klizišta. S obzirom na površinu ispod ROC krivulja, najvišu stopu točnosti (AUC=95 %) ima karta podložnosti na klizanje izvedena na temelju klizišta dobivenih modelom za automatizirano kartiranje klizišta, dok karte podložnosti na klizanje dobivene iz potpunog inventara vizualno interpretiranih klizišta iz LiDAR DMT-a imaju nižu točnost Procjena podložnosti s obzirom na površine cjelovitih klizišta ima stopu točnosti od 86 %, a s obzirom samo na broj klizišta 88 %.

Iz dobivenih stopa točnosti karata podložnosti na klizanje proizlazi da ne postoji značajna razlika ukoliko se prilikom analize utjecaja faktora klizanja koriste granice vizualno interpretiranih klizišta, odnosno poligoni koji predstavljaju cjelovita klizišta ili samo točke koja predstavljaju središnji dio kartiranog klizišta.

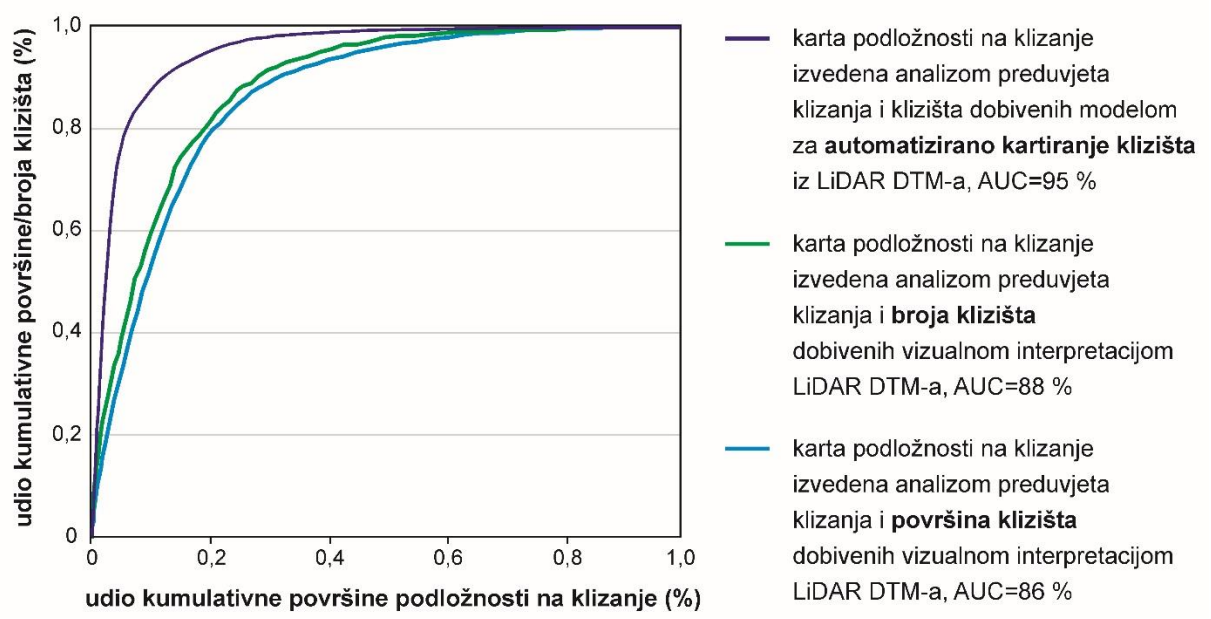

Slika 8.13 ROC krivulje za tri karte podložnosti na klizanje izvedenih na temelju površina klizišta dobivenih vizualnom interpretacijom LiDAR DMT-a, broja klizišta dobivenih vizualnom interpretacijom LiDAR DMT-a i inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta.

Karte podložnosti na klizanje dobivene na temelju automatizirano kartiranih klizišta verificirane su s obzirom na potpuni inventar vizualno interpretiranih klizišta (slika 8.14) na dijelu pilot područja na kojem je treniran model za automatizirano kartiranje klizišta (10,5 km^2), kao i području za verifikaciju modela (10,5 km^2). U odnosu na klizišta koja su vizualno kartirana kao poligoni, stopa predikcije karte podložnosti na klizanje na testnom području iznosi 81 %, dok u odnosu na inventar klizišta u kojemu su lokacije prikazane točkom, stopa predikcije iznosi 83 %. Na dijelu pilot područja za verifikaciju, stopa predikcije karte podložnosti na klizanje u odnosu na klizišta koja su vizualno kartirana kao poligoni iznosi 85 %, a u odnosu na inventar klizišta, u kojem su lokacije prikazane točkom, stopa predikcije iznosi 87 %. S obzirom na AUC vrijednosti dobivene validacijom karte podložnosti na klizanje izvedene na temelju automatizirano kartiranih klizišta proizlazi da model za automatizirano kartiranje klizišta omogućava kartiranje reprezentativnog uzorka klizišta koji omogućava izradu karte podložnosti na klizanje visoke točnosti i predikcije.

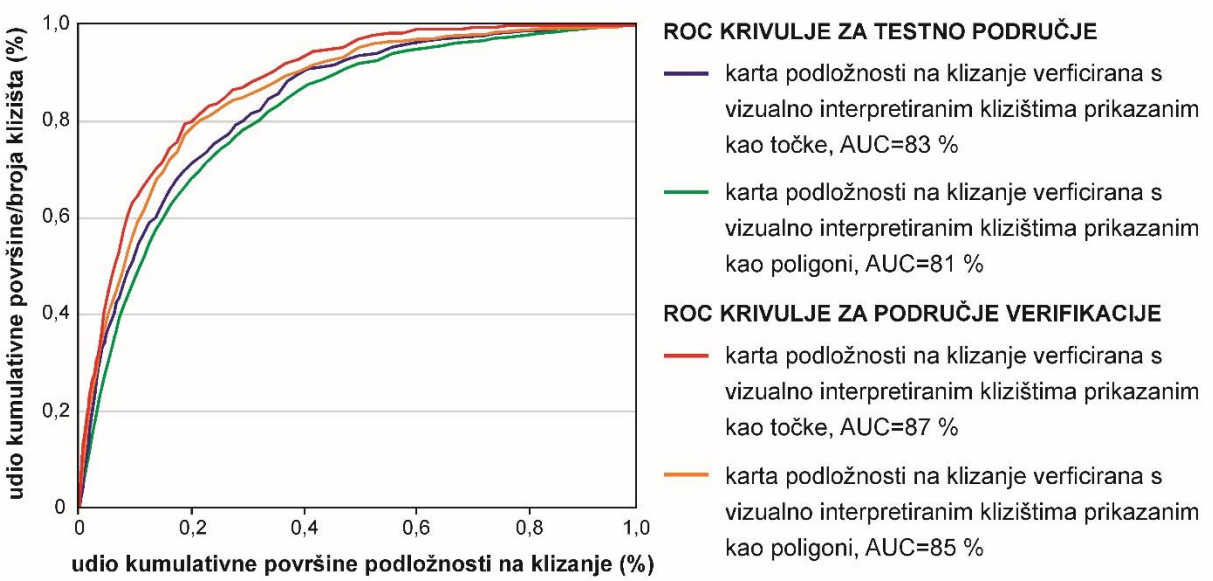

Slika 8.14 Verifikacija karte podložnosti na klizanje izvedene na temelju automatizirano kartiranih klizišta s inventarom klizišta dobivenog vizualnom interpretacijom LiDAR DMT-a. ROC krivulje prikazuju verifikaciju za testno područje i područje verifikacije na pilot području (21 km^2).

Za dodatnu usporedbu karte podložnosti na klizanje izvedene na temelju vizualno i automatizirano kartiranih klizišta, provedena je klasifikacija vrijednosti podložnosti na stabilne terene i nestabilne padine, a granične vrijednosti ovih klasa određene su s obzirom na raspodjelu vrijednosti na ROC krivulji. Nestabilne padine definirane su kao područja na kojima se nalazi 99 % kumulativne površine/broja klizišta, a suprotno tome, stabilne padine su područja sa svega 1 % površine/broja klizišta. Prostorna raspodjela i udio površina stabilnih i nestabilnih padina na kartama izvedenih na temelju vizualno i automatizirano kartiranih klizišta prikazana je na slici 8.15 i tablici 8.11. Na karti podložnosti na klizanje izrađenoj na temelju klizišta koja su vizualno kartirana kao poligoni, površina stabilnih padina iznosi 7,15 km^2 ili 33,87 % pilot područja, a površina nestabilnih padina iznosi 13,96 km^2 ili 66,13 % pilot područja. Udio stabilnih padina je veći na karti podložnosti na klizanje izvedenoj na temelju inventara u kojem su lokacije klizišta prikazane točkom i iznosi 9,03 km^2 ili 42,75 % pilot područja, dok je udio nestabilnih padina manji i iznosi 12,09 km^2 ili 57,25 % pilot područja. Na karti podložnosti na klizanje izvedenoj na temelju inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta udjeli stabilnih i nestabilnih padina su relativno jednaki kao na karti podložnosti na klizanje izvedenoj na temelju broja vizualno interpretiranih klizišta, a iznose 9,40 km^2 ili 44,53 % pilot područja za stabilne padine i 11,71 km^2 ili 55,47 % pilot područja za nestabilne padine.

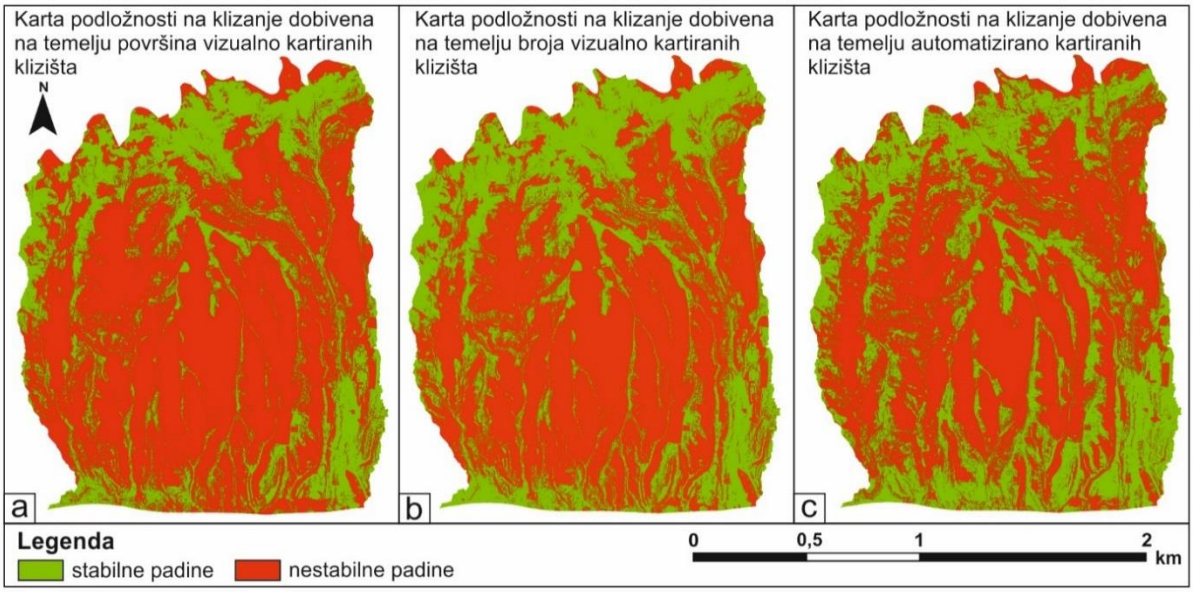

Slika 8.15 Usporedba karata podložnosti na klizanje klasificiranih na stabilne i nestabilne padine: (a) karta podložnosti izrađena na temelju površina vizualno kartiranih klizišta; (b) karta podložnosti izrađena na temelju broja vizualno kartiranih klizišta; (c) karta podložnosti izrađena na temelju automatizirano kartiranih klizišta.

Tablica 8.11 Usporedba površine stabilnih i nestabilnih padina na kartama podložnosti na klizanje izvedenih na temelju vizualno i automatizirano kartiranih inventara klizišta.

klasifikacija podložnosti	karta podložnosti na klizanje dobivena na temelju vizualno kartiranih klizišta (poligoni)		karta podložnosti na klizanje dobivena na temelju vizualno kartiranih klizišta (točke)		karta podložnosti na klizanje dobivena na temelju automatizirano kartiranih klizišta	
	km^2	%	km^2	%	km^2	%
stabilne padine	7,15	33,87	9,03	42,75	9,40	44,53
nestabilne padine	13,96	66,13	12,09	57,25	11,71	55,47

Stupanj kartografske podudarnosti položaja stabilnih i nestabilnih padina na različitim kartama podložnosti na klizanje, izvedenim na temelju vizualno i automatizirano kartiranih klizišta procijenjen je prema metodi koju je predložio Carrara et al. (1992). Sve tri izrađene karte podložnosti na klizanje (slika 8.15) međusobno su preklopljene, kako bi se iz unije i presjeka parova karata podložnosti odredio indeks podudarnosti (M) i indeks pogreške (E). Ukupno je analizirano tri kombinacije karata podložnosti, a rezultati su prikazani u tablici 8.12. Indeks pogreške je relativno nizak (E= 15 %) kada se usporede dvije karte podložnosti na klizanje izrađene na temelju vizualno interpretiranih klizišta, što također implicira relativno visokim indeksom podudarnosti (M= 85 %). Usporedbom karte podložnosti na klizanje izrađene na temelju automatizirano kartiranih klizišta s kartama podložnosti na klizanje izrađenim na temelju vizualno interpretiranih klizišta dobiveni su viši indeksi pogreške (E=25 % i E=30 %), odnosno niži indeksi podudarnosti (M= 70 %, M= 75 %).

Tablica 8.12 Usporedba kartografskog preklapanja karata podložnosti na klizanje dobivenih na temelju vizualno kartiranih klizišta, poligoni (KP1) i točke (KP2), i karte podložnosti dobivene na temelju automatizirano kartiranih klizišta (KP3).

površina nestabilnog terena u KP1	13,96 km^2
površina nestabilnog terena u KP3	11,71 km^2
KP1 ∪ KP3	15,04 km^2
KP1 ∩ KP3	10,64 km^2
indeks pogreške, E	29,26 %
indeks podudarnosti, M	70,74 %
površina nestabilnog terena u KP2	12,09 km^2
površina nestabilnog terena u KP3	11,71 km^2
KP2 ∪ KP3	14,04 km^2
KP2 ∩ KP3	10,64 km^2
indeks pogreške, E	24,25 %
indeks podudarnosti, M	75,75 %
površina nestabilnog terena u KP1	13,96 km^2
površina nestabilnog terena u KP2	12,09 km^2
KP1 ∪ KP2	14,06 km^2
KP1∩ KP2	11,99 km^2
indeks pogreške, E	14,73 %
indeks podudarnosti, M	85,27 %

Površine istovrsno klasificiranih stabilnih i nestabilnih padina na kartama podložnosti na klizanje izrađenim s vizualno identificiranim klizištima potpunog inventara klizišta i na karti podložnosti na klizanje izrađenoj iz automatizirano kartiranih klizišta su jednake i iznose 10,64 km^2 ili 50,4 % pilot područja, neovisno jesu li podložnosti procijenjene na temelju klizišta prikazanih točkom ili poligonom. Za usporedbu, presjek dvije karte podložnosti na klizanje dobivene na temelju inventara u kojima su klizišta vizualno kartirana je 11,99 km^2 ili 56,8 % pilot područja.

Analizom kartografske podudarnosti također je procijenjen udio točno klasificiranih stabilnih i nestabilnih padina na karti podložnosti na klizanje izvedenoj na temelju automatizirano kartiranih klizišta. Proizlazi da je 68 % područja klasificirano kao stabilne padine i 76 % područja klasificirano kao nestabilne padine točno klasificirano s obzirom na kartu podložnosti na klizanje izvedenu na temelju vizualno interpretiranih poligona klizišta. Međutim, udio točno klasificiranih stabilnih i nestabilnih padina na karti podložnosti na klizanje izvedenoj na temelju automatizirano kartiranih klizišta je veća ako se usporedba provede s kartom podložnosti na klizanje izvedenom na temelju inventara u kojem su lokacije vizualno interpretiranih klizišta prikazane točkom. Tada je čak 95 % područja klasificirano kao stabilni tereni i 88 % područja klasificirano kao nestabilne padine točno klasificirano na karti podložnosti na klizanje izvedenoj na temelju automatizirano kartiranih klizišta.

Konačne karte podložnosti na klizanje reklasificirane su s obzirom na četiri klase podložnosti, a granične vrijednosti klasa definirane su na temelju ROC krivulja (slika 8.16). Granice klasa podložnosti na klizanje definirane su s obzirom na granične udjele kumulativnih površina, odnosno udjele broja klizišta. Pri tome su granični udjeli definirani subjektivno, na temelju iskustva, na sljedeći način: (i) stabilne padine definirani su kao područja na kojima se nalazi samo 1 % kumulativne površine/broja klizišta; (ii) uvjetno stabilne padine su područja s maksimalno 5 % kumulativne površine/broja klizišta; (iii) uvjetno nestabilne padine imaju maksimalno 15 % kumulativne površine/broja klizišta; (iv) nestabilne padine su područja na kojima se nalazi 85 % kumulativne površine/broja klizišta. Karte podložnosti na klizanje izrađene na temelju površina vizualno kartiranih klizišta, broja vizualno kartiranih klizišta i klizišta dobivenih modelom za automatizirano kartiranje klizišta klasificirane su u četiri klase podložnosti primjenom navedenih istih kriterija i prikazane su na slikama 8.17, 8.18 i 8.19.

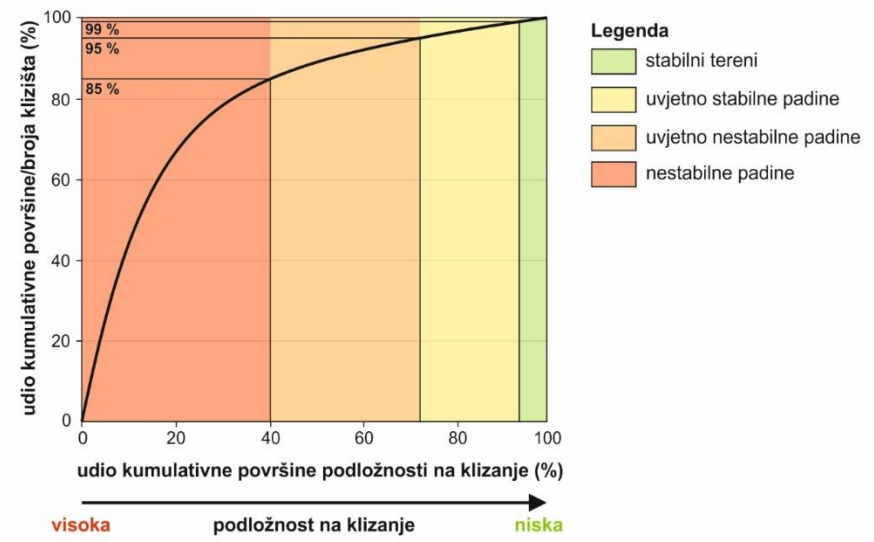

Slika 8.16 Klasifikacija podložnosti na klizanje s obzirom na granične vrijednosti kumulativnih površina ili broja klizišta.

U tablici 8.13 prikazana je usporedba klasa podložnosti na kartama podložnosti izrađenim na temelju vizualno i automatizirano kartiranih klizišta. Najmanju površinu stabilnih terena (7,15 km^2 ili 33,87 % pilot područja) ima karta podložnosti na klizanje dobivena na temelju površina vizualno kartiranih klizišta. Karta podložnosti na klizanje dobivena na temelju broja vizualno kartiranih klizišta ima 26 % veću površinu stabilnih terena (9,03 km^2 ili 42,75 % pilot područja), a karta podložnosti na klizanje izrađena na temelju automatizirano kartiranih klizišta ima 31 % veću površinu stabilnih terena (9,40 km^2 ili 44,53 % pilot područja), ujedno i najveću površinu stabilnih terena.

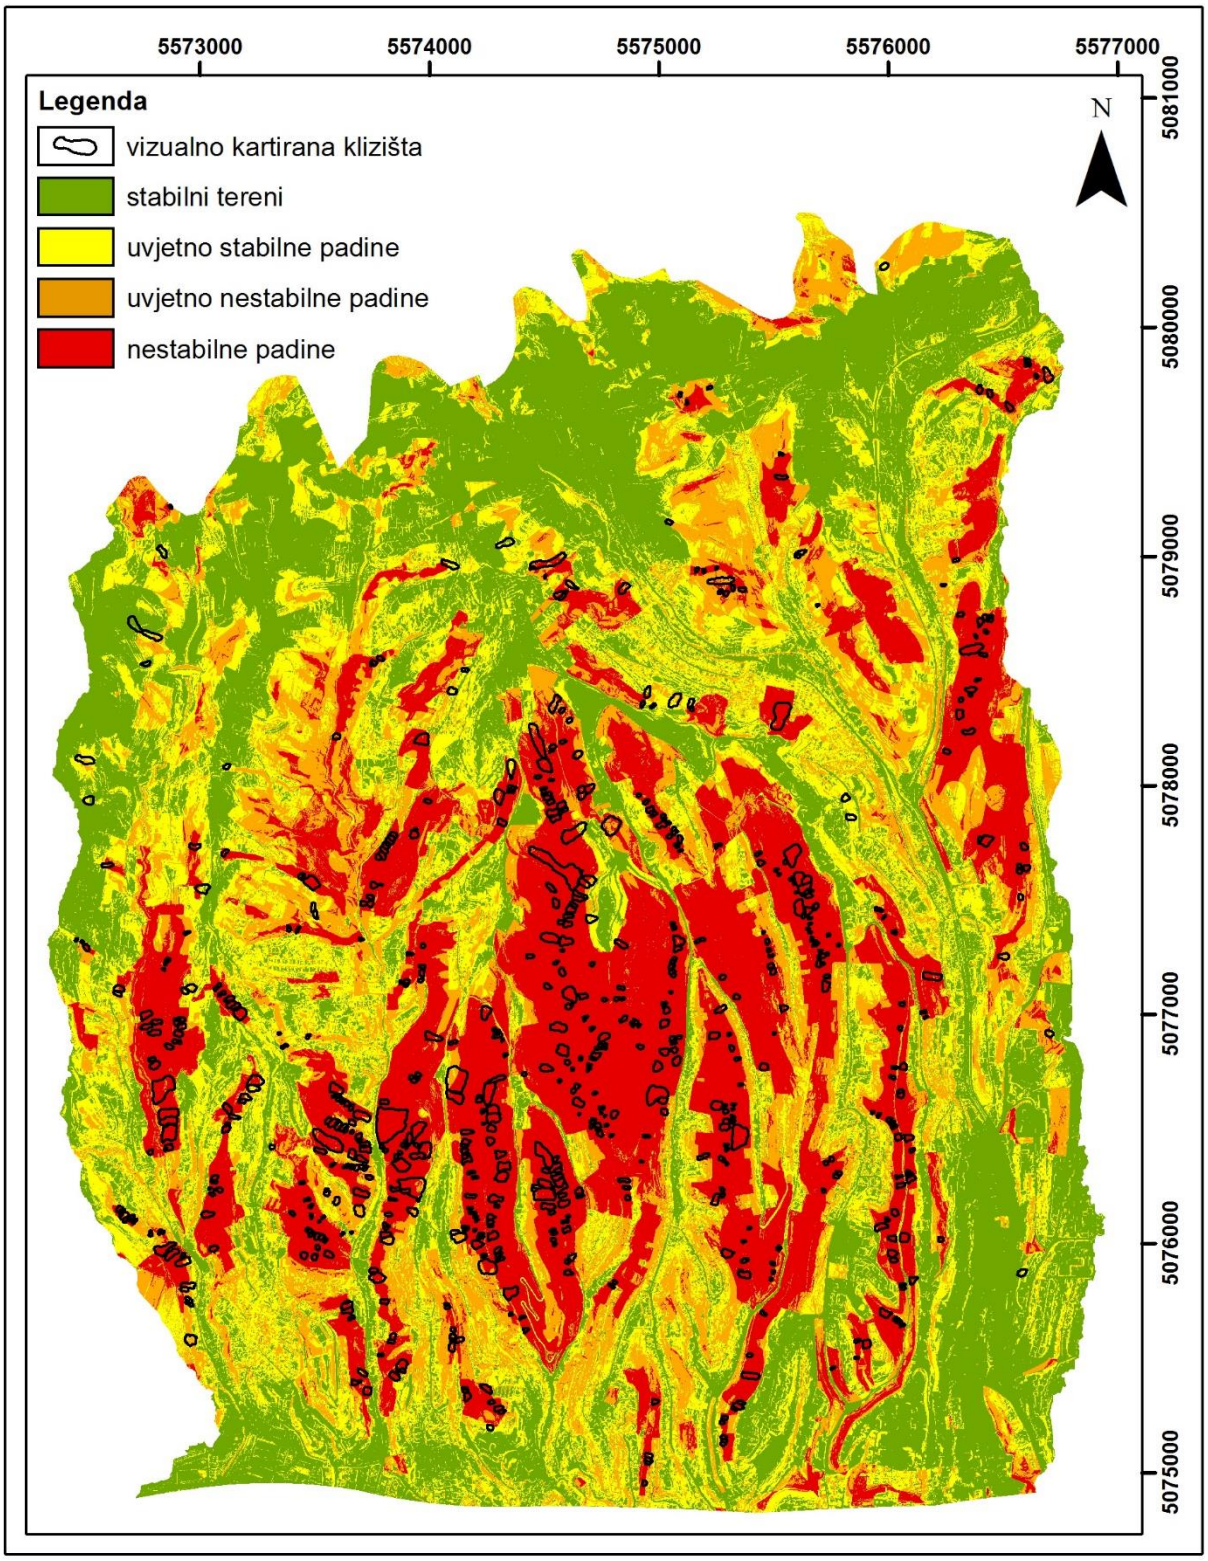

Slika 8.17 Karta podložnosti na klizanje (21 km^2) izrađena na temelju površina vizualno kartiranih klizišta iz potpunog inventara klizišta.

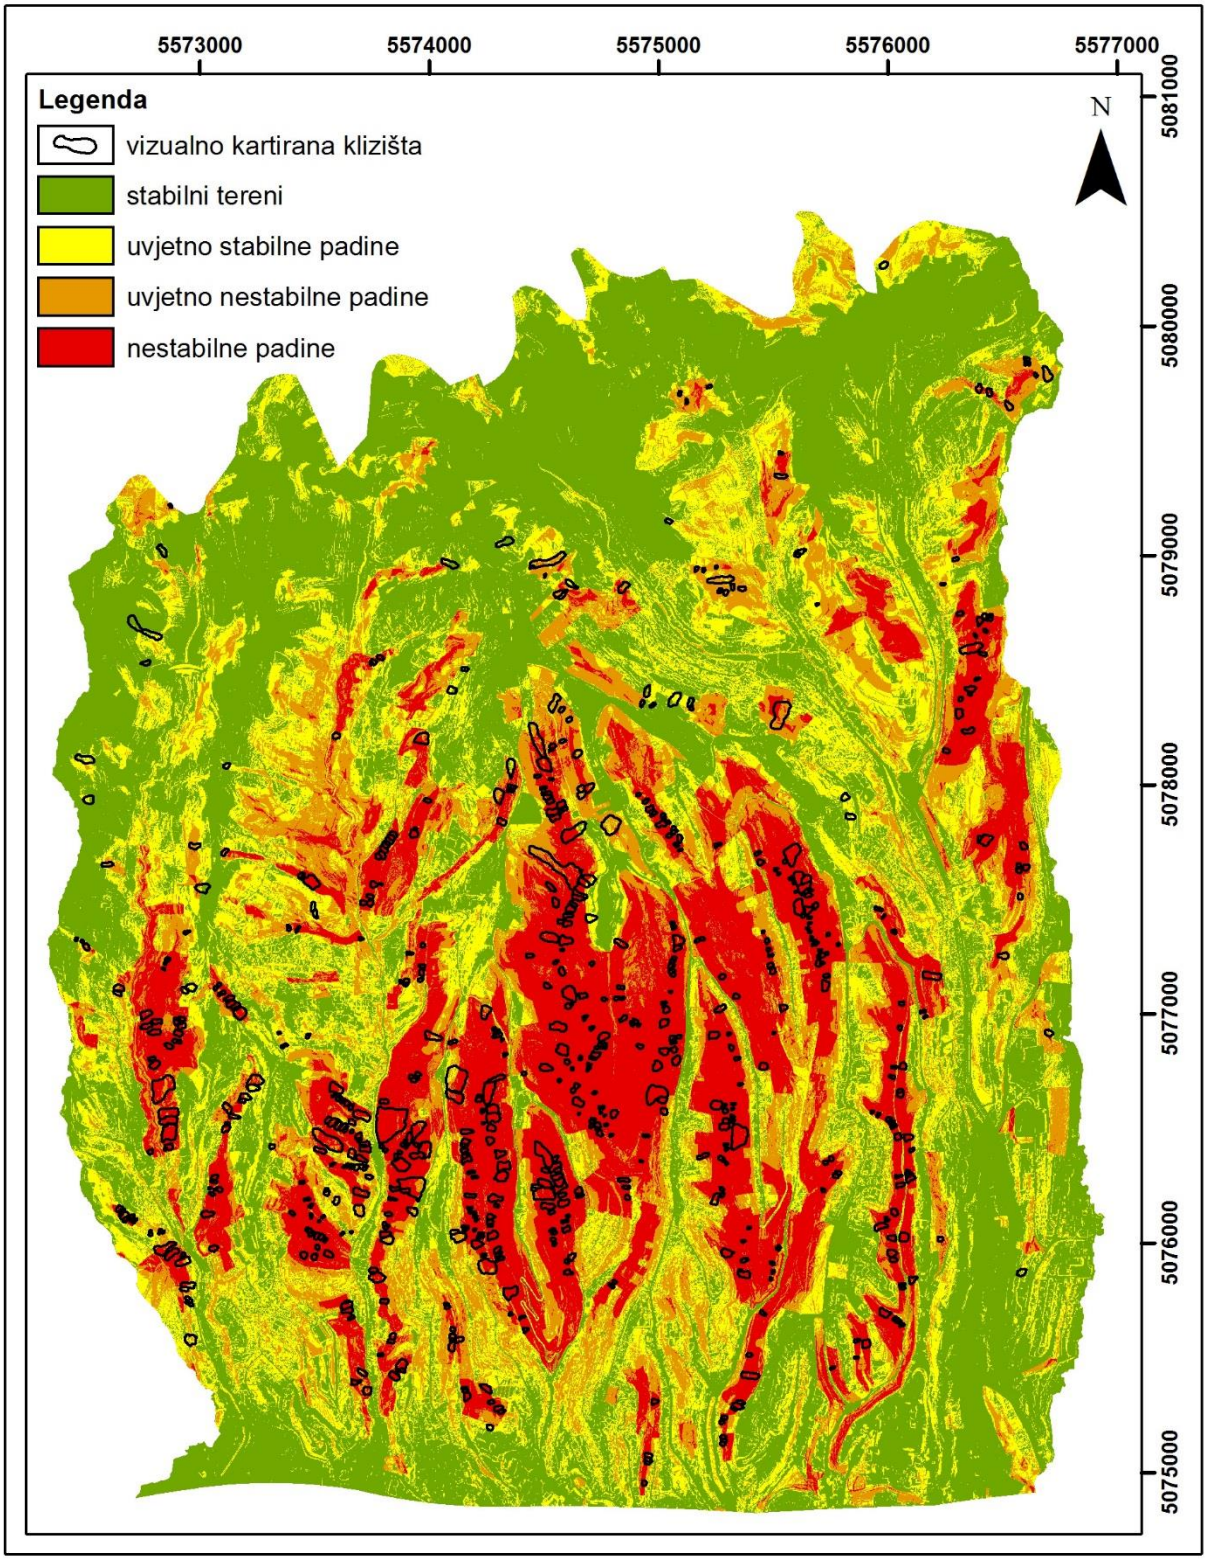

Slika 8.18 Karta podložnosti na klizanje (21 km^2) izrađena na temelju broja vizualno kartiranih klizišta iz potpunog inventara klizišta.

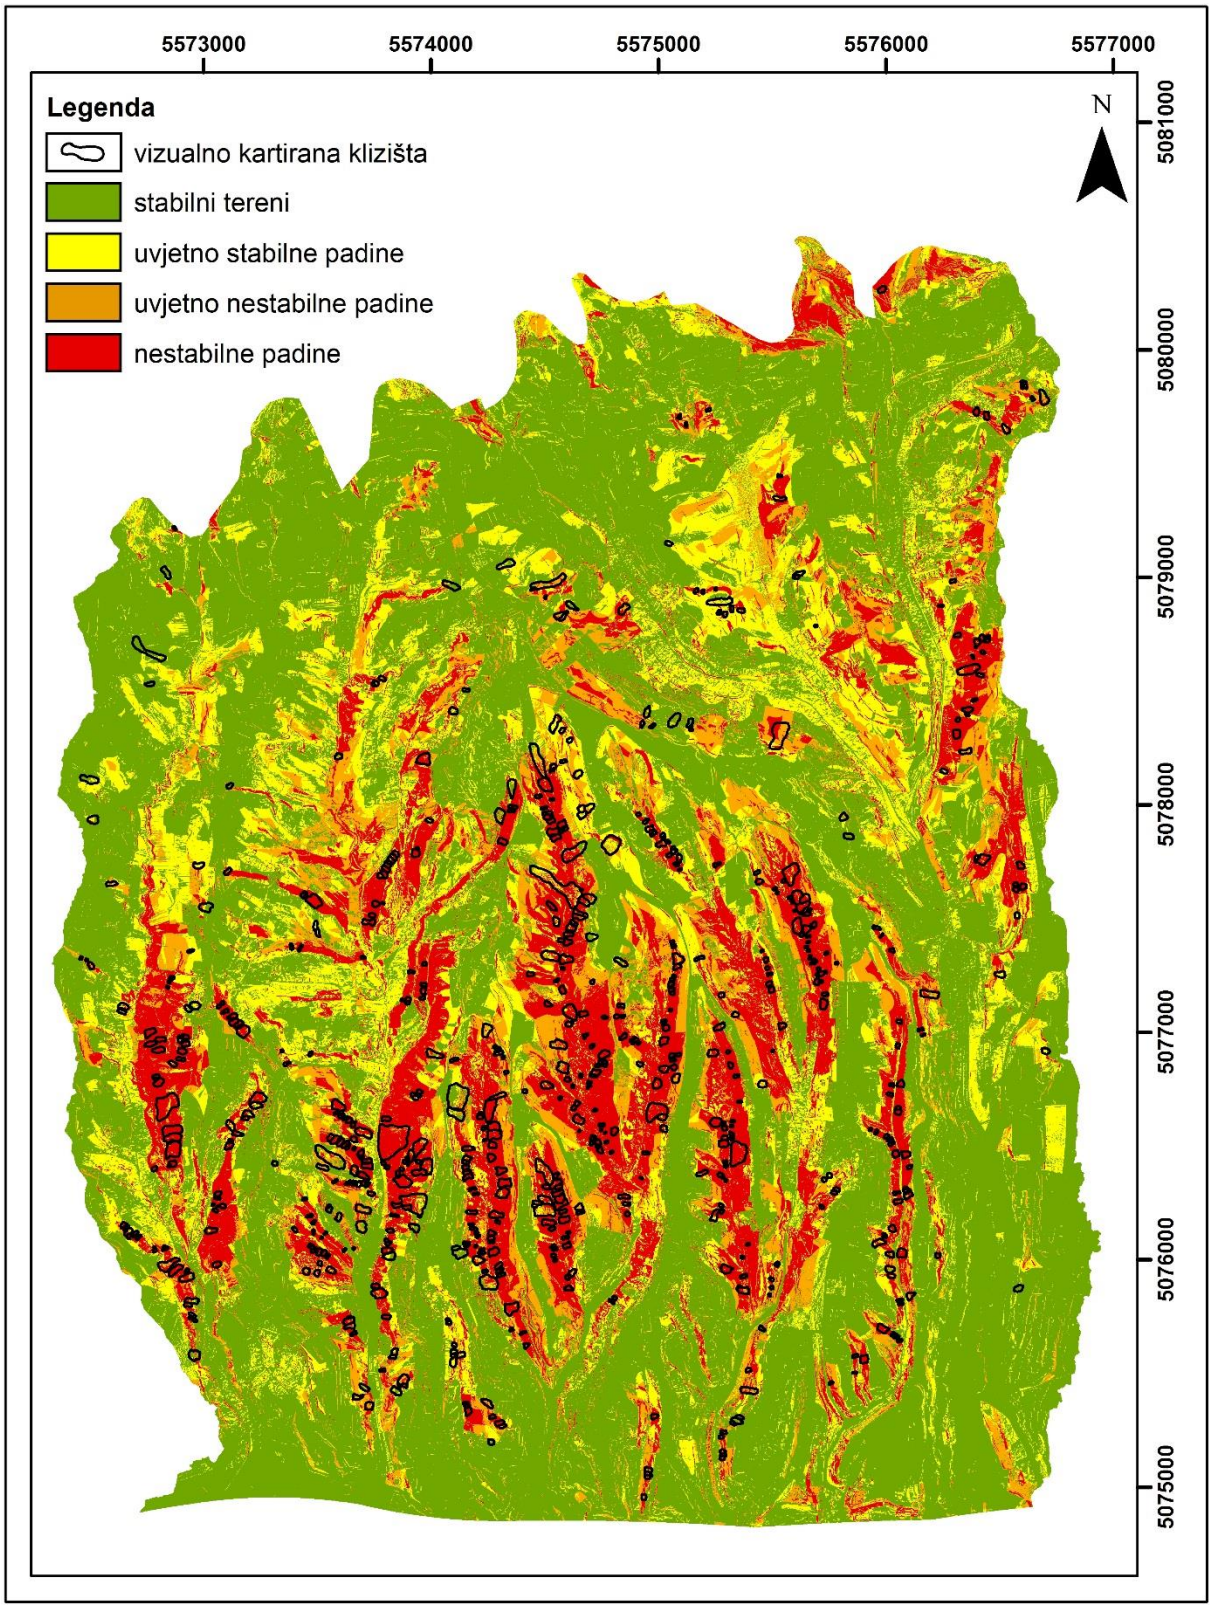

Slika 8.19 Karta podložnosti na klizanje (21 km^2) izrađena na temelju klizišta dobivenih pomoću modela za automatizirano kartiranje klizišta.

Najveću površinu uvjetno stabilnih padina ima karta podložnosti izrađena na temelju automatizirano kartiranih klizišta (7,31 km^2 ili 34,67 % pilot područja), dok karte podložnosti na klizanje izrađene na temelju vizualno kartiranih klizišta imaju 39 % manju površinu u slučaju klizišta prikazanih poligonima (4,48 km^2 ili 21,19 % pilot područja), odnosno 40 % manju površinu u slučaju klizišta prikazanih točkama (4,36 km^2 ili 20,63 % pilot područja). Uvjetno nestabilne padine su na karti podložnosti izrađenoj na temelju broja vizualno kartiranih klizišta zastupljene s 3,04 km^2 ili 14,40 % pilot područja, a na karti podložnosti na klizanje izrađenoj na temelju automatizirano kartiranih klizišta s 2,53 km^2 ili 12,01 % pilot područja. Karta podložnosti izrađena na temelju površina vizualno kartiranih klizišta ima 39 %, odnosno 66 % veću površinu uvjetno nestabilnih padina.

Na karti podložnosti izrađenoj na temelju broja vizualno kartiranih klizišta, nestabilne padine obuhvaćaju površinu 4,69 km^2 ili 22,22 % pilot područja, a najveću površinu nestabilnih padina ima karta podložnosti izrađena na temelju površina vizualno kartiranih klizišta (5, 27 km^2 ili 24,94 % pilot područja). Najmanju površinu nestabilnih padina ima karta podložnosti izrađena na temelju automatizirano kartiranih klizišta (1,85 km^2 ili 8,79 % pilot područja), što je 40 % manja površina nego na karti podložnosti izrađenoj na temelju površina vizualno kartiranih klizišta, odnosno oko 35 % manja površina nestabilnih padina nego na karti podložnosti izrađenoj na temelju broja vizualno kartiranih klizišta. Na kraju se može zaključiti da, u usporedbi s kartama podložnosti izrađenim na temelju vizualno kartiranih klizišta, karta podložnosti na klizanje izrađena na temelju automatizirano kartiranih klizišta ima znatno manju površinu nestabilnih padina i veću površinu uvjetno stabilnih padina, dok se površine stabilnih i uvjetno nestabilnih padina minimalno razlikuju od površina na kartama podložnosti izrađenim na temelju broja vizualno kartiranih klizišta.

Tablica 8.13 Usporedba karata podložnosti na klizanje dobivenih na temelju vizualno i automatizirano kartiranih inventara klizišta s obzirom na površine klasa podložnosti.

Klase podložnosti	Karta podložnosti na klizanje dobivena na temelju vizualno kartiranih klizišta (poligoni)		Karta podložnosti na klizanje dobivena na temelju vizualno kartiranih klizišta (točke)		Karta podložnosti na klizanje dobivena na temelju automatizirano kartiranih klizišta	
	km^2	%	km^2	%	km^2	%
stabilni tereni	7,15	33,87	9,03	42,75	9,40	44,53
uvjetno stabilne padine	4,48	21,19	4,36	20,63	7,31	34,67
uvjetno nestabilne padine	4,22	20,00	3,04	14,40	2,53	12,01
nestabilne padine	5,27	24,94	4,69	22,22	1,85	8,79

9 DISKUSIJA

Za pilot područje podsljemenske zone Grada Zagreba izrađene su karte klizišta primjenom LiDAR tehnologije. LiDAR tehnologija predstavlja tehniku daljinskih istraživanja koja omogućava izradu digitalnog modela terena bez vegetacije i vrlo visoke rezolucije, što se pokazalo značajnim karakteristikama za primjenu na istraživanom području podsljemenske zone Grada Zagreba s brojnim malim i plitkim klizištima u urbaniziranom okolišu te sa zastupljenom bujnom vegetacijom tipa bjelogorične šume. Sve analize su provedene na pilot području u zapadnom dijelu Grada Zagreba i podsljemenske zone, ukupne površine 21 km^2, što predstavlja 10 % površine podsljemenske zone. S obzirom na geomorfološke karakteristike, geološku građu, hidrološke i meteorološke uvjete, pilot područje se može smatrati reprezentativnim za cijelu podsljemensku zonu Grada Zagreba (180 km^2) zbog čega se svi rezultati istraživanja s pilot područja (21 km^2) mogu primijeniti na šire istraživano područje. Lasersko skeniranje iz zraka za cijelo područje podsljemenske zone Grada Zagreba provedeno je u okviru hrvatsko-japanskog SATREPS F2008 projekta „Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje rizika klizanja i bujica u Hrvatskoj“ (Mihalić i Arbanas, 2013; Arbanas et al., 2017). LiDAR podaci prikupljeni su tijekom prosinca 2013. godine, odnosno u vegetacijskom razdoblju bez lišća na listopadnom drveću, te šest mjeseci nakon MORLE događaja koji je zahvatio sjeverozapadu Hrvatsku kada je (re)aktivirano ukupno više od 900 klizišta (Bernat et al., 2014a). Na području podsljemenske zone Grada Zagreba u zimi 2012./2013. od strane građana prijavljeno je (re)aktiviranje više od 50 klizišta, a daljnjom analizom utvrđeno je da su prijavljivana samo klizišta koja se nalaze u neposrednoj blizini prometnica i stambenih građevina. Iz navedenog se može pretpostaviti da je broj klizišta (re)aktiviranih tijekom zime 2012./2013. godine na području podsljemenske zone Grada Zagreba daleko veći od broja prijavljenih klizišta. Na temelju provedenog laserskog skeniranja iz zraka, odnosno na temelju izrađenog LiDAR DMT-a visoke rezolucije, omogućeno je kartiranje svih recentnih pojava klizišta.

Primjenom LiDAR DMT-a izrađeno je ukupno šest karata klizišta, od kojih su tri karte inventara klizišta na kojima je prikazana lokacija postojećih klizišta (Pašek, 1975; Hansen, 1984; McCalpin, 1984; Wieczorek, 1984; Guzzetti et al., 2000) i tri karte podložnosti na klizanje izrađene zoniranjem istraživanog područja na homogene prostorne jedinice s obzirom na prostornu vjerojatnost pojave klizišta za unaprijed definirane preduvjete klizanja (Guzzetti et al., 1999; Corominas et al., 2013). Za izradu karata inventara klizišta primijenjene su dvije metode: (1) vizualna interpretacija morfometrijskih karata izvedenih iz LiDAR DMT-a; i (2)

automatizirano kartiranje klizišta izradom pikselno orijentiranog modela koji se temelji na statističkoj analizi morfometrijskih vrijednosti unutar vizualno kartiranih klizišta i na okolnom terenu bez klizišta. Vizualnom interpretacijom morfometrijskih karata izrađene su dvije karte inventara klizišta na kojima su pojave prikazane poligonima iscrtanim po granicama klizišta i točkama smještenim u središtima poligona. Primjenom WoE modela (Agterberg et al., 1990; Bonham-Carter et al., 1989) koji se može definirati kao bivarijantna statistička metoda, izvedene su tri karte podložnosti na klizanje: (1) karta podložnosti na klizanje izvedena na temelju površina klizišta kartiranih vizualnom interpretacijom LiDAR DMT-a; (2) karta podložnosti na klizanje izvedena na temelju broja klizišta kartiranih vizualnom interpretacijom LiDAR DMT-a; i (3) karta podložnosti na klizanje izvedena na temelju inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta.

9.1 Izrada optimalnog LiDAR DMT-a za kartiranje klizišta i priprema morfometrijskih karata za kartiranje klizišta

Za kartiranje klizišta na pilot području u podsljemenskoj zoni Grada Zagreba korišteno je više LiDAR DMT-a izvedenih iz oblaka točaka snimljenog laserskim skeniranjem 2013. godine. Prosječna gustoća od 3,61 točke/m^2 dobivena je nakon uklanjanja točaka reflektiranih od vegetacije i građevina. Analizom oblaka točaka utvrđena je najveća gustoća točaka na poljoprivrednim površinama (4,29 točke/m^2) koje prekrivaju 22 % površine pilot područja, a najmanja na umjetnim površinama (3,27 točaka/m^2) koje prekrivaju 55 % površine pilot područja. U svrhu izrade optimalnog LiDAR DMT-a, na oblaku točaka su primijenjene četiri različite metode interpolacije i različite rezolucije DMT-a. Primjenom metode inverznih udaljenosti, metode prirodnih susjeda, ANUDEM i kriging metode iz oblaka točaka izvedeno je ukupno 20 LiDAR DMT-a rezolucije 0,15 m, 0,3 m, 0,5 m, 1 m i 2 m. Procjena optimalne kvalitete LIDAR DMT-a za kartiranje klizišta provedena je na osnovi mogućnosti vizualne interpretacije za karakteristične veličine klizišta. Vizualno je bilo moguće procijeniti da metoda inverznih udaljenosti rezultira "najoštrijim" modelom terena, te da iz njega izvedene morfometrijske karte jasno ukazuju na morfologiju karakterističnu za klizišta. Suprotno tome, vizualno je procijenjeno da je metoda ANUDEM dala najlošiji rezultate, odnosno "zaglađen" DMT na kojemu je najmanje jasno izražena morfologija i granica klizišta, u usporedbi s ostalim modelima terena. S obzirom na površinu najmanjeg klizišta identificiranog u podsljemenskoj zoni Grada Zagreba, dimenzija oko 5 x 5 m, rezolucija DMT-a trebala bi iznositi minimalno 1 m. Nadalje, na osnovi vizualne interpretacije morfometrijskih karata izvedenih iz LiDAR

DMT-a rezolucije 2 m zaključeno je da za klizište dimenzije 20x20 m nije moguće iscrtati preciznu granicu što je značajno ograničenje ove rezolucije DMT-a, budući da je dimenzija 20x20 m najučestalija površina klizišta na pilot području. Iz provedene kvalitativne procjene proizlazi da je LiDAR DMT izveden metodom inverznih udaljenosti rezolucije 0,3 x 0,3 m optimalan za vizualnu interpretaciju izvedenih morfometrijskih karata i izradu detaljne karte inventara klizišta. Nedostatak LiDAR DMT-a rezolucije manje od 1 m je veći "šum", zbog jače izraženih malih nepravilnosti u reljefu, koje su nastale kao posljedica primijenjene interpolacijske metode. Ove nepravilnosti ne utječu na pouzdanost i preciznost vizualne interpretacije klizišta, ali mogu znatno utjecati na vrijednosti morfometrijskih parametara na kojima se temelji model za automatizirano kartiranje klizišta. Stoga su morfometrijske karte korištene za automatizirano kartiranje klizišta izvedene iz LiDAR DMT-a rezolucije 1 x 1 m.

Vizualna interpretacija klizišta na pilot području (21 km^2) u podsljemenskoj zoni Grada Zagreba provedena je na morfometrijskim kartama izvedenim iz LiDAR DMT-a rezolucije 0,3x0,3 m. Morfometrijske karte korištene za izradu karte inventara klizišta su karta osjenčanosti terena, karta nagiba terena i karta slojnica ekvidistancije 0,5 m, što su ujedno i najčešće korištene morfometrijske karte (Amundsen et al., 2010; Borkowski et al., 2011; Bell et al., 2012; Tarolli et al., 2012; Gorsevski et al., 2016; Petschko et al., 2015). Kao značajnu pomoć prilikom vizualne interpretacije klizišta mnogi autori navode i kartu zakrivljenosti terena (Amundsen et al., 2010; Miner et al., 2010), kartu hrapavosti terena i kartu akumulacije toka (Miner et al., 2010). Osim toga, kao jedan od zaključaka istraživanja provedenog u Vinodolskoj udolini, Đomlija (2018) navodi da je za vizualnu interpretaciju slabije izraženih morfologija klizišta na karti osjenčanog reljefa, potrebno koristiti veći broj morfometrijskih karata jer će za iscrtavanje granica pojedinačnih dijelova klizišta biti potrebno interpretirati i nekoliko morfometrijskih karata u kombinaciji, što se postiže međusobnim preklapanjem karata u različitim stupnjevima prozirnosti. Međutim, preliminarnom analizom LiDAR DMT-a i izvedenih morfometrijskih karata za pilot područje u Gradu Zagrebu, utvrđeno je da kombinacija triju morfometrijskih karata, karte nagiba terena prozirnosti od 65 % i karte slojnica ekvidistancije 0,5 m na karti osjenčanog terena, omogućava identifikaciju klizišta kao i detaljno kartiranje klizišta manjih od 100 m^2. Razlog tomu je geološka građa podsljemenske zone Grada Zagreba koja je gotovo u potpunosti izgrađena od kvartarnih i neogenskih sedimenata koji su najčešće prekriveni pokrivačem od sitnozrnastih tala debljine 0,5 do 3 m, a dominantni aktivni geomorfološki procesi na padinama su klizanje i erozija. Dijelovi terena na

kojima nema registriranih aktivnih geomorfoloških procesa su gotovo u potpunosti zaglađeni, a klizišta su jasno izražena, iako su radi o relativno malim i plitkim pojavama.

Za automatizirano kartiranje klizišta na pilot području (21 km^2) izveden je niz morfometrijskih karata iz LiDAR DMT-a rezolucije 1x1 m. Ukupno je izvedeno 127 morfometrijskih karata koje su svrstane u osam grupa, a to su karte nadmorskih visina, karte osjenčanosti terena, karte nagiba terena, karte slojnica, karte zakrivljenosti terena, karte hrapavosti terena, karte vlažnosti i osunčanosti terena te karte raščlanjenosti terena. U svijetu su za automatizirano kartiranje klizišta najčešće primjenjivane karte nagiba terena (Glenn et al., 2006; Kasai et al., 2009, Rau et al., 2012; Van Den Eeckhaut et al., 2012; Gorsevski et al., 2015), karte hrapavosti terena (McKean i Roering, 2004; Glenn et al., 2006; Kasai et al., 2009, Rau et al., 2012; Van Den Eeckhaut et al., 2012; Berti et al., 2013; Li et al., 2015) i karte zakrivljenosti terena (Tarolli et al., 2012; Van Den Eeckhaut et al., 2012; Gorsevski et al., 2015). Budući da za izradu karata nagiba, hrapavosti i zakrivljenosti terena postoje brojne metode pridobivanja, u ovom su istraživanju u okviru pripreme ulaznih podataka primijenjene različite metode. Općenito se može zaključiti da sve izvedene grupe karata, osim karata osjenčanosti, zakrivljenosti i vlažnosti terena, zapravo predstavljaju karte hrapavosti terena izvedene s obzirom na različite parametre reljefa (nadmorsku visinu, nagib, gustoću slojnica). Zbog velikog broja izvedenih karata, ali i primijenjenih metoda, morfometrijske karte grupirane su s obzirom na vrstu originalne karte iz kojih su izvedene (ulazne karte), odnosno prema nazivu originalnih ulaznih karata (npr. karte hrapavosti terena). Morfometrijske karte izvedene su primjenom svih metoda koje su bile dostupne u relevantnoj svjetskoj literaturi, odnosno u ovom radu je dan pregled svih vrsta morfometrijskih karata koje su do sada razvijene i koje se mogu primijeniti za kartiranje klizišta, bilo vizualno ili automatizirano. Također, u okviru provedenog istraživanja izvedene su i morfometrijske karte koje do sada nisu primjenjivane za kartiranje klizišta, a to su karte gustoće slojnica i karte standardne devijacije i raspona osjenčanosti terena. Većina morfometrijskih karata izvedena je s obzirom na različite oblike prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija), što je omogućilo analize morfometrijskih karata dobivenih različitim postavkama žarišne statistike, odnosno definiranje parametara žarišne statistike koji daju najoptimalnije morfometrijske karte za automatizirano kartiranje klizišta.

9.2 Vizualna identifikacija klizišta na LiDAR DMT-u

Vizualna identifikacija i kartiranje klizišta na izvedenim morfometrijskim kartama i dalje je najčešće korištena metoda izrade karata inventara klizišta primjenom LiDAR tehnologije (Petschko et al. (2015). Na pilot području (21 km^2) u podsljemenskoj zoni Grada Zagreba za vizualnu identifikaciju klizišta korištena je na morfometrijska karta osjenčanosti terena, nagiba terena i karta slojnica ekvidistancije 0,5 m izvedenih iz LiDAR DMT-a rezolucije 0,3x0,3 m. Klizišta su identificirana na temelju strme, konkavne glavne pukotine, zatim nožice klizišta karakterističnog konveksnog oblika te nepravilne morfologije samog klizišta. Također, prije samog postupka vizualne interpretacije izvedenih morfometrijskih karata nužna su preliminarna terenska istraživanja kako bi se utvrdilo da li su pojedini morfološki oblici posljedica procesa klizanja ili antropogenih aktivnosti. Općenito, jako je važno dobro poznavanje istraživanog područja, iz razloga što se geomorfološke značajke i geološka građa područja odražavaju na karakteristične oblike reljefa, svojstva materijala i aktivne geomorfološke procese, a time i na dominantne tipove i veličinu pokrenutih klizišta. Poznato je da točnost inventara klizišta izrađenih vizualnom interpretacijom LIDAR DMT-a visoke rezolucije ponajviše ovisi o iskustvu istraživača koji provodi identifikaciju i kartiranje klizišta (Van Den Eeckhaut et al., 2006). Naime, potrebna je određena praksa i iskustvo u identifikaciji klizišta na morfometrijskim kartama da bi se usvojila vještina interpretacije karakteristične morfologije klizišta na kartama izvedenim iz LiDAR DMT-a. Prilikom izrade inventara klizišta na pilot području, postupak identifikacije proveden je više puta za cijelo područje i svaki puta su uočene pojave "novih" klizišta koje u prethodnom postupku interpretacije izvedenih karata nisu uočene. Za svako identificirano klizište procijenjen je stupanj pouzdanosti kako bi se kvalitativno procijenila točnost inventara klizišta. Klizište je opisano kao pouzdano ukoliko su na izvedenim morfometrijskim kartama jasno izraženi svi pojedini dijelovi klizišta i karakteristična nepravilna morfologija, te kao nepouzdano identificirana (pretpostavljena) klizišta ukoliko je na izvedenim morfometrijskim kartama morfologija klizišta slabo izražena ili pojedini dijelovi klizišta izostaju zbog erozije, sanacije klizišta ili drugih antropogenih zahvata u okolišu.

Rezultat vizualne interpretacije morfometrijskih karata izvedenih iz LiDAR DMT-a rezolucije 0,3x0,3 m je karta inventara klizišta za pilot područje (21 km^2) podsljemenske zone Grada Zagreba koja se sastoji od ukupno 702 identificirana i iscrtana klizišta. S obzirom na subjektivnu procjenu pouzdanosti kartiranih pojava, 456 klizišta ili 65 % od ukupnog broja klizišta u inventaru opisano je kao pouzdano identificirane pojave, a od navedenog broja klizišta gotovo 70 % je kartirano s visokom i srednjom preciznošću. Ukupna površina klizišta na pilot

području iznosi 0,5 km^2 ili 2,43 % površine pilot područja, dok je srednja gustoća klizišta 33,3 klizišta/km^2. Najmanje identificirano i kartirano klizište je veličine 43 m^2, a najveće klizište ima površinu od 8.064 m^2. Najveći broj klizišta u inventaru je veličine oko 400 m^2, dok je 90 % klizišta veličine između 100 i 2.000 m^2. Raspodjela učestalosti površine kartiranih klizišta na pilot području može se opisati pomoću normalne raspodjele (Malamud et al., 2004), a prijelaz između rastućeg i padajućeg dijela krivulje raspodjele ukazuje na razliku između površinom malih klizišta u odnosu na srednje velika i velika klizišta. U inventaru klizišta pilot područja nalazi se 46,2 % malih klizišta veličine 43 do 398 m^2 , definiranih rastućim dijelom krivulje, i 53,8 % srednje velikih i velikih klizišta, veličine od 399 do 8.064 m^2, definiranih padajućim dijelom krivulje. S obzirom da raspodjela površina kartiranih klizišta na pilot području ima oblik simetrično razvijene Gauss-ove krivulje, može se zaključiti da je karta inventara klizišta izrađena vizualnom interpretacijom LiDAR DMT-a potpuna. Pod pojmom potpun inventar klizišta Malamud et al. (2004) podrazumijeva normalnu raspodjelu površina kartiranih klizišta zbog toga što su pojave klizišta rezultat prirodnih pokretača klizanja (npr. oborina i/ili otapanja snježnog pokrivača) ili antropogenih zahvata prisutnih na cijelom području (npr. deforestacija i urbanizacija), što ne znači nužno da inventar sadrži stvaran broj svih povijesnih klizišta ikada aktiviranih na nekom području. Drugim riječima, inventar klizišta izrađen vizualnom interpretacijom LiDAR DMT-a sadrži reprezentativan broj klizišta svih površina zastupljenih na pilot području, što je neophodno za pouzdanu procjenu podložnosti na klizanje na pilot području.

Prema Highland i Bobrowsky (2008) detaljni inventari klizišta moraju za svako identificirano i iscrtano klizište sadržavati podatke o tipu pokreta, aktivnosti, brzini kretanja, geološkoj starosti naslaga, dubini klizanja i materijalima koji su zahvaćeni klizanjem. Međutim, vizualnom interpretacijom LiDAR DMT-a na pilot području nije bilo moguće odrediti sve prethodno navedene značajke za svako identificirano klizište u inventaru. Prilikom vizualne interpretacije morfometrijskih karata utvrđeno je da su prema mehanizmu gibanja sve identificirane i kartirane pojave nestabilnosti na padinama nastale isključivo procesom klizanja. S obzirom da je pilot područje izgrađeno dominantno od neogenskih naslaga, može se zaključiti da se prema klasifikaciji klizišta razvijenoj od strane Cruden i Varnes (1996) radi dominantno o klizanju tla. Međutim, pojave klizišta identificirane i kartirane vizualnom interpretacijom LiDAR DMT-a nije bilo moguće klasificirati prema modificiranoj Varnesovoj klasifikaciji klizišta (Hungr et al., 2014) bez detaljnog poznavanja vrste materijala prisutne na pilot području. Naime, jedini dostupni podatak o geološkoj građi i litološkom sastavu naslaga na

istraživanom području je Osnovna geološka karta, list Zagreb mjerila 1:100.000 (Šikić et al., 1979) koja prikazuje samo osnovnu stijenu u sitnom mjerilu, a za mala klizišta je potrebna karta površinskih naslaga krupnog mjerila. Nadalje, vizualnom interpretacijom LiDAR DMT-a nije moguće odrediti dubinu klizanja, već je moguće samo procijeniti dubinu do klizne plohe s obzirom na površinu kartiranog klizišta. Također, stupanj aktivnosti i brzina klizanja su značajke klizišta koje nije moguće odrediti iz LiDAR DMT-a, ali se može pretpostaviti da je veliki broj klizišta recentno (re)aktiviran na temelju udjela površinom malih klizišta (>45 %) te relativno visok udio pouzdano identificiranih klizišta (65 %) u inventaru. Pregledom satelitskih snimaka na Google Earthu-u iz rujna 2012. i kolovoza 2013. godine nije bilo moguće odrediti koja su klizišta aktivirana tijekom zime 2012./2013. godine. Iz navedenog razloga, te s obzirom na izvor podataka i sadržaj koji prikazuje, inventar klizišta za 21 km^2 pilot područja predstavlja kombinaciju sezonskog i povijesnog inventara klizišta prema klasifikaciji inventara klizišta Guzzetti et al. (2012).

S obzirom na normalnu raspodjelu površina kartiranih klizišta, može se zaključiti da DMT rezolucije 0,3x0,3 m dobiven laserskim skeniranjem iz zraka omogućava pouzdanu vizualnu identifikaciju klizišta i izradu detaljnog i potpunog inventara klizišta za cijelo područje podsljemenske zone Grada Zagreba bez obzira na veličinu klizišta (mala i plitka klizišta), visoki stupanj urbaniziranosti (modificiran prirodni okoliš) i gustu vegetaciju (šumska područja). Međutim, predmetni inventar klizišta izrađen je na temelju LiDAR podataka iz 2013. godine i danas se ne može smatrati u potpunosti reprezentativnim. Iz tog razloga bi u skorijoj budućnosti bilo nužno ponovno provesti lasersko skeniranje iz zraka za cijelo područje podsljemenske zone Grada Zagreba (180 km^2), kako bi se inventar klizišta izrađen vizualnom interpretacijom iz 2013. godine ažurirao. No, samim time što je lasersko skeniranje iz zraka provedeno nakon (re)aktiviranja velikog broja klizišta u zimi 2012./2013., izvedeni LiDAR DMT predstavlja vrlo vrijednu podlogu koja omogućava kartiranje malih i plitkih klizišta čija morfologija je vrlo često očuvana kroz vrlo kratko vremensko razdoblje zbog erozije, poljoprivrednih aktivnosti, provedenih mjera sanacije ili drugih antropogenih zahvata u okolišu.

Karta inventara klizišta izrađenog vizualnom interpretacijom izvedenih morfometrijskih karata uspoređena je s postojećim povijesnim inventarima klizišta kako bi se prikazala prednost LiDAR tehnologije naspram konvencionalnih metoda kartiranja. U posljednjih 50-tak godina primjenom terenskog geomorfološkog kartiranja (Šikić, 1967; Polak et al., 1979; Miklin et al., 2007) te stereoskopskom analizom avionskih snimaka (Podolzski, 2014) za područje podsljemenske zone Grada Zagreba izrađeno je ukupno pet karata inventara klizišta. U okviru

provedenog doktorskog istraživanja na raspolaganju su bila dva inventara klizišta: inventar iz 1979. godine izrađen u okviru projekta *„Litološke obrade i kategorizacije terena prema stabilnosti“* (Polak et al., 1979) i inventar iz 2007 godine izrađen u okviru tzv. *Detaljne inženjerskogeološke karte Podsljemenske urbanizirane zone u mjerilu 1:5.000, DIGK – Faza I“* (Miklin et al., 2007). Inventar klizišta izrađen vizualnom interpretacijom LiDAR DMT-a uspoređen je s inventarima iz 1979. i 2007. godine primjenom triju metoda koje se temelje na usporedbi statističkih značajki karata inventara klizišta i raspodjele učestalosti površina klizišta (Malamud et al., 2004), stupnju kartografske podudarnosti granica klizišta dvaju inventara (Carrara et al., 1992) i kartama gustoća klizišta izvedenih na temelju različitih inventara klizišta (Guzzetti et al., 2000). Usporedba triju inventara klizišta pokazala je da povijesni inventari klizišta iz 1979. i 2007. godine nisu potpuni, odnosno da nemaju normalnu raspodjelu površina klizišta na pilot području. Naime, terenskim geomorfološkim kartiranjem nisu identificirana mala plitka klizišta (najmanje kartirano klizište u inventaru iz 1979. godine ima površinu 467 m^2, a u inventaru iz 2007. godine 282 m^2) već samo velika i duboka klizišta, pri čemu vrlo često granice većih pojava zapravo predstavljaju nestabilne zone koje obuhvaćaju veći broj manjih klizišta. Najveće kartirano klizište u inventaru iz 2007. godine ima površinu od 317.262 m^2, što je gotovo sedam puta veće od najvećeg klizišta kartiranog u inventaru iz 1979. godine (43.228 m^2), i gotovo 40 puta veće od najvećeg klizišta u inventaru iz 2013. godine (8.064 m^2). Također, u inventaru klizišta iz 2007. godine identificirano je 28 pojava s površinom većom od 30.000 m^2 koje nisu identificirane prilikom vizualne interpretacije LiDAR DMT-a. Usporedba inventara klizišta na temelju metode kartografske podudarnosti (Carrara et al., 1992) pokazala je vrlo nizak stupanj podudarnosti (M=6-4 %), odnosno indeks pogreške u sva tri slučaja je vrlo visok (E=94-96 %), pri čemu se inventari iz 2007. i 2013. godine podudaraju u samo 0,22 % ukupne površine klizišta, a inventari iz 1979. i 2013. godine u 0,9 % ukupne površine klizišta. Na temelju provedenih usporedbi inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a s inventarom klizišta iz 2007. godine, može se zaključiti da Grad Zagreb nema na raspolaganju odgovarajući inventar klizišta koji bi se koristio kao podloga za donošenje odluka vezanih za uvjete gradnje, odnosno izdavanje lokacijskih i građevinskih dozvola te izradu prostorno-planske dokumentacije. Osim navedenog, inventar klizišta iz 2007. godine nije pouzdan i reprezentativan ulazni podatak za procjenu podložnosti na klizanje što je dokazano izradom karata gustoće klizišta. Naime, za svaki od tri analizirane karte inventara klizišta, iz 1979., 2007. i 2013. godine, izrađena je karta gustoće klizišta. Vizualnom usporedbom izvedenih karata gustoće može se zaključiti da se karta gustoće klizišta izvedena na temelju inventara iz 2007. godine znatno razlikuje od preostalih

karata gustoća klizišta. Prema karti gustoće klizišta izrađenoj na temelju inventara iz 2007. godine, pilot područje ima 30 % više nestabilnih padina od karte gustoća klizišta izrađene na temelju vizualno kartiranih klizišta na LiDAR DMT-u.

9.3 Model za automatizirano kartiranje klizišta na temelju morfometrijskih parametara

Vizualnom identifikacijom klizišta na morfometrijskim kartama izvedenim iz LIDAR DMT-a za pilot područje površine 21 km^2 utvrđeno je da se primjenom novih tehnologija može relativno brzo i učinkovito izraditi detaljan i potpun inventar klizišta. Iako je vizualna identifikacija klizišta s LiDAR DMT-a brža, točnija i učinkovitija od terenskog geomorfološkog kartiranja, i dalje se radi o vremenski dugotrajnom procesu, a kvaliteta izrađenog inventara najčešće ovisi o iskustvu istraživača koji provodi identifikaciju i kartiranje klizišta (Van Den Eeckhaut et al., 2006). U posljednjih 15-tak godina sve se češće razvijaju modeli za automatizirano kartiranje klizišta (McKean i Roering, 2004; Glenn et al., 2006; Van Den Eeckhaut et al., 2012; Berti et al., 2013; Gorsevski et al., 2015; Pawluszek, 2018) kako bi se dodatno ubrzao postupak identifikacije i kartiranja klizišta, ali i kako bi se uklonila subjektivna procjena istraživača prilikom postupka vizualne interpretacije morfologije terena na LiDAR DMT-ima visoke rezolucije. Dosadašnji modeli za automatizirano kartiranje klizišta najčešće su razvijani u svrhu kartiranja detaljnih granica velikih i dubokih klizišta (Booth et al., 2009; Van Den Eeckhaut et al., 2012) ili nestabilnih padina (Booth et al., 2009; Berti et al., 2013). Nedostatak postojećih modela razvijenih za automatizirano kartiranje klizišta je nemogućnost kartiranja malih i plitkih klizišta koja čine znatan udio u ukupnoj površini kartiranih klizišta nekog područja, a bez kojih su inventari klizišta nepotpuni. Također, modeli za automatizirano kartiranje klizišta do sada nisu bili razvijani, niti primjenjivani na urbaniziranim područjima, u okolišima u kojima je značajan antropogeni utjecaj , neovisno o vrsti namjene zemljišta (npr. neobrađivane i zapuštene poljoprivredne površine na kojima se vide morfološki tragovi nekadašnje obrade terena, te uređeni parkovi i šetnice na području šuma i poluprirodnih područja). Drugim riječima, automatizirano kartiranje klizišta na urbaniziranim područjima je poseban izazov zbog toga što pojedini antropogeni zahvati u okolišu mogu imati sličan morfološki "otisak" na izvedenim morfometrijskim kartama LiDAR DMT-a kao i klizišta.

Model za automatizirano kartiranje klizišta na pilot području (21 km^2) u podsljemenskoj zoni Grada Zagreba razvijen je na temelju morfometrijskih karata izvedenih iz LiDAR DMT-a

rezolucije 1x1 m. Prije izrade morfometrijskih karata, iz LiDAR DMT-a je uklonjen dio površine terena unutar zone širine 3 m oko građevina i prometnica jer je preliminarnim morfometrijskim analizama utvrđeno da tereni na rubnim područjima oko građevina i prometnica imaju slične ili iste morfometrijske parametre kao i područja zahvaćena procesom klizanja. U tu svrhu je korišten vektorski sloj građevina i prometnica preuzet s DOF-a iz 2012. godine, izrađen kao jedna od karata stvarnog korištenja Grada Zagreba. Međutim, u zoni širine 3 m oko građevina i prometnica nisu sadržani svi antropogeni "otisci" na LiDAR DMT-u, kao na primjer, građevine izgrađene u razdoblju od snimanja DOF-a (ožujak 2012. godina) do snimanja LiDAR DMT-a (prosinac 2013. godine), te staze u parkovima, uređivane padine, nasipi uz ceste, i sl. Budući da ovi elementi nisu uklonjeni s LiDAR DMT-a, oni su prouzročili pogreške u inventaru automatizirano kartiranih klizišta, time što su pogrešno klasificirani kao klizišta. U okviru ovog doktorskog istraživanja nije provedena analiza kojom bi se utvrdio udio pogrešno klasificiranih automatizirano kartiranih klizišta uslijed opisanih antropogenih modifikacija prirodnog okoliša. Također, iz inventara automatizirano kartiranih klizišta nisu niti naknadno ručno uklanjane točke za koje je utvrđeno da su pogrešno klasificirane kao klizišta. Stoga je daljnjim istraživanjima potrebno utvrditi koliki utjecaj imaju antropogeni "otisci" na LiDAR DMT-u na model za automatizirano kartiranje klizišta.

Ukupno je izvedeno 127 morfometrijskih karata koje se mogu svrstati u osam grupa, a to su karte nadmorskih visina, karte osjenčanosti terena, karte nagiba terena, karte slojnica, karte zakrivljenosti terena, karte hrapavosti terena, karte vlažnosti i osunčanosti terena te karte raščlanjenosti terena. Prvi korak prilikom definiranja modela za automatizirano kartiranje klizišta bila je usporedba raspodjele učestalosti morfometrijskih vrijednosti unutar granica klizišta i na okolnom terenu bez tragova klizanja. Ova morfometrijska analiza provedena je s obzirom na vizualno kartirana klizišta na dijelu pilot područja površine 10,5 km^2. Na osnovi karakterističnih točaka preklapanja krivulja učestalosti morfometrijskih vrijednosti definirani su morfometrijski parametri koji ukazuju na morfologiju terena karakterističnu za klizišta. Međutim, iz prostornog položaja morfometrijskih parametra vidi se da definirane kritične vrijednosti ne ukazuju isključivo na morfologiju terena karakterističnu za klizišta, već da ukazuju i na dijelove terena sa sličnim morfološkim karakteristikama, npr. na nasipe, zasjeke uz prometnice i sl. Budući da navedeno može prouzročiti pogreške modela za automatizirano kartiranje klizišta u obliku krivo klasificiranih klizišta, provedena je analiza točnosti svake pojedine izvedene morfometrijske karte pomoću analize opisane u Carrara et al. (1992). Analizom kartografskog preklapanja morfometrijskih karata s granicama vizualno kartiranih

klizišta na LiDAR DMT-u dobiveni su indeksi podudarnosti u rasponu od 3,08-8,67 %. Iako je indeks podudarnosti relativno nizak, vizualnom usporedbom preklapanja vrijednosti morfometrijskih parametara i granica vizualno kartiranih klizišta na kartama može se zaključiti da pojedine karte morfometrijskih parametara daju relativno dobar uvid u područja s morfologijom karakterističnom za klizišta te zbog toga predstavljaju odgovarajući ulazni podatak za izradu modela za automatizirano kartiranje klizišta. Iz svake podgrupe izvedenih morfometrijskih karata, morfometrijski parametar s najvišim indeksom podudarnosti odabran je kao predikcijska karata za automatizirano kartiranje klizišta.

S obzirom na raspon indeksa podudarnosti svih predikcijskih karata (M=4,11-8,67 %), može se zaključiti da predikcijske karte iz grupe karata nadmorskih visina, a to su karta standardne devijacije nadmorske visine dobivena kvadratnim prozorom veličine 3x3 m i karta raspona vrijednosti nadmorske visine dobivena kružnim prozorom radijusa 5 m, imaju relativno visok indeks podudarnosti (M>7,5 %). Relativno visok stupanj točnosti ima i karta gustoće slojnica dobivena kružnim prozorom radijusa 9 m s indeksom podudarnosti od 7, 48 %. Morfometrijski parametri izvedeni iz karte osjenčanosti imaju znatno niže kartografsko preklapanje s vizualno interpretiranim klizištima na LiDAR DMT-u (M<5,8 %). Predikcijske karte u grupi karata nagiba terena imaju indeks podudarnosti između 5,6 i 6,2 %, a iznimke su karta indeksa položaja dobivena SIN metodom (M=7,44 %) i karta nagiba terena (M=7,12 %) s relativno višim indeksima podudarnosti s obzirom na raspon indeksa podudarnosti svih predikcijskih karata (M=4,11-8,67 %). Predikcijske karte zakrivljenosti terena imaju relativno nižu stopu točnosti 6,15-6,93 % u usporedbi s rasponom indeksa podudarnosti svih predikcijskih karata (M=4,11-8,67 %). Iznimka su karta standardne devijacije planarne zakrivljenosti terena dobivene kružnim prozorom radijusa 3 m s indeksom podudarnosti od 7,26 % te karte profilne zakrivljenosti terena s vrlo niskim indeksom podudarnosti, M=5,06 %. Na temelju provedene morfometrijske analize, može se zaključiti da karta profilne zakrivljenosti daje najlošije rezultate, odnosno prikazuje najmanju razliku između terena zahvaćenog klizanjem i terena bez klizišta, u usporedbi sa svim analiziranim kartama zakrivljenost. Od predikcijskih karata hrapavosti terena, karta omjera 3D i 2D površine terena (M=8,67 %) i karta hrapavosti terena dobivena kvadratnim prozorom veličine 5x5 m (M=7,46 %) imaju vrlo visok stupanj kartografskog preklapanja s vizualno kartiranim klizištima, a sve preostale predikcijske karte imaju indeks podudarnosti manji od 6 %. Indeks podudarnosti predikcijske karte raščlanjenosti terena iznosi 4,54 % što je među najnižim stopama točnosti u usporedbi s rasponom indeksa podudarnosti svih predikcijskih karata (M=4,11-8,67 %).

Iz opisane usporedbe morfometrijskih vrijednosti terena zahvaćenog klizanjem i terena bez klizišta na različitim vrstama izvedenih morfometrijskih karata vidljivo je da ista vrsta morfometrijskih karata može imati više indekse podudarnosti ako se primijene određene metode za izradu izvedenih karata. Drugim riječima, s određenim parametrima žarišne statistike moguće je dobiti morfometrijske karte s izraženijom morfologijom karakterističnom za klizišta. Također, na temelju provedene analize na izvedenim morfometrijskim kartama, proizlazi da bi morfometrijske karte izvedene iz LiDAR DMT-a za automatizirano kartiranje klizišta mogle biti prikladne i za vizualno kartiranje malih i plitkih klizišta u podsljemenskoj zoni Grada Zagreba. S obzirom na relativno visok indeks podudarnosti s vizualnom kartiranim klizištima na pilot području, za navedeno vizualno kartiranje najprikladnije su karta omjera 3D i 2D terena iz grupe karata hrapavosti terena, karta standardnih devijacija nadmorske visine dobivena kvadratnim prozorom veličine 3x3 m i karta raspona vrijednosti nadmorske visine dobivena kružnim prozorom radijusa 5 m. U daljnjim istraživanjima moguće je provedenu kvantitativnu analizu izvedenih morfometrijskih karata usporediti s kvalitativnom ocjenom morfometrijskih karata za vizualnu identifikaciju i kartiranje klizišta koju je u okviru doktorskog istraživanja provela Đomlija (2018). Naime, do sada su za vizualnu identifikaciju klizišta najčešće korištene karta osjenčanosti terena, karta nagiba terena, karta slojnica te eventualno karta hrapavosti i zakrivljenosti terena (Ardizzone et al., 2007; Schulz et al., 2007; Van Den Eeckhaut et al. 2007; Amundsen et al., 2010; Miner et al., 2010; Gorsevski et al., 2015; Petschko et al., 2015). Rezultati provedene morfometrijske analize na 127 izvedenih karata iz LiDAR DMT-a ukazuju da je pojedine vrste morfometrijskih karata, kao što su npr. karta omjera 3D i 2D terena i karta gustoće slojnica, potrebno primijeniti i prilikom vizualne identifikacije klizišta. Razlog tomu je morfologija klizišta koja je jasnije izražena na prethodno spomenutim morfometrijskim kartama nego na konvencionalno korištenim kartama (karta osjenčanosti terena, karta nagiba terena i karta slojnica) za vizualnu identifikaciju klizišta na LIDAR DMT-u, na što jasno ukazuje indeks podudarnosti, odnosno provedena analiza kartografskog preklapanja.

Konačna karta automatizirano kartiranih klizišta dobivena je zbrajanjem 28 predikcijskih karata. Zbrajanje karata provedeno je na dva načina: (a) zbrajanjem svih predikcijskih karata i reklasifikacijom konačne karte inventara klizišta s obzirom na parametre točnosti i (b) kombiniranjem predikcijskih karata primjenom *stepwise* metode (van Westen et al., 1993). Primjenom prve metode zbrajanja predikcijskih karata, zbrojene su sve predikcijske karte, bez obzira na njihov stupanj kartografskog preklapanja s vizualno kartiranim klizištima. U drugoj metodi zbrajanje predikcijskih karata je provedeno postupno, pri čemu je redoslijed određen na

osnovi indeksa podudarnosti, a iz konačnog zbroja su izuzete predikcijske karte koje smanjuju točnost karte inventara, odnosno modela za automatizirano kartiranje klizišta. Najoptimalnija karta inventara automatizirano kartiranih klizišta odabrana je s obzirom na dva parametra točnosti: (1) udio točaka točno klasificiranih kao klizišta, odnosno točaka klasificiranih kao klizišta unutar granica vizualno kartiranih klizišta te (2) udio točno predviđenih vizualno kartiranih klizišta. Općenito se može zaključiti da se smanjenjem granične vrijednosti povećava broj točaka klasificiranih kao klizišta i udio točno predviđenih vizualno kartiranih klizišta, ali se smanjuje udio točaka točno klasificiranih kao klizišta, odnosno povećava se broj točaka netočno klasificiranih kao klizišta. Kao najoptimalnija karta automatizirano kartiranih klizišta odabrana je karta reklasificirana s obzirom na graničnu vrijednosti 26. Ovako dobivena karta inventara na testnom području sadrži 3813 točaka klasificiranih kao klizišta, od toga se 34,9 % točaka nalazi unutar granica vizualno kartiranih klizišta, a točno je klasificirano 258 od 436 klizišta, odnosno 59,2 %. Primjenom *stepwise* metode kombiniranja predikcijskih karata (van Westen et al., 1993) izrađena je druga karta automatizirano kartiranih klizišta. Jedna po jedna predikcijska karta je zbrajana da bi se analizirao utjecaj predikcijske karte na model za automatizirano kartiranje klizišta, odnosno na konačan rezultat s obzirom na parametre točnosti. Redoslijed dodavanja i analize predikcijskih karata odabran je na temelju indeksa podudarnosti, na način da su prvo analizirane karte s višim stupnjem kartografskog preklapanja s vizualno kartiranim klizištima. Predikcijske karte koje su značajno smanjile udio točno predviđenih vizualno kartiranih klizišta, te stoga nisu primijenjene za izradu konačne karte inventara klizišta, su karta relativnog nagiba terena dobivena kvadratnim prozorom veličine 9x9 m s indeksom podudarnosti 6,07 %, karta profilne zakrivljenosti terena s indeksom podudarnosti 5,06 %, karta raščlanjenost terena dobivena kružnim prozorom radijusa 9 m s indeksom podudarnosti 4,83 % i karta vlažnosti terena s indeksom podudarnosti 4,72 %. Iz ovog postupka je proizašlo da karte i s nižim indeksom podudarnosti pozitivno utječu na točnost modela za automatizirano kartiranje klizišta, tako da nisu sve predikcijske karte s relativno nižim indeksom podudarnosti odbačene samo na temelju vrijednosti indeksa podudarnosti. Konačna karta automatizirano kartiranih klizišta na testnom području izrađena primjenom *stepwise* metode sadrži 5679 točaka klasificiranih kao klizišta, od toga se 42,2 % točaka nalazi unutar granica vizualno kartiranih klizišta, a točno je klasificirano 343 klizišta od 436, odnosno 74,1 %. Može se zaključiti da inventar automatizirano kartiranih klizišta izrađen primjenom *stepwise* metode kombiniranja predikcijskih karata sadrži 7,3 % više točno klasificiranih klizišta, odnosno gotovo 15 % više točno predviđenih vizualno kartiranih klizišta.

Verifikacija modela za automatizirano kartiranje klizišta provedena je na području površine 10,5 km^2 na kojem je vizualnom interpretacijom LiDAR DMT-a identificirano i iscrtano granice ukupno 293 klizišta. Na temelju graničnih vrijednosti morfometrijskih parametara dobivenih analizom vizualno kartiranih klizišta na području za treniranje modela te zbrajanjem 24 predikcijske karate, određene primjenom *stepwise* metode, izrađena je karta inventara automatizirano kartiranih klizišta za područje verifikacije. Modelom za automatizirano kartiranje klizišta točno je predviđeno 69,6 % od ukupnog broja vizualno kartiranih na području za verifikaciju modela, odnosno od ukupnog broja točaka klasificiranih kao klizišta, njih 29,3 % se nalazi unutar granica vizualno kartiranih klizišta, a gotovo 70 % točaka se nalazi unutar granica vizualno kartiranih granica nestabilnih padina. S obzirom na procjenu pouzdanosti vizualno identificiranih klizišta na LiDAR DMT-u, 83 % pouzdano vizualno identificiranih klizišta na području za verifikaciju je uspješno predviđeno modelom za automatizirano kartiranje klizišta, dok gotovo 50 % nepouzdano identificiranih (pretpostavljenih) klizišta nije predviđeno modelom za automatizirano kartiranje klizišta. Iz raspodjele površina točno predviđenih vizualno kartiranih klizišta se može zaključiti da se s povećanjem površine klizišta povećava udio točno predviđenih klizišta, na primjer 85 % vizualno kartiranih klizišta površine 1000-2000 m^2 predviđeno je modelom za automatizirano kartiranje klizišta, dok su sva klizišta površine veće od 2000 m^2 uspješno previđena modelom za automatizirano kartiranje klizišta. Suprotno navedenom, vizualno kartirana klizišta, koja nisu predviđena modelom za automatizirano kartiranje klizišta, su većinom površinom manja klizišta. Na primjer, od ukupno 27 vizualno kartiranih klizišta čija površina je manja od 125 m^2, modelom za automatizirano kartiranje klizišta predviđeno je 15 odnosno 55,6 % od ukupnog broja klizišta. Također, iz raspodjele površina točno predviđenih vizualno kartiranih klizišta može se zaključiti da je, s obzirom na površinu klizišta, modelom za automatizirano kartiranje klizišta predviđen reprezentativan uzorak klizišta.

Na temelju rezultata verifikacije automatizirano kartiranih klizišta može se zaključiti da metoda razvijena u okviru ovog doktorskog rada omogućava izradu karte inventara klizišta koja prikazuje lokacije (točke) koje ukazuju na morfologiju terena karakterističnu za klizišta. Međutim, model za automatizirano kartiranje klizišta ne omogućava kartiranje detaljnih i potpunih granica pojedinih klizišta na istraživanom području, što nije niti bila namjena predmetnog modela. Naime, u okviru provedenog doktorskog istraživanja jedan od ciljeva je razvijanje modela za automatizirano kartiranje klizišta u lokalnom, odnosno regionalnom mjerilu čija je daljnja primjena izrada prognostičkih karata hazarda klizanja. Naime, Petschko

et al. (2013) su zaključili da za procjenu podložnosti na klizanje nije potrebno koristiti potpuno granicu klizišta (poligon) već samo lokaciju (točku) postojećeg klizišta. Također, pregledom postojeće literature (Booth et al., 2009; Van Den Eeckhaut et al., 2012) može se zaključiti da do sada razvijeni modeli za automatizirano kartiranje klizišta omogućavaju kartiranje samo recentnih, velikih i dubokih klizišta, ali ne i izradu reprezentativne karte inventara klizišta za veće istraživano područje. Pod pojmom reprezentativne karte klizišta podrazumijeva se kartiranje reprezentativnog broja klizišta svih veličina (i starosti) na nekom području, a ne samo pojedine vrste klizišta. Razvijeni model za automatizirano kartiranje klizišta omogućava upravo izradu takvog inventara što se može zaključiti iz raspodjele veličina točno predviđenih vizualno kartiranih klizišta. Ukoliko daljnja namjena i primjena inventara klizišta zahtjeva detaljne i potpune granice klizišta, kartu inventara klizišta nužno je izraditi vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a visoke rezolucije. Također, inventar klizišta izrađen primjenom razvijenog modela za automatizirano kartiranje klizišta može poslužiti kao podloga za objektivniju identifikaciju i kartiranje klizišta vizualnom interpretacijom LiDAR DMT-a s obzirom da je verifikacija pokazala da je veliki broj automatizirano kartiranih klizišta izvan granica vizualno kartiranih klizišta (70,7 %), ali unutar granica kartiranih kao nestabilne padine (69,6 %). Udio automatizirano kartiranih klizišta (30,4 %) koja se nalaze izvan granice vizualno kartiranih klizišta i granica nestabilnih padina ne može se smatrati u potpunosti pogrešno klasificiranim iz razloga što pojedine lokacije ukazuju na morfologiju karakterističnu za klizišta, ali na predmetnim lokacijama nisu vizualno identificirana klizišta iz razloga što nije moguće izvući potpunu granicu klizišta (poligon). Drugim riječima, verifikacija automatizirano kartiranih klizišta s obzirom na vizualno kartirana klizišta nije u potpunosti pouzdana jer uvijek postoji mogućnost da nisu sva klizišta identificirana prilikom vizualne interpretacije LiDAR DMT-a na nekom području. Iz navedenog razloga, provedena je validacija modela za automatizirano kartiranje klizišta na način da je analizirana mogućnost primjene automatizirano kartiranih klizišta za izradu prognostičkih karata hazarda klizanja, odnosno izrađene su i uspoređene karte podložnosti na klizanje izvedene na temelju inventara klizišta dobivenog vizualnom interpretacijom i automatiziranim kartiranjem LiDAR DMT-a.

9.4 Primjena karata inventara klizišta dobivenih iz LiDAR DMT-a za izradu karata podložnosti na klizanje

Kao što je prethodno navedeno, u okviru ovog doktorskog istraživanja jedan od ciljeva je bio razvijanje modela za automatizirano kartiranje klizišta u lokalnom, odnosno regionalnom mjerilu sa svrhom dobivanja karte inventara klizišta za izradu prognostičkih karata hazarda klizanja. Iz tog razloga, u disertaciji su prikazani rezultati procjene podložnosti na klizanje u kojoj je kao ulazni podatak korišten inventar automatizirano kartiranih klizišta. Ista metoda procjene podložnosti primijenjena je i na podacima vizualno kartiranog inventara klizišta iz LiDAR DMT-a, čime je proveden postupak validacije svih konačnih rezultata.

Procjena podložnosti na klizanje provedena je primjenom bivarijantne statističke analize, odnosno WoE modelom (Bonham-Carter et al., 1989; Agterberg et al., 1990). Preduvjeti klizanja analizirani na pilot području (21 km^2) podsljemenske zone Grada Zagreba obuhvaćaju geomorfološke, geološke, hidrološke i antropogene faktore klizanja izvedene iz postojećih dostupnih podataka: LiDAR DMT rezolucije 1 m; digitalizirana Osnovna geološka karta, list Zagreb mjerila 1:100.000; i stvarno korištenje zemljišta Grada Zagreba u vektorskom obliku. Procjena podložnosti na klizanje provedena je s obzirom na pravilne ćelije dimenzija 1x1 m, što se može smatrati odgovarajućim s obzirom na rezoluciju geomorfoloških i hidroloških faktora klizanja izvedenih iz LIDAR DMT-a rezolucije 1x1 m. Antropogeni faktori klizanja izvedeni su iz stvarnog korištenja zemljišta Grada Zagreba dobivenog vektorizacijom DOF-a iz 2012. godine te su stoga također odgovarajući podloga za provedenu procjenu podložnosti na klizanje. Međutim, geološki faktori klizanja, korišteni kao ulazni podatak za WoE model, nisu odgovarajućeg mjerila jer su izvedeni iz vektorizirane OGK-a, list Zagreb mjerila 1:100.000. U daljnjim istraživanjima potrebno je koristiti geološke karte krupnijeg mjerila. Neovisno o kvaliteti geoloških faktora klizanja izvedenih iz OGK, smatra se da analizirani faktori klizanja predstavljaju odgovarajući set ulaznih podataka za validaciju inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta. Razlog tomu je što su izrađene tri karte podložnosti na klizanje izvedene s obzirom na isti skup faktora klizanja i tri različita inventara klizišta, vizualno i automatizirano kartiranih klizišta. Također, izvedene karte podložnosti se mogu smatrati reprezentativnim za predmetno pilot područje površine 21 km^2, ali u daljnjim istraživanjima nužno je primijeniti više različitih metoda za procjenu podložnosti na klizanje u podsljemenskoj zoni Grada Zagreba kako bi se odredila koja od postojećih statističkih metoda daje najbolje rezultate.

Analizira geomorfoloških faktora klizanja s obzirom na prostornu učestalost vizualno kartiranih klizišta, ukazuje da su nestabilnosti padina najčešće na područjima gdje su nagibi padina 15-40°, te kada su padine tog nagiba orijentirane prema sjeveroistoku, istoku, zapadu i sjeverozapadu. Analiza utjecaja nadmorske visine na pojavu klizišta pokazala je da klasa nadmorske visine 150-200 m n.m. doprinosi nestabilnosti padina što je vjerojatno povezano s litološkom građom koja prevladava na navedenoj nadmorskoj visini, a to su pijesci, šljunci, prahovi i gline pliokvartarne starosti. Također, analizama litoloških faktora utvrđeno je da se gotovo 93% klizišta na pilot području pojavljuje u pleistocenskim naslagama (heterogena mješavina krupnozrnastih i sitnozrnastih tala) i gornjepontskim naslagama (pijesci i laminirani lapori) koje zajedno prekrivaju oko 66% pilot područja. Analiza utjecaja udaljenosti od geoloških granica i rasjeda, s obzirom na prostornu učestalost vizualno kartiranih klizišta, pokazala je da na pojavu klizišta utječu klase faktora klizanja koje odgovaraju udaljenostima većim od 300 m, odnosno da se gustoća klizišta povećava s povećanjem udaljenosti od tektonskih struktura. Iz navedenog se može zaključiti da geološke granice i rasjedi nemaju značajan utjecaj na pojavu klizišta na pilot području podsljemenske zone Grada Zagreba. U okviru analize hidroloških faktora klizanja, analizirana je samo udaljenost od drenažne mreže, jer ostali javno dostupni digitalni podaci o stalnim i povremenim vodotocima nisu dovoljno kvalitetni, ili ne sadrže sve vodotoke ili vodotoci nisu odgovarajuće digitalizirani. Iz tog razloga, analiziran je samo utjecaj udaljenosti od drenažne mreže na pojavu klizišta. Ova analiza je pokazala da se više od 60 % klizišta nalazi u zoni širine 0-50 m oko drenažne mreže, te da navedena klasa faktorske karte nema utjecaj na stabilnost padina. Analizom vizualno i automatizirano kartiranih klizišta i stvarnog korištenja zemljišta može se zaključiti da je najveći broj klizišta kartiran na području šuma (85 %) te je primjenom WoE modela utvrđeno da navedena klasa faktora ima utjecaj na pojavu klizišta, dok umjetne površine imaju relativno najmanji utjecaj na pojavu klizišta. Međutim, analiza utjecaja udaljenosti od prometnica i građevina na pojavu klizišta pokazala je da sve klase udaljenosti veće od 10 m znatno utječu na pojavu klizanja. Najviši težinski faktor ima klasa udaljenosti 75-100 m što se može objasniti time što je su pilot području stambene i gospodarske građevina uglavnom izgrađene na zaravnjenim dijelovima u dolinama ili na hrptovima brda na kojima su također smještene i prometnice. Iz rezultata analize utjecaja antropogenih faktora na pojavu klizišta proizlazi da se gotovo 95 % vizualno kartiranih klizišta pojavljuje na poljoprivrednim površinama i šumama, a samo 7% na umjetnim površinama. Međutim, gotovo 37 % vizualno kartiranih klizišta se nalazi na udaljenosti manjoj od 10 m od građevina i prometnica, a čak 77 % klizišta na udaljenosti manjoj od 50 m. Iz navedenog proizlazi da su klizišta značajan ograničavajući faktor

na mogućnost daljnje urbanizacije na području podsljemenske zone Grada Zagreba te da su brojni elementi pod rizikom, pod čime se podrazumijevaju ljudi, stambene i gospodarske građevine i infrastruktura, izloženi hazardu klizanja.

Rezultat analize faktora klizanja s obzirom na učestalost površina vizualno kartiranih klizišta, broja vizualno kartiranih klizišta i broja automatizirano kartiranih klizišta su karte težinskih faktora. Vrijednosti težinskih faktora ukazuju na relativan utjecaj klasa faktora u odnosu na postojeća klizišta, a također imaju i prognozni karakter u smislu prostorne vjerojatnosti pojave budućih klizanja. Klase faktora klizanja s negativnim vrijednostima smatraju se područjima na kojima postoji niska prostorna vjerojatnost pojave klizišta, i obrnuto. Klase faktora s pozitivnim težinskim faktorom smatraju se područjima na kojima postoji određena prostorna vjerojatnost pojave klizišta. Zbrajanjem svih karata težinskih faktora izvedene su karte podložnosti. Za cijelo pilot područje (21 km^2) izrađene su tri različite karte podložnosti na klizanje, ovisno o tome na osnovi kojih karata inventara klizišta su procijenjeni težinski faktori. Za sve tri karte podložnosti je karakteristično da su vrlo heterogene s obzirom na prostornu raspodjelu vrijednosti ukupnog težinskog faktora, što otežava izvođenje kartografskih jedinica podložnosti. Naime, razlikuju se relativno velika područja na kojima prevladavaju visoke vrijednosti ukupnog težinskog faktora (npr. nestabilne padine s velikim brojem kartiranih klizišta), od manjih dijelova terena (npr. prometnice) koji su klasificirani kao stabilni jer imaju negativan ukupni težinski faktor. Razlog tomu je procjena podložnosti na klizanje u detaljnom mjerilu, po pravilnim ćelijama dimenzija 1x1 m. Karta podložnosti na klizanje bila bi homogenija ukoliko bi se procjena podložnosti provela na osnovi prostornih jedinica definiranih s obzirom na nagib i orijentaciju padine. Iz navedenog razloga, u daljnjim istraživanjima podložnost na klizanje potrebno je analizirati s obzirom na različite prostorne jedinice (morfološke jedinice ili pravilne ćelije većih dimenzija) ovisno o namjeni i mjerilu konačne karte hazarda klizanja.

Za sve tri izvedene karte podložnosti na klizanje konstruirana je ROC krivulja s obzirom na inventar klizišta na temelju kojeg je izvedena. Usporedba AUC vrijednosti pokazala je da najvišu stopu točnosti, odnosno vrlo visoki stupanj točnosti WoE modela ima karta podložnosti na klizanje izvedena na temelju automatizirano kartiranih klizišta (AUC=95 %). Karte podložnosti na klizanje dobivene vizualnom interpretacijom LiDAR DMT-a imaju nižu točnost, pri čemu procjena podložnosti s obzirom na površine klizišta ima stopu točnosti od 86 %, a s obzirom na broj klizišta 88 %. Karte podložnosti na klizanje izvedena na temelju automatizirano kartiranih klizišta verificirana je i s obzirom na vizualno kartirana klizišta. Na dijelu pilot

područja za verifikaciju (10,5 km^2), stopa predikcije karte podložnosti na klizanje s obzirom na klizišta koja su vizualno kartirana kao poligoni iznosi 84 %, a s obzirom na inventar u kojem su lokacije klizišta prikazane točkom stopa predikcije iznosi 87 %. Iz navedenog se može zaključiti da WoE model podložnosti na klizanje koji se temelji na automatizirano kartiranim klizištima ima visoki stupanj točnosti u usporedbi s WoE modelom podložnosti na klizanje koji se temelji na vizualno kartiranim klizištima. Ovime je potvrđeno da se automatizirano kartirane lokacije klizišta mogu primijeniti za izradu prognostičkih karata hazarda klizanja.

Konačne karte podložnosti na klizanje reklasificirane su na četiri klase podložnosti s graničnim vrijednostima definiranim na temelju ROC krivulja, odnosno s obzirom na granične udjele kumulativnih površina klizišta. Iskustveno, stabilni tereni definirani su kao područja na kojima se nalazi samo 1 % klizišta, uvjetno stabilni tereni su definirani su granicom od 5 % klizišta, uvjetno nestabilne padine definirane su s obzirom na granicu od 15 % klizišta, dok su nestabilne padine definirane kao područja na kojima se nalazi 85 % kumulativne površine/broja klizišta. Na karti podložnosti izrađenoj na temelju broja vizualno kartiranih klizišta, nestabilne padine obuhvaćaju površinu 4,69 km^2 ili 22,22 % pilot područja. Najveću površinu nestabilnih padina ima karta podložnosti izrađena na temelju površina vizualno kartiranih klizišta (5,27 km^2 ili 24,94 % pilot područja). Najmanju površinu nestabilnih padina ima karta podložnosti izrađena na temelju automatizirano kartiranih klizišta (1,85 km^2 ili 8,79 % pilot područja). Za usporedbu, površina klase klasificirane kao nestabilne padine na karti podložnosti na klizanje izvedene na temelju automatizirano kartiranih klizišta je samo tri i pol puta veća od površine vizualno kartiranih klizišta. Za razliku od toga, površina klase nestabilnih padina na kartama podložnosti na klizanje izvedenim na temelju vizualno kartiranih klizišta je devet, odnosno deset puta veća od površine vizualno kartiranih klizišta. Međutim, važno je napomenuti da su sve tri karte podložnosti na klizanje reklasificirane s obzirom na isti udio kumulativne površine ili udio broja klizišta (1 %, 5 % i 85 %). Karta podložnosti na klizanje izvedena na temelju automatizirano kartiranih klizišta ima stupanj točnosti gotovo 10 % veći od karata podložnosti na klizanje izvedenih na temelju vizualno kartiranih klizišta, te je za očekivati da se površine klasa podložnosti značajno razlikuju. Kada bi se karta podložnosti na klizanje izvedena na temelju automatizirano kartiranih klizišta reklasificirala s obzirom na drugačije granične vrijednosti, kao rezultat bi se mogle dobiti površine klasa podložnosti sličnije onima na kartama podložnosti izvedenim na temelju vizualno kartiranih klizišta. Drugim riječima, prilikom izrade karata podložnosti na temelju klizišta dobivenih modelom za automatizirano kartiranje klizišta potrebno je optimizirati granične vrijednosti klasa podložnosti na klizanje s obzirom na udio

vizualno kartiranih klizišta u pojedinoj klasi podložnosti na dijelu terena. Naime, površina klasa karata podložnosti ovisi o točnosti izvedenog WoE modela podložnosti, odnosno o obliku ROC krivulje.

S obzirom na provedene analize u okviru validacije karte inventara automatizirano kartiranih klizišta proizlazi da model za automatizirano kartiranje klizišta omogućava kartiranje reprezentativnog uzorka klizišta za izradu karte podložnosti na klizanje visoke točnosti i predikcije. Karta inventara klizišta dobivena modelom za automatizirano kartiranje klizišta predstavlja kartu točaka koje ukazuju na nepravilnu morfologiju karakterističnu za klizišta. Iz navedenog razloga, automatizirano kartiranje klizišta ne može u potpunosti zamijeniti vizualnu identifikaciju i kartiranje granica postojećih klizišta. Međutim, razvijeni model za automatizirano kartiranje klizišta omogućava klasifikaciju terena s obzirom na morfologiju karakterističnu za klizišta na učinkovitiji, odnosno brži i objektivniji način od vizualne interpretacije LiDAR DMT-a. Također, važno je napomenuti da je verifikacija i validacija automatizirano kartiranih klizišta nužna iz razloga što korištenje pogrešno izvedene karte podložnosti na klizanje može prouzročiti velike ekonomske gubitke ukoliko se karte podložnosti koriste za prostorno planiranje. Još opasniji od ekonomskih gubitaka su i ljudski gubici, koji su mogući ukoliko se karte podložnosti koriste u civilnoj zaštiti. Prezentirana verifikacija i validacija inventara klizišta i karata podložnosti stoga se smatra nužnim postupkom za eliminaciju nepotpunih i netočnih inventara klizišta za procjene hazarda i rizika klizanja.

10 ZAKLJUČAK

U okviru opisanog doktorskog istraživanja uspostavljena je metodologija za izradu karata klizišta korištenjem LIDAR tehnologije koja obuhvaća izradu optimalnog DMT-a visoke rezolucije i izvedenih morfometrijskih karata, kao ulaznih podataka, te izradu detaljnih i potpunih inventara klizišta, odnosno automatiziranog inventara klizišta, za izradu karata podložnosti na klizanje, kao konačnih karata. Razvoj ove metodologije proveden je na pilot području površine 21 km^2 u podsljemenskoj zoni Grada Zagreba (ukupne površine 180 km^2) za koju je provedeno lasersko skeniranje iz zraka u prosincu 2013. godine nakon (re)aktiviranja velikog broja klizišta tijekom zime 2012./2013. Ukupno su primijenjene dvije različite metode izrade karata inventara klizišta na temelju LiDAR tehnologije: metoda vizualne interpretacije morfometrijskih karata izvedenih iz LIDAR DMT-a i metoda automatiziranog kartiranja klizišta izradom modela koji se temelji na statističkim analizama vizualno kartiranih klizišta i izvedenih morfometrijskih karata. Procjenom podložnosti na klizanje na temelju različitih karata inventara klizišta analizirana je mogućnost njihove primjene za izradu prognostičkih karata hazarda te je ujedno validiran model razvijen za automatizirano kartiranje klizišta.

Pojedinačni rezultati provedenog doktorskog istraživanja postignuti u okviru razvoja metodologije za izradu karata klizišta korištenjem LIDAR tehnologije su:

- digitalni modeli terena bez vegetacije rezolucije 0,3x0,3 m i 1x1 m optimalni za vizualno i automatizirano kartiranje klizišta,
- detaljan i potpun inventar klizišta izrađen vizualnom interpretacijom morfometrijskih karata izvedenih iz LiDAR DMT-a,
- definirane granične vrijednosti morfometrijskih karata izvedenih iz LiDAR DMT-a koje ukazuju na nepravilnu morfologiju klizišta te omogućavaju automatizirano kartiranje klizišta,
- pikselno orijentiran model za automatizirano kartiranje klizišta na temelju morfometrijskih parametara izvedenih iz LiDAR DMT-a,
- tri karte podložnosti na klizanje dobivene analizom preduvjeta klizanja i karata inventara klizišta izrađenih na temelju vizualne interpretacije i automatiziranog kartiranja LiDAR DMT-a,
- doprinos poznavanju prostorne raspodjele klizišta te preduvjeta koji utječu na pojavu klizišta u podsljemenskoj zoni Grada Zagreba.

Laserskim skeniranjem iz zraka cijelog područja podsljemenske zone Grada Zagreba, koje je provedeno u okviru hrvatsko-japanskog SATREPS F2008 projekta „Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje rizika klizanja i bujica u Hrvatskoj“ (Mihalić i Arbanas, 2013; Arbanas et al., 2017), dobiven je oblak točaka gustoće 3,61 točke/m^2 nakon uklanjanja točaka reflektiranih od vegetacije i objekata. Na temelju kvalitativne procjene izraženosti morfologije klizišta na digitalnim modelima terena izvedenim iz ovog oblaka točaka primjenom različitih metoda interpolacije i s različitim veličinama ćelija, zaključeno je da je za vizualno kartiranje malih do srednje malih površinskih i plitkih klizišta najoptimalniji DMT rezolucije 30x30 cm izveden metodom inverzne udaljenosti. Za automatizirano kartiranje klizišta također je korišten DMT izveden metodom inverzne udaljenosti, ali rezolucije 1x1 m zbog toga što su pri nižim rezolucijama slabije izražene nepravilnosti u reljefu („šumovi“ na DMT-u) što može znatno utjecati na vrijednosti morfometrijskih parametara na kojima se temelji model za automatizirano kartiranje klizišta.

Za vizualnu identifikaciju morfologije klizišta i detaljno iscrtavanje granica klizišta korištene su tri morfometrijske karte izvedene iz LiDAR DMT-a, a to su karta osjenčanog reljefa, karta nagiba terena i karta slojnica ekvidistancije 0,5 m. Rezultat vizualne interpretacije ovih morfometrijskih karata je karta inventara klizišta koja na području veličine 21 km^2 sadrži ukupno 702 identificirana i iscrtana klizišta, veličine od 43 do 8.064 m^2. Ukupna površina klizišta na pilot području iznosi 0,5 km^2 ili 2,43 % površine pilot područja, dok je srednja gustoća klizišta 33,3 klizišta/km^2. Analiza učestalosti površina kartiranih klizišta pokazala je da krivulja raspodjele ima dva dijela, pozitivan dio krivulje koji opisuje površinom mala klizišta ($P > 400$ m^2), i negativan dio krivulje koji opisuje površinom srednje velika klizišta ($400 > P > 8000$ m^2). Na temelju raspodjele površine kartiranih klizišta te procjene da je 65% klizišta pouzdano identificirano, zaključeno je da inventar vizualno kartiranih klizišta za pilot područje površine 21 km^2 detaljan i potpun, što predstavlja kvalitetan i reprezentativan ulazni podatak za procjenu hazarda klizanja te razvoj modela za automatizirano kartiranje klizišta. S obzirom na broj i stupanj očuvanosti malih klizišta (> 400 m^2), zaključeno je da je većina klizišta recentna i (re)aktivirana ekstremnim hidrometeorološkim događajima u zimi 2012./2013. godine. Budući da pregledom satelitskih snimaka na Google Earthu-u iz rujna 2012. i kolovoza 2013. godine nije bilo moguće odrediti koja su to točno klizišta aktivirana tijekom zime 2012./2013., dobiveni inventar klizišta predstavlja kombinaciju sezonskog i povijesnog inventara klizišta.

Model za automatizirano kartiranje klizišta razvijen je na temelju 127 morfometrijskih karta izvedenih iz LiDAR DMT-a rezolucije 1x1 m te prethodno opisane karte inventara klizišta izrađene vizualnom interpretacijom LiDAR DMT-a. Izvedene morfometrijske karte svrstane su u osam grupa, a to su karte nadmorskih visina, karte osjenčanosti terena, karte nagiba terena, karte slojnica, karte zakrivljenosti terena, karte hrapavosti terena, karte vlažnosti i osunčanosti terena te karte raščlanjenosti terena. U okviru pripreme ulaznih podataka primijenjene su različite metode pridobivanja morfometrijskih karata, pri čemu su varirani parametri žarišne statistike s obzirom na različite oblike prozora (krug i kvadrat) i veličine prozora (3x3, 5x5 i 9x9 ćelija). Granične vrijednosti izvedenih morfometrijskih karata, odnosno morfometrijski parametri koji ukazuju na morfologiju klizišta određeni su na temelju krivulja raspodjele morfometrijskih vrijednosti površine terena zahvaćene klizanjem (unutar granica vizualno kartiranih klizišta) i površine okolnog terena bez klizišta. Metodom kartografske podudarnosti (Carrara et al., 1992) izrađene su karte morfometrijskih parametara klizišta koje su potom uspoređene s inventarom klizišta dobivenim vizualnom interpretacijom LiDAR DMT-a. Na ovaj način su izrađene predikcijske karte, odnosno definirani su morfometrijski parametri s najvišim indeksom podudarnosti čijim zbrajanjem je izvedena karta automatizirano kartiranih klizišta. Najviši indeks podudarnosti s vizualnom kartiranim klizištima imaju karta omjera 2D i 3D površine terena (M=8,67 %), a slijede morfometrijski parametri izvedeni iz karata nadmorskih visina, odnosno standardna devijacija nadmorske visine dobivena kvadratnim prozorom veličine 3x3 m (M=7,68 %) i raspon vrijednosti nadmorske visine dobiven kružnim prozorom radijusa 5 m (M=7,50 %). Druge značajnije predikcijske karte su karta gustoća slojnica ekvidistancije 0,5 m dobivena kružnim prozorom radijusa 10 m (M=7,48 %), karta hrapavosti terena dobivena kvadratnim prozorom veličine 5x5 m (M=7,46 %) te karta indeksa položaja dobivena metodom SIN (M=7,44 %).

Model razvijen za automatizirano kartiranje klizišta može se klasificirati kao pikselno orijentirana metoda koja se temelji na nadziranoj klasifikaciji morfometrijskih karata izvedenih iz LiDAR DMT-a. Rezultirajuća karta inventara automatizirano kartiranih klizišta zapravo predstavlja kartu točaka koje ukazuju na nepravilnu morfologiju karakterističnu za klizišta. Na području za testiranje modela (10,5 km^2) *stepwise* metodom kombiniranja predikcijskih karata izrađena je karta inventara koja sadrži ukupno 5679 točaka klasificiranih kao klizišta, od čega je 42,2 % točaka točno klasificirano jer se nalazi unutar granica vizualno kartiranih klizišta, čime je točno klasificirano 74,1 % vizualno kartiranih klizišta. Verifikacija modela za automatizirano kartiranje klizišta provedena je na drugom dijelu pilot područja površine

10,5 km^2. Ovako izvedena karta inventara sadrži ukupno 2807 točaka klasificiranih kao klizišta, a točno je predviđeno 69,6 % vizualno kartiranih klizišta. Analizom prostorne raspodjele točaka klasificiranih kao klizišta utvrđena je najveća gustoća automatizirano kartiranih klizišta na padinama na kojima postoje jasne morfološke značajke karakteristične za procese klizanja (tzv. nestabilnim padinama) ali na kojima nije moguće iscrtati točne granice klizišta u svim dijelovima takvih padina. Usporedbom površina vizualno kartiranih nestabilnih padina i klizišta s lokacijama automatizirano kartiranih klizišta, dobivena je točnost modela od gotovo 70 %. Daljnjom analizom vizualno kartiranih klizišta, uspješno predviđenih modelom za automatizirano kartiranje klizišta, zaključeno je da pouzdanost vizualne identifikacije klizišta, odnosno izraženost morfologije klizišta na izvedenim morfometrijskim kartama značajno utječe na točnost automatizirano kartiranih klizišta. Naime, preko 80 % pouzdano vizualno identificiranih klizišta na području za verifikaciju uspješno je predviđeno razvijenim modelom, dok gotovo 50 % nepouzdano identificiranih (pretpostavljenih) klizišta nije predviđeno modelom za automatizirano kartiranje klizišta. Također, raspodjela površina točno predviđenih vizualno kartiranih klizišta je jedan od dokaza da model za automatizirano kartiranje klizišta omogućava kartiranje reprezentativnog uzorka klizišta s obzirom na veličinu pojava nestabilnosti, odnosno omogućava izradu karte inventara u kojoj su identificirane morfologije klizišta svih veličina prisutnih na području istraživanja što je neophodno za pouzdanu procjenu podložnosti na klizanje.

Karte podložnosti na klizanje izrađene na temelju inventara klizišta dobivenih vizualnom interpretacijom i automatiziranim kartiranjem LiDAR DMT-a, kreirane su s ciljem validacije modela za automatizirano kartiranje klizišta, odnosno sa svrhom ocjene mogućnosti primjene automatizirano kartiranih klizišta za izradu karata prognostičkih karata hazarda klizanja. Procjena podložnosti na klizanje provedena je primjenom bivarijantne statističke analize, odnosno WoE modela (Bonham-Carter et al., 1989; Agterberg et al., 1990), kojim su analizirani preduvjeti klizanja na pilot području (21 km^2) podsljemenske zone Grada Zagreba, a koji obuhvaćaju geomorfološke, geološke, hidrološke i antropogene faktore klizanja. Sve faktorske karte izvedene su iz postojećih dostupnih podataka, a to su LiDAR DMT rezolucije 1 m, digitalizirana Osnovna geološka karta, list Zagreb mjerila 1:100.000 i stvarno korištenje zemljišta Grada Zagreba u vektorskom obliku. Rezultat analize faktora klizanja s obzirom na površine vizualno kartiranih klizišta, broj vizualno kartiranih klizišta i automatizirano kartirana klizišta su karte težinskih faktora čijim zbrajanjem su izvedene karte podložnosti na klizanje za pilot područje (21 km^2). Za svaku od karata podložnosti na klizanje konstruirana je ROC

krivulja s obzirom na inventar klizišta na temelju kojeg je izvedena, a usporedba AUC vrijednosti pokazala je da najvišu stopu točnosti ima karta podložnosti na klizanje izvedena na temelju automatizirano kartiranih klizišta (AUC=95 %). Karte podložnosti na klizanje dobivene vizualnom interpretacijom LiDAR DMT-a imaju nižu točnost, odnosno procjena podložnosti s obzirom na površine klizišta ima stopu točnosti od 86 %, a s obzirom na broj klizišta 88 %. Karta podložnosti na klizanje izvedena na temelju automatizirano kartiranih klizišta verificirana je i s obzirom na vizualno kartirana klizišta. Na dijelu pilot područja za verifikaciju (10,5 km^2), stopa predikcije karte podložnosti na klizanje s obzirom na klizišta koja su vizualno kartirana kao poligoni iznosi 84 %, a s obzirom na inventar u kojem su lokacije klizišta prikazane točkom, stopa predikcije iznosi 87 %. S obzirom na AUC vrijednosti dobivene validacijom karte podložnosti na klizanje izvedene na temelju automatizirano kartiranih klizišta može se zaključiti da model za automatizirano kartiranje klizišta omogućava kartiranje reprezentativnog uzorka klizišta iz kojega je moguće izraditi karte podložnosti na klizanje visoke točnosti i predikcije. Međutim, karta inventara klizišta dobivena modelom za automatizirano kartiranje klizišta predstavlja kartu točaka koje ukazuju na nepravilnu morfologiju karakterističnu za klizišta. Iz navedenog razloga, automatizirano kartiranje klizišta ne može u potpunosti zamijeniti vizualnu identifikaciju i kartiranje klizišta ukoliko daljnja namjena inventara iziskuje detaljno iscrtane granice postojećih klizišta.

Analizirani geomorfološki faktori klizanja ukazuju da na nestabilnost padina ponajviše utječu nagibi terena veći od 15° te padine orijentirane prema sjeveru, sjeveroistoku, zapadu i sjeverozapadu. Analiza utjecaja nadmorske visine na pojavu klizišta pokazala je da klasa nadmorske visine 150-200 m n.m. ima negativan utjecaj na stabilnost padina što je vjerojatno povezano s litološkom građom koja prevladava na navedenoj nadmorskoj visini, a to su pijesci, šljunci, prahovi i gline pliokvartarne starosti. Također, daljnjim analizama utvrđeno je da se gotovo 95% klizišta na pilot području pojavljuje u pleistocenskim naslagama (heterogena mješavina krupnozrnastih i sitnozrnastih tala) i gornjepontskim naslagama (pijesci i laminirani lapori) koji prekrivaju oko 63 % pilot područja. U okviru analize hidroloških preduvjeta, analiziran je utjecaj udaljenosti od drenažne mreže na pojavu klizišta koja je pokazala da se više od 60 % klizišta nalazi u zoni širine 0-50 m oko drenažne mreže, te da navedena klasa faktorske karte ima negativan utjecaj na stabilnost padina. Analizom vizualno i automatizirano kartiranih klizišta i stvarnog korištenja zemljišta može se zaključiti da je najveći broj klizišta kartiran na području šuma (85 %) te je primjenom WoE modela dobiveno da navedena klasa faktora ima negativan utjecaj na stabilnost padina, dok umjetne površine imaju relativno

najmanji utjecaj na pojavu klizišta. Međutim, analiza utjecaja udaljenosti od prometnica i građevina na pojavu klizišta pokazala je da sve klase udaljenosti veće od 10 m znatno utječu na pojavu klizišta. Najviši težinski faktor ima klasa udaljenosti 75-100 m što se može objasniti činjenicom da je na pilot području gradnja stambenih i gospodarskih građevina usko vezana za zaravnjeno područje oko prometnica koje najčešće prolaze najstabilnijim dijelovima terena, odnosno dolinama ili hrptovima brda. Iz rezultata analize utjecaja antropogenih faktora na pojavu klizišta proizlazi kako se gotovo 95 % vizualno kartiranih klizišta pojavljuje na poljoprivrednim površinama i šumama, a samo 7% na umjetnim površinama. Međutim, gotovo 35 % vizualno kartiranih klizišta se nalazi na udaljenosti do 10 m od građevina i prometnica. Iz navedenog proizlazi da klizišta mogu značajno utjecati na daljnju urbanizaciju na području podsljemenske zone Grada Zagreba te da su elementi pod rizikom, ljudi, stambene i gospodarske građevine i infrastruktura, izrazito izloženi hazardu klizanja.

S obzirom na istraživanja klizišta koja su prethodila izradi ove disertacije, područje podsljemenske zone Grada Zagreba izrazito je podložno na klizanje, što je posljedica geološke građe, karakterističnog reljefa te intenzivne urbanizacije. U posljednjih 50-ak godina na području Grada Zagreba izrađena su četiri inventara klizišta koja daju vrlo različite informacije o prostornoj raspodjeli i veličini klizišta. Postojeće karte inventara klizišta izrađene su primjenom konvencionalnih metoda istraživanja i kartiranja klizišta, odnosno terenskim geomorfološki kartiranjem (Šikić, 1967; Polak et al., 1979; Miklin et al., 2007) i stereoskopskom analizom avionskih snimaka (Podolzski, 2014). Budući da više od 30 % podsljemenske zone Grada Zagreba prekrivaju šume i poluprirodna područja, pri čemu su pojedini dijelovi terena u potpunosti obrasli niskom vegetacijom (makija i šikare), primijenjene konvencionalne metode kartiranja klizišta, onemogućavaju izradu potpunih inventara klizišta. Naime, postojeći inventari klizišta su nepotpuni jer su prilikom terenskog kartiranja identificirana samo velika i duboka klizišta ili nestabilne zone, odnosno mala i plitka klizišta nije bilo moguće identificirati na avionskim snimaka sitnog mjerila.

Inventar vizualno kartiranih klizišta, izrađen u ovom radu, verificiran je na terenu na način da je provedena prospekcija 10 % vizualno kartiranih pojava klizišta (70 slučajno odabranih klizišta). Za 40 % klizišta je potvrđeno da postoje ili je za njih pretpostavljeno da se radi o klizištima zbog nepravilne morfologije terena. Za gotovo 60 % klizišta nije bilo moguće utvrditi radi li se terenu zahvaćenom klizanjem, a razlog tome su neprohodna zemljišta obrasla početnim ili degradacijskim razvojnim stadijima šumskih sastojina (makija, šikare i dr.). Usporedbom dostupnih postojećih inventara klizišta (inventari klizišta iz 1979. i 2007. godine)

i inventara klizišta izrađenog vizualnom interpretacijom LiDAR DMT-a, zaključeno je da postoji značajna razlika u veličini i broju klizišta što ukazuje na nepouzdanost postojećih inventara klizišta, osobito inventara klizišta iz 2007. godine koji se koristi kao podloga za prostorno planiranje i donošenje odluka vezanih za uvjete gradnje, odnosno izdavanje lokacijskih i građevinskih dozvola. Naime, na pilot području površine 21 km^2, inventari iz 1979. i 2007. godine imaju oko 160 evidentiranih klizišta dok inventar dobiven interpretacijom LiDAR DMT-a ima 702 klizišta, odnosno 4,5 puta više kartiranih klizišta. Najveću ukupnu površinu kartiranih klizišta (3,73 km^2 ili 17,69 % pilot područja) ima inventar iz 2007. godine, a ona je gotovo sedam puta veća od ukupne površine klizišta u inventarima iz 1979. godine (0,61 km^2 ili 2,88 % pilot područja) i inventara izrađenog vizualnom interpretacijom LiDAR DMT-a (0,5 km^2 ili 2,43 % pilot područja). Iz navedenog se može zaključiti da karta inventara klizišta izrađena vizualnom interpretacijom LiDAR DMT-a ima 340% veću gustoću klizišta po kilometru kvadratnom od gustoće klizišta iz dostupnih povijesnih inventara, ali 86% manju ukupnu površinu klizišta od karte inventara iz 2007. godine. S obzirom na prethodne metode, kartiranje klizišta u podsljemenskoj zoni Grada Zagreba, primjena LiDAR tehnologije omogućava izradu karte inventara klizišta s gotovo 4,5 puta više klizišta koja su do sada na pilot području bila nepoznata. Iz svega navedenog proizlazi da DMT visoke rezolucije dobiven laserskim skeniranjem iz zraka omogućava pouzdanu vizualnu interpretacija klizišta i izradu detaljnog i potpunog inventara klizišta za cijelo područje podsljemenske zone Grada Zagreba bez obzira na veličinu klizišta (mala i plitka klizišta), visoki stupanj urbaniziranosti (modifikacija okoliša) i gustu vegetaciju (šumska područja).

Doktorskim istraživanjem ostvareni su sljedeći znanstveni doprinosi:

- doprinos razvoju metodologije za izradu detaljnih i potpunih karata inventara klizišta primjenom LiDAR tehnologije nakon pokretanja velikog broja klizišta;
- doprinos poznavanju preduvjeta klizanja i prostorne raspodjele klizišta u kvartarnim i neogenskim naslagama podsljemenske zone Grada Zagreba;
- doprinos razvoju metodologije za automatizirano kartiranje klizišta na temelju morfometrijskih parametara dobivenih iz LiDAR DMT-a visoke rezolucije;
- doprinos razvoju metodologije za procjenu podložnosti na klizanje primjenom inventara klizišta dobivenog modelom za automatizirano kartiranje klizišta.

S obzirom na rezultate ostvarene u okviru doktorskog istraživanja u budućnosti su planirane slijedeće aktivnosti:

- izrada detaljne karte inventara klizišta vizualnom interpretacijom LiDAR DMT za cijelo područje podsljemenske zone Grada Zagreba koja se može koristiti kao podloga za donošenje odluka vezanih za uvjete gradnje, odnosno izdavanje lokacijskih i građevinskih dozvola;
- identifikacija aktivnosti vizualno i automatizirano kartiranih pojava klizišta na temelju analize i interpretacije satelitskih snimaka;
- primjena modela razvijenog za automatizirano kartiranje klizišta, odnosno definiranih morfometrijskih parametara na područjima sličnih morfoloških značajki i geološke građe;
- primjena razvijene metodologije na područjima s morfološkim značajkama i geološkom građom različitom od predmetnog područja istraživanja;
- primjena razvijenog modela za automatizirano kartiranje klizišta na LiDAR DMT-u različitih rezolucija;
- primjena različitih metoda strojnog učenja za razvoj modela za automatizirano kartiranje na temelju izvedenih morfometrijskih karata;
- izrada karata podložnosti na klizanje za cijelo područje podsljemenske zone Grada Zagreba na temelju automatizirano kartiranih klizišta primjenom različitih statističkih metoda (multivarijante statističke analize i metode strojnog učenja) te analizom većeg broja faktora klizanja;
- izrada prognostičkih karata hazarda i rizika klizanja za cijelu podsljemensku zonu Grada Zagreba;
- primjena rezultata provedenih i budućih istraživanja u izradi prostorno-planske dokumentacije na području podsljemenske zone Grada Zagreba.

LITERATURA

Agterberg, F.P., Bonham–Carter, G.F., Wright, D.F. (1990): Statistical Pattern Integration for Mineral Exploration. U: Gaal, G., Merriam, D.F. (ur.): Computer Applications in Resource Estimation: Prediction and Assessment for Metals and Petroleum, Pergamon, Oxford, 1-21.

Aleotti, P., Chowdhury, R. (1999): Landslide hazard assessment: summary review and new perspectives. Bulletin of Engineering Geology and the Environment, 58, 21–44.

Amundsen, J., Johnson, S., Rouse, K., Wang, H. (2010): Using LiDAR-derived DEM's to delineate and characterize landslides in Northern Kentucky and Hamilton County, Ohio. URL: http://www.trishock.com/academic/pdf/lidar_landslides.pdf (zadnji pristup: 20. travnja 2019.)

Andabaka, D., Marić, S., Gudelj, A., Posavec, S. (2011): Ugroženost potoka na području grada Zagreba. U: Dadić, Ž. (ur.): XV. znanstveno - stručni skup Voda i javna vodoopskrba, 4-7.10.2011., Hrvatski zavod za javno zdravstvo, Zagreb, 191-192.

Antonini, G., Ardizzone, F., Cardinali, M., Galli, M., Guzzetti, F., Reichenbach, P. (2002): Surface deposits and landslide inventory map of the area affected by the 1997 Umbria–Marche earthquakes. Bollettino della Societa Geologica Italiana, 121 (2), 843–853.

Arbanas, Ž., Mihalić Arbanas, S., Sassa, K., Marui, H., Fukuoka, H., Krkač, M., Vivoda Prodan, M., Bernat Gazibara, S., Đomlija, P. (2017): The Croatian-Japanese SATREPS Joint Research Project on Landslides (IPL-161). U: Sassa, K., Mikoš, M., Yin, Y. (ur.): Advancing Culture of Living with Landslides, Cham: Springer, Vol. 1, 395-409.

Ardizzone, F., Cardinali, M., Carrara, A., Guzzetti, F., Reichenbach, P. (2002): Impact of mapping errors on the reliability of landslide hazard maps. Natural Hazards and Earth System Sciences, 2, 3–14.

Ardizzone F., Cardinali M., Galli M., Guzzetti F., Reichenbach P. (2007): Identification and mapping of recent rainfall-induced landslides using elevation data collected by airborne LiDAR. Natural Hazards and Earth System Sciences, 7(6), 637–650.

Ascione, A., Cinque, A., Miccadei, E., Villani, F., Berti, C. (2008): The Plio-Quaternary uplift of the Apennine chain: new data from the analysis of topography and river valleys in Central Italy. Geomorphology, 102, 105–118.

ASPRS, *The American Society for Photogrammetry i Remote Sensing* (2013): LAS Specification, verison 1.4–R 12 http://asprs.org/a/society/committees/standards/LAS_1_4_r12.pdf (zadnji pristup: 20. travnja 2019.)

Atkinson, P., Jiskoot, H., Massari, R., Murray, T. (1998): Generalized linear modelling in geomorphology. Earth Surface Processes and Landforms, 23, 1185–1195.

Axelsson, P. (2000): DEM generation from laser scanner data using adaptive TIN models. International Archives of Photogrammetry and Remote Sensing, 33 (B4/1), 110-117.

Bao, Y.F., Li, G.P., Cao, C.X., Li, X.W., Zhang, H., He, Q.S., Bai, L.Y., Chang, C.Y. (2008): Classification of LIDAR point cloud and generation of DMT from LIDAR height and intensity data in forested area. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 37 (Part B/3b), 313–318.

Basch, O. (1976): Osnovna geološka karta, List Ivanić Grad, M 1:100.000. Geološki zavod Zagreb.

Basch, O. (1980): Tumač za Osnovnu geološku kartu, List Ivanić Grad, M 1:100.000. Geološki zavod Zagreb.

Bell, F.G. (2003): Geological hazards: their assessment, avoidance and mitigation. Spon Press, Taylor and Francis Group, London, New York, 656 str.

Bell, R., Petschko, H., Röhrs, M., Dix, A. (2012): Assessment of landslide age, landslide persistence and human impact using airborne laser scanning digital terrain models. Geografiska Annaler: Series A, Physical Geography, 94, 135-156.

Bernat, S., Mihalić Arbanas, S., Krkač, M. (2014a): Inventory of precipitation triggered landslides in the winter of 2013 in Zagreb (Croatia, Europe). U: Sassa K., Canuti P., Yin Y. (ur.): Landslide Science for a Safer Geoenvironment, Volume 2: Methods of Landslide Studies. Springer, Cham, 829-836.

Bernat, S., Mihalić Arbanas, S., Krkač, M. (2014b): Landslides triggered in the continental part of Croatia by extreme precipitation in 2013. U: Lollino G., Giordan D., Crosta G., Corominas J., Azzam R., Wasowski J., Sciarra N. (ur.): Engineering Geology for Society and Territory, Volume 2: Landslide Processes, Springer, Heidelberg, 1599-1603.

Bernat Gazibara, S., Mihalić Arbanas, S., Krkač, M., Sečanj, M. (2017): Catalog of precipitation event that triggered landslides in northwestern Croatia. U: Abolmasov B., Marjanović M., Đurić U. (ur.): Proceedings of the 2nd Regional Symposium on Landslides in the Adriatic-Balkan Region, University of Belgrade, Faculty of Mining and Geology, Belgrade, 103-107.

Berry, J. K. (2002): Use surface area for realistic calculations. Geoworld 15(9), 20–1.

Berti, M., Corsini ,A., Daehne, A. (2012): Comparative analysis of surface roughness algorithms for the identification of active landslides. Geomorphology, 182, 1-18.

Beguería, S. (2006): Validation and evaluation of predictive models in hazard assessment and risk management. Natural Hazards, 37, 315–329.

Bezzi, M., Vitti, A. (2005): A comparison of some kriging interpolation methods for the production of solar radiation maps, Geomatics Workbooks, 5, 1-17.

Blaschke, T. (2010): Object based image analysis for remote sensing. ISPRS Journal of Photogrammetry and Remote Sensing, 65, 2-16.

Bognar, A. (1992): Inženjerskogeomorfološko kartiranje. Acta Geographica Croatica, 27, 173-185.

Bognar, A. (1994): Geomorfološke značajke reljefa Zagreba i njegove šire okolice. Geografski Horizont, 2, 27-34.

Bognar, A. (1996): Croatia – the land and natural features. GeoJournal, 38(4), 407–416.

Bognar, A. (2001): Geomorfološka regionalizacija Hrvatske. Acta Geographica Croatica, 34, 7–29.

Bonham-Carter, G.F. (2002): Geographic information systems for geoscientist: modelling with GIS. Pergamon, New York, 302–334.

Bonham-Carter, G.F., Agterberg, F.P., Wright, D.F. (1989): Weights of evidence modelling: a new approach to mapping mineral potential. Stat Appl in Earth Sci 89–9:171–183

Booth, A.M., Roering, J.J., Perron J.T. (2009): Automated landslide mapping using spectral analysis and high-resolution topographic data: Puget Sound lowlands, Washington, and Portland Hills, Oregon. Geomorphology, 109, 132–147.

Borkowski, A., Perski, Z., Wojciechowski, T., Jóźków, G., Wójcik, A. (2011): Landslides mapping in Roznow Lake vicinity, Poland using airborne laser scanning data. Acta Geodynamica et Geomaterialia, 8 (3), 325–333.

Brabb, E.E., Pampeyan, E.H., Bonilla, M.G. (1972): Landslide susceptibility in San Mateo County, California. US Geological Survey Miscellaneous Field Studies Map, MF-360, Map at 1: 62,500 scale.

Brabb, E.E., Harrod, B.L. (1989): Landslides: Extent and Economic Significance. Proceedings of the 28th international geologic congress symposium on landslides, Washington D.C.Balkema: Rotterdam, 385 str.

Brand, E.W. (1988): Special lecture: landslide risk assessment in Hong Kong. U: Bonnard, C. (ur.): Proceedings of the V. International Symposium on Landslides, Lausanne, Switzerland. A.A. Balkema, Amsterdam, 2, 1059–1074.

Brunetti, M.T., Guzzetti, F., Rossi, M. (2009): Probability distributions of landslide volumes. Nonlinear Processes in Geophysics, 16, 179–188.

Bulut, F., Boynukalin, S., Tarhan, S. and Ataoglu, E. (2000): Reliability of landslide isopleth maps. Bulletin of Engineering Geology and the Environment, 58(2), 95-98.

Burns, W.J., Duplantias, S., Jones, C.B., English, J.T. (2012): LiDAR dana and landslide invnetory maps of the North Fork Siuslaw River and Big Elk Creek Watersheds, Lane, Lincoln, and Benton Counties, Oregon. Open-file report O-12-07.

Cardinali, M., Guzzetti, F., Brabb, E.E. (1990): Preliminary map showing landslide deposits and related features in New Mexico, U.S. Geological Survey Open File Report 90/293, 4 sheets, scale 1:500,000.

Cardinali, M., Antonini, G., Reichenbach, P., Guzzetti, F. (2001): Photo geological and landslide inventory map for the Upper Tiber River basin. CNR, Gruppo Nazionale per la Difesa dalle Catastrofi Idrogeologiche, Publication n. 2116, scale 1:100,000.

Carrara, A., Cardinali, M., Guzzetti, F. (1992): Uncertainty in assessing landslide hazard and risk. ITC Journal, 2, 172–183. doi:10.1007/978-94-015-8190-5_12 (zadnji pristup: 20. travnja 2019.)

Carrara, A, Guzzetti F, Cardinali M, Reichenbach P (1999): Use of GIS technology in the prediction and monitoring of landslide hazard. Natural Hazards 20(2–3), 117–135.

Chacón, J., Irigaray, C., Fernández, T., El Hamdouni, R. (2006): Engineering geology maps: landslides and geographical information systems. Bulletin of Engineering Geology and the Environment, 65, 341–411.

Chigira, M., Duan, F., Yagi, H., Furuya, T. (2004): Using an airborne laser scanner for the identification of shallow landslides and susceptibility assessment in an area of ignimbrite overlain by permeable pyroclastics. Landslides, 1, 203–209.

Childs, C. (2004): Interpolating Surfaces in ArcGIS Spatial Analyst, ESRI Education Services, http://webapps.fundp.ac.be/geotp/SIG/interpolating.pdf (zadnji pristup: 20. travnja 2019.)

Chu, H.J., Wang, C.K, Huang, M.L., Lee, C.C, Liu, C.Y., Lin, C.C. (2014): Effect of point density and interpolation of LiDAR-derived high-resolution DEMs on landscape scarp identification. GIScience & Remote Sensing, 51(6), 731–747.

Clague, J.J., Roberts, N.J. (2012): Landslide hazard and risk. U: Clague, J:J, Stead, D. (ur.): Landslides Types, Mechanisms and Modeling. Cambridge, University Press, United Kingdom, 1-9.

Corominas, J., van Westen, C., Frattini, P., Cascini, L., Malet, J.P., Fotopoulou, S., Catani, F., Van Den Eeckhaut, M., Mavrouli, O., Agliardi, F., Pitilakis, K., Winter, M.G., Pastor, M., Ferlisi, S., Tofani, V., Hervas, J., Smith, J.T. (2013): Recommendations for the quantitative analysis of landslide risk. Bulletin of Engineering Geology and the Environment, Volume 73, Issue 2, 209–263.

Crawford, M.M. (2014): Inventory Mapping and Characterization of Landslides Using LiDAR: Kenton and Campbell Counties, Kentucky. Digital Mapping Techniques—Workshop Proceedings". U.S. Geological Survey Open-File Report 2014–1167 http://pubs.usgs.gov/of/2014/1167/ (zadnji pristup: 20. travnja 2019.)

Crozier, M. (2005): Multiple-occurrence regional landslide events in New Zealand: Hazard management issues. Landsldies 2(4), 247-256.

Cruden, D.M. (1991): A simple definition of a landslide. Bulletin of the International Association of Engineering Geology, 43, 27.

Cruden, D.M., Varnes, D.J. (1996): Landslide types and processes. U: Turner, A.K., Schuster, R.L. (ur.): Landslides, Investigation and Mitigation. Transportation Research Board, Special Report 247, Washington D.C., USA, 36–75.

Dai, F.C., Lee, C.F., Ngai, Y.Y. (2002): Landslide risk assessment and management: an overview. Engeering Geology 64, 65–87.

DeGraff, J.V. (1985): Using isopleth maps of landslide deposits as a tool in timber sale planning. Bulletin American Association of Engineering Geologists, 22, 445–453.

De Reu, J., Bourgeois, J., Bats, M., (2013): Application of the topographic position index to heterogeneous landscapes. Geomorphology 186, 39–49.

Duman, T.Y., Çan T., Emre Ö., Keçer M., Doğan A., Şerafetti, A., Serap D. (2005): Landslide inventory of northwestern Anatolia, Turkey. Engineering Geology, 77 (1–2), 99–114.

Državni hidrometeorološki savez, DHMZ (2013): Meteorološki i hidrološki bilten 1-3, 2013.

Državni zavod za statistiku, DZS (2011): Statistička izvješća - Popis stanovništva iz 2011. Godine. URL: http://www.dzs.hr (zadnji pristup: 20. travnja 2019.)

Đomlija, P. (2018): Identifikacija i klasifikacija klizišta i erzoije vizualnom interpretacijom digitalnoga modela reljefa Vinodolske udoline. Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet. Doktorski rad, 475 str.

Evans, I. S. (1972): General geomorphometry, derivatives of altitude, and descriptive statistics. U: Chorleym J. (ur.): Spatial Analysis in Geomorphology, London, 17-90.

Evans, J.S., Hudak, A.T. (2007): A multiscale curvature algorithm for classifying discrete return LiDAR in forested environments. IEEE Transactions on Geoscience and Remote Sensing, 45(4), 1029-1038.

Evans, J.S., Oakleaf, J., Cushman, S.A., Theobald, D. (2014): An ArcGIS toolbox for surface gradient and geomorphometric modeling, version 2.0-0. URL: http://evansmurphy.wix.com/evansspatial (zadnji pristup: 20. travnja 2019.)

Felicísimo, Á.M., Cuartero, A., Remondo, J., Quirós, E. (2012): Mapping landslide susceptibility with logistic regression, multiple adaptive regression splines, classification and regression trees, and maximum entropy methods: a comparative study. Landslides, 10, 175–189.

Fell, R., Corominas, J., Bonnard, C., Cascini, L., Leroi, E., Savage, W.Z. (on behalf of the JTC-1 Joint Technical Committee on Landslides and Engineered Slopes) (2008a): Guidelines for landslide susceptibility, hazard and risk zoning for land use planning. Engineering Geology, 102, 85–98.

Fell, R., Corominas, J., Bonnard, C., Cascini, L., Leroi, E., Savage, W.Z. (on behalf of the JTC-1 Joint Technical Committee on Landslides and Engineered Slopes) (2008b): Guidelines for landslide susceptibility, hazard and risk zoning for land-use planning. Engineering Geology, 102, 99–111.

Fernandez, T., Jiménez Fernández, P., El Hamdouni, R., Cardenal, F.J., Delgado, J., Irigaray, C., Chacón, J. (2008): Automatic detection of landslide features with remote sensing techniques in the Betic Cordilleras (Granada, Southern Spain). International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, 37(1), 351-356.

Fiorucci, F., Cardinali, M., Carlà, R., Rossi, M., Mondini, A.C., Santurri, L., Ardizzone, F., Guzzetti, F. (2011): Seasonal landslides mapping and estimation of landslide mobilization rates using aerial and satellite images. Geomorphology, 129 (1–2), 59–70.

Gajski, D. (2007): Osnove laserskog skeniranja iz zraka. Ekscentar, 10, 16-22.

Galli, M., Ardizzone, F., Cardinali, M., Guzzetti, F., Reichenbach, P. (2008) Comparing landslide inventory maps. Geomorphology, 94, 268–289.

Glade, T. (2001): Landslide hazard assessment and historical landslide data - an inseparable couple? U: Glade T., Albini P., Frances F. (ur.): The Use of Historical Data in Natural Hazards Assessment (Advances in Natural and Technological Hazard Research). Kluwer Academic Publications, Dordrecht, The Netherlands, 153–168.

Glenn, N.F., Streuker, D.R., Chadwick, D.J., Thackray, G.D., Dorsch, S.J. (2006): Analysis of Lidar derived topographic information for characterizing and differentiating landslide morphology and activity. Geomorphology, 73, 131–148.

Golek, D., Dobinić, D., Kordić, B. (2012): Usporedba terestričkih laserskih skenera. Ekscentar, 15, 54-61.

Goodchild, M. F., Mark, D. M. (1987): The fractal nature of geographic phenomena, Annals of Association of American Geographers, 77 (2), 265-278.

Goodchild, M. F., Yuan, M., Cova, T.J. (2007): Towards a general theory of geographic representation in GIS. International Journal of Geographical Information Science, 21(3), 239-260.

Gorsevski, P.V., Brown, M.K., Panter, K., Onasch, C.M., Simic, A., Snyder, J. (2016): Landslide detection and susceptibility mapping using LiDAR and an artificial neural network approach: a case study in the Cuyahoga Valley National Park, Ohio. Landslides, 13(3), 467–484.

Generalni urbanistički plan grada Zagreba, GUP (2016) URL: http://www.zagreb.hr/odluka-o-donosenju-generalnoga-urbanistickog-plana/89158 (zadnji pristup: 20. travnja 2019.)

Green, D.M., Swets, J.A. (1966): Signal Detection Theory and Psychophysics. Oxford, England: John Wiley, 455 str.

Grizelj, A. (2008): Mineraloške i geokemijske značajke miocenskih pelitnih sedimenata jugozapadnog dijela Panonskog bazena. Doktorska disertacija. Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb.

Guisan, A., Weiss, S.B., and Weiss, A.D. (1999): GLM versus CCA spatial modeling of plant species distribution. Plant Ecology, 143, 107–122.

Guzzetti, F., Carrara, A., Cardinali, M., Reichenbach, P. (1999): Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, Central Italy. Geomorphology, 31(1–4), 181–216.

Guzzetti, F., Cardinali, M., Reichenbach, P., Carrara, A. (2000): Comparing landslide maps: a case study in the upper Tiber River Basin, Central Italy. Environmental Management, 25 (3), 247–363.

Guzzetti, F., Galli, M., Reichenbach, P., Ardizzone, F., Cardinali, M. (2005): Landslide hazard assessment in the Collazzone area, Umbria, Central Italy. Natural hazards and earth system sciences, 6, 115–131.

Guzzetti, F., Mondini, A.C., Cardinali, M., Fiorucci, F., Santangelo, M., Chang, K.T. (2012): Landslide inventory maps: new tools for an old problem. Earth-Science Reviews, 112, 42–66.

Guzzetti, F., Reichenbach, P., Ardizzone, F., Cardinali, M., Galli, M. (2006): Estimating the quality of landslide susceptibility models. Geomorphology, 81(1–2), 166–184.

Hansen, A. (1984): Strategies for classification of landslides. U: Brunsden, D., Prior, D.B. (ur.): Slope Instability. Wiley, New York, 523–602.

Haugerud, R.A., Harding, D.J., Johnson, S.Y., Harless, J.L., Weaver, C.S., Sherrod, B.L. (2003): High-resolution LiDAR topography of the Puget Lowland, Washington - a bonanza for earth science. GSA Today, 13, 4–10.

Hengl, T. (2006): Finding the right pixel size. Computers and Geosciences, 32(9), 1283-1298.

Heritage, G.L., Milan, D.J., Large, A.R.G., Fuller, I.C. (2009): Influence of survey strategy and interpolation model on DEM quality. Geomorphology, 112, 334–344.

Highland, L.M., and Bobrowsky P. (2008): The landslide handbook - A guide to understanding landslides. Reston, Virginia, U.S. Geological Survey Circular 1325, 129.

Hölbling, D., Friedl, B., Eisank, C. (2015): An object-based approach for semi-automated landslide change detection and attribution of changes to landslide classes in northern Taiwan. Earth Science Informatics, 8, 327-335.

Hungr, O., Evans, S.G., Bovis, M.J., Hutchnison, N.J. (2001): A review of the classification of landslides of the flow type. Environmental and Engineering Geoscience 7, 3, 221–238.

Hungr, O., Leroueil, S., Picarelli, L. (2014): The Varnes classification of landslide types, an update. Landslides, 11, 167-194.

Hussain, M., Chen, D., Cheng, A., Wei, H., Stanley, D. (2013): Change detection from remotely sensed images: From pixel-based to object-based approaches. ISPRS Journal of Photogrammetry and Remote Sensing, 80, 91-106.

Hutchinson, M.F. (1989): A new procedure for gridding elevation and stream line data with automatic removal of spurious pits. Journal of Hydrology, 106, 211-232.

IGU, *International Geographical Union* (1968) The unified key to the detailed geomorphologial map of the world, 1: 25.000 – 1: 50.000. Folia geografica, series geographica-physica 2, Krakow.

Izmjene i dopune Generalnog urbanističkog plana grada Zagreba, GUP (2017) URL: https://www.zagreb.hr/izmjene-i-dopune-generalnog-urbanistickog-plana-gr/89159 (zadnji pristup: 20. travnja 2019.)

Jaboyedoff, M.,Choffet, M., Derron, M.H., Horton, P., Loye, A., Longchamp, C., Mazotti, B., Michoud, C., Pedrazzini, A. (2012): Preliminary Slope Mass Movement Susceptibility Mapping Using DEM and LiDAR DEM. Terrigenous Mass Movements, 109-170.

Jenness, J. S. (2004): Calculating landscape surface area from digital elevation models. Wildlife Society Bulletin, 32(3), 829-839.

Jenness, J. (2007): Some Thoughts on Analyzing Topographic Habitat Characteristics. URL: http://www.jennessent.com/downloads/topographic_analysis_online.pdf (zadnji pristup: 20. travnja 2019.)

IPL, *International Program on Landslides* (2013): World report on landslides URL:http://iplhq. org/category/iplhq/world-report-on-landslides/ (zadnji pristup: 20. travnja 2019.).

Jurak, V., Matković, I., Miklin, Ž., Cvijanović, D. (1998): Landslide hazard in the Medvednica submountain area under dynamic conditions. XIth Danube-European Conference on Soil Mechanics And Geotechnical Engineeering, Geotechnical hazards, Poreč, 827-834.

Jurak, V., Mihalić, S. (1995): Zoniranje područja Zagreba na osnovne geotehničke sredine. Priopćenja 2. Savjetovanja HDMTT-a, Geotehnički problemi u urbanim sredinama, Knjiga 1, Varaždin, 429-439.

Jurak, V., Ortolan, Ž., Ivšić, T., Herak, M., Šumanovac, F., Vukelić, I., Jukić, M., Šurina, Z. (2008): Geotehničko i seizmičko mikrozoniranje grada Zagreba – pokušaji i ostvarenje. Zbornik radova s konferencije razvitak Zagreba, Zagreb, 99-108.

Kasai, M., Ikeda, M., Asahina, T., Fujisawa, K. (2009): LiDAR-derived DEM evaluation of deep-seated landslides in a steep and rocky region of Japan. Geomorphology, 113, 57–69.

Kienholz, H. (1978): Map of geomorphology and natural hazards of Grindelwald, Switzerland, scale 1:10,000. Arctic, Antarctic, and Alpine Research, 10, 169–184.

Kleijnen, J.P. (2007): Kriging metamodeling in simulation: A review. European Journal of Operational Research, 192(3), 707-716.

Kovačić, M. (2004): Sedimentologija gornjomiocenskih naslaga jugozapadnog dijela Panonskog bazena. Doktorska disertacija. Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb.

Kobler, A., Pfeifer, N., Ogrinc, P., Todorovski, L., Oštir, K., Džeroski, S. (2007): Repetitive interpolation: A robust algorithm for DMT generation from Aerial Laser Scanner Data in forested terrain, Remote Sensing of Environment, 108(1), 9-23.

Komac, M. (2006): A landslide susceptibility model using the Analytical Hierarchy Process method and multivariate statistics in perialpine Slovenia. Geomorphology, 74(1-4), 17-28.

Komac, M. (2012): Regional landslide susceptibility model using the Monte Carlo approach– the case of Slovenia. Geological Quarterly, 56(1), 41-54.

Krkač, M., Špoljarić, D., Bernat, S., Mihalić Arbanas, S. (2017): Method for prediction of landslide movements based on random forests. Landslides, 14, 947-960.

Leshchinsky, B.A., Olsen, M.J.. Tanyu, B.F. (2015): Contour Connection Method for automated identification and classification of landslide deposits. Computers &Geosciences, 74, 27-38.

Levin N. (1999): Fundamentals of Remote Sensing. http://geography.huji.ac.il/personal /Noam%20Levin/1999-fundamentals-of-remotesensing.pdf (zadnji pristup: 20. travnja 2019.)

Li, X., Cheng, X., Chen, W., Chen, G., Liu, S. (2015): Identification of Forested Landslides Using LiDAR Data, Object-based Image Analysis, and Machine Learning Algorithms. Remote Sensing, 7, 9705-9726.

Li, J., Heap, A.D. (2008): A Review of Spatial Interpolation Methods for Environmental Scientists, Geoscience Australia, Record 2008/23, Canberra.

Lu, P., Stumpf, A., Kerle, N. Casagli, N. (2011): Object-Oriented Change Detection for Landslide Rapid Mapping. IEEE Geoscience and Remote Sensing Letters, 8(4), 701-705.

Luo, W., Taylor, M.C., Parker, S.R. (2008): A comparison of spatial interpolation methods to estimate continuous wind speed surfaces using irregularly distributed data from England and Wales. International Journal of Climatology, 28 (7), 947-959.

Magdalenić, A. (1966): Regionalna inženjerskogeološka istraživanja Zagreba i šire okolice. Knjiga I, Institut za geološka istraživanja, Zagreb, 59 str.

Magyar I., Geary D.H. (2012): Biostratigraphy in a late neogene caspian type Lacustrine basin: Lake Pannon, Hungary. U: Baganz O.W., Bartov Y., Bohacs K., Nummedal D. (ur.): Lacustrine sandstone reservoirs and hydrocarbon systems, AAPG Memoire, 95, 255-264.

Magyar, I., Geary, D.H., Muller, P. (1999): Paleogeographic in late Neogene Caspian – Type Lacrustine Basin: Pannon in Central Europe. Paleogeography, Paleoclimatology, Paleoecology, 147, 151-167.

Malamud, B.D., Turcotte, D.L., Guzzetti, F., Reichenbach, P. (2004): Landslide inventories and their statistical properties. Earth Surface Processes and Landforms, 29, 687–711.

Malik, I., Wistuba, M. (2012): Dendrochronological methods for reconstructing mass movements — An example of landslide activity analysis using tree-ring eccentricity. Geochronometria, 39 (3), 180-196.

Malvić, T. (2008): Primjena geostatistike u analizi geoloških podataka, Udžbenici Sveučilišta u Zagrebu, INA-Industrija nafte d.d., Zagreb, 99 str.

Malvić, T., Gaćeša, S. (2006): Geostatistika u opisivanju ležišta ugljikovodika, INA – industrija nafte. URL: http://bib.irb.hr/datoteka/382718.UVODNI.pdf (zadnji pristup: 20. travnja 2019.).

Mandić, O., Kurečić, T., Neubauer, T.A., Harzhauser, M. (2015): Stratigraphic and palaeogeographic significance of lacustrine molluscs from the Pliocene Viviparus bed sin Central Croatia. Geologia Croatica, 68/3, 197-297.

Martha, T.R., Kerle, N., Jetten, V., van Westen, C.J., Kumar, K.V. (2010): Characterising spectral, spatial and morphometric properties of landslides for semi-automatic detection using object-oriented methods. Geomoprhology, 116, 24-36.

Matenco, L., Radivojević, D. (2012): On the formation and evolution of the Pannonian Basin: Constraints derived from the structure of the junction area between the Carpathians and Dinarides. Tectonics, 31(6), 1-31.

Maune, D.F. (2007): Digital Elevation Model Technologies and Applications: The DEM Users Manual. American Society for Photogrammetry and Remote Sensing Bethesda, Maryland, USA, 539 str.

McCalpin, J. (1984): Preliminary age classification of landslides for inventory mapping. Proceedings 21st annual Engineering Geology and Soils Engineering Symposium, University Press, Moscow, Idaho, 99–111.

McCune, B., and D. Keon (2002) Equations for potential annual direct incident radiation and heat load index. Journal of Vegetation Science, 13, 603-606.

McKean, J., Roering, J. (2004): Objective landslide detection and surface morphology mapping using high-resolution airborne laser altimetry. Geomorphology, 57, 331-351.

McKenna, J.P., Lidke, D.J., Coe, J.A. (2008): Landslides Mapped from LIDAR Imagery, Kitsap County, Washington. Open –File Report 2008-1292, U.S. Department oft he Interior, U.S. Geological Survey, Reston, Virginia. URL: https://pubs.usgs.gov/of/2008/1292/downloads /OF08-1292.pdf (zadnji pristup: 20. travnja 2019.).

Medak, D., Pribičević, B., Krivorucho, K. (2008): Geostatistička analiza batimetrijskih mjerenja na primjeru jezera Kozjak. Geodetski list, 62(85), 131-142.

Medved, I., Pribičević, B., Medak, D., Kuzmanić, I. (2010): Usporedba metoda interpolacije batimetrijskih mjerenja za praćenje promjena volumena jezera. Geodetski list, 68(2), 71-86.

Metternicht, G., Hurni, L., Gogu, R. (2005): Remote sensing of landslides: an analysis of the potential contribution to geo-spatial systems for hazard assessment in mountain environments. Remote Sensing of Environment, 98, 284–303.

Mihalić, S. (1998): Recommendations for Landslide Hazard and Risk Mapping in Croatia. Geologia Croatica, 51(2); 195-204.

Mihalić, S., Marui, H., Nagai, O., Yagi, H., Miyagi, T. (2013): Landslide Inventory in the Area of Zagreb City: Effectiveness of Using LiDAR DEM. U: Margottini, C., Sassa K. (ur.): Proceedings of the 2nd World Landslide Forum 'Landslide Science and Practice'. Njemačka, Springer, 155-162.

Mihalić, S., Arbanas, Ž. (2013): The Croatian–Japanese joint research project on landslides: activities and public benefits. U: Sassa K., Rouhban B., Briceño S., McSaveney M., He B. (ur.) Landslides: global risk preparedness, Springer, Heidelberg. 333–349.

Mihalić, S., Marui, H., Nagai, O., Yagi, H., Miyagi, T. (2013): Landslide inventory in the area of Zagreb City: Effectiveness of using LiDAR DEM. Proceedings of the 2nd World Landslide Forum 'Landslide Science and Practice', Vol. 1, Heidelberg, Germany: Springer, 155-162.

Mihalić Arbanas, S., Arbanas, Ž. (2014): Landslide mapping and monitoring: Review of conventional and advanced techniques. U: Šešov, V.. (ur.): Proceedings of the 4th Symposium of Macedonian Association for Geotechnics, Jofi Sken, Skopje, 57-72.

Mihalić Arbanas, S., Krkač, M., Bernat, S., Arbanas, Ž. (2012): Use of existing data in the City of Zagreb (Croatia, Europe) for the purpose of geo-planning. U: Zhou Y., Cai J., Sterling R. (ur.): Proceedings of the Advances in Underground Space Development of the 13th World Conference of ACUUS 07-09.11.2012 Singapore, Singapore, Research Publishing, 465-477.

Mihalić Arbanas, S., Krkač, M., Bernat, S. (2016): Application of advanced technologies in landslide research in the area of the City of Zagreb (Croatia, Europe). Geologia Croatica, 69(2), 231–243.

Mihalić Arbanas, S., Bernat Gazibara, S., Cindrić Kalin, K., Arbanas, Ž. (2018): Procjena rizika od klizanja Republike Hrvatske. Studija izrađena na Rudarsko-geološko-naftnom fakultetu, Sveučilišta u Zagrebu, 31 str.

Miklin, Ž., Mlinar, Ž., Brkić, Ž., Hećimović, I., Dolić, M. (2007): Detaljna inženjerskogeološka karta Podsljemenske urbanizirane zone u mjerilu 1:5.000 (DIGK-Faza I). Hrvatski geološki institut, Zagreb, Knjige 1-4, 44 priloga.

Miklin, Ž., Podolszki, L., Martinčević, J. (2012): Geological and engineering-geological investigations in Brodsko brdo area. U: Knežević, M., Ščepanović, B. (ur.): Četvrti Internacionalni naučno-stručni skup Građevinarstvo-Nauka i praksa - Zbornik radova, Centralna Narodna Biblioteka Crne Gore, 2079-2084.

Miner, A., Flentje, P., Mazengarb, C., Windle, C.J. (2010): Landslide Recognition using LiDAR derived Digital Elevation Models-Lessons learnt from selected Australian examples. URL: http://ro.uow.edu.au/cgi/viewcontent.cgi?article=1590&context=engpapers (zadnji pristup: 20. travnja 2019.).

Mitas, L., Mitasova, H. (1999): Spatial Interpolation. U: Longley P., Goodchild M. F., Maguire D.J., Rhind D.W.): Geographical Information Systems: Principles, Techniques, Management and Applications (Second edition), Wiley, Chichester, 481-492.

Montealegre, A.L., Lamelas, M.T., de la Riva J. (2015): A comparison of open-source LiDAR filtering algorithms in a Mediterranean forest environment. IEEE journal of selected topics in applied earth observations and remote sensing, 8(8), 4072-4085.

Moore, I.D., Gessler, P.E., Nielsen, G.A., Petersen, G.A. (1993): Terrain attributes: estimation methods and scale effects. U: Jakeman, A.J., Beck, M.B., McAleer, M. (ur.): Modeling Change in Environmental Systems, Wiley , London, 189 - 214.

Nellemann, C., Fry, G. (1995): Quantitative analyses of terrain ruggedness in reindeer winter grounds. Arctic, 48, 172-176.

Neuhäuser, B., Damm, B., Terhorst, B. (2012): GIS-based assessment of landslide susceptibility on the base of the Weights-of-Evidence model. Landslides, 9, 511-528.

Paine, D.P., Kiser, J.D. (2012): Aerial Photography and Image Interpretation, Third Edition. John Wiley & Sons, Inc. Hoboken, New Jersey, 637.

Palenzuela, J.A., Marsella, M., Nardinocchi, C., Pérez, J.L., Fernández, T., Chacón J., Irigaray, C. (2015): Landslide detection and inventory by integrating LiDAR data in a GIS environment. Landlides, 12(6), 1035–1050.

Pašek, J. (1975): Landslide inventory. International Association Engineering Geologist Bulletin, 12, 73–74.

Pavlek, K. (2016): Primjena GIS tehnologije i daljinskih istraživanja u analizi promjene zemljišnog pokrova. Završni rad. Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geografski odsjek.

Pavelić, D. (2002): Tectonostratigraphic Model for the North Croatian and North Bosnian sector of the Miocene Pannonian Basin. Basin research., 3, 359-376.

Pawluszek, K., Borkowski, A. (2016): Landslides identification using airborne laser scanning data derived topographic terrain attributes and support vector machine classification. U: Halounova, L., Šafář, V., Toth, C. K., Karas, J., Huadong, G., Haala, N., Habib, A., Reinartz, P., Tang, X., Li, J., Armenakis, C., Grenzdörffer, G., le Roux, P., Stylianidis, S., Blasi, R., Menard, M., Dufourmount, H., Li, Z. (ur.): The international archives of the photogrammetry, remote sensing and spatial information sciences-XXIII ISPRS congress, Prague, Czech Republic, 12–19.

Pawluszek, K. (2018): Landslide features identification and morphology investigation using high‐resolution DEM derivatives. Natural Hazards. DOI:10.1007/s11069-018-3543-1

Petschko, H., Bell, R., Leopold, P.(2013): Landslide inventories for reliable susceptibility maps in Lower Austria. U: Margottini C, Canuti P, Sassa K (ur.): Landslide Science and Practice, Springer, 281–286.

Petschko, H., Bell, R., Glade, T. (2015): Effectiveness of visually analyzing LiDAR DMT derivatives for earth and debris slide inventory mapping for statistical susceptibility modeling. Landslides, 13(5), 857–872.

Podolzski, L. (2014) Stereoskopska analiza klizišta i relativne opasnosti od klizanja na južnim obroncima Medvednice. Doktorska disertacija. Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet. Zagreb

Polak, K., Klemar, M., Nejkova, M., Radošević, N., Stepan, Z., Miroslav, M., Križanić, Z. (1979): Litološka obrada i kategorizacija terena prema stabilnosti tla obronaka Medvednice na području grada Zagreba. Geotehnika-Geoexpert, Zagreb, 102.

Popescu, M.E. (2002): Landslide casusal factors and landslide remediatial options. Proceedings of 3rd international conference on landslides, slope stability and safety of Infrastructures, Singapure, 61-81.

Pribičević, B., Medak, D., Kordić, B. (2007): Primjena dvofrekventne batimetrije u određivanju sedrenih naslaga, Geodetski list, 1, 1-18.

Rau, J.Y., Chang, K.T., Shao, Y.C., Lau, C.C. (2012): Semi-automatic shallow landslide detection by the integration of airborne imagery and laser scanning data. Natural Hazards, 61, 469-480.

Razak, K.A., Straatsma, M.W., van Westen, C.J., Malet, J.-P., de Jong, S.M. (2011): Airborne laser scanning of forested landslides characterization: terrain model quality and visualization. Geomorphology, 126, 186–200.

Razak, K.A., Santangelo, M., Van Westen, C.J., Straatsma, M.W., de Jong, S.M. (2013): Generating an optimal DMT from airborne laser scanning data for landslide mapping in a tropical forest environment. Geomorphology, 190, 112-125.

Reichenbach, P., Guzzetti, F., Cardinali, M. (1998): Map of sites historically affected by landslides and floods in Italy, 2nd edition. CNR, Gruppo Nazionale per la Difesa dalle Catastrofi Idrogeologiche, Publication n. 1786, scale 1:1,200,000.

Riley, S.J., DeGloria, S.D., Elliot, R. (1999): A terrain ruggedness index that quantifies topographic heterogeneity. Intermountain Journal of Sciences, 5, 1-4.

Roberts, D. W., Cooper, S. V. (1989): Concepts and techniques of vegetation mapping. In Land Classifications Based on Vegetation: Applications for Resource Management. USDA Forest Service GTR INT-257, Ogden, UT, 90-96.

Rögl, F. (1988): Paleogeographic considerations for Mediterranian and Parathetys Oligocene and Miocene. Mitteilungen Ges. Geol. Bergbaustudenten, 41, 65-73.

Rossiter, D.G. (2003): Methodology for Soil Resource Inventories, 3rd ed. ITC Lecture Notes SOL.27. ITC, Enschede, The Netherlands, 110.

Royden, L.H. (1988): Late Cenozoik tectonics of the Pannonian Basin System. U: Royden L.H., Horvtah F. (ur.): The Pannonian Basin, AAPG Memoire, SAD.

Sabto, M. (1991): Probabilistic modelling applied to landslides in central Colombia using GIS procedures. Unpublished Msc. Thesis, ITC, Enschede, Netherlands, 26.

Salvati, P., Balducci, V., Bianchi, C., Guzzetti, F., Tonelli, G. (2009): A WebGIS for the dissemination of information on historical landslides and floods in Umbria, Italy. GeoInformatica, 13, 305–322.

Santangelo, M., Cardinali, M., Rossi, M., Mondini, A.C., Guzzetti, F. (2010): Remote landslide mapping using a laser rangefinder binocular and GPS. Natural Hazards and Earth System Sciences, 10, 2539–2546.

Scaioni, M., Longoni, L., Melillo, V., Papini, M. (2014): Remote Sensing for Landslide Investigations: An Overview of Recent Achievements and Perspectives. Remote Sensing, 6, 1-53.

Schulz, W.H. (2004): Landslides mapped using LIDAR imagery, Seattle, Washington. US Geol. Surv. Open-File Rep. 1396:11.

http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.593.1380&rep=rep1&type=pdf (zadnji pristup: 20. travnja 2019.).

Schulz, W.H. (2007): Landslide susceptibility revealed by LIDAR imagery and historical records, Seattle, Washington. Engineering Geology, 89, 67-87.

Shannon, C.E. (1949): Communication in the presence of noise. Proceedings of the Institute of Radio Engineers, 37 (1), 10–21.

Singhroy, V. (2005): Remote sensing of landslides. U: Glade T., Anderson M., Crozier M.J. (ur.): Landslide Hazard and Risk, John Wiley and Sons Ltd., West Sussex, England, 469–492.

Simon, N., De Roiste, M., Crozier, M.. Rafek, A.G. (2017): Representing Landslides as Polygon (Areal) or Points? How Different Data Types Influence the Accuracy of Landslide Susceptibility Maps. Sains Malaysiana, 46(1), 27–34.

Skøien, J.O., Merz, R., Bloschl, G. (2005): Top-kriging – geostatistics on stream Networks. Hydrology and Earth System Sciences, 2, 2253-2286.

Slaughter, S.L., Burns, W.J., Mickelson, K.A., Jacobacci, K.E., Biel, A., Contreras, T.A. (2017): Protocol for landslide inventory mapping from LiDAR data in Washington State. Washington Geological Survey, Bulletin 82., 35.

Soeters. R., van Westen. C.J. (1996): Slope instability recognition, analysis and zonation. U: Turner, A.K., Schuster, R.L. (ur.): Landslides investigation and mitigation. TRB Special Report 247. National Academy Press, Washington, DC, 129–177.

Stage, A. R. (1976): An Expression of the Effects of Aspect, Slope, and Habitat Type on Tree Growth. Forest Science, 22(3), 457-460.

Šikić, V. (1967): Inženjerska geologija Zagreb – sjever i jug. Institut za geološka istraživanja, Zagreb, 152.

Šikić, K. (1995): Geološki vodič Medvednice. Institut za geološka istraživanja, INA-Industrija nafte d.d., Zagreb.

Šikić, K., Basch, O., Šimunić, A. (1972): Osnovna geološka karta, List Zagreb, M 1:100.000. Geološki zavod Zagreb.

Šikić, K., Basch, O., Šimunić, A. (1979): Tumač za Osnovnu geološku kartu, List Zagreb. Geološki zavod Zagreb.

Šikić, V., Urumović, K. (1968): Regionalna inženjerskogeološka istraživanja Zagreba i šire okolice. Institut za geološka istraživanja, Zagreb, 131.

Tarolli, P., Sofia, G., Fontana, G.D. (2012): Geomorphic features extraction from high-resolution topography: landslide crowns and bank erosion. Natural Hazards, 61, 65–83.

Toševski, A. (2018): Podložnost porječja rijeke Dubračine površinskim geodinamičkim procesima. Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet. Dokstorski rad, 251 str.

Van Den Eeckhaut, M., Poesen, J., Verstraeten, G., Vanacker, V., Moeyersons, J., Nyssen, J. & van Beek, L.P.H. (2005): The effectiveness of hillshade maps and expert knowledge in mapping old deep – seated landslides. Geomorphology, 67, 351-363.

Van Den Eeckhaut, M., Poesen, J., Verstraeten, G., Vanacker, V., Moeyersons, J., Nyssen, J., van Beek, L.P.H, Vandekerckhove L. (2007): Use of LIDAR-derived images for mapping old landslides under forest. Earth Surface Processes and landforms, 32, 754-769.

Van Den Eeckhaut, M., Kerle, N., Poesen, J., Hervás, J. (2012): Object-oriented identification of forested landslides with derivatives of single pulse LiDAR data. Geomorphology, 173–174, 30-42.

van Schalkwyk, A., Thomas, M.A. (1991): Slope failures associated with the floods of September 1987 and February 1988 in Natal and Kwa-Zulu, Republic of South Africa. U: Blight et al. (ur.): Geotechnics in the African Environment, 57-63.

van Westen, C.J. (2002): Use of weights of evidence modeling for landslide susceptibility mapping. ITC Publication, 21 str.

van Westen, C.J., van Duren, I., Kruse, H.M.G., Terlien, M.T.J. (1993): Training Package for Geographic Information Systems in Slope Stability Zonation, Part 1: Theory. ITC Publication, Eeschede, Nizozemska. 245 str.

van Westen, C.J., Van Asch, T.W.J., Soeters, R. (2005): Landslide hazard and risk zonation; why is it still so difficult? Bulletin of Engineering geology and the Environment 65 (2), 167–184.

van Westen, C.J., Castellanos, E., Kuriakose, S.L. (2008): Spatial data for landslide susceptibility, hazard, and vulnerability assessment: an overview. Engineering Geology, 102, 112–131.

Varnes, D.J. (1978): Slope movements, type and processes. U: Schuster R.L., Krizek R.J. (ur.): Landslide Analysis and Control, Transportation Research Board, Special Report 176. National Academy of Sciences, Washington, 11–33.

Varnes, D.J., the IAEG Commission on Landslides and other Mass-Movements (1984): Landslide hazard zonation: a review of principles and practice. The UNESCO Press, Paris, 63.

Vink, A. (1975): Land Use in Advancing Agriculture, vol. X. Springer, New York, NY, 394 str.

Višić, M. (2012): Upotreba zajednice teških minerala u interpretaciji modela klizišta Črešnjevac na južnim obroncima. Diplomski rad. Sveučilište u Zagrebu. Prirodoslovno-matematički fakultet, Zagreb.

Vosselman, G. (2000): Slope based filtering of laser altimetry data. International Archives of Photogrammetry. Remote Sensing and Spatial Information Sciences, 33 (B3/2), 935-942.

Vrsaljko, D., Pavelić, D., Miknić, M., Brkić, M., Kovačić, M., Hećimović, I., Hajek-Tadesse V., Avanić R. Kurtanjek N. (2006): Middle Miocene (Upper Badenian/Sarmatian) Palaeoecology and Evolution of the Environments in the Area of Medvednica Mt. (North Croatia). Geologia Croatica, 59/1, 51-63.

Wehr, A., Luhr, U. (1999): Airborne laser scanning—an introduction and overview, ISPRS Journal of Photogrammetry & Remote Sensing 54, 68-82.

Wong, H.N., Ho, K.K.S. (1998): Overview of risk of old man-made slopes and retaining walls in Hong Kong. U: Li, K.S., Kay, Ho, K.K.S. (ur.): Proceedings of the Seminar on Slope Engineering in Hong Kong. A.A. Balkema, Hong Kong, 193–200.

WP/WLI, *International Geotechnical Society's UNESCO Working Party on World Landslide Inventory* (1990): A suggested method for reporting a landslide. Bull Inter Assoc Eng Geol, 41, 5–12

WP/WLI, *International Geotechnical Society's UNESCO Working Party on World Landslide Inventory* (1991): A suggested method for a landslide summary. Bull Intern Assoc Eng Geol , 43, 101–110.

WP/WLI, *International Geotechnical Society's UNESCO Working Party on World Landslide Inventory* (1993a): A suggested method for describing the activity of a landslide. Bull Intern Assoc Eng Geol, 47, 53–57.

WP/WLI, *International Geotechnical Society's UNESCO Working Party on World Landslide Inventory* (1993b): A multi-lingual landslide glossary. Bitech Publishers, Vancouver, 59.

WP/WLI, *International Geotechnical Society's UNESCO Working Party on World Landslide Inventory* (1994) A suggested method for describing the causes of a landslide. Bull Intern Assoc Eng Geol, 50, 71–74.

WP/WLI, *International Geotechnical Society's UNESCO Working Party on World Landslide Inventory* (1995): A suggested method for describing the rate of movement of a landslide. Bull Inter Assoc Eng Geol, 52, 75–78.

Wieczorek, G.F. (1984): Preparing a detailed landslide-inventory map for hazard evaluation and reduction. Bulletin of the Association of Engineering Geologists, 21 (3), 337–342.

Zaninović, K., Gajić-Čapka, M., Perčec Tadić, M. et al. (2008): Klimatski atlas Hrvatske 1961–1990., 1971–2000. Državni hidrometeorološki zavod, Zagreb, 200.

WEB izvori:

https://geoportal.dgu.hr/, Geoportal Državne geodetske uprave Republike Hrvatske (zadnji pristup: 20. travnja 2019.).

https://geoportal.zagreb.hr/karta, GeoPortal Zagrebačke infrastrukture prostornih podataka (zadnji pristup: 20. travnja 2019.)

ŽIVOTOPIS AUTORA

Sanja Bernat Gazibara rođena je 24.11.1987. godine u Kutini. Pohađala je osnovnu školu „Vladimira Vidrića“ i prirodoslovno-matematičku gimnaziju „Tin Ujević“ u Kutini. Preddiplomski studij Geološkog inženjerstva na Rudarsko-geološko-naftnom fakultetu Sveučilišta u Zagrebu upisuje 2006. godine, a diplomski studij Geološkog inženjerstva, smjer Hidrogeologija i inženjerska geologija 2009. godine. Diplomu magistre inženjerke geološkog inženjerstva stječe u srpnju 2011. godine obranom diplomskog rada pod nazivom „Inženjerskogeološki model klizišta Juradi u Istri“ izrađenog pod mentorstvom prof. dr. sc. Snježane Mihalić Arbanas.

Od srpnja 2013. godine zaposlena je na Rudarsko-geološko-naftnom fakultetu Sveučilišta u Zagrebu kao znanstvena novakinja na Zavodu za geologiju i geološko inženjerstvo. Poslijediplomski doktorski studij na Rudarsko-geološko-naftnom fakultetu, smjer Geološko inženjerstvo, upisuje 2014. godine. Tijekom poslijediplomskog studija usavršavala se na međunarodnoj ljetnoj školi LARAM (International school on Landslide Risk Assessment and Mitigation) Sveučilišta u Salernu (Italija) u trajanju od dva tjedna.

Do sada je sudjelovala na dva znanstvena projekta. Od 2011. do 2014. godine na međunarodnom bilateralnom hrvatsko-japanskom projektu „Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje nepogoda kod odrona zemlje i poplava u Hrvatskoj“ kao član Radne grupe 3 za kartiranje hazarda i primjenu u prostornom planiranju. U sklopu hrvatsko-japanskog projekta nabavljeni su LiDAR podaci koje koristi prilikom izrade svog doktorskog rada pod nazivom „Metodologija izrade karata klizišta korištenjem digitalnoga modela terena visoke rezolucije u podsljemenskoj zoni Grada Zagreba“. Od 2016. do 2018. godine član je bilateralnog hrvatsko-austrijskog projekta pod nazivom „Mineralogija glina pri procjeni opasnosti od klizanja“.

U koautorstvu je objavila 45 znanstvenih radova od kojih je većina na temu kartiranja klizišta primjenom daljinskih metoda istraživanja te analiza oborinskih uvjeta koji iniciraju pojavu velikog broja klizišta. Sudjelovala je na brojnim domaćim i međunarodnim znanstvenim skupovima na kojima je imala ukupno osam izlaganja te u organizaciji međunarodnog znanstvenog skupa pod nazivom „1. Regionalni simpozij o klizištima u Jadransko-Balkanskoj regiji“ održanog u Zagrebu 2013. godine. Od 2011. godine članica je Hrvatske grupe za klizišta koja je proglašena Svjetskim centrom izvrsnosti za smanjenje rizika od klizišta za razdoblje 2014.-2017. i 2017.-2020. godine od strane Međunarodnog konzorcija za klizišta (ICL). Također, od 2011. godine članica je Hrvatskog geološkog društva (HGD), Međunarodnog društva za inženjersku geologiju (IAEG), Hrvatskog geotehničkog društva (HGD), Međunarodnog društva za mehaniku stijena (ISRM) i Međunarodnog društva za mehaniku tla i geotehničko inženjerstvo (ISSMGE).

POPIS OBJAVLJENIH RADOVA

Poglavlja u knjigama

Krkač, M., Špoljarić, D., Bernat Gazibara, S., Mihalić Arbanas, S. (2018): TXT-tool 4.385-1.1: Method for Prediction of Landslide Movements Based on Random Forests. U: Sassa, K., Guzzetti, F., Yamagishi, H., Arbanas, Ž., Casagli, N., McSaveney, M., Dang, K. (ur.): Landslide Dynamics: ISDR-ICL Landslide Interactive Teaching Tools. Volume 1: Fundamentals, Mapping and Monitoring. Cham, Springer, 575-597.

Mihalić Arbanas, S., Krkač, M., Bernat Gazibara, S., Komac, M., Sečanj, M., Arbanas, Ž. (2018): TXT-tool 2.385-1.1 A Comprehensive Landslide Monitoring System: The Kostanjek Landslide, Croatia. Sassa, K., Guzzetti, F., Yamagishi, H., Arbanas, Ž., Casagli, N., McSaveney, M., Dang, K. (ur.): Landslide Dynamics: ISDR-ICL Landslide Interactive Teaching Tools. Volume 1: Fundamentals, Mapping and Monitoring. Cham, Springer, 449-464.

Izvorni znanstveni radovi i pregledni radovi u CC časopisima

Krkač, M., Špoljarić, D., Bernat, S., Mihalić Arbanas, S. (2017): Method for prediction of landslide movements based on random forests. Landslides, 14 (3), 947-960.

Mihalić Arbanas, S., Sečanj, M., Bernat Gazibara, S., Krkač, M., Begić, H. Džindo, A., Zekan, S., Arbanas, Ž. (2017): Landslides in the Dinarides and Pannonian Basin - from the largest historical and recent landslides in Croatia to catastrophic landslides caused by Cyclone Tamara (2014) in Bosnia and Herzegovina. Landslides, 14 (6), 1861-1876.

Znanstveni radovi u drugim časopisima

Bernat Gazibara, S., Krkač, M., Mihalić Arbanas, S. (2019): Verification of historical landslide inventory maps for the Podsljeme area in the City of Zagreb using LiDAR-based landslide inventory. Rudarsko-geološko-naftni zbornik, 44, 45-58.

Mihalić Arbanas, S., Krkač, M., Bernat, S. (2016): Application of advanced technologies in landslide research in the area of the City of Zagreb (Croatia, Europe). Geologia Croatica 69 (2), 231-243.

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

Arbanas, Ž., Mihalić Arbanas, S., Vivoda, M., Martinović, K., Bernat, S. (2014): Landslide Knowledge Exchange Through the Regional Cooperation in the Adriatic-Balkan Region. U: Sassa, K., Canuti, P., Yin, Y. (ur.): Proceedings of the 3rd World Landslide Forum, Landslide Science for a Safer Geoenvironment, Vol.1 The International Programme on Landslides (IPL). Cham, Springer, 199-208.

Arbanas, Ž., Mihalić Arbanas, S., Sassa, K., Marui, H., Fukuoka, H., Krkač, M., Vivoda Prodan, M., Bernat Gazibara, S., Đomlija, P. (2017): The Croatian-Japanese SATREPS Joint Research Project on Landslides (IPL-161). U: Sassa, Kyoji ; Mikoš, Matjaž ; Yin, Yueping (ur.): Advancing Culture of Living with Landslides. Vol. 1 ISDR-ICL Sendai Partnership 2015-2025. Cham, Springer, 395-409.

Arbanas, Ž., Mihalić Arbanas, S., Vivoda Prodan, M., Peranić, J., Sečanj, M., Bernat Gazibara, S., Krkač, M. (2017): Preliminary Investigations and Numerical Simulations of a Landslide Reactivation. U: Mikoš, Matjaž ; Tiwari, Binod ; Yin, Yueping ; Sassa, Kyoji (ur.): Advancing culture of living with landslides, Vol 2. Advances in Landslide Science. Cham, Springer, 649-657.

Arbanas, Ž., Vivoda, M., Mihalić Arbanas, S., Peranić, J., Sečanj, M., Bernat, S., Krkač, M. (2017): Analysis of a reservoir water level impact on landslide reactivation. U: Abolmasov, B., Marjanović, M., Đurić, U. (ur.): Proceedings of the 2nd Regional Symposium on Landslides in the Adriatic-Balkan Region. Belgrade, University of Belgrade, Faculty of Mining and Geology, C1-C6.

Arbanas, Ž., Vivoda, M., Dugonjić Jovančević, S., Peranić, J., Udovič, D., Bernat Gazibara, S., Krkač, M., Sečanj, M., Mihalić Arbanas, S. (2019): Rockfall Modelling and Rockfall Protection at the Slopes above the City of Omiš, Croatia. U: Miščević, P. (ur.): Proceedings of the ISRM Specialised Conference „Geotechnical challenges in karst“. Split, Hrvatsko geotehničko društvo, 121-126.

Bernat, S., Đomlija, P., Mihalić Arbanas, S. (2014): Slope movements and erosion phenomena in the Dubračina River Basin: A geomorphological approach. U: Mihalić Arbanas, S., Arbanas, Ž. (ur.): Landslide and Flood Hazard Assessment, Proceedings of the 1st Regional Symposium on Landslides in the Adriatic-Balkan Region. Zagreb, Hrvatska grupa za klizišta, 79-84.

Bernat, S., Mihalić Arbanas, S., Krkač, M. (2014): Inventory of precipitation triggered landslides in the winter of 2013 in Zagreb (Croatia, Europe). U: Sassa, K., Canuti, P., Yin, Y. (ur.): Proceedings of the 3rd World Landslide Forum, Landslide Science for a Safer Geoenvironment, Vol. 2: Methods of Landslide Studies. Cham, Springer, 829-836.

Bernat, S., Mihalić Arbanas, S., Krkač, M. (2015): Landslides Triggered in the Continental Part of Croatia by Extreme Precipitation in 2013. U: Lollino, G., Giordan, D., Crosta, G.B., Corominas, J., Azzam, R., Wasowski, J., Sciarra, N. (ur.): Proceedings of the XII IAEG Congress: Engineering Geology for Society and Territory, Vol. 2 Landslide Processes. Heidelberg, Springer, 1599-1603.

Bernat, S., Mihalić Arbanas, S., Krkač, M., Sečanj, M. (2017): Catalog of precipitation events that triggered landslides in northwestern Croatia. U: Abolmasov, B., Marjanović, M., Đurić, U., (ur.); Proceedings of the 2nd Regional Symposium on Landslides in the Adriatic- Balkan Region. Belgrade, University of Belgrade, Faculty of Mining and Geology, 103-107.

Bernat Gazibara, S., Krkač, M., Vlahek, I., Pavlić, K., Begić, H., Zekan, S., Sečanj, M., Mihalić Arbanas, S. (2018): Extreme precipitation events and landslides activation in Croatia and Bosnia and Herzegovina. U: Jemec Auflič, M., Mikoš, M., Verbovšek, T. (ur.): Proceedings of the 3rd Regional Symposium on Landslides in the Adriatic Balkan Region: Advances in Landslide Research. Geological Survey of Slovenia, 19-24, Ljubljana.

Bernat Gazibara, S., Krkač, M., Sečanj, M., Mihalić Arbanas, S. (2017): Identification and mapping of shallow landslides in the City of Zagreb (Croatia) using the LiDAR-based terrain model. U: Mikoš, M., Tiwari, B., Yin, Y., Sassa, K. (ur.): Advancing Culture of Living with Landslides, Vol 2. Advances in Landslide Science. Cham, Springer, 1093-1100.

Đomlija, P., Bernat, S., Mihalić Arbanas, S., Benac, Č. (2014): Landslide inventory in the area of Dubračina River Basin (Croatia). U: Sassa, K., Canuti, P., Yin, Y. (ur.): Landslide Science for a Safer Geoenvironment, Vol. 2: Methods of Landslide Studies. Cham, Springer, 837-842.

Grošić, M., Bernat, S., Arbanas, Ž., Mihalić Arbanas, S., Matjašić, I., Vidović, D. (2014): Instabilities of open pit cut slopes: case studiy from the torine Quarry in Croatia. U: Mihalić Arbanas, S., Arbanas, Ž. (ur.): Landslide and Flood Hazard Assessment, Proceedings of the 1st Regional Symposium on Landslides in the Adriatic-Balkan Region. Zagreb, Hrvatska grupa za klizišta, 153-158.

Krkač, M., Mihalić Arbanas, S., Arbanas, Ž., Bernat, S., Špehar, K., Watanabe, N., Nagai, O., Sassa, K., Marui, H., Furuya, G., Wang, C., Rubinić, J., Matsunami, K. (2014): U: Sassa, K., Canuti, P., Yin, Y. (ur.): Review of Monitoring Parameters of the Kostanjek Landslide (Zagreb, Croatia): Proceedings of the 3rd World Landslide Forum, Landslide Science for a Safer Geoenvironment, Vol. 2: Methods of Landslide Studies. Cham, Springer, 637-645.

Krkač, M., Mihalić Arbanas, S., Arbanas, Ž., Bernat, S., Špehar, K. (2015): The Kostanjek Landslide in the City of Zagreb: Forecasting and Protective Monitoring. U: Lollino, G., Manconi, A., Guzzetti, F., Culshaw, M., Bobrowsky, P., Luino, F. (ur.): Proceedings of the XII IAEG Congress: Engineering Geology for Society and Territory, Vol. 5 Urban Geology, Sustainable Planning and Landscape Exploitation. Heidelberg, Springer, 715-719.

Krkač, M., Mihalić Arbanas, S., Arbanas, Ž., Bernat Gazibara, S., Sečanj, M. (2017): Prediction of the Kostanjek Landslide Movements Based on Monitoring Results Using Random Forests Technique. U: Mikoš, Matjaž ; Arbanas, Željko ; Yin, Yueping ; Sassa, Kyoji (ur.): Advancing Culture of Living with Landslides, Vol. 3, Advances in Landslide Technology. Cham, Springer, 267-275.

Martinčević, J., Mihalić Arbanas, S., Krkač, M., Bernat, S., Miklin, Ž., Podolszki, L. (2014): Mineralogical composition of the Kostanjek landslide sediments and its possible influence on the sliding and swelling processes. U: Mihalić Arbanas, S., Arbanas, Ž. (ur.): Landslide and Flood

Hazard Assessment, Proceedings of the 1st Regional Symposium on Landslides in the Adriatic-Balkan Region. Zagreb, Hrvatska grupa za klizišta, 17-21.

Mihalić Arbanas, S., Krkač, M., Bernat, S., Arbanas, Ž. (2012): Use of existing data in the City of Zagreb (Croatia, Europe) for the purpose of geo-planning. U: Zhou, Y., Cai, J., Sterling, R., (ur.): Advances in underground space development. Singapore, Research Publishing, 465-477.

Mihalić Arbanas, S., Bernat, S., Fabijanović, S., Arbanas, Ž. (2014): Analysis of Historical Landslide Information from the Area of the City of Zagreb and Primorsko-Goranska County. U: Mihalić Arbanas, S., Arbanas, Ž. (ur.): Landslide and Flood Hazard Assessment, Proceedings of the 1st Regional Symposium on Landslides in the Adriatic-Balkan Region. Zagreb, Hrvatska grupa za klizišta, 91-96.

Mihalić Arbanas, S., Arbanas, Ž., Krkač, M., Bernat Gazibara, S., Vivoda Prodan, M., Đomlija, P., Jagodnik, V., Dugonjić Jovančević, S., Sečanj, M., Peranić, J. (2017): Landslide Risk Reduction in Croatia: Scientific research in the framework of the WCoE 2014- 2017, IPL 173, IPL 184, ICL ABN. U: Sassa, K., Mikoš, M., Yin, Y. (ur.): Advancing Culture of Living with Landslides, Vol. 1 ISDR-ICL Sendai Partnership 2015-2025. Cham, Springer, 301-312.

Mihalić Arbanas, S., Sečanj, M., Bernat Gazibara, S., Krkač, M., Arbanas, Ž. (2017): Identification and Mapping of the Valići Lake Landslide (Primorsko-Goranska County, Croatia). U: Abolmasov, B., Marjanović, M., Đurić, U. (ur.): Proceedings of the 2nd Regional Symposium on Landslides in the Adriatic-Balkan Region. Belgrade, Faculty of Mining and Geology, University of Belgrade, 197-202.

Sečanj, M.; Bernat Gazibara, S., Mihalić Arbanas, S., Krkač, M., Martinko, M., Arbanas, Ž. (2018): Identification of potentially unstable rock blocks on the road cut in the Krka National park, Croatia. U: Jemec Auflič, M., Mikoš, M., Verbovšek, T. (ur.): Proceedings of the 3rd Regional Symposium on Landslides in the Adriatic Balkan Region: Advances in Landslide Research. Ljubljana, Geological Survey of Slovenia, 113-118.

Sečanj, M., Mihalić Arbanas, S., Kordić, B., Krkač, M., Bernat Gazibara, S. (2017): Identification of Rock Fall Prone Areas on the Steep Slopes Above the Town of Omiš, Croatia. Mikoš, M., Vilimek, V., Yin, Y., Sassa, K. (ur.): Advancing Culture of Living with Landslides, Vol. 5 Landslides in Different Environments. Cham, Springer, 481-487.

Sečanj, M. Mihalić Arbanas, S., Krkač, M., Bernat Gazibara, M., Arbanas, Ž. (2019): Preliminary rockfall susceptibility assessment of the rock slopes above the Town of Omiš (Croatia). U: Miščević, P. (ur.): Proceedings of the ISRM Specialised Conference „Geotechnical challenges in karst“. Split, Hrvatsko geotehničko društvo, 347-352.

Drugi radovi u zbornicima skupova s recenzijom

Bernat Gazibara, Sanja; Krkač, Martin; Sečanj, Marin; Mihalić Arbanas, S. (2018): Izrada karata klizišta primjenom LiDAR tehnologije. U: Holcinger, N. (ur.): Zbornik radova VII. Konferencije Hrvatske platforme za smanjenje rizika od katastrofa. Zagreb, Državna uprava za zaštitu i spašavanje, 194-200.

Hrastovski, M., Mihalić Arbanas, S., Bernat Gazibara, S., (2018): Identifikacija pokretača urbanih poplava u Gradu Zagrebu kroz analizu vatrogasnih intervencija ispumpavanja i oborinskih događaja u 2013. i 2014. godine. U: Holcinger, N. (ur.): Zbornik radova VII. Konferencije Hrvatske platforme za smanjenje rizika od katastrofa. Zagreb, Državna uprava za zaštitu i spašavanje, 44-50.

Krkač, M., Mihalić Arbanas, S., Arbanas, Ž., Smolčak, N., Špehar, K., Bernat, S. (2013): Primjena rezultata praćenja permanentne GNSS mreže u modeliranju klizišta na primjeru klizišta Kostanjek u Zagrebu. U: Bašić, T., Marjanović, M., (ur.): Zbornik radova 3. CROPOS konferencije. Zagreb, Državna geodetska uprava, Geodetski fakultet Sveučilišta u Zagrebu, Hrvatska komora ovlaštenih inženjera geodezije, 103-110.

Krkač, M., Bernat Gazibara, S., Sečanj, M., Mihalić Arbanas, S. (2018): Praćenje i predviđanje gibanja klizišta. U: Holcinger, N. (ur.): Zbornik radova VII. Konferencije Hrvatske platforme za smanjenje rizika od katastrofa. Zagreb, Državna uprava za zaštitu i spašavanje, 212-219.

Mihalić Arbanas, S., Bernat Gazibara, S., Cindrić Kalin, K., Krkač, M., Sečanj, M., Đomlija, P., Arbanas, Ž. (2018): Analize hazarda i rizika klizanja: iskustva u svijetu i u Hrvatskoj tijekom posljednjih 20 godina. U: Holcinger, N. (ur Zbornik radova VII. Konferencije Hrvatske platforme za smanjenje rizika od katastrofa. Zagreb, Državna uprava za zaštitu i spašavanje, 180-187.

Radovi u zbornicima skupova bez recenzije

Mihalić, S., Bernat, S., Hamasaki, E., Gerber, N. (2012): Historical landslides in the City of Zagreb: landslide distribution analysis and 3D modeling of typical landslides in ADCALC3D. U: Ožanić, N., Arbanas, Ž., Mihalić, S., Marui, H., Dragičević, N., (ur.): Monitoring and analyses for disaster mitigation of landslides, debris flow and floods. Book of proceedings of the 2nd Japanese-Croatian Project Workshop. Rijeka, University of Rijeka, 122-125.

Mihalić Arbanas, S., Arbanas, Ž., Bernat, S., Krkač, M., Kalinić, P., Martinović, K., Fabris, N., Sajko, J., Antolović, A. (2013): U: Perinić, J. (ur.): Upravljanje kriznim situacijama uslijed pokretanja klizišta. Zbornik radova V. konferencije Hrvatske platforme za smanjenje rizika od katastrofa. Zagreb, DUZS, 151-164.

Mihalić Arbanas, S., Krkač, M., Bernat, S., Arbanas, Ž. (2014): Landslide mapping and monitoring in the City of Zagreb (Croatia, Europe). U: Sassa, K., Dang, K. (ur.): Proceedings of the SATREPS Workshop on Landslide Risk Assessment Technology, Kyoto, IPL, 214-226.

Sažeci u zbornicima skupova

Bernat, S., Mihalić Arbanas, S., Krkač, M. (2013): Landslides Triggered in the City of Zagreb in the Winter of 2013. U: Vlastelica, G., Andrić, I., Salvezani, D. (ur.): Book of abstracts - 4th workshop of the Japanese -Croatian project on Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia. Split, University of Split, Faculty of Civil Engineering, Architecture and Geodesy, 65-66.

Bernat Gazibara, S., Mihalić Arbanas, S. (2017): Klizišta u urbanom području Grada Zagreba. U: Marinović, P. (ur.): Urbana utopija - pristupi planiranju urbanih prostora. Zagreb, Udruga studenata geografije Zagreb, 17-17.

Đomlija, P., Bernat, S., Benac, Č., Mihalić Arbanas, S., Zidarić, M. (2013): Overview of Input Data for the Landslide Hazard Analysis in the Dubračina River Basin. U: Vlastelica, G., Andrić, I., Salvezani, D. (ur.): Book of abstracts - 4th workshop of the Japanese -Croatian project on Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia. Split, University of Split, Faculty of Civil Engineering, Architecture and Geodesy, 63-64.

Gradiški, K., Krkač, M., Mihalić Arbanas, S., Bernat, S. (2013): Slope stability analyses of the Kostanjek Landslide for extreme rainfalls in the winter of 2013. U: Vlastelica, G., Andrić, I., Salvezani, D. (ur.): Book of abstracts - 4th workshop of the Japanese -Croatian project on Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia. Split, University of Split, Faculty of Civil Engineering, Architecture and Geodesy, 17-18.

Hrastovski, M., Mihalić Arbanas, S., Bernat Gazibara, S. (2017): Identifikacija pokretača poplava u Gradu Zagrebu i analiza oborinskih događaja 2013. i 2014. godine. U: Marinović, P. (ur.): Urbana utopija - pristupi planiranju urbanih prostora, Zagreb, Udruga studenata geografije Zagreb, 18-18.

Martinčević Lazar, J., Vlastelica, G., Bernat, S., Miklin, Ž., Podolszki, L. (2013): Verification of mineralogical composition of Kostanjek landslide sediments using a visible and near-infrared (VIS-NIR) spectrometer. U: Vlastelica, G., Andrić, I., Salvezani, D. (ur.): Book of abstracts - 4th workshop of the Japanese -Croatian project on Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia. Split, University of Split, Faculty of Civil Engineering, Architecture and Geodesy, 19-20.

Mihalić Arbanas, S., Fabijanović, S., Perković, D., Arbanas, Ž., Bernat, S. (2013): Development of landslide data base conceptual model on the basis of historical landslide data from the City of Zagreb and Primorsko-Goranska County. U: Mihalić Arbanas, S., Arbanas, Ž. (ur.): Abstracts of 1st Regional Symposium on Landslides in the Adriatic-Balkan Region with 3rd Workshop of the Croatian-Japanese Project 'Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia. Zagreb, City of Zagreb, Emergency Management Office, 27-28.