



Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet
Geografski odsjek

Valerija Rossi

TIPOLOGIJA, VREDNOVANJE I ZAŠTITA KRAJOBRAZA GORSKE HRVATSKE

DOKTORSKI RAD

Zagreb, 2026.



Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet
Geografski odsjek

Valerija Rossi

TIPOLOGIJA, VREDNOVANJE I ZAŠTITA KRAJOBRAZA GORSKE HRVATSKE

DOKTORSKI RAD

Mentor: prof.dr.sc. Nenad Buzjak

Zagreb, 2026.



University of Zagreb

Faculty of Science
Department of Geography

Valerija Rossi

MOUNTAINOUS CROATIA LANDSCAPE TYPOLOGY, VALORIZATION AND PROTECTION

DOCTORAL DISSERTATION

Mentor: Nenad Buzjak, PhD, Full Professor

Zagreb, 2026.

ŽIVOTOPIS MENTORA:

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Doktorski rad

TIPOLOGIJA, VREDNOVANJE I ZAŠTITA KRAJOBRAZA GORSKE HRVATSKE

Valerija Rossi

Sveučilišni doktorski studij Geografije: prostor, regija, okoliš, pejzaž

Izvadak: tekst sažetka rada do maksimalno 150 riječi; jezgrovit, vrlo kratak sadržaj cijelog rada; uobičajeno se piše u jednom odlomku

... stranica, ...grafičkih priloga, ... tablica, ...bibliografskih referenci; izvornik na hrvatskom jeziku

Ključne riječi: 4 do 7 riječi

Mentor: Prof.dr.sc. Nenad Buzjak

Povjerenstvo: Prof.dr.sc. Neven Bočić
 Izv.prof.dr.sc. Andrija Krtalić
 Doc.dr.sc. Marin Mićunović

Tema prihvaćena: datum sjednice Senata Sveučilišta u Zagrebu

Rad prihvaćen: datum sjednice Vijeća GO

Datum i vrijeme obrane: datum i vrijeme

Rad je pohranjen u Središnjoj geografskoj knjižnici Sveučilišta u Zagrebu Prirodoslovno-matematičkog fakulteta, Trg Marka Marulića 19/II, Zagreb, Hrvatska, u Nacionalnoj i ssveučilišnoj knjižnici u Zagrebu, Hrvatska te na Sveučilištu u Zagrebu, Hrvatska.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Geography

Doctoral Thesis

**MOUNTAINOUS CROATIA LANDSCAPE TYPOLOGY, VALORIZATION AND
PROTECTION**

Valerija Rossi

Doctoral University Study of Geography: space, region, environment, landscape

Abstract: tekst sažetka rada do maksimalno 150 riječi; jezgrovit, vrlo kratak sadržaj cijelog rada; uobičajeno se piše u jednom odlomku

... pages; ... figures; ... tables; ... references; original in Croatian

Keywords: 4 do 7 riječi

Supervisor: Nenad Buzjak, PhD, Full Professor

Reviewers: Neven Bočić, PhD, Full Professor
Andrija Krtalić, PhD, Associate Professor
Marin Mićunović, PhD, Assistant Professor

Thesis submitted: datum sjednice Senata Sveučilišta u Zagrebu

Thesis accepted: datum sjednice Vijeća GO

Thesis defense: datum i vrijeme

Thesis deposited in Central Geographic Library, University of Zagreb Faculty of Science, Trg Marka Marulića 19/II, Zagreb, Croatia, in National and University Library in Zagreb, Croatia and at the University of Zagreb, Croatia.

SADRŽAJ:

1. UVOD	1
1.1. Predmet i svrha istraživanja.....	3
1.2. Cilj i hipoteze.....	4
1.3. Prostor istraživanja	4
2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA.....	7
2.1. Proučavanje krajobraza u Hrvatskoj	8
2.1.1. Geografski pristup proučavanja krajobraza u RH	14
2.2. Važeće tipologije krajobraza EU	26
2.3. Krajobraz u geokološkim školama u okruženju	27
3. ZAKONODAVNI, STRATEŠKI I PROSTORNO-PLANSKI OKVIR UPRAVLJANJA I ZAŠTITE KRAJOBRAZA	30
3.1. Krajobrazne osnove RH.....	32
4. TEORIJSKA POLAZIŠTA	35
4.1. Pojam i definicija krajobraza	35
4.2. Struktura krajobraza	37
4.2.1. Vertikalna struktura krajobraza	40
4.2.2. Horizontalna struktura krajobraza	40
4.3. Tipologija krajobraza.....	41
4.4. Vrednovanje krajobraza.....	44
4.5. Metrika krajobraza.....	45
5. METODE I MATERIJALI	46
5.1. Izdvajanje područja istraživanja	46
5.2. Daljinska istraživanja	46
5.3. Metrika krajobraza.....	51
5.4. Digitalna analiza reljefa.....	52
5.4.1. Opća geomorfometrija.....	52
5.4.2. Specifična geomorfometrija	52
5.5. Analiza morfogogenetskih tipova reljefa	60
5.6. Tipologija krajobraza.....	60
5.6.1. Vrednovanje krajobraza	66
6. REZULTATI.....	68
6.1. Komponente primarne strukture krajobraza GH	68
6.1.1. Geološka obilježja	68
6.1.2. Hipsometrija	74

6.1.3.	Nagibi	79
6.1.4.	Orijentacija padina	82
6.1.5.	Vertikalna raščlanjenost reljefa	85
6.1.6.	Topographic Position Index (TPI).....	88
6.1.7.	Krške depresije	93
6.1.8.	Speleološki objekti	105
6.1.9.	Proluvijalne plavine.....	112
6.1.10.	Hidrološka obilježja.....	115
6.2.	Sekundarna struktura krajobraza GH	122
6.2.1.	Površinski pokrov.....	122
6.3.	Metrika krajobraza površinskog pokrova GH	136
6.4.	Tipologija krajobraza Gorske Hrvatske– Makro razina	146
6.5.	Tipologija krajobraza GH – mezo razina	150
6.5.1.	Kompleksni krajobrazni gradijenti.....	155
6.6.	Metrika krajobraza GH.....	197
6.7.	Vrednovanje krajobraza GH.....	207
7.	RASPRAVA	210
7.1.	Stanje krajobraza GH.....	210
7.2.	Utjecaj elemenata vertikalne strukture na krajobraz GH.....	214
7.3.	Posebnosti krajobraza GH	220
7.4.	Izdvojena područja značajnih vrijednosti	223
7.5.	Evaluacija rezultata i metodologije istraživanja	231
8.	ZAKLJUČCI.....	237
9.	PRILOZI	243
10.	POPIS LITERATURE I IZVORA	244

1. UVOD

U Hrvatskoj u skladu sa svjetskim trendovima dolazi do sve većih promjena krajobraza uslijed širenja antropogenih utjecaja unutar kojih se posebno ističu aktivnosti povezane s promjenama načina korištenja zemljišta, izmjene zemljišnog pokrova te promjene izazvane klimatskim promjenama. Usporedno s time raste i potreba za intenzivnijim i dubljim poznavanjem obilježja krajobraza u svrhu adekvatne zaštite i upravljanja. S druge strane, krajobraz je višeznačan pojam te se u znanstvenom i stručnom aspektu najčešće doživljava kao estetska i jednodimenzionalna kategorija te je rijetko ili gotovo nikada kvantificiran.

Jedna od posljedica industrijalizacije, intenzivne poljoprivrede i urbanizacije od 18. stoljeća do suvremenoga doba jesu do tada nezabilježene brze promjene krajobraza praćene gubitkom njegova ekološko-funkcionalnoga kapaciteta (u smislu narušavanja usluga ekosustava), prirodne raznolikosti, estetskih vrijednosti te negativna učinka na povijesno vrijedne i funkcionalno bitne kulturne elemente. S druge strane, zahtjevi društva za produktivne, ekološki zdrave, atraktivne i multifunkcionalne krajobrazne zahtijevaju suvremeno promišljanje krajobraza te nove smjerove u planiranju i upravljanju krajobrazima (Bastian i dr., 2006).

Krajobraz kao prostorna jedinica i predmet proučavanja tijekom 19. stoljeća počinje dobivati na značenju u geografskim istraživanjima. A. von Humboldt prvi je na geografskim principima definirao pojam krajobraza kao potpuni i cjeloviti karakter jednoga područja. U svojim biogeografskim radovima postavlja temelje klasificiranja krajobraza i navodi da „svaka zona vegetacije ima svoj karakter te da postoji fizionomija prirode koja je specifična za svaki dio Zemlje” (Kwa, 2005). Razvoj istraživanja krajobraza od A. von Humboldta je prošao više faza, a krajobrazna razina istraživanja, uglavnom unutar regionalne geografije, postaje jedan od temeljnih pristupa u težnji da regionalne studije budu sinteza prirodnih i društvenih značajki prostora. Glavna zamjerka takvu pristupu bila je deskripcija koja je bila rezultat prevladavajućeg horološkog pristupa i težnja da se obuhvate brojne teme. S druge strane, jačanjem krajobrazne arhitekture početkom 20. st. krajobrazi se doživljavaju kroz vizualni doživljaj i simbole. Uslijed snažne degradacija i gubitka tradicionalnih krajobraza početkom 20. st. u zapadnoj Europi jačaju istraživanja usmjerena na njihovo očuvanje (Antrop, 2013). Iako je pred Drugi svjetski rat C. Troll, (1939) upotrebom zračnih fotografija uveo novinu u metodologiju izučavanja krajobraza i u geografiju uveo krajobraznu ekologiju kao novu disciplinu (odnosno geoekologiju koja je krajobrazne jedinice uzela kao temelj prostornih analiza), još je dugo vremena najveći problem u proučavanju krajobraza bila deskriptivnost.

Veće promjene događaju se s uvođenjem informatičkih tehnologija i satelitskih snimaka kao nove metode daljinskih istraživanja. Daljinska istraživanja su omogućila istovremenu prostornu analizu i vizualizaciju velikoga broja parametara, čime je u geografiji otvoren put za istraživanja i na njima utemeljene tipologije koja je usustavila krajobrazne analize. No, izostao je dogovor i jedinstveni sustav nalik tipologiji ekosustava pa različite države na različitim prostornim razinama razvijaju nacionalne tipologije čija je usporedba najčešće vrlo teška (Wascher, 2005). Izradom različitih tipologija koje se stavljaju u usporedbu dolazi i do krivih zaključaka o promjenama u krajobrazu. Kvaliteti istraživanja sasvim sigurno pridonio je interdisciplinarni pristup (Antrop, 2005; Tandarić i dr., 2018). Značajnu ulogu odigrala je potreba za primjenjivim znanjima i vještinama, dobar primjer čega su analize u svrhu proučavanja promjena okoliša s rastom svijesti o okolišnim problemima na globalnoj razini pa se radi potrebe usporedbe razvijaju univerzalne tipologije.

U Firenci je 2000. godine donesena Konvencija o europskim krajobrazima kojom identifikacija, zaštita, upravljanje i planiranje krajobraza dobiva paneuropski značaj i usmjerava fokus na krajobraz kao prostornu jedinicu u istraživanjima, upravljanju i zaštiti. To je njezin veliki pozitivni doprinos. No Konvencija ima i slabosti. U praktičnom smislu, konvencija je postavila obaveze pred države potpisnice, ali bez konkretnog praktičnog okvira za korake koji se nameću kao nužnu. Unatoč obavezi izrade tipologije, nema jasno definiranih kriterija niti indikatora koji bi omogućili usporedbu te praćenje stanja. Krajobraz definira kao prostor kako ga percipiraju ljudi, čije su značajke rezultat međusobnoga djelovanja prirodnih i/ili ljudskih čimbenika (NN 12/2002). Ta je definicija već u vrijeme donošenja bila problematična zbog svoje općenitosti i nedorečenosti, do krajnje mjere banalizirajući temeljnu prostornu kategoriju koja je u geografiji i drugim strukama do tada već kvalitetno definirana i interpretirana (Antrop, 1997). Naime, u okviru holističkih pogleda na svijet (u geografiji proizašlih iz funkcionalnih koncepata usluga ekosustava i krajobraza, zaštite i održivoga upravljanja krajobrazima) te opće krize okoliša (čija je jedna od najčešće upotrebljivanih mjera degradacija bioraznolikosti) stavljanje ljudske percepcije kao temeljnoga mjerila u shvaćanju krajobraza, uz istovremeno isključivanje percepcije i koegzistencije drugih živih bića s kojima dijelimo krajobraz, nešto je što iziskuje temeljitu promjenu u samoj Konvenciji. Iako se ovakav pristup definiranju krajobraza može opravdavati širenjem rasprave o krajobrazima izvan znanstvenih krugova u širu javnost (Erikstad i dr., 2015), on se općenito može ocijeniti kao korak unatrag u odnosu na dotadašnje i suvremene dosege u istraživanjima. Učinkovito praktično upravljanje krajobrazima moguće je samo ako se prema jasno definiranim kriterijima odrede univerzalni

krajobrazni tipovi. Prema njihovim značajkama (elementi, svojstva, stanje, namjena, ugroženost itd.), u cilju održivoga razvoja, potrebno je kreirati smjernice za istraživanje i planiranje te dati jasne upute za državne i regionalne vlasti, vlasnike i korisnike. Na razini političko-teritorijalne rascjepkanosti EU-a s velikim razlikama u pogledima i politikama prema krajobrazima (Wascher, 2005) barem je u širem regionalnom kontekstu potrebno imati zajedničke stavove i mjere. Bez usuglašene tipologije metoda istraživanja i monitoringa po istim kriterijima (Walz, 2015), da bi podatci bili usporedivi, teško je očekivati napredak. No premda nema nikakve pravne snage, Konvencija je ipak doprla do različitih struktura i usmjerila fokus na rastuće probleme (Antrop, 2004) na koje su države odgovarale više ili manje uspješno, ali bez dalekosežnijega učinka i ispunjenih očekivanja .

Definiranje i jedinstvena interpretacija koncepta krajobraza prvi su uvjet za ispravnu analizu i identifikaciju krajobraza te izradu tipologije kao konačnoga cilja. Nakon identifikacije vertikalne strukture krajobraza nužna je identifikacija horizontalne strukture tj. sastava i njihovih međuodnosa. Slijedi vrednovanje koje se odnosi na razvoj, promjene i dinamiku krajobraza. U široj znanstvenoj zajednici ustanovljene su etape u procesu istraživanja krajobraza: i) Izrada tipologije krajobraza, ii) Vrednovanje krajobraza, iii) Modeli upravljanja (Antrop i Van Eetvelde, 2017; Kozová i dr., 2007)

1.1. Predmet i svrha istraživanja

Predmet istraživanja ove disertacije je krajobraz Gorske Hrvatske, identifikacija tipova krajobraza, a potom i kvantifikacija strukture krajobraza. Navedeno je temelj za vrednovanje krajobraza na razini cjeline te daljnje upravljanje i zaštitu izdvojenih tipova.

Svrha istraživanja je znanstvena i pragmatična. Krajobraz u Republici Hrvatskoj, pa tako i u Gorskoj Hrvatskoj višeznačan je pojam koji nije identificiran sa svim svojim sastavnicama i strukturom. Svrha ove doktorske disertacije je definiranje temeljne metodologije za kvantitativno identificiranje krajobraza te njegovo vrednovanje. S druge strane, pragmatična primjena rezultata tipologije i vrednovanja je učinkovito upravljanje krajobrazom te adekvatna zaštita okolišnih vrijednosti krajobraza.

1.2. Cilj i hipoteze

Osnovni ciljevi istraživanja su razvoj metodologije za izradu tipologije, izrada tipologije krajobraza na primjeru Gorske Hrvatske te definiranje krajobraznih indikatora za praćenje stanja krajobraza kao temelja za adekvatnu zaštitu i održivo korištenje krajobraza. Namjera je kroz analizu te izradu tipologije krajobraza naglasiti i definirati ulogu geomorfoloških čimbenika tj. primarne strukture krajobraza u genezi krajobraza Gorske Hrvatske. Izradom metodologije vrednovanja kojom bi se elementi strukture krajobraza kvantificirali te izradom smjernica za zaštitu krajobraza na temelju tipologije i vrednovanja bili bi stvoreni preduvjeti za integraciju fizičkogeografskih značajki prostora u krajobraznu tipologiju te stvoreni preduvjeti za održivo korištenje i zaštitu krajobraza te usluga koje on pruža čovjeku.

Ciljevi istraživanja su:

(1.) izrada geografski utemeljene tipologije krajobraza bazirane na elementima primarne strukture na primjeru Gorske Hrvatske,

(2.) vrednovanje krajobraznih tipova kao temelja za adekvatnu zaštitu i održivo korištenje krajobraza

Horizontalni cilj: jačanje značaja geografskog pristupa analizi krajobraza u sektorima prostornog i strateškog planiranja te zaštitu okoliša.

Utvrđene hipoteze rada su:


H1 Primarna struktura glavna je determinanta tipologije krajobraza na području istraživanja.

H2 Izrada tipologije krajobraza te razvoj nove metodologije vrednovanja krajobraznih tipova može pridonijeti utemeljenom izdvajanju potencijalnih zaštićenih područja.

1.3. Prostor istraživanja

Pojam Gorska Hrvatska u javnosti, ali i u regionalno geografskim radovima odnosi se na područje Gorskog kotara, Ogulinsko-plašćanske submontane udoline i Like ili Gorsko-kotlinske regije (Pavić, 1978; Rogić, 1977). U prvoj objavljenoj geografskoj regionalizaciji Hrvatske, u sklopu serije knjiga Geografija SR Hrvatske izdvaja se regija Gorska Hrvatska koja je i opisana u zasebnoj knjizi (Crkvenčić, 1975). Regija Gorska Hrvatska izdvaja se kao

makroregija, a kao njezine posebnosti izdvojeno je da je reljefno najviša u Hrvatskoj te se sastoji od tri manje uvjetno-homogene regije: Gorskog kotara, Like i Ogulinsko-Plašćanske submontana udolina koja ima prijelazne značajke (Crkvenčić, 1975). U fizičkogeografskom pristupu regionalizaciji prostora RH izdvajaju se područja Gorskog reljefa ili reljefa sredogorja koji se dijeli na Gromadno gorje peripanonskog područja i Dinarski sredogorski reljef te područja Planinskog reljefa koje se dijele na sjeverozapadni dio planinskog reljefa Hrvatske i jugoistočni dio planinskog reljefa Hrvatske (Magaš, 2013). Fizičkogeografska regija Gorska Hrvatska izdvojena u ovome radu, na jugu je proširena kako bi bilo obuhvaćeno kontinuirano područje s planinskim karakterom. Prema tim parametrima, u regiju su uključene i planine Dinara, Kamešnica i Svilaja (Sl. 1.3.1) te je tako definirana fizičko-geografska regija Gorske Hrvatske (u nastavku Gorska Hrvatska). Bitno je napomenuti kako regija Gorska Hrvatska izdvojena za potrebe ovoga rada nije prostorni sinonim uvjetno-homogenoj regiji Gorska Hrvatska u koju spadaju Lika i Gorski kotar. Proteže se od 14° 34' 11.02908"E i 45° 40' 23.93688"N na svojoj najsjevernijoj točki do 16° 58' 12.40248"E i 43° 32' 42.52812"N na svojoj najjužnijoj točki. Fizičko-geografska regija Gorske Hrvatske stoga je prikazana na Sl. 1.3.1.



Sl. 1.3.1. Prostor istraživanja: fizičkogeografska regija Gorska Hrvatska

Prostor istraživanja obuhvaća 10.469 km² što je gotovo 20% cijelog teritorija Republike Hrvatske. Najniža nadmorska visina je 24,7 m, dok je najviša točka 1831 m, tj. vrh Dinara ili u narodu poznatiji kao Sinjal (x: 491006,11435, y: 4880284,09067). Prosječna nadmorska visina je 779,64 m. Najizrazitiji orografski elementi područja su lučno oblikovani grebeni, između kojih se na nadmorskoj visini od 500 do 700 m izmjenjuju niža brda, krška polja i manje krške depresije. Prema Geološkoj karti Republike Hrvatske 1:300.000, u geološkoj građi istraživanog

područja prevladavaju karbonati (91,6%), dok ostatak zauzimaju klastične stijene različitih litoloških značajki.

Gorska Hrvatska ističe se i po svojim negativnim sociogeografskim pokazateljima. To je najrjeđe naseljeno područje Republike Hrvatske, s najnižom gustoćom naseljenosti i najvećim administrativnim jedinicama, pretežno ruralnim. Teško je ispravno procijeniti ukupan broj stanovnika proučavanog područja, jer se radi o fizičko-geografskoj, a ne administrativnoj regiji. Ipak, prema popisu stanovništva iz 2021. godine, ovdje živi oko 130.000 stanovnika na 10 469 km², što je 12,4 stanovnika/km². Samo jedan grad u cijelosti se nalazi unutar regije, Gospić, s 11 502 stanovnika i najvećom gustoćom naseljenosti (11,89 stanovnika/km²) prema popisu stanovništva iz 2021. (Državni zavod za statistiku 2022.). Hrvatski rat za neovisnost 1990-ih teško je utjecao na područje, što je pogoršalo negativan demografski razvoj koji je već započeo. Danas je ovaj prostor najdepopuliranije područje s najvišim koeficijentom starenja u Republici Hrvatskoj. Vrlo dinamični fizičko-geografski procesi te nasuprot njima vrlo spori i negativni socio-geografski procesi pravi su odraz negostoljubivosti ove planinske regije.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Prva istraživanja tipologije krajobraza, nakon etape istraživanja temeljenih na opsežnom terenskom radu, ali s puno deskripcije, u Europi se provode od 19. stoljeća (Antrop, 2013). Rane originalne metode prostorne diferencijacije okolišnih razlika, pa tako i onih u krajobrazima, oslanjale su se na intuitivnu interpretaciju proučavanih uzoraka prostora te osobno iskustvo istraživača. Krajem 1990-ih pa sve do danas ta se istraživanja produbljuju i diversificiraju. Evolucijom istraživanja javljaju se teme o promjena krajobraza, identitetima povezanim s krajobrazom, načinu korištenja zemljišta i njegovu utjecaju na promjene u krajobrazu, zatim teme o kulturnima krajobrazima i vrednovanju te u najnovije vrijeme metrika krajobraza razvijena za potrebe kvantitativnih analiza. Ona je postala važan alat u razumijevanju i mjerenju kompleksnosti sastava i strukture krajobraza (Gökyer, 2013). Neki od autora sa značajnim novijim doprinosom u proučavanju i vrednovanju krajobraza na europskoj razini su Meeus, (1995) koji je izradio tipologiju krajobraza Europe, zatim Bohn i dr., (2007) koji su izradili regionalizaciju prirodne vegetacije Europe na bazi krajobraza sa svrhom primjene u zaštiti okoliša te Hazeu i dr., (2011) koji su usporedili pet tipologija europskih okoliša (Butorac i Buzjak, 2021).


Geografski utemeljena tipologija krajobraza Republike Hrvatske, ali niti prostora istraživanja ovoga rada do sada nisu izrađene. Prva izdvajanja krajobraza na nacionalnoj razini izradio je geograf (Rogić, 1962) koji je potom uvjetno-homogenu regionalizaciju Hrvatske (Rogić, 1983). Trenutno važeće i najrecentnije izdvajanje krajobraznih cjelina na nacionalnoj razini izradio je geograf Bralić, (1999) za potrebe izrade nacionalne razvojne strategije koja se zbog svoje koristi i preglednosti koristi i danas. To nije tipologija, već krajobrazna regionalizacija provedena na temelju prirodnih obilježja (reljefa, voda i vegetacija), ali i uz uvažavanje kulturnih elemenata prostora gdje su kao nazivi prostornih cjelina korišteni uglavnom nazivi vernakularnih regija. Problem s takvom regionalizacijom jest taj da kriteriji izdvajanja regija nisu jasni, stoga su posljedično i granice regija nejasne. Obzirom da metodologija izrade nije poznata, nije moguće niti ponoviti ili provjeriti dobivene rezultate. Dumbović Bilušić, (2015) izdvojila je tipove kulturnih krajobraza kojima se bavila i u više kasnijih radova i studija. Spomenuta tipologija iscrpna je i metodološki potkrijepljena te kao takva korisna podloga za donošenje odluka o zaštiti i korištenju izdvojenih tipova kulturnog krajobraza.

2.1. Proučavanje krajobraza u Hrvatskoj

Prema brojnosti radova, uspostavljenim istraživačkim temama i metodologijama u istraživanjima krajobraza ističu se oni geografski te oni iz područja arhitekture i krajobrazne arhitekture. Od radova ostalih struka s manje brojnim doprinosima javljaju se sociologija, agronomija, ekonomija, arheologija, antropologija i etnologija. Unutar navedenih struka nije moguće jasno izdvojiti pristup zbog pre malog broja radova. Prema brojnosti od ukupno 41 analiziranoga rada za razdoblje do 2019. godine ističu se geografija (34,14 %), krajobrazna arhitektura (34,14 %) i arhitektura (14,6 %), ostale struke zastupljene su s manje od 5 % (Butorac i Buzjak, 2021). U razdoblju od 2020. do 2026. i dalje su omjeri radova po strukama slični tj. prednjače geografija (37,5%) i krajobrazna arhitektura (31,25%). Prisutne su još i arhitektura s 18,75% i arheologija s 12,5%.

Prva tipološka istraživanja krajobraza unutar hrvatske geografije počinju se provoditi u drugoj polovici 20. st. Pionirska istraživanja proveli su (Rogić, 1958) koji je istraživao oblikovanje krajobraza velebitskih padina, (Crkvenčić, 1958) koji je istraživao agrarne krajobraze Ivanšćice i (Friganović, 1961) koji je pisao o genezi i promjenama krajobraza na području polja Gornje Krke.

Nakon toga uslijedilo je dugo razdoblje stagnacije. Ponovni rast interesa za tematiku krajobraza javlja se s početkom 2000-ih, uz varijacije u intenzitetu, te postupno jača sve do danas (Sl. 2.1.1) Najveći broj radova (šest) publiciran je 2017. godine, i 2021. godine a najintenzivnije razdoblje kontinuiranoga objavljivanja traje od 2011. godine do danas.



Sl. 2.1.1. Vremenski pregled istraživanja krajobraza u Hrvatskoj


Među analiziranim radovima u razdoblju do 2019. godine najzastupljeniji su izvorni znanstveni radovi (65,85 % od ukupnoga broja radova), a najmanje su zastupljeni stručni radovi (2,4 %). Od ostalih kategorija radova prisutni su pregledni radovi (17,07 %), poglavlja u knjigama (9,7 %) i prethodna priopćenja (7,3 %). U jedanaest radova (26,8 %) krajobraz je jasno definiran, dok u svim ostalim radovima izostaje definicija krajobraza (Butorac i Buzjak, 2021). U razdoblju od 2020. do danas (2026) prevladavaju izvorni znanstveni radovi (87,5%), a objavljen je i jedan pregledni rad te jedno poglavlje u knjizi.

Do 2019. godine, s obzirom na prostornu razinu analize po udjelu u ukupnom broju analiziranih radova izdvajaju se radovi na mikroregionalnoj (41,46 %) i subregionalnoj razini (19,51 %). Prema udjelu nadalje su zastupljeni radovi na nacionalnoj razini (9,7 %), radovi koji nisu prostorno relevantni (7,3 %) te najmanjim udjelom radovi na makroregionalnoj razini (4,8 %). Svega četiri rada izrađena su na nacionalnoj razini. Radovi nacionalne prostorne razine iz

područja arhitekture po kategorizaciji su pregledni radovi (dva). Dva su rada nacionalne razine iz područja krajobrazne arhitekture, a po kategorizaciji su stručni i pregledni rad (Butorac i Buzjak, 2021). Od 2020. do 2026. godine i dalje prednjače radovi na mikroregionalnoj (7) i subregionalnoj (7) prostornoj razini. Niti jedan rad mikroregionalne razine nije geografski, dok su jedini radovi na nacionalnoj i makroregionalnoj razini geografski.

Prema Butorac i Buzjak (2021) od ukupnoga broja analiziranih radova do 2019. godine, dva rada izrađena su na makroregionalnoj razini, a odnose se na Jadransku Hrvatsku i dinarski krš. Prema tipu prostornih jedinica izdvaja se administrativna prostorna jedinica gdje su granice područja istraživanja granice jedinica lokalne samouprave, naselja ili županija. Područja istraživanja u okvirima administrativnih područja jedina su jasno definirana u svim analiziranim istraživanjima. Uslijed analize radova postalo je jasno da za većinu radova nije moguće definirati tip prostorne jedinice. Većina autora u metodološkom pristupu ili u opisu područja istraživanja ne definira tip prostorne jedinice (uvjetno-homogena, fizionomska ili administrativna, krajobraz), već se za neke od njih da zaključiti iz konteksta rada o kakvoj se prostornoj jedinici radi. S druge strane, za većinu radova nije moguće tvrditi na koji je način izdvojena osnovna prostorna jedinica te kojega je tipa. Jedan od primjera iz analiziranih radova jest prostorna jedinica južni dio otoka Visa (Lozić, Krklec, i dr., 2012; Lozić, Šiljeg, i Krklec, 2013; Lozić, Šiljeg, Krklec, i dr., 2013), za koji autori navode određene reljefne značajke prema kojima se izdvaja od ostatka otoka, no nije moguće s velikom sigurnošću zaključiti koji je to tip prostorne jedinice, ali može se pretpostaviti da je to fizionomski tip prostorne jedinice. Još jedan primjer među analiziranim radovima jest i prostorna jedinica ušće rijeke Mure u Dravu (Butula, 2008, 2009) koja nema jasno definirane granice, stoga nije ni moguće odrediti tip prostorne jedinice. Kao što je spomenuto, kod administrativnoga tipa prostornih jedinica zbog sama naziva razvidno je o kojem se tipu radi, a i u tim slučajevima i sami autori eksplicitno navode tip prostorne jedinice. Administrativni tip osnovna je prostorna jedinica u 26,8 % od svih analiziranih radova do 2019. godine. Lokacije radova na prethodno navedenim prostornim razinama prikazane su na Sl. 2.1.2. Prostor istraživanja u tri rada, što je ujedno i najveći broj radova o jednoj lokaciji u promatranom razdoblju, južni je dio otoka Visa (Lozić, Šiljeg, i Krklec, 2013; Lozić, Šiljeg, Krklec, i dr., 2013; Lozić, Krklec, i dr., 2012). Po dva rada izrađena su za prostor južne padine Svilaje (Durbešić i Fuerst-Bjeliš, 2016, 2017), Grada Zagreba (Gašparović i Sopina, 2018; Pereković i Kamenečki, 2019) i ušća rijeke Mure u Dravu (Butula, 2008, 2009). Prostorni raspored analiziranih istraživanja krajobraza u Hrvatskoj raspršen je te nepravilan. Na području pojedinih županija nema ni jednoga provedenog istraživanja. Tako je

na prostoru kontinentalne Hrvatske čak pet županija (Vukovarsko-srijemska, Brodsko-posavska, Požeško-slavonska, Bjelovarsko-bilogorska i Zagrebačka županija) bez ijedne lokacije koja je bila područje istraživanja nekoga od istraživanja krajobraza. Karlovačka županija, na prijelazu iz Panonske u Gorsku Hrvatsku također nema obrađenih lokacija koje su područje istraživanja analiziranih radova s tematikom krajobraza.



Sl. 2.1.2 Karta prostora istraživanja i broj istraživanja za radove objavljenje do 2019. godine (Butorac i Buzjak, 2021)

U razdoblju od 2020. do 2026. objavljen je jedan pregledni rad na nacionalnoj razini (Butorac i Buzjak, 2021) koji daje pregled istraživanja krajobraza na prostoru RH do 2019. godine, te jedan na makroregionalnoj razini tj. za prostor fizičkogeografske regije Gorska Hrvatska (Rossi i dr., 2025). Na subregionalnoj razini Srednja Lika izdvaja se kao prostor istraživanja u čak

četiri izvorna znanstvena rada (Bogovac i dr., 2025; Hamzić i dr., 2020; Hamzić i Fuerst-Bjeliš, 2021b, 2021a). U radovima (Hamzić i dr., 2020; Hamzić i Fuerst-Bjeliš, 2021b, 2021a) regija je definirana kao teritorijalno-administrativna jedinica koja se sastoji od tri jedinice lokalne samouprave, dok u Bogovac i dr. (2025) nisu jasno definirane granice Srednje Like. U svim geografskim radovima u razdoblju 2020.-2026. jasno su definirani prostori istraživanja, a u dva su navedeni i kriteriji izdvajanja promatrane prostorne jedinice (Butorac i Buzjak, 2020; Rossi i dr., 2025). Ostale struke koje su u promatranom razdoblju objavljivale radove (arheologija, arhitektura i krajobrazna arhitektura) nemaju definirane prostorne jedinice te su kriteriji za odabir određene prostorne razine nejasni. Izuzetak je jedan rad u kojem je prostor istraživanja Park Prirode Dinara (Komšo i dr., 2023).

Analizom zastupljenosti istraživačkih tema povezanih s krajobrazom izdvojene su četiri najzastupljenije teme:

- Kulturni krajobraz
- Vrednovanje krajobraza
- Evolucija i promjene krajobraza
- Tipologija krajobraza.

U Butorac i Buzjak (2021) navedeno je kako je prema udjelu u ukupnom broju radova do 2019. godine najzastupljenija je istraživačka tema tipologija krajobraza (26,8 %), zatim vrednovanje krajobraza (21,95 %), kulturni krajobraz (19,5%) a najmanje je zastupljena tema evolucija i promjene krajobraza (17,7 %). U kategoriji „Ostalo” nalaze se teme koje su obrađene samo u pojedinačnim radovima, kao što je npr. subjektivna percepcija krajobraza, teorijski pristup istraživanju krajobraza i sl., a takvi su radovi u ukupnom broju analiziranih prisutni s 14,63 %.

U razdoblju 2020.-2026. najzastupljenije istraživačke teme s jednakim postotnim udjelom (31,25%) su kulturni krajobraz i vrednovanje krajobraza. Tipologija krajobraza glavna je istraživačka tema u 12,5% radova, a evolucija i promjene krajobraza u 6,25%. Ostali radovi (18,75%) bave se pojedinačnim istraživačkim temama, primjerice teorijskim pristupima u krajobrazu, kvalitetom podataka i strukturom krajobraza.

Pogledom na sva istraživanja krajobraza u RH jasno se izdvajaju dva pristupa istraživanju krajobraza u RH, a to su geografski i pristup arhitekture i krajobrazne arhitekture. koji, iako satkan od dvije struke, ali s vrlo sličnim zanimanjem za tematska područja, metodološkim okvirom te u istom vremenskom odsječku. S jedne strane geografski, a s druge strane pristup

arhitekture i krajobrazne arhitekture predstavljaju dva konceptualna pristupa istraživanju krajobraza. Geografski pristup zasnovan je na konceptu održivoga razvoja i prostorne realnosti, dok je pristup u arhitekturi i krajobraznoj arhitekturi baziran na konceptu dizajna i oblikovanja. Sa sve većim promjenama krajobraza u Hrvatskoj dolazi i do većega istraživačkog interesa u istraživanju krajobraza. Broj istraživanja naglo je narastao u razdoblju od 2016. do 2019. godine, a s time i raznolikost zastupljenih tema. Najizraženije razlike između dvaju pristupa odnose se na primarna tematska područja i primarno korištene metode. U geografskom pristupu prevladavaju teme evolucije i promjena krajobraza i tipologije krajobraza, dok u arhitektonsko-urbanističkom pristupu prevladavaju teme vrednovanja krajobraza i kulturnoga krajobraza. U geografskom pristupu u korištenim metodama svakako je najzastupljenije korištenje GIS alata te provođenje GIS analiza, dok je u pristupu u arhitekturi i krajobraznoj arhitekturi najčešće korištena metoda deskripcije i grafička/vizualna interpretacija. U prostornoj razini istraživanja krajobraza u geografskom pristupu prevladavaju veće prostorne jedinice, tj. supraregionalna prostorna razina, dok u pristupu u arhitekturi i krajobraznoj arhitekturi prevladava administrativna prostorna razina. Najveću razliku čini način određivanja granica područja istraživanja, gdje u geografskom pristupu prevladavaju orografski elementi prostora ili prirodno-geografske cjeline, dok u pristupu u arhitekturi i krajobraznoj arhitekturi prevladavaju administrativno-teritorijalne jedinice (Butorac i Buzjak, 2021).

U razdoblju od 2020.-2026. primjetna je promjena u korištenju metoda unutar pristupa arhitekture i krajobrazne arhitekture, koja upućuje na razdvajanje arhitektonskog pristupa te pristupa krajobrazne arhitekture. Radovi arhitekata koriste se istraživačkim metodama svojstvenim pristupu arhitekture u proučavanju krajobraza, a to su opsežne analize bibliografije te kartografskih podloga, dok je i dominantna istraživačka tema ostala kulturni krajobraz. Naime, radovi krajobraznih arhitekata u navedenom razdoblju sve više zalaze u korištenje geografskih metoda kao primarnih metoda u istraživanjima. Čak i osnovni geografski koncepti postaju predmetom istraživanja ili istraživačkom metodom unutar radova krajobraznih arhitekata. Tako su primjerice različite regionalizacije prostora RH predmet istraživanja u Bogovac i dr. (2025) stavljene u kontekst krajobraza, što je samo po sebi nesuvislost, obzirom da je svaka regionalizacija izrađena za drugu svrhu, a niti jednoj svrha nije bila izdvajanje krajobraznih jedinica. Primjetno je vrlo često miješanje koncepta regionalizacije i tipologije tj. izjednačavanja ta dva pojma, što ukazuje na netočne temeljne teorijske postavke djela.

Unutar hrvatske znanstvene zajednice formiran je krug istraživača kojima je primarni fokus istraživanja krajobraz te su unutar toga kruga formirana i dva jasna pristupa istraživanju, a s

druge strane krajobraz kao predmet istraživanja jasno je definiran u tek 25,4% svih radova. Nedostatak jasna definiranja predmeta istraživanja i jasne teorijske i metodološke osnove istraživanja izdvaja se i kao glavni nedostatak obaju istraživačkih pristupa te cjelokupne znanstvene aktivnosti orijentirane na krajobraz. Metodološki pristup u većini geografskim istraživanja je kvantitativan te stavlja naglasak na prostornu/fizičku stvarnost krajobraza, dok je u pristupu arhitekture i krajobrazne arhitekture deskriptivan te stavlja naglasak na percepciju čovjeka o samom krajobrazu. Analizom prostorne razine istraživanja radova iz obaju pristupa izražen je nedostatak postojanja geografski utemeljene nacionalne tipologije krajobraza Hrvatske koja bi bila metodološko polazište za sve tipologije nižega ranga te najbitnije, upravljački alat sektorima koje zanima krajobraz. Unatoč velikom znanstvenom interesu i izdvojenim dvama pristupima istraživanje krajobraza u Hrvatskoj individualizirano je s obzirom na aspekt i interese pojedinih istraživača. Prostorna je pokrivenost RH istraživanjima krajobraza nasumična i nepovezana te je svaki dio istraženoga prostora istražen na temelju različitih podataka i metoda. Najveći je pomak kroz vrijeme u istraživanju krajobraza Hrvatske korištenje daljinskih istraživanja i GIS okružja, čime je povećana točnost analiza i mogućnost analize područja većega prostornog obuhvata (Butorac i Buzjak, 2021).

2.1.1. Geografski pristup proučavanja krajobraza u RH

U drugoj polovici 20. stoljeća u Hrvatskoj nastaju prve tipologije krajobraza, a primarno se obrađuju materijalne (biotičke, abiotičke i antropogene) sastavnice krajobraza. Od prvoga definiranja do modernoga poimanja krajobraza u geografiji, pod velikim utjecajem razvoja daljinskih istraživanja i primjene alata GIS-a, krajobraz se prestaje definirati onime što je vidljivo sa stajališta istraživača jer se „pogledom odozgo” i digitalnim geoprostornim analizama otvaraju nove mogućnosti u istraživanjima. Korištenje GIS-a i daljinskih istraživanja u analizama krajobraza pospešuje prostornu i vremensku rezoluciju podataka. GIS omogućuje obradu velike količine te mogućnost generiranja novih prostornih podataka i relacija među njima koje nije moguće percipirati samo bivanjem u istraživanom prostoru. Analizama krajobraza u GIS okruženju povećava se broj prostornih upita kojim se stvaraju nove informacije i smanjuje se vrijeme samoga istraživanja. Prednost GIS-a jest mogućnost brze manipulacije prostornim podacima te izvođenja indeksa stanja krajolika iz njih. Katkad nedostatak može biti vrlo visoka cijena ili mukotrpna priprema kvalitetnih ulaznih podataka, no s obzirom na dugoročne prednosti brza i organizirana pristupa informacijama te

učinkovitosti manipulacije podacima spomenute dobrobiti premašuju kratkoročne troškove (Lee i dr., 1999).

S obzirom na razvoj geografije u Hrvatskoj te interes istraživača (klasični geografski pristup) prvi radovi bili su dubinske studije određenih reljefnih elemenata prostora, tj. primarno je prostor istraživanja bio određen geomorfološki. Tako su nastale opsežne studije Ivanšćice (Crkvenčić, 1958), primorske padine Velebita (Rogić, 1958) i polja Gornje Krke (Friganović, 1961). Nakon 2012. dolazi do povećanja u broju geografskih radova. Od 2012. do 2019. objavljeno je 11 znanstvenih radova. Svojevrsan moderni val istraživanja krajobraza javio se uslijed promjene paradigme zaštite okoliša i jačanja geoekologije u geografiji. S obzirom na prvotni prirodni determinizam, zatim socijalni determinizam unutar regionalne geografije, u modernim istraživanjima krajobraza nastaje holistički pogled na prostor i korištenja (prošloga i budućega) određenog prostora (Tab. 2.1.1). U razdoblju 2020.-2026. u geografskim radovima jača holistički pristup u kojem je naglasak na stvaranju sveobuhvatne tipologije krajobraza s jasnim kriterijima i metodama te na kvantifikaciji strukture krajobraza te njegovim intrinzičnim, neutilitarnim vrijednostima (Butorac i Buzjak, 2020; Hamzić i dr., 2020; Rossi i dr., 2025).

Tab. 2.1.1 Pregled analiziranih radova – geografski pristup istraživanju krajobraza

Autori	Naslov	Godina	Definicija krajobraza	Prostorna razina (1)	Prostorna razina	Primjena GIS-a	Kategorija rada	Vrsta rada
Crkvenčić I.	Prigorje planinskog niza Ivančice - evolucija agrarnog pejzaža	1958		mikroregionalna	Ivanščica	ne	Evolucija i promjene krajobraza	Izvorni znanstveni rad
Rogić V.	Velebitska primorska padina	1958		mikroregionalna	primorska padina Velebita	ne	Evolucija i promjene krajobraza	Izvorni znanstveni rad
Frganović M.	Polja Gornje Krke	1961		mikroregionalna	polja Gornje Krke	ne	Evolucija i promjene krajobraza	Izvorni znanstveni rad
Lončar J., Cvitanović M.	(Post)socijalizam i okoliš: promjena kulturnoga krajobraza Pridravske nizine Osijeka u posljednjih pedeset godina	2012	Krajobraz se definira kao kompleksno područje unutar kojega se mogu definirati različite značajke: fizičke i ekološke, kulturne i povijesne, estetske, socijalne, strukturne i funkcionalne značajke (Marić, Grgurević, 2007.).	mikroregionalna	Pridravska nizina Osijeka	da	Evolucija i promjene krajobraza	Prethodno priopćenje
Lozić S., Krklec K., Perica D.	Tipologija otoka Visa temeljena na geološkim, geomorfološkim i pedološkim karakteristikama prirodnog i kulturnog krajobraza	2012		mikroregionalna	otok Vis	da	Tipologija krajobraza	Izvorni znanstveni rad

Lozić S., Šiljeg A., Krklec K., Šiljeg S.	Vertical landscape structure of the southern part of Vis island, Croatia	2012	A landscape represents an interaction between social and natural processes in an environment, so the planning and decision making in the context of sustainable development should consider such spatial relations of its elements (Turner 1989).	mikroregionalna	Južni dio otoka Visa	da	Tipologija krajobraza	Izvorni znanstveni rad
Lozić S., Šiljeg A., Krklec K., Šiljeg S.	Strukturne značajke suhozidne mreže kao pokazatelji antropogenog utjecaja na krajobraz - primjer Južnog dijela otoka Visa, Hrvatska	2013		mikroregionalna	Južni dio otoka Visa	da	Tipologija krajobraza	Izvorni znanstveni rad
Lozić S., Šiljeg A., Krklec K., Jurišić M., Šiljeg S.	Some basic indices of horizontal landscape structure of the southern part of Vis Island, Croatia	2013	A landscape represents an interaction between social and natural processes in an environment, so the planning and decision making in the context of sustainable development should consider such spatial relations of its elements (Turner 1989).	mikroregionalna	Južni dio otoka Visa	da	Tipologija krajobraza	Prethodno priopćenje

Blaće A.	Razvoj i suvremena preobrazba krajolika naselja Danilskog polja kod Šibenika	2014	U najširem smislu krajolik je područje viđeno ljudskim okom čija je narav rezultat međusobnog djelovanja prirodnih i/ili ljudskih čimbenika (European Landscape Convention, 2000). Takva definicija implicira dualnost krajolika – s jedne strane objektivne, materijalne stvarnosti, a s druge strane subjektivne slike zbog uloge promatrača koji taj krajolik doživljava. Krajolik je i sustav prožet nematerijalnim vrijednostima i simbolikom kroz koji se izražava povezanost s povijesnim osobama i događajima (Dumbović Bilušić, 2014).	mikroregionalna	Danilo Biranj, Danilo, Danilo Kraljice	ne	Evolucija i promjene krajobraza	Izvorni znanstveni rad
Durbešić A., Fuerst-Bjeliš B.	Tipovi i trendovi promjene pejzaža planine Svilaje Ogorje	2016		mikroregionalna	Južna padina Svilaje, Ogorje	da	Tipologija krajobraza	Izvorni znanstveni rad
Blaće A., Čuka A.	Razvoj krajolika i poljoprivrede zemuničkog područja	2016	Više je definicija krajolika, a u najširem smislu on označava područje viđeno ljudskim okom čije je obilježje rezultat međusobna djelovanja prirodnih i/ili ljudskih čimbenika (European Landscape Convention, 2000.).	mikroregionalna	Zemunik Donji i Zemunik Gornji	ne	Evolucija i promjene krajobraza	Poglavlje u knjizi

Durbešić A., Fuerst-Bjeliš B.	Utjecaj promjene pejzaža na rizik od požara	2017		mikroregionalna	Južna padina Svilaje, Ogorje	da	Tipologija krajobraza	Poglavlje u knjizi
Fuerst-Bjeliš B., Kale J.	Povijesna dinamika kulturnih krajolika Šibenskog područja	2017		subregionalna	Šibensko- kninska Županija	ne	Evolucija i promjene krajobraza	Izvorni znanstveni rad
Fuerst-Bjeliš B., Kale J.	Deforestacija i reforestacija u hrvatskome dinarskom kršu: odnosi i implikacije	2018		makroregionalna	Dinarski krš	da	Evolucija i promjene krajobraza	Izvorni znanstveni rad
Fuerst-Bjeliš B., Vukosav B.	Landscapes of identities in shared spaces of borderlands	2018		nacionalna	RH	ne	Kulturni krajobraz	Izvorni znanstveni rad
Butorac V., Buzjak N.	Geodiversity and Landscape Services in the Region of Ogulinško- Plašćanska Zaval, Croatia	2020	Krajobraz je fizički prostor (u različitim mjerilima), dio površine Zemlje koji je oblikovan prirodnim procesima i formiran antropogenim djelovanjem različita intenziteta	mikroregionalna	Ogulinško- Plašćanska submontana udolina	da	Vrednovanje krajobraza	Izvorni znanstveni rad
Hamzić M., Fuerst-Bjeliš B., Pahernik M.	Structural Characteristics of Patches in the Central Lika Landscape— Application of Spatial and Regression Analysis	2020		subregionalna	Srednja Lika	da	Ostalo	Izvorni znanstveni rad
Butorac V., Buzjak N.	Landscape research in Croatia from 1945 to 2019	2021	Krajobraz je fizički prostor (u različitim mjerilima), dio površine Zemlje koji je oblikovan prirodnim procesima i formiran antropogenim djelovanjem različita intenziteta	nacionalna	RH	da	Ostalo	Pregledni rad

Hamzić M., Fuerst-Bjeliš B.	Application of spatial- and diachronic-process analysis of landscape development in Central Lika, Croatia from 1980 to 2012	2021	subregionalna	Srednja Lika	da	Evolucija i promjene krajobraza	Izvorni znanstveni rad
Hamzić M., Fuerst-Bjeliš B.	Landscape Development Types in Central Lika 1980–2012 – Applying Spatial and Process Oriented GIS Model	2021	subregionalna	Srednja Lika	da	Tipologija krajobraza	Izvorni znanstveni rad
Rossi V., Krtalić A., Buzjak N.	Land cover mapping in mountainous Croatia using Sentinel-2A satellite imagery	2025	makroregionalna	Gorska Hrvatska	da	Tipologija krajobraza	Izvorni znanstveni rad

U geografskom pristupu istraživanju krajobraza u RH radovi su većinom smješteni u dva tematska područja. Po broju istraživanja prednjači tema evolucija i promjene krajobraza. Klasične geografske studije geneze i razvoja kulturnih krajobraza u Hrvatskoj već se zarana bave problematikom promjena sprege načina života, gospodarenja prostorom i promjenama okoliša (Fuerst-Bjeliš, 2018). Najraniji analizirani i već nekoliko puta spomenuti geografski radovi o krajobrazu (Crkvenčić, 1958; Friganović, 1961; Rogić, 1958) iscrpna su istraživanja evolucije krajobraza u interakciji prirodnih datosti sa socijalnim strukturama. Lončar i Cvitanović, (2012) analizirali su promjene kulturnoga krajobraza pod utjecajem promjene socioekonomskih uvjeta i struktura. Blaće, (2014) analizira razvoj i suvremene promjene krajobraza triju naselja u zaobalju Šibenika na temelju demogeografskih podataka i analize promjena površinskog pokrova, a evolucija krajobraza zemuničkoga područja povezana s razvojem poljoprivrede obrađena je u radu Blaće i Čuka, (2016). Geneza kulturnoga krajobraza šibenskoga područja te njegove promjene kroz povijest istražene su u radu Fuerst-Bjeliš i Kale, (2018). Fuerst-Bjeliš, (2018) analizira odnos čovjeka i okoliša u dinarskom kršu kroz procese deforestacije i reforestacije te su takva područja detektirana kao kulturni krajobrazi. Hamzić i Fuerst-Bjeliš, (2021) prikazuju strukturalna obilježja te proces i intenzitet promjene krajobraza Srednje Like u tranzicijskom postsocijalističkom i poratnom razdoblju. U radu se primjenjuju i pokazatelji metrike krajobraza koji su poslužili za izradu indeksa razvoja krajobraza.

Druga su najzastupljenija tema u geografskim radovima o krajobrazu tipološka istraživanja. Izdvađa se rad Lozić i dr., (2012b) u kojem je multikriterijskom analizom definirana vertikalna struktura krajobraza južnoga dijela otoka Visa. Vertikalna struktura označava odnose između sastavnica (geološka, geomorfološka, vegetacijska obilježja) u svakom od izdvojenih tipova krajobraza. Tipovi su izdvojeni korištenjem GIS alata, a sama metodologija izrade tipologije daje važan doprinos razvoju jedinstvene geografske metodologije izdvajanja tipova na temelju analize strukture krajobraza. Lozić i dr., (2012a) izrađuju tipologiju krajobraza otoka Visa integrirajući fizičkogeografske i kulturne elemente strukture krajobraza. U Lozić i dr., (2013b) izvedeni su indeksi stabilnosti tipova krajobraza otoka Visa te su izdvojeni tipovi prema stabilnosti. Lozić i dr., (2013a) zatim analiziraju tipove krajobraza sa suhozidnom mrežom u južnom dijelu otoka Visa na temelju čega je kvantificiran antropogeni utjecaj na izdvojene krajobrazne tipove. U ovom je radu po prvi put u istraživanjima krajobraza u Hrvatskoj primijenjena metrika krajobraza. Durbešić i Fuerst-Bjeliš, (2017, 2016) za prostor planine Svilaje izrađuju klasifikaciju krajobraza temeljem samo jednoga elementa – zemljišnoga pokrova. Hamzić i Fuerst-Bjeliš, (2021) izdvajaju razvojne tipove krajobraza temeljene na

jednom kriteriju tj. jednom elementu strukture krajobraza, a to je površinski pokrov i način korištenja zemljišta. (Rossi i dr., 2025) izradili su tipologiju površinskog pokrova Gorske Hrvatske kao prvi korak u daljnjem kartiranju i izradi tipologije krajobraza. U radu je i kvantificirana struktura površinskog pokrova pomoću izračuna pokazatelja metrike krajobraza.

S obzirom na prostornu razinu u geografskom pristupu prevladavaju radovi koji obrađuju krajobraze na mikroregionalnoj (13 radova, Tab. 2.1.1) i subregionalnoj razini (četiri radova, Tab. 2.1.1) i makroregionalnoj razini (tri rada, Tab. 2.1.1). Od makroregija obrađen je dinarski krš (Fuerst-Bjeliš, 2018) i fizičkogeografska regija Gorska Hrvatska (Rossi i dr., 2025). Od radova subregionalne razine, tri istražuju prostor Srednje Like određen administrativno-teritorijalnim jedinicama (Hamzić i dr., 2020; Hamzić i Fuerst-Bjeliš, 2021b, 2021a), jedan se bavi prostorom otoka Visa (Lozić, Krklec, i dr., 2012) i jedan prostorom Šibensko - kninske županije (Fuerst-Bjeliš i Kale, 2018). Na mikroregionalnoj razini ističe se prostor južne padine planine Svilaje koji je obrađen u dva rada (Durbešić i Fuerst-Bjeliš, 2016, 2017). Tri tipološka rada izrađena su za mikroregionalnu prostornu razinu, tj. razinu manjih fizionomskih prostornih jedinica te se sva tri bave istom lokacijom, južnim dijelom otoka Visa (Lozić i dr., 2012; Lozić, Šiljeg, i Krklec, 2013; Lozić, Šiljeg, Krklec, i dr., 2013). Na nacionalnoj razini izrađena su dva rada, gdje Fuerst-Bjeliš i Vukosav (2019) obrađuju temu kulturnog krajobraza tj. povijesnih krajobraza u pograničnim područjima RH. Butorac i Buzjak (2021) dali su prikaz istraživanja krajobraza na prostoru RH od 1945.-2019. Prikladna prostorna rezolucija istraživanja krajobraza nužna je za vjerodostojno proučavanje krajobraza u svim istraživačkim fazama, tj. izradu tipologije, analize i vrednovanja krajobraza, kao i za interpretaciju funkcija krajobraza. Krajobrazne jedinice mogu se promatrati kao pravilne geometrijske jedinice kao što je grid ili kao nepravilne ne-geometrijske jedinice kao što su sljevovi, biogeografske zone i krajobrazne jedinice determinirane strukturom (Bastian i dr., 2006). Unutar geografskog pristupa, promatrajući prostornu razinu istraživanja, manje od trećine radova izrađeno je na administrativno-teritorijalnoj prostornoj razini, dok su svi ostali radovi izrađeni za fizionomske, fizičkogeografske prostorne jedinice. Kod svake prostorne razine potrebno je definirati specifične istraživačke metode kao i podatke koji su prikladni za istraživanje u određenoj prostornoj (i vremenskoj) rezoluciji (Krönert i dr., 2001), što je u geografskom pristupu prisutno u svakom promatranom radu u razdoblju od 1945. do 2026.

U korištenoj terminologiji unutar geografskog pristupa pojavljuju se tri pojma: pejzaž/krajolik/krajobraz. U jednoj trećini radova unutar geografskoga pristupa pojam krajobraza jasno je definiran. Lozić i dr., (2012b) u svom radu krajobraz definiraju prema

Turner, (1989) kao interakciju socijalnih i prirodnih procesa u okolišu te naglašavaju da upravo zbog takve kompleksne prirode krajobraza treba biti uzet u obzir prilikom donošenja odluka i pri planiranju. Definicijom krajobraza prema Turner (1989) autori se koriste i u radu Lozić i dr., (2013b). U Lončar i Cvitanović, (2012) krajobraz definiraju kao kompleksno područje unutar kojega se mogu definirati različite značajke: fizičke i ekološke, kulturne i povijesne, estetske, socijalne, strukturne i funkcionalne značajke, koja je preuzeta iz rada Marić i Grgurević (2007). Blaće (2014) preuzima definiciju krajobraza iz Europske konvencije o krajobrazima koja krajobraz definira u onom najširem smislu, kao područje viđeno ljudskim okom čije je obilježje rezultat međusobna djelovanja prirodnih i/ili ljudskih čimbenika, što se pokazuje kao ne prihvatljiva definicija krajobraza, obzirom na njegovu kompleksnost. Blaće i Čuka (2016) navode dvije definicije krajobraza. Jedna je također preuzeta iz Europske konvencije o krajobrazima, a nadopunjena je definicijom iz Dumbović Bilušić (2015) prema kojem je krajobraz sustav prožet nematerijalnim vrijednostima i simbolikom kroz koji se izražava povezanost s povijesnim osobama i događajima. U Butorac i Buzjak (2020, 2021) krajobraz je definiran kao fizički prostor (u različitim mjerilima), dio površine Zemlje koji je oblikovan prirodnim procesima i formiran antropogenim djelovanjem različita intenziteta.

Metoda GIS analize je unutar radova geografskoga pristupa korištena u 68,1 % radova. Radovi u kojima nije korišten GIS dijele se na rane radove koji su nastali prije same pojave GIS-a (Crkvenčić, 1958; Friganović, 1961; Rogić, 1958) i moderne geografske radove u kojima su korištene tradicionalne geografske metode bez upotrebe GIS-a (Blaće, 2014; Blaće i Čuka, 2016; Fuerst-Bjeliš i Kale, 2018; Fuerst-Bjeliš i Vukosav, 2019). Crkvenčić, (1958); Friganović, (1961); Rogić, (1958) služe se gotovo istim metodama koje provode gotovo istim slijedom. Analiza krajobraza zasniva se na dugotrajnom i iscrpnom terenskom radu, statističkoj obradi podataka arhivske pisane i kartografske građe te podataka prikupljenih na terenu, demografskih podataka, šumarskih karata, klimatskih podataka te nerijetko i uz provođenje strukturiranih intervjua i/ili anketiranja stanovništva. U ranim radovima Crkvenčić, (1958); Friganović, (1961); Rogić, (1958) korištene su metode terenske prospekcije, analize arhivskih pisanih i kartografskih izvora, demogeografska analiza te analiza reljefa, načina korištenja zemljišta i promjena načina korištenja zemljišta. U Blaće, (2014) i Blaće i Čuka, (2016) izrađena je demogeografska analiza u svrhu povezivanja s promjenama krajobraza, a čiji su rezultati stavljeni u odnos s analizom povijesnih karata, arheološke i povijesne pisane građe. Primarni podatci prikupljani su terenskim radom. U radovima Fuerst-Bjeliš i Kale (2018) i Fuerst-Bjeliš i Vukosav (2019) korištene su metode analize povijesnih pisanih i kartografskih

izvora, te analiza toponimije. Navedeni moderni geografski radovi koji ne provode GIS analize tematski se bave kulturnim krajobrazom ili evolucijom i promjenama krajobraza kroz povijest.

Radovi u kojima su provedene GIS analize mogu se izdvojiti oni koji provode metode *overlay* (preklapanja) (Lozić, Krklec, i dr., 2012; Lozić, Šiljeg, i dr., 2012; Lozić, Šiljeg, i Krklec, 2013; Lozić, Šiljeg, Krklec, i dr., 2013), radove koji koriste samo jedan kriterij za izdvajanje tipova krajobraza u GIS okružju (Butorac i Buzjak, 2020; Durbešić i Fuerst-Bjeliš, 2016, 2017; Fuerst-Bjeliš, 2018; Hamzić i dr., 2020; Hamzić i Fuerst-Bjeliš, 2021b, 2021a; Lončar i Cvitanović, 2012) i one koji provode kompleksne multikriterijske analize te klasifikacije satelitskih snimaka tj. daljinska istraživanja (Rossi i dr., 2025). (Lozić, Krklec, i dr., 2012) u GIS okružju proveli su analizu topografskih karata, satelitskih snimaka i aerofotogrametrijskih snimaka. Navedeni su slojevi preklapljeni te su iz njih izvedeni tipovi krajobraza. U radu (Lozić, Šiljeg, i dr., 2012) cjelokupna analiza krajobraza, tj. izrada tipologije provedena je u GIS okružju. Analizirana je litologija, vegetacija te morfometrijska obilježja reljefa. Svi promatrani slojevi prostora kodirani su i reklasificirani te preklapljeni (tzv. *overlay* metoda). (Lozić, Šiljeg, Krklec, i dr., 2013) provode digitalnu analizu reljefa, analizu primarnih i sekundarnih podataka, prostornu analizu, izrađuju tematske karte te provode metodu klasifikacije prirodnim granicama prema Jenks, (1967) i metriku krajobraza koja je glavna istraživačka metoda i u (Lozić, Šiljeg, i Krklec, 2013). Butorac i Buzjak (2020) proveli su analize reljefa, litologije i površinskog pokrova u GIS okružju, a tipologija krajobraza na temelju navedenih podataka i rezultati analiza u GIS-u poslužili su za vrednovanje usluga ekosustava koje pojedini tipovi krajobraza pružaju. Lončar i Cvitanović (2012) su korištenjem GIS-a izradili neprostorni, dinamički, deskriptivni induktivni model kroz analizu povezanosti promjena okoliša sa socijeekonomskim faktorima. Samo jedan element strukture krajobraza, tj. površinski pokrov korišten je kao sinonim krajobrazu Prostorno-vremenska analiza promjene načina korištenja zemljišta iz više izvora (povijesni katastarski planovi, tematske šumsko-vegetacijske karte, ortofoto snimke i baza podataka Corine Land Cover) provedena i vizualizirana u GIS-u korištena je u radovima Durbešić i Fuerst-Bjeliš, (2017, 2016) i Fuerst-Bjeliš, (2018). Vegetacijske i šumarske karte te Corine Land Cover korišteni su kao sinonim za krajobraz, tj. analiza je temeljena na samo jednom elementu strukture krajobraza, površinskom pokrovu. U radovima Hamzić i dr. (2020); Hamzić i Fuerst-Bjeliš (2021a, b) provedena je GIS analiza, bazirana na podacima Corine Land Cover za više trenutaka u vremenu, te je zemljišni pokrov izjednačen s pojmom krajobraz. Rossi i dr. (2025) jedini je rad u kojem su provedene kompleksne analize u GIS-u koje su uključivale daljinska istraživanja na temelju satelitskih snimaka u svrhu kartiranja površinskog pokrova.

No, ovaj rad tek je prvi korak u izradi tipologije krajobraza, te prikazuje samo stanje jednog elementa strukture krajobraza. U radu je navedeno kako površinski pokrov nije istoznačnica krajobrazu, ali je prvi korak u izradi utemeljene tipologije krajobraza.

Tipologija i analiza krajobraza Gorske Hrvatske do sada nije izrađena, iako postoje radovi koji se bave promjenama površinskog pokrova i načina korištenja zemljišta, za pojedine dijelove Gorske Hrvatske kao što je npr. Srednja Lika (Hamzić i dr., 2020; Hamzić i Fuerst-Bjeliš, 2021a; Jovanić, 2017) i planina Svilaja (Durbešić i Fuerst-Bjeliš, 2016). Važno je za napomenuti kako u radovima prevladava naziv krajobraz za ono što je zapravo površinski pokrov određenog područja, tj. često su vegetacijske karte i CORINE izjednačeni s pojmom krajobraz, čime je generalizirana i pojednostavljena višedimenzionalnost krajobraza.

Unutar hrvatske znanstvene zajednice formiran je krug istraživača kojima je primarni fokus istraživanja krajobraz te su unutar toga kruga formirana i dva jasna pristupa istraživanju, geografski pristup i pristup arhitekture i krajobrazne arhitekture. S druge strane u statistički zanemarivu postotku (26,8 %) krajobraz kao predmet istraživanja jasno je definiran. Nedostatak jasna definiranja predmeta istraživanja i jasne teorijske i metodološke osnove istraživanja izdvaja se i kao glavni nedostatak obaju istraživačkih pristupa te cjelokupne znanstvene aktivnosti orijentirane na krajobraz. Analizom prostorne razine istraživanja radova iz obaju pristupa izražen je nedostatak postojanja nacionalne tipologije krajobraza Hrvatske koja bi bila metodološko polazište za sve tipologije nižega ranga te najbitnije, upravljački alat sektorima koje zanima krajobraz. Zakonski okvir kojim je krajobraz u Hrvatskoj definiran iziskuje nacionalnu tipologiju, a istovremeno je prevelikom generalizacijom same definicije krajobraza on kao prostorna kategorija koju je potrebno vrednovati i kojom treba upravljati banaliziran. Unatoč velikom znanstvenom interesu i izdvojenim dvama pristupima istraživanje krajobraza u Hrvatskoj individualizirano je s obzirom na aspekt i interese pojedinih istraživača. Prostorna je pokrivenost RH istraživanjima krajobraza nasumična i nepovezana te je svaki dio istraženoga prostora istražen na temelju različitih podataka i metoda. Najveći je pomak kroz vrijeme u istraživanju krajobraza Hrvatske korištenje daljinskih istraživanja i GIS okružja, čime je povećana točnost analiza i mogućnost analize područja većega prostornog obuhvata.

2.2. Važeće tipologije krajobraza EU

Prva internacionalna tipologija krajobraza je “Svjetska karta krajobraza današnjice” koja je izrađena u koordinaciji United Nations Environmental Programme (UNEP). Izrađena je u mjerilu 1:50.000.000 a izdvojeno je 150 tipova krajobraza. Kao osnova za izradu korištene su satelitske snimke, regionalne tematske karte te terenska istraživanja. Obzirom na mjerilo ova je karta manjkava te se više ne koristi (Tichopádová i Romportl, 2014; Wascher, 2005).

Na Europskoj razini izrađena je tipologija Paneuropskih krajobraza u mjerilu 1:25,000,000 (Meeus, 1995). U obzir je uzeto šest kriterija uključujući klimatska i geomorfološka obilježja, održivost upravljanja, obilježja divljine, izvornost/netaknutost te slikovitost i vizualni karakter regije. Slikovitost i vizualni karakter odnose se na otvorenost ili zatvorenost krajobraza. Identificirano je 30 glavnih tipova ruralnog krajobraza. U tipologiji su isključena urbana i industrijska područja jer prema autoru ne predstavljaju prirodnu niti kulturnu baštinu, što ju čini manjkavom jer ne daje uvid u stvarno stanje krajobraza Europe (Tichopádová i Romportl, 2014).

U okviru projekta ELCAI (the European Landscape Character Assessment Initiative) izrađene su i dvije novije tipologije krajobraza. Jedna se odnosi na prirodna obilježja okoliša, a druga na kulturna (Wascher, 2005). Svrha i primjena tih tipologija je ugrađivanje u europske i nacionalne politike (Mücher i dr., 2003). Nedostatak zajedničkih kriterija i metodologija za identificiranje krajobraza i opisivanje njihovih karakteristika otežava usporedbu regionalnih ili nacionalnih vrednovanja krajobraza i bio je prepreka nekim od glavnih europskih političkih inicijativa; naime, razvoju provedbenih ciljeva za održivu budućnost Europe u širem ruralnom području (S. Mucher i Wascher, 2008).

Okolišna stratifikacija Europe (Metzger i dr., 2005) godine počiva na mnogobrojnim klimatskim podacima koji su odraz biofizičkih uvjeta na površini Zemlje. Naknadno je klasifikacija doradana s uvrštavanjem bazičnih geomorfoloških varijabli (nagibi i sl.). Kako je prva razina klasifikacije pokazala veliku heterogenost krajobraza u južnoj Europi, ostatak klasifikacije je obrađen zasebno. Rezultat je identifikacija 6 glavnih okolišnih regija te 84 okolišna sloja (Metzger i dr., 2005). Okolišna stratifikacija Europe tvori odgovarajuću stratifikaciju za slučajno uzorkovanje ekoloških resursa, odabir lokacija za reprezentativne studije diljem kontinenta i kao podloga za izvještavanje o stanju okoliša na europskoj razini. Prednosti su svakako vrlo jasno definirani kriteriji, korišteni podaci te već utvrđene statističke metode.

Europska klasifikacija krajobraza (The European Landscape Classification – LANMAP) (C. A. Mucher i dr., 2010) je kompleksna tipologija koja je osim varijabli prirodnog okoliša u obzir uzela i antropogene elemente. U ovoj tipologiji način korištenja zemljišta i zemljišni pokrov smatraju se varijablom koja predstavlja kulturne elemente krajobraza. Izdvojeno je 350 tipova krajobraza na najnižoj razini tipologije.

2.3. Krajobraz u geokološkim školama u okruženju

Neke države imaju dugu tradiciju proučavanja krajobraza unutar geografskih, točnije, nacionalnih geokoloških škola. Sukladno tome, te države uspješno provode politiku zaštite krajobraza kao potpisnice Europske konvencije o krajobrazima, što znači da imaju izrađene tipologije krajobraza, vrednovanje tipova krajobraza te smjernice za zaštitu. U Tab. 2.3.1 je dan kratki pregled pristupa izradi tipologije krajobraza te njegovog vrednovanja u Sloveniji (Perko i dr., 2015), Slovačkoj (Kozová i dr., 2007), Češkoj (Romportl i Chuman, 2012) i Mađarskoj (Csorba i dr., 2004).

Tab. 2.3.1 Pregled nacionalnih tipologija krajobraza Slovenije, Slovačke, Češke i Mađarske

Naziv dokumenta/projekta	Država	Definicija krajobraza	Metoda klasifikacije	Kriteriji	Rezultat	Vrednovanje

Determination of Natural Landscape Types of Slovenia Using a Geographic Information System	Slovenija	Krajobraz je funkcija klime, geomorfologije, hidrologije, tla, vegetacije, faune, korištenja zemljišta, strukture krajolika i vremena.	Segmentacija, decision tree method, ručna korekcija klasifikacije, validacija (classification accuracy analysis).	Reljef, litologija, klima, vegetacija	24 tipa krajobraza	Raznolikost krajobraza i svake njegove komponente korištenje u funkciji susjedstva i omjera ukupnog broja pojedinog elementa i stvarnog broja u prostornoj jedinici (1 km ² radius)
Landscape Ecology in Slovakia Development, Current State, and Perspectives	Slovačka	Krajobraz je homogena jedinica koja uzima u obzir karakter krajolika, funkcije i trenutni način korištenja zemljišta.	GIS overlay	relief type, quaternary deposits, climatic regions, and soil types on the land-cover map (CORINE Land Cover 2006 - CLC)	126 tipova krajobraza	LANDEP (Landscape ecological planning method)
Landscape Atlas of the Czech Republic	Češka	Krajobraz je dio Zemljine površine s karakterističnim reljefom, koji je stvoren kompleksom funkcionalno integriranih ekosustava i	PCA - OBIA	Klima, Geologija, Tla, Geomorfologija, Hidrografija, Potencijalna vegetacija, Rekonstruirana prirodna vegetacija, Fauna, Površinski pokrov/način korištenja zemljišta, Struktura krajobraza, Struktura i karakter naseljenosti	79 tipova krajobraza	Prirodni i antropogeni rizici, kvaliteta okoliša, prirodne i kulturne vrijednosti i krajobraz a,

		elemenata civilizacije.				
National Atlas of Hungary	Mađarska	Krajobraz je detalj Zemljine površine koji se izgledom i funkcijama razlikuje od susjednih krajobraza, funkcionalna je jedinica na čije prirodno djelovanje utječe i u kojem istovremeno sudjeluje ljudsko društvo.	GIS overlay	geologija, reljef, hidrografija, tla, vegetacija, način korištenja zemljišta	43 tipa krajobraza	promjene površinskog pokrova, intenzitet transformacije krajobraza ljudskim djelovanjem, vrijednost krajobraza, osjetljivost krajobraza na klimatske promjene,

Pristupi su generalno vrlo slični, posebice u vidu izbora kriterija za izdvajanje tipova krajobraza. U sve četiri države tipologija je bazirana na biofizičkim kriterijima koji predstavljaju primarnu strukturu krajobraza te površinski pokrov i način korištenja zemljišta kao sekundarnu strukturu tj. antropogeno djelovanje na krajobraz. Pristup se preklapa i u samim definicijama krajobraza gdje se kao primarni čimbenik krajobraza izdvaja reljef, a kao najveći modifikator i korisnik samih jedinica krajobraza izdvaja se čovjek. Važna karakteristika krajobraza je i homogenost njegovih elemenata, ali i funkcija vremena u kojoj dolazi do promjena u odnosima između elemenata krajobraza, pa tako i do samih promjena u krajobrazu općenito. U slovenskoj definiciji izdvaja se i struktura krajobraza jer ona govori o specifičnim

međudodnosima između elemenata određenog tipa krajobraza, ali i o međudodnosima pojedinih tipova krajobraza (Perko i dr., 2015). Sve navedene tipologije izrađene su korištenjem GIS alata, a Slovačka (Kozová i dr., 2007) i Mađarska (Csorba i dr., 2004) koristile su metodu preklapanja slojeva *eng. overlay* bez detaljnijeg navođenja metodologije. Broj dobivenih tipova krajobraza razlikuje se po državama, a svakako je ovisan o detaljnosti ulaznih podataka te mjerilu u kojem je izrađena tipologija. Tercijarna struktura rijetko je uvrštena kao kriterij u tipologiji zbog vrlo loših i ne dosljednih prostornih podataka.

Najveća razlika vidljiva je u vrednovanju krajobraza gdje svaka država ima svoj set pokazatelja koji su izvedeni iz tipologije krajobraza, a uvelike su ovisni o prirodi samih krajobraza. U vrednovanju se uvijek na neki način pokušava izračunati raznolikost te s druge strane potencijali, jedinstvenost, ali i ugroze.

3. ZAKONODAVNI, STRATEŠKI I PROSTORNO-PLANSKI OKVIR UPRAVLJANJA I ZAŠTITE KRAJOBRAZA

Pitanjima zaštite krajobraza u Hrvatskoj pristupa se "sektorski", sa stajališta nekoliko zakona u sklopu kojih se različito tumači njegovo određenje a to se posljedično odražava i u metodama upravljanja krajobrazom. Tome pridonosi i neusklađenost oko definicije krajobraza i pristupa krajobrazu koje trebaju zauzeti nadležne institucije. Obzirom da je krajobraz integrativan pojam, a u hrvatskom zakonodavstvu to još nije prepoznato, njegova zaštita i upravljanje u RH rascjepkani su unutar pojedinih grana kao što su zaštita kulturne baštine te zaštita prirode i okoliša, koji marginalno obuhvaćaju i pitanje krajobraza. Prostorno planiranje ima potencijal da postane kanal kojim bi se krajobraz trebao sagledavati u svojoj cijelosti (Dumbović Bilušić i Obad Šćitaroci, 2013).

Rastom znanstvenoga, stručnoga i sektorskoga interesa za ovu problematiku, koji je rezultirao prvim pokušajima izrade tipologija, krajobraz kao prostorna kategorija u Hrvatskoj i dalje nije pronašao svoj put prema nadležnim institucijama u zakonodavnom okviru zaštite okoliša i prirode te prostornoga uređenja. Potrebno je ukratko spomenuti najvažniju zakonsku regulativu jer i ona na svoj način usmjerava interese i konkretne akcije za krajobraz. U Zakonu o zaštiti okoliša (NN 80/13, 153/13, 78/15, 12/18, 118/18) i u Zakonu o zaštiti prirode (NN 80/13, 15/18, 14/19, 127/19, 155/23) rabe se pojmovi „krajobraz” i „krajobrazna raznolikost”. Da je krajobraz prepoznat kao prostorna kategorija vrijedna zaštite, dokazuje se Zakonom o zaštiti prirode (NN

80/13, 15/18, 14/19, 127/19, 155/23), gdje je kao jedna od kategorija zaštićenih područja definiran i značajni krajobraz. U toj su kategoriji zaštićena 83 područja (1,35 % teritorija RH; Biportal, 2020). Zakon navodi i krajobrazne tipove određene na temelju njihovih prirodnih ili „stvorenih” obilježja na kojima bi se trebala temeljiti zaštita krajobraza, no sektor zaštite prirode do sada nije proveo ni jednu konkretnu aktivnost na tom planu. Iako je u Zakonu o zaštiti okoliša krajobraz, u smislu sastavnice okoliša bitne za zdrav život i održivi razvitak, kao pojam vrlo banalno i ograničavajuće (na razini slike – „krajobraz je određeno područje viđeno ljudskim okom” – preuzeto iz Europske konvencije o krajobrazima) te nerazumljivo definiran, njegovo navođenje u kontekstu zaštite okoliša ipak je bitno za pravilno vrednovanje, korištenje i zaštitu. Zakon o prostornom uređenju (NN 155/25) uvažava krajobraz i krajobrazne vrijednosti kao cilj zaštite s određenim mjerama, ali provedba se ocjenjuje kao problematična (Dumbović Bilušić i Obad Šćitaroci, 2013). U Zakonu o zaštiti i očuvanju kulturnih dobara (NN 145/24, 151/25) krajobraz je djelomično obrađen kroz kulturne krajobraze i povijesne urbane krajobraze. Tu se krajobraz svrstava u nepokretna kulturna dobra (Butorac i Buzjak, 2021).

Kako je RH među prvima bila potpisnica Europske konvencije o krajobrazima, to je potvrdila i donošenjem Zakona o potvrđivanju Konvencije o europskim krajobrazima (NN 12/02). Prema (Dumbović Bilušić i Obad Šćitaroci, 2013) tim zakonom RH se obvezala na sljedeće:

- Zakonom priznati krajobraze kao bitnu sastavnicu čovjekova okruženja, izraz raznolikosti kulturnog i prirodnog naslijeđa i temelj identiteta područja;
- Uspostaviti i provoditi politike krajobraza koje za cilj imaju donošenje posebnih mjera za zaštitu i upravljanje krajobrazima;
- Omogućiti sudjelovanje javnosti, lokalne i regionalne uprave te ostalih sudionika u provedbi zaštite krajobraza;
- Ugraditi krajobraz u politike regionalnog i urbanističkog planiranja, ali i u ostale, kao što su gospodarstvo, poljoprivreda, turizam, vodoprivreda i sl., koje mogu izravno ili neizravno utjecati na krajobraz.

U cilju unaprjeđivanja znanja o vlastitim krajobrazima svaka zemlja potpisnica Konvencije obvezala se poduzeti sljedeće posebne mjere:

- prepoznavanje krajobraza na cjelokupnom teritoriju države i provođenje tipološke podjele - karakterizacije krajobraza;
- analiziranje i ocjena značajki krajobraza, pritisaka uslijed kojih se mijenjaju te praćenje promjena u krajobrazu;

- ocjena krajobraza na temelju stručnih kriterija vrednovanja, ali i onih koje im pridaje lokalno stanovništvo.

Od prethodno navedenih mjera koje je svaka potpisnica Europske konvencije o krajobrazima dužna provoditi, RH je započela s izradom tipologije i karakterizacije krajobraza, no i dalje su to samo pokušaji jer su kriteriji za izdvajanje tipova krajobraza dvosmisleni, redundantni i nisu opravdani dosadašnjim znanstvenim dostignućima u području izrade tipologije krajobraza. Druge dvije mjere (analiza i ocjena krajobraza i pritisaka te ocjena krajobraza na temelju stručnih kriterija vrednovanja) niti ne mogu biti provedene sve dok ne bude izrađena utemeljena tipologija krajobraza.

Krajobraz u nacionalnim zakonima pojedinih europskih zemalja - U europskim zemljama rijetki su primjeri da su pitanja zaštite krajobraza regulirana posebnim zakonom o krajobrazu. Postoji tek nekoliko zakona o krajobrazu na državnoj razini, i to u Italiji, Njemačkoj, Švicarskoj, Francuskoj, Češkoj i Slovačkoj (Dumbović Bilušić i Obad Šćitaroci, 2013).

3.1. Krajobrazne osnove RH

Unutar sektora strateškog planiranja, na nacionalnoj razini, krajobraz je najdetaljnije obrađen unutar strategija koje su izrađene za potrebe prostornog planiranja. To su Strategija prostornog uređenja Republike Hrvatske izrađena 1997. godine te Strategija prostornog razvoja Republike Hrvatske izrađena 2017. godine. Kao popratni produkt strategija izrađene su podloge kojima je zadatak bio obraditi krajobraz RH. Sadržajna i metoda podloga Krajobrazne osnove Hrvatske (Aničić i Koščak, 1999) i Krajolik – čimbenik strategije prostornog razvoja – stručna podloga za Strategiju prostornog razvoja Republike Hrvatske (Obad Šćitaroci i dr., 2014).

(Aničić i Koščak, 1999) krajobraz je definiraju kao dio područja izgled kojega je određen djelovanjem i međudjelovanjem prirodnih i ljudskih čimbenika, kakvim ga opaža stanovništvo, kroz perspektivu različitih lokalnih, regionalnih i nacionalnih kultura. Kao čimbenici krajobraza izdvojeni su prirodni i antropogeni. Velik je naglasak na antropogenim tj na načinu korištenja zemljišta, čime je naglašena i isključivo utilitarna vrijednost krajobraza tj kako ga čovjek koristi ili može koristiti. U tekstu se često miješaju ili koriste kao istoznačnice termini tipologije i regionalizacije, što samo studiju čini ne utemeljenom obzirom na krivo korištenje dvaju koncepata. Naime, tipologija je često korišten instrument početnog opažanja i utvrđivanja različitosti te sređivanja, komparacije i analize prikupljenih podataka (Lukić, 2012).

S druge strane, regionalizacija počiva na principu homogenosti ili uniformnosti, tj. određene jedinstvenosti. Dakle, cilj regionalizacije nije dioba prostora, kao što je to u tipologiji (Rogić, 1963). Kako je jedan od primarnih zadataka te podloge bilo izdvajanje tipova krajobraza u RH te njihovo vrednovanje, izrađena je regionalizacija krajobraza RH kojom je izdvojeno 16 regija (Bralić, 1999). Kriteriji izdvajanja su prirodna obilježja no ti kriteriji u tekstu nigdje nisu navedeni pojedinačno. Obzirom da se radi o regionalizaciji, pojavljuju se neke nelogičnosti, a to je prostorna rascjepkanost regije naziva Panonska gorja, jer izdvajanje regija počiva na principu homogenosti prostora. U dokumentu su izdvojene i smjernice za očuvanje i unaprijeđenje krajobrazne raznolikosti po prirodno-geografskim regijama Hrvatske. Regije za koje su izrađene smjernice nisu istovjetne regijama koje su izdvojene pri izradi krajobrazne regionalizacije za potrebe samog dokumenta, što je uočeno kao jedna od nelogičnosti. Izdvojeno je i poglavlje o vizualnim kvalitetama krajobraza čime se naglašava estetska vrijednost krajobraza.

U studiji Krajolik – čimbenik strategije prostornog razvoja – stručna podloga za Strategiju prostornog razvoja Republike Hrvatske (Obad Šćitaroci i dr., 2014) krajobraz je definiran kao antropogeni prostor stvoren međudjelovanjem čovjeka i njegova prirodnog okruženja. Podrazumijeva sintezu mjestopisnih (topografskih) obilježja, vegetacijskoga pokrova, korištenja zemlje, organizacije prostora, uzoraka naselja i poljodjelskih površina te povijesnih i kulturnih procesa i aktivnosti. Krajobraz se promatra i kao dio kulturne ekologije koja podrazumijeva sveukupnost ljudskog djelovanja na okoliš – sve što je stvorio ljudski rod, kao narodi, zajednice, obitelji i pojedinci. Valja istaknuti tvrdnju da: „Za razliku od okoliša koji je vanjska okolina, krajolik ne postoji izvan i bez čovjekove percepcije – on je i fizička i mentalna tvorba.“

Prostor RH pa tako i njemu pripadajuća Gorska Hrvatska nikada nisu sagledani kroz tipologiju krajobraza. Aktualna krajobrazna regionalizacija Hrvatske (Bralić, 1999) delineira krajobrazne tipove u odnosu na prirodne komponente ili primarni sastav, a kao temeljne, navode se tri komponente krajobraza (reljef, vode i vegetacija). Samo razgraničenje prostornih jedinica te kriteriji za razgraničenje u studiji nisu navedeni niti razjašnjeni. No, obzirom da se radi o regionalizaciji, ključ razgraničenja svakako je bio posebnost svake izdvojene prostorne jedinice. Nasuprot regionalizaciji, stoji tipologija kao geografska metoda organizacije i analize prostornih podataka s ciljem izdvajanja univerzalnih krajobraznih tipova usporedivih u prostoru i vremenu (Lukić, 2012).

Temeljem Zakona o potvrđivanju Konvencije o krajobrazima Vijeća Europe, Zavod za prostorni razvoj pokrenuo je u prosincu 2022. godine izradu Analitičke podloge za izradu Krajobrazne osnove Republike Hrvatske (KORH) s krajobraznim atlasom na makroregionalnoj i regionalnoj razini. Tim povodom stručni izrađivač, zajednica ponuditelja koju čine Agronomski fakultet Sveučilišta u Zagrebu i Zelena infrastruktura d.o.o. uz podršku podugovaratelja EKOMENA d.o.o., ASK Atelier d.o.o. i drugih vanjskih stručnjaka, izradio je u I. fazi Prijedlog metodološke osnove za identifikaciju i razvrstaj krajobraza na svim razinama te je u II. fazi, pored ostalog, izrađen krajobrazni atlas makroregionalne i regionalne razine (Andlar, 2025).

Prema prezentaciji izrađene tipologije krajobraza unutar KORH-a primjetno je kako sama tipologija nije geografski utemeljena, a odraz toga jest vrlo labilno korištenje termina tipologija i regionalizacija, te metodološke nejasnoće upravo oko ta dva temeljna pojma koji se odnose na diferencijaciju prostora prema određenim kriterijima. To je problem koji je detektiran i u dvije ranije krajobrazne osnove RH (Anićić i Koščak, 1999; Obad Šćitaroci i dr., 2014), no i dalje nije percipiran niti ispravljen. Kroz cijeli pristup miješaju se pojmovi tipa i regije tj. područja krajobraza. Tipologija na makroregionalnoj razini izrađena je na temelju postojećih regionalizacija prostora RH kojima su temeljne kartirane jedinice vrlo različitih prostornih rezolucija, izrađene su u različitim razdobljima, a neke su i metodološki nejasne. U konačnoj verziji, predviđena je izrada tipologije na pet ili šest razina. Kriteriji za izdvajanje tipova krajobraza na 6 razina navedeni su u Tab. 3.1.1.

Tab. 3.1.1 Kriteriji izdvajanja tipova krajobraza (Andlar, 2025)

Razina tipologije	Kriteriji izdvajanja
makroregionalna	klima, hidrogeologija, megareljef, prirodno-geografske regije i bioekološke regije
regionalna	(hidro)geologija, hidrologija, reljef, kulturne regije, površinski pokrov Corine Land Cover 1. razina i šumska vegetacija/zajednice
mikroregionalna	hidrologija, mezoreljef, pedologija, pokrov i namjena korištenja Corine Land Cover 2. razina, prirodno-geografske mikroregije i tipovi naselja
područna	hidrologiji, mikroreljefu, pedologiji, pokrovu i namjeni korištenja zemljišta Corine Land Cover 2. i 3. razina, tipu poljoprivrednog krajobraza, tipu naselja i ostalih izgrađenih područja te staništima 1. razine

lokalna	hidrologiji, mikoreljefu, pedologiji, pokrovu i namjeni korištenja zemljišta Corine Land Cover 3. i 4. razina, tipu poljoprivrednog krajobraza, tipu naselja i ostalih izgrađenih područja te staništima 2. razine
lokalitet	hidrologiji, mikoreljefu, pedologiji, pokrovu i namjeni korištenja zemljišta Corine Land Cover 3 i 4. razine, tipologiji poljoprivrednih površina, tipologiji naselja i ostalih izgrađenih područja te staništa 2. razine

Tipovi (generički) i područja (jedinstvena) razlikuju se u metodologiji samo prema izvođenju nomenklature. Primjetna je banalizacija fizičko-geografskih kriterija za izdvajanje krajobraza, jer se ponavljaju na nekoliko razina te za njih nema razjašnjenih indikatora, dok je nasuprot njima npr. kriterij staništa 2. razine vrlo detaljan. Hidrologija, reljef/mezoreljef/mikoreljef, pedologija su vrlo široki pojmovi te se neki od njih odnose na cijele znanstvene discipline. Kriteriji su vrlo različiti po detaljnosti. Tematska rezolucija podataka te prostorna rezolucija podataka na svim razinama izdvajanja krajobraza u Andlar (2025) nisu odgovarajuće za provođenje prostornih tipologija. Upravo načelo ponovljivosti svake tipologije kako bi bilo moguće pratiti stanje pomoću indikatora, ovdje nije zadovoljeno.

4. TEORIJSKA POLAZIŠTA

4.1. Pojam i definicija krajobraza

Mnogobrojne su definicije pojma krajobraz, a svaka od njih ovisi o profesionalnoj pozadini onoga tko ju piše. Razlika u definicijama otežava jasnu komunikaciju, a još je teže uspostaviti dosljedne politike upravljanja. Definiranje i jednoznačno tumačenje pojma krajobraz prvi je uvjet ispravne analize i identifikacije krajobraza. Bez obzira na mnogobrojne struke kojima je krajobraz od interesa, krajobraz se uvijek definira kao dio prirode tj. dio površine Zemlje. Tako je razvoj krajobraza započet razvojem planeta Zemlje i njezine litosfere. Utjecaji na litosferu su mnogobrojni, a dolaze iz unutrašnjosti Zemlje, ali i iz kontakta litosfere sa svim ostalim sferama (hidrosfera, pedosfera, biosfera i atmosfera). Sve te sfere u svom kontaktu i ispreplitanju čine krajobraznu sferu (Demek, 1978; Krcho, 1978). Međusobne interakcije u krajobraznoj sferi gdje su pojedine sfere u kontaktu manifestiraju se u raznolikosti krajobraza prema geometrijskim i položajnim svojstvima kroz tokove tvari i energije, te prirodne (fizičke,

kemijske i biološke) procese. Prisustvo čovjeka na Zemlji rezultiralo je promjenama krajobraza jer čovjek krajobraz koristi kao mjesto za život, rekreaciju, kulturu, političko i ekonomsko djelovanje (Kozová i dr., 2007).

Čak i unutar pojedinih znanstvenih disciplina dolazi do velikih razlika u definiranju krajobraza, a ona ključna razlika je u tom je li krajobraz samo fizička stvarnost ili je nešto više od toga, tj. ogledalo identiteta, povijesti i općenito ljudskog doživljaja tog fizičkog prostora. Takva definicija krajobraza naziva holističkim entitetom, a karakteristična je za jedan dio geografskih istraživanja (Antrop i Van Eetvelde, 2017). Fizičkogeografsko definiranje i poimanje krajobraza više je u skladu s definicijom krajobrazne ekologije, gdje je krajobraz heterogeno područje Zemljine površine sastavljeno od klastera ekosustava u međusobnoj interakciji koji se ponavljaju u sličnoj formi u prostoru. Krajobrazi variraju u veličini (od kilometra u promjeru na više). Nadalje, krajobraz je jasna, mjerljiva prostorna jedinica definirana prepoznatljivim i prostorno repetitivnim klasterom ekosustava, geomorfoloških obilježja i režima poremećaja koji su u međusobnoj interakciji (Forman i Godron, 1986).

S fizičkogeografskog gledišta, krajobraz se tumači kao materijalni entitet, odnosno stvarni krajobraz koji se sastoji od abiotičkih, biotičkih i antropogenih oblika korištenja zemljišta i objekata koje su stvorili ljudi, dok su ljudska aktivnost i ljudsko društvo važni čimbenici. U geografiji, takav krajobraz predmet je istraživanja, procjene i planiranja. Ljudsko društvo kao takvo (socioekonomska sfera) nije predmet istraživanja krajobraza. Međutim, društvo je određeno prirodnim uvjetima na različitim razinama, te analogno ima velik utjecaj na krajobraz i njegove prirodne sastavnice (Forman i Godron, 1986; Kozová i dr., 2007; Simensen i dr., 2021; Turner, 1989).

Obzirom na obilju definicija krajobraza, izdvojena je ona koja odražava fizičkogeografski pristup proučavanju krajobraza. (C. A. Mucher i dr., 2010) razvio je jednostavnu teoretsku jednadžbu za krajobraz, iz koje se može izvesti i definicija krajobraza kao funkcija više varijabli, prema kojoj je krajobraz funkcija klime (C), geomorfologije (G), hidrologije (H), tala (S), vegetacije (V), faune (F), načina korištenja zemljišta (LU), strukture krajobraza (STR) i vremena (T).

$$\text{Krajobraz} = f_C(t), G(t), H(t), S(t), V(t), F(t), LU(t), STR(t)_.$$

Krajobraz je lakše razumjeti i definirati kroz razumijevanje procesa geneze krajobraza. U genezi krajobraza primarni su geomorfološki procesi koji se odvijaju kroz određen, relativno dugačak period u odnosu na životni vijek čovjeka, nakon kojih slijede obrasci kolonizacije

organizama te lokalni poremećaji pojedinih ekosustava u kraćem vremenskom periodu (u odnosu na čovjekov životni vijek) (Forman i Godron, 1986).

4.2. Struktura krajobraza


Toblerov prvi zakon u geografiji koji kaže kako je sve povezano sa svime, ali su bliži objekti više povezani nego dalji naglašava važnost udaljenosti i povezanosti (Tobler, 1970). Odnosi u krajobrazu proizlaze iz interakcije među komponentama krajobraza. Ti odnosi mogu biti deterministički ili stohastički, stabilni ili varijabilni. Ti odnosi stvaraju prostornu ili funkcionalnu koherenciju. Odnosi u krajobrazu definiraju heterogenost i raznolikost, ali ti isti odnosi ovise o prostornoj konfiguraciji komponenti krajobraza. Odnosi u krajobrazu mogu biti vertikalni ili horizontalni (Antrop i Van Eetvelde, 2017).

Koherencija u krajobrazu povezuje se s redom/hijerarhijom te se razlikuje vertikalna i horizontalna koherencija. Horizontalna koherencija je topološka dok je vertikalna koherencija geokološka (Antrop i Van Eetvelde, 2017). Koherencija među komponentama krajobraza jest struktura krajobraza koja se onda isto tako dijeli na horizontalnu i vertikalnu strukturu. Vertikalnu strukturu krajobraza moguće je identificirati provođenjem tipologije krajobraza u naj većem mogućem mjerilu gdje se izdvajaju geotop/element krajobraza/econ/ekosustav/uzorak krajobraza istih značajki, kao na Sl. 1.3.1-a gdje su razgraničene prostorne jedinice jedinstvene/homogene vertikalne strukture. Horizontalna struktura krajobraza dijeli se još na kompoziciju i konfiguraciju koje je moguće determinirati prostornim analizama u GIS okruženju i/ili metrikom krajobraza.

Struktura krajobraza su prostorni odnosi među prepoznatljivim ekosustavima ili prisutnim „elementima krajobraza“ - točnije, raspodjela energije, materijala i vrsta u odnosu na veličine, oblike, brojeve, vrste i konfiguracije ekosustava (McGarigal i Marks, 1995).

Kako bi se prikazala koherencija/struktura u krajobrazu koristi se pokazatelj korelacije no kako se time ne prikazuje uzročno-posljedična veza i analiza regresije koristi se za prikaz koherencije. Točnost analize koherencije, kao i u svim dijelovima analize krajobraza ovisi o točnosti i prostornoj rezoluciji podataka na kojima je analiza temeljena (Antrop i Van Eetvelde, 2017).

Osnovni gradbeni elementi strukture krajobraza ovise o tome koji model krajobraza je primijenjen u istraživanju. Najčešće korišten je model uzorak-koridor-matriks (Forman i Godron, 1986) obzirom da je najkompatibilniji za primjenu u računalnim programima (npr. GIS i Fragstats). Postoji nekoliko modela krajobraza, a u fizičkogeografskom (geoekološkom) koristi se model element, komponenta, struktura. Elementi ovise o mjerilu analize, ali oni mogu biti predstavljeni kao drvo ili šuma, tj. pojedinačne kuće ili naselja itd. Komponente su fenomeni koji kontinuirano variraju kroz prostor i rijetko imaju vrlo jasne rubove i granice. To su primjerice nagibi, ekspozicija i nadmorska visina terena, tlo, hidrografski uvjeti, klimatska obilježja. Struktura je način na koji su elementi i/ili komponente povezani prostorno i/ili funkcionalno. (Antrop i Van Eetvelde 2017).



Sl. 4.2.1 Vertikalna i horizontalna struktura krajobraza, prilagođeno prema (Antrop i Van Eetvelde, 2017). Na slici a) prikazana je vertikalna struktura krajobraza, a brojevima od 1-12

označene su najmanje prostorne jedinice homogene vertikalne strukture (econ, geotop, element krajobraza, ekosustav itd). Na slici b) prikazana je horizontalna struktura vegetacije kao jednog elementa vertikalne strukture krajobraza, na slici c) prikazana je horizontalna struktura tala kao jednog od elementa vertikalne strukture krajobraza i na slici d) prikazana je horizontalna struktura litologije tala kao jednog od elementa vertikalne strukture krajobraza.

4.2.1. Vertikalna struktura krajobraza

Proučavajući svaki element vertikalne strukture krajobraza zasebno, omogućuje se lakša i transparentnija daljnja analiza krajobraza i odnosa između pojedinih komponenti (Sertel i dr., 2018). Opisivanje, kartiranje i analiza krajobraza postaju lakši i jasniji kada se krajobraz rastavi na vertikalne komponente te kada se ograniči prostorno (topološki). Vertikalna struktura temelj je klasifikacije krajobraza, tj. u slučaju ovoga rada, temelj je izrade tipologije krajobraza

Najmanja prostorna jedinica na kojoj se proučava vertikalna struktura je *geotop/element krajobraza/econ/ekosustav/uzorak krajobraza*. Econ je heterogen u vertikalnoj strukturi, a istovremeno je horizontalno homogen. U vertikalnoj strukturi izdvajaju se atmosfera, biosfera, hidrosfera, antroposfera, pedosfera, geomorfosfera i litosfera. Različiti autori na različite načine nazivaju komponente vertikalne strukture, a najčešći naziv za dijelove vertikalne strukture krajobraza su ili sfere ili geokomponente (Bastian i dr., 2002; Hubrich, 1993). Sfere ili geokomponente vertikalne strukture krajobraza prirodno (ne oštro) graniče tj. na nekim mjestima se i prožimaju. Krajobrazni ekolozi koriste nekoliko termina za označavanje osnovnih elemenata ili jedinica koje čine krajobraz, uključujući ekotop, biotop, krajobraznu komponentu, krajobrazni element, krajobraznu jedinicu, krajobraznu ćeliju, geotop, facijes, stanište i lokalitet (Forman i Godron 1986).

4.2.2. Horizontalna struktura krajobraza

Horizontalna struktura krajobraza zbirni je naziv za kompoziciju i konfiguraciju krajobraza. Bez razgraničenja krajobraza na temelju vertikalne strukture, nije moguće proučavati niti kvantificirati horizontalnu strukturu krajobraza. Proučavanjem kompozicije i konfiguracije krajobraza, moguće je kvantificirati horizontalnu strukturu krajobraza te pratiti stanje i promjene. Kompozicija krajobraza govori nam o tome koliko različitih uzoraka i/ili klasa se

nalazi u proučavanom krajobrazu, dok konfiguracija govori o odnosima i međuovisnostima između klasa i/ili uzoraka (Botequilha-Leitão i dr., 2006; Butorac i Buzjak, 2021; Mitchell i dr., 2015).

Kompozicija krajobraza odnosi se na značajke povezane s prisutnošću i količinom svake vrste uzorka unutar krajobraza, ali bez prostorne eksplicitnosti. Drugim riječima, kompozicija krajobraza obuhvaća raznolikost i obilje uzoraka unutar krajobraza, ali ne i smještaj ili lokaciju uzoraka unutar mozaika krajobraza. Kompozicija krajobraza važna je za mnoge ekološke procese i organizme. Postoje mnoge kvantitativne mjere kompozicije krajobraza, uključujući udio krajobraza u svakoj vrsti uzorka, bogatstvo uzorka, ujednačenost uzorka i raznolikost uzorka. Doista, zbog mnogih načina mjerenja raznolikosti, postoje doslovno stotine mogućih načina kvantificiranja kompozicije krajobraza.


Konfiguracija krajobraza odnosi se na fizičku raspodjelu ili prostorni karakter uzoraka unutar krajobraza. Neki aspekti konfiguracije, poput izolacije uzorka ili eng. *contagion* (zaraze) područja, mjere su smještaja tipova uzoraka u odnosu na druge tipove uzoraka, granice krajobraza ili druge značajke od interesa. Drugi aspekti konfiguracije, poput oblika i površine jezgre, mjere su prostornog karaktera uzorka. Konfiguracija se može kvantificirati korištenjem statistike u smislu najmanje kartirane krajobrazne jedinice (tj. uzorka). Metrika krajobraza na razini uzoraka (na primjer, srednja površina jezgre uzorka ili srednji oblik uzorka) prostorno eksplicitne na razini pojedinačnog uzorka. Takve metrike predstavljaju prepoznavanje da su ekološka svojstva uzorka pod utjecajem okolnog susjedstva (na primjer, rubni efekti) i da na veličinu tih utjecaja utječu veličina i oblik uzorka. Ove metrike jednostavno kvantificiraju, za krajobraz u cjelini, prosječne karakteristike uzoraka ili neku mjeru varijabilnosti u karakteristikama uzorka (McGarigal, 2013; McGarigal i Marks, 1995).

4.3. Tipologija krajobraza

Geografski prostor je kontinuum u kojem je moguće više ili manje razgraničiti prostor. Način razgraničenja ovisi o svrsi razgraničenja kao i o dostupnim podacima i njihovoj kvaliteti. Osim samog razgraničenja, izrađuje se i hijerarhija prostornih jedinica. Razgraničenje i izrada hijerarhije u jednom naziva se klasifikacija. Kako je krajobraz kompleksan prostorni pojam tako je i klasifikacija krajobraza kompleksna i iziskuje izradu više klasifikacija (geološka, geomorfološka, vegetacijska obilježja i dr). Nekada su granice krajobraza teško vizualno

uočljive ili su uočljive nakon analize „iz zraka“ to jest pogledom odozgo. Te granice nisu oštre niti linearne. Krajobrazi su prostorno organizirani hijerarhijski, a svaka manja jedinica krajobraza dio je integrirane veće jedinice krajobraza. O mjerilu proučavanja ovisi na koji način i u kojoj veličini će granice biti determinirane. Hijerarhija krajobraza započinje u najmanjoj krajobraznoj jedinici koja je homogena u vertikalnoj strukturi, a naziva se geotop ili ekotop. U geotopima je vrlo uska prostorna i funkcionalna korelacija između komponenti (Hubrich, 1993). Komponente u geotopu, ali i bilo kojoj većoj jedinici krajobraza s pomoću kojih je moguće plošno razgraničiti krajobraze dio su horizontalne strukture krajobraza.

Klasifikacija krajobraza sinteza je klasifikacija pojedinih komponenti vertikalne strukture krajobraza. Dva su osnova pristupa klasifikaciji krajobraza a to su tipologija i korologija ili regionalizacija. Tipologija je klasifikacija objekata u grupe ili tipove koji su jasno različiti međusobno prema atributima/kriterijima na kojima je temeljena tipologija. Tipologija nije prostorno uvjetovana te se različito provodi za kontinuirane i diskretne objekte. Često je hijerarhijski strukturirana prema razini generalizacije ili mjerilu. Korologija ili regionalizacija uzima u obzir geografski kontekst tipova krajobraza i njihov prostorni razmještaj. Spaja tipove u nadređene prostorne jedinice koje se u geografiji nazivaju regijama. Regije su jedinstvene, dok su tipovi ponovljivi u prostoru. Razlika između tipologije i korologije ilustrirana je na Sl. 4.3.1.



Sl. 4.3.1 Razlika između tipologije i korologije, A, B, C, D, E, F su tipovi krajobraza, I, II, III, IV su regije. Isti tipovi krajobraza mogu se pojavljivati u različitom prostornom kontekstu. Korologija prepoznaje konfiguraciju krajobraza. Prema (Antrop i Van Eetvelde, 2017).

Tipologija metodološki može biti izrađena podjelom cjeline na manje dijelove ili agregacijom sličnih manjih cjelina u veće. Drugi naziv za podjelu je segmentacija, a za agregaciju klastering (*eng. clustering*). Segmentacija je svojstvena u fotointerpretaciji i daljinskim istraživanjima tj.

pogledom odozgo, a klastering koristi setove atributa/parametara/kriterija (Antrop i Van Eetvelde, 2017).

Tipologija krajobraza može se provoditi trima osnovnim metodološkim pristupima: (1) holističke tipologije – temeljene na općoj percepciji krajobraza od strane stručnjaka, dionika ili donositelja odluka (npr. Antrop i Van Eetvelde, 2000; Palang i dr., 2006); (2) višekriterijske klasifikacije čimbenika krajobraza koju (npr. Meeus, 1995) i konačno (3) kvantitativne tipologije – obrađene matematičkim i statističkim metodama korištenjem GIS alata (Metzger i dr., 2005; Mücher i dr., 2003; Van Eetvelde i Antrop, 2009). Širok raspon metodoloških pristupa koristi se za definiranje tipova krajobraza kao i različitih čimbenika krajobraza (Romportl i Chuman, 2012).

Svaka tipologija je izrađena za određenu svrhu i zato odabire različite čimbenike okoliša i daje im različit značaj, prema definiranim ciljevima tipologije. Tipologije prirodnih krajobraznih tipova stoga logički ne koriste podatke o kulturnim čimbenicima; a s druge strane, tipologije krajobraza prema načinu korištenju zemljišta često izostavljaju ostale elemente vertikalne strukture krajobraza. (Romportl i Chuman, 2012).

Podaci o kulturnim, povijesnim, arheološkim, arhitektonskim i estetskim značajkama su vrlo fragmentirani, često specifični za određene lokalitete. Rijetko imaju dosljednu pokrivenost cijele zemlje s dovoljno detalja i kvalitete da bi se integrirali u nacionalnu klasifikaciju krajobraza (Simensen i dr., 2021; Van Eetvelde i Antrop, 2009).

Kao jedan od najvećih problema u definiranju krajobraznih tipova ističu se pogrešne početne postavke, nejasno definirani ciljevi i svrha. Tipologije krajobraza moraju se izrađivati prema jasno definiranim kriterijima te kao takve mogu služiti kao zajednička osnova za analize različitih dionika. Materijalno razumijevanje krajobraza preuzeto iz krajobrazne ekologije i geografije nudi takvu mogućnost karakteriziranja primjenom dosljednoga skupa kriterija koji dobivene krajobrazne tipove čine pogodnim za analize krajobraza na velikim površinama. Takav pristup dobra je podloga za komunikaciju o krajobrazima i procjenu stanja te donošenje odluka (Erikstad i dr., 2015). Kvaliteta i ispravnost analize ovise o znanju stručnjaka koji ju provodi i/ili o znanstvenoj ispravnosti podataka koji podliježu analizi. Kvaliteta podataka određuje identifikaciju krajobraza, mogućnost provjere i objektivizacije rezultata.

Tipologija prostora često je primjenjivana metoda geografskih i srodnih istraživanja. Jednu definiciju tipologije navodi i (Lukić, 2012). Tijekom pisanja ovoga rada, uz uvažavanje spomenutoga doprinosa A. Lukića, nastala je sljedeća definicija tipologije i definiran je plan

njene izrade. U ovom radu tipologija krajobraza definira se kao geografska metoda organizacije i analize prostornih podataka s ciljem izdvajanja univerzalnih krajobraznih tipova usporedivih u prostoru i vremenu. Etape izrade tipologije su: inventarizacija prostornih elemenata (pojava, procesa i veza), njihova klasifikacija i interpretacija (s obzirom na attribute, funkcije i prostorne odnose), simplifikacija i kodiranje te odabir i rangiranje prema važnosti. Njihovom se kombinacijom na temelju unaprijed zadanih kriterija izdvajaju prostorni tipovi tj. tipovi krajobraza različitih razina. Odabir kriterija u navedenom procesu ovisan je o namjeni tipologije i njezinoj primjeni u istraživanjima, planiranju korištenja prostora i sl.

4.4. Vrednovanje krajobraza

Koncept indikatora dolazi iz znanosti o okolišu (*eng. environmental sciences*) te se odnosi na numeričku vrijednost koja pomaže razumijevanju stanja okoliša ili neke njegove komponente. To su kvantitativne varijable mjerene kroz vrijeme koje pokazuju stanje okoliša u predefiniranom geografskom mjerilu. Kombinacijom standardnih varijabli može biti konstruiran indeks. Uobičajena je praksa u okolišnim znanostima različite varijable i/ili indekse grupirati u kriterije. Kriteriji služe za donošenje odluka u analizama tj. daju mjeru kvalitete značajnu za donošenje odluka. Kriteriji mogu biti kvantitativni ili kvalitativni. Provođenje vrednovanja krajobraza mora ispuniti određene uvjete primjerice da su vrijednosti bazirane na determiniranim kriterijima, a kriteriji opisuju svojstva i kvalitete krajobraza. Često kriteriji indiciraju svojstva i kvalitete krajobraza koje nisu direktno mjerljivi.

Jedan od načina vrednovanja krajobraza je i određivanje karaktera krajobraza (*eng. landscape character assessment*) a odnosi se na holističku sintezu svi konstituirajućih komponenti krajobraza. Ta metoda zaživjela je kao produkt konvencije o krajobrazima, a osmišljena je u Velikoj Britaniji (Swanwick, 2002) s fokusom na ruralna područja. Metoda određivanja karaktera krajobraza opisuje što je tipično za neki krajobraz, a ne vrednuje njegove kvalitete niti se donose ocijene o utilitarnosti krajobraza (Antrop i Van Eetvelde, 2017).

U ovome radu provodit će se vrednovanje krajobraza temeljeno na kvantitativnim varijablama koje ukazuju na intrinzične i okolišne vrijednosti krajobraza. Obzirom da je i sama tipologija orijentirana na prostornu stvarnost, a ne percepciju krajobraza, iz takve tipologije ne mogu se vrednovati vrijednosti krajobraza poput kulturne, povijesno-okolišne, rekreacijske, spiritualne i sl.


4.5. Metrika krajobraza

Metrika krajobraza mjeri i opisuje prostornu strukturu uzoraka eng. *patches*, klasa eng. *classes of patches* i cijelih krajobraza. Metrikom se dobiva slika o kompoziciji i konfiguraciji krajobraza ili horizontalnoj strukturi pojedinih komponenti krajobraza (Botequilha-Leitão i dr., 2006). Vrijednost metrike je u mogućnosti usporedbe alternativnih krajobraza ili njegovih komponenti, vrednovanju istog krajobraza u različitom vremenskom okviru ili u usporedbi jednog krajobraza u različitim razvojnim scenarijima (Gustafson, 1998).

Metrika krajobraza može se definirati na tri razine, a to su; razina krajobraza, klase i uzorka. Metrika na razini uzorka izračunava se za pojedinačne uzorke koje predstavljaju diskretna područja sličnih karakteristika. Metrika na razini klase izračunava se iz svih uzoraka određene klase. Metrika na razini krajobraza kombinacija je svih tipova klasa i uzoraka u određenom području (McGarigal, 2013; Sertel i dr., 2018).

U pokazateljima metrike krajobraza koji su mnogobrojni velika je redundancija, a mogu bit i zbunjujući za interpretaciju. S druge strane, pokazatelji metrike krajobraza korisni su u kvantifikaciji konfiguracije i kompozicije krajobraza koji su determinirani istom metodologijom i istim setom podataka (Antrop i Van Eetvelde, 2017).

Metrika krajobraza koristi se za pružanje objektivne i kvantitativne mjere horizontalne strukture krajobraza, usporedbu s drugim krajobrazima i promjene tijekom vremena te donošenje zaključaka o ekološkim procesima u određenom krajobrazu.



Sl. 4.5.1 Primjer analize metrike krajobraza od prostornog podatka do pokazatelja metrike

5. METODE I MATERIJALI

5.1. Izdvajanje područja istraživanja


Obilježje regije, po kojem god kriteriju se ona izdvajala je to da čini kontinuirani/neprekinuti prostor koji ima određene zajedničke značajke. Uzevši u obzir tradicionalno poimanje Gorske Hrvatske, nedostajale su konkretne granice u prostoru te su određeni dijelovi prostora koji imaju slične fizičkogeografske značajke bili izostavljeni.

Za identifikaciju fizičko-geografske regije Gorske Hrvatske provedena je analiza korištenjem Geografskog informacijskog sustava (u daljnjem tekstu GIS). U većini višekriterijskih analiza planinskih područja u Europi, uz nadmorsku visinu kao glavni kriterij uzimaju se u obzir i dodatni kriteriji poput klimatskih karakteristika i specifičnih geomorfoloških kriterija (Pantić, 2015). U hrvatskom Zakonu o brdsko-planinskim područjima (NN 118/2018), osnova za određivanje takvih područja su administrativne jedinice, dok ovaj rad ima za cilj odrediti fizičko-geografsku regiju koja je kontinuirana. Stoga su kriteriji prema kojima je identificirano područje istraživanja bili nadmorska visina veća od 500 m n.v., klimazonalna vegetacija koja odgovara planinskoj klimazonalnoj vegetaciji, a za završno izdvajanje preciznih granica korištena je karta grebena i talvega. S istočne strane, granicu dijelom predstavlja i državna granica s Bosnom i Hercegovinom. Na SZ granica je određena ručno prema karti talvega i grebena.

5.2. Daljinska istraživanja

U svrhu kartiranja površinskog pokrova provedena je metoda nadzirane klasifikacije satelitskih snimaka korištenjem QGIS 3.28.5, ArcGISPro 3.4.2 i The Sentinel Application Platform (dalje u tekstu: SNAP) 11.0. generalizirana shema metodologije daljinskih istraživanja provedenih u ovom radu prikazana je na Sl. 5.2.1. Dostupnost podataka i prostorna rezolucija podataka bili su glavni faktori u odabiru satelitskih snimaka, a Sentinel-2A ispunjavao je oba kriterija. U ovom radu, satelitske snimke Sentinel-2A korištene su za kartiranje površinski pokrov u Gorskoj Hrvatskoj. Sentinel-2A snimke, besplatne su satelitske snimke Europskog Svemirskog Programa (ESA – European Space Program), dostupne kroz COPERNICUS platformu (www.copernicus.eu) te imaju prostornu rezoluciju od 10 m, koja je pogodna za kartiranje površinskog pokrova u regionalnom kontekstu. Glavne karakteristike prostorne i spektralne

rezolucije Sentinel-2A snimaka mogu se pronaći na poveznici <https://docs.sentinel-hub.com/api/latest/data/sentinel-2-l2a/>.



Sl. 5.2.1 Generalizirana shema metodologije nadzirane klasifikacije Sentinel-2A snimaka

Sentinel-2A snimke preuzete su kroz dodatak Semi-Automatic Classification Plug-in (dalje u tekstu: SCP) (Congedo, 2021) u QGIS-u. Snimke su radiometrijski korigirane korištenjem Sen2core modula SNAP programa, gdje je provedena transformacija snimaka iz koordinatnog sustava Univerzalni Transverzalni Merkator (UTM) zona 33 u Hrvatski Terestrički Referentni Sustav (HTRS) te konverzija svih kanala snimaka u prostornu rezoluciju 10x10 m.

Obzirom na planinski karakter prostora istraživanja, prisutan je velik broj dana s naoblakom. Tijekom ljetnih mjeseci, naoblaka je najmanja. Nadalje, obzirom na veličinu prostora dolazilo je do poteškoća s pronalaskom snimaka s minimalnom naoblakom tijekom istog vegetacijskog perioda. Nakon pregleda snimaka, snimke iz ljeta 2020. odabrane su kao najpovoljnije za analizu.

Faze rada u daljinskim istraživanjima su predobrada, obrada i validacija podataka. Obzirom na veličinu područja, nije bilo moguće pronaći snimke istog datuma sa sličnim atmosferskim uvjetima i minimalnom naoblakom. Korištene su snimke različitih datuma, a njihovi nazivi, datumi i kut upada sunčevih zraka navedeni su u Tab. 5.2.1.

Tab. 5.2.1 Sentinel-2A snimke korištene u kartiranju površinskog pokrova Gorske Hrvatske

Naziv snimke	Datum snimanja	Kut upada sunčevih zraka
S2A_20200721T095041_T33TXJ	21.7.2020.	265.547.320.785.883
S2A_20200721T095041_T33TWK	21.7.2020.	278.246.076.995.778
S2A_20200721T095041_T33TWJ	21.7.2020.	270.645.756.787.713
S2A_20200912T100044_T33TVL	12.9.2020.	430.634.678.556.331
S2A_20200721T095041_T33TXK	21.7.2020.	273.257.354.717.439
S2A_20200721T095041_T33TWL	21.7.2020.	285.908.462.325.866
S2A_20200721T095041_T33TVK	21.7.2020.	283.408.545.736.689

Obzirom na preklapanje snimaka, različite datume snimanja, te kapacitet računalne opreme na raspolaganju, snimke su obrađivane pojedinačno. Digitalni ortofoto Državne Geodetske Uprave za godine 2019/2020 (dalje u tekstu: DOF 19/20) i topografska karta Republike Hrvatske u mjerilu 1:25000 korištene su kao referentne podloge.

Tri atmosferska kanala (1,9 i 10) nisu korišteni obzirom da se radi o klasifikaciji površinskog pokrova, a spomenuti kanali služe za monitoring atmosferskih uvjeta. Uz kanale satelitskih snimaka izračunati su i korišteni različiti indeksi koji osiguravaju da spektralni signal postane jednostavniji te lakše razdvojiv u daljnjoj interpretaciji. Od izračunatih indeksa: Normalized Difference Vegetation Index (NDVI), Soil-Adjusted Vegetation Index (SAVI), Leaf area index (LAI), Enhanced Vegetation Index (EVI), Normalized Difference Water Index (NDWI), NDVI

i SAVI su odabrani za korištenje u daljnjim koracima obrade snimaka, tj. analize razdvojitosti spektralnog signala. NDVI je indeks široke upotrebe koji je adekvatan za kvantifikaciju zelene vegetacije (Bhandari i dr., 2012). NDVI se računa kao omjer refleksije crvenog kanala (Red) i blizu infracrvenog kanala (NIR) kako je prikazano u Formuli 1. Vrijednosti NDVI indeksa u vrlo gustoj vegetaciji su pozitivne, dok su izgrađena područja i voda izraženi s vrijednostima bliže nuli i negativnim vrijednostima (Viana i dr., 2019). Prema Braun and Herold 2004 NDVI je:

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

SAVI indeks je vegetacijski indeks koji umanjuje svjetlinu tla korištenjem korektivnog faktora svjetline tla. Kreće se u vrijednostima od -1 do 1. Kao i NDVI, računa se kao omjer između refleksije crvenog kanala (Red) i bliskoinfracrvenog (NIR) s dodatkom konstante L kako je prikazano u Formuli 2. Generalno, L=1 za područja bez zelene vegetacije, L=0.5 za područja s umjereno zelenom vegetacijom i L=0 za područja s vrlo visokim/gustim vegetacijskim pokrovom (Huete, 1988). Prema Huete 1988 SAVI je:

$$SAVI = \frac{NIR - Red}{NIR + Red + L} \times 1 + L \quad (2)$$

Za potrebe ovog rada konstanta L je definirana kao 0.5. U kombinaciji s drugim kanalima, NDVI i SAVI korišteni su u prvoj razini klasifikacije snimaka kako bi se pojačao signal vegetacije u odnosu na druge ne vegetacijske klase. Statističkom analizom razdvojitosti signala tijekom konstrukcije parametara za izdvajanje vegetacije, upravo su dva spomenuta indeksa pokazala najbolje rezultate. Na drugoj razini klasifikacije snimaka, samo je NDVI indeks korišten u kombinaciji s primarnim kanalima snimaka, kako bi bila provedena klasifikacija različitih klasa vegetacije (travnjaci, šume itd).

Klasifikacija je provedena korištenjem kombinacija kanala satelitskih snimaka i spomenutih indeksa (Tablica x) u SCP modulu QGIS-a. Prvotna faza treninga modela odrađena je korištenjem metode *region of interest* (u daljnjem tekstu: ROI) gdje se poligoni za trening klasifikatora is crtavaju rukom stručnjaka/provoditelja nadzirane klasifikacije. Nakon iterativnog procesa treninga korištenjem ROI-a, izračunate su i analizirane spektralne udaljenosti svake klase. Prva razina klasifikacije, nakon provođenja treninga je izdvajanje dviju klasa, a to su vegetacija i sve ostalo (antropogene površine, vode, golo tlo, stijena itd). Trening

je provođen na desetke puta s različitim kombinacijama kanala i indeksa dok nije dobivena povoljna spektralna udaljenost između te dvije klase.

Kada su rezultati spektralne udaljenosti dviju spomenutih klasa bili zadovoljavajući, provedena je nadzirana klasifikacija u tri verzije, tj. korištenjem tri različite metode klasifikacije, a to su: *Minimum Distance to Mean*, *Spectral Angle Mapping* i *Maximum Likelihood*. Nakon provedene prve razine klasifikacije, prostor istraživanja klasificiran je u područja prekrivena vegetacijom te područja s ne-vegetacijskim pokrovom (antropogene površine, vode, golo tlo, izdanci stijena). Sljedeći korak je razdvajanje svih snimaka s pripadajućim kanalima na dijelove snimaka s vegetacijom i dijelove snimaka bez vegetacije. Nakon rezanja (eng. *clip*) snimaka na dijelove s vegetacijom i dijelove bez vegetacije, daljnja klasifikacija odrađena je zasebno jer je ova vrsta pristupa dala bolje rezultate pri analizi spektralne odvojivosti klasa. Klase i kombinacije kanala i indeksa kojima su klase odvojene navedene su u Tab. 5.2.2 Proces klasifikacije ponovljen je tri puta: prvi put za odvajanje sve vegetacije od svih ostalih klasa, drugi put za detaljniju klasifikaciju vegetacije (šume, travnjaci itd.) i treći put za klasifikaciju svih ostalih klasa (izdanci stijena, antropogena područja itd.). Takva obrada olakšava daljnju diferencijaciju klasa površinskog pokrova na temelju satelitskih snimaka, jer je raspon vrijednosti refleksije svake klase manji, manji je i šum refleksije drugih klasa, a analiza postaje specijaliziranija.

Tab. 5.2.2 Sekvenca nadzirane klasifikacije sa specificiranim produktima (klasama površinskog pokrova) te kombinacije kanala i indeksa korištenih u svakoj sekvenci klasifikacije

1. razina klasifikacije			
Klase		Kombinacija kanala i indeksa	
Vegetacija i Ostalo		NDVI	
		SAVI	
		Kanal 8	
2. razina klasifikacije			
Klase	Kombinacija kanala i indeksa	Klase	Kombinacija kanala i indeksa
Travnjaci / Šume /	NDVI	Vodene površine / Izdanci	Kanal 8
Poljoprivredna područja /	Kanal 11	stijena / Golo tlo/ Antropogene	Kanal 2
Oskudna vegetacija		površine	

Nakon svake završene faze nadzirane klasifikacije, svaka izdvojena klasa je pregledana te ručno korigirana na temelju fotointerpretacije DOF-a 19/20, korištenjem alata *sieve* u QGIS-u, u mjerilu 1:15,000. Nakon završetka korekcije svih klasa sa svih obrađenih snimaka, rasterski podaci pretvoreni su u vektorske podatke te spojeni u jedan sloj. Nakon spajanja podatka,

provjerena je i ispravljena geometrija podataka u konačnom vektorskom sloju. Konačni vektorski sloj (provjeren te korigirane geometrije) rezolucije 10x10 m.

Nakon uspješno završenih faza predobrade i obrade podataka, uslijedila je faza validacije podataka u odnosu na referentne podloge. Validacija točnosti podataka provedena je korištenjem ArcGISPro-a te korištenjem Excel računalnog programa. U ArcGISPro-u izrađena je matrica konfuzije. Kao referentna podloga za validaciju točnosti podataka korišten je DOF 19/20, a broj nasumično odabranih točaka na temelju kojih je izračunata matrica konfuzije je 3000. Za validaciju podataka o površinskom pokrovu dobivenih klasifikacijom Sentinel-2A snimaka i najčešće korištenih podataka o površinskom pokrovu u Hrvatskoj CORINE i NKS, izrađena je matrica konfuzije za podatke CORINE i NKS. Klase CORINE i NKS prilagođene su nomenklaturi korištenoj u klasifikaciji Sentinel-2A snimaka. Matrica konfuzije izrađena je za svaku od baza (CORINE i NKS) na temelju 1000 nasumično odabranih točaka u ArcGISPro-u. Referentna podloga za determinaciju *ground truth* vrijednosti za CORINE je DOF iz 2018. godine, a za NKS je korišten DOF iz 2016. godine, obzirom na godine izrade CORINE i NKS baze podataka. Uz matricu konfuzije, za prikazivanje točnosti podataka izračunati su indikatori Kappa koeficijent, Accuracy i Balanced Accuracy. Za svaku klasu izveden je i pokazatelj postotka ukupnih pogrešno klasificiranih slučajnih točaka i uspoređen za sve tri klasifikacije.

5.3. Metrika krajobraza

Metrika krajobraza može biti definirana na tri razine: krajobraz, klasa i uzorak. Metrika na razini uzorka računa se za individualne uzorke koji predstavljaju diskretna područja sličnih karakteristika. Metrika na razini klase računa se za sve uzorke određene klase. Metrika na razini krajobraza kombinira sve klase i uzorke određenog područja (Sertel i dr., 2018).

Indikatori metrike krajobraza izračunati su u računalnom programu Fragstats 4.2, u kojemu je ulazni podatak raster s klasama površinskog pokrova. Metrika krajobraza za površinski pokrov izračunata je na sve tri razine: krajobraz, klasa i uzorak. Rezultati izračuna metrike krajobraza dalje su obrađeni u Excel računalnom programu. Neki od pokazatelja izračunati su i vizualizirani u ArcGISPro-u. Linearna regresija dvaju pokazatelja metrike krajobraza na razini uzorka izračunata je i vizualizirana korištenjem Excel računalnog programa, korištenjem formule $Y = mX + b$. Pokazatelj AREA je zavisna varijabla, dok je indikator SHAPE nezavisna varijabla. Indikator AREA odnosi se na površinu u hektarima za svaki pojedini uzorak.

Indikator SHAPE opisuje odnos između stvarnog perimetra uzorka i kvadratni korijen površine uzorka, čime se prilagođava kvadratnom standardu. Stoga, taj je pokazatelj jednostavna mjera kompleksnosti oblika (McGarigal, 2013).

5.4. Digitalna analiza reljefa

Kao primarni podatak za digitalnu analizu reljefa te ekstrakciju novih podataka o reljefu korišten je digitalni model reljefa (u daljnjem tekstu: DMR) prostorne rezolucije 5x5 m. Korišteni DMR službeni je podatak DGU-a. DMR-u je promijenjena prostorna rezolucija iz 5x5 m u 10x10 m kako bi svojom prostornom rezolucijom, korišteni DMR te svi iz njega izvedeni podaci, bili kompatibilni s ostalim slojevima koji služe kao ulazni podaci za klasifikaciju krajobrazu. Promjena prostorne rezolucije provedena je korištenjem alata *resample* u ArcGISPro-u. Sve analize provedene su u GIS okruženju, korištenjem računalnog programa ArcGISPro.

5.4.1. Opća geomorfometrija

Provedena je već standardna geomorfološka analiza prostora istraživanja kroz izradu pokazatelja opće morfometrije te njihovu analizu: analiza hipsometrije, nagiba, ekspozicije padina, vertikalne raščlanjenosti reljefa te prvog trend vertikalne raščlanjenosti reljefa. Svi pokazatelji izvedeni su iz DMR-a. Pri izračunu vertikalne raščlanjenosti reljefa susjedstvo je definirano kao krug površine 1 km².

5.4.2. Specifična geomorfometrija

DMR 5x5 m ulazni je podatak za izračun topografskog pozicijskog indeksa (eng. *Topographic Position Index* – TPI) koji predstavlja vrijednost razlike nadmorske visine jedne ćelije korištenog DMR-a u odnosu na prosječnu nadmorsku visinu definiranog susjedstva te ćelije (Weiss, 2001) Vrijednost radijusa susjedstva tj. površina susjedstva nije definirana jer ovisi o obilježjima istraživanog prostora. Do definiranja adekvatnog radijusa dolazi se iterativnim procesom izračuna TPI-a u različitim mjerilima do dobivanja zadovoljavajućih rezultata (Zwolinski i Stefańska, 2015). Algoritam za izračun TPI-a prema (Weiss, 2001) je (Formula 3):

$$TPI_i = Z_0 \frac{\sum_{1-n} Z_n}{n} \quad (3)$$

Gdje;

Z_0 = nadmorska visina točke modela koji se procjenjuje

Z_n = nadmorska visina mreže ćelija unutar definiranog susjedstva

n = ukupan broj točaka koje okružuju početnu točku susjedstva

Pozitivne vrijednosti TPI-a predstavljaju lokacije koje su više od prosjeka lokalnog prozora, npr. grebeni. Negativne vrijednosti TPI-a predstavljaju lokacije koje su niže, npr. doline. Vrijednosti TPI-a blizu nule su ili ravna područja (gdje je nagib blizu nule) ili područja konstantnog nagiba (gdje je nagib točke znatno veći od nule), dok se visoke pozitivne vrijednosti odnose na vrhove i grebene (Seif, 2015; Weiss, 2001).

Izračunom TPI-a u jednom mjerilu moguće je definirati koje su padine više ili niže od prosjeka susjedstva. Izračunom TPI-a u kombinaciji sa slojem nagiba moguće je dobiti i pokazatelj *slope position*, te detaljniju klasifikaciju reljefa sa 6 klasa. Daljnjom kombinacijom TPI-a u manjem i većem mjerilu te sloja nagiba moguće je definirati 10 klasa reljefnih oblika. U ovom radu izrađena su sva tri pokazatelja. TPI_600 izračunat je za susjedstvo u obliku prstena unutarnjeg radijusa irad= 300 m, te vanjskog radijusa prstena orad=600 m, a TPI za sitnije mjerilo (TPI_3000) izračunat je s unutarnjim radijusom prstena irad=1500 m te vanjskim radijusom orad=3000 m. Odabir mjerila proveden je metodom pokušaja i pogreške obzirom na stručnu procjenu raznolikosti reljefa na istraživanom prostoru. Što je reljef proučavanog prostora raznolikiji, potrebno je koristiti manji proračunski prozor tj. krupnije mjerilo (Zwolinski i Stefańska, 2015). Odabir sitnijeg mjerila u odnosu na prvo definirano krupnije mjerilo daje najbolje rezultate s drugim proračunskim prozorom koji je otprilike pet puta veći od prvog. Istovremeno, veličina prvog prozora treba se prilagoditi promjenjivosti reljefa u danom području i približno odgovarati najmanjem obliku reljefa koji treba razlikovati (Zwolinski i Stefańska, 2015). TPI_600, TPI_3000 te TPI_orografija izračunati su i vizualizirani u ArcGISPro-u koracima prikazanim na Sl. 5.4.1.

postupkom izdvojene krške depresije svih veličina te neki antropogeni elementi terena, svi su podaci ručno pregledani i korigirani u mjerilu 1:5.000 u odnosu na referentu podlogu DOF 19/20 te sjenčani reljef izveden iz originalnog DMR-a. Vizualna interpretacija u odnosu na referentne podloge te druge morfometrijske ili specifične gomorfometrijske slojeve je nužna pri izdvajanju svake vrste krških depresija, a od najvećeg je značaja kod izdvajanja polja u kršu (Esposito i dr., 2025). Ovakvom metodom identificiraju se depresije kroz jednostavno aritmetičko oduzimanje ispunjenog (fill) DMR-a i originalnog DMR-a (Bauer, 2015; Wall i dr., 2017; Hofierka i dr., 2018; Cahalan i Milewski, 2018; Ferreira i dr., 2023). Obzirom da su izdvojene i veće krške depresije, bilo je potrebno dodatno analizirati područja polja u kršu te drugih većih krških depresija ili zaravni kako bi bile identificirane i takozvane ugniježdene ponikve. Izdvojeni su dijelovi DMR-a koji odgovaraju poljima u kršu te drugim velikim krškim depresijama, te je na tom DMR-u ponovno proveden proces detekcije ponikava s naknadnom ručnom korekcijom u odnosu na spomenute referentne podloge.

Osim ponikava, ovim su postupkom identificirane sve krške depresije, a daljnjom analizom su klasificirane u krške uvale i polja u kršu. Posebnost krških uvala je u tome da: i) imaju nepravilan oblik perimetra po hipsometrijski najvišoj zatvorenoj izohipsi, ii) jedan od promjera mora biti veći od 1.000 m, a dubina od najviše zatvorene konture barem 40-50 m, a može biti i više od 200 m, iii) nagibi padina su manji nego u ponikava, iv) uvale imaju svoju internu/endoreičku/kršku hidrografiju, v) dna uvala su uvijek iznad lokalnog vodnog lica, vi) generalno su bezvodne s mogućim manjim sezonskim vodotocima što je iznimka više nego pravilo, vii) sediment na dnu je oskudan, no ako je prisutan njegovo je podrijetlo s okružujućih padina, viii) korozija je izraženija od akumulacije čime uvale ostaju očuvane, ix) ovakve depresije nisu prisutne a zaravnima već u područjima račlanjenijeg reljefa, x) uvale su forme akcelerirane korozije – ne točkasto kao ponikve već arealno ili linearno, u većini slučajeva razvijene duž tektonski razlomljenih zona (Čalić, 2011). Obzirom na navedena obilježja, u izdvajanju uvala uzet je u obzir maksimalan broj obilježja koje je moguće determinirati korištenjem GIS alata, što je prikazano u Tab. 5.4.1.

Tab. 5.4.1 Kriteriji izdvajanja krške uvale te postupak u GIS-u

Obilježje krške uvale	Postupak u GIS-u
depresija promjera većeg od 1000 m po hipsometrijski najvišoj zatvorenoj konturi	vektorski sloj depresija pretvoren u krugove algoritmom <i>minimum bounding geometry</i> te izračunat promjer, selekcijom su izdvojene depresije promjera većeg od 1000 m.

minimalna dubina od 40 m	vektorskim slojem izdvojenih depresija izrezan DMR 5X5 m, za svaku depresiju izračunata dubina korištenjem fokalne statistike
blaži nagibi padina	prethodni izrezan DMR pretvoren u rasterski sloj nagiba, selekcijom su izdvojene depresije nagiba $> 15^{\circ} < 55^{\circ}$
endoreička hidrografija	vizualna interpretacija u odnosu na referentnu podlogu TK 1:25.000 i korištenjem baze podataka izrađene za potrebe ovoga rada koja uključuje speleološke objekte s hidrološkom funkcijom, hidrogeografske pojave izvora, ponora i estavela te sloj drenažne mreže
bezvodnost dna	vizualna interpretacija u odnosu na referentnu podlogu TK 1:25.000 i korištenjem baze podataka izrađene za potrebe ovoga rada koja uključuje speleološke objekte s hidrološkom funkcijom, hidrogeografske pojave izvora, ponora i estavela te sloj drenažne mreže
dno koje nije zaravnjeno	selekcija depresija koje nemaju obilježje zaravnjene ekspozicije (vrijednost 0) te depresija čije dno ima nagibe veće od 2°
nisu razvijene na zaravnjenim dijelovima reljefa	selekcija u odnosu na vrijednosti vertikalne raščlanjenosti reljefa ($> 30 \text{ m/km}^2$) za cijeli prostor istraživanja

Krške depresije najvećih dimenzija su polja u kršu. Na prostoru istraživanja, nakon izdvajanja ponikvi i krških uvala, iz sloja krških depresija izdvojena su polja u kršu. Rasterski sloj s velikim krškim depresijama koji je “očišćen” od ponikvi i krških uvala bio je primarni sloj za daljnje izdvajanje polja u kršu. Prema definicijama polja u kršu, karakteristike koje se uvijek izdvajaju su da je polje u kršu: i) najveća krška depresija, ii) nalazi se unutar hipsometrijski višeg područja koje se spušta vrlo strmim padinama do generalno zaravnjenog dna, iii) krška hidrografija tj. dotok vode u polje, iv) prisutnost ponornica (stalnih ili povremenih ponirućih vodotoka), v) sezonsko plavljenje, vi) selektivna korozijska i utjecaj tektonike, vii) sedimentom ispunjeno dno (Gams, 1978). Gams, (1978) definirao je kriterije koji moraju biti ispunjeni kako bi depresija bila klasificirana kao polje. To uključuje i) ravno dno u stijeni ili u nekonsolidiranim sedimentima poput aluvija, ii) zatvoreni bazen sa strmo uzlaznom marginalnom padinom na barem jednoj strani i iii) kršku drenažu (Mihevc i dr., 2010). Rasterski sloj s prethodno izdvojenim krškim depresijama koji je “očišćen” od ponikava te uvala dalje je procesuiran kako bi bila identificirana polja u kršu u skladu se prethodno navedenim kriterijima. U Tab. 5.4.2 navedeni su kriteriji te proces u GIS-u kojim je provedena identifikacija polja u kršu na istraživanom prostoru.

Tab. 5.4.2 Kriteriji izdvajanja polja u kršu te postupak u GIS-u (zelenom bojom označeni su dijagnostički kriteriji koji su minimum za izdvajanje polja u kršu prema (Gams, 1978).

Obilježje polja u kršu	Postupak u GIS-u
najveća krška depresija	vektorski sloj "očišćen" od ponikava i uvala prethodno opisanim metodama pretvoren u krugove algoritmom <i>minimum bounding geometry</i> te izračunat promjer. U sloju su nakon izdvajanja ponikvi i uvala depresije nazvane "nedefinirane krške depresije" koje su dalje identificirane u procesu izdvajanja polja u kršu
nalazi se unutar hipsometrijski višeg područja koje se spušta vrlo strmim padinama do generalno zaravnjenog dna	rasterski sloj "očišćen" od ponikava i uvala s "nedefiniranim krškim depresijama" procesuiran u ekstenziji <i>Spatial Analyst</i> (nagib, ekspozicija padina, sjenčani reljef), vizualnom interpretacijom morfometrijskih slojeva definirane su depresije s vrlo strmim padinama koje oštro prelaze u generalno zaravnjeno dno, korišten je TPI te referentne podloge (orohidrografska karta, TK 1:25.000, DOF 19/20)
krška hidrografija tj. dotok vode u polje	Korištenjem <i>Hydrology</i> alata izdvojena su područja krške i ne krške hidrografije sa svojim drenažnim bazenima i pripadajućim vodotocima, pregledom baze podataka speleoloških objekata i hidrogeoloških pojava (ponori, izvori, estavele) te vizualnom interpretacijom navedenih slojeva
prisutnost ponornica (stalnih ili povremenih ponirućih vodotoka)	Korištenjem <i>Hydrology</i> alata izdvojena su područja krške i ne krške hidrografije sa svojim drenažnim bazenima i pripadajućim vodotocima, pregledom baze podataka speleoloških objekata i hidrogeoloških pojava (ponori, izvori, estavele) te vizualnom interpretacijom navedenih slojeva
selektivna korozija i utjecaj tektonike	Vizualnom interpretacijom prethodno izdvojenih morfolineamenata, strukturnih elemenata prostora, morfometrijskih slojeva (nagibi, ekspozicija padina, vertikalna raščlanjenost reljefa, sjenčani reljef) i TPI-a
sedimentom ispunjeno dno	Interpretacija OGK 1:300.000, TK 1:25.000 i DOF 19/20

Identifikacija i definiranje hidrografskih režima jedan je od preduvjeta za kasniju analizu morfogenetskih tipova reljefa. Korištenjem alata *Hydrology* u ArcGISPro-u izvođenjem već standardnog niza algoritama nad DMR-om prostorne rezolucije 5x5 m (*Fill* → *Flow Direction* → *Flow Accumulation* → *Greater than [10,000 m²]* → *Stream Link* → *Stream Order* → *Stream to Feature*). Dobiveni vektorski sloj s izdvojenim vodotocima ručno je ispravljen pregledom prostora istraživanja u mjerilu 1:5.000 u odnosu na referentne podloge (TK 1:25.000, orohidrografska karta) te slojeve izrađene unutar geomorfološke analize za potrebe ovoga rada

(TPI landforms, sjenčani reljef, izohipse ekvidistance 10 m, nagibi). Drenažni bazeni ručno su vektorizirani po grebenima na temelju sloja TPI landforms, povremenih i stalnih vodotoka izdvojenih prethodno opisanim postupkom, sjenčanog reljefa i izohipsi ekvidistance 10 m. Nazivi su im dodijeljeni po tekućici čijem drenažnom bazenu pripadaju, a ako su drenažni bazeni dio većih drenažnih bazena, to je navedeno u samoj nomenklaturi.

Podaci o speleološkim objektima prikupljeni su iz postojećih dostupnih baza podataka (Katastar speleoloških objekata RH), slanjem zahtjeva Speleološkom odsjeku HPD “Željezničar” iz Zagreba te vektorizacijom s TK 1:25.000 pregledom prostora istraživanja u mjerilu 1:5.000. Podaci su objedinjeni u jednu proračunsku tablicu te istovjetni vektorski sloj. Obzirom na ponavljanje nekih speleoloških objekata u bazi Crospeleo, arhivi SOHPD Željezničar in a TK 1:25.000 obrisani su svi identificirani duplikati.

Podaci o hidrogeološkim pojavama prikupljeni izdvajanjem iz sloja speleoloških objekata ukoliko je za neki speleološki objekt ustanovljeno da ima hidrogeološku funkciju izvora, ponora ili estavele. Ostali podaci prikupljeni su vektorizacijom s referentne podloge TK 1:25.000 u mjerilu 1:5.000. Obzirom na vrlo raznoliko korištenje termina hidrološka karakteristika i hidrogeološka funkcija u osnovnom speleološkom zapisniku koji dolazi uz podatke o speleološkim objektima, izvršena je promjena nomenklature kako bi podaci bili prikazani unificirano za potrebe ovoga rada Tab. 5.4.3. Kod navođenja nekoliko hidroloških karakteristika speleološkog objekta, u novoj nomenklaturi izdvojena je samo najpermanentnija kategorija koja govori o ulozi toga objekta u krškom sustavu. Ukoliko je u originalnom zapisniku navedeno da u objektu ima prokapnice i povremenog toga, onda će u novoj nomenklaturi povremeni tok opisivati hidrološku karakteristiku objekta. Za potrebe prikupljanja podataka o hidrogeološkim pojavama, iz sloja speleoloških objekata izdvojeni su samo oni koji su prema Tab. 5.4.3. klasificirani kao ponor, povremeni ponor, izvor, povremeni izvor i estavela.

Tab. 5.4.3 Prilagodba nomenklature hidrološke karakteristike speleoloških objekata

Hidrološka karakteristika – original	Hidrološka karakteristika - novo
Izvor	izvor
Nakapnica/prokapnica	prokapnica
nakapnica/prokapnica, potopljen, stalni tok	stalni tok
nakapnica/prokapnica, povremena stajaća voda, stalna stajaća voda	stalna stajaća voda
nakapnica/prokapnica, povremena stajaća voda, stalni tok	stalni tok
nakapnica/prokapnica, povremeni tok	povremeni tok
nakapnica/prokapnica, povremeni tok, povremeno potopljen	povremeni tok
nakapnica/prokapnica, povremeni tok, stalna stajaća voda	povremeni tok

nakapnica/prokapnica, povremeni tok, stalni tok	stalni tok
nakapnica/prokapnica, povremeno potopljen, stalni tok	stalni tok
nakapnica/prokapnica, stalna stajaća voda	stalna stajaća voda
nakapnica/prokapnica, stalni tok	stalni tok
ponor	ponor
potopljen	potopljen
potopljen, povremeni tok	povremeni tok
potopljen, povremeno potopljen, stalna stajaća voda	povremeni tok
potopljen, stalni tok	stalni tok
povremena stajaća voda, povremeni tok	povremeni tok, stalna stajaća voda
povremeni tok	povremeni tok
povremeni tok, povremeno potopljen	povremeni tok
povremeni tok, stalna stajaća voda	povremeni tok, stalna stajaća voda
povremeni tok, stalni tok	povremeni tok
povremeno potopljen	povremeno potopljen
povremeno potopljen, stalni tok	stalni tok
stalna stajaća voda	stalna stajaća voda
stalna stajaća voda, stalni tok	stalni tok, stalna stajaća voda
stalni tok	stalni tok
suh	suh

Prikupljeni su i analizirani podaci o reljefnim oblicima jarugama te s njima povezanim proluvijalnim plavinama. Identifikacija jaruga i proluvijalnih padina provedena je GIS analizom hidrografije te opće i specifične morfometrija istraživanog prostora. Obzirom da prisutnost jaruge uvjetuje prisutnost proluvijalne plavine, prvotno su izdvojene jaruge, kako bi izdvajanje proluvijalnih plavina bilo usmjerenije. Za izdvajanje jaruga korištena je TK 1:25.000, orohidrografska karta, izohipse E=10 m, sjenčani reljef, drenažna mreža te *Stream Power Index* (SPI). SPI je korišten za identifikaciju i opisivanje potencijalnih linearnih denudacijskih procesa poput vododerina i jaružanja duž padina na temelju nagiba i doprinosećeg područja tj. područja koje je drenirano (Maerker i dr., 2015; Vianello i D'Agostino, 2007). SPI mjeri erozivnu snagu vodotoka na temelju pretpostavke da je protok proporcionalan specifičnom doprinosećem području (A_s), a brzina protoka proporcionalna nagibu padina ($\tan\beta$) (Wilson i Gallant, 2000). SPI definiran je kako je prikazano u formuli 4 (Wilson i Gallant, 2000):

$$SPI = A_s * \tan\beta \quad (4)$$

Doprinosće područje (A_s) je uzvodno područje ili ravninsko/planarno područje i opisuje prostorni opseg prikupnog područja preko kojeg se može akumulirati voda od kiše, snijega itd. (Gruber i Peckham, 2009). Za potrebe izračuna pokazatelj SPI korišten je sloj *Flow Accumulation* koji je izrezan vektorskim slojem na područja koja pripadaju ne krškim morfogenetskim tipovima reljefa, obzirom da je osnovna karakteristika krša bezvodnost na površini. Isključivanjem krškog morfogenetskog tipa reljefa povećava se točnost hidrografske

analize. Svi ulazni podaci i izlazni podaci su prostorne rezolucije 5x5 m. Preklapanjem svih rasterskih slojeva s najvećim težinskim faktorom na sloju SPI, stvoren je vektorski sloj jaruga. Vektorski sloj jaruga ručno je korigiran u mjerilu 1:5.000 u odnosu na TK 1:25,000, izohipse E=10 m, te orohidrografsku kartu.

Nakon izdvajanja jaruga, uslijedio je proces izdvajanja proluvijalnih plavina. Obzirom na postanak proluvijalnih plavina te njihove morfometrijske karakteristike za izdvajanje proluvijalnih plavina korišteni su sljedeći podaci: rubovi polja u kršu, jaruge, drenažni bazeni, drenažna mreža, nagibi, sjenčani reljef, izohipse E=10m (Norini i dr., 2016). Ekspertnom analizom prostora istraživanja s prethodno navedenim podacima i podlogama u mjerilu 1:5.000 ručno su vektorizirane točke koje predstavljaju proluvijalne plavine.

5.5. Analiza morfogenetskih tipova reljefa

Morfogenetska analiza reljefa te samo izdvajanje morfogenetskih tipova reljefa provedeno je korištenjem podataka koji su prethodno prikupljeni i organizirani u bazu podataka. Podaci koji predstavljaju entitete reljefnih oblika organizirani su u geomorfološku bazu podataka te su organizirani prema pripadnosti morfogenetskim tipovima reljefa, u svrhu lakše determinacije morfogenetskih tipova reljefa. Osim podataka generiranih unutar opće morfometrijske te specifične geomorfometrijske analize, korištene su razne kartografske podloge koje su derivati DMR-a 5x5m (izohipse E=10 m, sjenčani reljef, TK 1:25.000, DOF 19/21, orohidrografska karta). Osim geomorfološke baze podataka te spomenutih kartografskih podloga, korišteni su i podaci o geološkim obilježjima prostora s Osnovne Geološke Karte 1:300.000. To su podaci o strukturnim elementima reljefa te litostratigrafski podaci. Pregledom prostora istraživanja u mjerilu 1:5.000, uz korištenje svih spomenutih podataka te kartografskih podloga, izvršena je ručna vektorizacija morfogenetskih tipova reljefa.

5.6. Tipologija krajobraza

Prva faza izrade tipologije krajobraza je provođenje predobrade podataka te analize dostupnih podataka i podloga kako bi bile izdvojene varijable za diferencijaciju tipova krajobraza u različitim mjerilima. U prvoj fazi nastoji se sustavno istražiti čimbenike koji stvaraju varijacije u krajobrazu na različitim razinama. Uzimajući u obzir teorijski okvir ovoga rada koji odražava

suvremeni geoekološki pristup proučavanju krajobraza, multivarijantna statistička metoda odabrana je kao glavna metoda za razdvajanje tipova krajobraza. Dva su pristupa u izradi tipologije krajobraza, a to su odozdo prema gore i od gore prema dolje, tj. pristup u kojem se podaci agregiraju te pristup u kojem se podaci razdvajaju. Vrlo često koristi se kombinacija oba pristupa.


Obzirom na velik prostorni obuhvat, kompleksnost elemenata krajobraza koji odražavaju vertikalnu i horizontalnu strukturu te različite kvalitete podataka u kontekstu točnosti i prostorne rezolucije, bilo je potrebno utvrditi principe provođenja tipologije krajobraza Gorske Hrvatske.

1. Tipologija podrazumijeva i hijerarhijski poredak izdvojenih prostornih jedinica te ona mora biti provedena na način da identificira apstraktne tipove krajobraza koji nisu vidljivi ljudskim okom s težnjom da ih odvoji na način koji je najbliži prostornoj stvarnosti koju čovjek može percipirati.
2. Tipologija mora sadržavati u svojoj strukturi homogene tipove krajobraza, ali odražavati i prostornu varijaciju određenih elemenata krajobraza.
3. Tipologija se izrađuje na način da ne ovisi o znanju i percepciji pojedinih stručnjaka, već je maksimalno kvantitativna i lako ponovljiva.
4. Tipologija krajobraza mora biti prikladna za prikaz varijacije krajobraza i krajobraznih tipova u mjerilu 1:50.000.

Tipovi krajobraza izdvajani su prema kriterijima homogenosti komponenti strukture krajobraza, a varijacija krajobraza prikazana je kompleksnim krajobraznim gradijentima tj. dodatnim varijablama.

Kombinirani pristup polazi od najveće prostorne razine ka najnižoj, ali se služi metodama agregacije tj. klasteringa. Razdvajanje i agregacija sa istim setovima podataka vrlo su komplementarne metode kojima se dolazi do jasnije određenih granica između tipova/klastera (Chahouki, 2013). Proces je razdvojen u dva koraka. Na temelju 4 varijable metodom K-means izdvojeni su makro tipovi krajobraza. Na Sl. 5.6.1 prikazana je pojednostavljena metodološka shema izrade makro tipologije krajobraza kombiniranom metodom. Varijable za izdvajanje tipova krajobraza navedene su u Tab. 5.6.1. Kao kriterij izdvajanja makro tipova krajobraza izdvojena su orografska reljefna obilježja tj. obilježja primarne strukture krajobraza, koja je modelirana pomoću morfometrijskih pokazatelja te pokazatelja specifične geomorfometrije

koji odražavaju reljefna obilježja na regionalnoj razini, tj. u ovom slučaju na razini fizičkogeografske regije GH. Izračunate su srednje vrijednosti svake varijable, korištenjem alata *Focal Statistic*. U tablici x. navedene su varijable korištenje za izdvajanje makro tipova krajobraza. Sam proces provođenja klasteringa je iterativan proces a faktor zbog kojeg se proces ponavlja je zadani broj klastera. Kada je konačan rezultat reprezentativan, što se potvrđuje validacijom pomoću referentnih podloga, proces se zaustavlja.




Sl. 5.6.1 Shematski prikaz kombinirane metodologije izrade tipologije krajobraza na makro razini.

Tab. 5.6.1 Varijable za izdvajanje makro tipova krajobraza GH kombiniranom metodom

MAKRO TIPOVI KRAJOBRAZA		
Naziv varijable	Originalna vrijednost/raspon	Reklasificirana vrijednost
tpi_mean_R500	duboko usječene doline, kanjoni	1
	uske doline, V profil	2
	izvorišta	3
	široke doline, niži pristranci	4
	zaravni i ravnice ($n^{\circ} \leq 5$)	5
	padine dolinskih strana	6
	padine gorskih strana	7
	manji grebeni i kose, uzvišenja u dolinama	8
	tjemena uzvišenja, uzvišenja u ravnicama	9
	vrhovi i izraziti grebeni	10
vertikalna_raščlanjenost_reljefa_mean_R500 (m/km ²)	0-109	1
	109-208	2
	208-321	3
	321-900	4
hipsometrija_mean_R500 (m n.v.)	196-526	1
	526-716	2
	716-924	3
	924-1175	4
	1175-1757	5
nagibi_mean_R500 (°)	2-9	1
	9-13	2
	13-18	3
	18-26	4

Druga faza izdvajanja tipova krajobraza kombiniranom metodom odnosi se na izdvajanje makro krajobraznih tipova. Prethodno opisanom metodom dobivena su 4 makro krajobrazna tipa. U sljedećim koracima svaki od 4 makro krajobrazna tipa su obrađivani pojedinačno, ali potpuno istom metodom, kao što je prikazano na Sl. 5.6.2.



Sl. 5.6.2 Shematski prikaz kombinirane metodologije izrade tipologije krajobraza na mezo razini.

Kriterij za izdvajanje mezo krajobraznih tipova su obilježja primarne i sekundarne strukture krajobraza, a korištene varijable navedene su u Tab. 5.6.2.

Tab. 5.6.2 Varijable za izdvajanje mezo tipova krajobraza GH kombiniranom metodom

MEZO TIPOVI KRAJOBRAZA		
Naziv varijable	Originalna vrijednost	Reklasificirana vrijednost
morfogenetski tipovi reljefa	fluvijalni	1
	fluviudenudacijski	2
	fluviokrš	3
	glaciokrš	4
	krš	5
površinski pokrov	vodene površine	1
	šume	2
	antropogene površine	3
	livade-travnjaci	4
	izdanci stijena	5
	poljoprivredne površine	6
	golo tlo	7
	oskudna vegetacija	8

Treća razina tipologije izrađena je izračunom kompleksnih krajobraznih gradijenata koji su potom definirani u svakom pojedinom mezo krajobraznom tipu. Definirani su: udjelom

površine klase pojedinog kompleksnog krajobraznog gradijenta preklapanjem slojeva u GIS-u. Kompleksni krajobrazni gradijenti su funkcionalne varijable koje predstavljaju komponente svih razina strukture krajobraza koje nisu vidljive u makro i mezo razini tipologije krajobraza, ali njihova prisutnost određuje strukturu krajobraza na mikro razini (Simensen i dr., 2020). Kompleksni krajobrazni gradijenti definirani su reklasifikacijom, funkcijama susjedstva i izračunom indeksa iz prethodno obrađenih podataka. U Tab. 5.6.3 navedeni su kompleksni krajobrazni gradijenti korišteni za određivanje 3. razine (mikro) tipologije krajobraza GH.

Tab. 5.6.3 Kompleksni krajobrazni gradijenti, njihov opis, način izračuna te pripadnost razini vertikalne strukture krajobraza

Funkcionalna varijabla	Kompleksni krajobrazni gradijent	Opis	Način izračuna
Primarna struktura	Obilje speleoloških objekata	varijacija broja speleoloških objekata	Reklasifikacija, Focal Statistics (circle, r=500, units=map), Raster Calculator
	Obilje plavina	varijacija broja proluvijalnih plavina	Reklasifikacija, Focal Statistics (circle, r=500, units=map), Raster Calculator
	Obilje hidrogeoloških pojava	varijacija broja hidrogeoloških pojava	Reklasifikacija, Focal Statistics (r=500, units=map), Raster Calculator
	Obilje drenažne mreže	varijacija broja vodotoka (stalnih i povremenih)	Reklasifikacija, Focal Statistics (r=500, units=map), Raster Calculator
	Obilje ponikava	varijacija broja ponikava	Reklasifikacija, Focal Statistics (r=500, units=map), Raster Calculator
	Obilje grebena	varijacija u broju grebena	Reklasifikacija, Raster Calculator
	Prisutnost kanjona/duboko usječenih dolina	varijacija u prisutnosti kanjona/duboko usječenih dolina	Reklasifikacija
Sekundarna struktura	Obilje ugroženih staništa	varijacija broja ugroženih staništa	Reklasifikacija, Focal Statistics (r=500, units=map), Raster Calculator
Tercijarna struktura	Frekvencija korištenja zemljišta	Intenzitet prisutnosti antropogeniziranih površina i površina pod velikim utjecajem čovjeka	Reklasifikacija, Focal Statistics (r=500, units=map), Raster Calculator, Calculate Composite Index
	Frekvencija poljoprivrednih površina	Intenzitet prisutnosti poljoprivrednih površina	Reklasifikacija, Focal Statistics (r=500, units=map), Raster Calculator
	Frekvencija izgrađenosti prostora	Intenzitet prisutnosti antropogeniziranih površina	Reklasifikacija, Focal Statistics (r=500, units=map), Raster Calculator

5.6.1. Vrednovanje krajobraza

Vrednovanje krajobraza provedeno je korištenjem programa ArcGISPro 3.4.2 i Microsoft Excell-a. Vrednovanje je kvantitativno te podijeljeno u kriterije vrednovanja. Svaki kriterij dobiva i svoju ukupnu ocjenu, a izdvaja se i ukupna ocjena krajobraza po svim kriterijima. Vrednovanje je provedeno na mezo krajobraznoj razini. Kriteriji vrednovanja i) ekološko stanje, ii) fragmentacija, iii) povezanost iv) rijetkost konstruirani su prema pokazateljima metrike krajobraza izračunate na razini klasa (mezo tipova) krajobraza GH. Kriteriji vrednovanja i) georaznolikost i ii) utjecaj čovjeka konstruirani su prema rezultatima kompleksnih krajobraznih gradijenata GH. Svi kvantitativni pokazatelji korišteni u konstruiranju pojedinih kriterija prikazani su u Prilogu I.

Klase pojedinih kompleksnih krajobraznih gradijenata preračunate su u postotak površine koju zauzimaju na prostoru GH. Za svaki mezo tip krajobraza izrađena je tablica distribucije udjela pojedine klase kompleksnog krajobraznog gradijenta. Promatrane su klase koje označavaju značajno ili izrazito značajno obilje određenog kompleksnog krajobraznog gradijenta. U

Tab. 5.6.4 je prikazana distribucija udjela površine kompleksnih krajobraznih gradijenata na cijelom prostoru GH prema kojoj su određene klase koje spadaju u klase velikog obilja. Promatrajući samo klase velikog obilja, određene su ocjene od 1 do 3. Ukoliko je udio klasa velikog obilja bio veći od 5% tada je dodijeljena ocjena 3, ukoliko je udio klasa velikog obilja 0,01-10% tada je dana ocjena 2, a ukoliko nema zastupljene klase velikog obilja dana je ocjena 1.

Ostali kriteriji kreirani su prema vrijednostima pojedinih pokazatelja metrike krajobraza na razini klasa (mezo tipova) (Tab. 5.6.5). Svaki izdvojeni pokazatelj klasificiran je u tri klase. Kod kriterija ekološkog stanja ocjena je veća što je bolje ekološko stanje. Kod kriterija fragmentacije, što je veći stupanj fragmentacije, to je veća ocjena. Kod kriterija rijetkosti/učestalosti, što je klasa rjeđa to je veća ocjena. Kod kriterija povezanosti, što je veća povezanost, to je manja ocjena.

Kriteriji i ocjene konstruirani su u svrhu izdvajanja ekološki stabilnih, rijetkih, sa značajnim vrijednostima obilja kompleksnih krajobraznih gradijenata koji čine kriterij georaznolikosti, a istovremeno su ugroženi utjecajem čovjeka, bilježe visok stupanj fragmentacije i lošu povezanost.

Tab. 5.6.4 Kompleksni krajobrazni gradijenti – udjeli pojedinih klasa na prostoru GH te ocjena korištena u vrednovanju

IPF				PPF				SO			
klasa	pov (km ²)	udio (%)	značaj	klasa	pov (km ²)	udio (%)	značaj	klasa	pov (km ²)	udio (%)	značaj
1	9928.193	90.356047	N	1	8934.6124	81.313514	N	1	10682.2873	97.2543	N
2	818.322	7.447512		2	924.3617	8.412575	S	2	284.2235	2.587644	S
3	189.7946	1.727312	S	3	843.0041	7.672143		3	17.3607	0.158056	V
4	42.5852	0.387566		4	285.8785	2.601768	V	POO			
5	8.9619	0.081562	V	HO				klasa	pov (km ²)	udio (%)	značaj
PLO				klasa	pov (km ²)	udio (%)	značaj	1	3096.9334	29.580157	N
klasa	pov (km ²)	udio (%)	značaj	1	9769.7407	88.94795	N	2	3864.6219	36.912684	
1	10742.394	97.803191	N	2	1095.8387	9.97699	S	3	2266.3761	21.647143	S
2	230.8555	2.101804	S	3	102.2523	0.930949		4	978.2095	9.343304	V
3	10.4351	0.095005	V	4	15.8286	0.14411	V	5	263.4904	2.516711	
DMO				RSO				GO			
klasa	pov (km ²)	udio (%)	značaj	klasa	pov (km ²)	udio (%)	značaj	klasa	pov (km ²)	udio (%)	značaj
1	1724.3576	30.808264	N	1	6126.7257	55.768553	N	1	8690.361875	79.083035	N
2	1594.7751	28.493076		2	2306.566	20.995529	S	2	1502.46785	13.672586	S
3	1162.3283	20.766758	S	3	1542.1016	14.036988		3	796.0781	7.244379	V
4	802.9975	14.346769		4	1010.5931	9.198929	V	KSO			
5	312.6033	5.585132	V					klasa	pov (km ²)	udio (%)	značaj
								1	9388.703975	85.438008	N
								2	1098.756775	9.998781	S
								3	501.447075	4.563211	V

Tab. 5.6.5 Pokazatelji metrike krajobraza korišteni u kriterijima vrednovanja te njihovi rasponi i vrijednosti s dodijeljenom ocjenom, **R**-raspon vrijednosti pokazatelja, **1,2,3** – ocjene dodijeljene u vrednovanju

UČESTALOST/RIJETKOST					
CA		AREA_MN		AREA_AM	
R	215977.59	R	1026.5178	R	23240.8693
1	0-71992.53	1	0-342.1726	1	0-7746.95
2	71998.54-143985.06	2	342.1727-684.3452	2	7746.96-15493.91
3	143985.07-215977.59	3	684.3453-1026.5178	3	15493.92-23240.8693
STANJE KLASJE					
LPI		TE		ED	
R	4.8266	R	5358260	R	5.1162
3	0-1.60	3	0-1786068.7	3	0-1.7054
2	1.61-3.21	2	1786068.8-3572173.4	2	1.7055-3.4108
1	3.22-4.8266	1	3572173.5-5358260	1	3.4109-5.1162
POVEZANOST		SHAPE_AM		PARA_AM	
R	4.8266	R	3.5541	R	39.0693
3	0-1.60	3	0-1.1847	3	0-13.0231
2	1.61-3.21	2	1.1848-2.3694	2	13.0232-26.0462
1	3.22-4.8266	1	2.3695-3.5541	1	26.0463-39.0693
FRAGMENTACIJA		MESH			
R	0.215	R	4042.4408	R	4042.4408
1	0-0.0716	1	0-0.0029	3	0-1347.48
2	0.0717-0.1433	2	0.0030-0.0058	2	1347.49-2694.96
3	0.1434-0.215	3	0.0059-0.0087	1	2694.97-4042.4408

6. REZULTATI

6.1. Komponente primarne strukture krajobraza GH

6.1.1. Geološka obilježja

Gorskom Hrvatskom dominiraju karbonatne stijene koje se prostiru na 91 % prostora istraživanja (Sl. 6.1.1, Tab. 6.1.1). Najzastupljenije su naslage mezozojske starosti među kojima prevladavaju karbonati (Tab. 6.1.1). Kao najstariji član mezozoika trijas je u odnosu na mlađe naslage otkriven na znatno manjim površinama. Njegove pojave vežu se na duboko erodirane izdignute strukture, prate navlačne kontakte i duboke rasjede, ili su više ili manje prisutne u masivima višefazno izdizanih planina. Iz navedenih razloga trijas zastupan cjelokupnim razvojem ili samo pojedinim razinama otkriven je u krškom području Hrvatske od Gorskoga kotara do Konavala (najbolje na Velebitu, istočnoj Lici i sjevernoj Dalmaciji) (Velić i Vlahović, 2009). Trijaskie naslage u najznačajnijim površinama se javljaju duž ličke strane Velebita na kontaktu sa zavalom Ličkog polja, na prostoru Plješevice i masiva Poštaka te Gračačkog polja.

Ujedno i najzastupljenije na cijelom prostoru istraživanja, naslage jurske starosti dominiraju GH (Tab. 6.1.2), a pretežito su u kontaktu s trijaskim i krednim naslagama. Izgrađuju velik dio

Gorskog kotara te najznačajnijih goranskih planina (Risnjak, Snježnik, Velika Kapela). Naslage jure ostatci su mezozojske karbonate platforme

Kredne naslage dominiraju središnjim dijelom GH u I dijelu Ličke zavale, te na prostoru Male Kapele, Ogulinsko-Plašćanske zavale i Unsko-Koranske zaravni, a javljaju se i na krajnjem sjeveru te na krajnjem jugu gdje izgrađuju najznačajnije planine Dinaru, Svilaju i Kamešnicu.

Paleogenske i neogenske vapnenačke breče izgrađuju značajan dio Velebita, posebice njegovog sjevernog i južnog dijela te dijelove istočnog dijela zavale Ličkog polja. Paleogenske i neogenske breče značajne su u kontekstu speleogeneze, obzirom da su u tim naslagama razvijeni mnogobrojni speleološki objekti te svi speleološki objekti najznačajnijih dimenzija (dubine) koji su smješteni upravo na sjevernom dijelu Velebita.

Ne karbonate stijene zastupljene su poglavito naslagama kvartarne starosti, te paleogenkim flišom. Paleogeni fliš prisutan je u području oko Klane na SZ dijelu GH te u vrlo malom arealu na području Velike Kapele II od Ogulina. Površinom je na cijelom prostoru GH paleogeni fliš zastupljen na 0,18% ukupne površine prostora istraživanja.

Kvartarne naslage ukupno se prostiru na 6,4% površine GH, a najzastupljenije su deluvijalno-proluvijalne holocenske naslage. Najveći areal deluvijalno-proluvijalnih holocenskih naslaga nalazi se u podnožju Velebita na kontaktu s zavalom Ličkog polja. Obzirom na njihovu genezu, smještene su podnožjima hipsometrijski viših predjela, a litološki sastav ovisi o građi neposrednog okruženja. Generalno promatrajući, sve kvartarne naslage prisutne u GH rasprostiru se u zaravnjenim dijelovima prostora ili u dnu većih krških depresija.

Tab. 6.1.1 Površine i udjeli stratigrafskih jedinica u ukupnoj površini GH po erama i periodima


era	period	površina (km ²)	udio (%)
PALEOZOIK		258,48865	2,46908281
	TRIJAS	692,325201	6,61308825
MEZOZOIK	JURA	4488,00105	42,8693726
	KREDA	3070,07969	29,325392
KENOZOIK	PELEOGEN	836,296126	7,98829809
	NEOGEN	16,463963	0,15726373
KVARTAR	PLEISTOCEN	17,224457	0,16452796
	HOLOCEN	652,519246	6,23286189

Izvor: Osnovna Geološka karta Republike Hrvatske, 1:300.000

Tab. 6.1.2 Površine i udjeli litostratigrafskih jedinica u ukupnoj površini GH po pojedinim kartiranim jedinicama

		LITOSTRATIGRAFSKE KARTIRANE JEDINICE	površina (km ²)	udio (%)
PALEOZOIK		KLASTIČNE I KARBONATNE NASLAGE (karbon, perm)	79.3311876	0.757771267
		PRETEŽITO KLASTIČNE NASLAGE (karbon, perm)	173.8004196	1.660141089
		EVAPORITNE I KLASTIČNE NASLAGE (gornji perm): evaporiti	5.357043007	0.051170459
MEZOZOIK	TRIJAS	SAJSKE I KAMPILSKE NASLAGE (donji trijas)	149.0531887	1.423755613
		KARBONATNE NASLAGE (srednji trijas)	472.5914194	4.514191826
		KLASTIČNE I PIROKLASTIČNE NASLAGE (srednji trijas)	51.30426835	0.490058218
		MAGMATSKJE STIJENE: andeziti i bazalti (srednji i gornji trijas)	1.042354448	0.009956567
		KLASTIČNE NASLAGE (?gornji ladinik - donji norik)	18.33396967	0.175126023
		VAPNENCI I DOLOMITI (donja jura)	1106.749134	10.57166442
		DEBELOSLOJEVITI VAPNENCI I DOLOMITI (srednja jura)	1047.246951	10.00329975
	JURA	VAPNENCI I DOLOMITI (gornja jura)	1841.467256	17.58968973
		VAPNENCI S ROŽNJACIMA: slojeviti s dolomitima (gornji oksford - donji titon)	103.8116277	0.991608358
		VAPNENCI S ROŽNJACIMA: pločasti slojeviti - Lemeške naslage (gornji oksford - donji titon)	11.08842603	0.105916612
		PRIGREBENSKO-GREBENSKI VAPNENCI I DOLOMITI (kimeridž, titon)	371.4784615	3.548361154
		SLOJEVITI I MASIVNI DOLOMITI (titon, valendis)	6.159191767	0.058832581
		VAPNENCI I DOLOMITI (donja kreda)	1844.309123	17.61683524
		DOLOMITI I POSTSEDIMENTACIJSKE DIJAGENETSKJE BREČE (gornji alb, donji cenoman)	163.3099322	1.559935984
KENOZOIK	PALEOGEN	RUDISTNI VAPNENCI (cenoman - mastriht)	1062.460632	10.14862079
		KARBONATNI FLIŠ I KLASTITI (paleocen, eocen)	2.847911391	0.027203241
		LIBURNIJSKE NASLAGE, FORAMINIFERSKI VAPNENCI I PRIJELAZNE NASLAGE (?gornji paleocen, donji i srednj*)	34.71982884	0.331643701
		FLIŠNE NASLAGE (srednji i gornji eocen)	17.32584784	0.165496447
		PROMINSKE NASLAGE (eocen, oligocen)	24.13535486	0.230540837
		VAPNENAČKE BREČE (paleogen, neogen)	757.2671826	7.233413866
		MIOCENSKJE NASLAGE DINARIDA	10.8416026	0.103558956
	NEOGEN	KLASTIČNE NASLAGE PLIOKVARTARA	5.622360365	0.053704769
KVARTAR	PLEISTOCEN	FLUVIOGLACIJALNE NASLAGE (pleistocen)	10.82617052	0.103411548
		FLUVIJALNE NASLAGE (pleistocen)	6.398286431	0.061116413
	HOLOCEN	EOLSKI PIJESCI (holocen)	5.070159065	0.048430144
		JEZERSKE NASLAGE (holocen)	18.57715087	0.17744889
		BARSKE NASLAGE (holocen)	42.83446007	0.409154635
		DELUVIJALNO-PROLUVIJALNE NASLAGE (holocen)	435.2558147	4.157562241
		ALUVIJALNE NASLAGE (holocen)	150.7816614	1.44026598


Izvor: Osnovna Geološka karta Republike Hrvatske, 1:300.000



Sl. 6.1.1 Litostratigrafske kartirane jedinice na prostoru GH

Izvor: izrađeno prema Osnovnoj Geološkoj karti Republike Hrvatske, 1:300.000

Prostor GH cijelim je svojim opsegom dio krških Dinarida. Današnja orografija Dinarida najvećim je dijelom posljedica tektonski aktivnog razdoblja koje je započelo krajem krede i početkom tercijara, a trajalo je do kraja miocena, najvjerojatnije i početka pliocena, no to je samo jedna od tektonskih faza koje se mogu raspoznati u stijenskom zapisu. Prisutnost vrlo strmo položenih površina reverznih struktura ukazuju na reaktivaciju struktura mezozojsko karbonatnog kompleksa. Tijekom ranijeg mezozoika na prostor GH djelovali su ekstenzijski tektonski pokreti, dok krajem mezozoika na prijelazu u rani kenozoik počinje kompresijsko djelovanje tektonike. Daljnjim sužavanjem prostora u mlađem eocenu i oligocenu prestaje klastično-karbonatna sedimentacija u najvećem dijelu područja današnjih Krških Dinarida, te započinje konačno izdizanje Dinarida kao planinskog lanca. Izdizanje i kontrakcija prostora posljedica su kompresijske tektonike koja je u to vrijeme djelovala najvećim regionalnim stresom po pravcu sjeveroistok- jugozapad. Kombinacijom boranja, reverznog rasjedanja i navlačenja nastale su strukture čije je glavno obilježje pružanje po pravcu sjeverozapad-jugoistok - tzv. strukture dinarskog pravca pružanja. Intenzivni kompresijski tektonski pokreti uzrokovali su značajna kretanja i ekshumaciju čak i gornjopaleozojskih naslaga. Sredinom ili krajem miocena započelo je neotektonsko razdoblje, koje traje i danas, a djelovanje regionalnog stresa usmjereno je u pravcu I-Z. U neotektonskom razdoblju reaktivirane su postojeće strukture (Velić i Vlahović, 2009). Na Sl. 6.1.2 prikazane su geološke granice i strukture na prostoru GH. Razlomljenost litostratigrafskih jedinica značajna je u dijelu Gorskog kotare gdje su strukturni elementi brojniji, ali i manji, što se odražava i u morfostrukturama tog prostora. Strukturni elementi Like definiraju orografske odnose i pružanje morfostrukture koje su sve izdužene u smjeru SZ-JI, za razliku od goranskog dijela prostora gdje je prisutan velik broj struktura usmjerenja Z-I.




Sl. 6.1.2 Karta geoloških granica i strukturnih elemenata GH

Izvor: izrađeno prema Osnovnoj Geološkoj karti Republike Hrvatske, 1:300.000


6.1.2. Hipsometrija

Distribucija vrijednosti nadmorskih visina u GH je normalna što nije uobičajeno za reljef Hrvatske, ali i reljef općenito, gdje prevladavaju niže nadmorske visine (Sl. 6.1.3). Najmanja visina na prostoru GH je 24 m n.v. dok je najveća 1.831 m n.v., što čini raspon od 1.807 m. Srednja vrijednost nadmorskih visina iznosi 779,14, dok je medijan vrlo blizu na 747 m n.v., čime se još jednom potvrđuje simetrična distribucija vrijednosti. Obzirom na regionalni obuhvat istraživanja, distribucija vrijednosti nadmorskih visina ukazuje na dinamičan i raščlanjen reljef.




Sl. 6.1.3 Distribucija vrijednosti nadmorskih visina (m) na prostoru GH

Na Sl. 6.1.4 prikazani su udjeli površina pojedinih hipsometrijskih razreda koji potvrđuju normalnu distribuciju vrijednosti, a kao najzastupljeniju razred izdvaja se onaj od 600-800 m n.v. (31,2 %), dok su n.v. do 200 m zastupljene sa samo 0,02%.



Sl. 6.1.4 Udjeli površina pojedinih hipsometrijskih razreda (m n.v.) u ukupnoj površini GH

Hipsometrijska obilježja prikazana na Sl. 6.1.2.3 prikazuju glavne orografske cjeline Gorske Hrvatske. U visinskim razredima iznad 1.000 m n.v. ističu se svi najistaknutiji konveksni oblici u GH. To su masivi, planinski lanci i gorske skupine. Najznačajniji su Obruč/Grobničke Alpe, Snježnik, Risnjak, Velika Kapela, Mala Kapela, Velebit s masivom Crnopca, Medveđak, Lička Plješivica, Poštak, Ličko sredogorje, Dinara, Svilaja i Kamešnica. Jasno se izdvajaju i sve veće krške depresije u obliku zavala polja u kršu, krške zaravni i doline velikih tekućica. Sve orografske strukture izdužene su u dinarskom pravcu SZ-JI.



Sl. 6.1.5


Hipsometrijska obilježja GH s istaknutim linijama hipsometrijskih profila

Regionalno jasne orografske strukture konveksne ili zaravnjene morfologije vidljivo zauzimaju niže hipsometrijske razrede tj. do 600 m n.v. Najznačajnije takve strukture su Ogulinsko-Plašćanska zaval, niz polja Drežničko-Lug-Crnačko-Stajničko, zatim Kosinjsko-Gacko-Ličko i Gračačko polje, Krbavsko, Lapačko i Koreničko te fragmenti Unsko-Koranske krške zaravni i doline izvorišnih dijelova Une i Krke.


Prema prostornoj raspodjeli hipsometrijskih razreda vidljivo je da je najzastupljeniji hipsometrijski razred (600-800 m n.v.). Taj hipsometrijski razred uokviruje izrazito visoke i raščlanjene dijelove reljefa te ih dijeli od onih nižih i zaravnjenijih dijelova reljefa. Najniži hipsometrijski razred pojavljuje se izolirano samo na SZ dijelu GH u kanjonu rijeke Kupe koja u tom dijelu čini i granicu GH. Hipsometrijski razred od 200-400 m u SZ dijelu GH uz kanjon rijeke Kupe i uz vodotok rijeke Korane javlja se u najvećem arealu, a izolirano je prisutan u dolinama većih tekućica kao što su rijeka Una, Butižnica, Krčić i Radljevac kao pritoke Krke u gornjem toku. Morfologija dva najniža hipsometrijska razreda prati doline tekućica te su u smjerovima tečenja izduženi. Hipsometrijski razred koji obuhvaća visine od 400 do 600 m n.v. javlja se u vrlo velikim arealima unutar zavalata krških polja, na fragmentima krških zaravni te na padinama brdskih okvira dolina velikih tekućica. Visinski razredi od 800-1.000 i od 1.000-1.200 m n.v. prisutni su na padinama najviših orografskih struktura (Velika Kapela, Lička Plješivica, Velebit, Dinara, Svilaja), te na grebenima i padinama ostalih masiva i lanaca (Obruč, Risnjak, Snježnik, Mala Kapela, Ličko sredogorje, Poštak). Najviši hipsometrijski razred (1.400-1.831 m n.v.) u najvećem kontinuiranom arealu nalazi se na Velebitu. Javlja se i na najvišem grebenu Velike Kapele, na grebenima Ličke Plješivice, Dinare i Svilaje.

Obzirom na morfologiju prostora GH u kojoj se hipsometrijski viši dijelovi izdvajaju u nizovima koji uokviruju središnji više zaravnjen i hipsometrijski niži prostor, izrađeno je više hipsometrijskih profila. Na hipsometrijskom profilu (Sl. 6.1.6) od Obruča na sjeveru do Koma na jugu prostor se postepeno snižava prema Gackom polju gdje se spušta na 450 m n.v. Profil prolazi istočnim rubom zavalata Ličkog polja te zahvaća južni dio Ličkog sredogorja čiji se vrhovi nalaze na oko 1000 m n.v. Krajnji južni dio Ličkog sredogorja je u kontaktu s Gračačkim poljem koje je generalno zaravnjeno na n.v. oko 550 m. Hipsometrijski profil (Sl. 6.1.7) Pokupsko pobrđe-Kamešnica prolazi istočnim rubom GH. Uočljiv je trend rasta n.v. od S prema J. Sa nešto više od 700 m n.v. na vrhovima Pokupskog pobrđa, prostor se snižava prema dolini rijeke Dobre gdje n.v. iznosi oko 320 m. U cijelom ovom profilu izmjenjuju se strmo uzdignute padine i grebeni planinskih lanaca ili masiva te zavalata polja ili doline tekućica. Dno Lapačkog polja je na oko 550 m n.v., izvorišni prostor rijeke Une na 630 m n.v., a izvorišni prostor rijeke Krke na 350 m n.v. Lapačko polje i izvorišni prostor Une uokvireni su sa svoje zapadne strane padinama Ličke Plješivice, a od izvorišnog prostora rijeke Krke odvojeni su masivom Poštaka. Od izvorišnog dijela rijeke Krke rub GH se strmo izdiže prema grebenima Dinare na 1800 m n.v. te nastavlja planinskim okvirom do J kraja GH na grebenima Kamešnice (1300 m n.v.). Većinski dio zapadnog ruba GH čini planinski lanac Velebita. Od S do J zapadnog ruba (Sl.


6.1.8) počevši od Senjskog bila, planinski lanac Velebita uzdiže na visine veće od 1.000 m. Hipsometrijski se jasno izdvajaju sjeverni, srednji i južni dio Velebita. Grebeni sjevernog Velebita nalaze se na oko 1500 m n.v., dok je srednji Velebit hipsometrijski niži (oko 1200 m n.v.) od kuda se ponovno izdiže prema jugu i najvišem Vaganskom vrhu na 1.757 m n.v. Krajnji JI dio Velebita se spušta te se na masivu Crnopca n.v. kreću oko 1.300 m n.v. U najširem dijelu GH u smjeru Z-I od Velebita prema Ličkoj Plješivici (Sl. 6.1.9) jasno je vidljiv planinski karakter okvira Like te unutarnji generalno zaravnjen i hipsometrijski niži prostor zavale najvećeg polja u kršu u prostoru istraživanja. Velebit se od 0 m n.v. izdiže na oko 1.500 m n.v., pa se sa svoje istočne padine vrlo strmo obrušava u zavalu Ličkog polja na 590 m n.v. Dno zavale Ličkog polja blago se uzdiže prema I gdje je Ličkim sredogorjem odvojeno od Kravskog polja. Istočni rub Kravskog polja u kontaktu je s padinama Ličke Plješivice koje se uzdižu do vrhova na oko 1.550 m n.v. Istočne padine Ličke Plješivice potom se strmo obrušavaju u Lapačko polje te dalje prema dolini rijeke Une na 520 m n.v.



Sl. 6.1.6 Hipsometrijski profil Obruč-Velika Kapela-Ličko sredogorje-Kom



Sl. 6.1.7 Hipsometrijski profil Pokupsko pobrđe-Dobra-Lička Plješivica-Poštak-Dinara-Kamešnica



Sl. 6.1.8 Hipsometrijski profil Velebit-Tremzina-Poštak




Sl. 6.1.9 Hipsometrijski profil Velebit-Ličko polje-Lička Plješivica-Srb

6.1.3. Nagibi

Nagibi padina klasificirani su prema standardnoj geomorfološkoj klasifikaciji Internacionalne Geografske Unije (Demek, 1972). Na prostoru GH zastupljeni su nagibi od 0 do 87° (Sl. 6.1.11). Nagibi veći od 87° također su prisutni, ali nisu identificirani u obradi izvornog DMR-a te su te vrijednosti zbog prostorne rezolucije ostale izostavljene. Prostorom dominira klasa nagiba 12-32° koja zauzima čak 48% ukupne površine GH (Sl. 6.1.11). Srednja vrijednost nagiba padina iznosi 13°, dok je medijalna vrijednost 12°. Srednja i medijalna vrijednost u slučaju nagiba GH nisu reprezentativne vrijednosti obzirom da je distribucija apsolutnih vrijednosti desna, tj. većina vrijednosti nalazi se na lijevoj strani grafa (Sl. 6.1.10). Unatoč tome što distribucija


vrijednosti nagiba padina nije simetrična, ona je potpuno normalna za ovaj morfometrijski pokazatelj, jer su velike vrijednosti nagiba padina u stvarnosti rijetke. Kao i kod hipsometrije, distribucija vrijednosti nagiba padina ukazuje na vrlo raščlanjen i dinamičan reljef.




Sl. 6.1.10 Distribucija vrijednosti nagiba padina (°)

Prostorna distribucija nagiba na prostoru GH prikazana je na Sl. 6.1.12. Najzastupljenija klasa nagiba u RH je 0-2° koja je prisutna na 43.5% teritorija (Lozić, 1996). Najzastupljenija klasa nagiba GH prisutna je na svim konveksnim strukturama u prostoru: pobrđa, padine planinskih lanaca i masiva, jaruge te strme strane kanjonskih tokova velikih tekućica. Na takvim padinama izražena je snažna denudacija, spiranje te izrazito kretanje masa. Klasa nagiba 0-2° karakterizirana je kao ravničarski prostor na kojima se ne opaža kretanje masa. Ova klasa na prostoru GH zastupljena je sa 10,2%, a prostorno se manifestira u izoliranim arealima vezanim uz dna zavalu krških polja, na fragmentima krških zaravni, u dolinama tekućica. Na fragmentima krških zaravni ova klasa javlja se mozaično u vrlo malim površinama na grebenima koji odvajaju mnogobrojne ponikve ili također mozaično u dnima većih ponikvi. Klasa nagiba padina 2-5° predstavlja generalno zaravnjen reljef sa slabo izraženim spiranjem. Na prostoru GH zastupljena je na 11,48% površine. Klasa je kompozicijom vrlo mozaična na fragmentima krških zaravni, u dnima ponikava i na vanjskim obodima ponikava. U nešto većim arealima javlja se na kontaktima fluviodenudacijskih padina s rubovima polja u kršu ili pretežito fluvioakumulacijskim terenima, ali i na predgorskim stepenicama. Klasa nagiba padina 5-12° obuhvaća nagnute terene na kojima je prisutno pojačano spiranje i kretanje masa. Na prostoru GH, ova klasa zauzima 26,6% površine. vrlo je raspršene kompozicije te se javlja mozaično na fragmentima zaravni među ponikvama, na grebenima i padinama nižih pobrđa, i na padinama visokih planinskih lanaca i masiva. Klasa nagiba od 32-55° obuhvaća vrlo strme terene na

kojima su prisutni intenzivni derazijski procesi. Na prostoru GH javlja se na 3,5% ukupne površine. Uzorci ove klase su izduženi i kontinuirani, a prisutni su u na padinama duboko usječenih dolina oblikovanih fluviudenudacijskim procesima ten a padinama hipsometrijski najviših planinskih lanaca i masiva. U konkavnim i hipsometrijski nižim predjelima ova klasa u potpunosti izostaje. Klasa nagiba padina većih od 55° na prostoru GH javlja se na 0,05% površine. Kompozicija klase je pokazuje izoliranost pojedinih areala koji se javljaju na specifičnim mjestima kao što su kameniti grebeni i vrhovi Velebita, uključujući i kukove, na padinama duboko usječenih jaruga u izvorišnim dijelovima velikih tekućica te na predgorskoj stepenici Dinare. U ovoj klasi nagiba padina prisutni su strmci, a glavni procesi su urušavanje i osipavanje materijala.



Sl. 6.1.11 Udjeli površina pojedinih klasa nagiba padina (°) u ukupnoj površini GH




Sl. 6.1.12 Klase nagiba padina (°) na prostoru GH

6.1.4. Orijentacija padina

Orijentacija padina prema glavnim i sporednim stranama svijeta (u klasama po 45°). Prostorna distribucija orijentacije padina na prostoru GH prikazana je na Sl. 6.1.12 Kompozicija klasa orijentacije padina u nekom prostoru može ukazivati na značajne strukturno-geomorfološke jedinice.


Na prostoru GH klase su izrazito mozaične strukture te raspršene u veoma male areale što ukazuje na raznolikost morfologije padina. Prostorno se izdvajaju zone dominantno SZ i zone dominantno JI orijentacije padina, što je okomito na dinarski pravac.



Sl. 6.1.13 Orijentacija padina prema glavnim i sporednim stranama svijeta (°) na prostoru GH


Distribucija vrijednosti je lijeva, na što ukazuje izgled histograma distribucije vrijednosti (Sl. 6.1.14), ali i srednja i medijalna vrijednost stupnjeva, tj. orijentacije padina.

Na histogramu distribucije vrijednosti vidljivo je kako postoje dva maksimuma vrijednosti, no ipak prevladava desna strana grafa u vrijednostima koje se odnose ne padine JZ orijentacije. Manji maksimum s lijeve strane grafa okupljen je oko vrijednosti koje ukazuju na SI orijentaciju padina.



Sl. 6.1.14 Distribucija vrijednosti orijentacije padina (°)

Kada su vrijednosti klasificirane, opet se potvrđuju dva maksimuma, od kojih je najveći u padinama JZ orijentacije, dok je manje izražen maksimum vezan za padine SI orijentacije (Sl. 6.1.15). Orijentacija padina u pravcu SI-JZ ukazuje na značaj neotektonike i izražen utjecaj strukture na morfologiju morfostrukture. Indikativan je i podatak da je klasa orijentacije vrijednosti 0 potpuno nepostojeća.




Sl. 6.1.15 Udjeli površina pojedinih klasa orijentacije padina (°) u ukupnoj površini GH

Najveći areali padina orijentiranih na JZ prisutni su na hipsometrijski najvišim morfostrukturama (planinski lanci, masivi), a najistaknutiji takvi areali su na krajnjem južnom

dijelu prostora na padinama Dinare, Kamešnice i Svilaje. Padine JZ i SI orijentacije u većim arealima javljaju se i u izvorišnim dijelovima velikih tekućica, što također ukazuje na strukturnu uvjetovanost razvoja hidrografske mreže u prostoru GH. km²


6.1.5. Vertikalna raščlanjenost reljefa

Vertikalna raščlanjenost reljefa parametar je intenziteta egzogenih procesa u lokalnim okvirima, tj. prostori s većim vrijednostima su dominantno denudacijski, dok su prostori s manjim vrijednostima dominantno akumulacijski. U regionalnom okviru predstavlja odraz neotektonske aktivnosti, tj. ukazuje na položaj struktura te na njihov predznak (Lozić, 1995). Vertikalna raščlanjenost reljefa klasificirana je prema unaprijed utvrđenim klasama prema (Bognar, 1992). Prostorni raspored klasa vertikalne raščlanjenosti reljefa prikazan je na Sl. 6.1.18. Distribucija vrijednosti je desna što je vidljivo na histogramu (Sl. 6.1.16). Takva distribucija je očekivana za ovaj pokazatelj.




Sl. 6.1.16 Distribucija vrijednosti vertikalne raščlanjenosti reljefa (m/km²)

Udjelom, klasa 100-300 m/km² (umjereno raščlanjen reljef) zauzima najveću površinu, 65,4% (Sl. 6.1.17). Unatoč desnoj distribuciji apsolutnih vrijednosti, kada su vrijednosti klasificirane u klase koje odgovaraju prirodi procesa koje se odražavaju pokazateljem, distribucija klasificiranih vrijednosti pokazuje lijevu usmjerenost, tj. najviše vrijednosti se nalazi s desne strane grafa. Postotni udjeli u 4. klasi vertikalne raščlanjenosti reljefa odudaraju od udjela klasa vertikalne raščlanjenosti reljefa na razini cijele RH (Lozić, 1995).



Sl. 6.1.17 Udjeli površina pojedinih klasa vertikalne raščlanjenosti reljefa (m/km²) u ukupnoj površini GH


Klasa vertikalne raščlanjenosti reljefa 100-300 m/km² proteže se kroz cijeli prostor na pobrđima te na gorskim stranama svih planinskih masiva i lanaca, ali i na vršnim dijelovima i grebenima planinskih lanaca i masiva. Zaravnjen reljef (0-5 m/km²) zauzima 0.17% prostora GH, a nalazi se samo u izoliranim arealima na dnima velikih polja u kršu. Slabo raščlanjene ravnice (5-30 m/km²) zauzimaju 5,1% prostora GH, javlja se u izoliranim arealima na dnima većih krških depresija. Najveći areali smješteni su u najvećim poljima u kršu. Slabo raščlanjen reljef (30-100 m/km²) zastupljen je s 14% na prostoru GH. Kompozicija ove klase je raspršena po cijelom prostoru, a areali su različitih oblika i veličina. Izduženi areali ove klase javljaju se na kontaktima velikih krških depresija i gorskih strana, dok se najveći areali nalaze na fragmentima zaravni, na nižim pobrđima oblikovanim fluviodenudacijskim reljefom. Izrazito raščlanjen reljef (100-500 m/km²) zauzima 15,1% prostora GH, a javlja se u hipsometrijski višim prostorima u izduženim arealima dinarskog smjera pružanja. U cijelom prostoru istraživanja, ova klasa se javlja na izrazito denudiranim padinama izvorišnih dijelova velikih tekućica te na strmim padinama koje se obrušavaju prema manjim i većim krškim depresijama te na padinama predgorskih stepenica. Isključivo na Velebitu, ova klasa je zastupljena i na visokim uzdužnim grebenima. Vrlo izrazito raščlanjen reljef (>800 m/km²) zauzima 0,01% prostora, što je ujedno i najmanje zastupljena klasa. Prisutna je u samo dva izrazito mala areala podno Vaganskog vrha te na padinama podno vrha Dinara.



Sl. 6.1.18 Nagibi reljefa na prostoru GH


6.1.6. Topographic Position Index (TPI)

TPI uspoređuje nadmorsku visinu svake ćelije unutar definiranog susjedstva. Kombinacijom TPI-a izrađenog u dva različita mjerila te korekcijom pojedinih klasa s vrijednostima nagiba dobiva se realnija slika pojavnosti reljefnih oblika, tj. identificiraju se i ugniježđeni reljefni oblici (Weiss, 2001). Na prostoru GH javlja se svih 10 klasa TPI-a (Sl. 6.1.19).




Sl. 6.1.19 Topographic Position Index – reljefni oblici na prostoru GH

Klase TPI-a od 1 do 4 odnose se na konkavne oblike, klasa 5 na zaravnjene, a klase 6 do 10 odnose se na konveksne reljefne oblike. Distribucija klasa TPI-a na prostoru GH je simetrična, s malenom prevlašću lijeve distribucije obzirom da je medijalna vrijednost veća od srednje vrijednosti (Sl. 6.1.20).



Sl. 6.1.20 Distribucija klasa TPI-a


Udjelom najveću površinu zauzima klasa 6-padine dolinskih strana (Sl. 6.1.21). Kompozicija ove klase je izrazito mozaična te je prisutna na svim morfostrukturama, osim u dnima velikih krških depresija. Prisutna je na nižim padinama fluviudenudacijskih pobrđa, tj., na kosama razdvojenim manjim jarugama. Na krškim pobrđima izduženo prati morfologiju nižih padina pri kontaktu s lokalnim erozijskim bazama. Mozaičan izgled poprima na manje nagnutim padinama gorskih masiva i hrptova s razvijenom mrežom ponikvi, te na fragmentima zaravni, također s razvijenom mrežom ponikvi.



Sl. 6.1.21 Udjeli površina pojedinih klasa TPI-a u ukupnoj površini GH

Sljedeća po zastupljenosti je klasa 5- zaravni i ravnice ($n^{\circ} \leq 5$) koja zauzima 17,6% površine, a kompozicijom je veoma okupljena te se javlja u velikim arealima. Većim dijelom nalazi se na dnima krških polja, fluvioakumulacijskim dolinama te na fragmentima zaravni. U vrlo malim arealima, gotovo točkasto javlja se u dnima ponikvi u nižim hipsometrijskim razredima ili kao ugniježđena dna ponikvi na vršnim dijelovima planinskih masiva i lanaca. Linijski se javlja u dnima manjih jaruga i vododerina te na zaravnjenim tjemena kosa i vrhova hipsometrijski najnižih pobjega. Klasa 4- široke doline, niži pristranci, zastupljena je s 8,5%. Areali su generalno izduženi i to u dinarskom pravcu, a upravo takvi nalaze se na najnižim padinama planinskih masiva i hrptova. U kontaktnim dijelovima strmih padina planinskih okvira s poljima u kršu javlja se u većim, rasprostranjenim arealima. Na cijelom prostoru istraživanja, ova klasa se javlja na blaže nagnutim padinama oblikovanim fluviodenudacijom u izvorišnim dijelovima velikih tokova. Klasa 7-padine gorskih strana zauzima 7,3% prostora, a kompozicijom je ova klasa u potpunosti izdužena u dinarskom pravcu te je smještena podno vršnih dijelova planinskih masiva i hrptova, na raščlanjenim grebenima nižih pobjega, te na tjemena većih jaruga. Klasa 10-vrhovi i izraziti grebeni javlja se na 6,9% prostora. Kompozicijom je također izdužena u dinarskom pravcu, a nalazi se na grebenima najviših planinskih masiva i lanaca. U S dijelu istraživanog prostora na masivu Obruča, Snježniku i Risnjaku i Velikoj Kapeli prevladavaju manji areali većinom dinarskog pravca pružanja, ali se javljaju i grebeni poprečnog usmjerenja (I-Z). Najveći kontinuirani izduženi areali prisutni su na Velebitu i javljaju se u nizovima. Klasa 2-uske doline V profila javlja se na 6,9% prostora. Također su areali generalno dinarskog smjera pružanja, poglavito u krškom morfogenetskom tipu reljefa gdje se ova klasa javlja na dnima velikih ponikvi i dnima nizova ponikvi, krškim uvalama i međugorskim zavalama. U fluviodenudacijskom i fluviokrškom morfogenetskom tipu reljefa ova klasa se manifestira u dolinama nastalim jaružanjem, a javlja se i u dolinama većih tekućica. Klasa 9-tjemena uzvišenja, uzvišenja u ravninama zauzima 6,3% prostora GH. Klasa se javlja na svim konkavnim oblicima te kako i sam naziv klase nalaže čini tjemena uzvišenja tj. sporedne grebene na planinskim masivima i hrptovima, te grebene pobjega i izoliranih uzvisina u pretežito nižim prostorima. U fluviodenudacijskom morfogenetskom tipu reljefa javlja se i na obodima velikih jaruga i na rubovima kanjonskih dijelova velikih tekućica. Klasa 1-duboko usječene doline, kanjoni zauzima 4,5% prostora. Kompozicijom su areali vrlo izduženi jer prate dna kanjona velikih tekućica ili predgorske stepenice i eskarpmane na planinskim masivima i hrptovima. Javlja se i u duboko usječenim jarugama te vrlo dubokim ponikvama. Klasa 3-izvorišta, prikupišta oborine zauzima 0,4% površine, a javlja se samo u


hipsometrijski višim dijelovima prostora, u dubokim ponikvama, mrežama dubokih ponikava i u izvorišnim oblucima te tjemenu velikih jaruga. Najmanje zastupljena je klasa 8-manji grebeni i kose, uzvišenja u dolinama koja se nalazi na 0,2% prostora. Ova se klasa javlja izolirano u fluviodenudacijskom morfogenetskom tipu reljefa u izvorišnim prostorima velikih tekućica (Kupa, Dobra). Na Velebitu se javlja na tjemenu predgorske stepenice. Primjeri klasa TPI-a u prikazani su na Sl. 6.1.22



Sl. 6.1.22 Topographic Position Index – pregled kompozicije pojedinih klasa na prostoru GH

6.1.7. Krške depresije

Zatvorene krške depresije variraju po veličini i genezi, a najbrojnije su ponikve, koje su ujedno i dijagnostički reljefni oblici krša. U krške depresije spadaju još i krške uvale, poligenetske krške depresije i zavale polja u kršu. Na prostoru GH evidentirano je 378 krških uvala i 35 polja u kršu koja se nalaze na 16% površine GH (Sl. 6.1.23).




Sl. 6.1.23 Polja u kršu i krške uvale na prostoru GH


Prostorna distribucija polja u kršu konkordantna je morfometrijskim obilježjima zaravnjenih te hipsometrijski naj nižih područja. Na samom jugu prostora GH nema evidentiranih polja u kršu, dok je središnjim dijelom između Velebita, Ličkog sredogorja i Ličke Plješivice dominiraju. S obzirom na veličinu, ona najveća polja nalaze se u središnjem dijelu GH, dok su manja položena u sjevernom djelu GH. S druge strane, krške uvale konkordantne su morfometrijskim klasama dinamičnog te hipsometrijski višeg reljefa te su tako položene i rasprostranjene na planinskim masivima, gorskim skupinama i lancima, izdužene u smjeru pružanja većih struktura. Na krajnjem sjevernom djelu GH javlja se veća gustoća krških uvala, dok su najmanje zastupljene na krajnjem južnom dijelu.

Hipsometrijski, krške uvale javljaju se u rasponu od 196 do 1.547 m n.v. Krške uvale koje se javljaju od 196 do 500 m n.v. svojim oblikom te trenutnim morfogenetskim okruženjem odudaraju od generalnog poimanja krških uvala. Ove su krške depresije ostatci paleo drenažne mreže i “*compound*” krške depresije na krškoj zaravni nastale spajanjem dna manjih krških depresija duž izraženih pukotina. Prema površini, najzastupljenije su uvale koje spadaju u naj manju klasu (do 1,5 km²), što čini 84% svih uvala na prostoru GH (Sl. 6.1.25).

Uvale koje spadaju u klasu najvećih površinom (4.5 do 18,7 km²) u pravilu se nalaze u rasjednim zonama te su ispresječene sa dva ili više rasjeda. Iako su sve uvale strukturno predisponirane, one kompleksnijih tlocrta te većih površina odraz su kompleksnije strukture te kompleksa procesa koji su sudjelovali u njihovoj genezi. Na planinskim masivima i u gorskim skupinama uvale su prostorno raspršenije, te su neke izdužene u dinarskom pravcu, a neke okomito na njega. Uvale u nizovima duž dinarskog pravca primjetne su duž Velebita i Dinare (Sl. 6.1.24).




Sl. 6.1.24 Prostorna distribucija krških uvala prema površini (km²)



Sl. 6.1.25 Raspodjela broja krških uvala po površini (km²)


Analizom odnosa opsega i površine svih krških uvala, izdvojeno je 13 krških uvala koje odstupaju od prosjeka tj. ponašaju se kao ekstremne vrijednosti. Daljnjom analizom utvrđeno je da su izdvojene krške depresije poligenetske, dok su krške uvale isključivo krški oblici u kojima vlada korozija kao primarni proces tj. takozvane prave krške uvale (Sl. 6.1.26).



Sl. 6.1.26 Odnos površine i opsega krških uvala na prostoru GH


Analizom pokazatelja odnosa ruba i površine (eng. *edge area ratio*) vidljiva je desna distribucija podataka, što ukazuje na vrlo jednostavne uzorke krških uvala (Sl. 6.1.27). Ovim pokazateljem kvantificira se kompleksnost ili jednostavnost pojedinog poligona, ali je osjetljiv na velike površine, tj. povećanjem površine poligona uzrokuje se smanjenje vrijednosti odnosa ruba i površine. Iz ovog skupa podataka izdvojene su sve krške uvale koje se nalaze izvan jedne standardne devijacije, tj. krške uvale najkompleksnijih oblika. Takvih uvala je ukupno 49. Daljnjom analizom utvrđeno je kako izdvojene uvale površinom spadaju u male krške uvale, te

su većinom plitke uvale nastale na zaravni, suhe doline tj. okršeni relikti paleodrenažne mreže i napuštene ponorske-slijepe doline.




Sl. 6.1.27 Distribucija vrijednosti odnosa ruba i površine krških uvala na prostoru GH

Dna polja u kršu nalaze se na visinama od 343 do 1.194 m n.v. Ona s najmanjom visinom dna nalaze se između Velike i Male Kapele te sjevernog dijela Velebita. S druge strane se ističu polja na Velebitu čija su dna ujedno najviša (800-1.194 m n.v.) Najveće je Ličko polje, čije se dno rasprostire na visini od 500 do 700 m n.v. Sljedeće po veličini je Gacko, zatim Gračačko koje je u istim hipsometrijskim okvirima kao i Ličko, te Krbavsko, čije dno je na visini od 600 do 700 m n.v. Brojem prevladavaju manja polja koja spadaju u klasu polja površine 0,5 do 30 km² (Sl. 6.1.28, Sl. 6.1.29). Ona čine 88,5% svih polja na prostoru GH. No, gledajući udio ukupne površine polja u kršu, četiri najveća polja zauzimaju 79,3% od ukupne površine svih polja u kršu na prostoru GH.




Sl. 6.1.28 Površine polja u kršu na prostoru GH



Sl. 6.1.29 Polja u kršu na prostoru GH klasificirana prema površini (km²)

Analizom odnosa površine i opsega opet se izdvajaju četiri najveća polja kao ekstremne vrijednosti (Sl. 6.1.30). Uz njih, izdvajaju se i Kosinjsko i Plaško polje.




Sl. 6.1.30 Odnos površine i opsega polja u kršu na prostoru GH

Analizom pokazatelja odnosa ruba i površine (eng. *edge area ratio*), kao i u slučaju krških uvala, distribucija je desna, tj. prevladavaju polja manje kompleksnih tlocrta.

Ponikve, kao najmanje od tri tipa analiziranih krških depresija, naj brojniji su reljefni oblik prisutan na prostoru GH. Na prostoru GH evidentirano je 184.034 ponikava. Stvarni broj ponikava vjerojatno je veći, obzirom da prostorna rezolucija DMR-a korištenog za izdvajanje ponikava. Prostorni raspored ponikava nije ujednačen te se izdvajaju pojedine jezgre većih gustoća ponikava (Sl. 6.1.31). Najveća gustoća ponikava iznosi 123,354 ponikava/km². Promatrajući cijeli prostor GH, dakle i dijelove bez ponikava, prosječna gustoća je 3,6 ponikava km². Distribucija vrijednosti gustoće je desna, tj. prevladavaju manje gustoće ponikava. Klasa neznatne gustoće (0-10 ponikava/km²) prostire se na 88,3% prostora GH. Klasa male gustoće (10-30 ponikava/km²) prostire se na 8,4% prostora. Klasa srednje gustoće (30-60 ponikava/km²) prostire se na 2,4%

površine, dok klase velike (60-100 ponikava/km²) i vrlo velike gustoće (100-200 ponikava/km²) skupa zauzimaju 0,7% prostora GH. Podatci o površini i udjelu pojedinih klasa gustoće ponikava prikazani su u Tab. 6.1.3. Klasa vrlo velike gustoće ponikava (100,001-123,354 ponikava/km²) te velike gustoće ponikava (60,001-100 ponikava/km²) u najvećem arealu nalaze se na prostoru Slunjske zaravni i JI okvira Ogulinsko-Plašćanske zavale. Velika gustoća ponikava javlja se i duž Ličkog sredogorja, na prostoru južnog Velebita te na masivu Crnopca i Tremzini. Najmanji areal ove klase gustoće ponikava javlja se i na gorskom hrptu Svilaje.




Sl. 6.1.31 Gustoća ponikava na prostoru GH

Tab. 6.1.3 Gustoća ponikava na prostoru GH – površine i udjeli pojedinih klasa


Klasa gustoće ponikava	Površina (km ²)	Udio (%)
0,001-10	44966,2535	88,35412
10,001-30	4287,3219	8,424151
30,001-60	1255,1199	2,466183
60,001-100	347,7577	0,683309
100,001-123,354	36,7641	0,072238

Obzirom na površinu koju ponikve zauzimaju u tlocrtu po najvišoj konturi oboda, znatne su razlike u veličinama ponikvi. Za potrebe ovoga rada, izdvojene su samo ponikve najvećih površina tlocrta (veće od 10.000 m²/0,01 km²) te je izračunata Kernel gustoća ponikava tlocrta velike površine. Obzirom da Kernel gustoća računa gustoću točaka, na nekim prostorima GH, ukoliko nisu izdvojene ponikve velikih tlocrta, dolazi do krive percepcije pojavnosti ponikava. Najveća površina tlocrta ponikve na prostoru GH 1,33 km², a nalazi se na krajnjem JI dijelu Velebita podno planine Tremzine, ponikva Duboki dol. Prema ovom pokazatelju, jezgre najvećih gustoća tlocrtom velikih ponikava javljaju se na krajnjem sjeveru na gorskim masivima Obruča, Snježnika i Risnjaka te Velike Kapele, na Slunjskoj zaravni, te duž Velebita i na dijelu SZ Ličkog sredogorja (Sl. 6.1.32). Na prostoru Slunjske zaravni zapravo se radi o plitkim ponikvama koje su snažnom korozijom spojene, te stoga tvore velike tlocrte. Izuzimanjem samo ekstremnih vrijednosti iz skupa ponikava velikih tlocrta, tj. ponikava tlocrta površine $\geq 0,05$ km² izdvaja se samo područje Velebita s jezgrom najveće gustoće na prostoru Sjevernog Velebita te sa sekundarnim jezgrom na južnom Velebitu (Sl. 6.1.32).

Distribucija broja ponikava u odnosu na morfometrijske karakteristike prostora kod svih morfometrijskih pokazatelja ukazuje na simetričnu distribuciju. Tako se najveći broj ponikava nalazi u hipsometrijskoj klasi 600-800 m n.v., u klasi nagiba 5-12°, u klasi vertikalne raščlanjenosti 100-300 m/km² (umjereno raščlanjen reljef). Kod distribucije vrijednosti broja ponikava po klasama orijentacije padina, distribucija je bimodalna, tj. najzastupljenije orijentacije su SZ, Z i S. Distribucije vrijednosti broja ponikava po pojedinim morfometrijskim pokazateljima prikazane su na Sl. 6.1.33.



Sl. 6.1.32 Gustoća ponikava tlocrta većeg od 0,01 km² te gustoća ponikava tlocrta većeg od 0,05 km² na prostoru GH



Sl. 6.1.33 Broj ponikava po klasama morfometrijskih obilježja, a) hipsometrija, b) nagibi, c) vertikalna raščlanjenost reljefa, d) orijentacija padina


Naj učestalija kombinacija morfometrijskih parametara na kojoj se javljaju ponikve je orijentacija padina prema SZ, klasa nagiba 5-12°, hipsometrijska klasa 600-800 m n.v. te klasa

umjereno raščlanjenog reljefa 100-300 m/km². Na takvoj morfometrijskoj konfiguraciji javlja se ukupno 2% ponikava. Sljedeća najzastupljenija kombinacija razlikuje se samo u orijentaciji padina koja je ovoj skupini ponikava dominantno zapadna. Takvih je ponikava ukupno 1,7%.

6.1.8. Speleološki objekti


Na prostoru GH evidentirano je 3.304 speleološka objekata. Stvarni broj je zasigurno veći, obzirom da nije cijeli prostor GH speleološki rekognosciran niti istražen, niti su podaci o svim do sada istraženim objektima tijekom izrade ove disertacije bili dostupni. Prostorna distribucija speleoloških objekata je neravnomjerna te se pojedina područja izdvajaju po gustoći speleoloških objekata. Prosječna gustoća speleoloških objekata je 0,07 speleoloških objekata/km², a najveća zabilježena je 5,99 speleoloških objekata /km². Samo 0,06% prostora spada u klasu najveće gustoće ponikava (4,796-5,993 speleoloških objekata/km²) (Sl. 6.1.39). Dvije su takve jezgre, jedna na prostoru Sjevernog Velebita, a jedna na prostoru JI Velebita, tj. masivu Crnopac. Na 5,3% površine GH nalazi se 50,3% svih speleoloških objekata.

Distribucija broja speleoloških objekata prema morfometrijskim karakteristikama različita je po svim morfometrijskim pokazateljima. Distribucija podataka je lijeva kod nagiba i vertikalne raščlanjenosti reljefa. U nekim klasama vertikalne raščlanjenosti reljefa nema zabilježenih speleoloških objekata, a to su klasa 0-5 m/km² (zaravnjen reljef) i klasa >800 m/km² (vrlo izrazito raščlanjen reljef). Speleološki objekti najzastupljeniji su u klasi 100-300 m/km² (umjereno raščlanjen reljef) u kojoj se nalazi 67,6% svih ulaza u speleološke objekte na prostoru GH. U klasi izrazito raščlanjenog reljefa (300-800 m/km²) nalazi se 23,2% speleoloških objekata. U klasi slabo raščlanjenog reljefa (30-100 m/km²) nalazi se njih 9%, dok se u klasi slabo raščlanjenih ravnica (5-30 m/km²) nalaze se 3 speleološka objekta. Broj i udio speleoloških objekata po klasama vertikalne raščlanjenosti reljefa nalazi se u Sl. 6.1.34, Tab. 6.1.4.



Sl. 6.1.34 Broj speleoloških objekata po klasama vertikalne raščlanjenosti reljefa


U klasi nagiba $12-32^\circ$ (jako nagnuti tereni) nalazi se 53% svih speleoloških objekata. Idući prema većim i manjim vrijednostima, broj speleoloških objekata opada. Sljedeća najzastupljenija klasa je $5-12^\circ$ (nagnuti tereni) u kojoj se nalazi 22,1% speleoloških objekata. Broj i udio speleoloških objekata po klasama nagiba prikazani su na Sl. 6.1.35 i u Tab. 6.1.4.



Sl. 6.1.35 Broj speleoloških objekata po klasama nagiba


Distribucija broja speleoloških objekata po hipsometrijskim klasama je bimodalna te posljedično ima dva maksimuma. Klasa 0-200 m n.v. nije zastupljena, tj. nema zabilježenih speleoloških objekata. Obzirom da se na prostoru GH ova klasa hipsometrije veže za fluvijalno-akumulacijski morfogenetski tip reljefa, rezultat je očekivan. Objekti su najbrojniji u klasi 600-800 m n.v. (22,1%), te u klasi 1.000-1.200 m n.v. (21,8%). Sljedeća najbrojnija klasa je 800-1.000 m n.v. sa 16,1%. Klase 400-600 m n.v. sa 13,3%, klasa 1.400-1.831 m n.v. s 12,2%, zatim klasa 1.200-1.400 s 10,9% su podjednako zastupljene. Klasa 200-400 m n.v. sadrži 3,2%

speleoloških objekata GH. Broj i udio speleoloških objekata po pojedinim hipsometrijskim klasama prikazan je na Sl. 6.1.37 i u Tab. 6.1.4.




Sl. 6.1.36 Broj speleoloških objekata po hipsometrijskim klasama

Distribucija speleoloških objekata po klasama orijentacije padina je bimodalna, s dva izražena maksimuma. Najveći broj speleoloških objekata ima ulaz na padini orijentiranoj prema SI (15,6%) i prema S (14%). Druge dvije najzastupljenije klase su JZ (13,4%) i Z (12,1%). Broj i udio speleoloških objekata po pojedinim klasama orijentacije padina prikazan je na Sl. 6.1.37 i u Tab. 6.1.4.



Sl. 6.1.37 Broj speleoloških objekata po klasama orijentacije padina

Distribucija broja speleoloških objekata po klasama TPI-a je simetrična, te se najveći broj speleoloških objekata nalazi u klasi padina dolinskih strana (40,2%). Sljedeća najzastupljenija klasa je padine gorskih strana (14,6%). Po brojnosti se još ističu i klasa uskih dolina, V profila (10,6%), te vrhovi i izraziti grebeni (8,5%). Broj i udio speleoloških objekata po pojedinim klasama orijentacije padina prikazan je na Sl. 6.1.38 i u Tab. 6.1.4.



Sl. 6.1.38 Broj speleoloških objekata po klasama TPI-a


Naj učestalija kombinacija morfometrijskih karakteristika padina na kojima se nalaze ulazi u speleološke objekte je orijentacija padina SI, klasa nagiba 12-32, klasa vertikalne raščlanjenosti reljefa 100-300 m/km², te hipsometrijska klasa 1.000-1.200 m n.v. Ovakva kombinacija javlja se kod 1,7% speleoloških objekata na prostoru GH.

Promatrajući morfometrijski kontekst klase najveće gustoće speleoloških objekata, speleološki objekti se javljaju samo u dvije klase vertikalne raščlanjenosti reljefa. Najbrojnija klasa vertikalne raščlanjenosti je 100-300 m/km² (umjereno raščlanjen reljef) gdje se nalazi 63% populacije speleoloških objekata. U klasi 300-800 m/km² (izrazito raščlanjen reljef) nalazi se 36% populacije speleoloških objekata u zoni najveće gustoće. U klasama nagiba dominira klasa 12-32° (56,7%) kao i u cjelokupnoj populaciji speleoloških objekata. Prostor s najvećom gustoćom speleoloških objekata generalno je hipsometrijski visok. Objekti se nalaze u rasponu od 600 do 1.831 m n.v., a kao i u cijeloj populaciji, distribucija broja speleoloških objekata po hipsometrijskim klasama je bimodalna te su izražena dva maksimuma. Primarni maksimum je u najvišoj klasi (1.400-1.831 m n.v.), koja prevladava na sjevernom Velebitu, te sekundarni maksimum u klasi 1.000-1.200 m n.v. koja prevladava na masivu Crnopca. Distribucija broja speleoloških objekata u području naj veće gustoće po klasama orijentacije padina, odudara od obilježja cijele populacije objekata GH, ali je također bimodalna. Maksimum je izražen na padinama orijentiranim prema SI (20%). Gotovo jednako su zastupljene padine orijentacije I (16,3%) i S (16,5%). Odnos broja speleoloških objekata u klasi najveće gustoće s klasama TPI-a u skladu je s karakteristikama cijele populacije, iako su neke klase TPI-a ovdje izostavljene, što je očekivano, jer se radi o hipsometrijski visokom prostoru. Najveći broj speleoloških objekata na prostoru velike gustoće nalazi se u klasi padine gorskih strana (36,5%) te u klasi padine dolinskih strana (25,9%). U odnosu na opću populaciju, najveća je razlika prisutna u

klasi izvorišta, prikupišta oborine koja na prostoru najveće gustoće sudjeluje s a 7,2% te se javlja samo na masivu Crnopca. Speleološki objekti čiji se ulazi nalaze u ovoj klasi TPI-a karakteristični su za masiv Crnopca, jer se upravo na tom prostoru nalazi glavnina populacije objekata u toj klasi (63%), dok su ostali objekti u ovoj klasi raspršeni duž Velebita. Sve vrijednosti (apsolutne i relativne) prikazane su u Tab. 6.1.4.

Tab. 6.1.4 Broj speleoloških objekata i udjeli po morfometrijskim pokazateljima


Speleološki objekti na prostoru GH			Speleološki objekti u klasi najveće gustoće speleoloških objekata na prostoru GH		
Vertikalna raščlanjenost reljef	Broj speleo	Udio (%)	Vertikalna raščlanjenost reljefa	Broj speleo	Udio (%)
5-30	3	0.000908			
30-100	298	0.090194	100-300	381	63.07947
100-300	2234	0.67615	300-800	223	36.92053
300-800	769	0.232748			
Nagibi (°)	Broj speleo	Udio (%)	Nagibi (°)	Broj speleo	Udio (%)
0-2	114	3.450363	0-2	3	0.496689
2-5	236	7.142857	2-5	5	0.827815
5-12	732	22.15496	5-12	48	7.94702
12-32	1752	53.02663	12-32	343	56.78808
32-55	442	13.37772	32-55	201	33.27815
>55	28	0.847458	55-90	4	0.662252
Hipsometrija (m n.v.)	Broj speleo	Udio (%)	Hipsometrija (m n.v.)	Broj speleo	Udio (%)
200-400	106	3.208232			
400-600	440	13.31719			
600-800	733	22.18523	600-800	2	0.331126
800-1000	533	16.13196	800-1000	46	7.615894
1000-1200	723	21.88257	1000-1200	219	36.25828
1200-1400	363	10.98668	1200-1400	103	17.05298
1400-1831	406	12.28814	1400-1831	234	38.74172
Orijentacija padina	Broj speleo	Udio (%)	Orijentacija padina	Broj speleo	Udio (%)
Zaravnjeno	21	0.635593			
S	463	14.01332	S	100	16.55629
SI	516	15.61743	SI	121	20.03311
I	409	12.37893	I	99	16.39073
JI	320	9.68523	JI	61	10.09934
J	370	11.19855	J	48	7.94702
JZ	446	13.49879	JZ	48	7.94702
Z	402	12.16707	Z	63	10.43046
SZ	357	10.80508	SZ	64	10.59603
TPI	Broj speleo	Udio (%)	TPI	Broj speleo	Udio (%)
vrhovi i izraziti grebeni	282	8.535109	vrhovi i izraziti grebeni	78	12.91391
tjemene uzvisine, uzvisine u rav	161	4.872881	tjemene uzvisine, uzvisine u rav	46	7.615894
grebeni i kose, uzvisine u doli	3	0.090799			
padine gorskih strana	485	14.67918	padine gorskih strana	221	36.5894
padine dolinskih strana	1331	40.2845	padine dolinskih strana	157	25.99338
zaravni i ravice	281	8.504843	zaravni i ravice	6	0.993377
široke doline, niži pristranci	153	4.630751			
izvorišta, prikupišta oborine	69	2.088378	izvorišta, prikupišta oborine	44	7.284768
uske doline, V profil	353	10.68402	uske doline, V profil	50	8.278146
duboko usječene doline, kanj	186	5.62954	duboko usječene doline, kanjor	2	0.331126




Sl. 6.1.39 Speleološki objekti i gustoća speleoloških objekata na prostoru GH

6.1.9. Proluvijalne plavine

Na prostoru GH evidentirano je 378 proluvijalnih plavina. Ističu se četiri jezgre velike gustoće ($0,067-0,109$ plavina/km²) (Sl. 6.1.40, Sl. 6.1.41). Najveći areal klase najveće gustoće nalazi se na prostoru Pokupskog pobrđa, a proluvijalne plavine su smještene su u dolinskim proširenjima duž korita rijeke Dobre, u dolinskim proširenjima duž pritoka rijeke Kupe, te u dolini rijeke Lepenice kod Fužina. U ovom arealu plavine su manjih dimenzija obzirom da zbog smještaja u dolinama tekućica, nemaju prostora za neometanu sedimentaciju, a vodotoci odnose sediment koji erodiraju. Druga jezgra klase najveće gustoće nalazi se na prostoru Ogulinsko-Plašćanske zavale, gdje su proluvijalne plavine smještene duž zapadnog ruba Plaškog polja te duž fluviokrškog ruba sa istočne strane akumulacijskog jezera Sabljaci. Treća jezgra nalazi se na kontaktu Male Kapele te Ličke zavale, a proluvijalne plavine smještene su na sjevernom rubu Koreničkog polja te na sjevernom i istočnom rubu Krbavskog polja i polja Krbavica. Obzirom na velik zaravnjen prostor, ovdje se plavine ističu po većoj površini. Četvrta jezgra najveće gustoće nalazi se u prostoru Mazinskog pobrđa, prostora koji razdvaja Gračačko polje o Lapačkog polja te nešto južniji prostor drenažnih bazena pritoka rijeke Une u gornjem toku (Dabašnica, Sredica). Plavine su ovdje smještene na sjevernom rubu Lapačkog polja na kontaktu s dolinskim stranama Ličke Plješivice, zatim na prostoru Mazina gdje plavine zapunjavaju dno krške depresije, te u Brezovcu Dobroselskom gdje također proluvijalne plavine prekrivaju dno krške depresije. Nešto južnije u Srbskom klancu gdje pritoke Une izlaze iz svog gorskog okvira smještene su plavine u nizovima. Primjetno je kako su proluvijalne plavine prisutne južnom i zapadnom dijelu GH zastupljene samo sporadično. Krbavsko, Lapačko i Gračačko polje ističu se po broju proluvijalnih lepeza. U rubovima Krbavskog polja nalazi se 20 proluvijalnih plavina, Lapačkog polja 13, a Gračačkog 11 proluvijalnih plavina.



Sl. 6.1.40 Udjeli klasa gustoće proluvijalnih plavina na prostoru GH




Sl. 6.1.41 Proluvijalne plavine i gustoća proluvijalnih plavina na prostoru GH

6.1.10. Hidrološka obilježja


Unatoč činjenici da je prostor GH prostor s najviše padalina u cijeloj Hrvatskoj, prostorni raspored i pojavnost hidroloških obilježja nije determiniran samo količinom padalina. Obzirom da na prostoru GH prevladavaju karbonati te da su orografske cjeline strukturno determinirane, upravo o tim obilježjima ovisi i pojava vode i s njom povezanih geomorfoloških osobitosti.

Površinski vodotoci, oni povremeni i stalni javljaju se u dnima krških polja te u drenažnim bazenima većih tekućica, ali i drenažnim bazenima krških polja te pojedinih jaruga. Drenažni bazeni nalaze se na 18,4% prostora GH, a polja u kršu nalaze se na 12,2% površine. Na prostoru GH evidentirano je 173 drenažna bazena (Sl. 6.1.42). Prema popisu tekućica duljih od 40 km na prostoru RH (Čanjevac i dr., 2022) na prostoru GH nalazi se njih 10 (Kupa, Una, Korana, Cetina, Dobra, Krka-Krčić, Zrmanja, Lika, Čikola, Butižnica). Od navedenih, samo rijeka Lika i Butižnica cijelim svojim tokom od izvora do ponora/ušća teku prostorom GH. Izvorišni dijelovi i topografski drenažni bazeni gornjih tokova navedenih tekućica nalaze se na prostoru GH.



Sl. 6.1.42 Hidrološka obilježja prostora GH


Gustoća drenažne mreže najveća je na prostoru drenažnih bazena Kupe, a spada u klasu gustoće 2,9-5,3 km/km² (Sl. 6.1.43). Ova klasa gustoće drenažne mreže javlja se samo u područjima topografskih drenažnih bazena, dok se nasuprot tome klasa najmanje gustoće drenažne mreže (0-0,4 km/ km²) javlja u dnima krških polja te na područjima bez površinskih vodotoka. Jezgre veće gustoće vodotoka (1,8-2,9 km/ km²) javljaju se i u topografskim drenažnim bazenima na rubovima velikih polja u kršu (Ličko polje, Lapačko polje, Kravsko polje, Gračačko polje), te kao iznimka u ovoj klasi se nalazi i topografski drenažni bazen Plitvičkih jezera, koji čini gornji tok rijeke Korane.



Sl. 6.1.43 Gustoća drenažne mreže na prostoru GH


Klasa gustoće drenažne mreže 0,4-1,014 km/ km²) veže se uz površinom manje topografske drenažne bazene manjih polja u kršu, veće jaruge ili sustave jaruga te rubne prostore na kojima se jarugama voda drenira direktno u podnožja (primjerice podnožje Dinare, Kamešnice i Svilaje). Obzirom na hidrogeološka obilježja prostora, jezgre veće gustoće vodotoka ukazuju na slabo vodopropusne hidrogeološke strukture

Na prostoru GH ukupna površina stalnih stajaćih vodenih površina iznosi 0,11% tj. oko 12,5 km². Evidentirano je 118 stajaćica od kojih je 105 prirodnih, a 12 umjetnih jezera. Umjetna jezera zauzimaju 83,52% od ukupne površine stajaćih kopnenih voda na prostoru GH. Prirodne stajaće vode na prostoru GH generalno su malih površina, ali je česta pojava da se više stajaćih vodenih površina nalazi na istom mjestu (Sl. 6.1.44). Iznimka u površini su Plitvička jezera. Unatoč tome što su i Plitvička jezera brojna (16 jezera), ona zapravo čine cjelinu, a odvojena su sedrenim barijerama.




Sl. 6.1.44 Odnos broja poligona površinskih stajaćih voda i njihove površine u m²

U ovom radu, u hidrogeološke pojave spadaju izvori, ponori, protočni speleološki objekti i estavele. Na prostoru GH evidentirano je 2.309 hidrogeoloških pojava. od kojih je 88% u klasi izvora. Sljedeća najzastupljenija klasa je ponor s 10%, protočni speleološki objekti s 0,5% te najmanje zastupljene estavele s 0,1% (Sl. 6.1.45).



Sl. 6.1.45 Broj hidrogeoloških pojava na prostoru GH


Prostorni raspored hidrogeoloških pojava uvjetovan je strukturnim odnosima u prostoru. Izvori i ponori javljaju se duž lineamenata izduženih u dinarskom pravcu. Skupovi hidrogeoloških pojava prostorno su okupljeni, a gustoća pojavnosti hidrogeoloških pojava pokazuje kako se izdvajaju četiri jezgre s najvećom klasom gustoće (0,465-0,858 točaka/km²), a to je na sjeveru izvorišni prostor rijeke Čabranke i Kupe na Pokupskoj gorskoj skupini, zatim predgorski prostor Velike Kapele s nizovima uvala te gorski okvir Ogulinsko-Plaščanske zavele koji čine i topografski drenažni bazen rijeke Dobre. Na ovom prostoru nalazi se površinom najveći areal klase najveće gustoće hidrogeoloških pojava. Druga jezgra najveće gustoće je II prostor gorske skupine Male Kapele u topografskom drenažnom bazenu Plitvičkih jezera i gornjeg toka rijeke Korane. Treća, ujedno površinom najmanje jezgra maksimalne gustoće nalazi se na zapadnom rubu Ličkog polja na kontaktu s padinama južnog dijela Velebita. Dna polja u kršu te dna drugih većih krških depresija su jezgre klase gustoće 0,273-0,464 točaka/km². Ova se klasa proteže duž zvale Ličkog polja i kontakta podnožjem Velebita, zatim se nastavlja prema Gračačkom polju te njegovom kontaktu s II dijelom Ličkog sredogorja te prema II dijelu Ličke Plješivice tj. topografskom drenažnom bazenu rijeke Une. Najmanja površinom takva jezgra javlja se u južnom dijelu GH na masivu Poštaka tj. u topografskom drenažnom bazenu rijeke Krke. Ponori, estavele i protočni speleološki objekti povezani su isključivo uz krški i fluviokrški morfogenetski tip reljefa, dok se izvori nalaze i u fluviodenudacijskom morfogenetskom tipu. To je vidljivo u prostornom rasporedu izvora, te zonama najveće gustoće hidrogeoloških pojava (Sl. 6.1.46) (obzirom da izvori dominiraju udjelom) koje u najvećem arealu maksimalne gustoće koincidiraju s fluviodenudacijskim tipom reljefa.



Sl. 6.1.46 Hidrogeološke pojave (točkasto) i Kernel gustoća hidrogeoloških pojava na prostoru GH

Odnos klasa TPI-a i broja hidrogeoloških pojava prikazan je na slici Sl. 6.1.47. Klasa TPI-a s najbrojnjom populacijom hidrogeoloških pojava su padine dolinskih strana, gdje se nalazi ukupno 792 hidrogeološke pojave, od čega su 742 izvora, 59 ponora i 4 protočna speleološka objekta. Ova klasa TPI sadrži ujedno najbrojniju populaciju izvora jer je u njoj 36.26% svih izvora na prostoru GH. Izvori su podjednako raspoređeni i u klasi usječene doline, kanjoni (347), uske doline, V profil (321), zaravni i ravnice (258) te u klasi široke doline, niži pristranci (242). Ponori su

podjednako brojnošću podjednako raspoređeni u četiri klase TPI-a. Najbrojniji su u klasi zaravni i ravnice (59), zatim u klasi široke doline, niži pristranci (51), jednako su zastupljeni u klasi padine dolinskih strana (46) i duboko usječene doline, kanjoni (46), te u klasi uske doline V profila (40). Dva ponora javljaju se u klasi padine gorskih strana te jedan u klasi vrhovi i izraziti grebeni. Estavele se javljaju u klasi široke doline, niži pristranci (2), uske doline, V profila (1) i duboko usječene doline, kanjoni (1). Klasa TPI-a s najmanjom ukupnom populacijom hidrogeoloških pojava je klasa manji grebeni i kose, uzvisine u dolinama, te klasa izvorišta/prikupišta oborine.



Sl. 6.1.47 Broj hidrogeoloških pojava po pojedinim klasama TPI-a

6.2. Sekundarna struktura krajobraza GH

6.2.1. Površinski pokrov

Rezultati validacije podataka, tj. izračuni matrice konfuzije za klasificirani površinski pokrov na temelju Sentinel-2A snimaka, pokazuju visoku točnost provedene klasifikacije (Tab. 6.2.1). Kappa koeficijent kreće se od 0 do 1, a klasifikacija provedena pomoću Sentinel-2A snimaka iznosi 0,94. Kappa koeficijent svakako nije nepogrešiv pokazatelj točnosti klasifikacije, već pokazatelj slaganja između klasificiranih i referentnih vrijednosti (Foody, 2020). Prema (McHugh, 2012), Kappa koeficijent od 0,94 pripada skupini gotovo savršenog slaganja između klasificiranih i referentnih podataka, gdje je Kappa koeficijent iznad 0,90. Klasifikacija površinskog pokrova je neuravnotežena, tj. postoji više od dvije klase, a same klase nisu ravnomjerno zastupljene. U slučaju Gorske Hrvatske prevladava klasa šuma. Nasuprot tome, klasa vodenih površina, na primjer, ima vrlo nizak prostorni udio, što se odražava i na validaciju podataka. Uz Kappa koeficijent, najčešće se koristi pokazatelj *Accuracy*, što dovodi do lažno visokih performansi u neuravnoteženim klasifikacijama zbog sustavnog predviđanja većinske klase. U izuzetno neuravnoteženim klasifikacijama nijedan pokazatelj točnosti nije u potpunosti vjerodostojan, ali u takvim slučajevima, pokazatelj *Balanced Accuracy*, definirana kao aritmetička sredina druga dva pokazatelja, *Recall* i *Specificity*, pokazala se kao dobar pokazatelj. *Recall* ili osjetljivost odgovara točnim pozitivnim predviđanjima podijeljenim sa svim pozitivnim uzorcima, a *Specificity* odgovara točnim negativnim predviđanjima podijeljenim sa svim negativnim uzorcima (Thölke i dr., 2023). *Balanced Accuracy* za klasifikaciju snimaka Sentinel-2A iznosi 0,91, za CORINE klasifikaciju 0,61, a za NKS klasifikaciju 0,57.

Tab. 6.2.1 Matrica konfuzije za klasifikaciju površinskog pokrova na temelju Sentinel-2A snimaka

Klasa	8	15	20	32	40	50	60	80	Ukupno	Kappa
8 - vodene površine	9	1	0	3	0	0	0	0	13	0
15 - šume	0	2240	1	13	0	8	0	1	2263	0
20 - antropogene površine	0	0	20	0	0	0	0	0	20	0
32 - travnjaci	0	9	1	202	0	11	0	0	223	0
40 – izdanci stijena	0	1	0	2	82	0	0	5	90	0

50 - poljoprivredne površine	0	2	1	9	0	279	0	1	292	0
60 – golo tlo	0	1	0	0	0	0	9	0	10	0
80 - oskudna vegetacija	0	0	0	0	1	0	0	97	98	0
Ukupno	9	2254	23	229	83	298	9	104	3009	0
Kappa	0	0	0	0	0	0	0	0	0	0,94373282

Prema matrici konfuzije kreiranoj za CORINE klasifikaciju, Kappa koeficijent za klase površinskog pokrova iznosi 0,75, što znači da pripada skupini umjerenog slaganja klasificiranih i referentnih podataka, u kojima je Kappa koeficijent između 0,60 i 0,79 (McHugh, 2012) (Tab. 6.2.2). *Balanced Accuracy* CORINE klasifikacije iznosi 0,61.

Tab. 6.2.2 Matrica konfuzije za CORINE klasifikaciju

Klasa	8	15	20	32	40	50	60	80	90	100	110	Ukupno	Kappa
8 - vodene površine	8	0	0	1	0	0	1	0	0	0	0	10	0
15 - šume	0	687	1	17	2	6	1	3	0	0	0	717	0
20 - antropogene površine	0	2	6	2	0	0	0	0	0	0	0	10	0
32 - travnjaci	0	16	0	109	0	6	0	10	0	0	0	141	0
40 - izdanci stijena	0	0	0	0	10	0	0	0	0	0	0	10	0
50 - poljoprivredne površine	0	11	1	11	0	77	1	0	0	0	0	101	0
60 - golo tlo	0	0	0	0	0	0	0	0	0	0	0	0	0
80 - oskudna vegetacija	0	1	0	2	2	0	0	7	0	0	0	12	0
90 - močvare	0	5	0	2	3	0	0	0	0	0	0	10	0

100 - opožarene površine	0	3	0	1	0	1	0	0	0	5	0	10	0
110 - šikare	0	3	0	1	1	0	0	3	0	0	2	10	0
Ukupno	8	731	8	146	18	90	3	23	0	5	2	1034	0
Kappa	0	0	0	0	0	0	0	0	0	0	0	0	0,752884875

Prema matrici konfuzije kreiranoj za NKS, Kappa koeficijent za klase površinskog pokrova iznosi 0,68, što znači da pripada skupini umjerenog slaganja klasificiranih i referentnih podataka, gdje je Kappa koeficijent između 0,60 i 0,79 (McHugh, 2012) (Tab. 6.2.3). *Balanced Accuracy* za NKS klasifikaciju iznosi 0,57.

Tab. 6.2.3 Matrica konfuzije za NKS klasifikaciju

Klasa	8	15	20	32	40	50	60	80	90	100	110	Ukupno	Kappa
8 - vodene površine	0	0	0	0	0	0	0	0	0	0	0	0	0
15 - šume	0	644	3	18	17	0	6	0	0	0	0	688	0
20 - antropogene površine	0	2	5	0	0	3	0	0	0	0	0	10	0
32 - travnjaci	0	28	1	159	2	27	0	12	0	0	0	229	0
40 - izdanci stijena	0	2	0	0	14	0	0	0	0	0	0	16	0
50 - poljoprivredne površine	0	6	1	0	0	34	0	0	0	0	0	41	0
60 - golo tlo	0	0	0	0	0	0	0	0	0	0	0	0	0
80 - oskudna vegetacija	0	4	1	1	3	0	0	1	0	0	0	10	0
90 - močvare	0	2	0	0	0	0	0	0	8	0	0	10	0
100 - opožarene površine	1	13	0	5	0	1	0	0	0	0	0	20	0


110 - šikare	0	5	0	0	0	0	0	0	0	0	4	9	0
Ukupno	1	706	11	183	36	65	6	13	8	0	5	1034	0
Kappa	0	0	0	0	0	0	0	0	0	0	0	0	0,682830931

Vrijednosti Kapa koeficijenta i *Balanced Accuracy* za sva tri skupa podataka pokazuju bolje performanse klasifikacije Sentinel-2A u usporedbi s CORINE i NKS. I CORINE i NKS stvoreni su na temelju klasifikacije Landsat snimaka (Antonić i dr., 2005; Heymann i dr., 1994). Rezultati ukupne procjene točnosti u skladu su s postojećim studijama u kojima Sentinel ima veću točnost u usporedbi s Landsatom, uglavnom zbog bolje prostorne rezolucije podataka (Marangoz i dr., 2017; Topaloğlu i dr., 2016).

Kao rezultat iterativnog procesa nadzirane klasifikacije korištenjem metode *Minimum Distance to Mean* u kombinaciji s vizualnom interpretacijom referentne podloge i ručnom vektorizacijom, izdvojeno je 8 klasa površinskog pokrova u Gorskoj Hrvatskoj (Tab. 6.2.4, Sl. 6.2.1). U vizualnoj interpretaciji koja se odnosi na referentnu podlogu tijekom klasifikacije Sentinel-2A snimaka, metoda *Minimum Distance to Mean* pokazala je najprihvatljivije rezultate (Almeida i dr., 2016; El-Kawy i dr., 2011). Neke studije su pokazale da vizualna interpretacija može eliminirati pogrešnu klasifikaciju jer interpretator može prepoznati tekture, uzorke i objekte, ali interpretator mora dobro poznavati prostor. Negativan učinak vizualne interpretacije je da je radno intenzivna i posljedično skupa te može dovesti do heterogenih rezultata ovisno o znanju različitih stručnjaka (Varga i dr., 2021).

Tab. 6.2.4 Klase površinskog pokrova na temelju klasifikacije Sentinel-2A snimaka

Numerička oznaka klase	Naziv klase
8	vodene površine
15	šume
20	antropogene površine
32	travnjaci
40	izdanci stijena
50	poljoprivredne površine
60	golo tlo
80	oskudna vegetacija



Sl. 6.2.1 Površinski pokrov GH: A- Sentinel-2A klasifikacija, B- CORINE klasifikacija, C- NKS klasifikacija

U CORINE klasifikaciji razlikuje se 9 klasa površinskog pokrova (Tab. 6.2.5), a u NKS klasifikaciji 10 klasa (Tab. 6.2.6). Izvorne klase CORINE i NKS u ovom su radu prilagođene nomenklaturi klasifikacije površinskog pokrova Sentinel-2A klasifikacije kako bi se olakšala usporedba kvalitete podataka te njihova interpretacija i primjena. U CORINE klasifikaciji, uz površinski pokrov prikazuju se i klase načina korištenja zemljišta. Društveno-ekonomske aktivnosti određuju vrstu korištenja zemljišta na određenoj klasi površinskog pokrova, a podaci se dobivaju katastarskim uvidima, anketama i terenskim radom (Nedd i dr., 2021; US EPA, 2017; Winkler i dr., 2021). U ovome radu, način korištenja zemljišta nije integriran u kartu površinskog pokrova.

Tab. 6.2.5 Klase površinskog pokrova prema CORINE klasifikaciji

Numerička oznaka klase	Naziv klase	Originalna CORINE klasa
20	antropogene površine	nepovezana gradska područja, cestovna i željeznička mreža i pripadajuće zemljište, industrijske ili komercijalne jedinice, mjesta eksploatacije mineralnih sirovina, odlagališta otpada, sportsko rekreacijske površine, zračne luke
40	izdanci stijena	ogoljene stijene
90	močvare	močvare i vrištine
110	opožarene površine	opožarena područja
80	oskudna vegetacija	područja s oskudnom vegetacijom
50	poljoprivredne površine	ne navodnjavano obradivo zemljište, kompleks kultiviranih parcela, pretežno poljodjelska zemljišta s većim područjima prirodne vegetacije
32	travnjaci	pašnjaci, prirodni travnjaci
8	vodene površine	vodotoci,
100	šikare	sklerofilna vegetacija

Tab. 6.2.6 Klase površinskog pokrova prema NKS klasifikaciji

Numerička oznaka klase	Naziv klase	Originalna NKS klasa
8	vodene površine	kanali, povremene stajačice, povremeni vodotoci, Sedrotvorne riječne zajednice, stalne stajačice, stalni vodotoci, zakorijenjena vodenjarska vegetacija
15	šume	šume
20	antropogene površine	izgrađena i industrijska staništa
32	travnjaci	brdske livade uspravnog ovsika na karbonatnoj podlozi, bujadnice, gažene površine šumskih puteva, ilirsko-dinarske planinske rudine uskolisne šašike, ilirsko-submediteranske livade rječnih dolina, intenzivne košanice i pašnjaci,

		istočnojadranski kamenjarski pašnjaci epimediterranske zone, istočnojadranski kamenjarski pašnjaci submediteranske zone, korovna i ruderalna vegetacija Sredozemlja, livada sitne busike s livadnim procjepkom, livade brdske zečine i rane pahovke, livade gomoljaste končare i rane pahovke, Livade vrkutâ i žučkaste zobike, livade zečjeg trna i rane pahovke, livade-košarice obične beskoljenke i panonskog grašara, ličke vrištine, mezofilne livade košarice Srednje Europe, nitrofilni pašnjaci i livade-košarice nizinskog vegetacijskog pojasa, pretplaninske rudine oštre vlasulje, ruderalne zajednice kontinentalnih krajeva, srednjoeuropske livade obične beskoljenke, srednjoeuropske livade rane pahovke, trajno vlažne livade Srednje Europe, travnjaci trave tvrdače, travnjaci vlasastog zmijka, visoke zeleni s pravom končarom, vrištine vlasaste vlasulje, zajednice higrofilnih zeleni, zajednice nitrofilnih, higrofilnih i skiofilnih staništa
40	izdanci stijena	alpsko-karpatško-balkanske vapnenačke stijene, gorska, pretplaninska i planinska točila, ilirsko-jadranska, primorska točila, tirensko-jadranske vapnenačke stijene
50	poljoprivredne površine	maslinici, mozaici kultiviranih površina, vinogradi, voćnjaci, zapuštene poljoprivredne površine
80	oskudna vegetacija	neobrasle i slabo obrasle obale tekućica, neobrasle i slabo obrasle obale stajaćica
90	močvare	batofilni cretovi, trščaci, rogozici, visoki šiljevi i visoki šaševi
100	šikare	mezofilne živice i šikare kontinentalnih, izuzetno primorskih krajeva, pretplaninska klekovina, pretplaninske šikare, mediteranske listopadne šikare, šikare stranog grmlja, vrbici i šikare, vrbici šljunkovitih i pjeskovitih riječnih sprudova, vrbici pepeljaste i uškaste vrbe
110	opožarene površine	požarišta

Klasa golog tla ne pojavljuje se u CORINE klasifikaciji, dok su dvije klase pokrova zemljišta koje nisu klasificirane pomoću Sentinel-2A snimaka izdvojene, i to močvare i opožarena područja. Što se tiče samog cilja ovog rada, kvantifikacije površinskog pokrova radi praćenja stanja pomoću kvantitativnih pokazatelja, a kasnije i prepoznavanja odnosa s drugim komponentama krajobrazu, niska prostorna rezolucija i visoka tematska rezolucija CORINE klasifikacije predstavljaju problem. Veličina minimalne kartirane jedinice u CORINE klasifikaciji je 25 ha ili 250.000 m² za pojave koje zauzimaju određenu površinu, a minimalna širina linearnih pojava je 100 m (<https://land.copernicus.eu/>). Prilikom kartiranja površinskog pokrova pomoću Sentinel-2A snimaka, minimalna veličina kartirane jedinice određena je najboljom prostornom rezolucijom Sentinel-2A snimaka, 10 x 10 m, tj. 100 m² ili 0,01 ha. Visoka tematska rezolucija temeljena na podacima niske prostorne rezolucije kao primarnom izvoru za NKS klasifikaciju dovodi do visokog udjela pogrešno klasificiranih točaka u nekim klasama. U močvarama je 22%, u opožarenim područjima 100%, a u klasi šikara 55,5%

kontrolnih točaka bilo je pogrešno klasificirano. Prostorna i tematska rezolucija podataka o površinskom pokrovu ovisi o svrsi za koju se podaci analiziraju i načinu na koji su podaci prikupljeni. Prilikom analize povezanosti krajobraznih dijelova reprezentativnih za metriku krajobraza, tematska rezolucija ima manji utjecaj na konačne rezultate od prostornog rasporeda analiziranih uzoraka (Pelorosso i dr., 2021).

Postoje značajne razlike u udjelu određenih klasa između tri promatrane klasifikacije. Razlika je najočitija u udjelima klasa izdanaka stijena, oskudne vegetacije, travnjaka i poljoprivrednih površina. U klasifikaciji Sentinel-2A, izdanci stijena zauzimaju 3,052%, u CORINE 0,003%, a u NKS 1,596% površine GH. Iz gore navedene procjene točnosti podataka pojedinih klasa može se zaključiti da je udio klase izdanaka stijena iz klasifikacije Sentinel-2A najpouzdaniji podatak. Takve razlike u udjelima određenih klasa mogu se vidjeti i u prostornoj rasprostranjenosti, što se može vidjeti na Sl. 6.2.1. U najjužnijem dijelu GH, na planinskom lancu Velebit, prema klasifikaciji Sentinel-2A, nalazi se najveća koncentracija područja klasificiranih kao izdanci stijena. Istovremeno, u CORINE klasifikaciji gotovo da nema izdanaka stijena. U NKS klasifikaciji, rasprostranjenost stijenskih izdanaka slična je Sentinel-2A klasifikaciji. Zbog najvećeg udjela travnjaka u NKS klasifikaciji, prostorna rasprostranjenost značajno se razlikuje od ostale dvije. U sve tri klasifikacije, klasa travnjaka općenito se nalazi oko najviših planinskih vrhova i visokih grebena, ali i u krškim poljima u kontaktu s poljoprivrednim površinama. U NKS klasifikaciji, 11,7% kontrolnih točaka u klasi travnjaka pogrešno je klasificirano kao klasa poljoprivrednih površina. To se odražava na prostornoj rasprostranjenosti u krškim poljima diljem Gorske Hrvatske. Ponovno, prema procjeni točnosti podataka, klasifikacija Sentinel-2A može se smatrati najpouzdanijom od tri ispitane klasifikacije.

Prostorna distribucija klasa površinskog pokrova je vrlo neujednačena. Prostorom dominira klasa šuma, koja zauzima 75% prostora GH (Sl. 6.2.1 (A)). Ističe se južni dio prostora GH (južno od masiva Poštaka) gdje šume gotovo da i nema. Obzirom da šuma zauzima većinu prostora, tako zastupljenost ove klase po morfometrijskim pokazateljima odraz opisanih morfometrijskih odnosa. Hipsometrijski razred od 600-800 m n.v., klasa nagiba 12-32°, klasa vertikalne raščlanjenosti reljefa 100-300 m/km², te klasa TPI-a padine dolinskih strana.

Druga najzastupljenija klasa su poljoprivredne površine (9,7%) koje se hipsometrijski većinski nalaze između 400-800 m n.v, te na padinama nagiba 0-2°, u klasi vertikalne raščlanjenosti reljefa 30-300 m/km² i u klasi TPI-a zaravni i ravnice. Poljoprivredne površine smještene su isključivo u krškim depresijama (svih veličina) te u ostalim hipsometrijski nižim te morfološki

zaravnjenim prostorima. Treća najzastupljenija klasa su travnjaci (7,5%), koji se u velikim površinama javljaju u krškim depresijama te na gorskim stranama i grebenima planinskih lanaca i masiva. Posebice se tu ističe Velebit (s naglaskom na J i JI dio) te Obruč i zapadni obronci Velike Kapele. Klasa oskudne vegetacije javlja se na 3,2% površine GH, a rasprostranjena je isključivo na primorski orijentiranim stranama naj zapadnijih obronaka Velike Kapele i Velebita. Najveća gustoća ove klase je u južnom djelu GH na padinama Dinare, Svilaje, Kamešnice. Travnjaci su najzastupljeniji na nadmorskim visinama između 400-1000 m n.v., njih 78,9%. Naj zastupljenija klasa nagiba na kojima se nalaze travnjaci je 12-32°, dok u višim klasama naglo opada zastupljenost travnjaka. U klasi vertikalne raščlanjenosti 100-300 m/km² nalazi se 55,8 površina travnjaka GH, dok su najmanje zastupljeni u klasi 0-5 m/km². Na prostoru GH većinski su generalno južnih orijentacija, 50% ukupne površine travnjaka nalazi se na padinama orijentacije JI-JZ, dok su na JZ najzastupljeniji (21,2%). Od TPI klasa, travnjaci su najzastupljeniji u klasama široke doline i niži pristranci, zaravni i ravnice te padine dolinskih strana.

Klasa oskudne vegetacije pokriva 3,2% ukupne površine GH. Na nadmorskim visinama od 400-800 m nalazi se 64,9% svih površina oskudne vegetacije, dok se u najnižoj klasi 24-200 m n.v. uopće ne javlja ova klasa površinskog pokrova. Najčešće se rasprostire na padinama nagiba 12-32°, te u klasi vertikalne raščlanjenosti reljefa 100-300 m/km², a uopće se ne javlja u klasi 0-5 m/km². Kao i kod travnjaka, najveća površina oskudnih travnjaka nalazi se na padinama generalno južne orijentacije, tj. 74,9% površine oskudne vegetacije je na padinama JI-J-JZ-Z orijentacije, dok je JZ orijentacija najzastupljenija (31,5%). Oskudna vegetacija najčešće se javlja na padinama dolinskih strana (37,07%) te u širokim dolinama i na nižim pristrancima (23,2%). Prostorno, klasa oskudne vegetacije javlja se isključivo na zapadnom rubu te na samom jugu GH (zapadne padine Velike Kapele, Senjsko bilo, Velebit, Dinara, Svilaja, Dinara i Kamešnica).

Klasa izdanci stijena javlja se na 2,9% površine GH. Promatrajući hipsometrijski kontekst, izdanci stijena površinom su najzastupljeniji u klasi 100-1.200 m n.v. (27,14% površine klase). Generalno se ova klasa površinskog pokrova veže uz hipsometrijski viši prostor, dok se u klasama nižim od 400 m n.v. vrlo rijetko javlja, a u klasi 24-200 m n.v. nema evidentiranih izdanaka stijena. Izdanci stijena najčešće su na angibima 12-32° (57,1%). U klasi vertikalne raščlanjenosti reljefa 100-300 m/km² nalazi se 65,3% izdanaka stijena, dok u klasi 0-5 m/km² nisu evidentirani. Najzastupljenija orijentacija padina na kojima se nalaze izdanci stijena je JZ (27,3%) i J (21,7%). Najčešće se nalaze na padinama dolinskih strana (31%), te na vrhovima i

izrazitim grebenima (17,6%). Ova klasa dominira u južnom dijelu prostora GH (Svilaja, Dinara i Kamešnica), te kao i klasa oskudne vegetacije, javlja se poglavito uz zapadni rub prostora GH.

Antropogene površine čine 0,6% prostora GH. Antropogene površine okupljene su u hipsometrijski nižim klasama, a najveći postotak ove klase nalazi se između 400-600 m n.v. (43,1%). Antropogene površine najčešće su smještene na najmanjim nagibima. U klasi 0-2° smješteno je 28,9% antropogenih površina, a podjednako (26,9%) nalazi se u klasi nagiba 2-5° te u klasi nagiba 5-12° (25,6%). U klasama većih nagiba, naglo opada postotak antropogenih površina. Distribucija antropogenih površina po klasama vertikalne raščlanjenosti je u skladu sa samom distribucijom površina klase ovog pokazatelja, te je najveći postotak antropogenih površina u klasi 100-300 m/km². Distribucija antropogenih površina po klasama orijentacije padina je ujednačena, s maksimumom u padinama JZ orijentacije (17,6%). U klasama TPI-a izražen maksimum antropogenih površina je u klasi zaravni i ravnice (48,3%). Značajne površine ove klase nalaze na padinama dolinskih strana (27,5%).

Klasa golog tla nalazi se na 0,25% površine GH. Ova klasa najučestalija je u klasi nadmorskih visina 600-800 (38,1%), a nije evidentirana u naj nižoj klasi (24-200 m n.v.). Najčešće se javlja u klasi nagiba 12-32° (51,7%). U klasi vertikalne raščlanjenosti 0-5 m/km² nema evidentiranog golog tla, a maksimum u vertikalnoj raščlanjenosti je u klasi 100-300 m/km². Golo tlo najčešće se nalazi na padinama JZ orijentacije (27,3%), zatim na padinama J orijentacije (23%). U klasama TPI-a najčešće se javlja na padinama dolinskih strana (38%). Prostorno, naj značajnije površine golog tla nalaze se u južnom dijelu GH na gorskom hrptu Kozjaka kod Svilaje. Masivi i hrptovi Poštaka, Koma i Tremzine također imaju značajnije površine golog tla.

Najmanje zastupljena klasa površinskog pokrova, vodene površine, javlja se na 0,14% prostora GH. Vodene površine odnose se na umjetna jezera, prirodna jezera te šire dionice velikih vodotoka. Mali postotak vodenih površina u skladu je s generalno krškim i fluviokrškim morfogenetskim tipom reljefa koji prevladava na prostoru GH. Vodene površine koncentrirane su u hipsometrijskoj klasi 400-600 m n.v. (62,2%), te nisu prisutne iznad 1.000 m n.v. Najčešće su na padinama nagiba 0-2° što je potpuno očekivano, obzirom da se vodene površine te veliki vodeni tokovi zadržavaju i formiraju na zaravnjenim prostorima. Najčešće su smješteni na prostoru vertikalne raščlanjenosti 100-300 m/km² (44,7%), što je odraz generalnih morfometrijskih odnosa na prostoru GH. U klasi 0-5 m/km² nema evidentiranih vodenih površina. Vodene površine najčešće su prisutne na padinama JI-J-JZ-Z, a maksimum je u Z orijentaciji (18,3%). Od klasa TPI-a, najveći postotak vodenih površina nalazi se na zaravnima

i ravninama (41,7%), te u širokim dolinama i na nižim pristrancima (23,2%). Značajan je postotak u klasi uskih dolina V profila (15,4%), što ukazuje na povremene vodotoke u jarugama i potočnim dolinama gornjih tokova pritoka većih vodotoka i na linearnu eroziju koja oblikuje ovu klasu TPI-a. Distribucija površina pojedinih klasa površinskog pokrova po morfometrijskim pokazateljima prikazana je u Tab. 6.2.7.

Tab. 6.2.7 Klase površinskog pokrova s prikazanim udjelima u klasama morfometrijskih pokazatelja

Antropogene površine														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	15.814,42	0,02	0-2	20.184.467,49	28,97	0-5	22.027,15	0,03	Zaravnjeno	8.159,50	0,01	duboko usječne doline, kanjoni	3.033.778,70	4,34801
200-400	7.777.895,82	11,15	2-5	18.791.059,21	26,97	5-30	10.312.937,34	14,78	S	6.549.955,90	9,40	uske doline, V profil	3.489.598,09	5,00129
400-600	30.087.194,48	43,12	5-12	17.836.988,16	25,60	30-100	24.440.392,21	35,03	SI	8.205.882,85	11,78	izvorišta	10.876,10	0,01559
600-800	24.185.810,79	34,66	12-32	11.986.266,67	17,20	100-300	33.019.148,22	47,33	I	8.439.686,94	12,11	Široke doline, niži pristranci	7.848.395,06	11,2483
800-1000	6.451.131,92	9,25	32-55	872.708,57	1,25	300-800	1.972.265,50	2,83	Jl	8.435.783,28	12,11	zaravni i ravnice	33.753.324,38	48,3752
1000-1200	906.427,17	1,30	55-90	13.230,23	0,02	800-939	0,00	0,00	J	10.288.752,55	14,76	padine dolinskih strana	19.211.508,88	27,5339
1200-1400	322.927,81	0,46							JZ	11.960.495,80	17,16	padine gorskih strana	684.680,55	0,98128
1400-1831	25.432,46	0,04							Z	9.345.015,08	13,41	manji grebeni i kose, uzvisine u dolinama	44.224,50	0,06338
									SZ	6.450.100,60	9,26	tjemena uzvisine	925.378,66	1,32625
												vrhovi i izraziti grebeni, uzvisine u ravnicama	772.192,91	1,10671
Golo tlo														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	0	0	0-2	1.017.458,82	3,68623137	0-5	0	0	Zaravnjeno	30.430,87	0,110255	duboko usječne doline, kanjoni	1.127.153,80	4,06675
200-400	206.057,29	0,743486612	2-5	2.903.957,77	10,5209765	5-30	330.357,92	1,19257972	S	1.137.267,72	4,120456	uske doline, V profil	1.071.627,31	3,86642
400-600	4.985.522,74	17,98853771	5-12	8.549.322,30	30,9740105	30-100	2.932.298,13	10,5854863	SI	1.860.747,72	6,741711	izvorišta	110.333,50	0,39808
600-800	10.586.225,61	38,1967405	12-32	14.274.427,26	51,7159425	100-300	17.984.738,94	64,9242332	I	2.351.872,18	8,521113	Široke doline, niži pristranci	2.900.248,42	10,4641
800-1000	8.129.222,96	29,33149465	32-55	803.078,66	2,90953668	300-800	6.453.723,74	23,2977007	Jl	3.264.526,02	11,82777	zaravni i ravnice	2.920.763,73	10,5381
1000-1200	3.528.372,63	12,73091456	55-90	53.354,58	0,19330249	800-939	0,00	0	J	6.372.683,28	23,08899	padine dolinskih strana	10.543.722,89	38,0416
1200-1400	221.688,45	0,799886232							JZ	7.539.417,32	27,31621	padine gorskih strana	3.679.249,81	13,2747
1400-1831	57.907,64	0,208939736							Z	3.230.718,64	11,70528	manji grebeni i kose, uzvisine u dolinama	17.095,32	0,06168
									SZ	1.812.863,61	6,568221	tjemena uzvisine	1.685.706,11	6,082
												vrhovi i izraziti grebeni, uzvisine u ravnicama	3.660.398,61	13,2067
Izdanci stijena														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	0	0	0-2	3.510.065,31	1,10238502	0-5	0	0	Zaravnjeno	53.044,52	0,01666	duboko usječne doline, kanjoni	18.431.982,00	5,77066
200-400	58.110,43	0,018193491	2-5	15.192.445,35	4,77139959	5-30	351.196,84	0,10997762	S	17.294.351,48	5,431603	uske doline, V profil	12.845.504,81	4,02166
400-600	21.434.598,63	6,710846063	5-12	73.202.918,84	22,9903988	30-100	9.430.061,07	2,95303235	SI	23.532.559,79	7,390825	izvorišta	2.207.928,17	0,69126
600-800	47.473.955,44	14,86337171	12-32	182.031.818,06	57,1696342	100-300	208.551.077,33	65,3079628	I	27.500.924,78	8,637162	Široke doline, niži pristranci	26.504.486,03	8,29799
800-1000	70.206.647,69	21,9806311	32-55	42.668.216,83	13,4005493	300-800	100.711.792,53	31,537991	Jl	35.429.738,83	11,12735	zaravni i ravnice	14.578.395,19	4,56419
1000-1200	86.714.636,30	27,14903067	55-90	1.801.012,52	0,56563313	800-939	290.710,19	0,09103617	J	69.203.705,00	21,73467	padine dolinskih strana	99.165.304,34	31,0466
1200-1400	51.423.729,74	16,09998583							JZ	87.087.676,47	27,35146	padine gorskih strana	53.180.591,96	16,6497
1400-1831	42.090.650,87	13,17794112							Z	40.937.466,01	12,85715	manji grebeni i kose, uzvisine u dolinama	4.992.574,91	1,56307
									SZ	17.362.871,15	5,453123	tjemena uzvisine, , uzvisine u ravnicama	31.127.787,52	9,74545
												vrhovi i izraziti grebeni	56.373.816,73	17,6494

Antropogene površine														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	15.814,42	0,02	0-2	20.184.467,49	28,97	0-5	22.027,15	0,03	Zaravnjeno	8.159,50	0,01	duboko usječne doline, kanjoni	3.033.778,70	4,34801
200-400	7.777.895,82	11,15	2-5	18.791.059,21	26,97	5-30	10.312.937,34	14,78	S	6.549.955,90	9,40	uske doline, V profil	3.489.598,09	5,00129
400-600	30.087.194,48	43,12	5-12	17.836.988,16	25,60	30-100	24.440.392,21	35,03	SI	8.205.882,85	11,78	izvorišta	10.876,10	0,01559
600-800	24.185.810,79	34,66	12-32	11.986.266,67	17,20	100-300	33.019.148,22	47,33	I	8.439.686,94	12,11	Široke doline, niži pristranci	7.848.395,06	11,2483
800-1000	6.451.131,92	9,25	32-55	872.708,57	1,25	300-800	1.972.265,50	2,83	JI	8.435.783,28	12,11	zaravni i ravnice	33.753.324,38	48,3752
1000-1200	906.427,17	1,30	55-90	13.230,23	0,02	800-939	0,00	0,00	J	10.288.752,55	14,76	padine dolinskih strana	19.211.508,88	27,5339
1200-1400	322.927,81	0,46							JZ	11.960.495,80	17,16	padine gorskih strana	684.680,55	0,98128
1400-1831	25.432,46	0,04							Z	9.345.015,08	13,41	manji grebeni i kose, uzvisine u dolinama	44.224,50	0,06338
									SZ	6.450.100,60	9,26	tjemena uzvisine	925.378,66	1,32625
												vrhovi i izraziti grebeni, uzvisine u ravnicama	772.192,91	1,10671
Golo tlo														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	0	0	0-2	1.017.458,82	3,68623137	0-5	0	0	Zaravnjeno	30.430,87	0,110255	duboko usječne doline, kanjoni	1.127.153,80	4,06675
200-400	206.057,29	0,743486612	2-5	2.903.957,77	10,5209765	5-30	330.357,92	1,19257972	S	1.137.267,72	4,120456	uske doline, V profil	1.071.627,31	3,86642
400-600	4.985.522,74	17,98853771	5-12	8.549.322,30	30,9740105	30-100	2.932.298,13	10,5854863	SI	1.860.747,72	6,741711	izvorišta	110.333,50	0,39808
600-800	10.586.225,61	38,1967405	12-32	14.274.427,26	51,7159425	100-300	17.984.738,94	64,9242332	I	2.351.872,18	8,521113	Široke doline, niži pristranci	2.900.248,42	10,4641
800-1000	8.129.222,96	29,33149465	32-55	803.078,66	2,90953668	300-800	6.453.723,74	23,2977007	JI	3.264.526,02	11,82777	zaravni i ravnice	2.920.763,73	10,5381
1000-1200	3.528.372,63	12,73091456	55-90	53.354,58	0,19330249	800-939	0,00	0	J	6.372.683,28	23,08899	padine dolinskih strana	10.543.722,89	38,0416
1200-1400	221.688,45	0,799886232							JZ	7.539.417,32	27,31621	padine gorskih strana	3.679.249,81	13,2747
1400-1831	57.907,64	0,208939736							Z	3.230.718,64	11,70528	manji grebeni i kose, uzvisine u dolinama	17.095,32	0,06168
									SZ	1.812.863,61	6,568221	tjemena uzvisine	1.685.706,11	6,082
												vrhovi i izraziti grebeni, uzvisine u ravnicama	3.660.398,61	13,2067
Izdanci stijena														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	0	0	0-2	3.510.065,31	1,10238502	0-5	0	0	Zaravnjeno	53.044,52	0,01666	duboko usječne doline, kanjoni	18.431.982,00	5,77066
200-400	58.110,43	0,018193491	2-5	15.192.445,35	4,77139959	5-30	351.196,84	0,10997762	S	17.294.351,48	5,431603	uske doline, V profil	12.845.504,81	4,02166
400-600	21.434.598,63	6,710846063	5-12	73.202.918,84	22,9903988	30-100	9.430.061,07	2,95303235	SI	23.532.559,79	7,390825	izvorišta	2.207.928,17	0,69126
600-800	47.473.955,44	14,86337171	12-32	182.031.818,06	57,1696342	100-300	208.551.077,33	65,3079628	I	27.500.924,78	8,637162	Široke doline, niži pristranci	26.504.486,03	8,29799
800-1000	70.206.647,69	21,9806311	32-55	42.668.216,83	13,4005493	300-800	100.711.792,53	31,537991	JI	35.429.738,83	11,12735	zaravni i ravnice	14.578.395,19	4,56419
1000-1200	86.714.636,30	27,14903067	55-90	1.801.012,52	0,56563313	800-939	290.710,19	0,09103617	J	69.203.705,00	21,73467	padine dolinskih strana	99.165.304,34	31,0466
1200-1400	51.423.729,74	16,09998583							JZ	87.087.676,47	27,35146	padine gorskih strana	53.180.591,96	16,6497
1400-1831	42.090.650,87	13,17794112							Z	40.937.466,01	12,85715	manji grebeni i kose, uzvisine u dolinama	4.992.574,91	1,56307
									SZ	17.362.871,15	5,453123	tjemena uzvisine, , uzvisine u ravnicama	31.127.787,52	9,74545
												vrhovi i izraziti grebeni	56.373.816,73	17,6494

Travnjaci														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	18.820,03	0,002378742	0-2	143.931,040,50	18,2095766	0-5	64.677,83	0,00817453	Zaravnjeno	265.763,31	0,033623	duboko usječne doline, kanjoni	29.161.675,98	3,68559
200-400	13.236.867,90	1,673062456	2-5	151.193.130,25	19,128347	5-30	87.763.638,92	11,0923033	S	61.115.066,35	7,732072	uske doline, V profil	46.047.047,82	5,81964
400-600	210.595.566,82	26,61804431	5-12	225.372.395,95	28,5132094	30-100	176.988.861,26	22,3693338	SI	71.727.219,90	9,074685	izvorišta	3.145.347,97	0,39752
600-800	248.653.565,68	31,42835212	12-32	256.790.382,91	32,4880868	100-300	441.763.444,38	55,8337619	I	87.757.047,69	11,10273	Široke doline, niži pristranci	76.140.964,67	9,62306
800-1000	165.264.429,78	20,8884545	32-55	12.835.061,83	1,62384042	300-800	84.488.463,66	10,6783593	Jl	97.080.638,78	12,28231	zaravni i ravnice	240.838.882,98	30,4384
1000-1200	94.225.503,12	11,90955088	55-90	291.977,62	0,03693984	800-939	142.949,40	0,01806714	J	135.863.218,58	17,18896	padine dolinskih strana	250.906.384,53	31,7107
1200-1400	39.205.065,72	4,955290334							JZ	167.811.532,71	21,23095	padine gorskih strana	50.334.182,90	6,36147
1400-1831	19.976.138,04	2,52486667							Z	103.818.697,18	13,13479	manji grebeni i kose, uzvisine u dolinama	1.384.858,64	0,17502
									SZ	64.970.800,62	8,219886	tjemena uzvisine	38.350.747,96	4,84695
												vrhovi i izraziti grebeni, uzvisine u ravnicama	54.924.702,85	6,94164
Vodene površine														
Hipsometrija (m n.v.)	Površina (m²)	Udio (%)	Nagibi (°)	Površina (m²)	Udio (%)	Vertikalna rašćlanjenost reljefa (m/km²)	Površina (m²)	Udio (%)	Orijentaci ja padina	Površina (m²)	Udio (%)	TPI	Površina (m²)	Udio (%)
24-200	460.772,59	3,055623431	0-2	10.592.327,96	71,906609	0-5	0	0	Zaravnjeno	996.481,55	6,76439	duboko usječne doline, kanjoni	1.402.781,90	9,20263
200-400	1.973.610,68	13,08804207	2-5	1.017.213,85	6,90541292	5-30	2.830.890,86	18,5786234	S	1.132.888,10	7,690355	uske doline, V profil	2.348.741,54	15,4084
400-600	9.383.219,93	62,22502664	5-12	1.433.312,39	9,73012109	30-100	5.277.537,55	34,635522	SI	1.426.536,58	9,683721	izvorišta	783,99133	0,00514
600-800	3.248.875,29	21,544987	12-32	1.550.547,22	10,5259763	100-300	6.814.614,16	44,7230772	I	1.296.907,09	8,80376	Široke doline, niži pristranci	3.547.814,04	23,2746
800-1000	13.016,75	0,08632086	32-55	136.075,37	0,92375523	300-800	314.312,72	2,0627774	Jl	1.917.421,46	13,01598	zaravni i ravnice	6.360.809,48	41,7286
1000-1200	0,00	0	55-90	1.196,94	0,00812548	800-939	0,00	0	J	1.542.321,11	10,4697	padine dolinskih strana	1.582.345,05	10,3806
1200-1400	0,00	0							JZ	2.324.290,13	15,77792	padine gorskih strana	0,00	0
1400-1831	0,00	0							Z	2.698.460,69	18,31789	manji grebeni i kose, uzvisine u dolinama	0,00	0
									SZ	1.395.978,87	9,476287	tjemena uzvisine	0,00	0
												vrhovi i izraziti grebeni, uzvisine u ravnicama	0,00	0

6.3. Metrika krajobraza površinskog pokrova GH

Važno je naglasiti prostornu rezoluciju podataka korištenih za kartiranje i analizu površinskog pokrova, kada su primarni korišteni podaci proizvod metoda daljinskog istraživanja, budući da su neki elementi površinskog pokrova manji od rezolucije senzora (Garrigues i dr., 2006). Metrike pružaju pokazatelje strukture površinskog pokrova (pokazatelje oblika, heterogenosti, agregacije itd.); stoga se zbog velikog mjerila i niske prostorne rezolucije podataka gubi dokaziva heterogenost promatranih klasa i ukupnog krajobraza (Degen i dr., 2018). Budući da je nakon validacije podataka klasifikacija pokrova zemljišta pomoću snimaka Sentinel-2A pokazala najveću točnost podataka, na rezultate ove klasifikacije primijenjena je metrika krajolika. To je potkrijepljeno prostornom rezolucijom podataka u usporedbi s klasifikacijom CORINE i NKS te time što se metrike klasa temelje uglavnom na metrikama uzoraka.

Metrika uzoraka odnosi se na pojedinačne uzorke i obično se koristi za određivanje najvećih ili najmanjih uzoraka u klasi ili cijelom krajobrazu, ali i kao osnova za izračun metrika klase (Botequilha-Leitão i dr., 2006). U GH evidentirano je 281118 uzoraka na temelju rezultata klasifikacije snimaka Sentinel-2A, od kojih većina pripada klasi oskudne vegetacije (27,7 %) i klasi šuma (21,1 %). Najmanji uzorci povezani su s prostornom rezolucijom klasifikacije, tako da u svakoj klasi najmanji uzorci su veličine 10 x 10 m, dok je najveći uzorak zabilježen u klasi šuma s površinom od 7196,223 km². Na cijelom području istraživanja, jedan uzorak šume pokriva 68,7 % površine GH. Gustoća uzoraka (eng. *patch density* PD) u skladu je s raspodjelom vrijednosti indikatora za broj uzoraka (eng. *patch number* PN).

S druge strane, redundancija u uzorcima je također korisna jer smanjuje rizik od prirodnih katastrofa poput pojave i širenja štetnih organizama, razornih oluja, poplava i požara (Franklin i Forman, 1987; Saunders i dr., 1991). Što se tiče varijabilnosti površine uzoraka, najbolje je promatrati uzorke kroz metriku njima nadređenih klasa. Najveća varijabilnost u veličini uzoraka pronađena je u klasi šuma, izdanaka stijena i oskudne vegetacije.

Budući da je primarna vegetacija Gorske Hrvatske šuma, a geneza travnjaka posljedica je prošlih poljoprivrednih aktivnosti ili intenzivne deforestacije, uglavnom se nalazi u krškim depresijama različitih oblika, ali i u blizini naselja. Manja područja travnjaka u blizini stambenih zgrada povezana su s naseljima, dok su uzorci većih površina povezani s reljefnim oblicima krških depresija. Travnjaci se nalaze i oko najviših planinskih vrhova i visokih grebena.

Metrike na razini klase kvantificiraju karakteristike jedne klase i obično ukazuju na stupanj fragmentacije (Botequilha-Leitão i dr., 2006). Metrika krajobraza na razini klase (pokazatelji ruba i površine) prikazana je u Tab. 6.3.1. Pokazatelji koji opisuju rub i površinu te njihov odnos pomažu u determinaciji kompozicije i konfiguracije pojedinih klasa. Prosječna veličina površine klase (AREA_MN) pokazuje kako šumska klasa sadrži uzorke najveće površinom. Po veličini su potom zastupljene poljoprivredne i vodene površine. Nasuprot tome, klase s uzorcima manjih površina uključuju travnjake, izdanke stijena, oskudnu vegetaciju, golo tlo i antropogena područja. Ponderirana srednja vrijednost po površini (AREA_AM) pokazuje da je šumska klasa dominantna po veličini (656.380,19 ha), dok se ostale klase kreću između 27,5 i 4.612,3 ha. Antropogene površine bilježe najmanje vrijednosti. Klasa šuma u pokazateljima površine bilježi ekstremne vrijednosti. Osim što sadrži najveće uzorke po površini, najvećeg je i raspona površina, ali i koeficijenta varijacije u površini uzorka. U svim ostalim pokazateljima ruba i površine, klasa šuma bilježi ekstremne vrijednosti u odnosu na druge klase.

GYRATE_AM (Polumjer tromosti-ponderirana srednja vrijednost po površini) mjera je povezanosti klase. Klase koje imaju više izdužene uzorke bilježe veću vrijednost polumjera tromosti, a u suprotnom ukazuje na klase kompaktnijih uzoraka. Klasa šuma bilježi najveću vrijednost GYRATE_AM, ali i najveću vrijednost koeficijenta varijacije polumjera tromosti (GYRATE_CV). Klasa poljoprivrednih površina također bilježi veliku vrijednost GYRATE_AM, te proporcionalno velik koeficijent varijacije polumjera tromosti. Gledajući samo srednje vrijednosti, situacija je drugačija. Prema srednjoj vrijednosti polumjera tromosti (GYRATE_MN) najveću vrijednost bilježi klasa vodenih površina, te poljoprivredne površine i klasa travnjaka. Ostale klase bilježe male vrijednosti polumjera tromosti. Klasa antropogenih površina izdvaja se kao druga klasa po najvećim vrijednosti koeficijenta varijacije polumjera tromosti. U skladu s pokazateljima površine, kreću se i vrijednosti pokazatelja ruba. Klasa šuma, obzirom na najveću površinu, bilježi i najveću vrijednost ukupnog ruba (TE), ali i najveću vrijednost gustoće ruba (TD). Klasa travnjaka, oskudne vegetacije i poljoprivredne površine također bilježe velike vrijednosti TE i TD.

Tab. 6.3.1 Metrika krajobraza na razini klasa površinskog pokrova – pokazatelji ruba i površine, MN-srednja vrijednost, AM_vrijednost ponderirana po površini, MD_medijalna vrijednost, RA_raspon vrijednosti, SD_standardna devijacija, CV_koeficijent varijacije

KLASA	CA	PLAND	PN	PD	LPI	TE	ED	LSI	AREA_MN	AREA_AM	AREA_MD
šume	789507.6	75.4012	59551	5.6874	68.7269	61541660	58.7748	175.5701	13.2577	656380.1924	0.03
travnjaci	79027.97	7.5475	35415	3.3823	0.346	27738510	26.4914	247.7797	2.2315	889.6148	0.05
antropogene površine	6903.54	0.6593	32767	3.1294	0.0182	7642020	7.2984	230.2978	0.2107	27.5061	0.03
poljoprivredne površine	101874.97	9.7295	11585	1.1064	1.5254	21548570	20.5798	169.1454	8.7937	4612.3179	0.06
izdanci stijena	31351.84	2.9942	53258	5.0864	0.5076	17604450	16.813	250.6592	0.5887	1637.1699	0.02
vodene površine	1539.22	0.147	421	0.0402	0.0445	421110	0.4022	30.7962	3.6561	230.8277	0.04
golo tlo	2692.9	0.2572	9993	0.9544	0.0666	1871370	1.7872	90.8921	0.2695	210.1481	0.02
oskudna vegetacija	34176.91	3.264	78135	7.4622	0.5149	24314910	23.2217	331.914	0.4374	1234.0136	0.02
KLASA	AREA_RA	AREA_SD	AREA_CV	GYRATE_MN	GYRATE_AM	GYRATE_MD	GYRATE_RA	GYRATE_SD	GYRATE_CV		
šume	719622.3	2949.8978	22250.4972	17.9704	43703.4425	7.0711	47654.5232	203.2679	1131.1279		
travnjaci	3623.01	44.4992	1994.1546	29.7362	1332.325	10.2757	4079.1048	80.8176	271.7816		
antropogene površine	190.85	2.3981	1138.222	16.606	696.4312	6.6667	9294.4694	76.6338	461.4827		
poljoprivredne površine	15971.86	201.2014	2288.0183	44.0205	3472.7644	10.6982	10478.4375	175.8843	399.551		
izdanci stijena	5314.6	31.039	5272.6591	13.8786	1576.5991	6.449	3848.4969	41.2614	297.3019		
vodene površine	465.48	28.8195	788.2567	64.0019	1419.5684	9.4281	2876.3619	208.7723	326.197		
golo tlo	697.39	7.5205	2790.7562	11.7534	624.0349	5	1732.7913	28.0279	238.4661		
oskudna vegetacija	5391.21	23.2288	5310.5486	12.9857	1789.5793	6.449	5554.1626	42.2823	325.6052		

Pokazatelji oblika kvantitativno opisuju geometrijsku kompleksnost uzoraka i klasa. Vrijednosti pokazatelja oblika za sve klase površinskog pokrova prikazane su u tablici x. Prema prosječnom indeksu oblika (SHAPE_MN), klase poljoprivrednih i vodenih površina izdvajaju se kao morfološki složenije klase. Klasa travnjaka također ima složeniji oblik, a morfološki najjednostavnija klasa je golo tlo. S druge strane, prosječni indeks oblika ponderiran površinom (SHAPE_AM), koji je zbroj indeksa oblika za sve uzorke svake pojedine klase površinskog pokrova pomnožen s proporcionalnom brojnošću uzoraka, pokazuje različite rezultate (Rosa i Carreiras, 2017).


Najveće vrijednosti SHAPE_AM ima klasa šuma, dok se od ostalih klasa nešto više vrijednosti javljaju u klasama poljoprivredne površine, izdanci stijena i oskudna vegetacija. Najveći koeficijent varijacije indeksa oblika je zabilježen u klasi poljoprivredne površine. Promatrajući pokazatelj srednje vrijednosti indeksa fraktalne dimenzije (FRAC_MN), sve klase površinskog pokrova bilježe vrijednost blizu 1, što upućuje na klase manje kompleksnih oblika. Najveći raspon vrijednosti indeksa fraktalne dimenzije bilježe klase oskudna vegetacija, antropogene površine, travnjaci i poljoprivredne površine. Najveći koeficijent varijacije indeksa fraktalne dimenzije bilježi klasa vodenih površina. Pokazatelj oblika PARA_MN (odnos perimetra i površine) najveću vrijednost bilježi u klasama antropogene površine, izdanci stijena, golo tlo i oskudna vegetacija. Kada je pokazatelj PARA ponderiran površinom klase (PARA_AM) po kompleksnosti oblika izdvaja se klasa antropogenih površina. Poljoprivredne površine i travnjaci imaju najveći koeficijent varijacije odnosa perimetra i površine.

Prema pokazatelju srednje vrijednosti povezane opisujuće kružnice (CIRCLE_MN) te njegovoj vrijednosti ponderiranoj po površini (CIRCLE_AM), klasa vodenih površina je oblikom najkompleksnija. Ostale klase vrlo su ujednačene u vrijednosti pokazatelja povezane opisujuće kružnice, ali sve pokazuju kompleksnost oblika. Najmanje kompleksne oblikom su klase golo tlo i izdanci stijena. Vodene površine bilježe i najveći koeficijent varijacije pokazatelja povezane opisujuće kružnice.

Prosječna vrijednost indeksa susjedstva (CONTIG_MN) najveća je u klasama poljoprivredne površine i travnjaci, a najmanja u klasama antropogene površine, golo tlo i oskudna vegetacija. Sve klase generalno bilježe nisku srednju vrijednost indeksa susjedstva, što ukazuje na slabiju povezanost unutar klasa. Indeks susjedstva ponderiran po površini klase (CONTIG_AM) najveću vrijednost ima u klasi šuma, a zatim u klasama poljoprivredne površine, vodene površine i travnjaci. Klasa golo tlo ima najveći koeficijent varijacije vrijednosti indeksa susjedstva (CONTIG_CV). Analizom raspodjele vrijednosti površine i indeksa oblika za uzorke po pojedinačnim klasama te izračunom i vizualizacijom linearne regresije na razini uzorka, evidentirana je veza između površine uzorka i indeksa oblika uzorka. Kako se površina uzorka povećava, indeks oblika linearno se povećava, tj. uzorci s većom površinom također su i složenijeg oblika. Prosječna vrijednost koeficijenta determinacije linearne regresije za cijelo proučavano područje i sve klase površinskog pokrova iznosi 0,73. Ovaj odnos između indeksa oblika i površine uzorka može se vidjeti i u svim prethodno opisanom pokazateljima oblika koji su ponderirani po površini. Primjer je pokazatelj SHAPE_AM, gdje klasa šume ima najveći stupanj složenosti i najveću prosječnu površinu uzorka na razini klase (Sl. 6.3.1).

Tab. 6.3.2 Metrika krajobraza na razini klasa površinskog pokrova – pokazatelji oblika, MN-srednja vrijednost, AM_vrijednost ponderirana po površini, MD_medijalna vrijednost, RA_raspon vrijednosti, SD_standardna devijacija, CV_koeficijent varijacije

KLASA	SHAPE_MN	SHAPE_AM	SHAPE_MD	SHAPE_RA	SHAPE_SD	SHAPE_CV	FRAC_MN	FRAC_AM
šume	1.2904	100.8532	1	107.0295	0.8261	64.0187	1.0622	1.4049
travnjaci	1.51	11.872	1.25	50.1145	1.0102	66.9019	1.0858	1.2686
antropogene površine	1.3162	5.7312	1	23.0722	0.701	53.2635	1.0692	1.2425
poljoprivredne površine	1.6275	21.943	1.25	69.6337	1.3996	85.9998	1.0911	1.3092
izdanci stijena	1.2697	21.9006	1	47.5107	0.7276	57.2991	1.0608	1.3332
vodene površine	1.7792	7.5981	1.2857	13.0208	1.3644	76.6891	1.1121	1.2617
golo tlo	1.213	7.1334	1	16.5974	0.4664	38.4488	1.0549	1.2359
oskudna vegetacija	1.33	19.633	1	42.6359	0.8611	64.7426	1.0696	1.3434
KLASA	FRAC_MD	FRAC_RA	FRAC_SD	CIRCLE_SD	CIRCLE_CV	CONTIG_MN	CONTIG_AM	CONTIG_MD
šume	1.0453	0.4291	0.0663	0.2873	70.1956	0.3072	0.978	0.2778
travnjaci	1.0745	0.4595	0.0797	0.2917	62.643	0.3865	0.9019	0.3333
antropogene površine	1.0384	0.47	0.0787	0.3188	75.1709	0.2462	0.6951	0.1667
poljoprivredne površine	1.0745	0.4508	0.0837	0.2947	62.3753	0.3928	0.941	0.3333
izdanci stijena	1.029	0.4498	0.0696	0.2948	74.7811	0.2524	0.8444	0.1667
vodene površine	1.0946	0.3882	0.104	0.3604	66.1871	0.2985	0.9116	0.2222
golo tlo	1.0222	0.3735	0.0666	0.3063	84.2295	0.2165	0.8085	0.1667
oskudna vegetacija	1.0222	0.4767	0.0823	0.306	76.9556	0.2223	0.805	0.1667
KLASA	CONTIG_RA	CONTIG_SD	CONTIG_CV	FRAC_CV	PARA_MN	PARA_AM	PARA_MD	PARA_RA
šume	0.9857	0.2762	89.929	6.2391	2635.1447	79.038	2666.6667	3949.0584
travnjaci	0.9903	0.3154	81.6231	7.3417	2338.7062	352.6005	2400	3965.6013
antropogene površine	0.9715	0.2337	94.9541	7.3624	2889.6956	1108.8659	3000	3899.2674
poljoprivredne površine	0.9872	0.3245	82.6218	7.6719	2320.4245	211.9901	2400	3954.3609
izdanci stijena	0.9479	0.2447	96.9323	6.5585	2860.4686	566.3687	3000	3810.8466
vodene površine	0.9608	0.2769	92.7582	9.349	2695.2498	314.1201	2800	3861.5493
golo tlo	0.961	0.235	108.5205	6.3116	3021.8366	700.7018	3000	3860.038
oskudna vegetacija	0.949	0.216	97.1537	7.6956	2993.4794	718.2732	3000	3816.6959
KLASA	PARA_SD	PARA_CV	CIRCLE_MN Rel	CIRCLE_AM	CIRCLE_MD	CIRCLE_RA		
šume	1154.4325	43.8091	0.4093	0.8216	0.4907	0.9797		
travnjaci	1294.753	55.3619	0.4656	0.7435	0.5414	0.9775		
antropogene površine	1013.267	35.0648	0.4241	0.7998	0.4907	0.9978		
poljoprivredne površine	1326.0962	57.1489	0.4724	0.7646	0.5616	0.9617		
izdanci stijena	1045.2827	36.5424	0.3943	0.7239	0.4907	0.985		
vodene površine	1173.9189	43.5551	0.5445	0.9129	0.6817	0.9936		
golo tlo	1017.2096	33.662	0.3637	0.7259	0.4907	0.9813		
oskudna vegetacija	942.5219	31.4858	0.3977	0.7822	0.4907	0.9529		



Sl. 6.3.1 Odnos pokazatelja površine uzorka i indeksa oblika uzorka za klasu šuma

Pokazatelji agregacije odnose se na tendenciju tipova uzoraka da budu prostorno agregirani; to jest, da se javljaju u velikim, agregiranim ili "zaraznim" distribucijama. Podskupina pokazatelja agregacije su pokazatelji izolacije. Izolacija je usko povezana s konceptom podjele; oboje se odnosi na podjelu *per se* tipova uzoraka, ali izolacija se eksplicitno bavi stupnjem do kojeg su uzorci prostorno izolirani jedni od drugih, dok se podjela ne odnosi na udaljenost između uzoraka, već samo na to da su oni razdvojeni. Pokazatelji agregacije/izolacije na razini klasa prikazani su u

Tab. 6.3.3. Srednja vrijednost indeksa blizine (PROX_MN) te srednja vrijednost indeksa blizine ponderiran po površini najveću vrijednost bilježe u klasi šuma. Najmanju vrijednost, tj. najveći stupanj izolacije pokazuju klase antropogenih i vodenih površina. Klasa vodenih površina bilježi i vrlo velik koeficijent varijacije indeksa blizine.

Na prostoru GH najveća srednja vrijednost euklidske udaljenosti najbližeg susjeda (ENN_MN) i površinski ponderirana srednja euklidska udaljenost najbližeg susjeda (ENN_AM) zabilježena je u klasi vodenih površina, što znači da su uzorci u ovoj klasi najizoliraniji jedni od drugih, a s obzirom na prevlast krškog morfofenetskog tipa reljefa, ovaj rezultat je očekivan. Ova klasa u ENN pokazateljima predstavlja ekstremnu vrijednost jer se ističe od ostalih klasa.

Klase golog tla, antropogenih područja i travnjaka pokazuju nešto veći stupanj agregacije, dok ostale klase pokazuju slične vrijednosti koje ukazuju na agregiranje uzoraka. Klase šuma i oskudne vegetacije imaju najveći stupanj agregacije

Tab. 6.3.3 Metrika krajobraza na razini klasa površinskog pokrova – pokazatelji agregacije/izolacije, MN-srednja vrijednost, AM_vrijednost ponderirana po površini, MD_medijalna vrijednost, RA_raspon vrijednosti, SD_standardna devijacija, CV_koeficijent varijacije

KLASA	PROX_MN	PROX_AM	PROX_MD	PROX_RA	PROX_SD	PROX_CV	ENN_MN	ENN_AM	ENN_MD	ENN_RA	ENN_SD	ENN_CV
šume	1949642.38	443617.157	15985.422	18124092	4657714.6	238.901	33.9394	20.2992	22.3607	840.0581	25.0706	73.8688
travnjaci	1875.5686	6614.3584	11.6828	93889.306	8126.3659	433.2748	70.98	52.0332	30	4537.247	135.8201	191.3497
antropogene površine	51.0116	116.9589	1.6861	4775.5232	314.1508	615.8414	71.7971	73.7964	30	4391.848	153.3138	213.5378
poljoprivredne površine	6101.3169	7399.9594	72.5192	399803.64	34598.462	567.0655	49.4493	53.7746	22.3607	6059.679	130.7105	264.3324
izdanci stijena	1778.2521	2410.4697	13.8895	133562.93	10067.32	566.1357	44.3952	33.1425	28.2843	6251.148	97.8738	220.4606
vodene površine	92.2544	51.7155	1.0942	9313.4973	684.7365	742.2266	319.739	1129.9561	31.6228	16230.35	1642.75	513.7784
golo tlo	175.6766	242.2403	2.2852	17445.009	1319.2742	750.9674	82.2194	84.3579	30	12641.24	311.4283	378.7773
oskudna vegetacija	2513.4994	5520.3714	21.2989	137235.54	12961.814	515.688	30.1919	22.1989	22.3607	1068.531	24.2429	80.2962

Izdvojeni su i pokazatelji agregacije, a prikazani su u Tab. 6.3.4. Vrijednost indeksa grudanja (CLUMPY) pokazuje kako su sve klase površinskog pokrova u GH izrazito agregirane. Najviše agregirana je klasa poljoprivrednih površina, a najmanje agregirana je klasa antropogenih površina. Postotak sličnih susjedstava (PLADJ) bilježi slične rezultate kao i indeks grudanja, ali je klasa koja prednjači u agregaciji klasa šuma, zatim poljoprivredne površine i vodene površine. Klasa antropogenih površina bilježi najmanje vrijednosti, no, sve klase promatrane zajedno imaju karakter agregiranih klasa. Indeks intersperzije i jukstapozicije (IJI) ukazuje da su klase šume i golo tlo susjedne klase gotovo svim drugim klasama. Travnjaci su najizoliranija klasa prema IJI pokazatelju te su susjedni s najmanjim brojem klasa. Indeks kohezije (COHESION) vrlo je ujednačen po svim klasama te ukazuje na agregirane, manje fragmentirane, dobro povezane uzorke u klasama. Indeks agregacije (AI) pokazuje vrlo male razlike u vrijednosti po klasama, ali se izdvaja klasa šuma kao najviše agregirana te klasa antropogenih površina koja je manje agregirana.

Vrijednost normaliziranog indeksa oblika krajobraza (NLSI) pokazuje najveću varijaciju u vrijednostima po klasama površinskog pokrova od svih pokazatelj iz ove skupine. Unatoč varijaciji i dalje su rezultati redundantni te potvrđuju da su sve klase dobro agregirane te nemaju obilježja fragmentiranih klasa. Poljoprivredne površine prema NLSI su najmanje agregirane, no i dalje ne prelaze granicu vrijednosti NLSI-a koja bi ukazivala na fragmentirane klase.

Tab. 6.3.4 Metrika krajobraza na razini klasa površinskog pokrova – pokazatelji agregacije

KLASA	CLUMPY	PLADJ	IJI	COHESION	AI	NLSI
šume	0,9201	98,024	77,5917	99,9902	98,0351	0,0602
travnjaci	0,905	91,185	48,8548	99,2684	91,2174	0,0878
antropogene površine	0,7218	72,2784	62,4562	95,2183	72,3655	0,2763
poljoprivredne površine	0,9416	94,7002	48,5409	99,7684	94,7299	0,0527
izdanci stijena	0,8545	85,8408	63,8764	99,3641	85,8893	0,1411
vodene površine	0,9237	92,147	54,1866	98,9788	92,3826	0,0762
golo tlo	0,826	82,4825	78,2102	97,5658	82,6417	0,1736
oskudna vegetacija	0,8148	82,0432	53,5083	99,0969	82,0876	0,1791

Pokazatelji agregacije koji se odnose na podjelu (Tab. 6.3.5) (eng. *subdivision*) usko su povezani s konceptom disperzije; oboje se odnosi na agregaciju tipova uzoraka, ali podjela se eksplicitno bavi stupnjem do kojeg su tipovi uzoraka “razbijeni” (tj. podijeljeni) na odvojene uzorke (tj. fragmente). Pokazatelji agregacije za sve klase površinskog pokrova prikazani su u (Tab. 6.3.5). Vrijednosti indeksa podijeljenosti krajobraza (DIVISION) iznosi 1 gotovo za sve klase, dok za klasu šuma iznosi 0,52 što ukazuje na velike, dobro povezane uzorke. Efektivna veličina mreže (MESH) ukazuje na vrlo veliku vrijednost povezanosti uzoraka klase šuma, povezanost uzoraka poljoprivrednih površina, malu vrijednost povezanosti u klasama travnjaka, izdanaka stijena i oskudne vegetacije. Ostale klase nemaju značajnije povezanosti tj. vrlo su fragmentirane. Vrijednosti indeksa razdvojenosti (SPLIT) konkordantne su vrijednostima MESH-a, iako su pokazatelji obrnuto proporcionalni.

Tab. 6.3.5 Metrika krajobraza na razini klasa površinskog pokrova – pokazatelji agregacije

KLASA	DIVISION	MESH	SPLIT
šume	0,5273	494918,9	2,1156
travnjaci	0,9999	67,1437	15594,55
antropogene površine	1	0,1814	5773714
poljoprivredne površine	0,9996	448,7546	2333,291
izdanci stijena	1	49,0206	21359,88
vodene površine	1	0,3393	3085794
golo tlo	1	0,5405	1937358
oskudna vegetacija	1	40,2787	25995,78


Metrika na razini cijelog krajobraza, u ovom slučaju površinski pokrov cijele GH sa svim svojim klasama i uzorcima daje uvid u kompoziciju i konfiguraciju na najvišoj prostornoj razini. Vrijednosti pojedinih pokazatelja metrike krajobraza na razini cijele GH prikazane su u Tab. 6.3.6. Prema pokazateljima površine i ruba u cijelom površinskom pokrovu GH dominira jedan veliki uzorak, a to je uzorak iz klase šuma koji je i u metrici na razini klasa bilježio ekstremne vrijednosti. Prema pokazateljima oblika, radi se o površinskom pokrovu izduženih, ali ne jako kompleksnih oblika uzoraka. Pokazatelji ponderirani po površini bolje odražavaju stanje u cjelini kao što je GH, tako pokazatelj polumjera tromosti koji je ponderiran po površini za cijeli prostor GH ukazuje na prevlast velikih uzoraka u površinskom pokrovu. Prema pokazateljima agregacije/izolacije radi se o dobro povezanim i agregiranim uzorcima s vrlo malim stupnjem fragmentacije. Prema pokazateljima agregacije površinski pokrov GH gotovo je maksimalno agregiran i povezan. Pokazatelj podijeljenosti krajobraza odskaka od drugih pokazatelja agregacije te za cijeli površinski pokrov GH bilježi vrijednost 0,5 što je srednja vrijednost mogućeg raspona (od 0 do 1) što upućuje na površinske pokrove koji nisu niti agregirani, ali nisu niti fragmentirani. Pokazatelji raznolikosti ukazuju na manje raznolik površinski pokrov. Shannonov indeks raznolikosti (SIDI) bilježi male vrijednosti te ukazuje na malu raznolikost. Simpsonov indeks raznolikosti (SIDI) ukazuje na osrednje raznolik površinski pokrov, tj. 41% iznosi vjerojatnost da su sva nasumično uzorkovana uzorka površinskog pokrova različiti.

Tab. 6.3.6 Metrika krajobraza za površinski pokrov – razina krajobraza

POVRŠINA/RUB	TA	AREA_MN	AREA_AM	AREA_MD	AREA_RA	AREA_SD	AREA_CV
	1047074,95	3,7246	495525,1281	0,03	719622,3	1358,5335	36474,7277
	GYRATE_MN	GYRATE_AM	GYRATE_MD	GYRATE_RA	GYRATE_SD	GYRATE_CV	LPI
	18,0544	33505,2841	6,6667	47654,5232	111,8365	619,4405	68,7269
	TE	ED					
OBLIK	81341300	77,6843					
	SHAPE_MN	SHAPE_AM	SHAPE_MD	SHAPE_RA	SHAPE_SD	SHAPE_CV	FRAC_MN
	1,34	80,4395	1	107,0295	0,8588	64,0851	1,0688
	FRAC_AM	FRAC_MD	FRAC_RA	FRAC_SD	FRAC_CV	PARA_MN	PARA_AM
	1,3794	1,0457	0,4767	0,0762	7,128	2770,6174	156,8116
	PARA_MD	PARA_RA	PARA_SD	PARA_CV	CIRCLE_MN	CIRCLE_AM	CIRCLE_MD
	3000	3965,6013	1110,5637	40,0836	0,4132	0,8057	0,4907
	CIRCLE_RA	CIRCLE_SD	CIRCLE_CV	CONTIG_MN	CONTIG_AM	CONTIG_MD	CONTIG_RA
	0,9978	0,3007	72,7661	0,2764	0,9566	0,2083	0,9903
	CONTIG_SD	CONTIG_CV	PAFRAC				
AGREGACIJA- IZOLACIJA	0,2631	95,2023	1,3912				
	PROX_MN	PROX_AM	PROX_MD	PROX_RA	PROX_SD	PROX_CV	ENN_MN
	414530,2785	335965,9094	21,8616	18124092,32	2286703,273	551,6372	46,7407
AGREGACIJA	ENN_AM	ENN_MD	ENN_RA	ENN_SD	ENN_CV		
	28,5466	22,3607	16230,3538	125,6325	268,7858		
	LSI	CONTAG	PLADJ	IJI	COHESION	AI	
AGGREGATION - PODJELA	202,4142	73,4316	96,0797	66,1713	99,961	96,0976	
	DIVISION	MESH	SPLIT	NP	PD		
RAZNOLIKOST	0,5268	495525,1281	2,1131	281125	26,8486		
	PR	PRD	SHDI	SIDI			
	8	0,0008	0,9094	0,4143			

6.4. Tipologija krajobraza Gorske Hrvatske– Makro razina

Na prostoru GH izdvojena su 4 tipa krajobraza na makro razini, a njihova prostorna distribucija prikazana je na Sl. 6.4.2. **Tip 1 - Udoline, fragmenti zaravni i krške depresije većih dimenzija** hipsometrijski se nalazi na nadmorskim visinama od 500-700 m, što su ujedno hipsometrijski najniži dijelovi prostora GH. Orografski obuhvaća poglavito zaravni i ravnice te padine dolinskih strana. Prosječan nagib je između 9 i 13°. Prosječna vrijednost vertikalne raščlanjenosti reljefa u ovom tipu krajobraza kreće se od 80 do 110 m/km². **Tip 2 - Pobrđa i niži pristranci dolinskih strana** u prosjeku se nalaze na 700-900 m n.v. Orografski su najčešće obuhvaćene padine gorskih strana, prosječan nagib kreće se između 10 i 13 °, a prosječna vertikalna raščlanjenost reljefa iznosi 110-210 m/km². **Tip 3 - Planinski lanci i masivi, izraženi hrptovi** u prosjeku se nalaze na 700-900 m n.v. Orografski su najčešće obuhvaćene padine gorskih strana, manji grebeni i kose te uzvisine u dolinama. Prosječan nagib iznosi 18-26 °, a prosječna vertikalna raščlanjenost reljefa 320-900 m/km². **Tip 4 - Niži pristranci i strme dolinske strane** u prosjeku se nalaze na 700-900 m n.v. Orografski su najčešće obuhvaćene široke doline i niži pristranci. Prosječan nagib iznosi 18-26°, a prosječna vertikalna raščlanjenost reljefa iznosi 210-320 m/km². Sve vrijednosti prikazane su na Sl. 6.4.1 i u Tab. 6.4.1.



Sl. 6.4.1 Prikaz izdvojenih tipova krajobraza na makro razini i raspona vrijednosti varijabli


Raspodjela površina tipova krajobraza je ujednačena, no najveću površinu (31,2%) zauzima tip 1, zatim tip 2 (29,9%). Udjeli površine tipova krajobraza makro razine prikazani su na Sl. 6.4.3.

Prema prostornom rasporedu tipova krajobraza, tip 1 dominira središnjim dijelom GH gdje se nalaze najveće i naj brojnije zavale polja u kršu, te na istočnom rubu gdje se nalaze velike udoline i doline tekućica. Prostorno najveći uzorci također su vezani uz središnji prostor, a površinom manji uzorci prisutni su na krajnjem jugu i krajnjem sjeveru. Na sjeveru i na zapadnom rubu nema prisutnog tipa krajobraza Udoline, fragmenti zaravni i krške depresije većih dimenzija.


Tab. 6.4.1 Tipovi krajobraza GH (makro razina) s prikazanim srednjim vrijednostima varijabli

Varijable:	Makro tipovi krajobraza GH			
	1_Udoline, fragmenti zaravni i krške depresije većih dimenzija	2_Pobrđa i niži pristranci dolinskih strana	3_Planinski lanci i masivi, izraženi hrptovi	4_Niži pristranci i strme dolinske strane
hipsometrija (m n.v.)	500-700	700-900	700-900	700-900
orografija	zaravni, ravnice i padine dolinskih strana	padine gorskih strana, padine dolinskih strana	padine gorskih strana, manji grebeni i kose, uzvisine u dolinama	široke doline, niži pristranci
nagibi (°)	9-13	9-13	18-26	18-26
vertikalna raščlanjenost reljefa (m/km ²)	80-110	110-210	320-900	210-320


U tipu jedan nalazi se najmanji broj uzoraka, što ukazuje na uzorke najvećih površina. Drugi najzastupljeniji tip, gotovo jednako zastupljen kao tip 1 je tip 2-pobrđa i niži pristranci dolinskih strana. Ova klasa dominira sjevernim i središnjim dijelom, a uopće se ne javlja na zapadnom rubu prostora GH. U ovoj klasi nalazi se velik broj uzoraka, što ukazuje na fragmentiranost ove klase te male površine uzoraka. Tip 3-planinski lanci i masivi, izraženi hrptovi prostire se na sjeveru, zapadnom rubu te na jugu jugoistočnom i južnom dijelu prostora. Manji uzorci malih površina nalaze se i u središnjem dijelu prostora GH. Ovaj tip prostire se na 21,5% prostora GH, a sadrži mali broj uzoraka, što ukazuje na uzorke velikih površina. Tip 4-niži pristranci i dolinske strane strmih padina prostire se na 17,2% površine te je najmanje zastupljen tip krajobraza. Ovaj tip krajobraza sadrži najveći broj uzoraka. Obzirom na odnos ukupne površine klase i broj uzoraka, ova klasa je najviše fragmentirana. Ovaj tip krajobraza prostorno je vezan uz tip 3 te ga gotovo obrubljuje. U središnjem dijelu prostora GH ova klasa javlja se i kao granična klasa između tipa 2 i tipa 1. Udjeli površina i broj uzoraka u svakom tipu krajobraza prikazana su na Sl. 6.4.3 i Sl. 6.4.4.



Sl. 6.4.2 Tipovi krajobraza Gorske Hrvatske izdvojeni kombiniranom metodom (makro razina)



Sl. 6.4.3 Udjeli površina tipova krajobraza na prostoru GH



Sl. 6.4.4 Broj uzoraka po tipovima krajobraza na prostoru GH

6.5. Tipologija krajobraza GH – mezo razina

Na prostoru GH izdvojeno je 20 tipova krajobraza na mezo razini, a njihova prostorna distribucija prikazana je na Sl. 6.5.25. Prosječne vrijednosti varijabli za sve izdvojene tipove krajobraza GH na mezo razini prikazane su u Tab. 6.5.1.

Tab. 6.5.1 Tipovi krajobraza GH (mezo razina) s prikazanim srednjim vrijednostima varijabli


Varijable:	Mezo tipovi krajobraza GH			
	1_1	2_1	3_1	4_1
prevladavajući morfologenetski tip reljefa	krš	krš	krš	fluviokrš
prevladavajući površinski pokrov	šume	šume	šume	šume
	1_2	2_2	3_2	4_2
	glaciokrš	fluviokrš	glaciokrš	krš
prevladavajući površinski pokrov	poljoprivredne površine/golo tlo	šume	šume	šume
	1_3	2_3	3_3	4_3
	fluviokrš	krš	fluviodenudacijski/fluviokrš	fluvijalni/fluviodenudacijski
prevladavajući površinski pokrov	šume	izdanci stijena/travnjaci	šume	šume
	1_4	2_4	3_4	4_4
	fluvijalni	fluviokrš	glaciokrš	fluviodenudacijski/fluviokrš
prevladavajući površinski pokrov	šume/antropogene površine	izdanci stijena	travnjaci/izdanci stijena	poljoprivredne površine/golo tlo
	1_5	2_5	3_5	4_5
	fluvijalni	glaciokrš	fluviokrš/glaciokrš	krš
prevladavajući površinski pokrov	poljoprivredne površine	oskudna vegetacija	golo tlo/oskudna vegetacija	izdanci stijena

Unutar 20 tipova krajobraza na mezo razini izdvojeno je ukupno 2.146 uzoraka. Distribucija broja uzoraka je ujednačena po makro tipovima krajobraza. Makro tipovi s većim brojem uzoraka, zauzimaju manju površinu prostora GH. Na mezo razini površinom prevladavajući tip krajobraza na prostoru GH je **Tip 2_1** Pobrđa i niži pristranci dolinskih strana krškog morfogenetskog tipa sa šumom, koji se prostire na 21% prostora GH. Drugi najzastupljeniji površinom je **Tip 1_1** Udoline, fragmenti zaravni i krške depresije većih dimenzija krškog morfogenetskog tipa reljefa sa šumom koji se rasprostire na 17,2% površine GH. Površinom najmanje zastupljen tip je **Tip 3_5** Planinski lanci i masivi, izraženi hrptovi u kršu ili glaciokršu te prekriveni golim tlom ili oskudnom vegetacijom koji se nalazi na 0,4% prostora GH. Sljedeći po vrlo maloj zastupljenosti površinom je **Tip 2_5** Pobrđa i niži pristranci dolinskih strana u glaciokršu prekriveni oskudnom vegetacijom koji se nalazi na 0,5% prostora GH. Obzirom na brojnost uzoraka u cjelokupnom krajobrazu GH prednjači **Tip 4_1** Niži pristranci i strme dolinske strane u fluviokrškom morfogenetskom tipu reljefa sa šumom u kojem se nalazi 13,2% svih uzoraka GH. Sljedeći po broju uzoraka je **Tip 2_1** Pobrđa i niži pristranci dolinskih strana krškog morfogenetskog tipa sa šumom u kojem se nalazi 12,8% uzoraka. Površine i broj uzoraka po svakom mezo tipu prikazane su u **tablici x**. Najučestalija kombinacija morfogenetskog tipa i površinskog pokrova je krš – šume, te se javlja u 4 mezo tipa. Sljedeća vrlo zastupljena kombinacija je fluviokrš – šume te se javlja u 3 mezo tipa. Sve ostale kombinacije su jedinstvene. Makro tip s najvećom raznolikošću morfogenetskih tipova i površinskog pokrova je **Tip 3** Planinski lanci i masivi, izraženi hrptovi koji sadrži 5 potpuno različitih mezo tipova krajobraza (Tab. 6.5.2).

Tab. 6.5.2 Površine i broj uzoraka svakog mezo tipa u apsolutnim vrijednostima te udjeli površina i broja uzoraka u cijelom prostoru GH i u nadređenim makro tipovima krajobraza


Tip krajobraza	Površina (km ²)	Udio u GH (%)	Udio u makro tipu (%)	Broj uzoraka	Udio u GH (%)	Udio u makro tipu (%)
1_1	1801,029163	17,20344983	54,84399574	148	7,07118968	32,81596452
1_2	528,3170453	5,046490068	16,08803365	125	5,972288581	27,71618625
1_3	325,8295642	3,112327483	9,921991048	94	4,491161013	20,84257206
1_4	288,8950181	2,759528304	8,797279617	54	2,580028667	11,97339246
1_5	339,8423133	3,246177412	10,34869994	38	1,815575729	8,425720621
Ukupno:		31,3679731	99,99999999	459	21,93024367	101,7738359
2_1	2204,686751	21,05919143	69,9756151	269	12,85236503	47,52650177
2_2	612,8512382	5,853961584	19,45158075	136	6,497849976	24,02826855
2_3	164,8532722	1,57468022	5,23235744	87	4,156712852	15,37102473
2_4	109,4744404	1,045701026	3,474662014	77	3,678929766	13,60424028
2_5	58,78434627	0,561508704	1,865784691	21	1,003344482	3,71024735
Ukupno:		30,09504297	100	590	28,1892021	104,2402827
3_1	834,74337	7,973477601	36,91732633	206	9,842331581	43,18658281
3_2	780,4386098	7,45475795	34,51564621	47	2,245580506	9,853249476
3_3	362,5278822	3,46287021	16,03314337	122	5,828953655	25,57651992
3_4	238,5168972	2,278315954	10,54863859	75	3,583373149	15,72327044
3_5	44,88869263	0,428777272	1,985245494	32	1,528905877	6,708595388
Ukupno:		21,59819899	100	482	23,02914477	101,048218
4_1	791,6352523	7,561708399	44,54868659	278	13,2823698	46,41068447
4_2	481,1284326	4,595743935	27,07514564	184	8,791208791	30,71786311
4_3	274,1920941	2,619085816	15,4299567	39	1,863354037	6,510851419
4_4	145,2492566	1,387422453	8,173794171	66	3,153368371	11,01836394
4_5	84,80639378	0,810071581	4,772416901	48	2,293358815	8,013355593
Ukupno:		16,97403218	100	615	29,38365982	102,6711185

Na Sl. 6.5.1 prikazan je raspon varijabli te mezo tipovi krajobraza **Tip 1** Udolina, fragmenata zaravni i krških depresija većih dimenzija. Obzirom na prevladavajući površinski pokrov GH, nije iznenađujuće da je upravo klasa šuma često prevladavajući tip površinskog pokrova. Ovaj makro tip krajobraza je najmanje raznolik po površinskom pokrovu. Obzirom da u ovom makro tipu krajobraza prevladavaju zaravnjeni i hipsometrijski najniži dijelovi prostora u GH fluvijalni morfogenetski tip reljefa prevladava kao samostalan morfogenetski tip reljefa u čak dva tipa krajobraza (1_4 i 1_5).



Sl. 6.5.1 Prikaz izdvojenih tipova krajobraza na mezo razini i raspona vrijednosti varijabli za makro Tip 1


Na Sl. 6.5.2 prikazan je raspon varijabli te mezo tipovi krajobraza **Tip 2** Pobrđa i niži pristranci dolinskih strana. Ovaj makro tip raznolik je u pogledu površinskog pokrova te se u 5 mezo tipova javlja 5 različitih klasa prevladavajućeg površinskog pokrova. Po pitanju morfogenetskih tipova reljefa je najmanje raznolik tj. javljaju se 3 od mogućih 5 morfogenetskih tipova reljefa.



Sl. 6.5.2 Prikaz izdvojenih tipova krajobraza na mezo razini i raspona vrijednosti varijabli za makro Tip 2


Na Sl. 6.5.3 prikazan je raspon varijabli te mezo tipovi krajobraza **Tip 3** Planinski lanci i masivi, izraženi hrptovi. Ovaj makrotip raznolik je po morfogenetskim tipovima i po vrsti površinskog

pokrova koji prevladavaju u pojedinim mezotipovima, te ima samo jednu kombinaciju morfogenetskog tipa i površinskog pokrova koja je ponavljajuća u cijelom krajobraz GH, a to je u **Tipu 3_1** morfogenetski tip krškog reljefa te šuma kao površinski pokrov.



Sl. 6.5.3 Prikaz izdvojenih tipova krajobraza na mezo razini i raspona vrijednosti varijabli za makro Tip 3


Na Sl. 6.5.4 prikazan je raspon varijabli te mezo tipovi krajobraza **Tip 4** Niži pristranci i strme dolinske strane. Tip 4 ukupno zauzima najmanju površinu u prostoru GH. Kao i Tip 1 vrlo je uniforman po površinskom pokrovu, te tako u 3 od 5 mezo tipa prevladavajući površinski pokrov je šuma. Tip **4_3** jedini je tip na mezo razini u kojem su prevladavajući morfogenetski tipovi reljefa fluvijalni i fluviodenudacijski.




Sl. 6.5.4 Prikaz izdvojenih tipova krajobraza na mezo razini i raspona vrijednosti varijabli za makro Tip 4

6.5.1. Kompleksni krajobrazni gradijenti

Obilje ugroženih staništa prema (prema Prilogu II. Pravilnika o popisu stanišnih tipova i karti staništa) javlja se u 4 klase. Klasa 1 označava prisutnost rijetkih i ugroženih staništa, a klasa 4 označava iznimno obilje rijetkih i ugroženih staništa. Prostorna distribucija obilja ugroženih staništa prikazana je na Sl. 6.5.5. Prostorno, upravo klase značajnijeg obilja (klasa 3 i 4) u površinski većim arealima javlja se na južnom dijelu prostora GH. Promatrajući raspodjelu postotnog udjela klase obilja ugroženih staništa po mezo tipovima krajobraza, klasa 5 čini više od 50% mezo tipova MLT 2_3, MLT 2_4 i MLT 3_4 (Sl. 6.5.6). U tri navedena mezo tipa izdanci stijena i travnjaci javljaju se kao dominantan površinski pokrov.




Sl. 6.5.5 Kompleksni krajobrazni gradijent obilje ugroženih staništa




Sl. 6.5.6 Postotni udjeli klasa obilja ugroženih staništa po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Prisutnost kanjona/duboko usječenih dolina i strmih strana javlja se u 3 klase. Klasa 1 označava prostor u kojem gotovo da i nema kanjona i duboko usječenih dolina, klasa 2 označava prisutnost, a klasa 3 značajnu prisutnost. Prostorni raspored klasa ovoga kompleksnog krajobraznog gradijenta prikazan je na Sl. 6.5.7. Prostorom GH dominira klasa 1, a klasa 2 i 3 nadovezuju se prostorno jedna na drugu. Duž Velebita te na kontaktu Velebita i zavale Ličkog polja javljaju se kontinuirani pojasevi klase 2 i 3. Izraženi kontinuirani areali klase 3 značajni su i na prostoru Pokupskog pobrđa te na južnom dijelu prostora GH u izvorišnom prostoru rijeke Une te oko masiva Poštaka. Promatrajući distribuciju postotnih udjela površina klasa po mezo tipovima krajobraza, najznačajniji udio klase 2 i 3 prisutan je u svim mezo tipovima makro tipa 4_Niži pristranci i strme dolinske strane.




Sl. 6.5.7 Kompleksni krajobrazni gradijent prisutnost kanjona/duboko usječenih dolina i strmih strana




Sl. 6.5.8 Postotni udjeli klasa prisutnosti kanjona/duboko usječenih dolina po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Obilje grebena javlja se u 3 klase. Klasa 1 označava prostor na kojem gotovo i nema grebena, klasa 2 umjereno obilje, te klasa 3 značajno obilje grebena. Prostorni raspored klasa obilja grebena prikazan je na Sl. 6.5.9. Najveći kontinuirani pojasevi klase 3 prisutni su duž Velebita. Klasa 1, tj. prostor bez grebena povezan je sa zaravnjenim prostorima polja u kršu, međugorskog zavalu i fragmenata zaravni. Klasa 2 i 3 obilja grebena jasno su povezane s hipsometrijski najvišim prostorom, obzirom da su udjeli tih dviju klasa najznačajniji u svim mezo tipovima makro tipa krajobraza 3_ Planinski lanci i masivi, izraženi hrptovi (Sl. 6.5.10).




Sl. 6.5.9 Kompleksni krajobrazni gradijent obilje grebena




Sl. 6.5.10 Postotni udjeli klasa obilja grebena po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Obilje drenažne mreže javlja se u 5 klasa. Klasa 1 označava prisutnost drenažne mreže, a klasa 5 označava značajno obilje drenažne mreže. Prostorni raspored obilja drenažne mreže prikazan je na Sl. 6.5.11. Veliki kontinuirani pojasevi značajnog obilja drenažne mreže nalaze se na SI i J dijelu prostora GH. Kontaktne padine lanaca i masiva sa zavalama polja u kršu, te Velebitska primorska padina bilježe klasu 3, 4 i 5 obilja drenažne mreže, a dna polja u kršu bilježe klasu 1 i 2 obilja drenažne mreže. Promatrajući Sl. 6.5.12 po najvećem udjelu klase 5 ističe se MLT 4_3. Najveće postotne udjele klase 1 bilježe mezo tipovi MLT 1_1, MLT 2_1 i MLT 3_1 u kojima je dominantan morfogenetski tip reljefa krš.




Sl. 6.5.11 Kompleksni krajobrazni gradijent obilje drenažne mreže




Sl. 6.5.12 Postotni udjeli klasa obilja drenažne mreže po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Obilje hidrogeoloških pojava javlja se u 4 klase. Klasa 1 označava prostor na kojem gotovo da i nema hidrogeoloških pojava, dok klasa 4 označava prostor sa značajnim obiljem hidrogeoloških pojava. Prostorni raspored prikazan je na Sl. 6.5.13. Prostorni raspored vrlo je sličan prostornom rasporedu obilja drenažne mreže. Na samom SI i duž I ruba GH sve do masiva Poštaka, te na zapadnom rubu duž kontakta Velebita sa zavalom Ličkog polja javljaju se kontinuirani pojasevi obilja hidrogeoloških pojava. Značajno obilje hidrogeoloških pojava javlja se točkasto na pojedinim lokalitetima. Promatrajući distribuciju postotnih udjela obilja hidrogeoloških pojava po mezo tipovima krajobraza (Sl. 6.5.14) najveći udio klase 4 i 5 bilježi MLT 2_4. Najveći udio klase 1 bilježe MLT 2_1, MLT 2_3, MLT 2_5, MLT 3_4 i MLT 4_5.




Sl. 6.5.13 Kompleksni krajobrazni gradijent obilje hidrogeoloških pojava




Sl. 6.5.14 Postotni udjeli klasa obilja hidrogeoloških pojava po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Obilje proluvijalnih plavina javlja se u 3 klase. Klasa 1 označava prostor gotovo bez proluvijalnih plavina, a klasa 3 značajno obilje proluvijalnih plavina. Prostorni raspored prikazan je na Sl. 6.5.15. Klasa 2 i 3 zauzimaju vrlo mali udio prostora GH (2,1%). Značajnije jezgre klase 3 javljaju se na SI sijelu prostora GH, u izvorišnom prostoru rijeke Une, na prostoru Nove Kršlje kod Rakovice, te na kontaktu Velebita i zavale Ličkog polja. Promatrajući distribuciju postotnih udjela (Sl. 6.5.16) u mezo tipovima makro tipa 3_ Planinski lanci i masivi, izraženi hrptovi je najmanji postotni udio klasa 2 i 3, tj. prevladava klasa 1. Najveći udio klase 3 bilježi MLT 4_3 i MLT 1_3.




Sl. 6.5.15 Kompleksni krajobrazni gradijent obilje proluvijalnih plavina




Sl. 6.5.16 Postotni udjeli klasa obilja proluvijalnih plavina po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Obilje ponikava javlja se u 5 klasa. Klasa 1 označava prostor u kojem gotovo i nema ponikava, dok klasa 5 označava prostor značajnog obilja ponikava. Prostorni raspored obilja ponikava prikazan je na Sl. 6.5.17. Areal najvećeg obilja ponikava (klasa 5) javlja se na prostoru Unsko-Koranske krške zaravni. Javljaju se još kontinuirani areali velikih površina klase 4 na samom S prostora GH, duž Velebita te duž Ličkog sredogorja. Promatrajući distribuciju postotnih udjela (Sl. 6.5.18) najveći udio klase 5 bilježi MLT 1_1 i MLT 1_2. Najveći udio klase 1 bilježe MLT 1_4 i MLT 1_5.




Sl. 6.5.17 Kompleksni krajobrazni gradijent obilje ponikava




Sl. 6.5.18 Postotni udjeli klasa obilja ponikava po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Obilje speleoloških objekata javlja se u 3 klase. Klasa 1 označava prostor gotovo bez speleoloških objekata, dok klasa 3 označava značajno obilje speleoloških objekata. Prostorni raspored prikazan je na Sl. 6.5.19. Klasa 2 i 3 javljaju se točkasto, a najznačajniji areali klase 3 javljaju se na sjevernom Velebitu, na masivu Crnopca i na prostoru NP Plitvička jezera. Promatrajući postotne udjele (Sl. 6.5.20) po mezo tipovima, vidljivo je kako je obilje speleoloških objekata prostorno vrlo ograničeno, a značajno obilje svojim udjelom ističe se u MLT 3_1, MLT 3_2, MLT 3_3 i MLT 3_4, od kojih najznačajniji udio ima MLT 3_2. Vidljivo je da je ovaj kompleksni krajobrazni gradijent s najznačajnijim udjelom klase 5 prisutan u makro tipu 3_ Planinski lanci i masivi, izraženi hrptovi.




Sl. 6.5.19 Kompleksni krajobrazni gradijent obilje speleoloških objekata




Sl. 6.5.20 Postotni udjeli klasa obilja speleoloških objekata Sl. 6.5.18 po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH

Frekvencija poljoprivrednih površina javlja se u 5 klasa. Klasa 1 označava prostor gotovo bez poljoprivrednih površina dok klasa 4 označava prostor s iznimnom frekvencijom poljoprivrednih površina. Prostorni raspored prikazan je na Sl. 6.5.21. Klasa 5 frekvencije poljoprivrednih površina javlja se u većim arealima na dnima velikih krških depresija te je tako velika koncentracija areala klase 5 prisutna u Ličkom, Krbavskom, Koreničkom itd., te u dolinama tekućica (Dobra, Zagorska Mrežnica, izvorišni prostor rijeke Une itd). Na krajnjem južnom, sjevernom i zapadnom dijelu GH manji je broj areala s većom frekvencijom poljoprivrednih površina, ali su i ti areali manjih površina. Promatrajući postotne udjele (Sl. 6.5.22) po mezo tipovima krajobraza, s najvećim udjelom frekvencije poljoprivrednih površina ističe se MLT 1_5 u kojem je dominantan morfogenetski tip reljefa fluvijalni, a površinski pokrov upravo poljoprivredne površine. U mezo tipovima makro tipa 3_ Planinski lanci i masivi, izraženi hrptovi najmanji je udio klase 4 frekvencije poljoprivrednih površina, te ujedno i najveći udio klase 1.




Sl. 6.5.21 Kompleksni krajobrazni gradijent frekvencija poljoprivrednih površina




Sl. 6.5.22 Postotni udjeli klasa frekvencije poljoprivrednih površina Sl. 6.5.18 po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH


Frekvencija izgrađenosti prostora javlja se u 5 klasa. Klasa 1 označava prostor gotovo bez izgrađenih površina, a klasa 5 označava značajno izgrađene površine. Prostorni raspored prikazan je na Sl. 6.5.23. Izgrađeni prostor (od klase 2 do klase 5) zauzima 9,6% prostora GH, dok se klasa 5 prostire na 0,08% prostora GH. Areali koji obuhvaćaju klasu 5 odnose se na značajnija naselja od kojih se ističe Gospić, Ogulin, Delnice i Otočac, ili na prometna čvorišta kao što su to primjerice Rapain Klanac i Vrata. Klasa 2 i 3 većinom se odnose na prometne koridore. Promatrajući distribuciju postotnih udjela (Sl. 6.5.24) po mezo tipovima vidljiv je izražen utjecaj morfometrije na izgrađenost prostora, tako se najveći udio klasa 2, 3, 4 i 5 nalazi u mezo tipovima makro tipa 1_ Udoline, fragmenti zaravni i krške depresije većih dimenzija, dok u mezo tipovima makro tipa 3_ Planinski lanci i masivi, izraženi hrptovi prevladava klasa 1.



Sl. 6.5.23 Kompleksni krajobrazni gradijent frekvencija izgrađenosti prostora




Sl. 6.5.24 Postotni udjeli klasa frekvencije izgrađenosti prostora po mezo tipovima krajobraza i prikazana distribucija postotnih udjela klasa na cijelom prostoru GH



Sl. 6.5.25 Tipovi krajobraza Gorske Hrvatske izdvojeni kombiniranom metodom (mezo razina)

MLT 1_1

Mezo tip 1_1-prisutan je u gotovo cijelom prostoru GH no najveći uzorci te najveća gustoća uzoraka je u središnjem dijelu te na istočnom rubu prostora. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.26. U ovom tipu nalazi se 148 uzoraka, a prosječna veličina uzorka je 12,1 km², ali prevladavaju mali uzorci (86% uzoraka spada u klasu malih uzoraka veličine 0,000104-12 km²). Najveći uzorak veličine je 486,7 km². Najveći uzorci (100-486,7 km²) nalaze se u zavali Ličkog polja, Gackog polja te na fragmentima Unsko-Koranske krške zaravni i na prostoru Ogulinsko-Plašćanske zavale. Uzorci srednjih veličina (12-100 km²) nalaze se u sjevernom dijelu Ogulinsko-Plašćanske zavale, u nizovima zavalu Velike Kapele, na Kastavskoj zavali, u zavali Lapačkog polja te manjim zavalama u brdskom okviru Lapačkog polja te zavalama i zaravnima Ličkog sredogorja. U južnom dijelu GH dominiraju mali uzorci (0,000104-12 km²), a u ostatku prostora mali uzorci raštrkani su po dijelovima polja u kršu i zaravni koji su prekriveni šumom.




Sl. 6.5.26 Mezo tip krajobraza 1_1 – prostorna distribucija i karakteristike kompleksnih gradijenata krajobraza

Tip 1_1 bilježi velike vrijednosti frekvencije izgrađenosti prostora, veliku vrijednost obilja ponikava, te veliku vrijednost obilja rijetkih staništa. Ostali kompleksni gradijenti krajobraza zastupljeni su u srednjim vrijednostima tj. prisutni su, ali nisu dominantni.

MLT 1_2


Mezo tip 1_2 ne pojavljuje se u sjevernom dijelu prostora GH niti duž zapadnog ruba. Prisutan je u dnima velikih krških depresija u njihovim fluviokrškim dijelovima gdje se na relativno zaravnjenoj karbonatnoj podlozi razvilo površinsko tečenje, tj. vodotoci. Na krajnjem južnom djelu prostora GH ovaj tip zastupljen je u međugorskim zavalama i na fragmentima zaravni. Dominantna vegetacija su poljoprivredne površine i golo tlo. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.27. U ovom tipu krajobraza GH nalazi se 125 uzoraka, a prosječna veličina je 5,2 km². Najmanji uzorak veličine je 0,3 dok je najveći 45,3 km². Najveći uzorci u ovom tipu (20-45,3 km²) podjednako su zastupljeni u cijelom prostoru GH (osim na krajnjem sjeveru i zapadnom rubu gdje se ovaj tip krajobraza ne javlja). Veliki uzorci povezani su s prostorom Ogulinsko-Plaščanske zavale tj. njezinim najnižim dijelom gdje je razvijena hidrografska mreža na karbonatnoj podlozi. Na fragmentima Slunjske zaravni oko Rakovice i Drežnik Grada, u dijelovima Gackog polja, sjevernim dijelom Gračačkog polja te njegovog fluviokrškog okvira, Velikopopinskom polju te manjim zavalama južnije od njega. Najjužniji uzorci iz skupine velikih uzoraka tipa 1_2 nalaze se u fluviokrškim zavalama/udolinama podno Svilaje i Kozjaka. Uzorci srednjih površina (5,5-20 km²) ravnomjerno su zastupljeni u cijelom pojavnom prostoru ovoga tipa, a javlja se u dnima manjih polja u kršu (npr. Vrhovinsko i Turjansko polje), kao i skupina uzoraka malih površina (0,3-5,5 km²) koji se nalaze na fluviokrškim rubovima velikih polja, manjim udolinama i fragmentima zaravni na kojima je razvijena hidrografska mreža. Ovaj mezo tip krajobraza bilježi velike vrijednosti frekvencije poljoprivrednih površina, veliku vrijednost obilja ponikava, proluvijalnih plavina, obilja drenažne mreže te obilja rijetkih staništa. U ovom mezo tipu frekvencija izgrađenosti prostora, obilje hidrogeoloških pojava te obilje kanjona ili strmih strana bilježe osrednju zastupljenost. Speleološki objekti i grebeni u ovom tipu nisu uopće zastupljeni.



Sl. 6.5.27 Mezo tip krajobraza 1_2 – prostorna distribucija i karakteristike kompleksnih gradijenata krajobraza

MLT 1_3

Prostorna distribucija mezo tipa **1_3** vrlo je slična tipu 1_2 uz iznimku pojave uzoraka u zapadnu rubu prostora GH. Prostorna povezanost ova dva mezo tipa očituje se u dominantnom morfofenetskom tipu reljefa, a to je fluviokrš, dok je dominantan površinski pokrov u ovom mezo tipu šuma. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.28. U ovom tipu nalaze se 94 uzorka, također površinom sličnih karakteristika kao što je tip 1_2. Najmanji uzorak površine je 0,30 km², a najveći 45,87 km², slijedom čega je raspon površina 45,56 km². Srednja vrijednost površine uzorka iznosi 3,4 km². Najbrojnija je skupina malih uzoraka (0,3 – 3,4 km²) kojih čine 70% uzoraka ovog mezo tipa krajobraza. Nalaze se na šumovitim, fluviokrškim rubovima zavalu polja u kršu, manjih dijelova zaravni i udolina manjih dimenzija. Uzorci srednjih veličina (3,4-20 km²) prate pojavnost manjih uzoraka, ali se nalaze na rubovima većih polja, ili fragmenata zaravni i udolina. Prisutna su dva uzorka iz velike klase (20-45,87 km²), a oba se nalaze na prostoru Ogulinsko-Plašćanske zavale.




Sl. 6.5.28 Mezo tip krajobraza 1_3 – prostorna distribucija i karakteristike kompleksnih gradijenata krajobraza

Prema zastupljenosti kompleksnih krajobraznih gradijenata, obilje proluvijalnih plavina, obilje hidrogeoloških pojava te obilje drenažne mreže karakteristični su za ovaj mezo tip. Osrednje su zastupljena izgrađena područja, ponikve, grebeni, kanjoni ili strme strane te rijetka staništa. U ovom tipu gotovo uopće nisu zastupljene poljoprivredne površine i speleološki objekti.

MLT 1_4

Prostorna distribucija mezo tipa 1_4 je neravnomjerna, a najveća gustoća uzoraka je u središnjem dijelu prostora GH. Dominantni morfogogenetski tip reljefa je fluvijalni, a površinski pokrov šume i antropogene površine. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.29. U ovom tipu nalazi se 54 uzorka. Minimalna površina uzorka je 0,30 km², a uzorak najveće površine je 59,34 km². Srednja vrijednost površine uzorka iznosi 5,3 km². Najzastupljeniji po brojnosti su uzorci manjih površina (0,30-5,3 km²). Ova klasa uzoraka te klasa uzoraka srednje vrijednosti površine (5,3-20 km²) javlja

se u dnima manjih krških depresija, tj. manjih polja u kršu, primjerice Lug i Drežničko polje, te u dijelovima većih polja u kojima je razvijen fluvijalni morfogenetski tip reljefa. U klasi uzoraka velikih površina (20-59,04 km²) nalaze se četiri uzorka te su svi smješteni u zavali Ličkog polja, tj. u njegovim najnižim dijelovima u kojima je razvijen fluvijalni reljef.




Sl. 6.5.29 Mezo tip krajobraza 1_4 – prostorna distribucija i karakteristike kompleksnih gradijenata krajobraza

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristična je velika vrijednost frekvencije izgrađenosti prostora te frekvencije poljoprivrednih površina. Osrednje su zastupljene proluvijalne plavine, hidrogeološke pojave, drenažna mreža, kanjoni i strme strane te rijetka staništa, dok speleoloških objekata, ponikava i grebena gotovo i nema.

MLT 1_5

Prostorna distribucija mezo tipa 1_5 prati prostornu distribuciju mezo tipa 1_4. Prostorna povezanost ova dva mezo tipa očituje se u dominantnom morfogenetskom tipu reljefa, a to je fluvijalni. Ovaj mezo tip s jednim uzorkom se javlja i u južnom dijelu GH, dok je vrlo oskudno

zastupljen na krajnjem sjeveru. U ovom mezo tipu dominantan tip površinskog pokrova su poljoprivredne površine. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.30. U ovom tipu nalazi se 38 uzoraka, a svi se nalaze u dnima polja u kršu, a velik broj uzoraka poklapa se u potpunosti s cijelim dnima polja u kršu manjih ili osrednjih dimenzija. Minimalna površina uzorka iznosi 0,36 km², maksimalna 74,2 km², a srednja vrijednost iznosi 8,94 km². Brojem dominiraju uzorci malih površina (0,3-8,9 km²) koji čine 73,6% svih uzoraka ovog tipa te se često poklapaju s cjelovitim poljima u kršu (Lič, Stajničko, Dabar, Vrhovinsko, Krbavica, Podlapača). Dva površinom najveća uzorka ovog tipa (30-74,2 km²) nalaze se u južnom dijelu Gackog polja i cijelom dnu Krbavskog polja. Uzorci srednjih površina (8,9-30 km²) poklapaju se s dnima cijelih polja u kršu manjih dimenzija (Brinjsko, Plaško, Podlapača).




Sl. 6.5.30 Mezo tip krajobraza 1_5 – prostorna distribucija i karakteristike kompleksnih gradijenata krajobraza

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristična je velika vrijednost frekvencije poljoprivrednih površina, ali i velika vrijednost obilja rijetkih staništa. Osrednje su zastupljene izgrađene površine, ponikve, proluvijalne

plavine, hidrogeološke pojave, drenažna mreža te kanjoni i strme strane. U ovom mezo tipu nisu zastupljeni ili su vrlo malo zastupljeni speleološki objekti te grebeni.

MLT 2_1

Mezo tip krajobraza **2_1** široko je rasprostranjen po cijelom prostoru GH, osim na zapadnom rubu duž Velebita. Dominantni morfogenetski tip reljefa je krš dok je prevladavajući površinski pokrov šuma. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.31. U ovom tipu krajobraza nalazi se 269 uzoraka. Minimalna površina uzorka iznosi 0,29 km², a maksimalna 435,06 km². Srednja vrijednost površine uzorka u ovom tipu iznosi 8,19 km². Distribucija vrijednosti površine uzoraka je vrlo varijabilna, na što ukazuje i vrijednost standardne devijacije koja iznosi 32,5. Po brojnosti se izdvajaju uzorci manjih površina (0,29-8 km²), koji se rasprostiru na 84% površine koju zauzima mezo tip 2_1. Na krajnjem sjeveru i krajnjem jugu GH dominiraju uzorci malih površina te uzorci srednjih površina (8-120 km²). Uzorci srednjih površina i velikih (120-435 km²) rasprostiru se središnjim dijelom GH. Najveći uzorci ovoga mezo tipa rasprostiru se duž Velike Kapele, Male Kapele te Ličkog sredogorja. Uzorci srednjih površina u središnjem dijelu GH zastupljeni su na dolinskim stranama većih masiva i hrptova ili na gorskim rubovima polja u kršu.




Sl. 6.5.31 Mezo tip krajobraza 2_1 – prostorna distribucija i karakteristike kompleksnih gradijenata krajobraza

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristična je velika vrijednost frekvencije izgrađenosti prostora, obilja ponikava te grebena. Osrednje su zastupljene poljoprivredne površine, speleološki objekti, hidrogeološke pojave, drenažna mreža, kanjoni i strme strane te rijetka staništa. Nisu zastupljene ili su neznatno zastupljene proluvijalne plavine.

MLT 2_2

Prostorna distribucija mezo tipa 2_2 prati prostornu distribuciju mezo tipa 2_1. Prostorna povezanost ova dva mezo tipa očituje se u dominantnom površinskom pokrovu, a to su šume. U mezo tipu 2_2 dominantan morfogenetski tip reljefa je fluviokrš. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.32. Najveća gustoća uzoraka jest na području Pokupskih pobrđa, Male Kapele, Ličkog sredogorja, te na pristrancima i dolinskim stranama Plješevice. U ovom mezo tipu nalazi se 136 uzoraka. Minimalna

vrijednost površine uzorka je 0,30 km², a maksimalna 108,22 km². Srednja vrijednost površine iznosi 4,5 km², Ovim tipom brojčano dominiraju uzorci malih površina, koji zauzimaju 76,4% površine ovog mezo tipa.




Sl. 6.5.32 Mezo tip krajobraza 2_2 – prostorna distribucija i karakteristike kompleksnih gradijenata krajobraza

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristična je velika vrijednost obilja proluvijalnih plavina, hidrogeoloških pojava te obilja drenažne mreže. Osrednje su zastupljene izgrađene površine, poljoprivredne površine, grebeni, kanjoni i strme strane te rijetka staništa. Nisu zastupljeni ili su neznatno zastupljeni speleološki objekti i ponikve.

MLT 2_3

Mezo tip krajobraza 2_3 rasprostranjen je marginalno u izoliranim skupinama uzoraka. Gotovo ga i nema u središnjem i zapadnom dijelu prostora. Grupiran je uz istočni, jugoistočni, južni i

jugozapadni dio GH. Dominantni morfogenetski tip reljefa u ovom mezo tipu je krš, a dominantan površinski pokrov su izdanci stijena i travnjaci. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.33. U ovom tipu nalazi se 87 uzoraka. Minimalna površina uzorka iznosi 0,29, a maksimalna 32,66 km². Srednja vrijednost površine uzorka iznosi 1,89 km². U ovom mezo tipu generalno prevladavaju uzorci malih površina, odnosu na prethodno opisane mezo tipove krajobraza. Jasna je prostorna dominacija uzoraka većih (10-32,6 km²) i srednjih površina (1,89-10 km²) na krajnjem jugu GH. Ovaj mezo tip većinom je smješten na nižim pristrancima većih masiva ili hrptova (Velika Kapela, JZ Velebit, Dinara, Kamešnica, Svilaja).




Sl. 6.5.33 Mezo tip krajobraza 2_3 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje rijetkih staništa. Osrednja je zastupljenost poljoprivrednih površina, proluvijalnih plavina, hidrogeoloških pojava, drenažne mreže, grebena, kanjona i strmih strana. Nisu zastupljeni ili su neznatno zastupljena izgrađena područja, speleološki objekti i ponikve.

MLT 2_4

Prostorna distribucija mezo tipa 2_4 prati prostornu distribuciju mezo tipa 2_3. Prostorna povezanost ova dva mezo tipa očituje se u dominantnom površinskom pokrovu, a to su izdanci stijena. U mezo tipu 2_4 dominantan morfogenetski tip reljefa je fluviokrš. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.34. U ovom tipu krajobraza nalazi se 64 uzorka. Minimalna površina uzorka iznosi 0,29 km², a maksimalna 19,73 km². Srednja vrijednost površine uzoraka iznosi 1,7 km². U ovom tipu dominiraju uzorci malih površina, što se očituje i u srednjoj vrijednosti površine uzoraka. Uzorci su grupirani u jugoistočnom i južnom dijelu prostora GH na pristrancima pobrđa Kokirne, pristrancima oko gornje Zrmanje te fluviokrškim dolinskim stranama Dinare i Svilaje. Manji broj uzoraka smješten je i na fluviokrškim dolinskim stranama primorske strane hrptova Velike Kapele te u dijelu Pokupskog pobrđa kod Ravne Gore i Delnica. U središnjem dijelu GH ovaj tip mezo krajobraza javlja se na pristrancima Vrhovinskog polja.




Sl. 6.5.34 Mezo tip krajobraza 2_4 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje hidrogeoloških pojava te rijetkih staništa. Osrednje su zastupljena izgrađena područja, poljoprivredne površine, drenažna mreža, grebeni te kanjoni i strme strane. Speleološki objekti, ponikve i proluvijalne plavine nisu ili gotovo uopće nisu zastupljene.

MLT 2_5

Uzorci mezo tipa 2_5 prisutni su samo u južnom dijelu prostora GH (južno od masiva Poštaka), a u ostalim dijelovima GH se uopće ne pojavljuje. U mezo tipu 2_5 dominantan morfogenetski tip reljefa je glaciokrš, a dominantan površinski pokrov je oskudna vegetacija. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.35. U ovom tipu krajobraza nalazi se 21 uzorak. Veličina uzoraka vrlo je ujednačena. Minimalna površina uzorka iznosi 0,39 km², a maksimalna površina 10,31 km². Srednja vrijednost površine uzorka iznosi 2,79 km². Ovaj mezo tip javlja se na dolinskim stranama i nižim pristrancima Svilaje, Dinare i Kamešnice.




Sl. 6.5.35 Mezo tip krajobraza 2_5 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je da nema izraženih krajobraznih gradijenata s velikom zastupljenošću. Osrednje su zastupljeni drenažna mreža, grebeni, kanjoni i strme strane te rijetka staništa. Izgrađeni prostori, poljoprivredne površine, speleološki objekti, ponikve, plavine te hidrogeološke pojave nisu zastupljene ili su neznatno zastupljene.

MLT 3_1

Mezo tip krajobraza **3_1** neravnomjerno je rasprostranjen. Nije zastupljen na sjeverozapadnom rubu niti u središnjem dijelu, a oskudno se javlja u krajnjem južnom i krajnjem sjevernom dijelu prostora. Dominantni morfogenetski tip reljefa u ovom mezo tipu je krš, a dominantan površinski pokrov su šume. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.36. U ovom mezo tipu nalazi se 206 uzoraka. Minimalna površina uzorka iznosi 0,29 km², a maksimalna iznosi 72,44 km². Srednja vrijednost površine uzorka iznosi 8,08 km². Najbrojniji su uzorci malih površina (0,29-5 km²) koji se javljaju na izraženim hrptovima gorskih skupina i na rubnim nizovima hrptova (Pokupski niz gorskih skupina, rubni nizovi hrptova Velike Kapele, Mala Kapela, Ličko sredogorje, Plješivica, Svilaja, Dinara, Kamešnica). Uzorci srednjih površina 5-30 km² javljaju se na gorskim masivima, hrptovima i skupinama (Risnjak, Velika Kapela, Plješivica, Senjsko bilo, Velebit, Crnopac, Poštak, Dinara, Svilaja. Od ukupno četiri uzorka velike površine (30-72,74 km²), tri se nalaze na gorskoj skupini Velika Kapela, a jedan na sjevernom Velebitu.




Sl. 6.5.36 Mezo tip krajobraza 3_1 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje speleoloških objekata i grebena. Osrednje su zastupljene ponikve, proluvijalne plavine, hidrogeološke pojave, drenažna mreža, kanjoni i strme strane te rijetka staništa. U ovom mezo tipu nisu zastupljena ili su neznatno zastupljena izgrađena područja i poljoprivredne površine.

MLT 3_2

Mezo tip krajobraza **3_2** neravnomjerno je rasprostranjen, te prati prostornu distribuciju mezo tipa 3_1. Veza između ova dva mezo tipa očituje se u istom dominantnom površinskom pokrovu, a to su šume. U mezo tipu 3_2 prevladavajući morfogenetski tip reljefa je glaciokrš. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.37. U ovom tipu nalazi se 47 uzoraka. Minimalna površina uzorka iznosi 0,29 km², a maksimalna iznosi 210,99 km². Srednja vrijednost površine uzorka iznosi 16,6 km². Brojem,

prevladavaju uzorci malih površina (0,29-16 km²), te čine 76,5% uzoraka ovoga mezo tipa krajobraza. Prostorno, najgušće su raspoređeni na jugu prostora GH (južno od Plješivice) na manjim hrptovima Plješevica, Poštaka, Dinare, Kamešnice i Svilaje. Takvi manji uzorci javljaju se i na hrptovima Male Kapele, Velike Kapele te rubnim hrptovima Velebita i Senjskog bila. Uzorci srednjih (16-90 km²) površina javljaju se na raščlanjenim hrptovima Velike Kapele, Senjskog bila, južnog Velebita i Plješivice. Uzorci velikih površina (90-210,99 km²) dominiraju krajnjim sjeverom prostora GH (Obruč, Risnjak, Snježnik), te sjevernim, srednjim i južnim dijelom Velebita.




Sl. 6.5.37 Mezo tip krajobraza 3_2 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje speleoloških objekata, hidrogeoloških pojava te grebena. Osrednje su zastupljene ponikve, drenažna mreža, kanjoni i strme padine te rijetka staništa. Izgrađena područja, poljoprivredne površine te proluvijalne plavine nisu zastupljene ili su neznatno zastupljene u ovom mezo tipu krajobraza.

MLT 3_3

Mezo tip krajobraza 3_3 rasprostranjen je duž izraženih masiva, gorskih skupina i hrptova, na sjeveru, istočnom i zapadnom rubu te u južnom dijelu prostora GH. U središnjem prostoru GH ovaj mezo tip krajobraza nije prisutan. Dominantni morfogenetski tipovi reljefa u ovom mezo tipu su fluviodenudacijski i fluviokrš, a dominantan površinski pokrov je šuma. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.38. U ovom mezo tipu krajobraza nalazi se 122 uzorka. Minimalna površina uzorka iznosi 0,30 km², a maksimalna površina iznosi 30,87 km². Srednja vrijednost površine uzorka iznosi 2,9 km². Brojem prevladavaju uzorci malih površina (0,3-3 km²) te čine 79,7% broja uzoraka ovoga tipa. Prostorno, uzorci ovog tipa pojavljuju se u skupinama na prostoru Pokupskog niza gorskih skupina, na gorskim stranama Velebita, Velike i Male Kapele, Plješivice, Poštaka, Dinare, Kamešnice i Svilaje.




Sl. 6.5.38 Mezo tip krajobraza 3_3 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje speleoloških objekata i grebena. osrednje su zastupljene proluvijalne plavine, hidrogeološke pojave, drenažna mreža, kanjoni i strme strane te rijetka staništa. Izgrađena područja, poljoprivredne površine i ponikve nisu zastupljeni ili su neznatno zastupljeni.

MLT 3_4

Mezo tip krajobraza **3_4** prati prostornu distribuciju mezo tipa 3_2, a povezuje ih zajednički dominantni morfogenetski tip reljefa, glaciokrš. U mezo tipu 3_4 dominantan površinski pokrov čine travnjaci i izdanci stijena. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.39. Ovaj mezo tip najveće je gustoće uzoraka duž južnog i jugoistočnog Velebita, Plješivice, Poštaka, Dinare, Kamešnice i Svilaje. U ovom mezo tipu nalazi se 77 uzoraka. Minimalna površina uzorka iznosi 0,29 km², a maksimalna površina iznosi 42,95 km². Srednja vrijednost površine uzorka iznosi 3,09 km². Brojem, dominiraju uzorci malih površina (0,29-3 km²), koji čine 81 % svih uzoraka ovoga mezo tipa. S malim brojem uzoraka javlja se na prostoru sjevernog Velebita i Senjskog bila, te Obruča i Snježnika. Uzorci malih površina dominiraju sjevernim i istočnim rubom prostora GH, dok su uzorci srednjih i većih površina koncentrirani u južnom dijelu. Idući od sjevera prema jugu, jasno se povećava površina uzoraka ovoga mezo tipa.




Sl. 6.5.39 Mezo tip krajobraza 3_4 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje speleoloških objekata, grebena i rijetkih staništa. Osrednje su zastupljeni kompleksni krajobrazni gradijenti frekvencije poljoprivrednih površina, obilja hidrogeoloških pojava, drenažne mreže te obilja kanjona i strmih strana. Izgrađene površine, ponikve i proluvijalne plavine nisu ili su neznatno zastupljene u ovom mezo tipu krajobraza.

MLT 3_5

Mezo tip krajobraza **3_5** rasprostranjen je gotovo samo u južnom dijelu prostora GH. Izolirani uzorci ovog tipa javljaju se još i na Velebitu, tj. zapadnom rubu prostora GH. Dominantni morfogenetski tipovi reljefa u ovom mezo tipu su fluviokrš i glaciokrš, a dominantne klase površinskog pokrova su golo tlo i oskudna vegetacija. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.40. U ovom mezo tipu nalazi se 32 uzorka. Minimalna površina uzorka iznosi 0,29 km², a maksimalna površina uzorka iznosi

6,43 km². Srednja vrijednost površine uzorka iznosi 1,4 km², a standardna devijacija 1,38 km². Sve statističke veličine ukazuju na vrlo malu varijabilnost površine uzoraka u ovom mezo tipu.




Sl. 6.5.40 Mezo tip krajobraza 3_5 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza nema izraženih gradijenata koji su vrlo zastupljeni. Osrednje su zastupljene poljoprivredne površine, hidrogeološke pojave, drenažna mreža, grebeni, kanjoni i strme padine te rijetka staništa. Izgrađena područja, speleološki objekti, ponikve i proluvijalne plavine nisu zastupljeni ili su neznatno zastupljeni kompleksni krajobrazni gradijenti u ovome mezo tipu krajobraza.

MLT 4_1

Mezo tip krajobraza **4_1** rasprostranjen je u gotovo čitavom prostoru GH, izuzev fragmenta Unsko-Koranske zaravni, zavale Ličkog polja, i fragmenta Centralnodalmatinske zaravni. Dominantan morfogenetski tip reljefa je fluviokrš, a dominantna klasa površinskog uzorka

šuma. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.41. U ovom mezo tipu nalazi se 278 uzoraka. Minimalna površina uzorka iznosi 0,0001 km², a maksimalna površina iznosi 124,26 km². Srednja vrijednost površine uzorka iznosi 2,8 km². Brojem dominiraju uzorci malih površina (0,0001-3 km²) koji čine 81,6% od ukupnog broja uzoraka u ovom mezo tipu. Uzorci velikih površina (30-124,26 km²) javljaju se na sjevernom hrptu Velebita i Senjskom bilu te duž JI Plješivice i masiva Poštaka. Uzorci su generalno smješteni na strmim dolinskim stranama kontakata krških depresija i masiva i hrptova, te na pedimentima i glacis terasama.




Sl. 6.5.41 Mezo tip krajobraza 4_1 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje proluvijalnih plavina, hidrogeoloških pojava, drenažne mreže, kanjona i strmih strana. Svi ostali kompleksni krajobrazni gradijenti, osrednje su zastupljeni u ovome mezo tipu.

MLT 4_2

Mezo tip krajobraza **4_2** rasprostranjen je u cijelom prostoru GH izuzev fragmenata Unsko-Koranske zaravni i Centralnodalmatinske zaravni te zavale Ličkog polja. Uzorci su neravnomjerno rasprostranjeni. Dominantan morfogenetski tip reljefa je krš, a dominantna klasa površinskog pokrova je šuma. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.42. U ovome mezo tipu nalazi se 184 uzorak. Minimalna površina uzorka iznosi 0,29 km², a maksimalna iznosi 35,18 km². Srednja vrijednost površine uzorka iznosi 2,61 km². Brojem dominiraju uzorci malih površina (0,29-3 km²), koji čine 79,3% svih uzoraka ovoga mezo tipa. Kao i kod mezo tipa 4_1, ovaj tip također se prostire na dolinskim stranama i strmim padinama na kontaktima masiva ili hrptova i krških depresija. Najveća gustoća uzoraka primjerna je na prostoru Velike Kapele i Velebita, a manja jezgra koncentracije nalazi se na prostoru gorske skupine Plješivice. Izolirano se javljaju uzorci ovoga tipa na padinama Dinare i Svilaje te Male Kapele.




Sl. 6.5.42 Mezo tip krajobraza 4_2 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje hidrogeoloških pojava te kanjona i strmih strana. Osrednje su zastupljeni kompleksni krajobrazni gradijenti frekvencije poljoprivrednih površina, obilja speleoloških objekata, ponikava, drenaže mreže i rijetkih staništa. Frekvencija izgrađenosti prostora je neznatna, kao i obilje proluvijalnih plavina koje su neznatno ili uopće nisu zastupljene u ovome mezo tipu.

MLT 4_3

Mezo tip krajobraza 4_3 u prostoru je rasprostranjen u nekoliko skupina uzoraka koji su izolirani jedni od drugih. Tako se izdvaja ovaj tip na samom sjeveru, zapadu te pojava izoliranih uzoraka na jugoistočnom rubu i na jugu. Dominantni morfogenetski tipovi reljefa su fluvijalni i fluviodenudacijski, a dominantna klasa površinskog pokrova je šuma. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.43. U ovome mezo tipu nalazi se 39 uzoraka. Minimalna površina uzorka iznosi 0,32 km², a maksimalna površina iznosi 98,4 km². Srednja vrijednost površine uzorka iznosi 7,03 km². Raspon površina i standardna devijacija površine ukazuju na veliku varijabilnost u površinama uzoraka. Brojem dominiraju uzorci malih površina (0,32-5 km²) koji čine 76,9% od ukupnog broja uzoraka u ovome mezo tipu. Prostorno, mali uzorci nalaze se na nižim pristrancima i strmim stranama manjih drenažnih bazena (drenažnih bazena jaruga) ili endoreičkih drenažnih bazena manjih polja u kršu, s dominantno šumom, primjerice niži pristranci okvira Jasenačkog polja. Uzorci srednjih površina (5-30 km²) javljaju se na kontaktima nižih pristranaka većih konveksnih orografskih cjelina i većih krških depresija, poglavito polja u kršu. Takvi su uzorci primjerice na kontaktu pristranaka Velebita s zavalom Ličkog polja. Dominantan je fluviodenudacijski reljef, tj. drenažni bazeni jaruga. Najveći uzorak nalazi se u dolini Kupe i na prostoru Pokupskog pobrđa na sjeveroistoku GH gdje je dominantan fluviodenudacijski i fluvijalni morfogenetski tip reljefa, a površinskim pokrovom dominira šuma.




Sl. 6.5.43 Mezo tip krajobraza 4_3 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje proluvijalnih plavina, hidrogeoloških pojava, drenažne mreže te kanjona i strmih strana. Osrednje su zastupljeni kompleksni krajobrazni gradijenti obilja speleoloških objekata, grebena i rijetkih staništa. Frekvencija izgrađenosti prostora i poljoprivrednih površina te obilje ponikava nisu zastupljeni ili su neznatno zastupljeni.

MLT 4_4

Mezo tip krajobraza 4_4 rasprostranjen je na sjeveru, zapadu i jugu prostora GH. Dominantni morfogenetski tipovi reljefa su fluviodenudacijski i fluviokrš, a dominantna klasa površinskog pokrova je šuma. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.44. U ovom mezo tipu nalazi se 66 uzoraka. Minimalna površina uzorka iznosi 0,29 km², a maksimalna površina iznosi 24,66 km². Srednja vrijednost površine uzorka iznosi 2,2 km². Prema statističkim pokazateljima, u ovome tipu prevladavaju uzorci malih i

srednjih površina. Brojem dominiraju uzorci malih površina (0,29-5 km²) koji čine 93,9% svih uzoraka u ovome mezo tipu. Prostorno, na sjevernom dijelu GH javljaju se pojedinačni uzorci malih površina, a nalaze se na pristrancima krških depresija (Lič polje, Gerovo, Jasenačko) ili u gornjim tokovima malih drenažnih bazena (Vitunjčica). Mali uzorci ovoga mezo tipa javljaju se i na strmim stranama Kosinjskog polja te duž primorske strane sjevernog i srednjeg Velebita. Mali uzorci prisutni su i na strmim pristrancima gornje Une te na pristrancima JI Plješivice koji se spuštaju prema rubu Gračačkog polja. Veća gustoća, a i pojava većih uzoraka ovoga mezo tipa krajobraza primjetna je južno od masiva Poštaka, na strmim stranama Dinare, Kamešnice i Svilaje na kontaktu s Cetinskim poljem. Površinom veliki uzorci (5-24,66 km²) prisutni su i s primorske strane srednjeg i južnog Velebita.




Sl. 6.5.44 Mezo tip krajobraza 4_4 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje proluvijalnih plavina, drenažne mreže te kanjona i strmih strana. Osrednje su zastupljeni kompleksni krajobrazni gradijenti frekvencije poljoprivrednih

površina, hidrogeoloških pojava i rijetkih staništa. Frekvencija izgrađenosti prostora, obilje speleoloških objekata, ponikava te grebena nisu zastupljeni ili su neznatno zastupljeni.

MLT 4_5

Mezo tip krajobraza 4_5 na prostoru GH pojavljuje se neravnomjerno. Prisutan je s malim brojem izoliranih uzoraka na sjeveru i istoku, dok je nešto izraženija gustoća uzoraka na jugoistoku i jugu. U ovome mezo tipu dominantan morfogenetski tip reljefa je krš, a dominantna klasa površinskog pokrova izdanci stijena. Prostorna distribucija i zastupljenost kompleksnih krajobraznih gradijenata prikazana je na Sl. 6.5.45. U ovome mezo tipu nalazi se 48 uzoraka. Minimalna površina uzorka iznosi 0,33 km², a maksimalna površina iznosi 22,24 km². Srednja vrijednost površine uzorka iznosi 1,76 km². U ovome mezo tipu prevladavaju uzorci malih površina (0,33-5 km²), koji čine 93,7% svih uzoraka ovoga tipa. Veći uzorci (5-22,24 km²) prisutni su na primorskoj padini južnog Velebita i na nižim pristrancima Dinare, podno samog vrha Dinara.




Sl. 6.5.45 Mezo tip krajobraza 4_5 – prostorna distribucija i karakteristike kompleksnih gradijenata

Prema zastupljenosti kompleksnih krajobraznih gradijenata, za ovaj mezo tip krajobraza karakteristično je obilje hidrogeoloških pojava te kanjona i strmih strana. Osrednje su zastupljeni kompleksni krajobrazni gradijenti frekvencije poljoprivrednih površina, obilja speleoloških objekata, ponikava, drenažne mreže, grebena i rijetkih staništa. Frekvencija izgrađenosti prostora i obilje proluvijalnih plavina nisu ili su neznatno zastupljeni u ovom mezo tipu krajobraza.

6.6. Metrika krajobraza GH

Razina uzorka

Na prostoru GH evidentirano je 2786 uzoraka mezo tipova krajobraza, od kojih većina pripada tipu MLT 2_1 (21,05 %) i tipu MLT 1_1 (17,19 %). Najmanji uzorci povezani su s prostornom rezolucijom klasifikacije, tako da u svakoj klasi najmanji uzorci su veličine 10 x 10 m, dok je najveći uzorak zabilježen u tipu MLT 2_1 (Pobrđa i niži pristranci dolinskih strana u kršu sa šumom) površine 511,9267 km². Promatrajući uzorke veće od 100 km² te njihovu pojavnost u mezo tipovima krajobraza, kao što je spomenuto, najveći uzorak nalazi se u tipu MLT 2_1, te se u njemu nalazi ukupno 4 uzorka veća od 100 km². U mezo tipu MLT 1_1 (Udoline, fragmenti zaravni i krške depresije većih dimenzija u kršu sa šumom) također se nalaze dva uzorka veća od 100 km². U mezo tipu MLT 3_2 (Planinski lanci i masivi, izraženi hrptovi u glaciokršu sa šumom) nalaze se 2 uzorka veća od 100 km², a u mezo tipovima MLT 4_1 (Niži pristranci i strme dolinske strane fluviokršu sa šumom) i MLT 2_2 (1 (Pobrđa i niži pristranci dolinskih strana u fluviokršu sa šumom) po jedan uzorak. Na Sl. 6.6.1. prikazani su rasponi vrijednosti za sve uzorke pojedinih mezo tipova krajobraza s izraženom srednjom vrijednošću. Najveći raspon različitih površina uzoraka izražen je u tipu MLT 1_5. Uzorci najmanjih površina i mezo tip s najmanjim rasponom veličina površina uzoraka je MLT 4_5. Upravo ovaj mezo tip se izdvaja i po drugim pokazateljima.




Sl. 6.6.1 Rasponi vrijednosti s izraženim srednjim vrijednostima pokazatelja metrike krajobraza na razini uzorka za sve mezo tipove krajobraza GH

Razina klase

Metrika na razini klase, promatrajući pokazatelje površine konkordantna je s pokazateljima na razini uzoraka. Metrika krajobraza na razini klase – pokazatelji ruba i površine navedeni su u

Tab. 6.6.1. Mezo tip MLT 2_1 dominira u ukupnoj površini koju zauzima. Prema pokazateljima na razini uzorka, u ovom tipu nalaze se i najveći uzorci na prostoru GH. Sljedeći tip koji ima najveću površinu je MLT 1_1, koji također prema metrici na razini uzorka sadrži velike uzorke (veći od 100 km²). Po površini koju zauzimaju, izdvaja se i mezo tip MLT 3_2. Uz pokazatelj CA i prema pokazateljima AREA_MN i AREA_AM izdvajaju se spomenuta tri mezo tipa krajobraza. Pokazatelj PLAND govori o dominaciji ili rijetkosti određenog tipa krajobraza. Kao i u slučaju površine klase, dominira tip MLT 2_1, a nakon njega tu je MLT 1_1. Ukupno zauzimaju 38.24% prostora GH. Najrjeđi mezo tipovi krajobraza su MLT 3_5, MLT 2_5 i MLT 4_5. Prema pokazatelju LPI opet se izdvajaju MLT 2_1, MLT 1_1, i MLT 3_2. Promatrajući odnos CA i NP (Sl. 6.6.2), neki mezo tipovi izdvajaju se po tome što imaju ukupno veliku površinu, no ta je površina rezultat velikog broja uzoraka (MLT 2_1). Neke klase zauzimaju veliku površinu prostora GH, ali je manji broj uzoraka, tj. uzorci su generalno većih površina (MLT 1_1), te su prisutne klase koje zauzimaju malu ukupnu površinu i imaju velik broj uzoraka (MLT 4_1 i MLT 4_2).



Sl. 6.6.2 Metrika na razini klasa – odnos pokazatelja CA (eng. *class area*) i NP (eng. *number of patches*)

Radius tromosti (GYRATE) konkordantan je s ostalim pokazateljima ruba i površine, te se i u njemu izdvajaju tipovi MLT 2_1, MLT 1_1, MLT 3_2, MLT 4_3 i MLT 4_1.

Tab. 6.6.1 Metrika krajobraza na razini klasa – pokazatelji ruba i površine, MN-srednja vrijednost, AM_vrijednost ponderirana po površini, MD_medijalna vrijednost, RA_raspon vrijednosti, SD_standardna devijacija, CV_koeficijent varijacije

Mezo tip krajobraza	CA	PLAND	NP	PD	LPI	TE	ED	LSI	AREA_MN	AREA_AM
MLT1_1	180103.27	17.1969	207	0.0198	4.6472	3591710	3.4295	22.6944	870.0641	23513.6542
MLT1_2	52843.39	5.0457	172	0.0164	0.433	1440800	1.3757	17.5692	307.229	1799.8605
MLT1_3	32586.53	3.1115	122	0.0116	0.438	974490	0.9305	15.1867	267.1027	1338.0175
MLT1_4	28889.72	2.7585	76	0.0073	0.5667	745500	0.7118	11.2247	380.1279	2838.6109
MLT1_5	33984.16	3.2449	45	0.0043	0.7092	738300	0.705	10.0122	755.2036	2962.0225
MLT2_1	220466.28	21.0509	367	0.035	4.888	5575350	5.3235	30.0075	600.7256	17233.0845
MLT2_2	61285.03	5.8517	218	0.0208	1.0885	1942480	1.8547	19.9873	281.124	3223.0054
MLT2_3	16484.87	1.574	106	0.0101	0.3118	665910	0.6358	13.3512	155.5176	954.5981
MLT2_4	10947.99	1.0454	72	0.0069	0.1884	489750	0.4676	11.7754	152.0554	635.6789
MLT2_5	5878.3	0.5613	25	0.0024	0.1649	217090	0.2073	7.1838	235.132	844.9298
MLT3_1	83474.09	7.9704	244	0.0233	0.6945	2819040	2.6917	24.526	342.1069	2030.3857
MLT3_2	78043.05	7.4518	68	0.0065	2.0147	1240660	1.1846	11.352	1147.6919	12793.8163
MLT3_3	36252.55	3.4615	153	0.0146	0.2948	1380570	1.3182	18.4148	236.9448	915.5966
MLT3_4	23851.7	2.2774	106	0.0101	0.4101	721550	0.689	12.4665	225.016	1780.933
MLT3_5	4488.69	0.4286	40	0.0038	0.0614	247350	0.2362	9.2664	112.2173	272.7849
MLT4_1	79171.4	7.5595	339	0.0324	1.1866	2905840	2.7746	28.5959	233.544	3176.9399
MLT4_2	48116.52	4.5943	225	0.0215	0.342	1849170	1.7656	21.8359	213.8512	903.6011
MLT4_3	27418.76	2.618	47	0.0045	0.9429	691510	0.6603	11.734	583.3779	4769.2025
MLT4_4	14534.82	1.3878	84	0.008	0.2359	574880	0.5489	15.0949	173.0336	836.9581
MLT4_5	8482.19	0.8099	70	0.0067	0.2124	371610	0.3548	10.6547	121.1741	796.5283
Mezo tip krajobraza	AREA_MD	AREA_RA	AREA_SD	AREA_CV	GYRATE_MN	GYRATE_AM	GYRATE_MD	GYRATE_RA	GYRATE_SD	GYRATE_CV
MLT1_1	65.19	48670.53	4438.6231	510.149	753.4518	7949.5211	389.7724	12474.8693	1537.4082	204.0486
MLT1_2	70.93	4534.54	677.1851	220.4171	594.1213	2277.1946	375.5318	4981.6585	795.5904	133.9104
MLT1_3	84.595	4586.97	534.831	200.2342	583.2254	1677.7546	402.0159	3767.4306	633.0164	108.5372
MLT1_4	78.235	5935.13	966.715	254.3131	632.8658	3049.9788	348.1235	5865.1176	989.8401	156.406
MLT1_5	339.83	7427.12	1290.9677	170.943	1031.0012	2511.2777	791.7243	4324.3314	972.1935	94.2961
MLT2_1	66.34	51192.66	3160.9307	526.1855	680.7324	6788.9735	358.7904	16043.692	1270.4043	186.6232
MLT2_2	59.725	11399.91	909.4138	323.4921	528.3524	2624.8705	330.3012	6520.6578	750.2846	142.0046
MLT2_3	65.505	3265.89	352.5211	226.6759	461.3919	1242.3704	392.3412	2770.3509	402.1619	87.1628
MLT2_4	72.7	1973.47	271.1781	178.3416	464.8821	1120.5231	379.163	2504.1781	400.3869	86.1265
MLT2_5	90.37	1727.03	378.6594	161.0412	602.8968	1586.3116	414.2546	3017.0686	632.2758	104.873
MLT3_1	97.4	7273.8	759.9815	222.1474	696.7166	2203.5778	476.3276	6076.6923	752.2141	107.9656
MLT3_2	54.71	21099.7	3655.9763	318.5503	864.4587	5489.1836	328.4435	7397.4288	1558.2217	180.254
MLT3_3	105.27	3087.42	401.0025	169.2388	613.3497	1533.3991	499.5744	3266.4568	619.8591	101.0613
MLT3_4	60.205	4295.01	591.6978	262.9581	477.6896	1917.9253	333.2169	4103.9345	620.2554	129.8449
MLT3_5	65.43	643.49	134.2329	119.6187	446.247	863.8795	388.804	1551.0089	371.223	83.1878
MLT4_1	56.42	12426.91	829.1033	355.0095	601.8608	3542.3706	394.8008	10655.5423	899.2794	149.4165
MLT4_2	92.27	3581.88	384.0623	179.5932	584.0203	1790.0788	429.0347	7071.2107	704.408	120.6136
MLT4_3	72.19	9874.52	1562.6636	267.8647	977.4812	4386.3473	451.4539	6895.6942	1411.5775	144.4097
MLT4_4	56.035	2470.49	338.9414	195.8818	596.4563	2267.5923	365.731	7506.0004	906.1784	151.927
MLT4_5	56.505	2224.75	286.069	236.0809	375.0219	1465.6396	329.2386	3546.2385	485.2878	129.4025

Promatrajući ukupno sve pokazatelje oblika na razini klasa mezo tipovi krajobraza GH su ujednačeni (Tab. 6.6.2). Promatrajući pokazatelj SHAPE_AM gdje su vrijednosti ponderirane po površini, po kompleksnijim oblicima izdvajaju se mezo tipovi MLT 1_1, MLT 2_1, MLT 3_2, MLT 4_3, MLT 4_1. Prema pokazatelju PARA_AM mezo tip MLT 3_5 i MLT 4_4 imaju oblikom najkompleksnije uzorke. Prema pokazatelju CONTIG_MN, svi mezo tipovi krajobraza bilježe vrijednosti iznad 0.5, što govori i osrednjoj ili dobroj povezanosti među uzorcima u tipovima. Izdvajaju se MLT 1_5, MLT 2_3, MLT 2_4, MLT 2_5, MLT 3_1 i MLT 3_5 s najvećom povezanošću s vrijednošću pokazatelja CONTIG_MN većom od 0.8. Pokazatelj PAFRAC mjera je kompleksnosti oblika uzoraka prema kojoj su svi mezo tipovi krajobraza na prostoru GH jednostavnih oblika. Varijacija vrijednosti pokazatelja PAFRAC je vrlo mala među mezo tipovima, no izdvajaju se neki mezo tipovi s nešto kompleksnijim uzorcima, a to su MLT 1_1, MLT 2_1, MLT 3_1, MLT 4_1 i MLT 4_4.

Tab. 6.6.2 Metrika krajobraza na razini klasa krajobraza – pokazatelji oblika, MN-srednja vrijednost, AM_vrijednost ponderirana po površini, MD_medijalna vrijednost, RA_raspon vrijednosti, SD_standardna devijacija, CV_koeficijent varijacije

Mezo tip krajobraza	SHAPE_MN	SHAPE_AM	SHAPE_MD	SHAPE_RA	SHAPE_SD	SHAPE_CV	FRAC_MN	FRAC_AM	FRAC_MD	FRAC_RA	
MLT1_1	1.737	5.3927	1.4817	8.2606	1	57.5736	1.0683	1.1656	1.0643	0.3417	
MLT1_2	1.6055	2.3784	1.5103	2.5657	0.5252	32.7152	1.0732	1.0984	1.0633	0.2552	
MLT1_3	1.5398	2.187	1.3831	2.5284	0.5122	33.2675	1.0574	1.091	1.0507	0.249	
MLT1_4	1.5009	2.5667	1.3333	3.0662	0.5514	36.7399	1.0587	1.1026	1.0463	0.2314	
MLT1_5	1.6448	2.1685	1.5546	2.2098	0.53	32.2208	1.0608	1.0888	1.0621	0.136	
MLT2_1	1.6319	5.1848	1.3636	8.4841	0.874	53.5578	1.0569	1.1584	1.0481	0.2694	
MLT2_2	1.603	2.8407	1.4052	3.9672	0.6327	39.4685	1.0709	1.1144	1.0679	0.293	
MLT2_3	1.5598	1.8386	1.4617	2.8636	0.4755	30.4879	1.0623	1.0756	1.0538	0.2898	
MLT2_4	1.5374	1.9637	1.4705	2.0382	0.4001	26.0224	1.0602	1.0827	1.0565	0.1324	
MLT2_5	1.5547	2.1126	1.3874	1.6731	0.5108	32.8519	1.0562	1.0903	1.0484	0.1486	
MLT3_1	1.7249	2.6513	1.6091	3.5627	0.6138	35.583	1.0707	1.1104	1.0683	0.2233	
MLT3_2	1.582	3.5935	1.3894	4.3386	0.7677	48.531	1.0553	1.1298	1.0485	0.1748	
MLT3_3	1.6226	2.2396	1.478	2.7904	0.5671	34.9469	1.0657	1.0961	1.0589	0.2683	
MLT3_4	1.4628	2.1549	1.3053	2.7637	0.4801	32.8173	1.0516	1.0886	1.0414	0.1926	
MLT3_5	1.5735	1.9026	1.5498	1.4744	0.3938	25.0274	1.0673	1.0849	1.0667	0.1926	
MLT4_1	1.7724	3.2384	1.6647	5.4354	0.7123	40.1857	1.0756	1.1268	1.076	0.2203	
MLT4_2	1.5912	2.2138	1.5	3.0877	0.4864	30.5707	1.0632	1.0947	1.0636	0.259	
MLT4_3	1.9058	3.5591	1.8009	4.2223	0.768	40.2972	1.0835	1.1377	1.0864	0.1984	
MLT4_4	1.7661	2.6767	1.6312	3.6975	0.6668	37.7554	1.0784	1.1173	1.0786	0.2118	
MLT4_5	1.4475	2.1728	1.3772	2.4375	0.4609	31.8451	1.0498	1.0914	1.0481	0.1481	
Mezo tip krajobraza	FRAC_SD	FRAC_CV	PARA_MN	PARA_AM	PARA_MD	PARA_RA	PARA_SD	PARA_CV	CIRCLE_MN	CIRCLE_AM	
MLT1_1	0.0565	5.2905	1208.0015	21.3911	74.8956	3988.1423	1726.2819	142.904	0.5172	0.7596	
MLT1_2	0.0563	5.2421	1097.8221	30.5745	70.6572	3983.8217	1674.8985	152.5656	0.5442	0.7083	
MLT1_3	0.0416	3.9311	955.6082	33.6575	64.2354	3983.9796	1547.2628	161.9139	0.5161	0.6926	
MLT1_4	0.0489	4.6189	1165.0258	26.4205	67.3224	3985.1105	1751.4779	150.3381	0.487	0.7299	
MLT1_5	0.0346	3.2631	709.3573	21.7248	37.9606	3990.4916	1363.6539	192.238	0.56	0.6915	
MLT2_1	0.0483	4.5675	1145.3375	25.564	70.793	3983.23	1714.7713	149.7176	0.469	0.7407	
MLT2_2	0.055	5.1345	1489.6104	32.3005	83.7587	3982.9382	1798.4234	120.7311	0.521	0.7156	
MLT2_3	0.0426	4.0111	661.8201	41.5969	71.3702	3982.9327	1302.2421	196.7668	0.5662	0.657	
MLT2_4	0.0338	3.1843	614.9692	45.0238	66.8835	3979.0532	1309.424	212.9252	0.5308	0.6334	
MLT2_5	0.0384	3.6378	765.3242	37.4938	58.6478	3974.8623	1434.3605	187.4187	0.523	0.7034	
MLT3_1	0.0427	3.9916	648.7626	33.9593	63.6337	3982.1326	1348.1403	207.8018	0.5882	0.7218	
MLT3_2	0.0468	4.4385	1304.4605	16.2564	71.5551	3989.8234	1808.998	138.6779	0.4643	0.7173	
MLT3_3	0.0502	4.7111	989.7651	38.6963	60.8569	3980.8968	1639.3444	165.6296	0.5417	0.7063	
MLT3_4	0.0412	3.9209	1106.5033	32.2904	74.6857	3987.1013	1651.955	149.2951	0.4786	0.6791	
MLT3_5	0.0412	3.8608	777.6858	55.3257	72.9853	3963.5501	1449.3498	186.367	0.5554	0.6978	
MLT4_1	0.0498	4.633	826.7567	40.6556	87.2815	3979.5015	1469.0473	177.688	0.5964	0.7894	
MLT4_2	0.0409	3.8505	825.0372	39.8267	65.4984	3980.2216	1492.8304	180.941	0.5403	0.7057	
MLT4_3	0.0476	4.3918	827.3587	28.3477	80.461	3982.0582	1483.9201	179.3563	0.6513	0.8464	
MLT4_4	0.0483	4.4829	901.8659	50.099	81.6521	3972.8409	1506.7614	167.0716	0.6149	0.7862	
MLT4_5	0.0418	3.982	1345.3072	46.2758	78.8553	3974.3518	1830.5072	136.0661	0.4248	0.6745	
Mezo tip krajobraza	CIRCLE_MD	CIRCLE_RA	CIRCLE_SD	CIRCLE_CV	CONTIG_MN	CONTIG_AM	CONTIG_MD	CONTIG_RA	CONTIG_SD	CONTIG_CV	PAFRAC
MLT1_1	0.618	0.9684	0.2963	57.3007	0.6946	0.9939	0.978	0.9967	0.4305	61.969	1.1419
MLT1_2	0.618	0.9491	0.2674	49.1407	0.7286	0.9913	0.9799	0.9954	0.4091	56.153	1.0894
MLT1_3	0.6057	0.906	0.2634	51.0285	0.7498	0.9903	0.9812	0.9953	0.3978	53.0545	1.1115
MLT1_4	0.5317	0.9062	0.2635	54.1046	0.7134	0.9925	0.981	0.9958	0.4266	59.7943	1.0933
MLT1_5	0.5926	0.8268	0.2233	39.8828	0.8113	0.9938	0.9887	0.9973	0.3573	44.0373	1.1198
MLT2_1	0.541	0.9021	0.288	61.4198	0.7085	0.9927	0.9795	0.9952	0.4316	60.9212	1.1379
MLT2_2	0.618	0.9534	0.2888	55.4215	0.6259	0.9908	0.976	0.9951	0.4441	70.9613	1.1138
MLT2_3	0.6136	0.9672	0.2342	41.3695	0.8244	0.9881	0.9796	0.9952	0.3379	40.9942	1.105
MLT2_4	0.5977	0.8722	0.2289	43.1207	0.8409	0.9872	0.9808	0.9941	0.3314	39.4061	1.1085
MLT2_5	0.6051	0.9047	0.2573	49.2029	0.8002	0.9892	0.9827	0.9929	0.3686	46.0689	1.1209
MLT3_1	0.6533	0.9422	0.2421	41.1486	0.8331	0.9903	0.9817	0.9949	0.3404	40.8588	1.1371
MLT3_2	0.5715	0.9311	0.3007	64.759	0.6736	0.9954	0.9799	0.9971	0.4486	66.5989	1.1223
MLT3_3	0.5964	0.9564	0.2857	52.7453	0.752	0.9889	0.9825	0.9945	0.4059	53.9717	1.1136
MLT3_4	0.5073	0.9261	0.2782	58.1377	0.7139	0.9908	0.9789	0.9963	0.4204	58.8829	1.1049
MLT3_5	0.6454	0.8531	0.2519	45.3623	0.8032	0.9842	0.9793	0.9892	0.3602	44.842	1.1045
MLT4_1	0.6813	0.9607	0.2818	47.2424	0.786	0.9884	0.975	0.9942	0.3725	47.3982	1.1496
MLT4_2	0.6118	0.9474	0.2618	48.4554	0.7881	0.9886	0.9812	0.9943	0.377	47.8434	1.1157
MLT4_3	0.7458	0.929	0.2735	41.9929	0.7893	0.9919	0.9766	0.9949	0.3719	47.1214	1.1551
MLT4_4	0.6809	0.9644	0.2688	43.7125	0.768	0.9858	0.9766	0.9923	0.3795	49.4162	1.1429
MLT4_5	0.5112	0.8823	0.3036	71.4672	0.6632	0.9867	0.9775	0.9926	0.4544	68.5185	1.1078

Prema pokazateljima agregacije/izolacije na razini klase (Tab. 6.6.3) vidljive su uočljive razlike u izolaciji uzoraka unutar pojedinih mezo tipova krajobraza. Pokazatelj ENN predstavlja srednju vrijednost udaljenosti u metrima između uzoraka u pojedinoj klasi tj. mezo tipu krajobraza GH. Najveću povezanost pokazuju mezo tipovi MLT 2_1, MLT 1_1, MLT 3_1, MLT 4_1. Najveću izolaciju među uzorcima iste klase pokazuju mezo tipovi MLT 2_5, i MLT 4_5. Ostali mezo tipovi bilježe podjednake vrijednosti izolacije uzoraka (ENN u rasponu od 1.000 do 3.000 m). Promatrajući nadređene makro tipove krajobraza, najveću izolaciju pokazuju makro tipovi krajobraza 2_ Pobrđa i niži pristranci dolinskih strana i 4_ Niži pristranci i strme dolinske strane.

Tab. 6.6.3 Metrika krajobraza na razini klasa krajobraza – pokazatelji agregacije/izolacije, MN-srednja vrijednost, AM_vrijednost ponderirana po površini, MD_medijalna vrijednost, RA_raspon vrijednosti, SD_standardna devijacija, CV_koeficijent varijacije

Mezo tip krajobraza	ENN_MN	ENN_AM	ENN_MD	ENN_RA	ENN_SD	ENN_CV
MLT1_1	811.7928	292.543	230	12595.926	1468.9655	180.9533
MLT1_2	1205.6325	842.6891	530.8478	9218.1005	1745.8232	144.8056
MLT1_3	1042.8979	896.8267	323.0137	11042.604	1801.2468	172.7156
MLT1_4	2634.9059	1542.8586	460.9772	32543.353	6566.8557	249.2254
MLT1_5	2833.4339	2654.8569	1188.4864	29348.062	4880.0236	172.23
MLT2_1	545.2015	238.9957	280	5157.5863	799.1482	146.5785
MLT2_2	955.8265	914.3066	64.0312	13091.742	1873.4439	196.0025
MLT2_3	2680.1767	1822.4548	1067.8446	22191.986	4332.1739	161.6376
MLT2_4	2872.4031	2491.6201	851.3316	31448.01	5398.3342	187.9379
MLT2_5	5003.387	1751.8216	427.2002	44746.423	11999.138	239.8203
MLT3_1	873.0719	612.4489	487.9549	7811.3473	1146.2684	131.2914
MLT3_2	1552.315	524.2234	261.725	20752.571	3405.0901	219.3556
MLT3_3	1327.2264	1012.7218	570	12612.136	2187.8559	164.8442
MLT3_4	1124.4612	649.7059	212.6029	20957.527	2621.5752	233.1406
MLT3_5	2998.6181	2398.6402	823.4746	29191.078	5866.6163	195.644
MLT4_1	993.3458	594.4062	561.4268	7747.2196	1283.8361	129.2436
MLT4_2	1390.5374	1012.8927	724.4998	17149.389	2118.0009	152.3153
MLT4_3	2764.8712	1154.5833	463.8965	20760.604	5084.817	183.9079
MLT4_4	2158.8145	1766.1185	691.512	13518.762	3071.1926	142.2629
MLT4_5	3171.1491	2375.3529	643.5607	23215.066	5134.2057	161.9036

Prema pokazateljima agregacije (Tab. 6.6.4) mezo tipovi krajobraza GH pokazuju različite stupnjeve agregacije ovisno o samom pokazatelju, što ukazuje na različito uvjetovanu genezu uzoraka unutar mezo tipova krajobraza. Prema pokazatelju CLUMPY svi mezo tipovi krajobraza bilježe gotovo maksimalnu agregiranost uzoraka, obzirom da vrijednosti blizu 1 ukazuju na agregaciju, vrijednost -1 na maksimalnu fragmentaciju, a vrijednost 0 ukazuje na slučajnu prostornu distribuciju uzoraka. Pokazatelj PLADJ ukazuje na isti stupanj agregacije kao i prethodno opisan CLUMPY. Prema pokazatelju IJI postoje određene razlike u

vrijednostima među mezo tipovima, ali i sam pokazatelj ukazuje na agregiranost tj. interspenziju klase (mezo tipa krajobraza) s drugim klasama. Tako je mezo tip MLT 2_2 maksimalno agregiran te vrlo rijetko dijeli rub s nekom drugom klasom/mezo tipom krajobraza. Takve vrijednosti i karakteristike bilježe i mezo tipovi MLT 2_3, MLT 2_4, MLT 2_5, MLT 3_4, MLT 3_5, MLT 4_1, MLT 4_3, MLT4_4 i MLT 4_5. Na makro krajobraznoj razini najveći stupanj agregiranosti, a istovremeno odvojenosti od svih ostalih tipova krajobraza ima makro tip 4_ Niži pristranci i strme dolinske strane. Pokazatelji COHESION i AI ukazuju na agregaciju ili fragmentaciju unutar klase, te redundantno pokazuju kako su svi mezo tipovi krajobraza GH izuzetno agregirani. Pokazatelj NLSI ukazuje na fragmentiranost i kompleksnost oblika uzoraka (vrijednosti blizu 1), te s druge strane na kompaktnost i jednostavnost uzoraka (vrijednosti bliže 0). Najveću kompleksnost i fragmentiranost unutar klase pokazuju mezo tip MLT 3_5, MLT 4_4, MLT 4_5 i MLT 2_4. I dalje, promatrajuće raspon pokazatelja i sve mezo tipove krajobraza GH, generalno prevladavaju jednostavni, nekompleksni uzorci.

Tab. 6.6.4 Metrika krajobraza na razini klasa krajobraza – pokazatelji agregacije

Mezo tip krajobraza	CLUMPY	PLADJ	IJI	COHESION	AI	NLSI
MLT1_1	0.9938	99.4652	53.3073	99.9106	99.4887	0.0051
MLT1_2	0.9924	99.2356	65.0366	99.6886	99.2788	0.0072
MLT1_3	0.9919	99.1586	63.9142	99.6254	99.2135	0.0079
MLT1_4	0.9938	99.3395	57.7727	99.7526	99.398	0.006
MLT1_5	0.9949	99.4569	61.6849	99.7595	99.5109	0.0049
MLT2_1	0.9922	99.3609	66.2438	99.8865	99.3821	0.0062
MLT2_2	0.9918	99.1925	83.8354	99.7257	99.2326	0.0077
MLT2_3	0.9902	98.9601	76.5011	99.4449	99.0372	0.0096
MLT2_4	0.9896	98.8744	75.9561	99.4373	98.969	0.0103
MLT2_5	0.9919	99.0627	78.8659	99.5665	99.1921	0.0081
MLT3_1	0.9911	99.151	58.2023	99.6898	99.1854	0.0081
MLT3_2	0.996	99.5936	69.9504	99.8967	99.6293	0.0037
MLT3_3	0.9905	99.0326	67.664	99.5783	99.0846	0.0092
MLT3_4	0.9924	99.1927	74.7207	99.6354	99.257	0.0074
MLT3_5	0.9876	98.6169	78.5685	99.284	98.7643	0.0124
MLT4_1	0.9894	98.9836	82.0097	99.6961	99.0188	0.0098
MLT4_2	0.99	99.0043	68.6985	99.5605	99.0495	0.0095
MLT4_3	0.9933	99.2913	73.1933	99.8107	99.3513	0.0065
MLT4_4	0.9881	98.7475	75.4863	99.5423	98.8295	0.0117
MLT4_5	0.9894	98.8431	79.0307	99.478	98.9505	0.0105

Prema pokazateljima agregacije/podjele (Tab. 6.6.5) mezo tipovi krajobraza GH pokazuju međusobno različitost u vrijednostima, ali i različitost u pojedinim mezo tipovima po svakom pokazatelju. Pokazatelj DIVISION ukazuje na veliku podijeljenost klase na mnoštvo uzoraka u svim mezo tipovima. Pokazatelj MESH ukazuje da neki mezo tipovi imaju veće i bolje

strukturno povezane uzorke (MLT 1_1, MLT 2_1, MLT 3_2. Najveću fragmentiranost pokazuju mezo tipovi MLT 3_5, MLT 2_5, MLT 2_4 i MLT 4_5. Pokazatelj SPLIT obrnuto je proporcionalan od pokazatelja MESH te potvrđuje činjenicu da su mezo tipovi MLT 3_5, MLT 2_5, MLT 2_4 i MLT 4_5 najviše fragmentirane klase krajobraza GH.

Tab. 6.6.5 Metrika krajobraza na razini mezo tipova krajobraza – pokazatelji agregacije/podjele

Mezo tip krajobraza	DIVISION	MESH	SPLIT
MLT1_1	0.9961	4043.6099	259.0021
MLT1_2	0.9999	90.8149	11532.287
MLT1_3	1	41.632	25156.201
MLT1_4	0.9999	78.3027	13375.06
MLT1_5	0.9999	96.1153	10896.325
MLT2_1	0.9965	3627.7113	288.6953
MLT2_2	0.9998	188.6006	5553.0236
MLT2_3	1	15.0257	69700.978
MLT2_4	1	6.6451	157605.99
MLT2_5	1	4.7424	220837.39
MLT3_1	0.9998	161.8295	6471.6455
MLT3_2	0.9991	953.3708	1098.5267
MLT3_3	1	31.6935	33044.733
MLT3_4	1	40.5597	25821.295
MLT3_5	1	1.1691	895787.48
MLT4_1	0.9998	240.1623	4360.8147
MLT4_2	1	41.5144	25227.488
MLT4_3	0.9999	124.8594	8387.864
MLT4_4	1	11.6156	90163.664
MLT4_5	1	6.4511	162343.81

Razina krajobraza

Promatrajući krajobraz GH u cijelosti (Tab. 6.6.6) i pokazatelje na razini krajobraza, moguće je vršiti usporedbe s drugim krajobrazima ili s drugim slojevima prostora koji su obrađeni kroz metriku krajobraza. Oblik krajobraza prema pokazateljima SHAPE_MN i SHAPE_AM je jednostavan. To potvrđuju i pokazatelji FRAC i GYRATE. Krajobraz je dobro povezan što potvrđuju i pokazatelji CONTIG i PAFRAC. Pokazatelj CONTAG ukazuje na osrednje kompleksan krajobraz, Prema pokazateljima PLADJ, COHESION i AI krajobraz GH gotovo je maksimalno agregiran. No, prema pokazatelju IJI, krajobraz GH je heterogen (iako ne značajno) te su klase (tj. mezo tipovi) krajobraza dobro izmiješani u prostoru. S druge strane pokazatelj DIVISION koji ukazuje na podijeljenost unutar klasa bilježi visoku vrijednost koja ukazuje na značajnu podijeljenost/fragmentiranost, kao i pokazatelj SPLIT. Prema pokazateljima raznolikosti, krajobraz GH je izuzetno raznolik. Pokazatelj SIDI bilježi gotovo maksimalnu vrijednost.

Tab. 6.6.6 Metrika krajobraza za prostor GH u cijelosti– razina krajobraza

POVRŠINA/ RUB	TA	NP	PD	LPI	TE	ED	
	1047303.31	2786	0.266	4.888	14591780	13.9327	
	LSI	AREA_MN	AREA_AM	AREA_MD	AREA_RA	AREA_SD	
	39.2008	375.9165	9806.4252	71.275	51192.66	1882.8392	
	AREA_CV	GYRATE_MN	GYRATE_AM	GYRATE_MD	GYRATE_RA	GYRATE_SD	GYRATE_CV
	500.8664	622.793	4516.0453	393.2508	16043.692	952.865	152.9987
OBLIK	SHAPE_MN	SHAPE_AM	SHAPE_MD	SHAPE_RA	SHAPE_SD	SHAPE_CV	FRAC_MN
	1.6395	3.6839	1.4824	8.4841	0.6765	41.2602	1.0656
	FRAC_AM	FRAC_MD	FRAC_RA	FRAC_SD	FRAC_CV	PARA_MN	PARA_AM
	1.1287	1.0609	0.3417	0.0484	4.5435	996.4526	29.2552
	PARA_MD	PARA_RA	PARA_SD	PARA_CV	CIRCLE_MN	CIRCLE_AM	CIRCLE_MD
	72.3665	3990.4916	1610.6546	161.6389	0.5346	0.7337	0.6176
	CIRCLE_RA	CIRCLE_SD	CIRCLE_CV	CONTIG_MN	CONTIG_AM	CONTIG_MD	CONTIG_RA
	0.9684	0.2779	51.9785	0.7464	0.9917	0.9793	0.9973
	CONTIG_SD	CONTIG_CV	PAFRAC				
	0.4036	54.0777	1.1241				
AGREGACIJA- IZOLACIJA	ENN_MN	ENN_AM	ENN_MD	ENN_RA	ENN_SD	ENN_CV	
	1363.4356	731.275	431.6248	44748.7838	3032.8239	222.4398	
AGREGACIJA	CONTAG	PLADJ	IJI	COHESION	AI		
	56.3603	99.2686	75.4952	99.8113	99.3072		
AGREGACIJA - PODJELA	DIVISION	MESH	SPLIT	NP	PD		
	0.9906	9806.4252	106.7977	2786	0.266		
RAZNOLIKOST	PR	PRD	RPR	SHDI	SIDI	MSIDI	SHEI
	20	0.0019	100	2.5594	0.8946	2.2496	0.8544
	SIEI	MSIEI					
	0.9416	0.7509					


6.7. Vrednovanje krajobraza GH

Unutar vrednovanja, izračunati su i bodovi za pojedine kriterije vrednovanja, a prostorna distribucija rezultata vrednovanja po kriterijima i ukupna ocjena vrednovanja krajobraza GH prikazani su na Sl. 6.7.1 i u Tab. 6.7.1, a kompletna tablica vrednovanja nalazi se u Prilogu I. Prema kriteriju ekološkog stanja, u naj lošijem stanju su MLT 1_1 i MLT 2_1, MLT 2_2, MLT 3_1, MLT 4_1 i MLT 4_2. U izvrsnom stanju su MLT 1_3, MLT 1_5, MLT 2_4, MLT 2_5, MLT 3_2, MLT 3_3, MLT 3_4, MLT 3_5 i MLT 4_5. Prema kriteriju stupnja fragmentacije, u najboljem stanju je MLT 1_1, dok su s jednakim brojem bodova i sa velikim stupnjem fragmentacije mezo tipa MLT 1_2, MLT 1_3, MLT 2_2, MLT 2_3, MLT 3_1, MLT 3_3, MLT 3_4- MLT 3_5, MLT 4_1, MLT 4_2, MLT 4_3. Najveću povezanost unutar mezo tipa imaju MLT 1_5, MLT 2_3, MLT 2_4, MLT 2_5, MLT 3_5, MLT 4_4 i MLT 4_5. Vrlo lošu povezanost uzoraka unutar mezo tipa pokazuju MLT 1_1, MLT 2_1, MLT 3_1, MLT 3_2, MLT 3_4 i MLT 4_1. Najučestaliji mezo tip krajobraza GH je MLT 1_1. Nasuprot, oni najrjeđi mezo tipovi su MLT 1_2, MLT 1_3, MLT 2_2, MLT 2_3, MLT 2_4, MLT 2_5, MLT 3_4, MLT 3_5, MLT 4_2, MLT 4_4 i MLT 4_5. Izdvajaju se mezo tipovi MLT 3_1 i MLT 4_1 kao generalno ugroženi mezo tipovi krajobraza, obzirom da su u vrlo lošem ekološkom stanju, visoko fragmentirani, loše povezani, a istodobno bilježe obilje elemenata georaznolikosti i rijetkih staništa. Po obilju elemenata georaznolikosti i rijetkih staništa ističe se MLT 4_1 s najvećim brojem bodova u ovom kriteriju, a u istoj klasi obilja georaznolikosti i rijetkih staništa nalaze se i MLT 1_2, MLT 1_3, MLT 3_1, MLT 3_2 i MLT 4_3. Mezo tipovi s najmanjom ocjenom elemenata georaznolikosti i rijetkih staništa su MLT 1_4 i MLT 3_5. Promatrajući frekvenciju poljoprivredne aktivnosti i frekvenciju antropogene aktivnosti skupa, stvoren je kriterij vrednovanja koji ukazuje na utjecaj čovjeka na određeni mezo tip krajobraza. Što je veći utjecaj čovjeka, to je manji broj bodova ostvario određeni mezo tip. Tako je mezo tip s najvećim utjecajem čovjeka MLT 1_4. Najmanji utjecaj čovjeka bilježe mezo tipovi MLT 2_5, MLT 3_1, MLT 3_2, MLT 3_3 i MLT 4_3. Promatrajući ukupnu ocjenu vrednovanja ističu se dva tipa s najvećim brojem bodova, a to su MLT 1_3 i MLT 4_3. Obzirom da su vrijednosti klasificirane u bonitetne kategorije, osim navedenih mezo tipova, u klasu najvrjednijih krajobraza spadaju i MLT 3_3, MLT 3_4 i MLT 4_5 (slika x *Ukupna ocjena*, Prilog x).

Makro tip krajobraza 2_Pobrđa i niži pristranci dolinskih strana nema niti jedan mezo tip ocijenjen vrlo vrijednim, dok makro tip 3_Planinski lanci i masivi, izraženi hrptovi i 4_Niži pristranci i strme dolinske strane bilježe po dva makro tipa ocijenjena kao iznimno vrijedna, te samim time i adekvatnim za zaštitu.

Tab. 6.7.1 Bodovi po kriterijima vrednovanja te ukupna bodovi vrednovanja krajobraza GH

Tip krajobraza	Ekološko stanje	Fragmentacija	Povezanost	Rijetkost	Georaznolikost	Utjecaj čovjeka	Ukupna ocjena
1_1	8	3	1	4	17	3	36
1_2	9	6	2	12	18	3	50
1_3	10	6	2	12	18	5	53
1_4	9	4	2	11	13	2	41
1_5	11	5	3	10	15	3	47
2_1	7	4	1	5	17	3	37
2_2	7	6	2	12	17	4	48
2_3	9	6	3	12	15	5	50
2_4	10	4	3	12	15	4	48
2_5	10	4	3	12	12	6	47
3_1	7	6	1	10	18	6	48
3_2	11	5	1	6	18	6	47
3_3	10	6	2	11	17	6	52
3_4	10	6	1	12	17	5	51
3_5	10	6	3	12	13	5	49
4_1	7	6	1	10	20	4	48
4_2	8	6	2	12	17	5	50
4_3	9	6	2	11	19	6	53
4_4	9	4	3	12	16	5	49
4_5	10	4	3	12	17	5	51



Sl. 6.7.1 Kriteriji vrednovanja te ukupna ocjena vrednovanja krajobraza GH

7. RASPRAVA

7.1. Stanje krajobraza GH

Obzirom na odvojen proces i različite rezultate dobivene izračunom pokazatelja metrike krajobraza za površinski pokrov (sekundarnu strukturu krajobraza) te krajobraz u cijelosti sa svim komponentama strukture, potrebno je i zasebno sagledati stanje površinskog pokrova te stanje krajobraza sa svim komponentama strukture. Povezanost u prostoru predmet je Toblerovog 1. zakona u geografiji i važnosti udaljenosti, tj. veza između promatranih pojava u prostoru (Tobler, 1970). U krajobrazu, kao i u njegovoj sekundarnoj strukturi, površinskom pokrovu, ta povezanost proizlazi iz konfiguracije uzoraka u određenoj klasi i izražava se pokazateljima povezanosti (Antrop i Van Eetvelde, 2017). U ovom slučaju, to je topološka ili horizontalna povezanost promatranih elemenata određenog područja. Vrijednosti ANN-a pokazuju da sve klase površinskog pokrova na prostoru GH pokazuju agregaciju, tj. izrazito su povezane, ali s drugim metrikama postaje jasno da su različiti utjecaji doveli do takvog stanja u svakoj pojedinoj klasi površinskog pokrova. Na primjer, promatrajući prostornu raspodjelu uzoraka u klasi oskudne vegetacije, najveća područja nalaze se u hipsometrijski najvišim područjima gdje prevladavaju padine orijentirane prema moru. Klasteri su veći i izduženiji prema jugu, što ukazuje na utjecaj klime i reljefa u ovom slučaju. Klasa poljoprivrednih površina pokazuje veliku koncentraciju u klasterima. Gotovo su isključivo povezani s hipsometrijski najnižim dijelovima prostora, tj. s krškim depresijama različitih veličina. Uzorci su lokalizirani blizu antropogenih područja. Klasa vodenih površina je naj lošije povezana, ali razlog tome leži u prirodi pojave vode u kršu. U (Hamzić i Fuerst-Bjeliš, 2021a) ANN je izračunat za klase pokrova zemljišta u središnjem dijelu Gorske Hrvatske na temelju CORINE iz 2012., a rezultati pokazuju izolaciju u antropogenim područjima i klasama vodenih površina, dok sve ostale klase pokazuju agregaciju. Ovi rezultati su više u skladu s pokazateljem ENN_AM. Pokazatelj ANN uvelike ovisi o veličini analiziranog područja, što bi mogao biti razlog različitih rezultata. S druge strane, budući da je u (Hamzić i Fuerst-Bjeliš, 2021a) analiziran površinski pokrov na temelju CORINE 2012, a u ovom radu je za 2021. godinu napravljena Sentinel-2A klasifikacija, postoji mogućnost promjena u klasi antropogenih područja, a također postoji mogućnost da su razlike u kvaliteti korištenih podataka uzrokovale drugačije rezultate.

Na razini prostora GH, pokazatelji se izračunavaju i interpretiraju neovisno o pojedinim klasama. Pokazatelj koji opisuje površine i rubove unutar cijelog prostora istraživanja Indeks

najvećeg uzorka površinskog pokrova (eng. *Largest Patch Index* LSI) za cijeli prostor GH, iznosi 68,7. To je u skladu s metrikom na razini uzorka, gdje jedan uzorak iz klase šuma zauzima više od 50% površine GH. Od pokazatelja koji opisuju morfologiju krajobraza, indeks oblika, koji iznosi 1,34 pokazuje da cijelim površinskim pokrovom GH dominiraju uzorci jednostavnih morfologija. To potvrđuje i fraktalna dimenzija perimetra i površine, koja iznosi 1,32 i ukazuje na morfološki jednostavne uzorke. Prema pokazateljima agregacije ili disperzije, pokazatelj *Contagion* pokazuje da je površinski pokrov GH kompaktan, tj. postoji velika vjerojatnost da dvije susjedne ćelije pripadaju istoj klasi. Korištena su dva pokazatelja raznolikosti: Shannonov indeks raznolikosti i Simpsonov indeks raznolikosti. Oba pokazuju da prostor GH nema raznolik površinski pokrov. Ovaj nalaz u skladu je s rezultatima rada (Hamzić i Fuerst-Bjeliš, 2021a) u kojem su neki pokazatelji metrike krajobraza za površinski pokrov izračunati na temelju CORINE podataka za središnji dio Gorske Hrvatske. Rezultati tog rada pokazuju prevladavanje klase šuma i više fragmentiranih klasa travnjaka i poljoprivrednih površina koje se nalaze uz antropogene površine.

Kroz pokazatelje metrike krajobraza te iz njih izvedene kriterije vrednovanja krajobraza moguće je dobiti uvid u generalno stanje krajobraza GH, kao i u stanje pojedinih makro i mezo tipova krajobraza GH. Promatrajući klase ekološkog stanja mezo tipova krajobraza, 30 % (6 od 20) mezo tipova krajobraza GH u lošem je stanju. Promatrajući distribuciju površina koje zauzimaju klase ekološkog stanja, većina vrijednosti nalazi se u klasi lošeg stanja tj. prevladavaju mezo tipovi u lošem ekološkom stanju koji se prostiru na 64% površine GH. Loše stanje odnosi se na vrlo velike vrijednosti pokazatelja stanja ruba uzoraka, udjela malih uzoraka te velike vrijednosti pokazatelja oblika. Svi navedeni pokazatelji ponašaju se tako da sa većom vrijednošću ukazuju na lošije stanišno/ekološko stanje klase (mezo tipa krajobraza). Što je rub kompleksniji, dulji, što su oblici kompleksniji to su u lošijem ekološkom stanju. Uzorci velikih površina ili dominacija nekoliko velikih uzoraka ukazuje na stabilnost i dobre ekološke uvjete. Nasuprot lošem stanju, pokazatelji ruba koji ukazuju na male duljine rubova, malu gustoću rubova, jednostavne oblike te dominaciju uzoraka velikih površina karakteristični su za tipove krajobraza dobrog ekološkog/stanišnog stanja (Bonsu i Bonin, 2023; Botequilha-Leitão i dr., 2006). Prema kriteriju fragmentacije, više od polovice (55%) mezo tipova krajobraza bilježi visok stupanj fragmentacije. Promatrajući udjele površine koje zauzima, klasa visokog stupnja fragmentacije zauzima 44,49% prostora GH. Makro tip 3_ Planinski lanci i masivi, izraženi hrptovi po svim mezo tipovima bilježi visok stupanj fragmentacije te je fragmentacijom najugroženiji makro tip krajobraza GH. Upravo geomorfološka obilježja ovoga makro tipa

krajobraza GH ga čine fragmentiranim, jer prema kriteriju utjecaja čovjeka makro tip 3 je pod najmanjim utjecajem čovjeka. Kako 8 od ukupno 12 fragmentiranih mezo tipova krajobraza pripadaju makro tipu 3 i 4 koji predstavljaju reljefno dinamičnije mezo tipove, uputno je da je fragmentacija uzoraka u ovim mezo tipovima geogena, dok je fragmentacija u makro tipovima 1 i 2 antropogena (Jaeger, 2000; Romanillos i dr., 2024). Utjecaj primarne strukture krajobraza na fragmentaciju najviše je izražen upravo u gorskim i planinskim regijama, a dokazana je i složena nelinearna veza između kompleksnosti reljefa i fragmentacije krajobraza (Fang i dr., 2026). Fragmentacija na prostoru GH tako je prvenstveno geogena te determinirana primarnom strukturom krajobraza. Antropogena fragmentacija manje je prisutna, ali značajnija u pogledu budućih konzervacijskih napora. I u već postojećim istraživanjima (Dobrowski, 2011; Fang i dr., 2026; GESSLER i dr., 1995) ustanovljeno je kako geomorfološka obilježja preoblikuju i oblikuju prirodne i kulturne krajobraze na višestruke načine. Geomorfološka obilježja igraju ključnu ulogu u oblikovanju regionalnih krajobraznih obrazaca. Perspektiva temeljena na primarnoj strukturi krajobraza pruža kritičan uvid u dinamiku krajobraza i pomaže u prepoznavanju strukturnih problema, posebno fragmentacije (Fang i dr., 2026).

Krajobraz GH prema kriteriju povezanosti većinski spada u klasu izrazito dobro povezanih mezo tipova krajobraza. U klasu izrazito dobro povezanih mezo tipova krajobraza spada 63% prostora GH, dok samo 9% prostora GH spada u klasu loše povezanih mezo tipova krajobraza. Obzirom na planetarni proces smanjenja prirodnih površina, povezanost u krajobrazu postaje vrlo važan konzervacijski prioritet. Povezani krajobrazi omogućuju pristup dnevnim, sezonskim i cjeloživotnim resursima koji su potrebni divljim životinjskim vrstama za preživljavanje i reprodukciju. Osobito je to bitno za vrste koje migriraju. Postojanje manjih, ali ne povezanih uzoraka krajobraza tj. fragmentiranih klasa i uzoraka krajobraza nije dostatno za očuvanje vrsta. Upravo je povezanost ključna za protok gena i opstanak vrsta (Naidoo i dr., 2025).

Prema kriteriju rijetkosti više od polovice mezo tipova krajobraza GH (55%) spada u klasu rijetkih tipova na prostoru GH. Gotovo sve klase kriterija rijetkosti zauzimaju podjednaku površinu GH, no klasa izrazito rijetkih tipova krajobraza zauzima 26,68% prostora GH. Prema stupnju antropogenog utjecaja, samo je jedan mezo tip krajobraza pod značajnim antropogenim utjecajem, a to je MLT 1_4 u kojem je dominantan morfogenetski tip reljefa fluvijalni, a površinski pokrov šume i antropogene površine. Pod antropogenim utjecajem (klasa 3), bilo kroz poljoprivredne aktivnosti ili prisutnost naselja i/ili prometnica je 35% mezo tipova krajobraza GH. Promatrajući površinu koju zauzimaju klase antropogenog utjecaja, klasa 4


(značajan antropogeni utjecaj) prostire se na 2,7% površine GH. Prostorno najraširenija klasa antropogenog utjecaja je klasa 3 (prisutan antropogeni utjecaj) koja se rasprostire na 60,99% površine GH. Prema kriteriju georaznolikosti, 10% mezo tipova krajobraza ima obilježja značajnog obilja elemenata georaznolikosti. Ova klasa vrijednosti georaznolikosti rasprostire se na 10,1% prostora GH. Ovakvi rezultati ukazuju na prostornu ograničenost značajne georaznolikosti.

Prema ukupnoj ocjeni krajobraza 15% (3 od 20) mezo tipova krajobraza spada u klasu najvrjednijih krajobraza na prostoru GH. Površina koju zauzimaju najvrjedniji mezo tipovi krajobraza iznosi 9,1%. Pogledom na ukupnu ocjenu krajobraza te izdvojene najvrjednije mezo tipove krajobraza, ali s osvrtom na ocjenu svakog pojedinog kriterija, dva od tri najvrjednija mezo tipa imaju izvrsno ekološko stanje, dok jedan bilježi dobro stanje, a sva su tri mezo tipa izrazito fragmentirana te spadaju u klasu osrednje povezanosti. Prema kriteriju rijetkosti, dva su mezo tipa osrednje prisutna (nisu niti rijetki niti učestali), dok je jedan ocijenjen kao vrlo rijedak na prostoru GH. Prema kriteriju obilja georaznolikosti i obilja rijetkih staništa, dva su mezo tipa u klasi izrazito značajnog obilja, dok je jedan u klasi značajnog obilja. Prema stupnju antropogenog utjecaja, dva su ocijenjena kao mezo tipovi gotovo bez antropogenog utjecaja, dok je jedan ocijenjen kao mezo tip s minimalnim antropogenim utjecajem.

Kako bi ocijenili ukupno stanje cijelog krajobraza sa svim njegovim makro i mezo tipovima, potrebno je sagledati rezultate metrike na razini cijelog prostora GH. Prema Simpsonovom indeksu raznolikosti, krajobraz GH spada u raznolike krajobraze (0,8946). Ovaj indeks mjera je kompozicije krajobraza te govori o mogućnosti da dvije nasumično odabrane ćelije pripadaju različitim klasama krajobraza (mezo tipovima krajobraza). Shannonov indeks ravnomjernosti iznosi 0,8544. Ova vrijednost govori o ujednačenoj distribuciji mezo tipova krajobraza GH, što je bliže vrijednosti 1. Simpsonov indeks ravnomjernosti koji također ogovori o vrlo ujednačenoj tj. heterogenoj distribuciji mezo tipova krajobraza (0,9416). Obzirom da većina znanstvenih publikacija koje kvantificiraju krajobraz zapravo izjednačuju pojam krajobraza s površinskim pokrovom ili staništem, vrlo je mali broj publikacija s kojima je moguće usporediti rezultate ovoga istraživanja. Prema istraživanju (Perko i Ciglič, 2015) Hrvatska spada u top 10 europskih zemalja po raznolikosti krajobraza. Također, iz rezultata istraživanja (Perko i Ciglič, 2015) jasno je kako su upravo gorska/planinska područja ona s najvećim vrijednostima raznolikosti krajobraza, a rezultati ovoga rada potvrđuju kako je krajobraz GH iznimno raznolik.

7.2. Utjecaj elemenata vertikalne strukture na krajobraz GH

Promatrajući odnos pojedinih kriterija vrednovanja (Sl. 7.2.1) vidljiva je izražena pozitivna korelacija kod kriterija rijetkosti i kriterija povezanosti mezo tipa krajobraza. Rjeđe prisutni mezo tipovi imaju lošiju povezanost među uzorcima, a bolje povezani mezo tipovi su učestali. Povezanost i georaznolikost bilježe statistički značajnu negativnu korelaciju, tj. ukoliko je povezanost uzoraka loša, obilje elemenata georaznolikosti je malo, dok je povezanost uzoraka dobra, tada je obilje elemenata georaznolikosti značajno. Statistički značajna pozitivna korelacija uočena je i u odnosu ekološkog stanja i povezanosti uzoraka, slijedom čega mezo tipovi krajobraza boljeg ekološkog stanja su lošije povezani, te s druge strane, mezo tipovi lošijeg ekološkog stanja su dobro povezani. Učestalost i fragmentacija bilježe statistički značajnu pozitivnu korelaciju slijedom čega mezo tipovi krajobraza GH koji su značajno fragmentirani su ujedno i rijetki, dok su značajno agregirani tipovi učestali. Na temelju statistički značajnih vrijednosti Pearsonovog koeficijenta korelacije mezo tipovi krajobraza GH koji imaju manju povezanost tj. koji su više izolirani imaju i manje vrijednosti obilja elemenata georaznolikosti, ali su i izrazito fragmentirani i rjeđi tipovi krajobraza, no u dobrom su ekološkom stanju.



Sl. 7.2.1 Matrica korelacije kriterija vrednovanja krajobraza GH, u donjem lijevom kutu prikazani su dijagrami rasipanja, a u gornjem desnom kutu vrijednost Pearsonovog koeficijenta korelacije s izraženim p-vrijednostima (* $p < 0,05$, ** $p < 0,01$, *** $p < 0,001$)

Svi mezo tipovi krajobraza GH u izvrsnom ekološkom/stanišnom stanju kao dominantan površinski pokrov imaju različite površinske pokrove, no ponavljaju se klasa šuma, travnjaka i izdanaka stijena. Što se tiče dominantnog morfogenetskog tipa najučestaliji u mezo tipovima izvrsnog ekološkog stanja su fluviokrš i glaciokrš. U vertikalnoj strukturi krajobraza kod mezo tipova izvrsnog ekološkog stanja nema dominacije određene klase površinskog pokrova niti morfogenetskog tipa reljefa, no okupljenost mezo tipova izvrsnog ekološkog stanja u mezo tipovima koji imaju više dinamičan reljef (veće nadmorske visine, veći nagibi, veća vertikalna raščlanjenost) ukazuju na utjecaj morfometrijskih obilježja prostora na ekološko stanje mezo tipova krajobraza. U kriteriju rijetkosti tipova krajobraza, mezo tipovi koji su najučestaliji kao dominantan površinski pokrov imaju klasu šuma, te u 3 od 4 najučestalija mezo tipova dominantan morfogenetski tip reljefa je krš. Obzirom da i krš i šume zauzimaju najveću površinu prostora GH, ovakav rezultat je očekivan. Kao i kod ekološkog stanja, primjetan je utjecaj morfometrijskih obilježja prostora, gdje više nadmorske visine, veći nagibi i veća vertikalna raščlanjenost mezo tipove krajobraza čine rjeđima u prostoru po svojoj pojavnosti. Kriterij antropogenog utjecaja izražen je povezan s geomorfološkim obilježjima prostora tj. primarnom strukturom krajobraza. Što je reljef više raščlanjen, većih nagiba i na većoj nadmorskoj visini, to je manji antropogeni utjecaj. Najveći broj bodova u kriteriju obilja georaznolikosti odnosi MLT 4_1 u kojem je dominantan površinski pokrov šuma dok je dominantan morfogenetski tip reljefa fluviokrš. Ostali mezo tipovi u klasi značajnog obilja georaznolikosti (MLT 4_3, MLT 1_2, MLT 1_3, MLT 3_1, MLT 3_2) ukazuju na to da morfometrijski i općenito generalizirani pristup georaznolikosti nije adekvatan, obzirom da značajno obilje elemenata georaznolikosti u sebi nose mezo tipovi iz makro tipa 1_Udoline, fragmenti zaravni i krške depresije većih dimenzija koji ima obilježja vrlo umjerenog reljefa koji se nalazi na generalno zaravnjenim prostorima, malih nagiba i male vrijednosti vertikalne raščlanjenosti reljefa. Promatrajući dominantan površinski pokrov u mezo tipovima reljefa sa značajnim obiljem elemenata georaznolikosti, u 5 od ukupno 6 mezo tipova, dominantna klasa je šuma. Upravo ovakva situacija ukazuje na potrebu sagledavanja prostora kroz prostornu jedinicu krajobraza ali s definiranom vertikalnom strukturom u kojoj je determiniran i reljef jer samo površinski pokrov ili samo geomorfološki pristup ne daju realnu prostornu sliku međuovisnosti i međudjelovanja pojedinih elemenata vertikalne strukture. Kada bismo samo promatrali površinski pokrov kao „krajobraz“ onda bi klasa šuma bila ocijenjena kao stabilna i u dobrom stanju dok pristupom u ovom radu kroz rezultate metrike krajobraza i kompleksne krajobrazne gradijente, vidimo da se ispod klase površinskog pokrova šume krije mnoštvo različitih krajobraznih tipova koji imaju potpuno drugačije karakteristike.

Najučestaliji morfogenetski tip reljefa u kojem je zabilježeno značajno obilje georaznolikosti i rijetkih staništa je fluviokrš. Takvi podaci odudaraju od dosadašnjih tvrdnji o velikoj georaznolikosti krša. Pretpostavka je da je ova činjenica uzrokovana dosadašnjem pristupu analize i kvantifikacije georaznolikosti, ali i nedostatku adekvatnih podataka o morfogenetskim tipovima reljefa i o prostornim razinama istraživanja gdje se većina istraživanja provodi na malim površinama, a ne u regionalnom ili nacionalnom kontekstu. Značajna je podudarnost raspodjele vrijednosti kriterija ekološkog stanja, fragmentacije i utjecaja čovjeka po makro tipovima krajobraza GH, tj. prema morfometrijskim obilježjima prostora. Utjecaj čovjeka obrnuto je proporcionalan fragmentaciji, što još jednom potvrđuje geogenu fragmentaciju u makro tipovima 3 i 4. Sveukupno, učinci ljudske aktivnosti na fragmentaciju su dobro utvrđeni, ali promjene strukture krajobraza također su duboko ukorijenjene u prirodnom geografskom okruženju. Razumijevanje kako prirodni čimbenici oblikuju obrasce fragmentacije jednako je važno. Među prirodnim odrednicama poput klime i tla, reljef ima najtemeljniji i najsustavniji utjecaj na evoluciju regionalnog krajobraza. On služi ne samo kao fizički supstrat za formiranje krajobraza, već i nameće važna ograničenja na način na koji se krajobrazi razvijaju tijekom vremena (Fang i dr., 2026).

Promatrajući sve kriterije vrednovanja te njihovo ponašanje u kontekstu vertikalne strukture krajobraza, primjetan je utjecaj morfometrijskih obilježja na 4 od 6 kriterija vrednovanja, čime se taj utjecaj može okarakterizirati kao značajan. Iz aspekta utjecaja dominantnog morfogenetskog tipa reljefa ili dominantne klase površinskog pokrova na vrijednost krajobraza GH kada se sagledaju izdvojeni najvrjedniji mezo tipovi krajobraza GH, u sva tri tipa dominantna klasa površinskog pokrova je šuma, dok nema dominantne klase morfogenetskog tipa reljefa već se javlja ukupno 5 morfogenetskih tipova reljefa. Upravo raznolikost morfogenetskih tipova reljefa u mezo tipovima krajobraza pridonose varijaciji u krajobrazu. Klasa šuma prema pokazateljima metrike krajobraza je najstabilnija klasa sa svim povoljnim pokazateljima, a prema pokazateljima metrike krajobraza za površinski pokrov u cijelosti, izdvaja se vrlo mala raznolikost površinskog pokrova te izrazito dobri pokazatelji ekološkog stanja, fragmentacije i povezanosti. Nasuprot površinskom pokrovu, geomorfološka obilježja prostora imaju značajan utjecaj na varijabilnost krajobraza GH i njegovu dinamičnu konfiguraciju i kompoziciju. Kada se stave u odnos pokazatelji metrike krajobraza za cjelokupni površinski pokrov i krajobraz u cijelosti vidljive su značajne razlike u gotovo svim pokazateljima (Tab. 7.2.1). Prema pokazateljima površine i ruba, PD za površinski pokrov značajno je veći te ukazuje na heterogenost klasa površinskog pokrova, a nasuprot tome nešto

manju heterogenost tipova krajobraza. LPI ukazuje na to da je površinski pokrov GH ipak vrlo malo fragmentiran, obzirom da prostorom prevladava jedan dominantan uzorak, a ostatak uzoraka je heterogen i fragmentiran. Nasuprot navedenoj situaciji s površinskim pokrovom, krajobraz GH bilježi vrlo malu vrijednost LPI što ukazuje na veliku heterogenost krajobraza. Kod površinskog pokrova i krajobraza, PD i LPI ukazuju na oprečne karakteristike. Jedan dominantan uzorak u krajobrazu podržava daleko više prirodnih procesa, a time i bioraznolikosti, nego mnogo malih uzoraka (Forman i Godron, 1986). Stoga je površinski pokrov GH u puno boljem stanju nego što je to krajobraz GH. No, pokazatelj ED pokazuje isti trend kao i PD, a ova dva pokazatelja su redundantna (Vizzari i Sigura, 2013). Stoga, površinski pokrov pokazuje veći stupanj heterogenosti nego što je to slučaj kod tipova krajobraza. ED ukazuje i na erodiranost granica uzoraka kod površinskog pokrova te očuvanje granice kod tipova krajobraza. LPI u ovom slučaju navodi na krivi dojam, jer ne balansira pokazatelje po klasama, tj. dominacija jednog uzorka šume u površinskom pokrovu koja se odražava u velikoj vrijednosti LPI-a ukazuje ne homogenost klase šuma, dok upravo ostale klase površinskog pokrova pokazuju velik stupanj fragmentacije/heterogenosti (za razliku od klase šuma) na što je točno ukazao pokazatelj PD. Analiza svih razina metrike krajobraza (uzorak, klasa, krajobraz) zato je nužna u adekvatnoj interpretaciji pokazatelja.

Vrijednosti pokazatelja CIRCLE_AM podjednaki su za površinski pokrov i tipove krajobraza, kao i vrijednosti pokazatelja CONTIG_AM. CIRCLE_AM ukazuje na to da su uzorci površinskog pokrova kao i uzorci krajobraza manje kompleksnih oblika, dok CONTIG_AM ukazuje na vrlo dobru povezanost uzoraka pojedinih klasa i u površinskom pokrovu i u krajobrazu.

Prema pokazateljima agregacije-izolacije (ENN_AM i ENN_MN) značajna je razlika u vrijednostima, tako površinski pokrov bilježi izrazitu agregiranost u pojedinim klasama, dok se kod krajobraza pokazuje izražena izolacija u klasama, što je i odraz pojavnosti geomorfoloških elemenata prostora koji utječu na strukturu samoga krajobraza.

CONTAG kao pokazatelj agregacije klasa ukazuje na bolje ekološko stanje površinskog pokrova, nego što je to kod tipova krajobraza. Krajobraz bilježi gotovo medijalnu vrijednost raspona pokazatelja CONTAG čime se može klasificirati kao krajobraz u osrednjem ekološkom stanju na pragu fragmentacije. Prema pokazatelju IJI i površinski pokrov i tipovi krajobraza u značajnoj su intersperziji tj. pojedine klase su dobro izmiješane, te nisu značajno izolirane jedne od drugih, za razliku od ostalih pokazatelja koji ukazuju na agregaciju klasa, a ne njihove

međusobne odnose. COHESION i AI i kod površinskog pokrova i kod tipova krajobraza ukazuju na dobro ekološko stanje kada se sagleda prostor u cijelosti.

Pokazatelji raznolikosti ukazuju na značajne razlike kod površinskog pokrova i tipova krajobraza. Prema vrijednostima SHDI-a krajobraz bilježi veću raznolikost te veću ujednačenost u raspodjeli uzoraka u prostoru, a pokazatelj SIDI dodatno potvrđuje veliku raznolikost tipova krajobraza GH te s druge strane malu vrijednost raznolikosti površinskog pokrova GH.

Tab. 7.2.1 Usporedba pokazatelja metrike krajobraza na razini cijelog prostora GH za površinski pokrov i krajobraz,
lijeva strana stupca - površinski pokrov, desna strana stupca - krajobraz

POVRŠINA/RUB	NP		PD		LPI		TE		ED		AREA_AM	
	▲281125	▼2786	▲26.8486	▼0.266	▲68.7269	▼4.888	▲81341300	▼14591780	▲77.6843	▼13.9327	▲495525.1281	▼9806.4252
OBLIK	SHAPE_AM		PARA_AM		CIRCLE_AM		CONTIG_AM					
	▲80.4395	▼3.6839	▲156.8116	▼29.2552	▲0.8057	▼0.7337	▼0.9566	▲0.9917				
AGREGACIJA- IZOLACIJA	ENN_MN		ENN_AM									
	▼46.7407	▲1363.4356	▼28.5466	▲731.275								
AGREGACIJA	CONTAG		PLADJ		IJI		COHESION		AI			
	▲73.4316	▼56.3603	▼96.0797	▲99.2686	▼66.1713	▲75.4952	▲99.961	▼99.8113	▼96.0976	▲99.3072		
AGREGACIJA - PODJELA	DIVISION		MESH		SPLIT							
	▼0.5268	▲0.9906	▲495525.1281	▼9806.4252	▼2.1131	▲106.7977						
RAZNOLIKOST	SHDI		SIDI									
	▼0.9094	▲2.5594	▼0.4143	▲0.8946								

7.3. Posebnosti krajobraza GH

Mezo krajobrazni tipovi koji su vrednovanjem izdvojeni kao najvrjedniji rasprostranjeni su po cijelom prostoru GH. Mezo tip MLT 1_3 u izvrsnom je ekološkom stanju, no značajno je fragmentiran te osrednje povezan. Ovaj mezo tip krajobraza spada u izrazito rijetke mezo tipove krajobraza na prostoru GH. Spada u klasu mezo tipova sa značajnim obiljem elemenata georazolikosti i obilja rijetkih staništa, a antropogeni utjecaj je minimalan. Od elemenata georazolikosti, u ovom mezo tipu karakteristične su velike vrijednosti obilja proluvijalnih plavina, obilja hidrogeoloških pojava te obilja drenažne mreže.

Mezo tip MLT 4_3 u osrednjem je ekološkom stanju, poglavito zbog dominacije vrlo malih uzoraka koji imaju velike duljine ruba te velike vrijednosti pokazatelja gustoće ruba što ukazuje na erodiranost granica. Kao i ostali vrlo vrijedni mezo tipovi krajobraza i ovaj je tip značajno fragmentiran, te bilježi značajno obilje elemenata georazolikosti i obilje rijetkih staništa. Od elemenata georazolikosti za ovaj mezo tip karakteristično je obilje proluvijalnih plavina, obilje hidrogeoloških pojava, drenažne mreže te obilje kanjona i strmih strana. MLT 4_3 bilježi najveće vrijednosti obilja proluvijalnih plavina te je drugi po udjelu obilja drenažne mreže na prostoru GH.

Mezo tip MLT 3_3 u izvrsnom je ekološkom stanju, izrazito fragmentiran, osrednje povezan, te spada u klasu rijetkih mezo tipova krajobraza GH. Prema vrijednosti obilja georazolikosti i rijetkih staništa spada u klasu velikog obilja, ali ne i značajnog. Prema stupnju antropogenog utjecaja spada u klasu mezo tipova gotovo bez utjecaja čovjeka.

Obzirom da u vrednovanju krajobraza GH nisu korišteni težinski faktori kod pojedinog kriterija, u finalnim rezultatima nisu zastupljeni mezo tipovi koji su prema pojedinim kriterijima vodeći, već oni koji bilježe velike vrijednosti u svim kriterijima. Slijedom navedenog, bitno je sagledati i posebnosti ostalih krajobraznih tipova koji se po određenim kriterijima, ili obilju određenih kompleksnih krajobraznih gradijenata izdvajaju. Biti će obrađeni samo oni tipovi koji imaju apsolutno najveći broj bodova, a ne cijela populacija određene klase. Izdvojeni su i tipovi koji pokazuju negativne karakteristike, primjerice loše ekološko stanje, obzirom da vrednovanje služi za artikulaciju potreba u upravljačkom aspektu. Mezo tipovi i izdvojena obilježja prikazani su u Tab. 7.3.1. Nastavno na izneseno, vrednovanje u ovome radu stavlja naglasak na ne utilitarne vrijednosti krajobraza te služi kao alat za upravljanje i donošenje odluka o prostoru na razini krajobraza.

U najlošijem ekološkom stanju su mezo tipovi MLT 1_1 i MLT 4_2. Stupanj antropogenog utjecaja kod ova dva mezo tipa je potpuno različit, MLT 1_1 spada u klasu 2 (prisutan antropogeni utjecaj), dok MLT 4_2 spada u klasu 3 minimalnog antropogenog utjecaja. MLT 4_2 izuzetno je fragmentiran dok kod MLT 1_1 gotovo da i nije fragmentiran. MLT 1_1 najčešći/najrašireniji je mezo tip krajobraza na prostoru GH, dok MLT 4_2 spada u vrlo rijetke mezo tipove krajobraza GH. MLT 1_1 bilježi najveći udio klase izrazito intenzivno izgrađenog područja od svih mezo tipova na prostoru GH, dok MLT 4_2 u istom kompleksnom krajobraznom gradijentu bilježi vrijednost 0. Kod oba mezo tipa dominantan površinski pokrov je šuma, a dominantan morfogenetski tip reljefa je krš. Morfometrijski su potpuno različiti, u MLT 1_1 prevladavaju zaravnjene i hipsometrijski niske padine, dok u MLT 4_2 prevladavaju veliki nagibi padina te se sam MLT nalazi na prosječno hipsometrijskim višem prostoru s većim vrijednostima vertikalne raščlanjenosti reljefa. Uzrok lošeg ekološkog stanja kod MLT 1_1 je vidljiv iz samog obilja izgrađenih područja. U ovom mezo tipu nalazi se većina naselja te popratne antropogene infrastrukture na cijelom prostoru GH, te je upravo utjecaj stupnja antropogenizacije odgovoran za loše ekološko stanje. Kod MLT 4_2 izraženo je obilje strmih strana i kanjona te u ovom slučaju upravo prirodna manifestacija strmih strana i kanjona dovodi do velikog stupnja fragmentacije i lošeg ekološkog stanja. Takve padine prostorno su ograničene, izdužene i malih dimenzija, tj. uvjetovane su dominantnim morfogenetskim procesima koji su na velikim nagibima u ovom mezo tipu podložni daljnjoj izloženosti destruktivnim gravitacijskim procesima. S druge strane, upravo zbog velikih nagiba ovaj mezo tip krajobraza nije pod utjecajem čovjeka jer je nepovoljan za izgradnju i poljoprivredno iskorištavanje te bilo kakve druge gospodarske aktivnosti. Ova dva mezo tipa krajobraza izvrstan su primjer fragmentiranih krajobraza, kod kojih su uzroci fragmentacije potpuno različiti. Poglavito u istraživanjima fragmentacije i njenog utjecaja na staništa uočeno je kako promjena krajobraza kroz proces fragmentacije nije slučajna: nesrazmjerne promjene obično se događaju u zaravnjenim područjima, na nižim nadmorskim visinama i na produktivnijim tlima, što ukazuje na utjecaj čovjeka kao primarni uzrok fragmentacije (Bennett i Saunders, 2011). Upravo MLT 1_1 je mezo tip krajobraza najviše izložen utjecaju čovjeka, koji je i uzrok samoj fragmentaciji i lošem ekološkom stanju. Indikatori izrazito lošeg stanja mogu biti i pokazatelji izolacije, posebice na razini uzoraka. Ukoliko su određeni uzorci izolirani od ostatka klase, a male su površine, bilježe velike vrijednosti pokazatelja ruba te su kompleksnih oblika, oni su najpodložniji nestanku. I kod MLT 1_1 i kod MLT 4_2 uzorci koji pokazuju najveću izolaciju nalaze se na krajnjem južnom djelu prostora GH. Površine uzoraka MLT 1_1 veće su nego površine uzoraka MLT 4_2, čime je ovaj mezo tip ugroženiji, tj. velik broj uzoraka je u

opasnosti od nestanka. No, obzirom da je utjecaj čovjeka minimalan, ovi uzorci su jedino u opasnosti od prirodnih procesa, poglavito destruktivnih geomorfoloških procesa (Forman i Godron, 1986). Takvi uzorci spadaju u *disturbance patches* koji imaju obilježja izuzetno prirodnih krajobrazza, te se povremeno mijenjaju pod utjecajem upravo prirodnih ekstremnih događaja. S druge strane uzorci MLT 1_1 također imaju karakteristike uzoraka koji spadaju u *disturbance patches*, ali u one koji su kronično ugroženi ljudskom aktivnošću gdje dolazi do kontinuiranih i ponavljajućih antropogenih pritisaka.

Prema kriteriju utjecaja čovjeka, najveći stupanj antropogenog utjecaja bilježi MLT 1_4 u kojem je dominantan morfogenetski tip fluvijalni, a dominantan površinski pokrov čine šuma i antropogene površine. Prema ukupnom broju bodova, ovaj mezo tip spada u klasu najmanje vrijednih krajobrazza GH, a ta ocjena je odraz osrednjeg ekološkog stanja, osrednje povezanosti, male georaznolikosti te osrednje učestalosti, a istovremeno spada u klasu mezo tipova koji bilježe najmanji stupanj fragmentacije. U ovom tipu zastupljena su i rijetka staništa, stoga je upravo na njih potrebno obratiti dodatnu pozornost. Obzirom na dominaciju fluvijalnog morfogenetskog tipa reljefa, unatoč malim vrijednostima obilja drenažne mreže, ovaj mezo tip karakterističan je po prisutnosti velikih tekućica što je izuzetno značajno za prostor GH u kojem je površinska voda vrlo rijetka pojava.

Promatrajući pojedine kompleksne krajobrazne gradijente, potrebno je izdvojiti mezo tipove krajobrazza koji se ističu po maksimalnim vrijednostima pojedinih kompleksnih krajobraznih gradijenata. Najveću vrijednost obilja speleoloških objekata bilježi MLT 3_2 (Planinski lanci i masivi, izraženi hrptovi-glaciokrš/šume). Obilje speleoloških objekata karakteristično je za makro tip 3_Planinski lanci i masivi, izraženi hrptovi, izuzev MLT 3_5 u kojem gotovo i nema speleoloških objekata. Promatrajući MLT 3_2 u kontekstu zaštićenih područja, velik dio se nalazi u postojećim zaštićenim područjima.

Maksimalne vrijednosti obilja ponikava bilježi MLT 1_1 koji ujedno bilježi i maksimalne vrijednosti frekvencije izgrađenosti prostora. Obzirom na morfometrijska obilježja te faktore koji utječu na genezu ponikava, nije začuđujuće da se upravo u ovom mezo tipu nalazi maksimum obilja ponikava, no s druge strane, ista morfometrijska obilježja prostora najpovoljnija su i za izgradnju/naseljavanje i širenje infrastrukture.

Najveće vrijednosti obilja hidrogeoloških pojava bilježi MLT 2_2 koji je u lošem ekološkom stanju, izrazito fragmentiran i rijedak tip krajobrazza GH. MLT 4_1 bilježi najveće vrijednosti obilja drenažne mreže, a istovremeno spada u klasu lošeg ekološkog stanja te u izrazito

fragmentirane mezo tipove krajobraza. MLT 3_1 bilježi najveće vrijednosti obilja grebena, a istovremeno je u lošem ekološkom stanju te izrazito fragmentiran. Najveće obilje strmih strana/padina i kanjona bilježi MLT 4_2, koji je istovremeno u lošem ekološkom stanju, izrazito fragmentiran te jedan od rijetkih tipova krajobraza GH.

Po obilju rijetkih staništa izdvajaju se MLT 1_2 i MLT 3_4. MLT 1_2 u osrednjem je ekološkom stanju, izrazito je fragmentiran, spada u rijetke tipove krajobraza GH te nosi i veliku vrijednost georaznolikosti. MLT 3_4 u odličnom je ekološkom stanju, ali je izrazito fragmentiran i rijedak tip krajobraza GH. Promatrajući pokazatelj udjela obilja rijetkih staništa po površini mezo tipa, izdvaja se i MLT 2_4, koji je u odličnom ekološkom stanju, nije fragmentiran, ali je izrazito loše povezan te također spada u rijetke tipove krajobraza GH.

Kada se uzmu u obzir i rezultati vrednovanja te vrijednosti po svakom pojedinom kriteriju i maksimalne vrijednosti kompleksnih krajobraznih gradijenata, MLT 1_1 i MLT 4_2 izdvajaju se po maksimumu u dva kompleksna krajobrazna gradijenta, a istovremeno nisu izdvojeni procesom vrednovanja. Upravo MLT 1_1 prema rezultatima vrednovanja ima najmanji broj bodova, obzirom da je u izrazito lošem ekološkom stanju te je pod izraženim utjecajem čovjeka.


Tab. 7.3.1 Mezo tipovi krajobraza s izdvojenim karakteristikama kompleksnih krajobraznih gradijenata te značajnih negativnih vrijednosti izdvojenih po kriterijima vrednovanja

MLT	značajni udio kompleksnih krajobraznih gradijenata	značajna georaznolikost	izrazito loše ekološko stanje	loša povezanost	izrazita fragmentacija	rijedak mezo tip krajobraza GH	izražen utjecaj čovjeka
1_1	obilje ponikava		x				
1_2	obilje rijetkih staništa				x	x	
1_4	najveći utjecaj čovjeka						x
2_2	obilje hidrogeoloških pojava				x	x	
2_4	obilje rijetkih staništa			x		x	
3_1	obilje grebena				x		
3_2	obilje speleoloških objekata						
3_4	obilje rijetkih staništa				x	x	
4_1	obilje drenažne mreže	x			x		
4_2	obilje strmih strana/kanjona		x		x	x	

7.4. Izdvojena područja značajnih vrijednosti

Preklapanjem uzoraka s najvećim vrijednostima kompleksnih krajobraznih gradijenata, izuzev gradijenata koji ukazuju na stupanj antropogenog utjecaja, te uzoraka mezo tipova koji su izdvojeni kao najvrjedniji, determinirani su uzorci i kompleksi uzoraka na koje je potrebno usmjeriti pažnju pri budućim istraživanjima, upravljanju prostorom i u kontekstu sektora zaštite


okoliša. Pojedini uzorci fizički su u kontaktu ili su dijelom uklopljeni u postojeća zaštićena područja. Od svih uzoraka na cijelom prostoru GH izdvaja se uzorak MLT 4_3, koji se nalazi na SI dijelu prostora GH. Ovaj uzorak pripada mezo tipu krajobraza koji je izdvojen vrednovanjem kao izniman te sadrži najveću površinu prekrivenu najvećim vrijednostima čak 4 kompleksna krajobrazna gradijenta, na Sl. 7.4.1 prikazan crvenom bojom. Ovaj uzorak jednim dijelom je dio NP Risnjak, a u potpunosti prekriva Hidrološki spomenik prirode Izvor Kupe s užom okolinom u Gorskom kotaru te Značajni krajobraz Vražji prolaz i Zeleni vir. Upravo ovaj uzorak izdvaja se kao dobar primjer mogućeg proširenja postojećeg zaštićenog područja. Osim navedenog uzorka, koji se izdvaja u cijelom prostoru GH po obilju kompleksnih krajobraznih gradijenata te time što spada u mezo tip 4_3 koji je izdvojen kao jedan od najvrjednijih, na ovom dijelu prostora GH izdvaja se kontinuirani kompleks uzoraka sa značajnim vrijednostima, a uokviruju postojeća zaštićena područja (NP Risnjak, Hidrološki spomenik prirode Izvor Kupe s užom okolinom u Gorskom kotaru, Značajni krajobraz Vražji prolaz i Zeleni vir, Park šuma Japlenški vrh, Posebni rezervat šumske vegetacije Debela lipa - Velika Rebar kod Lokava). U neposrednoj blizini nalaze se i Park šuma Golubinjak te Značajni krajobraz Kamačnik. Na izdvojenom prostoru u kompleksu uzoraka sa značajnim vrijednostima zastupljeno je 12 mezo tipova krajobraza, te sva 4 makro tipa krajobraza GH.



Sl. 7.4.1 Izdvojeni uzorci krajobraza s najvećim vrijednostima kompleksnih krajobraznih gradijenata – prijedlog 1


Promatrajući sve uzorke na izdvojenom području, samim detektiranim vrijednostima ističe se već spomenuti uzorak MLT 4_3 koji obuhvaća prostor doline Kupe te dijelove Čabarsko-Gerovskog pobrđa, gorske skupine Drgomalj te gorske skupine Skradskog vrha. Ovaj uzorak izdvaja se kao potencijalno proširenje ili novo zaštićeno područje, dok ostatak izdvojene površine, nosi potencijal kao zona značajnih krajobraznih vrijednosti. Izdvojeni uzorak s najvećim brojem preklapanja u sebi nosi veliku vrijednost obilja proluvijalnih plavina, obilje hidrogeoloških pojava, obilje drenažne mreže, te obilje strmih strana/kanjona te je ujedno dio MLT 4_3 koji je ocijenjen kao jedan od tri najvrjednija mezo tipa krajobraza GH.

Značajni krajobraz Kamačnik, značajni krajobraz Klek, Značajni krajobraz Dabarsko polje, Nacionalni park Plitvička jezera s Posebnim rezervatom šumske vegetacije Čorkova uvala prema rezultatima izdvajanja značajnih uzoraka krajobraza, čine povezanu cjelinu (Sl. 7.4.2). Površinom najveći, ali i brojem preklapanja značajnih vrijednosti kompleksnih krajobraznih gradijenata izdvaja se veliki kontinuirani uzorak koji pripada mezo tipu MLT 2_1 koji je svrstan u mezo tipove lošeg ekološkog stanja. U izdvojenom uzorku MLT 2_1 evidentirana je značajna georaznolikost te površine sa značajnim obiljem speleoloških objekata, hidrogeoloških pojava i obiljem drenažne mreže. Upravo mjerama zaštite, ovaj uzorak koji je izdvojen prema svojim vrijednostima kompleksnih krajobraznih gradijenata, može održati ili poboljšati ekološko stanje. Izdvojen kompleks uzoraka mezo tipova krajobraza GH velikim djelom prostire se Velikom Kapelom od njenog istočnog do centralnog niza, zatim zauzima gotovo u cijelosti prostor gorske skupine Male Kapele te se prostire i II dijelom gorskog okvira Ogulinsko-Plašćanske udoline na kontaktu sa Slunjskom zaravni i Rakovičkim pobrđem. Na ovom prostoru izmjenjuju se 10 mezo tipova krajobraza GH te sva 4 makro tipa GH.




Sl. 7.4.2 Izdvojeni uzorci krajobraza s najvećim vrijednostima kompleksnih krajobraznih gradijenata – prijedlog 2

Osim površinom dominantnih povezanih cjelina, pojavljuju se i manje izdvojeni uzorci koji se svojim kvantificiranim vrijednostima pokazuju kao potencijalni prostori proširenja postojećih zaštićenih područja, kao što je to jedan uzorak MLT 1_3 koji se nalazi tik uz Značajni krajobraz Baraćeve špilje (Sl. 7.4.3). U ovome uzorku evidentirana je značajna georaznolikost. Uzorak je pokazuje izolaciju u odnosu na ostale uzorke mezo tipa 1_3. Dominantan morfogogenetski tip reljefa u ovome uzorku je fluviokrš, koji je okružen s velikom površinom krškog morfogogenetskog tipa reljefa, te ovdje predstavlja značajnu varijaciju u krajobrazu u odnosu na okružujući prostor. Obzirom na izolaciju i malu površinu uzorka, potrebno je provoditi mjere očuvanja izdvojenog uzorka.




Sl. 7.4.3 Izdvojeni uzorci krajobraza s najvećim vrijednostima kompleksnih krajobraznih gradijenata – prijedlog 3

Na JI dijelu prostora GH prostire se kompleks kontinuiranih uzoraka izdvojenih po iznimnim vrijednostima, a u kontaktu je ili je dio postojećih zaštićenih područja, Hidrološki spomenik prirode Vrelo Une te Park prirode Dinara (Sl. 7.4.4). Uzorak najveće površine pripada mezo tipu MLT 4_1 koji bilježi najveće vrijednosti obilja elemenata georaznolikosti i rijetkih staništa, ali je istovremeno u lošem ekološkom stanju te spada u klasu izrazito fragmentiranih tipova krajobraza. Ovaj kompleks uzoraka prostire se na JI obroncima Plješivice, masivom Poštaka te gorskim hrptom Dinare. Na ovom prostoru izmjenjuje se 10 mezo tipova krajobraza, te tri makro tipa krajobraza. U ovom kompleksu ne pojavljuje se makro tip 1_ Udoline, fragmenti zaravni i krške depresije većih dimenzija. Dominiraju makro tip 2_ Pobrđa i niži pristranci dolinskih strana i makro tip 4_ Niži pristranci i strme dolinske strane.



Sl. 7.4.4 Izdvojeni uzorci krajobraza s najvećim vrijednostima kompleksnih krajobraznih gradijenata – prijedlog 4

Na samom JZ dijelu prostora GH izdvaja se manji kompleks uzoraka krajobraza iznimnih vrijednosti koji je dio postojećeg zaštićenog područja Značajni krajobraz Sutina (Sl. 7.4.5). Ovaj kompleks uzoraka krajobraza rasprostire se I i II dolinskim stranama Svilaje. Uzorak najveće površine pripada mezo tipu MLT 4_1, koji bilježi najveće vrijednosti obilja elemenata georaznolikosti i rijetkih staništa, ali je istovremeno u lošem ekološkom stanju te spada u klasu izrazito fragmentiranih tipova krajobraza. Na izdvojenom prostoru javljaju se tri mezo tipa krajobraza GH koja pripadaju makro tipu 3_Planinski lanci i masivi, izraženi hrptovi i 4_Niži pristranci i strme dolinske strane.




Sl. 7.4.5 Izdvojeni uzorci krajobraza s najvećim vrijednostima kompleksnih krajobraznih gradijenata – prijedlog 5

Vrednovanja krajobraza temeljena na metrici krajobraza te vrijednostima kompleksnih krajobraznih gradijenata ukazuju na prostore sa jedinstvenim obilježjima. Svrha vrednovanja jest izdvajanje prostora koji u sebi nose iznimne krajobrazne vrijednosti koje nemaju utilitarnu vrijednost. Vrijednosti koje nose izdvojena područja su intrinzična vrijednost, znanstvena i edukativna vrijednost. U izdvojenim područjima postoji potencijal proširenja postojećih zaštićenih područja. S druge strane, obzirom da se radi o kompleksima pojedinih uzoraka krajobraza koji su različiti po vertikalnoj strukturi, ali i prema svom ekološkom stanju, stupnju fragmentacije, povezanosti i rijetkosti, moguće je donošenje mjera za poboljšanje/očuvanje ekološkog stanja, usporavanje/zaustavljanje fragmentacije, čime dolazi i do očuvanja rijetkih mezo tipova krajobraza. Pokazatelji metrike krajobraza za svaki mezo tip pokazuju trenutno stanje, što je polazišna točka za praćenje stanja u budućim razdobljima te primjerice pri postupcima procjene utjecaja na okoliš.

Prethodno prikazanih 5 prijedloga proširenja postojećih zaštićenih područja ili prijedloga za zone zaštite u okvirima prostornih planova, iznimno vrijedni kompleksi uzoraka krajobraza

prepoznati su i na površinom najvećem zaštićenom području GH, u Parku prirode Velebit, te unutar nacionalnih parkova koji su prostorno uklopljeni u PP Velebit, a to su NP Sjeverni Velebit i NP Paklenica (Sl. 7.4.6).



Sl. 7.4.6 Izdvojeni uzorci krajobraza s najvećim vrijednostima kompleksnih krajobraznih gradijenata – prostor PP Velebit s ostalim zaštićenim područjima unutar granica PP

Upravo na dijelu sjevernog Velebita je velika koncentracija uzoraka iznimnih vrijednosti koji prekrivaju veliku površinu zaštićenog područja. Na cijelom prostoru PP izmjenjuje se kompleks uzoraka 9 različitih mezo tipova krajobraza. Najzastupljeniji makro tip krajobraza je 4_Niži pristranci i strme dolinske strane, a s jednim mezo tipom manje je zastupljen makro tip 3_Planinski lanci i masivi, izraženi hrptovi. Makro tip 2_Pobrđa i niži pristranci dolinskih strana nije zastupljen na ovom prostoru, dok je makro tip 1_Udoline, fragmenti zaravni i krške depresije većih dimenzija najmanje zastupljen (s dva mezo tipa). Najveći uzorak na ovom prostoru pripada MLT 3_2, a uzorci s najvećim brojem preklapanja vrijednosti pripadaju mezo tipu MLT 4_3. Velika površina i broj uzoraka iznimnih vrijednosti na sjevernom dijelu Velebita mogu biti i odraz dugogodišnje i sustavne zaštite ovoga prostora.

Upravo kompleksni krajobrazni gradijenti koji su u ovu svrhu iskorišteni za provođenje dodatnog vrednovanja krajobraza, u svrhu izdvajanja područja koja su u potrebi za mjerama zaštite, svojom izoliranom pojavnošću koja nije primjetna ljudskim okom u kombinaciji s pokazateljima metrike krajobraza koju također nije moguće percipirati vizualno i bivanjem u krajobrazu, predstavljaju konkretne kvantitativne pokazatelje stanja i potreba krajobraza GH.

7.5. Evaluacija rezultata i metodologije istraživanja


Prostor istraživanja

U ovome radu definirana je fizičkogeografska regija Gorska Hrvatska, koja do sada u takvim granicama nije definirana. Prema globalnoj inventarizaciji planinskih regija za biogeografske svrhe (Körner i dr., 2017; Snethlage i dr., 2022) kontinuirana gorska regija generalno se poklapa s rezultatima navedenih radova. U krupnijem mjerilu (Snethlage i dr., 2022) vidljiva je razlika obzirom da u planinska područja ne pripadaju polja u kršu, obzirom da morfometrijski ne odgovaraju kriterijima izdvajanja, dok je u ovome radu kao morfometrijski kriterij korištena samo nadmorska visina, čime su i polja u kršu te krške zaravni. No, obzirom da su svrha navedenih globalnih inventarizacija biogeografska istraživanja, jasno je kako je detaljnija morfometrija itekako značajna za izdvajanje samo planinskih područja, dok je u ovome radu naglasak na fizičkogeografskim obilježjima i izdvajanju gorskih krajobraza. Preporučljivo bi bilo revidirati granicu s primorske strane Velebita kako bi se očuvala cjelina (planinski lanac).


Površinski pokrov

Prilikom analize pojedinačnih klasa u sve tri klasifikacije, pogreška je najviše raspršena u klasi šuma, a u sve tri klasifikacije najznačajnija pogreška javlja se u zamjeni klasom šume s klasom travnjaka (Sl. 7.5.1). Spektralna sličnost ove dvije klase jasan je odgovor na takvu situaciju, ali zbog klasifikacije Sentinel-2A snimaka, pogreška se smanjuje kombiniranim pristupom, tj. vizualnim odvajanjem po referentnim podlogama. Raspršenost pogreške i izražena zamjena drugom klasom javljaju se i u suprotnoj situaciji, tj. klasa travnjaka najčešće se pogrešno klasificira kao klasa šuma. Najprikladnija metoda za odvajanje spektralno sličnih klasa je korištenje satelitskih snimaka s većom prostornom rezolucijom ili snimaka s bespilotnih letjelica (UAV) u kombinaciji s *deep learning* metodama (Zhang i dr., 2021). Kombinacija s drugim prostornim skupovima podataka, poput klimatskih i topografskih podataka, također dovodi do dobrih rezultata u odvajanju klasa travnjaka i šuma (Ma i dr., 2017). U slučaju krivo

klasificiranih uzoraka klase travnjaka, NKS klasifikacija ima najznačajniju pogrešku, dok klasifikacija snimaka Sentinel-2A ima najmanju pogrešku (Sl. 7.5.2).




Sl. 7.5.1 Postotak netočno klasificiranih točaka koje predstavljaju klasu šume u klasifikacijama Sentinel-2 A, CORINE i NKS



Sl. 7.5.2 Postotak netočno klasificiranih točaka koje predstavljaju klasu travnjaka u klasifikacijama Sentinel-2 A, CORINE i NKS

Klasa poljoprivrednih površina također ima visok postotak pogrešnih klasifikacija u sve tri klasifikacije, ali najveća vrijednost zabilježena je u NKS klasifikaciji, gdje je poljoprivredna površina netočno klasificirana kao šuma u 14,53% točaka. U CORINE klasifikaciji, poljoprivredne površine najčešće su pogrešno klasificirane kao šuma (10,89% točaka) i kao travnjaci (10,89% točaka). U Sentinel-2A klasifikaciji, 3,08% točaka klase poljoprivredne površine pogrešno je klasificirano kao travnjak. Kao i kod pogrešne klasifikacije travnjaka i šuma, uzrok problema leži u sličnom spektralnom potpisu. U (Varga i dr., 2021), CORINE je analiziran kako bi se pokazala podudarnost spektralnih informacija iz Landsat-8, Sentinel-2 i PlanetScope snimaka s CORINE klasama, a analiza na razini klase pokazala je da klase poljoprivrednih površina i močvare imaju najviše problema s pogrešnom klasifikacijom. (Jogun i dr., 2019) proveli su klasifikaciju površinskog pokrova i analizu na temelju Landsat snimaka i izvijestili o najvećoj pogrešnoj klasifikaciji u klasama travnjaka i šikara.

NKS klasifikacija pokazuje značajnu pogrešku (više od 50% točaka) u klasama područja s oskudnom vegetacijom, opožarenih područja i šikara. Jedan od razloga za to je što je glavna svrha NKS-a kartiranje i vizualizacija staništa. NKS je izrađen na temelju Landsat satelitskih snimaka, a 22% klasificiranih poligona provjereno je na terenu. S obzirom na činjenicu da se 22% verificiranih poligona nalazi diljem Hrvatske, nije sigurno da verifikacija podjednako pokriva sve odabrane tipove staništa. CORINE klasifikacija ima značajnu pogrešku (više od 50% točaka) u klasama močvara, opožarenih područja i šikara. Skriveni problem u validaciji podataka koji je vidljiv na primjeru CORINE klasifikacije je klasa izdanaka stijena, koja je 100% točna, ali u samoj klasifikaciji postoji samo jedan poligon klasificiran kao stijenski izdanak na cijelom području istraživanja (Sl. 7.5.3). S druge strane, prema klasifikaciji Sentinel-2A snimaka, gdje je pogreška za ovu klasu 8,8%, površina prekrivena stijenskim izdancima iznosi 319 km². Nasuprot tome, prema NKS klasifikaciji, gdje je pogreška za klasu 12,5 %, površina koju zauzima ova klasa iznosi 167 km². Prema CORINE klasifikaciji, površina prekrivena izdancima stijena na proučavanom području iznosi 0,31 km².



Sl. 7.5.3 Klasa izdanaka stijena i kontrolne točke za CORINE klasifikaciju

NKS i CORINE klasifikacije ne uključuju klasu golog tla, ali s druge strane Sentinel-2A klasifikacija ne uključuje klase močvara, opožarenih područja i šikara. Sve tri klase imaju visok postotak pogreške u klasifikacijama CORINE i NKS (Tab. 7.5.1). Najveći problem su opožarena područja, koja u klasifikaciji CORINE imaju 30% podudaranja s klasom šuma, a u klasifikaciji NKS čak 65% točaka klasificiranih kao opožarena područja pripada klasi šuma. S obzirom na visok postotak podudaranja s klasom šuma, pogreška je prisutna, s obzirom na to da ne može doći do sukcesije iz opožarenog područja u klasu šuma unutar jedne godine. S obzirom na vremensko razdoblje u kojem se takva klasa manifestira i brzu sukcesiju nakon formiranja opožarenog područja, može se reći da je klasa neprikladna za uvrštavanje u karte/baze koje se obnavljaju u više od 2 godine. S druge strane, neki indeksi mogu se koristiti za brzo i jednostavno otkrivanje izgorjelih područja na satelitskim snimkama, kao što je normalizirani omjer izgaranja (NBR) koji se koristi za identifikaciju izgorjelih područja i mjerenje magnitude požara (Chen i dr., 2011). Velika prednost u takvim istraživanjima je što snimke Sentinel-2A imaju vremensku rezoluciju od 5 dana, stoga je požarišta lako detektirati na način da se koristi samo lokalni isječak snimke te da se primijene indeksi za detekciju požarišta. U regionalnom kontekstu, kao što je kontekst karte površinskog pokrova u ovom radu, takve vremenski prolazne klase bolje je izostaviti.

Tab. 7.5.1 Postotak pogreške netočno klasificiranih točaka za klase 90 - močvare, 100 - opožarene površine i 110 - šikare

Iz – U:	Sentinel -2A	% CORI		NK S	Iz – U:	Sentinel -2A	% CORI		NK S	Iz – U:	Sentinel -2A	% CORI		NKS
		NE	S				NE	S				NE	S	
90 - močvare	90 - 8	0	0		100 - 8	0	5			110 - 8	0	0		
	90 - 15	50	20		100 - 15	30	65			110 - 15	30	55,55		
	90 - 20	0	0		100 - 20	0	0			110 - 20	0	0		
	90 - 32	20	0		100 - 32	10	25			110 - 32	10	0		
	90 - 40	30	0		100 - 40	0	0			110 - 40	10	0		
	90 - 50	0	0		100 - 50	10	5			110 - 50	0	0		
	90 - 60	0	0		100 - 60	0	0			110 - 60	0	0		
	90 - 80	0	0		100 - 80	0	0			110 - 80	30	0		
	90 - 90	0	0		100 - 90	0	0			110 - 90	0	0		
	90 - 100	0	0		100 - 100	0	0			110 - 100	0	0		
	90 - 110	0	0		100 - 110	0	0			110 - 100	0	0		
					100 - 110	0	0			110 - 100	0	0		

Klasifikacijom Sentinel-2A snimaka u kombinaciji s vizualnom interpretacijom, pogreške u smislu opsega i raspršenosti po klasama su znatno niže, što je prednost ove metode u detekciji površinskog pokrova. S druge strane, s obzirom na to da je klasifikacijski produkt korištenjem Sentinel-2A snimaka prikazan i u rasterskom i u vektorskom obliku, prostorna rezolucija ove klasifikacije je 10 x 10 m, za CORINE baze 500 x 500 m, dok je za NKS 124,89 x 124,89 m (1,56 ha). U kontekstu daljnjeg korištenja NKS i CORINE baze za tipologiju i analize krajobraza, negativna strana je raspršenost pogrešaka klasifikacije i manja prostorna rezolucija.

Tipologija krajobraza

Zračne fotografije i satelitske snimke nude pogled na komponente krajobraza kao što su površinski pokrov, vrste tala te izgled reljefa, a nekada i njihove odnose. Upravo iz navedenih razloga zračne fotografije i daljinska istraživanja postala su glavni alat u proučavanju krajobraza. Razvojem i dostupnošću satelitskih snimaka postaje lakše proučavati krajobraz u puno većim mjerilima (regionalnim, nacionalnim, pa čak i planetarnim). Ovakvim pristupom postaje moguće kvantificirati krajobraz i njegove komponente što je uistinu teško napraviti samo terenskim radom i “bivanjem” u krajobrazu (Antrop i Van Eetvelde, 2017). Upravo

korištenje daljinskih istraživanja kojima dolazi do bržeg prikupljanja i obrade podataka velike prostorne rezolucije je prednost metodologije izrade tipologije krajobrazu u ovome. Kako je i spomenuto, ovakvim pristupom izrađivač tipologije izmiče se iz krajobrazu, te dobiva pogled odozgo na prostor, te mogućnost razdvajanja svake pojedine komponente vertikalne strukture. Metodologija korištena u ovome radu najbližija je metodologiji izrade tipologije krajobrazu Norveške. Prostor Norveške također je planinski/gorski prostor te da je sam pristup izrađivača najbližiji pristupu u ovome radu (geoekološki pristup) (Erikstad i dr., 2015; Simensen i dr., 2020, 2021). Sami kompleksni krajobrazni gradijenti te varijable za izdvajanje makro i mezo tipova krajobrazu su različiti, jer su GH i Norveška u različitim klimatskim pojasevima, ali je i dostupnost podataka određene tematske i prostorne rezolucije različita. U Norveškoj metodologiji ipak je veći naglasak na geomorfološkim oblicima površine od 2 do 20 km² pri izdvajanju glavnih (makro) tipova krajobrazu, dok su u ovome radu sami geomorfološki oblici korišteni samo kao kompleksni krajobrazni gradijenti, a pokazatelji izvedeni iz digitalnog modela reljefa glavne su varijable za izdvajanje makro tipova krajobrazu. Naglasak u Norveškoj metodologiji je na fizičkoj pojavnosti elemenata strukture krajobrazu te što vjernijeg prikaza varijacije u krajobrazu, što je preneseno i na ovaj rad. Postoji mnoštvo metoda karakterizacije i kartiranja krajobrazu, ali malo ih uzima u obzir da se svojstva krajobrazu postupno i kontinuirano mijenjaju/variraju u više smjerova. U norveškoj metodologiji, kao i u metodologiji ovoga rada izrađena je gradijentna analiza, utemeljena na teoriji ekološkog kontinuuma, za analizu varijacija krajobrazu na velikim prostorima. Cilj je objasniti razlike u svojstvima krajobrazu na najjednostavniji mogući način, identificiranjem „kompleksnih krajobraznih gradijenata“, tj. složenih gradijenata istodobno prisutnih elemenata i svojstava krajobrazu (Simensen i dr., 2020). U ovome radu prikaz varijacije krajobrazu postignut je kroz uključivanje kontinuiranih i diskontinuiranih obilježja reljefa i površinskog pokrova kao varijabli za izdvajanje tipova krajobrazu. Do sada izrađene tipologije krajobrazu u Hrvatskoj obuhvaćale su isključivo vizualne i estetske kvalitete krajobrazu, što je uobičajeno i u mnogim drugim tipologijama na prostoru Europe, koje počivaju na načelima arhitekture i krajobrazne arhitekture. Osim nacionalnih geoekoloških škola obrađenih u uvodnom dijelu ovoga rada, Norveški geoekološki pristup, prema svojim teorijskim postavkama, jedini je kompatibilan pristupu u ovome radu. Razlika u pristupu ovome radu i u norveškom modelu jest to da je u ovome radu naglasak na prikupljanju primarnih podataka, dok je u norveškom modelu naglasak na korištenju postojećih podataka o elementima strukture krajobrazu. Elementi vertikalne strukture krajobrazu u ovome radu, kao i u (Erikstad i dr., 2015) ne obuhvaćaju kulturne te ostale „nematerijalne“ elemente vertikalne strukture krajobrazu. Tercijarnu strukturu ili tzv.

kulturni krajobraz nije moguće kartirati na način na koji se kartiraju fizičke osobine prostora, posebice na regionalnoj ili nacionalnoj razini. Kulturni i doživljajni elementi krajobraza najčešće su predmet karakterizacija krajobraza u lokalnim okvirima (Erikstad i dr., 2015).

Prema (Halvorsen i dr., 2020) sistematizacija varijacije, tj raznolikosti prostora u aspektu krajobraza i (geo)ekosustava još uvijek nedostaje (Ferrer-Paris i dr., 2020; Keith i dr., 2015). Postojeće sistematizacije limitirane su svojim opsegom (prema broju varijabli i prostorno). Generalno takve sistematizacije obuhvaćaju ili tipologiju ili set esencijalnih varijabli npr., Pereira i dr., 2013; Pettorelli i dr., 2016, a rijetko kombinaciju oba pristupa. Na najvišoj razini sistematizacije uvijek se u obzir uzima varijacija jedne varijable, najčešće vegetacija Ewald, 2003; Faber-Langendoen i dr., 2016; Whittaker, 1962. Ono malo primjera sistematizacija koje adresiraju nekoliko aspekata prirodne raznolikosti istovremeno nisu sveobuhvatne, ili su pragmatične, utemeljene na znanjima stručnjaka i dizajnirane za vrlo specifične svrhe (CONNOR i dr., 2004; Davies i dr., 2004; Ferrer-Paris i dr., 2020; Leathwick i dr., 2003; Sayre i dr., 2020). Univerzalna sistematizacija na najvišoj razini mora biti holistička i utemeljena na jasnim principima ukorijenjenim u teoriji ekologije (Halvorsen i dr., 2020).

8. ZAKLJUČCI

Metodama daljinskih istraživanja i analiza u GIS-u determinira su 4 makro tipa te 20 mezo tipova krajobraza Gorske Hrvatske s ukupno 2.146 uzoraka. Za potrebe rada izdvojena je i fizičkogeografska regija Gorska Hrvatska koja svojom površinom zauzima 10.469 km², gotovo 20% kopnenog teritorija Republike Hrvatske.

Primjenom metrike krajobraza na izdvojene tipove krajobraza GH te usporedbom rezultata pokazatelja metrike krajobraza na tipologiji krajobraza i na tipologiji površinskog pokrova GH utvrđena je značajna razlika u vrijednostima pokazatelja. Najznačajniji pokazatelj razlika u stanju površinskog pokrova i krajobraza GH je pokazatelj raznolikosti. Vrijednost Simpsonovog indeksa raznolikosti za površinski pokrov GH iznosi 0,4, dok za krajobraz GH iznosi 0,89. Obzirom da je raspon indeksa od 0-1, razlika u vrijednosti je zaista značajna. Nadalje, primjenom statističkih analiza na rezultatima metrike krajobraza te usporedbom s izdvojenim obilježjima pojedinih tipova krajobraza na makro i mezo razini, utvrđena je uloga primarne strukture krajobraza kao glavne determinante varijacije u krajobrazu. U kriterijima vrednovanja krajobraza, varijacija u vrijednostima kriterija dešava se duž morfometrijskih

obilježja prostora koja su prikazana na makro razini krajobraza. Na mezo razini krajobraza, varijacija je izražena u morfogogenetskim tipovima reljefa, dok dominantan površinski pokrov u mezo tipovima krajobraza pokazuje obilježje uniformnosti. Tim rezultatima potvrđena je prva hipoteza H1 koja pretpostavlja da je upravo uloga primarne strukture krajobraza najznačajnija za izdvajanje tipova krajobraza kroz proces izrade tipologije.

Rezultati tipologije krajobraza i metrike krajobraza GH pretočeni su u vrednovanje krajobraza. Rezultati vrednovanja krajobraza, te rezultati pojedinih kriterija vrednovanja ukazali su na različite vrijednosti u krajobrazu GH, ali i na pojedine mezo tipove krajobraza i pojedine uzorke krajobraza koji se izdvajaju prema nekoliko kriterija vrednovanja i prema kompleksnim krajobraznim gradijentima. Upravo sadržavanje više od jedne vrijednosti u pojedinom mezo tipu ili uzorku mezo tipa krajobraza ukazalo je na prostore GH koji se izdvajaju te samim time posjeduju potencijal za nova zaštićena područja čime je potvrđena druga hipoteza H2. Osim potencijala za stvaranje novih zaštićenih područja ili proširenja postojećih, vrednovanje je ukazalo i na tipove i uzorke krajobraza koji u sebi nose jedinstvene vrijednosti ili skup vrijednosti koji zaslužuju pozornost određenih sektora (prostorno i strateško planiranje te zaštita okoliša u okviru procjena utjecaja na okoliš). Posebice je to važno istaknuti, obzirom da je dosadašnje poimanje krajobraza u RH bilo svedeno na estetske vrijednosti te na samo jedan sloj krajobraza, a to je površinski pokrov.

Potvrđivanjem hipoteza istraživanja ciljevi ovoga rada u potpunosti su postignuti, a to je izrada geografski utemeljene tipologije krajobraza bazirane na elementima primarne strukture za prostor Gorske Hrvatske, koja je primijenjena u provedbi vrednovanja krajobraznih tipova kao temelja za adekvatnu zaštitu i održivo korištenje krajobraza.

U ovome radu postavljen je i horizontalni cilj koje je također postignut, obzirom da je u radu isključivo geografskim metodama, izrađena tipologija krajobraza fizičkogeografske regije. Regija kao prostor istraživanja, te samo izdvajanje regije i izrada tipologije određenih prostornih datosti obilježja su geografije kao polja znanosti. Nadalje, upravo kartiranje i analiza objektivne prostorne stvarnosti sa svim sadržajima, procesima, vezama i odnosima koji su nastali djelovanjem čimbenika prirodne osnove i društvene nadgradnje su predmet istraživanja geografije. Upravo tipologija krajobraza s kvantifikacijom strukture krajobraza te njegovim vrijednostima s ciljem razumijevanja veza, procesa i odnosa među strukturama krajobraza, temelj su za optimalno upravljanje prostorom kroz sektore prostornog i strateškog planiranja te zaštite okoliša. U pregledu dosadašnjih istraživanja krajobraza u RH, jasno su izdvojena dva

pristupa krajobrazu, koja se podudaraju i sa pristupima krajobrazu na europskoj i svjetskoj razini. Geografski, tj. geokološki pristup, krajobraz promatra kroz njegovu vertikalnu i horizontalnu strukturu. Vertikalna i horizontalna struktura krajobraza u takvom pristupu osnova je provođenje vrednovanja kvantitativnim metodama, što je u ovome radu urađeno upravo tim redoslijedom i metodama. Geografski pristup krajobrazu koji sagledava sve razine strukture i pojedine elemente strukture nepobitno daje cjelovit pogled na krajobraz, ali i kvantitativne, mjerljive i prostorno jasno determinirane veličine koje su temelj za očuvanje, planiranje i praćenje krajobraza GH.

Buduća istraživanja potrebno je usmjeriti u detaljniju inventarizaciju prostora GH kako bi se izradili dodatni kompleksni krajobrazni gradijenti koji bi doprinijeli stvaranju kompleksnijeg modela krajobraza GH. Jedan od sljedećih koraka u istraživanju krajobraza GH mora biti i terenska provjera izdvojenih tipova krajobraza na temelju koje će tipologija biti korigirana te na temelju čega će biti izračunati pokazatelji točnosti, kako bi i svako daljnje praćenje krajobraza davalo visoko kvalitetne podatke o promjenama krajobraza. Također, nužna je i daljnja raščlamba krajobraza na nižu prostornu razinu, tj. izdvajanje sub tipova krajobraza. Posebice je bitno usmjeriti istraživanja u uzorke, komplekse uzoraka krajobraza te mezo tipove krajobraza koji su izdvojeni po određenim vrijednostima. Osim onih sa iznimnim vrijednostima, posebice je bitno provoditi mjere praćenja stanja vrlo rijetkih mezo tipova krajobraza i onih koji su izrazito fragmentirani i u lošem ekološkom stanju. Osim navedenog, otvoren je i niz novih pitanja koja je potrebno istražiti, a to je detekcija načina utjecaja geogene fragmentacije krajobraza, tj. identifikacija kvantitativnih pragova mitigacijske ili pogoršavajuće uloge primarne strukture na ekološko stanje krajobraza. Svakako je poželjno na temelju identificiranih tipova krajobraza te njihovih obilježja kvantificiranim metrikom krajobraza, iskoristiti kao ulazne podatke za model promjene krajobraza GH.

Znanstveni doprinos ovoga rada očituje se u sveobuhvatnoj metodologiji za izradu tipologije krajobraza. Obzirom na kompleksnost krajobraza, u ovome radu je krajobraz sagledan kroz vertikalnu i horizontalnu strukturu. Kako bi navedene strukture krajobraza bile determinirane, te kao preduvjet za izradu tipologije krajobraza, osmišljena je i metodologija za kartiranje i analizu podataka o površinskom pokrovu, te pojedine metode za detekciju geomorfoloških oblika i obilježja prostora GH. Za potrebe rada multikriterijskom analizom u GIS-u izdvojena je fizičkogeografska regija Gorska Hrvatska koja odgovara obilježjima planinskih regija (klimatska, vegetacijska i morfometrijska obilježja planinskih regija).

Korištenjem daljinskih istraživanja, GIS analiza te kvantitativnih pokazatelja metrike krajobraza kartirano je i analizirano stanje površinskog pokrova regije Gorska Hrvatska. Kartiranje i analiza površinskog pokrova provedeni su kao prvi korak u daljnjoj analizi cjelokupnog krajobraza, te se u radu koncept površinskog pokrova stavlja u kontekst jedne od komponenti strukture krajobraza. U radu se po prvi puta kvantificira i uspoređuje kvaliteta dobivenih podataka s postojećim podacima široke upotrebe o površinskom pokrovu, a to su EU baza podataka Corine Land Cover te Nacionalna klasifikacija staništa Republike Hrvatske. Rezultati analize točnosti klasifikacije podataka satelitskih snimaka Sentinel 2-A u usporedbi s najčešće korištenim podacima o površinskom pokrovu (Corine Land Cover i Nacionalna klasifikacija staništa RH) pokazuju da klasifikacijom Sentinel 2-A satelitskih snimaka podaci imaju značajno veću prostornu rezoluciju i točnost. Rezultati klasifikacije površinskog pokrova na temelju Sentinel 2-A snimaka podvrgnuti su analizi metrike krajobraza čime je kvantificirano stanje površinskog pokrova Gorske Hrvatske, tj. dan je uvid u strukturu i stanje površinskog pokrova. Metodologija klasifikacije Sentinel 2-A snimaka predstavlja besplatan, brz i precizan način kartiranja površinskog pokrova u planinskim regijama, koje su svojom površinom te svojstvima (dinamičan reljef, nedostupnost) vrlo izazovna područja za precizno kartiranje velike prostorne rezolucije. Nadalje, u radu je primjenom metrike krajobraza na kartiranim klasama površinskog pokrova postavljen temelj za monitoring stanja površinskog pokrova, kvantifikacijom strukture. Rezultatima točnosti klasifikacije površinskog pokrova potvrđeno je i kako je generalizacija u broju klasa poželjnija od povećanja broja klasa. Ako je potrebno povećati broj klasa, terenski rad postaje neizbježan, čime se potencijalni monitoring poskupljuje i produžuje.

Za detekciju i kvantifikaciju primarne strukture krajobraza GH korištene su metode poluautomatske detekcije korištenjem GIS alata, a rezultati dobiveni tim metodama po prvi puta zbirno prikazuju objektivnu stvarnost o geomorfološkim datostima cijelog prostora GH. Nadalje, dobiveni podaci korišteni su kao varijable u daljnjem procesu izrade tipologije krajobraza GH.

U ovome radu po prvi puta su izdvojeni tipovi krajobraza GH na dvije prostorne razine, što predstavlja jedinu regionalnu studiju koja donosi tipologiju krajobraza, sagledavajući sve njegove komponente strukture. Upravo zbog vjerodostojnosti konačne tipologije, poseban je značaj pridat činjenici da svi podaci/varijable budu maksimalno kompatibilni u prostornoj i tematskoj rezoluciji. Metodom multivarijantne klasifikacije izdvojeni su tipovi krajobraza na makro i mezo razini. Također je uveden i koncept kompleksnih krajobraznih gradijenata koji

se često koristi u analizi ekosustava, a rezultati ovoga rada pokazuju kako je to konceptualni okvir prikladan za studije varijacija na razini krajobraza.

Metodologija kartiranja površinskog pokrova prezentirana u radu prilagođena je specifičnim uvjetima planinskih regija, stoga je jedan od doprinosa primjenjivost metodologije u svim planinskim regijama umjerenog pojasa. Prvi puta je kvantificirana struktura površinskog pokrova u Gorskoj Hrvatskoj, čime je izrađeno nulto stanje na temelju kojeg je moguće pratiti promjene pomoću u radu prezentiranih pokazatelja metrike krajobraza. Isti set pokazatelja metrike krajobraza izračunat je i za mezo tipove krajobraza GH što predstavlja prvu kvantifikaciju stanja krajobraza neke regije na teritoriju RH. Usporedbom pokazatelja metrike krajobraza za površinski pokrov i krajobraz GH dobiveni su značajno različiti rezultati koji ukazuju na različitu prostornu pojavnost površinskog pokrova i krajobraza te različite procese koji uvjetuju stanje detektirano pokazateljima metrike krajobraza. Rezultatima kvantifikacije strukture površinskog pokrova Gorske Hrvatske vidljivo je kako je površinski pokrov u ovoj regiji vrlo uniforman, što je suprotno dosadašnjim narativnima koji su ga karakterizirali raznolikim. Prema rezultatima rada površinski pokrov kao komponenta krajobraza Gorske Hrvatske ne pokazuje raznolikost, ali je u izvrsnom ekološkom stanju. Do sada nisu provedena istraživanja krajobraza i njegove vertikalne strukture ili njegovih pojedinačnih komponenti koja bi mogla otkriti veliku krajobraznu raznolikost Gorske Hrvatske. Dosadašnji pristup krajobrazu u HR pa tako i na prostoru GH sagledavao je samo površinski pokrov koji je bio izjednačen s pojmom krajobraz. Ovim radom po prvi puta je kvantificirana struktura krajobraza te njegovo stanje, a rezultati upućuju na loše ekološko stanje, i veliku raznolikost krajobraza GH. Osim toga, u dosadašnjim istraživanjima nije bilo kvantifikacije stanja površinskog pokrova, već su ocjenjivanje njegove estetske/vizualne vrijednosti na pojedinim lokacijama.

Time je ostvaren i doprinos rada u teorijskom aspektu jer mijenja dosadašnji koncept korištenja površinskog pokrova kao istoznačnice krajobrazu, obzirom da krajobraz sa svim svojim komponentama strukture ima potpuno drugačija obilježja od površinskog pokrova. Uputno je ne izjednačavati ta dva pojma, te zasebno, kartirati i analizirati površinski pokrov kao jednu od komponenti krajobraza.

Obzirom na manjkavost nacionalne infrastrukture podataka o okolišu te nekompatibilnost podataka u prostornoj i tematskoj rezoluciji, u ovom radu prezentirana je metodologija koja je ponovljiva u bilo kojem periodu, bez ovisnosti o periodama objave podataka na nacionalnoj razini te njihovoj prostornoj rezoluciji. Upravo površinski pokrov sloj je krajobraza podložan

najbržim promjenama, stoga je u ovome radu stavljen i veliki naglasak na metodologiju klasifikacije površinskog pokrova, koja je ponovljiva svakih 6 dana, obzirom da satelit Sentinel 2-A na istu točku dolazi svakih 6 dana. Predstavljena metodologija izrade tipologije krajobraza te rezultati primjene metrike krajobraza i vrednovanja krajobraza čine efikasan pristup za praćenje stanja i brzu detekciju promjena (bilo pozitivnih ili negativnih) s primjenom u sektorima zaštite okoliša, prostornog i regionalnog planiranja. Kompleksi uzoraka izdvojenih vrednovanjem predloženi za dodatne mjere zaštite predstavljaju prvi korak u zaštiti krajobraza na krajobraznoj razini, a ne na razini uzorka. Ovakva analitička podloga je za daljnje zaštitne radnje, a to su:

- Prevencija nastavka fragmentacije na uzorcima u najlošijem stanju.
- Prioritizacija očuvanja velikih uzoraka.
- Rješavanje problema koji utječu na fizički okoliš i kompoziciju kompleksa uzoraka na većim prostornim razinama, kao što su promijenjeni hidrološki režimi i gustoća prometnica i drugih prepreka.
- Povećanje povezanosti krajobraza stvaranjem regionalnih i lokalnih kompleksa uzoraka krajobraza.
- Stvaranje scenarija i modela budućeg razvoja krajobraza kao podloge za donošenje upravljačkih strategija.
- Integracija istraživačkih i upravljačkih aktivnosti.

9. PRILOZI

Prilog I. Tablica vrednovanja krajobraza GH

Tip krajobraza	Ekološko stanje					Ekološko stanje bodovi	Fragmentacija		Fragmentacija bodovi	Povezanost		Povezanost bodovi	Učestalost			Učestalost bodovi
	LPI	TE	ED	SHAPE_AM	PARA_AM		NLSI	MESH		ENN_AM	CA		AREA_MN	AREA_AM	PLAND	
1_1	3	1	1	1	2	8	2	1	3	1	1	1	1	1	1	4
1_2	1	3	3	1	1	9	3	3	6	2	2	3	3	3	3	12
1_3	1	3	3	2	1	10	3	3	6	2	2	3	3	3	3	12
1_4	1	3	3	1	1	9	1	3	4	2	2	3	2	3	3	11
1_5	1	3	3	2	2	11	2	3	5	3	3	3	1	3	3	10
2_1	3	1	1	1	1	7	3	1	4	1	1	1	2	1	1	5
2_2	1	2	2	1	1	7	3	3	6	2	2	3	3	3	3	12
2_3	1	3	3	1	1	9	3	3	6	3	3	3	3	3	3	12
2_4	1	3	3	2	1	10	3	1	4	3	3	3	3	3	3	12
2_5	1	3	3	2	1	10	3	1	4	3	3	3	3	3	3	12
3_1	1	2	2	1	1	7	3	3	6	1	1	2	3	3	2	10
3_2	2	3	3	1	2	11	2	3	5	1	1	2	1	1	2	6
3_3	1	3	3	2	1	10	3	3	6	2	2	3	3	3	2	11
3_4	1	3	3	2	1	10	3	3	6	1	1	3	3	3	3	12
3_5	1	3	3	2	1	10	3	3	6	3	3	3	3	3	3	12
4_1	1	2	2	1	1	7	3	3	6	1	1	2	3	3	2	10
4_2	1	2	2	2	1	8	3	3	6	2	2	3	3	3	3	12
4_3	1	3	3	1	1	9	3	3	6	2	2	3	2	3	3	11
4_4	1	3	3	1	1	9	3	1	4	3	3	3	3	3	3	12
4_5	1	3	3	2	1	10	3	1	4	3	3	3	3	3	3	12
Tip krajobraza	Obilje speleoloških objekata	Obilje plavina	Obilje ponikava	Obilje hidrogeoloških pojava	Obilje drenažne mreže	Obilje grebena	Prisutnost kanjona/duboko usječenih dolina	Obilje ugroženih staništa	Elementi georaznolikosti bodovi	Frekvencija poljoprivredne aktivnosti	Frekvencija antropogene aktivnosti	Utjecaj čovjeka bodovi	Ukupni bodovi			
1_1	2	2	2	2	2	2	2	3	17	2	1	3	36			
1_2	1	3	3	2	3	1	2	3	18	1	2	3	50			
1_3	1	3	2	3	3	2	2	2	18	3	2	5	53			
1_4	1	2	1	2	2	1	2	2	13	1	1	2	41			
1_5	1	2	2	2	2	1	2	3	15	1	2	3	47			
2_1	2	1	3	2	2	3	2	2	17	2	1	3	37			
2_2	1	3	1	3	3	2	2	2	17	2	2	4	48			
2_3	1	2	1	2	2	2	2	3	15	2	3	5	50			
2_4	1	1	1	3	2	2	2	3	15	2	2	4	48			
2_5	1	1	1	1	2	2	2	2	12	3	3	6	47			
3_1	3	2	2	2	2	3	2	2	18	3	3	6	48			
3_2	3	1	2	3	2	3	2	2	18	3	3	6	47			
3_3	3	2	1	2	2	3	2	2	17	3	3	6	52			
3_4	3	1	1	2	2	3	2	3	17	2	3	5	51			
3_5	1	1	1	2	2	2	2	2	13	2	3	5	49			
4_1	2	3	2	3	3	2	3	2	20	2	2	4	48			
4_2	2	1	2	3	2	2	3	2	17	2	3	5	50			
4_3	2	3	1	3	3	2	3	2	19	3	3	6	53			
4_4	1	3	1	2	3	1	3	2	16	2	3	5	49			
4_5	2	1	2	3	2	2	3	2	17	2	3	5	51			

10. POPIS LITERATURE I IZVORA

- Almeida, C., Coutinho, A., Dalla, J., Esquerdo, M., Adami, M., Venturieri, A., Diniz, C., Dessay, N., Durieux, L., i Gomes, A. (2016). High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. *Acta Amazonica*, 291, 291–302. <https://doi.org/10.1590/1809-4392201505504>
- Andlar, G. (2025). *Metodološki vodič za izradu krajobraznih osnova u Republici Hrvatskoj*. Sveučilište u Zagrebu, Agronomski fakultet, Zelena infrastruktura d.o.o.
- Aničić, B., i Koščak, V. (1999). *Krajolik, Sadržajna i metoda podloga Krajobrazne osnove Hrvatske*. Ministarstvo prostornog uređenja, graditeljstva i stanovanja i Agronomski fakultet Sveučilišta u Zagrebu.
- Antonić, O., Kušan, V., Bakran-Petricioli, T., Alegro, A., Gottstein, S., Peternel, H., i Tkalcec, Z. (2005). Klasifikacija staništa Republike Hrvatske. *Drypis*, 1.
- Antrop, M. (1997). The concept of traditional landscapes as a base for landscape evaluation and planning. The example of Flanders Region. *Landscape and Urban Planning*, 38(1), 105–117. [https://doi.org/10.1016/S0169-2046\(97\)00027-3](https://doi.org/10.1016/S0169-2046(97)00027-3)
- Antrop, M. (2004). Editorial: Landscape research in Europe. *Belgeo. Revue Belge de Géographie*, (2–3), 199–208. <https://doi.org/10.4000/belgeo.13796>
- Antrop, M. (2005). From holistic landscape synthesis to transdisciplinary landscape management. In *From landscape research to landscape planning: Aspects of integration, education and application* (pp. 27–50). <http://hdl.handle.net/1854/LU-339574>
- Antrop, M. (2013). A brief history of landscape research. In *The Routledge Companion to Landscape Studies*. Routledge.
- Antrop, M., i Van Eetvelde, V. (2000). Holistic aspects of suburban landscapes: Visual image interpretation and landscape metrics. *Landscape and Urban Planning*, 50(1), 43–58. [https://doi.org/10.1016/S0169-2046\(00\)00079-7](https://doi.org/10.1016/S0169-2046(00)00079-7)
- Antrop, M., i Van Eetvelde, V. (2017). Landscape perspectives: The holistic nature of landscape. In *ISSN: 1572-7742* (Vol. 23). Springer. <http://hdl.handle.net/1854/LU-8547609>
- Bastian, O., Glawion, R., Haase, D., Haase, G., Klink, H.-J., Steinhardt, U., i Volk, M. (2002). Landscape analysis, synthesis, and diagnosis. In O. Bastian i U. Steinhardt (Eds.),

- Development and Perspectives of Landscape Ecology* (pp. 113–168). Springer Netherlands. https://doi.org/10.1007/978-94-017-1237-8_3
- Bastian, O., Krönert, R., i Lipský, Z. (2006). Landscape Diagnosis on Different Space and Time Scales – A Challenge for Landscape Planning. *Landscape Ecology*, 21(3), 359–374. <https://doi.org/10.1007/s10980-005-5224-1>
- Bauer, C. (2015). Analysis of dolines using multiple methods applied to airborne laser scanning data. *Geomorphology*, 250, 78–88. <https://doi.org/10.1016/j.geomorph.2015.08.015>
- Bennett, A., i Saunders, D. (2011). Habitat Fragmentation and Landscape Change. In *Conservation Biology for All* (Vol. 93, pp. 88–106). <https://doi.org/10.1093/acprof:oso/9780199554232.003.0006>
- Bhandari, A. K., Kumar, A., i Singh, G. K. (2012). Feature Extraction using Normalized Difference Vegetation Index (NDVI): A Case Study of Jabalpur City. *Procedia Technology*, 2nd International Conference on Communication, Computing i Security, 6, 612–621. <https://doi.org/10.1016/j.protcy.2012.10.074>
- Blaće, A. (2014). Razvoj i suvremena preobrazba krajolika naselja Danilskog polja kod Šibenika. *Ekonomika i ekohistorija : časopis za gospodarsku povijest i povijest okoliša*, 10(1), 173–188.
- Blaće, A., i Čuka, A. (2016). Razvoj krajolika i poljoprivrede zemunčkog područja (*The development of the landscape and agriculture in the Zemunik area*) (pp. 260–271).
- Bognar, A. (1992). Inženjerskogeomorfološko kartiranje. *Acta Geographica Croatica*, 27(1), 173–184.
- Bogovac, L., Kamenečki, M., Pereković, P., Hrdalo, I., i Tomić Reljić, D. (2025). Regionalization of the Croatian Landscape: An Integrative Approach to Methods and Criteria for Defining Boundaries. *Land*, 14(10), 2068. <https://doi.org/10.3390/land14102068>
- Bohn, U., Zazanashvili, N., i Nakhutsrishvili, G. (2007). The Map of the Natural Vegetation of Europe and its application in the Caucasus Ecoregion. *Bulletin of the Georgia Academy of Science*, 175, 112–121.
- Bonsu, K., i Bonin, O. (2023). Assessing landscape fragmentation and its implications for biodiversity conservation in the Greater Accra Metropolitan Area (GAMA) of Ghana. *Discover Environment*, 1(1), 22. <https://doi.org/10.1007/s44274-023-00023-z>

- Botequilha-Leitão, A., Miller, J., Ahern, J., i McGarigal, K. (2006). *Measuring Landscapes: A Planner's Handbook*.
- Bralić, I. (1999). Krajobrazno diferenciranje i vrednovanje s obzirom na prirodna obilježja. In V. Koščak i B. Aničić, *Krajolik. Sadržajna i metodska podloga Krajobrazne osnove Hrvatske* (pp. 101–109). Ministarstvo prostornog uređenja, graditeljstva i stanovanja i Agronomski fakultet Sveučilišta u Zagrebu, Zagreb.
- Braun, M., i Herold, M. (2004). *Mapping imperviousness using NDVI and linear spectral unmixing of ASTER data in the Cologne-Bonn region (Germany)*. 5239, 274–284.
<https://doi.org/10.1117/12.510978>
- Butorac, V., i Buzjak, N. (2020). Geodiversity and Landscape Services in the Region of Ogulinsko-Plašćanska Zavala, Croatia. *Ekológia (Bratislava)*, 39(2), 130–144.
<https://doi.org/10.2478/eko-2020-0010>
- Butorac, V., i Buzjak, N. (2021). Prilog poznavanju (novijih) istraživanja krajobraza u Hrvatskoj 1945. – 2019. Godine. *Hrvatski geografski glasnik*, 83(1), 25–56.
<https://doi.org/10.21861/HGG.2021.83.01.02>
- Butula, S. (2008). Landscape Evaluation and Public Preferences: Is there Room for Optimisation? *Agriculturae Conspectus Scientificus*, 73(2), 109–114.
- Butula, S. (2009). PUBLIC PREFERENCES TOWARDS LANDSCAPE IDENTITY – A CASE STUDY OF RIPARIAN LANDSCAPES IN CROATIA. *Društvena Istraživanja : Časopis Za Opća Društvena Pitanja*, 18(3 (101)), 479–501.
- Cahalan, M. D., i Milewski, A. M. (2018). Sinkhole formation mechanisms and geostatistical-based prediction analysis in a mantled karst terrain. *CATENA*, 165, 333–344.
<https://doi.org/10.1016/j.catena.2018.02.010>
- Ćalić, J. (2011). Karstic uvala revisited: Toward a redefinition of the term. *Geomorphology, Geomorphology and Natural Hazards in Karst Areas*, 134(1), 32–42.
<https://doi.org/10.1016/j.geomorph.2011.06.029>
- Čanjevaca, I., Pavlek, K., i Orešić, D. (2022). Duljine tekućica u Hrvatskoj određene na temelju topografske karte mjerila 1: 25 000. *Hrvatski geografski glasnik*, 84(1), 5–30.
<https://doi.org/10.21861/HGG.2022.84.01.01>

- Chahouki, M. A. Z. (2013). Classification and Ordination Methods as a Tool for Analyzing of Plant Communities. In *Multivariate Analysis in Management, Engineering and the Sciences*. IntechOpen. <https://doi.org/10.5772/54101>
- Chen, X., Vogelmann, J. E., Rollins, M., Ohlen, D., Key, C. H., Yang, L., Huang, C., i Shi, H. (2011). Detecting post-fire burn severity and vegetation recovery using multitemporal remote sensing spectral indices and field-collected composite burn index data in a ponderosa pine forest. *International Journal of Remote Sensing*, 32(23), 7905–7927. <https://doi.org/10.1080/01431161.2010.524678>
- Congedo, L. (2021). Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. *Journal of Open Source Software*, 6(64), 3172. <https://doi.org/10.21105/joss.03172>
- CONNOR, D., ALLEN, J., Golding, N., Howell, K., LIEBERKNECHT, L., NORTHEN, K., i Reker, J. (2004). *The Marine Habitat Classification for Britain and Ireland Version 04.05 JNCC*.
- Crkvenčić, I. (1958). Prigorje planinskog niza Ivančice. *Acta Geographica Croatica*, 1(1), 7–113.
- Crkvenčić, I. (1975). *Geografija SR Hrvatske IV. Gorska Hrvatska*. Školska knjiga.
- Csorba, P., Lóczy, D., i Mezosi, G. (2004). Recent landscape research in Hungary. *Belgeo. Revue Belge de Géographie*, (2–3), 289–300. <https://doi.org/10.4000/belgeo.13813>
- Davies, C., Moss, D., i Hill, M. (2004). *EUNIS habitat classification revised 2004*.
- De Montis, A. (2014). Impacts of the European Landscape Convention on national planning systems: A comparative investigation of six case studies. *Landscape and Urban Planning*, 124, 53–65. <https://doi.org/10.1016/j.landurbplan.2014.01.005>
- Degen, R., Aune, M., Bluhm, B. A., Cassidy, C., Kedra, M., Kraan, C., Vandepitte, L., Wlodarska-Kowalczyk, M., Zhulay, I., Albano, P. G., Bremner, J., Grebmeier, J. M., Link, H., Morata, N., Nordstrom, M. C., Shojaei, M. G., Sutton, L., i Zuschin, M. (2018). Trait-based approaches in rapidly changing ecosystems: A roadmap to the future polar oceans. *Ecological Indicators*, 91, 722–736. <https://doi.org/10.1016/j.ecolind.2018.04.050>
- Demek, J. (1978). The landscape as a geosystem. *Geoforum*, 9(1), 29–34. [https://doi.org/10.1016/0016-7185\(78\)90022-2](https://doi.org/10.1016/0016-7185(78)90022-2)

- Demek, J., i Mapping. (1972). *Manual of detailed geomorphological mapping*.
<https://www.semanticscholar.org/paper/Manual-of-detailed-geomorphological-mapping-Demek-Mapping/31d0bb85d9e29b536487a9a1b7d614bc3ada586e>
- Dobrowski, S. Z. (2011). A climatic basis for microrefugia: The influence of terrain on climate. *Global Change Biology*, 17(2), 1022–1035. <https://doi.org/10.1111/j.1365-2486.2010.02263.x>
- Doctor, D. H., i Young, J. A. (2013). *An evaluation of automated GIS tools for delineating karst sinkholes and closed depressions from 1-meter LIDAR-derived digital elevation data*. 449–458. <https://doi.org/10.5038/9780979542275.1156>
- Dumbović Bilušić, B. (2015). *Krajolik kao kulturno naslijeđe*. Ministarstvo kulture i medija Republike Hrvatske.
- Dumbović Bilušić, B., i Obad Šćitaroci, M. (2013). Zaštita krajolika; Usporedba zakonodavne osnove u Hrvatskoj i europskim zemljama. *Prostor : znanstveni časopis za arhitekturu i urbanizam*, 21(1(45)), 104–115.
- Durbešić, A., i Fuerst-Bjeliš, B. (2016). Tipovi i trendovi promjene pejzaža planina Svilaje – Ogorje. *Ekonomika i ekohistorija : časopis za gospodarsku povijest i povijest okoliša*, 12(1), 208–221.
- Durbešić, A., i Fuerst-Bjeliš, B. (2017). Utjecaj promjene pejzaža na rizik od požara. In V. Kapitanović, N. Marinov, i M. Matas (Eds.), *Župa Ogorje. Putovima života i vjere između Svilaje i Moseća* (pp. 79–96). Kulturni sabor Zagore ; Franjevačka Provincija Presvetog Otkupitelja ; Župa sv. Jure mučenika Ogorje ; Župa sv. Franje Asiškog, Crivac ; Odsjek za povijest Filozofskog fakulteta Sveučilišta u Splitu.
- El-Kawy, O. R., Rød, J. K., Ismail, H., i Suliman, A. (2011). Land use and land cover change detection in the Western Nile Delta of Egypt using remote sensing data. *Applied Geography - APPL GEOGR*, 31, 483–494. <https://doi.org/10.1016/j.apgeog.2010.10.012>
- Erikstad, L., Uttakleiv, L. A., i Halvorsen, R. (2015). Characterisation and mapping of landscape types, a case study from Norway. *Belgeo. Revue Belge de Géographie*, (3).
<https://doi.org/10.4000/belgeo.17412>
- Esposito, L., Leone, G., Ginolfi, M., Chenari, S. A., Fiorillo, F., Esposito, L., Leone, G., Ginolfi, M., Chenari, S. A., i Fiorillo, F. (2025). Mapping of Closed Depressions in Karst Terrains: A GIS-Based Delineation of Endorheic Catchments in the Alburni Massif

- (Southern Apennine, Italy). *Hydrology*, 12(7).
<https://doi.org/10.3390/hydrology12070186>
- Ewald, J. (2003). A critique for phytosociology. *Journal of Vegetation Science*, 14(2), 291–296.
<https://doi.org/10.1111/j.1654-1103.2003.tb02154.x>
- Faber-Langendoen, D., Keeler-Wolf, T., Meidinger, D., Josse, C., Weakley, A., Tart, D., Navarro, G., Hoagland, B., Ponomarenko, S., Fults, G., i PhD, E. H. (2016). Classification and description of world formation types. *Gen. Tech. Rep. RMRS-GTR-346. Fort Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station*. 222 p., 346. <https://doi.org/10.2737/RMRS-GTR-346>
- Fang, L., Yang, L., Liu, Q., i Ou, M. (2026). Exacerbating or mitigating landscape fragmentation: Exploring the role of topographic heterogeneity in shaping landscape patterns in China. *Environmental Impact Assessment Review*, 116, 108091.
<https://doi.org/10.1016/j.eiar.2025.108091>
- Ferreira, C. F., Hussain, Y., Uagoda, R., Silva, T. C., i Cicerelli, R. E. (2023). UAV-based doline mapping in Brazilian karst: A cave heritage protection reconnaissance. *Open Geosciences*, 15(1). <https://doi.org/10.1515/geo-2022-0535>
- Ferrer-Paris, J., Keith, D., Nicholson, E., i Kingsford, R. (2020). *IUCN Global Ecosystem Typology 2.0: Descriptive profiles for biomes and ecosystem functional groups*.
<https://doi.org/10.2305/IUCN.CH.2020.13.en>
- Foody, G. M. (2020). Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, 239, 1–37. <https://doi.org/10.1016/j.rse.2019.111630>
- Forman, R. T. T., i Godron, M. (1986). *Landscape Ecology* (First Edition). John Wiley i Sons.
- Franklin, J. F., i Forman, R. T. T. (1987). Creating landscape patterns by forest cutting: Ecological consequences and principles. *Landscape Ecology*, 1(1), 5–18.
<https://doi.org/10.1007/BF02275261>
- Friganović, M. (1961). Polja gornje Krke. *Acta Geographica Croatica*, 3.(1.), 8–164.
- Fuerst-Bjeliš, B. (2018). Deforestacija i reforestacija u hrvatskome dinarskom kršu: Odnosi i implikacije. *Ekonomika i ekohistorija : časopis za gospodarsku povijest i povijest okoliša*, 14(1), 136–144.

- Fuerst-Bjeliš, B., i Kale, J. (2018). *POVIJESNA DINAMIKA KULTURNIH KRAJOLIKA ŠIBENSKOG PODRUČJA* (pp. 545–561).
- Fuerst-Bjeliš, B., i Vukosav, B. (2019). Landscape of identities in shared spaces of the borderlands. *Europa Regional*, 26.2018(2), 5–13.
- Gams, I. (1978). The polje: The problem of definition. With special regard to the Dinaric karst. *Zeitschrift Für Geomorphologie*, 170–181. <https://doi.org/10.1127/zfg/22/1978/170>
- Garrigues, S., Allard, D., Baret, F., i Weiss, M. (2006). Quantifying spatial heterogeneity at the landscape scale using variogram models. *Remote Sensing of Environment*, 103(1), 81–96. <https://doi.org/10.1016/j.rse.2006.03.013>
- Gašparović, S., i Sopina, A. (2018). Uloga pejzaža u planiranju grada Zagreba od početka 20. Do početka 21. Stoljeća. *Prostor : znanstveni časopis za arhitekturu i urbanizam*, 26(1(55)), 132–145. [https://doi.org/10.31522/p.26.1\(55\).10](https://doi.org/10.31522/p.26.1(55).10)
- GESSLER, P. E., MOORE (deceased), I. D., McKENZIE, N. J., i RYAN, P. J. (1995). Soil-landscape modelling and spatial prediction of soil attributes. *International Journal of Geographical Information Systems*, 9(4), 421–432. <https://doi.org/10.1080/02693799508902047>
- Gökyer, E. (2013). Understanding Landscape Structure Using Landscape Metrics. In *Advances in Landscape Architecture*. IntechOpen. <https://doi.org/10.5772/55758>
- Gruber, S., i Peckham, S. (2009). Chapter 7 Land-Surface Parameters and Objects in Hydrology. In *Developments in Soil Science* (Vol. 33, pp. 171–194). [https://doi.org/10.1016/S0166-2481\(08\)00007-X](https://doi.org/10.1016/S0166-2481(08)00007-X)
- Gustafson, E. (1998). Quantifying Landscape Spatial Pattern: What Is the State of the Art? *Ecosystems*, 1, 143–156. <https://doi.org/10.1007/s100219900011>
- Halvorsen, R., Skarpaas, O., Bryn, A., Bratli, H., Erikstad, L., Simensen, T., i Lieungh, E. (2020). Towards a systematics of ecodiversity: The EcoSyst framework. *Global Ecology and Biogeography*, 29(11), 1887–1906. <https://doi.org/10.1111/geb.13164>
- Hamzić, M., i Fuerst-Bjeliš, B. (2021a). Primjena prostorne i dijakronijsko-procesne analize razvoja krajolika na području Srednje Like (Hrvatska) od 1980. Do 2012. *Hrvatski geografski glasnik*, 83(2), 33–58. <https://doi.org/10.21861/HGG.2021.83.02.02>

- Hamzić, M., i Fuerst-Bjeliš, B. (2021b). Razvojni tipovi krajolika srednje Like 1980–2012 – primjena prostorno i procesno orijentiranog GIS-modela. *Kartografija i geoinformacije*, 20(35), 5–29. <https://doi.org/10.32909/kg.20.35.1>
- Hamzić, M., Fuerst-Bjeliš, B., i Pahernik, M. (2020). Structural Characteristics of Patches in the Central Lika Landscape – Application of Spatial and Regression Analysis. *Kartografija i Geoinformacije*, 19, 14–38. <https://doi.org/10.32909/kg.19.34.2>
- Hazeu, G. W., Metzger, M. J., Múcher, C. A., Perez-Soba, M., Renetzeder, Ch., i Andersen, E. (2011). European environmental stratifications and typologies: An overview. *Agriculture, Ecosystems i Environment, Scaling Methods in Integrated Assessment of Agricultural Systems*, 142(1), 29–39. <https://doi.org/10.1016/j.agee.2010.01.009>
- Heymann, Y., Steenmans, C., Croisille, G., Bossard, M., Lenco, M., Wyatt, B., Weber, J.-L., O'Brien, C., Cornaert, M.-H., i Sifakis, N. (1994). *Corine Land Cover Technical Guide, Part I*.
- Hofierka, J., Gallay, M., Bandura, P., i Šašak, J. (2018). Identification of karst sinkholes in a forested karst landscape using airborne laser scanning data and water flow analysis. *Geomorphology*, 308, 265–277. <https://doi.org/10.1016/j.geomorph.2018.02.004>
- Hubrich, H. (1993). *Kurswissen Landschaftsökologie: Eine Einführung in die Grundbegriffe, Probleme und Methoden*. Klett.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Jaeger, J. (2000). Landscape division, splitting index, and effective mesh size: New measures of landscape fragmentation. *Landscape Ecology*, 15, 115–130. <https://doi.org/10.1023/A:1008129329289>
- Jenks. (1967). The Data Model Concept in Statistical Mapping International. *International Yearbook of Cartography*, 7, 186–190.
- Jogun, T., Lukić, A., i Gašparović, M. (2019). Simulation model of land cover changes in a post-socialist peripheral rural area: Požega-Slavonia County, Croatia. *Hrvatski Geografski Glasnik*, 81(1), 31–59. <https://doi.org/10.21861/HGG.2019.81.01.02>
- Jovanić, M. (2017). *GIS analiza i razvojna tipologija krajolika Srednje Like*. University of Zagreb. Faculty of Science. Department of Geography.

- Keith, D., Rodríguez, J., Brooks, T., Burgman, M., Barrow, E., Bland, L., Comer, P., Franklin, J., Link, J., McCarthy, M., Miller, R., Murray, N., Nel, J., Nicholson, E., Oliveira-Miranda, M., Regan, T., Rodríguez-Clark, K., Rouget, M., i Spalding, M. (2015). The IUCN Red List of Ecosystems: Motivations, Challenges, and Applications. *Conservation Letters*, 8. <https://doi.org/10.1111/conl.12167>
- Komšo, K., Butula, S., i Reljić, D. T. (2023). Landscape planning as a tool for preserving the landscape values of the Dinara Nature Park. *Acta Horticulturae et Regiotecturae*, 26(2), 99–108. <https://doi.org/10.2478/ahr-2023-0014>
- Körner, C., Jetz, W., Paulsen, J., Payne, D., Rudmann-Maurer, K., i M. Spehn, E. (2017). A global inventory of mountains for bio-geographical applications. *Alpine Botany*, 127(1), 1–15. <https://doi.org/10.1007/s00035-016-0182-6>
- Kozová, M., Hrnčiarová, T., Drdoš, J., i Elias sen, P. (2007). *Landscape Ecology in Slovakia: Development, current state, and perspectives*.
- Kranjc, A. (2006). Some large dolines in the Dinaric karst. *Speleogenesis and Evolution of Karst Aquifers*, 4.
- Krcho, J. (1978). The spatial organisation of the physical-geographical sphere as a cybernetic system expressed by means of measure as entropy. *Acta Facultatis Rerum Naturalium Universitas Comenianae (Geographica)*, 16, 57–147.
- Krönert, R., Volk, M., i Steinhardt, U. (2001). Introduction: Landscape balance and landscape assessment. In R. Krönert, U. Steinhardt, i M. Volk (Eds.), *Landscape Balance and Landscape Assessment* (pp. 1–22). Springer. https://doi.org/10.1007/978-3-662-04532-9_1
- Kwa, C. (2005). Alexander von Humboldt's invention of the natural landscape. *The European Legacy*, 10(2), 149–162. <https://doi.org/10.1080/1084877052000330084>
- Leathwick, J., Morgan, F., Wilson, G., Rutledge, D., Mcleod, M., i Johnston, K. (2003). *Land Environments of New Zealand: A Technical Guide*.
- Lee, J. T., Elton, M. J., i Thompson, S. (1999). The role of GIS in landscape assessment: Using land-use-based criteria for an area of the Chiltern Hills Area of Outstanding Natural Beauty. *Land Use Policy*, 16(1), 23–32. [https://doi.org/10.1016/S0264-8377\(98\)00033-7](https://doi.org/10.1016/S0264-8377(98)00033-7)
- Liu, H., i Wang, L. (2006). An efficient method for identifying and filling surface depressions in digital elevation models for hydrologic analysis and modelling. *International Journal of*

- Geographical Information Science*, 20, 193–213.
<https://doi.org/10.1080/13658810500433453>
- Lončar, J., i Cvitanović, M. (2012). (Post)socijalizam i okoliš: Promjena kulturnoga krajobraza Pridravske nizine Osijeka u posljednjih pedeset godina. *Sociologija i prostor : časopis za istraživanje prostornoga i sociokulturnog razvoja*, 50(3 (194)), 327–343.
<https://doi.org/10.5673/sip.50.3.3>
- Lozić, S. (1995). Vertikalna raščlanjenost reljefa kopnenog dijela Republike Hrvatske. *Acta Geographica Croatica*, 30.(1.), 17–26.
- Lozić, S. (1996). Nagibi padina kopnenog dijela Republike Hrvatske. *Acta Geographica Croatica*, 31.(1.), 41–49.
- Lozić, S., Krklec, K., i Perica, D. (2012). Tipologija otoka Visa temeljena na geološkim, geomorfološkim i pedološkim karakteristikama prirodnog i kulturnog krajobraza. *NAŠE MORE : znanstveni časopis za more i pomorstvo*, 59(1–2), 82–91.
- Lozić, S., Šiljeg, A., i Krklec, K. (2013). Strukturne značajke suhozidne mreže kao pokazatelji antropogenog utjecaja na krajobraz – primjer južnog dijela otoka Visa, Hrvatska. *Annales. Series historia et sociologia*, 23(2), 501–518.
- Lozić, S., Šiljeg, A., Krklec, K., Jurišić, M., i Šiljeg, S. (2013). Some Basic Indices of Horizontal Landscape Structure of the Southern Part of Vis Island, Croatia. *Geodetski List*, 67 (90)(2), 67–92.
- Lozic, S., Šiljeg, A., Krklec, K., i Šiljeg, S. (2012). Vertical landscape structure of the southern part of Vis Island, Croatia. *Dela*, 37, 65–90. <https://doi.org/10.4312/dela.37.4.65-90>
- Lozić, S., Šiljeg, A., Krklec, K., i Šiljeg, S. (2012). Vertikalna struktura površja na južnom delu otoka Vis, Hrvatska. *Dela*, (37), 65–90. <https://doi.org/10.4312/dela.37.65-90>
- Lukić, A. (2012). *Mozaik izvan grada – tipologija ruralnih i urbaniziranih naselja Hrvatske*.
<https://www.bib.irb.hr:8443/594606>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., i Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Maerker, M., Quénéhervé, G., Bachofer, F., i Mori, S. (2015). A simple DEM assessment procedure for gully system analysis in the Lake Manyara area, northern Tanzania. *Natural Hazards*, 79(1), 235–253. <https://doi.org/10.1007/s11069-015-1855-y>

- Magaš, D. (2013). *Geografija Hrvatske*. https://shop-hr.unizd.hr/detalji_proizvoda.b4f955abc64e4aeabf157fb1e4a26f74.geografija-hrvatske.aspx
- Marangoz, A., Sekertekin, A., i Akcin, H. (2017). *Analysis of Land Use Land Cover Classification Results Derived From Sentinel-2 Image*.
- Marić, M., i Grgurević, O. (2007). Krajobraz – suvremena europska kretanja, slovenski model i iskustva, stanje u Hrvatskoj. *Prostor : znanstveni časopis za arhitekturu i urbanizam*, 15(2(34)), 274–281.
- McGarigal, K. (2013). Landscape Pattern Metrics. In *Encyclopedia of Environmetrics*. John Wiley i Sons, Ltd. <https://doi.org/10.1002/9780470057339.val006.pub2>
- McGarigal, K., i Marks, B. J. (1995). FRAGSTATS: Spatial pattern analysis program for quantifying landscape structure. *Gen. Tech. Rep. PNW-GTR-351*. Portland, OR: U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station. 122 p, 351. <https://doi.org/10.2737/PNW-GTR-351>
- McHugh, M. (2012). Interrater reliability: The kappa statistic. *Biochemia Medica : Časopis Hrvatskoga Društva Medicinskih Biokemičara / HDMB*, 22, 276–282. <https://doi.org/10.11613/BM.2012.031>
- Meeus, J. H. A. (1995). Pan-European landscapes. *Landscape and Urban Planning*, 31(1), 57–79. [https://doi.org/10.1016/0169-2046\(94\)01036-8](https://doi.org/10.1016/0169-2046(94)01036-8)
- Metzger, M. J., Bunce, R. G. H., Jongman, R. H. G., Múcher, C. A., i Watkins, J. W. (2005). A climatic stratification of the environment of Europe. *Global Ecology and Biogeography*, 14(6), 549–563. <https://doi.org/10.1111/j.1466-822X.2005.00190.x>
- Mihevc, A., Prelovšek, M., i Hajna, N. Z. (2010). Introduction to the Dinaric Karst. In ZRC SAZU, Založba ZRC. ZRC SAZU, Založba ZRC. <https://doi.org/10.3986/9789612541989>
- Mitchell, M. G. E., Suarez-Castro, A. F., Martinez-Harms, M., Maron, M., McAlpine, C., Gaston, K. J., Johansen, K., i Rhodes, J. R. (2015). Reframing landscape fragmentation's effects on ecosystem services. *Trends in Ecology i Evolution*, 30(4), 190–198. <https://doi.org/10.1016/j.tree.2015.01.011>
- Múcher, C. A., Bunce, R. G. H., Jongman, R. H. G., Klijn, J. A., Koomen, A. J. M., Metzger, M. J., i Wascher, D. M. (2003). *Identification and characterisation of environments and*

- landscapes in Europe*. <https://research.wur.nl/en/publications/identification-and-characterisation-of-environments-and-landscape/>
- Mucher, C. A., Klijn, J. A., Wascher, D. M., i Schaminée, J. H. J. (2010). A new European Landscape Classification (LANMAP): A transparent, flexible and user-oriented methodology to distinguish landscapes. *Ecological Indicators*, 10(1), 87–103. <https://doi.org/10.1016/j.ecolind.2009.03.018>
- Mucher, S., i Wascher, D. (2008). European Landscape Characterisation. *Europe's Living Landscapes : Essays on Exploring Our Identity in the Countryside*.
- Naidoo, R., Aylward, C., Elliott, W., Keeley, A., Kinnaird, M., Knight, M., Papp, C.-R., Thapa, K., i Antelo, R. (2025). From science to impact: Conserving ecological connectivity in large conservation landscapes. *Proceedings of the National Academy of Sciences*, 122(31), e2410937122. <https://doi.org/10.1073/pnas.2410937122>
- Nedd, R., Light, K., Owens, M., James, N., Johnson, E., i Anandhi, A. (2021). A Synthesis of Land Use/Land Cover Studies: Definitions, Classification Systems, Meta-Studies, Challenges and Knowledge Gaps on a Global Landscape. *Land*, 10(9), Article 9. <https://doi.org/10.3390/land10090994>
- Norini, G., Zuluaga, M. C., Ortiz, I. J., Aquino, D. T., i Lagmay, A. M. F. (2016). Delineation of alluvial fans from Digital Elevation Models with a GIS algorithm for the geomorphological mapping of the Earth and Mars. *Geomorphology*, 273, 134–149. <https://doi.org/10.1016/j.geomorph.2016.08.010>
- Obad Šćitaroci, M., Dumbović Bilušić, B., Bojanić Obad Šćitaroci, B., i Božić, N. (2014). *KRAJOLIK – ČIMBENIK STRATEGIJE PROSTORNOG RAZVOJA stručna podloga za Strategiju prostornog razvoja Republike Hrvatske*. HRVATSKI ZAVOD ZA PROSTORNI RAZVOJ.
- Osmar Abílio De Carvalho, J., Guimarães, R. F., Montgomery, D. R., Gillespie, A. R., Gomes, R. A. T., Martins, É. D. S., Silva, N. C., Osmar Abílio De Carvalho, J., Guimarães, R. F., Montgomery, D. R., Gillespie, A. R., Gomes, R. A. T., Martins, É. D. S., i Silva, N. C. (2013). Karst Depression Detection Using ASTER, ALOS/PRISM and SRTM-Derived Digital Elevation Models in the Bambuí Group, Brazil. *Remote Sensing*, 6(1), 330–351. <https://doi.org/10.3390/rs6010330>

- Palang, H., Printsman, A., Gyuró, É. K., Urbanc, M., Skowronek, E., i Woloszyn, W. (2006). The Forgotten Rural Landscapes of Central and Eastern Europe. *Landscape Ecology*, 21(3), 347–357. <https://doi.org/10.1007/s10980-004-4313-x>
- Pantić, M. (2015). Delineation of mountains and mountain areas in Europe—A planning approach. *Journal of the Geographical Institute Jovan Cvijic, SASA*, 65, 43–58. <https://doi.org/10.2298/IJGI1501043P>
- Pavić, R. (1978). *Prilozi analizi socijalno-geografske strukture Gorskog Kotara i Ogulinsko-plašćanske submontane udoline (doktorska dizertacija)*. <https://www.antikvarijatz.hr/knjige/prilozi-analizi-socijalno-geografske-strukture-gorskog-kotara-i-ogulinsko-plascanske-submontane-udoline-doktorska-dizertacija/68578/>
- Pelorosso, R., Apollonio, C., Rocchini, D., i Petroselli, A. (2021). Effects of Land Use-Land Cover Thematic Resolution on Environmental Evaluations. *Remote Sensing*, 13(7), Article 7. <https://doi.org/10.3390/rs13071232>
- Pereira, H., Ferrier, S., Walters, M., Geller, G., Scholes, R., Bruford, M., Brummitt, N., Butchart, S., Cardoso, A., Coops, N., Dulloo, M., Faith, D., Freyhof, J., Gregory, R., Heip, C., Höft, R., Hurtt, G., Jetz, W., i Wegmann, M. (2013). Essential Biodiversity Variables. *Science (New York, N.Y.)*, 339, 277–278. <https://doi.org/10.1126/science.1229931>
- Pereković, P., i Kamenečki, M. (2019). Značaj periurbanih krajobraza za vizualne kvalitete grada Zagreba. *Journal of Central European Agriculture*, 20(4), 1224–1247. <https://doi.org/10.5513/JCEA01/20.4.2373>
- Perko, D., i Ciglič, R. (2015). Slovenia as a European landscape hotspot. *Acta Geobalcanica*, 1, 45–54. <https://doi.org/10.18509/AGB.2015.05>
- Perko, D., Hrvatin, M., i Ciglič, R. (2015). A methodology for natural landscape typification of Slovenia. *Acta Geographica Slovenica*, 55(2), 235–270. <https://doi.org/10.3986/AGS.1938>
- Pettorelli, N., Wegmann, M., Skidmore, A., Múcher, S., Dawson, T. P., Fernandez, M., Lucas, R., Schaepman, M. E., Wang, T., O'Connor, B., Jongman, R. H. G., Kempeneers, P., Sonnenschein, R., Leidner, A. K., Böhm, M., He, K. S., Nagendra, H., Dubois, G., Fatoyinbo, T., ... Geller, G. N. (2016). Framing the concept of satellite remote sensing essential biodiversity variables: Challenges and future directions. *Remote Sensing in Ecology and Conservation*, 2(3), 122–131. <https://doi.org/10.1002/rse2.15>

- Planchon, O., i Darboux, F. (2002). A fast, simple and versatile algorithm to fill the depressions of digital elevation models. *Catena*, 46, 159–176. [https://doi.org/10.1016/S0341-8162\(01\)00164-3](https://doi.org/10.1016/S0341-8162(01)00164-3)
- Rogić, V. (1958). Velebitska primorska padina. *Acta Geographica Croatica*, 2.(1.), 8–119.
- Rogić, V. (1962). Fizionomska i funkcionalna regionalizacija Hrvatske. *Zbornik VI.Kongresa Geografov FLRJ*.
- Rogić, V. (1963). Geografski koncept regije. *Hrvatski geografski glasnik*, 25.(1.), 113–119.
- Rogić, V. (1977). Regionalizacija Gorske Hrvatske. *Hrvatski geografski glasnik*, 39.(1.), 25–43.
- Rogić, V. (1983). Nacrt uvjetno homogene regionalizacije SR Hrvatske. *Hrvatski geografski glasnik*, 45.(1.), 75–89.
- Romanillos, G., Robazza, G., i Lovato, F. (2024). A fragmented world: Mapping the global extent of Anthropogenic Landscape Fragmentation. *Journal of Maps*, 20(1), 2307539. <https://doi.org/10.1080/17445647.2024.2307539>
- Romportl, D., i Chuman, T. (2012). Present Approaches to Landscape Typology in the Czech Republic. *Journal of Landscape Ecology*, 5. <https://doi.org/10.2478/v10285-012-0057-5>
- Rosa, I., i Carreiras, J. (2017). Spatial and temporal dimensions of landscape fragmentation across the Brazilian Amazon. *Regional Environmental Change*, 17. <https://doi.org/10.1007/s10113-017-1120-x>
- Rossi, V., Krtalić, A., i Buzjak, N. (2025). Land cover mapping in mountainous Croatia using Sentinel-2A satellite imagery. *Environmental Earth Sciences*, 84(17), 499. <https://doi.org/10.1007/s12665-025-12510-y>
- Saunders, D. A., Hobbs, R. J., i Margules, C. R. (1991). Biological Consequences of Ecosystem Fragmentation: A Review. *Conservation Biology*, 5(1), 18–32. <https://doi.org/10.1111/j.1523-1739.1991.tb00384.x>
- Sayre, R., Karagulle, D., Frye, C., Boucher, T., Wolff, N. H., Breyer, S., Wright, D., Martin, M., Butler, K., Van Graafeiland, K., Touval, J., Sotomayor, L., McGowan, J., Game, E. T., i Possingham, H. (2020). An assessment of the representation of ecosystems in global protected areas using new maps of World Climate Regions and World Ecosystems. *Global Ecology and Conservation*, 21, e00860. <https://doi.org/10.1016/j.gecco.2019.e00860>

- Seif, A. (2015). *Using Topography Position Index for Landform Classification (Case study: Grain Mountain)*. [https://www.semanticscholar.org/paper/Using-Topography-Position-Index-for-Landform-\(Case-Seif/cf145ac0ad4a83fa2e8efd9cbcc84bc6c919a7fd](https://www.semanticscholar.org/paper/Using-Topography-Position-Index-for-Landform-(Case-Seif/cf145ac0ad4a83fa2e8efd9cbcc84bc6c919a7fd)
- Sertel, E., Topaloğlu, R. H., Şallı, B., Yay Algan, I., i Aksu, G. A. (2018). Comparison of Landscape Metrics for Three Different Level Land Cover/Land Use Maps. *ISPRS International Journal of Geo-Information*, 7(10), Article 10. <https://doi.org/10.3390/ijgi7100408>
- Simensen, T., Erikstad, L., i Halvorsen, R. (2021). Diversity and distribution of landscape types in Norway. *Norsk Geografisk Tidsskrift - Norwegian Journal of Geography*, 75(2), 79–100. <https://doi.org/10.1080/00291951.2021.1892177>
- Simensen, T., Halvorsen, R., i Erikstad, L. (2020). *Gradient analysis of landscape variation in Norway* (p. 2020.06.19.161372). bioRxiv. <https://doi.org/10.1101/2020.06.19.161372>
- Snethlage, M. A., Geschke, J., Ranipeta, A., Jetz, W., Yoccoz, N. G., Körner, C., Spehn, E. M., Fischer, M., i Urbach, D. (2022). A hierarchical inventory of the world's mountains for global comparative mountain science. *Scientific Data*, 9(1), 149. <https://doi.org/10.1038/s41597-022-01256-y>
- Swanwick, C. (2002). *Landscape Character Assessment, Guidance for England and Scotland*. he Countryside Agency and Scottish Natural Heritage. <https://www.scirp.org/reference/referencespapers?referenceid=1014097>
- Tandarić, N., Ćosić, M., Buzjak, N., Bočić, N., Dubovečak, V., Lacković, I., Zastavniković, I., i Tomić, D. (2018). Fizičkogeografska analiza i geoekološko vrednovanje potencijalno zaštićenog područja—Primjer doline Kupčine. *Hrvatski geografski glasnik*, 80(1), 27–59. <https://doi.org/10.21861/HGG.2018.80.01.02>
- Thölke, P., Mantilla-Ramos, Y.-J., Abdelhedi, H., Maschke, C., Dehgan, A., Harel, Y., Kemtur, A., Mekki Berrada, L., Sahraoui, M., Young, T., Bellemare Pépin, A., El Khantour, C., Landry, M., Pascarella, A., Hadid, V., Combrisson, E., O'Byrne, J., i Jerbi, K. (2023). Class imbalance should not throw you off balance: Choosing the right classifiers and performance metrics for brain decoding with imbalanced data. *NeuroImage*, 277, 1–14. <https://doi.org/10.1016/j.neuroimage.2023.120253>
- Tichopádová, E., i Romportl, D. (2014). A typology of natural landscapes of Central Europe. *GEOGRAPHICA*, 49, 57–63. <https://doi.org/10.14712/23361980.2014.15>

- Tobler, W. R. (1970). A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography*, 46, 234–240. <https://doi.org/10.2307/143141>
- Topaloğlu, R. H., Sertel, E., i Musaoğlu, N. (2016). ASSESSMENT OF CLASSIFICATION ACCURACIES OF SENTINEL-2 AND LANDSAT-8 DATA FOR LAND COVER / USE MAPPING. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B8, 1055–1059. XXIII ISPRS Congress, Commission VIII (Volume XLI-B8) - 12indash;19 July 2016, Prague, Czech Republic. <https://doi.org/10.5194/isprs-archives-XLI-B8-1055-2016>
- Troll, C. (1939). Luftbildplan und ökologische Bodenforschung. *Zeitschrift Der Gesellschaft Für Erdunde*, 7(8), 241–298.
- Turner, M. G. (1989). Landscape Ecology: The Effect of Pattern on Process. *Annual Review of Ecology, Evolution, and Systematics*, 20(Volume 20, 1989), 171–197. <https://doi.org/10.1146/annurev.es.20.110189.001131>
- US EPA, O. (2017, November 2). *Land Use* [Reports and Assessments]. <https://www.epa.gov/report-environment/land-use>
- Van Eetvelde, V., i Antrop, M. (2009). A stepwise multi-scaled landscape typology and characterisation for trans-regional integration, applied on the federal state of Belgium. *Landscape and Urban Planning*, 91(3), 160–170. <https://doi.org/10.1016/j.landurbplan.2008.12.008>
- Varga, O. G., Kovács, Z., Bekő, L., Burai, P., Csátriné Szabó, Z., Holb, I., Ninsawat, S., i Szabó, S. (2021). Validation of Visually Interpreted Corine Land Cover Classes with Spectral Values of Satellite Images and Machine Learning. *Remote Sensing*, 13(5), Article 5. <https://doi.org/10.3390/rs13050857>
- Velić, I., i Vlahović, I. (2009). *Tumač geološke karte 1:300.000*. Hrvatski geološki institut.
- Viana, C. M., Oliveira, S., Oliveira, S. C., i Rocha, J. (2019). 29—Land Use/Land Cover Change Detection and Urban Sprawl Analysis. In H. R. Pourghasemi i C. Gokceoglu (Eds.), *Spatial Modeling in GIS and R for Earth and Environmental Sciences* (pp. 621–651). Elsevier. <https://doi.org/10.1016/B978-0-12-815226-3.00029-6>
- Vianello, A., i D’Agostino, V. (2007). Bankfull width and morphological units in an alpine stream of the dolomites (Northern Italy). *Geomorphology, Mountain Rivers II: Channel Processes*, 83(3), 266–281. <https://doi.org/10.1016/j.geomorph.2006.02.023>

- Vizzari, M., i Sigura, M. (2013). Urban-rural gradient detection using multivariate spatial analysis and landscape metrics. *Journal of Agricultural Engineering*, 44.
<https://doi.org/10.4081/jae.2013.333>
- Wall, J., Bohnenstiehl, D., Wegmann, K., i Levine, N. (2017). Morphometric comparisons between automated and manual karst depression inventories in Apalachicola National Forest, Florida, and Mammoth Cave National Park, Kentucky, USA. *Natural Hazards*, 85. <https://doi.org/10.1007/s11069-016-2600-x>
- Walz, U. (2015). Indicators to monitor the structural diversity of landscapes. *Ecological Modelling, Use of Ecological Indicators in Models*, 295, 88–106.
<https://doi.org/10.1016/j.ecolmodel.2014.07.011>
- Wascher, D. M. (2005). *European landscape character areas: Typologies, cartography and indicators for the assessment of sustainable landscapes*.
<https://research.wur.nl/en/publications/european-landscape-character-areas-typologies-cartography-and-ind/>
- Weiss, A. D. (2001). *Topographic position and landforms analysis*.
<https://www.semanticscholar.org/paper/Topographic-position-and-landforms-analysis-Weiss/221157f21f5f9c479de7328f03f980251708af09>
- Whittaker, R. H. (1962). Classification of natural communities. *The Botanical Review*, 28(1), 1–239. <https://doi.org/10.1007/BF02860872>
- Wilson, J. P., i Gallant, J. (2000). *Terrain analysis: Principles and applications*.
<https://www.semanticscholar.org/paper/Terrain-analysis-%3A-principles-and-applications-Wilson-Gallant/b42e384e7ad6d2c93e87ab37809a7d178aac7d00>
- Winkler, K., Fuchs, R., Rounsevell, M., i Herold, M. (2021). Global land use changes are four times greater than previously estimated. *Nature Communications*, 12(1), 1–10.
<https://doi.org/10.1038/s41467-021-22702-2>
- Zhang, C., Zhang, L., Zhang, B., Sun, J., Dong, S., Wang, X., Li, Y., Xu, J., Chu, W., Dong, Y., i Wang, P. (2021). Land cover classification in a mixed forest-grassland ecosystem using LResU-net and UAV imagery. *Journal of Forestry Research*, 33.
<https://doi.org/10.1007/s11676-021-01375-z>
- Zwolinski, Z., i Stefańska, E. (2015). *Relevance of moving window size in landform classification by TPI* (pp. 273–278).