Povijesno kartiranje vegetacije korištenjem arhivskih Landsat snimaka

Špadina, Barbara

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:192071

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet

Biološki odsjek

Barbara Špadina

POVIJESNO KARTIRANJE VEGETACIJE KORIŠTENJEM ARHIVSKIH LANDSAT SNIMAKA

Diplomski rad

Zagreb, 2019.

Ovaj rad je izrađen u Botaničkom zavodu Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, pod vodstvom prof. dr. sc. Svena Jelaska. Rad je predan na ocjenu Biološkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu radi stjecanja zvanja magistre eksperimentalne biologije (mag. biol. exp.), modul botanika

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Biološki odsjek

Diplomski rad

POVIJESNO KARTIRANJE VEGETACIJE KORIŠTENJEM LANDSAT ARHIVSKIH SNIMAKA

Barbara Špadina

Rooseveltov trg 6. 10000 Zagreb, Hrvatska

Vegetacijske karte su topografski prikazi sastava i rasprostranjenosti biljnih zajednica nekog područja te kao takve predstavljaju značajan izvor informacija. Retrospektivnim kartiranjem omogućuje se uvid u prošlost i pružanje osnove na temelju koje je moguće odrediti tijek i intenzitet okolišnih promjena. S ciljem provjere mogućnosti dopune starih terenskih vegetacijskih karata iz druge polovice 20. stoljeća koje pokrivaju područja PP Medvednica, PP Žumberak-Samoborsko gorje i NP Krka, metodom kontrolirane klasifikacije u okviru geografskog informacijskog sustava analizirane su slobodno dostupne Landsat arhivske satelitske snimke. Na svim analiziranim područjima, algoritam *maximum likelihood* se pokazao pouzdanijim od algoritma *minimum distance*. Kontrola točnosti procesa klasifikacije pokazala je vrlo slabo podudaranje klasificiranih klasa i kontrolnih klasa karte staništa za područje PP Medvednica čije Kappa vrijednosti iznose 0,121 za *maximum likelihood* i 0,065 za *minimum distance* algoritam, dok se najpouzdanijim pokazalo područje PP Žumberak-Samoborsko gorje s Kappa vrijednostima od 0,716 za *maximum likelihood* i 0,616 za *minimum distance* algoritam. Za sjevernu satelitsku snimku područja NP Krka Kappa vrijednosti iznose 0,620 za *maximum likelihood* i 0,456 za *minimum distance* algoritam, a za južnu satelitsku snimku 0,511 za *maximum likelihood* i 0,245 za *minimum distance* algoritam. S povećanjem broja kartiranih klasa, točnost klasifikacije se smanjuje. Rezultati ovog istraživanja ukazuju na ograničenu mogućnost primjene Landsat arhivskih snimaka za potrebe retrospektivnog kartiranja.

(47 stranica, 12 slika, 17 tablica, 45 literaturnih navoda, 2 priloga, jezik izvornika: hrvatski)

Rad je pohranjen u Središnjoj biološkoj knjižnici.

Ključne riječi: kartiranje vegetacije, retrospektivno kartiranje, daljinsko promatranje, GIS, Landsat TM

Voditelj: dr. sc. Sven Jelaska, prof.
Ocjenitelji: dr. sc. Sven Jelaska, prof.
dr.sc. Ivana Maguire, prof.
dr.sc. Sofia Ana Blažević, doc.
Zamjena: dr.sc. Tomislav Ivanković, doc.
Rad prihvaćen: 02.05.2019.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Division of Biology

Graduation thesis

HISTORICAL VEGETATION MAPPING USING LANDSAT ARCHIVE IMAGES

Barbara Špadina

Rooseveltov trg 6, 10000 Zagreb, Croatia

Vegetation maps represent the composition and distribution of plant communities of an area and thereby are a significant source of information. Retrospective mapping can provide an insight into the past and provide a basic point according to which it is possible to determine the course and intensity of the environmental changes. This research examines the possibilities of supplementing the old field vegetation maps from the second half of the 20th century that cover the areas of Nature parks Medvednica and Žumberak-Samoborsko gorje and National park Krka, using the supervised classification of Landsat archive satellite images in a geographic information system environment. The results suggest that "maximum likelihood" algorithm was more reliable than the "minimum distance" algorithm in all analyzed areas. The accuracy analysis of the classification process showed very poor matching of classified classes and control classes of habitat maps for the area of Nature park Medvednica whose Kappa values are 0.121 for "maximum likelihood" and 0.065 for "minimum distance" algorithm, while the most reliable area was Nature park Žumberak-Samoborsko gorje with Kappa values of 0.716 for "maximum likelihood" and 0.616 for the "minimum distance". For the northern satellite image of the National park Krka area, the Kappa values are 0.620 for "maximum likelihood" and 0.456 for the "minimum distance" and for the southern satellite image 0.511 for "maximum likelihood" and 0.245 for the "minimum distance" algorithm. With increase of mapped classes, obtained accurracy decreased. The results of this research indicate limited possibilities of using Landsat archive imagery for the purpose of retrospective mapping.

(47 pages, 12 pictures, 17 tables, 45 references, 2 appendices, original in: Croatian)

Thesis deposited in the Central Biological Library.

Key words: vegetation mapping, retrospective mapping, remote sensing, GIS, Landsat TM

Supervisor: dr.sc. Sven Jelaska, prof.
Reviewers: dr.sc. Sven Jelaska, prof.
dr.sc. Ivana Maguire, prof.
dr.sc. Sofia Ana Blažević, asst. Prof.
Substitute: dr.sc. Tomislav Ivanković, Asst. Prof.
Thesis accepted: 02.05.2019.

Htjela bih najprije zahvaliti svojoj majci Lidiji, kojoj i posvećujem ovaj rad, na neizmjernom strpljenju i ljubavi te mudrim savjetima tijekom cijelog mog školovanja i dosadašnjeg života. Trebala sam ih bolje čuti.

Htjela bih zahvaliti i Goranu koji me trpio u svim najgorim stanjima moje svijesti.

Također, htjela bih zahvaliti svom mentoru Svenu na velikom strpljenju i ohrabrujućim riječima podrške u najkritičnijm trenutcima izrade ovog rada. Vas ću se uvijek sjetiti kada ću od stresa bježati u šumu.

Hvala i svima onima koji su mi pomogli razgovorom, prijedlozima i podrškom tijekom ovih dugih dviju godina izrade diplomskog rada.

Sadržaj

1 Uvod 1
1.1 Vegetacijsko kartiranje 1
1.2 Daljinsko promatranje 2
1.3 Cilj istraživanja 5
2 MATERIJALI I METODE 5
2.1 Područje istraživanja 5
2.2 Korištene prostorne podloge 5
2.2.1 Rukopisne vegetacijske karte 6
2.2.2 Satelitske snimke 6
2.3 Analiza podataka 7
2.3.1 Preliminarna obrada podataka 7
2.3.2 Klasifikacija satelitskih snimaka 8
2.3.3 Obrada klasificiranih satelitskih snimaka 9
2.3.4 Usporedba ispravnosti klasifikacije 9
3 REZULTATI 11
3.1 Rezultati preliminarne obrade podataka 11
3.2 Rezultati klasifikacije satelitskih snimaka 11
3.3 Rezultati post-obrade satelitskih snimaka 18
3.4 Rezultati usporedbe ispravnosti klasifikacije 20
4 RASPRAVA 33
5 ZAKLJUČAK 38
6 LITERATURA 39
7 Prilozi 43

1 Uvod

1.1 Vegetacijsko kartiranje

Smatra se kako prve karte vegetacije, one nalik današnjim suvremenim vegetacijskim kartama, potječu iz 19. stoljeća (Küchler i Zonneveld 1967, Jelaska 2009), no tek razvoj fitocenologije početkom 20. stoljeća u Europi značajno doprinosi naglom porastu interesa botaničara za kartiranje. Vegetacijske karte u suvremenom znanstvenom smislu jesu topografski prikazi koji u sebi sadrže prikaz sastava i rasprostranjenosti biljnih zajednica prisutnih na nekom području i kao takve predstavljaju značajan izvor informacija (Šugar 1969).

Određivanje i taksonomska sistematizacija biljnih zajednica i njihovih međuodnosa dovela je i do potrebe za otvaranjem instituta posebno specijaliziranih za kartiranje vegetacije, poput *Service de la Carte de la Végétation e la France a*u 1:200 000 u Toulouse-u i *Service de la Carte des Groupments Végétaux de la France au* 1:20 000 u Montepellier-u kasnije preimenovanog u *Centre d'Etudes Phytosociologiques et Ecologiques Louis Emberger*. Instituti za kartiranje vegetacije otvaraju se i u Njemačkoj (*Bundesstelle für Vegetationskartierung*) i Belgiji (*Centre de Cartographie Phytosociologique*), dok se švicarski *Geobotanical Research Institute* u Zürichu smatra centrom fitocenološkog istraživanja i kartiranja. U brojnim drugim državama Europe počinju se objavljivati vegetacijske karte pa tako i u tadašnjoj Jugoslaviji (Küchler & Zonneveld 1967).

Prve karte na kojima je zabilježena vegetacija s područja Hrvatske, javljaju se već u 18. i 19. stoljeću u sklopu vojnih karata Austrije i na njima je vegetacija bila podijeljena na šume, travnjake, močvare, vinograde i usjeve (Jelaska 2009). Nešto kasnije, početkom 20. stoljeća, vegetacija Hrvatske obuhvaćena je u prikazima vegetacije ilirskih, odnosno balkanskih zemalja, no na njima nisu bile prikazane vegetacijske jedinice korištene od 30-tih godina prošlog stoljeća nadalje. Do sredine 20. stoljeća u Hrvatskoj se, po uzoru na Europu, razvila ideja i želja za kartiranjem vegetacije pa je tako u razdoblju od 1963.-1986. vršeno terensko kartiranje vegetacije Hrvatske od strane članova Odsjeka za vegetacijsku kartu u tadašnjem Institutu za botaniku Sveučilišta u Zagrebu. Kartiranje se vršilo u mjerilu 1:50 000 te je iskartirana ukupna površina od 16 700 km^2 što čini skoro jednu trećinu ukupne površine Hrvatske. Projekt kartiranja vegetacije Hrvatske nikada nije dovršen u cijelosti. Do 1994. je tiskano sveukupno 14 vegetacijskih karata u mjerilu 1: 100 000 na kojima je obrađeno područje Slavonije, Istre, Gorskog kotara, Like i dalmatinskog zaleđa sve do Splita, otoci od Istre do Šibenika zajedno sa primorjem, dok karte područja Samoborskog i Žumberačkog gorja te karte dijelova Hrvatskog zagorja i područja oko Jastrebarskog nikada nisu otisnute (Šugar 1994).

Fitocenološka istraživanja provođena na području Hrvatske od 20. stoljeća do danas počivaju na metodi Zürich-Montepellier fitocenološke škole koja kao osnovnu jedinicu vegetacije koristi fitocenozu, odnosno biljnu zajednicu ili asocijaciju (Šegulja i Hršak 1988). Fitocenološke, odnosno vegetacijske snimke nekog područja daju nam uvid u sastav biljnih zajednica na

određenom području, ali i mnogo više. Prisutnost određene biljne zajednice ukazuje na klimatske faktore područja na kojem se pojavljuje, na količinu svjetlosti i vlage, govori nam o svojstvima tla i sastavu stijena na kojima raste te je ovisna o geografskom položaju. Pojavnost i rasprostranjenost biljnih zajednica ovisi o abiotičkim kao i biotičkim faktorima. Vegetacijska karta time predstavlja znanstveni alat za tumačenje ekoloških faktora i zaključivanje o odnosima između biljnih zajednica (Braun-Blanquet 1932) pa tako i vegetacijska karta Hrvatske predstavlja jedan od osnovnih izvora informacija o sastavu flore i tipovima staništa u RH i uz dodatna terenska istraživanja pruža temelje za postavljanje planova upravljanja određenim zaštićenim područjima ili pak uključivanje u nacionalnu ekološku mrežu (Mitić i sur. 2009). Prema Zakonu o zaštiti prirode RH (NN 80/13) stanište se definira kao jedinstvena funkcionalna jedinica kopnenog ili vodenog ekosustava, određena geografskim, biotičkim i abiotičkim svojstvima, neovisno o tome je li prirodno ili doprirodno. Sva staništa iste vrste čine jedan stanišni tip (čl. 7. toč. 52). S obzirom da se za potrebe kartiranja u Hrvatskoj tijekom 20. stoljeća najviše koristila srednjo-europska metoda klasifikacije prema Braun-Blanquetu (1964), ova fitocenološka podjela biljnog pokrova poslužila je kao osnova pri kartiranju staništa. Na temelju stečenih znanja i iskustava odabrani tim stručnjaka osmislio je i izradio plan Nacionalne klasifikacije staništa sa ciljem uspostave mreže ekološki važnih i zaštićenih područja te je proveden projekt kartiranja staništa Hrvatske (2000.-2004.) gdje su stare vegetacijske karte korištene kao podloge i reference za interpretaciju i kontrolu točnosti rezultata dobivenih klasifikacijom satelitskih Landsat ETM+ snimaka (Antonić i sur. 2005). Dobivena karta staništa je prostorni prikaz rasprostranjenosti stanišnih tipova na području Republike Hrvatske i kao takva podložna je konstantnim promjenama koje mogu biti uzrokovane prirodnim ili antropogenimm djelovanjem (http://www.haop.hr, pristupljeno 7.12.2018.). Kvalitetni povijesni izvori o vegetaciji određenog područja u vidu vegetacijskih karata vrlo su bitni za praćenje dinamike vegetacije nekog područja sa ciljem predviđanja utjecaja klimatskih promjena, ali i za praćenje stanja staništa u svrhu zaštite i očuvanja (Thorne i sur. 2006).

1.2 Daljinsko promatranje

Daljinsko promatranje je pojam koji označava postupak dobivanja informacija/podataka o Zemljinoj površini bez direktnog kontakta na temelju elektromagnetskih signala koje sastavnice Zemljine površine poput vegetacije, stijena ili voda emitiraju (Campbell i Wynn 2011). Tehnologija daljinskog promatranja temelji se na senzorima koji detektiraju i sakupljaju informacije u obliku elektromagnetskih valova koje sastavnice Zemljine površine emitiraju ili reflektiraju s površine te ih pohranjuje u obliku vizualne snimke koju je moguće interpretirati. Prije pojave prvih umjetnih satelita u Zemljinoj orbiti, tehnika daljinskog promatranja svodila se na snimanje, točnije fotografiranje iz zraka, što je omogućavalo brže, jeftinije i preglednije kartiranje. Nakon Drugog svjetskog rata, lansiranjem satelita te kasnijim razvojem i unapređenjem optičkih i računalnih tehnologija daljinsko promatranje se dovodi na novu razinu.

Jedna od najvećih prednosti korištenja tehnologije daljinskoga snimanja jest njeno vrlo široko područje primjene. Nakon lansiranja prve serije američkog Landsat satelita, kao samo neka od

mogućih područja primjene satelitskih snimaka navode se agrikultura, šumarstvo, geologija, hidrologija, kao i mogućnost promatranja zemljišnog pokrova. Revolucionarna je bila spoznaja da je na temelju različitih spektralnih refleksija i emisija moguće identificirati, opisati i kategorizirati sastavnice Zemljinog pokrova s krajnjim ciljem izrade karata promatranih područja (Lauer i sur. 1997). Satelitske snimke odličan su alat pri detekciji i identifikaciji prirodnih staništa, a time i lociranju vrsta usko vezanih za određeni tip staništa, kako kopnenih, tako i morskih (Long i sur. 1993). Produkti daljinskog promatranja u vidu satelitskih snimaka i tematskih karata koje iz njih proizlaze predstavljaju odličnu podlogu prilikom kartiranja staništa na terenu, ali ih je potrebno upotpuniti terenskim istraživanjima kako bi se mogli potvrditi rezultati daljinskog snimanja te izvesti potrebne dopune (Topić i sur. 2006). Satelitske snimke mogu se koristiti i za prebrojavanje jedinki i određivanje veličine populacija vrsta koje se ističu u ogoljenim staništima u kojima obitavaju, poput recimo pingvina na Antarktici (Fretwell i sur. 2012).

Nadalje, Achard i suradnici su za period između 1990. i 1997. metodama daljinskog promatranja prikazali proces deforestacije i degradacije šuma na globalnoj razini. Pokazalo se kako između jugoistočne Azije, Afrike i Amerike, jugoistočna Azija ima najvišu stopu deforestacije kao i degradacije šuma, a vlažne tropske šume se najčešće pretvaraju u velike agrikulturne površine. Kim i suradnici (2014) su pomoću slobodno dostupnih Landsat snimaka preuzetih s USGS portala retrospektivno proizveli mapu vegetacijskih promjena za period od 1990.-2000. Uočene su i prikazane globalne promjene u veličini šumskih površina, odnosno povećanje i smanjenje

veličine šumskih površina s naglaskom na Sjevernu Ameriku, Amazonu, Švedsku i Indoneziju. Alonso i Casanova (2004) su uz pomoć metoda daljinskog promatranja pokazali pozitivnu promjenu, to jest porast vegetacijske aktivnosti u Španjolskoj od 1987.-2001. Satelitske snimke

vegetacije pružaju vizualan doživljaj i interpretaciju vegetacije oko nas i pomoću njih je vrlo lako vizualno prikazati odnose i promjene koje se događaju u okolišu. Osim uvida u deforestaciju i krčenje šuma, analize satelitskih snimaka putem spektralnih potpisa omogućuju šumarima prepoznavanje područja infestacije šuma štetnicima, najčešće potkornjacima te otvaraju prostor za moguću prevenciju stradavanja šuma (Coops i sur. 2006, Franklin i sur. 2003). Osim toga, metode daljinskog promatranja omogućuju i uvid u pojavnost i širenje požara, a satelitske snimke mogu ukazivati na porijeklo samog požara, odnosno da li je nastao prirodno ili je namjerno induciran od strane čovjeka, npr. u svrhu stvaranja agrikulturnih površina (Prasetyo i sur. 2015).

Ljudi nemaju samo indirektnu korist od daljinskog promatranja kao što su praćenje agrikulturnih prinosa te praćenje ekoloških i krajobraznih promjena poput deforestacije i uništavanja prirodnih staništa, već je putem daljinskog promatranja moguće pratiti i izrađivati planove kontrole i suzbijanja nekih, po ljudski rod vrlo opasnih bolesti, kao što su kolera (Lobitz i sur. 1999) i malarija (Franke i sur. 2015). Klasifikacija biljnog pokrova i staništa putem metoda daljinskog snimanja i geoinformacijski sustavi (GIS) pokazali su se vrlo korisnima u epidemiologiji prilikom praćenja dinamike širenja i kartiranja izvora zaraznih bolesti u svrhu kontrole i sprječavanja širenja vektora zaraznih bolesti. Na području Afrike klasificiranjem biljnog pokrova moguće je locirati vlažna staništa koja pogoduju razmnožavanju komarca roda *Anopheles,* prijenosnika najopasnije vrste uzročnika malarije (*Plasmodium falciparum*). Također, uz pomoć

GIS programskih sustava moguće je rekonstruirati karte prošlosti, odnosno rekonstruirati paleookoliše, a takve su karte od velikog značaja arheobotaničarima, ali i arheolozima i antropolozima (Ray i Adams, 2001).

Landsat program je najstariji satelitski sustav za daljinsko snimanje Zemlje iz svemira, nastao kao zajednički projekt dviju američkih organizacija, National Aeronautics and Space Administration (NASA-e) i United States Geological survey (USGS-a). Od 1972. godine u orbitu je lansirano sveukupno 8 generacija satelita od kojih su neki funkcionalni i danas. U tom skoro 45-godišnjem razdoblju optička, komunikacijska i računalna tehnologija je uvelike i rapidno napredovala i omogućila usavršavanje satelitskih senzora, detektora i kamera, čime je proširena lepeza spektralnih kanala te su povećane prostorna i vremenska razlučivost satelitskih/daljinskih snimaka. Novi senzori na satelitima omogućuju snimanje Zemlje u ljudskom oku nevidljivom dijelu elektromagnetnog spektra, odnosno infracrvenom, ultraljubičastom dijelu spektra, kao i u području radio valova. Uz mogućnost snimanja različitih dijelova elektromagnetskog spektra, noviji senzori imaju i povećanu prostornu i vremensku razlučivost. Prostorna razlučivost određuje jasnoću i detaljnost snimke te se izražava veličinom piksela i o njenoj veličini ovisi mogućnost identifikacije i karakterizacije malih objekata, a optički senzori visoke prostorne razlučivosti koja iznosi 0.5-10 metara, poput IKONOS-a, QuickBirda, SPOT-5 (Satellite Pour l'Observation de la Terre-5), najčešće se koriste u okolišnim studijama (Wang i sur. 2010).

Za potrebe kartiranja vegetacije neki od najčešće korištenih senzora su Landsat senzori i to najčešće serije Thematic Mapper (TM) i Enhanced Thematic Mapper Plus (ETM+). To su multispektralni senzori, srednje prostorne razlučivosti od 30 m, koja je dovoljna za vegetacijsko kartiranje na razini biljnih zajednica. Neki također često korišteni satelitni senzori su SPOT (Satellite Pour l'Observation de la Terre) visoke prostorne razlučivosti i do 2.5 m, NOAA-AVHRR najpogodniji za detektiranje fitoplanktona u velikim vodenim masama , IKONOS i QuickBird te Hyperion hiperspektralni senzor s preko 200 spektralnh kanala (Xie i sur. 2008). Landsat 4-5 TM serija satelita puštena u pogon 1982. godine, predstavlja novu i poboljšanu verziju prijašnje Landsat 1-3 Multiscanner Scanner (MSS) serije pošto sadrži jedan novi, dodatni termalni senzor, odnosno sadrži ukupno 8 spektralnih kanala za daljinsko snimanje, ima skoro dvostruko bolju prostornu razlučivost koja iznosi do 30m, odnosno 120m za termalni kanal te je trajanje orbitalne putanje skraćeno sa 18 na 16 dana, a površina koju pokriva pojedina satelitska snimka iznosi 170 x 183 km (USGS portal, pristupljeno 20.2.2017.)

U početku, snimke Landsat programa bile su komercijalno dostupne što je relativno ograničavalo internacionalnu jednakost po pitanju globalne dostupnosti podataka (Miller 1984). Danas su Landsat snimke slobodno dostupne za preuzimanje čime se proširila mogućnost korištenja satelitskih podataka na manje imućne, te zemlje u razvoju. Puštanjem u promet slobodno dostupne, odnosno besplatne serije Landsat snimaka omogućuje se korištenje informacija još većem broju pojedinaca iz akademskog, ali i privatnog, vladinog pa i vojnog sektora (Lauer i sur. 1997).

1.3 Cilj istraživanja

S obzirom na nepotpunost rukopisnih vegetacijskih karata Hrvatske iz druge polovice 20. stoljeća, cilj ovog istraživanja jest provjera mogućnosti korištenja arhivskih satelitskih snimki za potrebe retrospektivnog kartiranja vegetacije i dopune starih karata te utvrđivanje pouzdanosti dobivenih podataka.

2 MATERIJALI I METODE

2.1 Područje istraživanja

U ovom istraživanju analizirala sam dva područja iz različitih biljno-geografskih dijelova Republike Hrvatske.

- Iz eurosibirsko-sjeverno američke, kontinentalne vegetacijske regije odabrano je područje Medvednice i Samoborsko-Žumberačkog gorja, smještenih u sjevero-zapadnom dijelu Republike Hrvatske.
- Iz mediteranske vegetacijske regije, s dijelovima eumediteranske i submediteranske vegetacijske zone odabrano je područje sjeverne Dalmacije, točnije rijeke Krke, od njenog izvora podno Dinare do ušća u Jadransko more.

Sva tri područja uključena su u Natura 2000 ekološku mrežu kao Područja očuvanja značajna za vrste i stanišne tipove, a područje rijeke Krke pripada i u Područja značajna za ptice. Sva tri područja također uživaju neki oblik zaštite na nacionalnoj razini. Medvednica i Žumberak-Samoborsko gorje u kategoriji Parkova prirode, dok je područje rijeke Krke svrstano u jedan od 8 Nacionalnih parkova Republike Hrvatske.

2.2 Korištene prostorne podloge

Satelitske snimke i digitalizirane karte predstavljaju grafički oblik podataka koji se koriste za prostorne analize u geoinformacijskim sustavima. GIS metode sastoje se od prikupljanja, pohrane, upravljanja, dohvata, analize i prikaza prostornih podataka. Iako se često koristi za izradu karata, jedna od osnovnih funkcija GIS-a je analiza prostornih podataka. Prostorni su podatci objedinjeni u tzv. slojevima koji se sastoje od 2 temeljna tipa podataka- geometrijski (rasterski ili vektorski: točke,linije, poligoni) i atributni (opisni) na temelju kojeg se vrše analize i vizualizacija. Jedna od bitnih sastavnica daljinskog promatranja su računalni softveri koji omogućuju manipulaciju podatcima, QGIS i SAGA GIS jedni su od popularnijih softvera otvorenog koda (Šulc 2016).

2.2.1 Rukopisne vegetacijske karte

U istraživanju su korišteni listovi starih rukopisnih vegetacijskih karata, nastalih u sklopu projekta Vegetacijska karta Hrvatske. Ukupno je odabrano 14 listova, 8 za područje sjevero-zapadne Hrvatske, odnosno Medvednice i Samoborskog i Žumberačkog gorja te 6 za područje sjeverne Dalmacije, to jest rijeke Krke. Karte su rađene u mjerilu M 1:50 000, što znači da 1 mm^2 na karti predstavlja 2 500 m^2 u stvarnosti, što je ujedno i iznos minimalne površine kartiranja. Vegetacijske karte nalaze se u Gauss-Krüger projekciji, zona 5. Na vegetacijskim kartama su različitim bojama i uzorcima naznačene prisutne biljne zajednice objašnjene u pripadnoj legendi (Slika 1.).

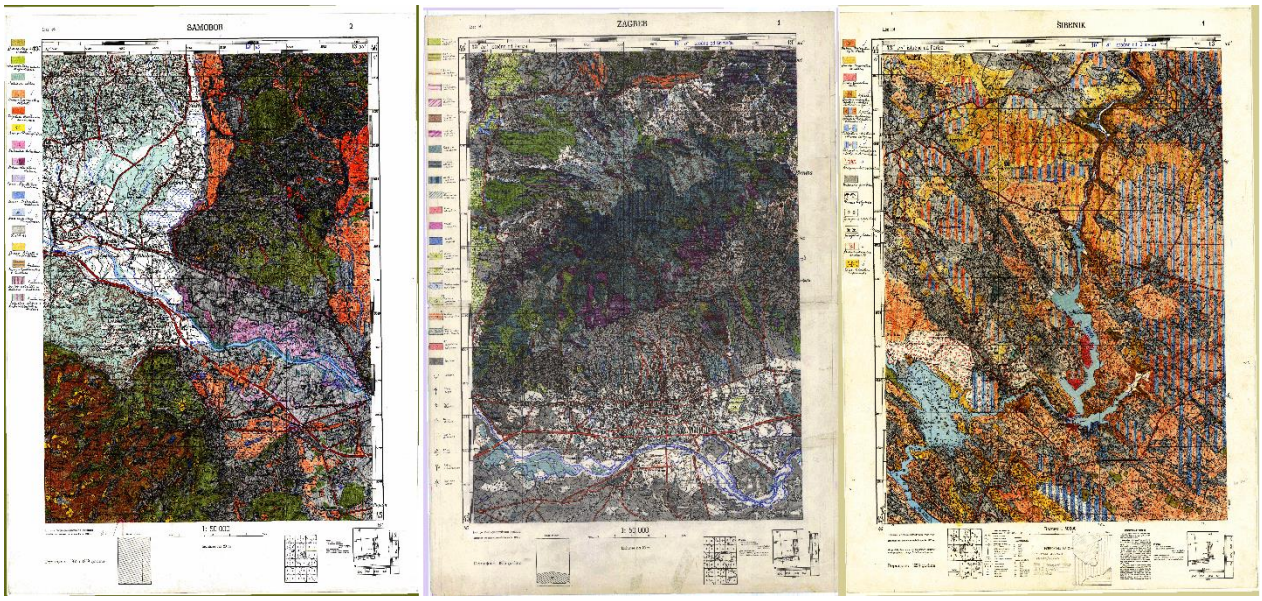

Slika 1. Primjeri triju listova rukopisnih vegetacijskih karata korištenih u ovom istraživanju. Na kartama su, s lijeva nadesno, prikazani dijelovi područja PP Žumberak-Samoborsko gorje, PP Medvednica i NP Krka.

2.2.2 Satelitske snimke

S USGS EarthExplorer portala preuzeta su 3 paketa slobodno dostupnih Landsat 5 TM snimaka koje pokrivaju odabrana područja i datumom snimanja su najbliža vremenu izrade rukopisnih vegetacijskih karata. Odabrano područje rijeke Krke pokrivaju dvije satelitske snimke, a područje Medvednice i Samoborsko-Žumberačkog gorja jedna. Snimke imaju 7 spektralnih kanala, a prostorna rezolucija snimaka iznosi 30 metara što znači da je površina jednog piksela 900 m^2. S obzirom na dostupnost, kvalitetu i period vegetacijskog maksimuma odabrane su satelitske snimke snimljene 21.09.1986. za područje Medvednice i Samoborsko-Žumberačkog gorja i 27.06.1984. za područje Krke (Slika 2.).

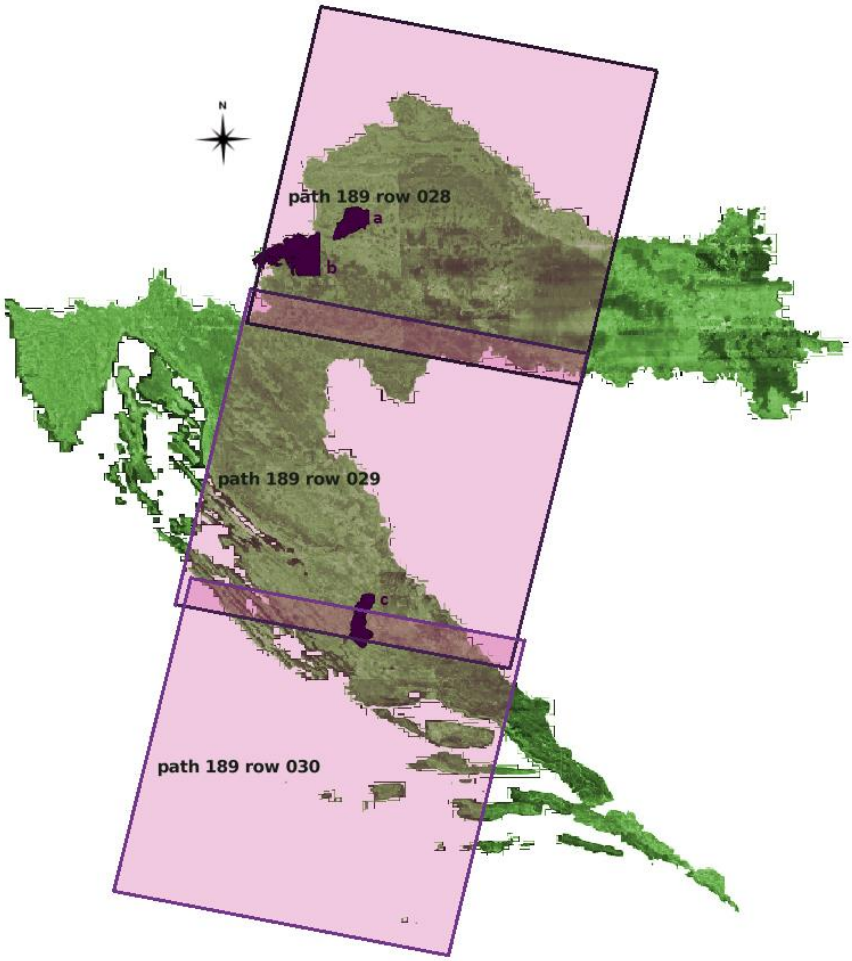

Slika 2. Prikaz smještaja satelitskih snimaka korištenih u istraživanju s naznačenim vrijednostima path i row u odnosu na smještaj područja PP Medvednica (a), PP Samoborsko-Žumberačko gorje (b) te NP Krka (c) na karti Hrvatske.

2.3 Analiza podataka

2.3.1 Preliminarna obrada podataka

Prije procesa klasifikacije bilo je potrebno pripremiti vektorski sloj s poligonima biljnih zajednica koji je izrađen u slobodno dostupnom programu QGIS 2.18.14 na temelju starih rukopisnih vegetacijskih karata. Sastavljen je popis biljnih zajednica navedenih u legendama starih rukopisnih karata koji će poslužiti kao popis za digitalizaciju trening područja, odnosno stvaranje poligona i definiranje specifičnih spektralnih vrijednosti karakterističnih za pojedinu biljnu zajednicu.

Kako bi se olakšala vizualna interpretacija biljnog pokrova izrađene su *False Color Composite* slike (Slika 3.) od snimaka spektralnih kanala 1, 2 i 3 (vidljivi dio spektra) te 3, 4 i 5 (infracrveni dio spektra).

a) 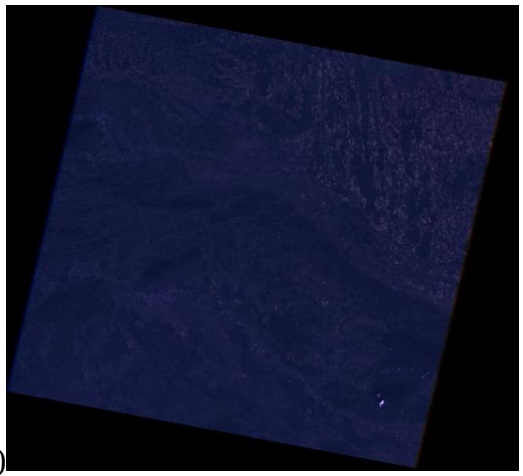 b) 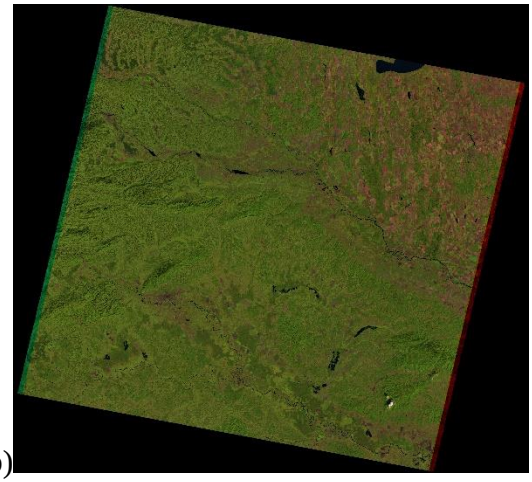

Slika 3: Primjeri *False Color Composite* slika satelitskih snimaka za područje Medvednice i Samoborsko-Žumberačkog gorja: a) *False Color Composite* slika sastavljena od spektralnih kanala 1, 2 i 3 ; b) *False Color Composite* slika sastavljena od spektralnih kanala 3, 4 i 5.

2.3.2 Klasifikacija satelitskih snimaka

Prvi korak u procesu analize satelitskih snimaka jest klasifikacija biljnog pokrova, koja je izvršena u programu Idrisi 17.0 The Selva Edition. Ovaj program omogućuje proces identifikacije spektralnih vrijednosti pojedinačnih piksela na temelju kojih se oni grupiraju u klase, u ovom slučaju vegetacijske zajednice, odnosno to je proces računalne interpretacije satelitskih snimaka izvediv uz pomoć GIS-a. Klasifikacija biljnog pokrova izvedena je prema uputama navedenim u priručniku Idrisi Selva Tutorial, *manual version 17* (Eastman 2012). Preklapanjem dvaju slojeva, False Color Composite slike i vektorskog sloja s poligonima biljnih zajednica i vodenih površina, locirana, identificirana i definirana su poligonska trening područja.

Metoda klasifikacije korištena u ovom istraživanju je metoda kontrolirane klasifikacije. Ova metoda zasniva se na poznavanju unaprijed definiranih skupina podataka – klasa biljnih zajednica, to jest nije sasvim automatizirana.

Za klasifikaciju satelitskih snimaka odabrane su 2 metode, odnosno 2 statistička algoritma (tzv. *hard classifiers*) koji donose konačnu odluku o pripadnosti pojedinog piksela usporedbom sličnosti spektralnog potpisa pojedinog piksela sa spektralnim potpisom unaprijed definirane klase, te ih na temelju najveće sličnosti svrstavaju u određenu klasu. Odabrani statistički algoritmi su *maximum likelihood* i *minimum distance* (Eastman 2012).

Klasifikacija biljnog pokrova putem metode kontrolirane klasifikacije odvija se u 4 koraka:

- **i.** Identifikacija i lociranje reprezentativnih primjera pojedinih biljnih zajednica na satelitskoj snimci, odnosno kreiranje tzv. trening područja, minimalne površine 54 000 m^2, odnosno 60 piksela Landsat snimke (broj spektralnih kanala korištenih za klasifikaciju * 10). Termalni infracrveni kanal prostorne razlučivosti od 120 m nije korišten u analizi.
- **ii.** Digitalizacija poligona trening područja, odnosno dodjeljivanje jedinstvenog koda/imena svakoj identificiranoj klasi biljnog pokrova.
- **iii.** Analiza piksela unutar trening područja i stvaranje specifičnog spektralnog potpisa za svaku od identificiranih klasa.
- **iv.** Klasifikacija satelitske snimke tzv. *per-pixel* metodom koja uspoređuje spektralni potpis svakog pojedinog piksela sa spektralnim potpisima definiranih trening područja i koristeći se statističkim metodama određuje sličnost, odnosno pripadnost pojedinog piksela prethodno definiranoj klasi.

2.3.3 Obrada klasificiranih satelitskih snimaka

Kao metoda post-obrade klasificiranih satelitskih snimki korištene su operacije susjedstva, izvedene u slobodno dostupnom računalnom programu SAGA (2.3.2). To su metode prostorne analize podataka koje pojedinim ćelijama rasterskog sloja dodjeljuju nove vrijednosti na temelju većinske vrijednosti susjednih piksela (Baghdadi i sur. 2018). U ovom istraživanju korištene su operacije *Majority Filter* 3x3 i *Majority Filter* 5x5.

2.3.4 Usporedba ispravnosti klasifikacije

Ispravnost procesa klasifikacije provjerena je usporedbom dobivenih tematskih karata i kontrolnih podloga koje su sačinjavali vektorski slojevi karte staništa iz 2004. godine. Kontrolne podloge obuhvaćaju površine PP Medvednica, PP Žumberak-Samoborsko gorje i NP Krka (Slika 1.). Prilikom ovog procesa najprije je bilo potrebno dešifrirati nepoznate kodove stanišnih tipova iz atributnih tablica vektorskih slojeva karte staništa i pridružiti im imena odgovarajućih vegetacijskih zajednica što je izvedeno preklapanjem i usporedbom slojeva karte staništa i rukopisnih vegetacijskih karata . Uz kolonu s imenom dešifriranih vegetacijskih zajednica, stvorena je i dodatna kolona s odgovarajućim klasifikacijskim kodovima uvećanima za dvije nule kako bi se olakšali daljnji koraci potrebni za izradu matrice pogreške i interpretaciju rezultata. Ovaj korak rađen je u programu QGIS 2.18.14.

Nakon toga, vektorski slojevi su prebačeni i rasterizirani u programu SAGA (2.3.2) gdje su potom spojeni s obrađenim rasterskim produktima klasifikacije pomoću matematičke operacije zbrajanja u modulu *Grid Calculator*.

Za kraj su u programu ArcView 3.3 iz zbrojenih rasterskih slojeva operacijom *Count* pobrojani zajednički pikseli te su izrađene matrice pogreške u Microsoft Office programu Excel 2016. Iz matrica pogreške izračunate su Kappa vrijednosti (Monserud i Leemans 1992).

3 REZULTATI

3.1 Rezultati preliminarne obrade podataka

U legendama 14 listova starih rukopisnih vegetacijskih karata za područje sjevero-zapadne Hrvatske zabilježeno je ukupno 77 različitih biljnih kategorija, što uključuje biljne zajednice i njihove kombinacije, nasade i sastojine različitih vrsta drveća te površine obrasle poljoprivrednim kulturama i voćnjake. Kombinacije biljnih zajednica su na kartama naznačene jer je površina koju zauzima pojedina biljna zajednica bila manja od odgovarajuće minimalne površine kartiranja zadane mjerilom karte M 1:50 000.

U legendama 6 listova starih vegetacijskih karata za područje srednje Dalmacije zabilježeno je 39 različitih biljnih kategorija koje uključuju biljne zajednice i njihove kombinacije, kulture i sastojine različitih vrsta drveća te ratarske površine.

S obzirom na nomenklaturnu zastarjelost biljnih zajednica navedenih na rukopisnim vegetacijskim kartama koje su rađene i dopunjavane u periodu od 1963.-1982., izrađen je popis prisutnih zajednica na starim vegetacijskim kartama koji je usklađen s nazivljem navedenim u IV. verziji Nacionalne klasifikacije staništa Republike Hrvatske (NKS) za područje Medvednice i Samoborsko-Žumberačkog gorja te za područje rijeke Krke (Prilog 1).

3.2 Rezultati klasifikacije satelitskih snimaka

Na području sjevero-zapadne Hrvatske ukupno su digitalizirana 33 trening područja različitih tipova pokrova od kojih jedno predstavlja vodenu površinu - rijeku Savu (Tablica 1).

Zbog pokrivenosti područja rijeke Krke s dvije satelitske snimke, svaka je snimka analizirana zasebno. Za sjevernu satelitsku snimku područja rijeke Krke, ukupno je digitalizirano 23 trening područja različitih tipova pokrova, od čega tri trening područja predstavljaju vodene površine mora, rijeke Krke i Vranskog jezera (Tablica 1.). Za južnu satelitsku snimku područja rijeke Krke digitalizirano je ukupno 14 različitih trening područja (Tablica 1.), od čega dva trening područja označavaju vodene površine rijeke Krke i mora, a 12 trening područja označava biljne kategorije navedene u legendama rukopisnih vegetacijskih karata.

Sve kombinacije biljnih zajednica izbačene su iz postupka klasifikacije za oba područja kako ne bi smanjile točnost očitavanja spektralnog potpisa pojedine zajednice.

Rezultati klasifikacije satelitskih snimaka predstavljeni su u obliku tematskih karata na kojima je svaka klasificirana vegetacijska zajednica prikazana drugom bojom (Slike 5.-10.).

Tablica 1. Popis digitaliziranih biljnih zajednica po satelitskoj snimci prema redoslijedu digitalizacije

snimka /br.	Sjevero-zapadna Hrvatska path 189 row 028	Sjeverna Krka path 189 row 029	Južna Krka path 189 row 030
1	*Abieti-Fagetum*	*Seslerio-Fagetum*	*Ononidi-Brometum*
2	*Agrosti-Juncetum conglomerati*	*Fagetum subalpinum*	*ratarske povrsine*
3	*Arrhenatheretum elatioris*	*Seslerio-Ostryetum*	*Festuco-Koelerietum splendentis*
4	*Betulo-Quercetum*	*Festuco-Koelerietum splendentis*	*Pinus halepensis*
5	*Bromo-Cynosuretum cristati*	*Querco-Carpinetum orientalis*	*Scolymo-Marrubietum*
6	*Bromo-Plantaginetum*	*Festucetum pseudovino vallesiaceae*	*Juniperus oxycedrus*
7	*Caricetum tricostatum vulpinae*	*Quercus pubescens*	*Orno-Quercetum ilicis*
8	*Carici-Alnetum glutinosae*	*ratarske površine*	*Paliuretum adriaticum*
9	*Carpino betuli-Quercetum roboris*	*Paliuretum adriaticum*	*Stipo-Salvietum*
10	*Corno-Ligustretum*	*Orno-Quercetum ilicis*	*Querco-Carpinetum orientalis*
11	*Deschampsietum caespitosae*	*Satureio-Edraianthetum*	*Quercus pubescens*
12	*Fagetum montanum*	*Carici-Centauretum rupestris*	*Vransko jezero*
13	*Genisto-Callunetum*	*Stipo-Salvietum*	*Rijeka Krka*
14	*kulture*	*Pinus halepensis*	*more*
15	*Lolio-Plantaginetum*	*Juniperus oxycedrus*	
16	*Leucoio-Fraxinetum angustifoliae*	*Ononidi-Brometum*	
17	*Luzulo-Fagetum*	*Scolymo-Marrubietum*	
18	*Luzulo-Quercetum petrae*	*Pinus nigra*	
19	*Nardetum stricta campicolum*	*Robinia pseudoacaccia*	
20	*Molinio-Quercetum petrae*	*more*	
21	*Myriophyllo-Nupharetum*	*Rijeka Krka*	
22	*Oenantho-Alopecuretum*	*Vransko jezero*	
23	*Querco-Carpinetum*	*Bromo-Seslerietum interruptae*	
24	*Querco-Carpinetum luzuletosum*		
25	*Querco-Castaneetum*		
26	*Querco-Ostryetum*		
27	*Salicion albae*		
28	*Salici-Populetum*		
29	*Seslerietum kalnikensis*		
30	*Trifolio-Agrostietum*		
31	*Robinia pseudoacaccia*		
32	*voćnjak*		
33	*rijeka Sava*		

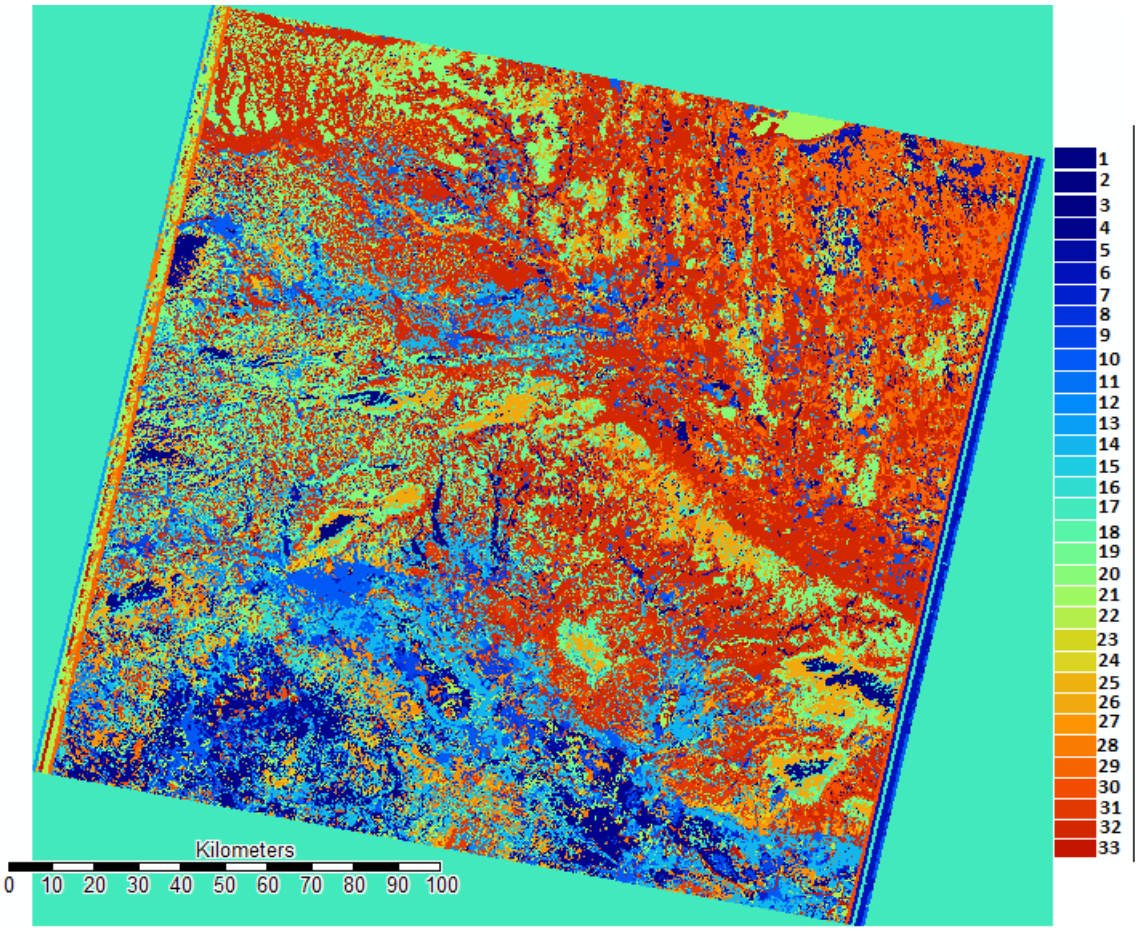

Slika 5. Tematska karta područja Medvednice i Samoborsko-Žumberačkog gorja dobivena klasifikacijskim algoritmom *maximum likelihood* nakon primjene Majority filtera. U pripadnoj legendi su brojevima predstavljene klasificirane biljne zajednice (vidi Tablicu 1.)

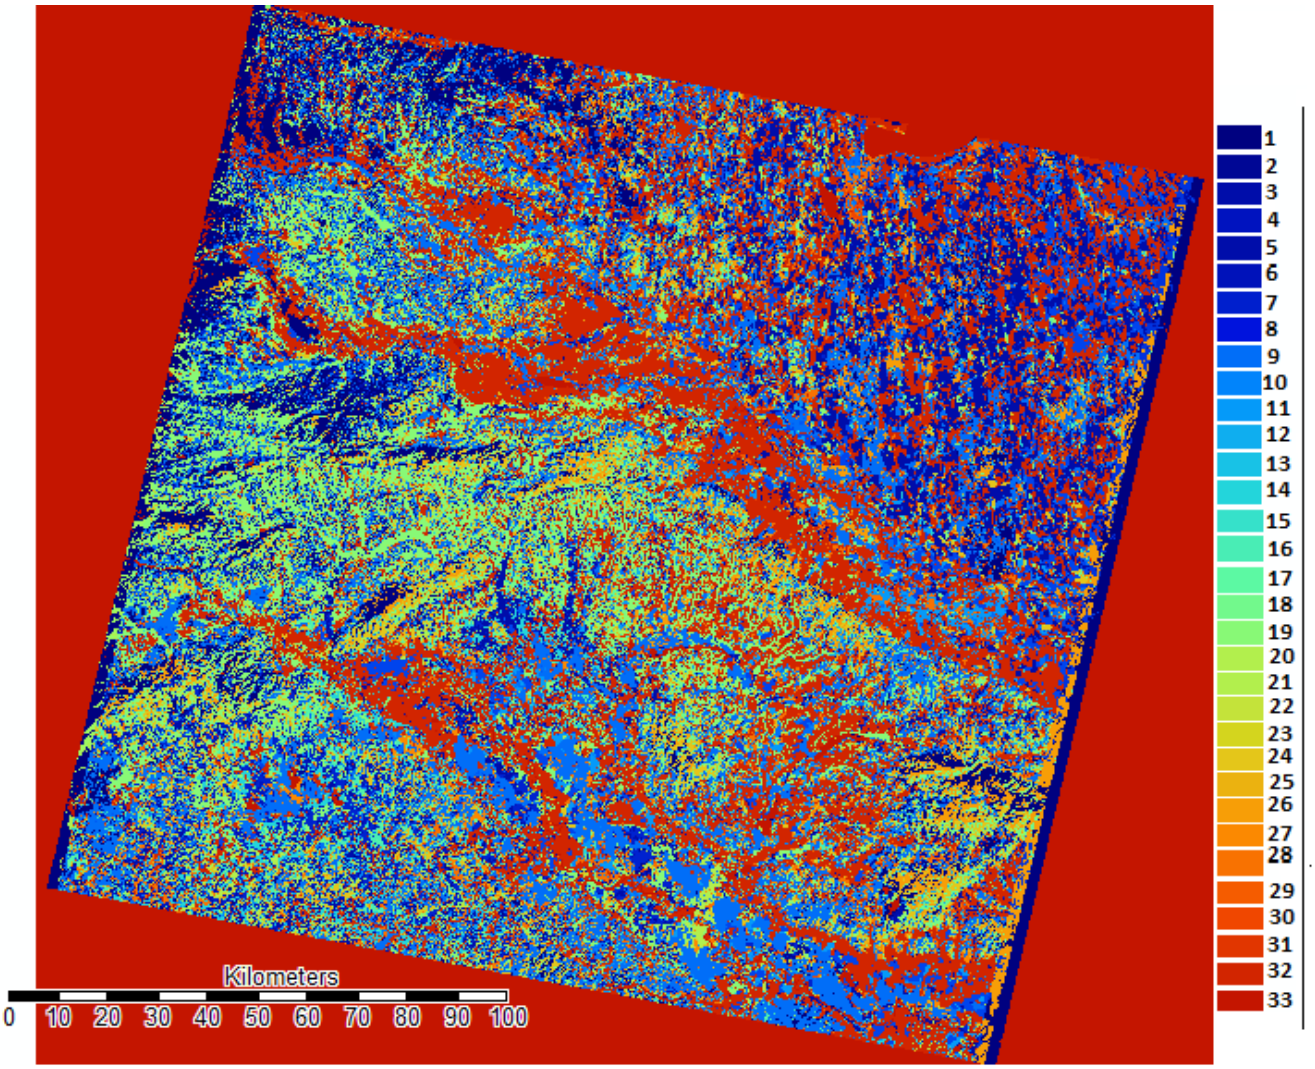

Slika 6. Tematska karta područja Medvednice i Samoborsko-Žumberačkog gorja dobivena klasifikacijskim algoritmom *minimum distance* nakon primjene Majority filtera. U pripadnoj legendi su brojevima predstavljene klasificirane biljne zajednice (vidi Tablicu 1.)

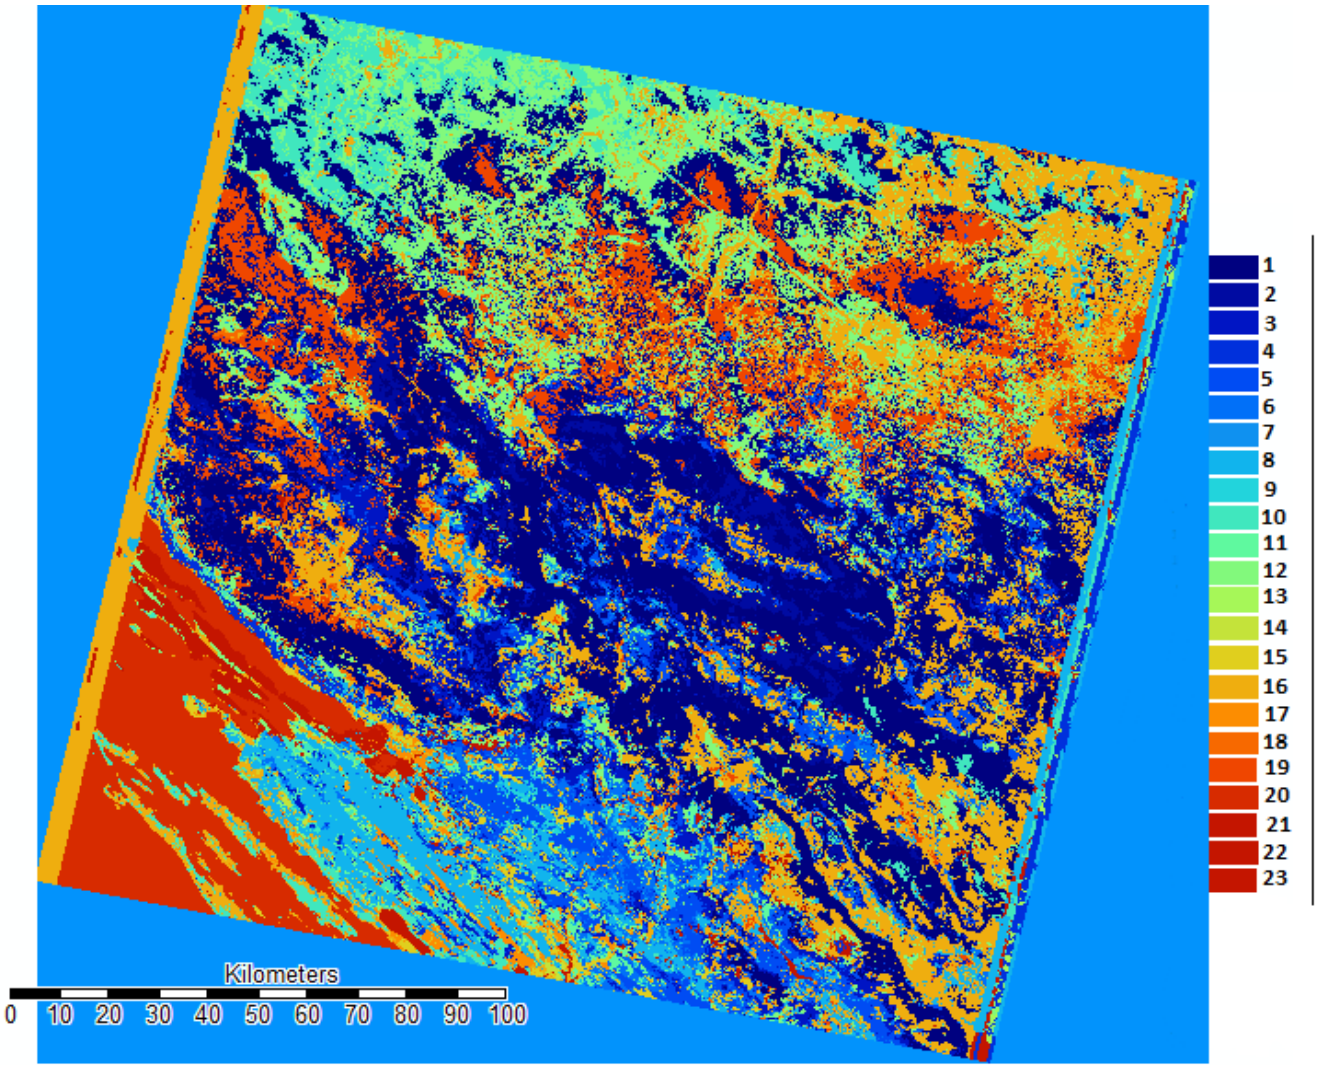

Slika 7. Tematska karta područja rijeke Krke dobivena klasifikacijom sjeverne satelitske snimke klasifikacijskim algoritmom *maximum likelihood* nakon primjene Majority filtera. U pripadnoj legendi su brojevima predstavljene klasificirane biljne zajednice (vidi Tablicu 1.)

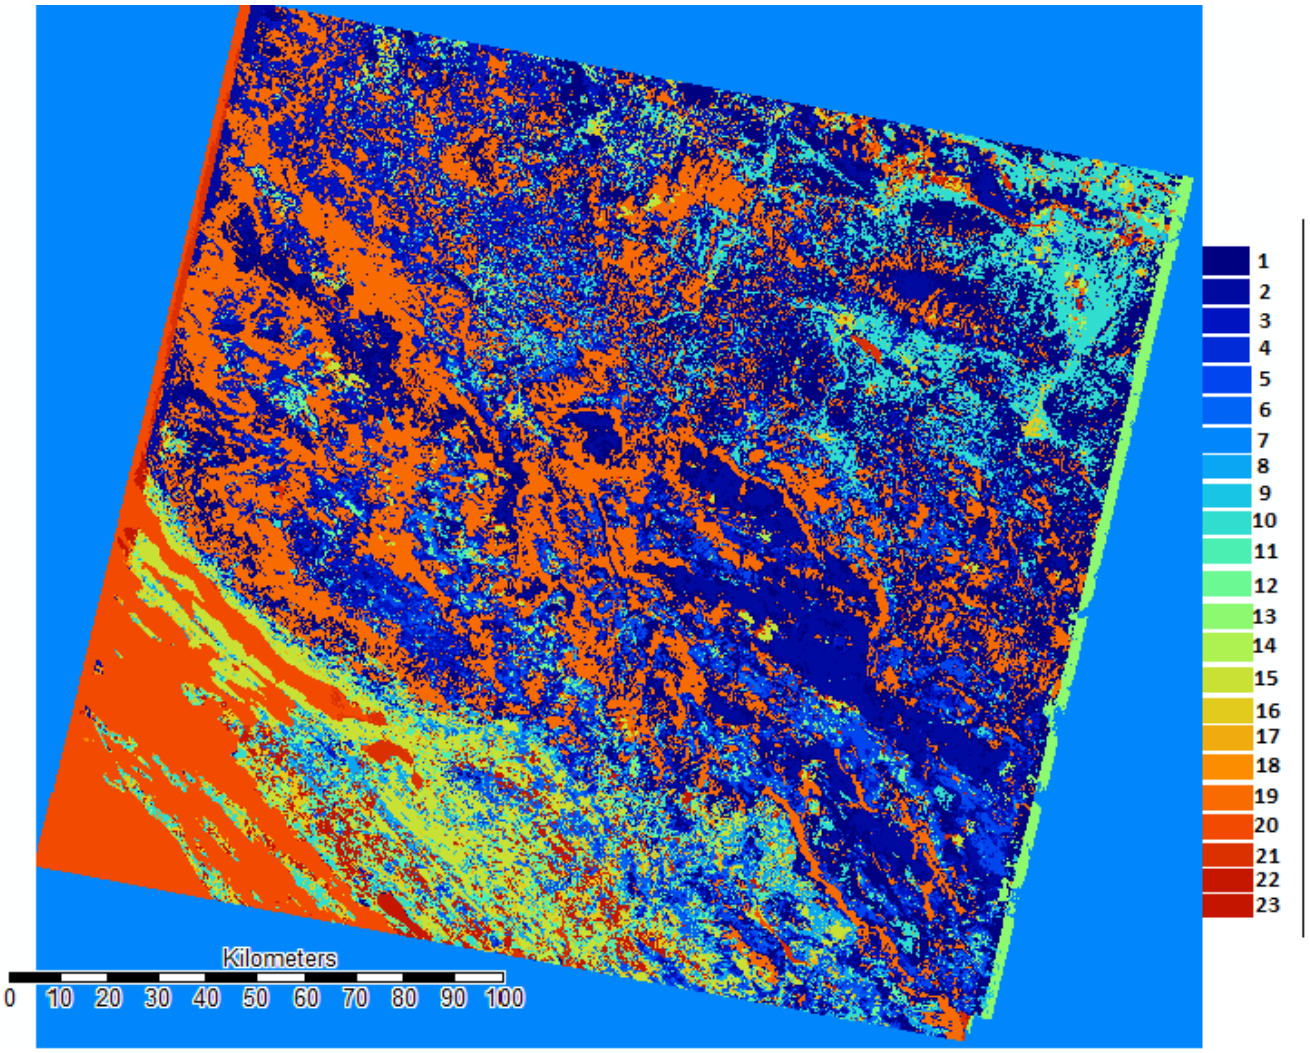

Slika 8. Tematska karta područja rijeke Krke dobivena klasifikacijom sjeverne satelitske snimke i klasifikacijskim algoritmom *minimum distance* nakon primjene Majority filtera. U pripadnoj legendi su brojevima predstavljene klasificirane biljne zajednice (vidi Tablicu 1.)

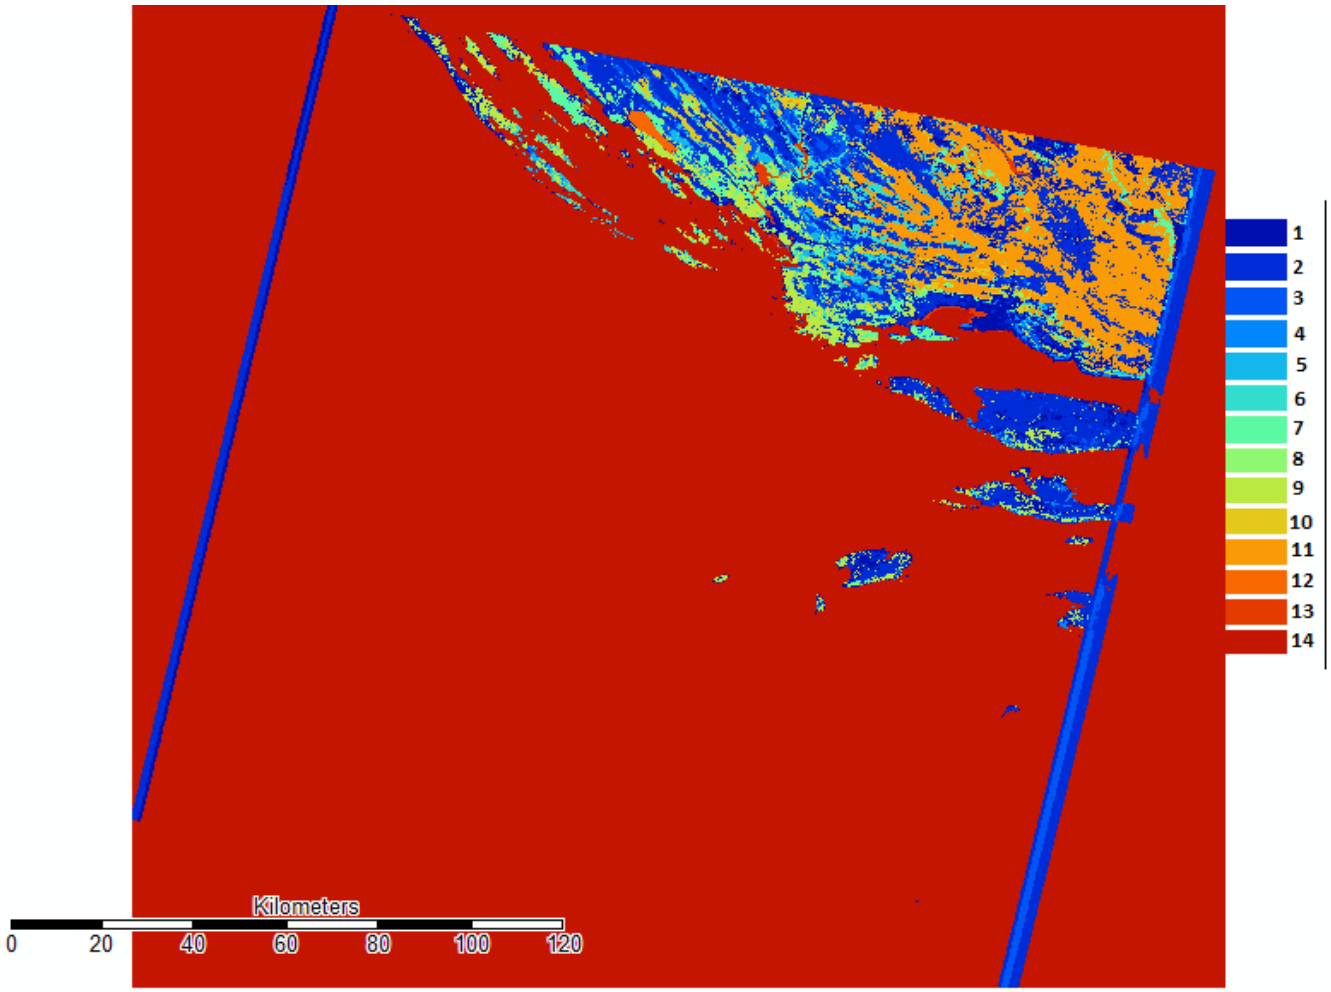

Slika 9. Tematska karta područja rijeke Krke dobivena klasifikacijom druge satelitske snimke i klasifikacijskim algoritmom *maximum likelihood* nakon primjene Majority filtera. U pripadnoj legendi su brojevima predstavljene klasificirane biljne zajednice (vidi Tablicu 1.)

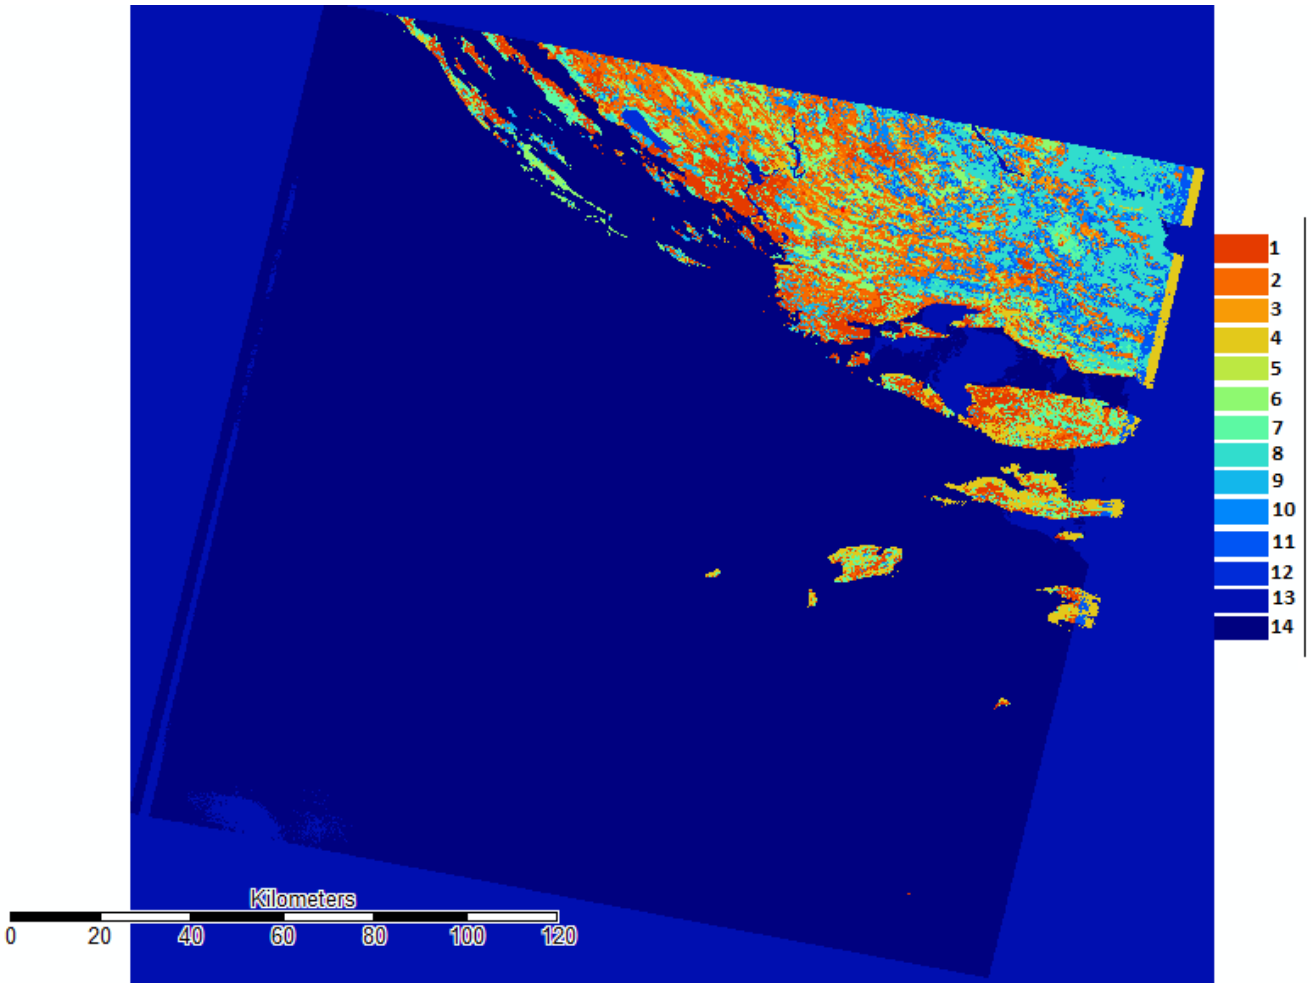

Slika 10. Tematska karta područja rijeke Krke dobivena klasifikacijom druge satelitske snimke i klasifikacijskim algoritmom *minimum distance* nakon primjene Majority filtera. U pripadnoj legendi su brojevima predstavljene klasificirane biljne zajednice (vidi Tablicu 1.)

3.3 Rezultati post-obrade satelitskih snimaka

Zbog nekompatibilnosti formata programa Idrisi 17.0 The Selva Edition u kojem je vršena klasifikacija satelitskih snimaka i programa SAGA (2.3.2) u kojem je izvedena post-obrada klasificiranih satelitskih snimaka, klasificirane tematske karte su eksportirane iz programa Idrisi 17.0 The Selva Edition u ASCII formatu kako bi bilo moguće provesti daljnje operacije u programu SAGA (2.3.2).

Rezultati post-obrade klasificiranih satelitskih snimaka su također prikazani kao tematske karte. Između dviju izvedenih operacija, kao prikladnija s obzirom na mjerilo M 1:50 000 starih vegetacijskih karata odabrana je operacija *Majority filter* 5x5 (Slika 11.)

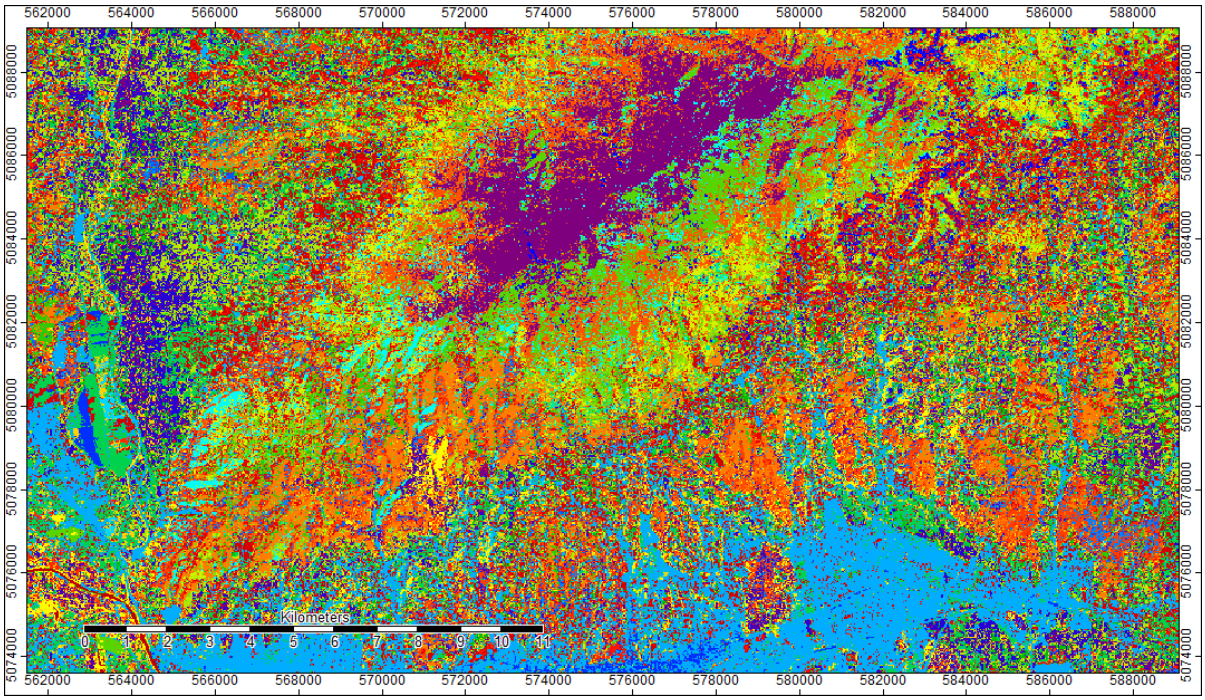

a)

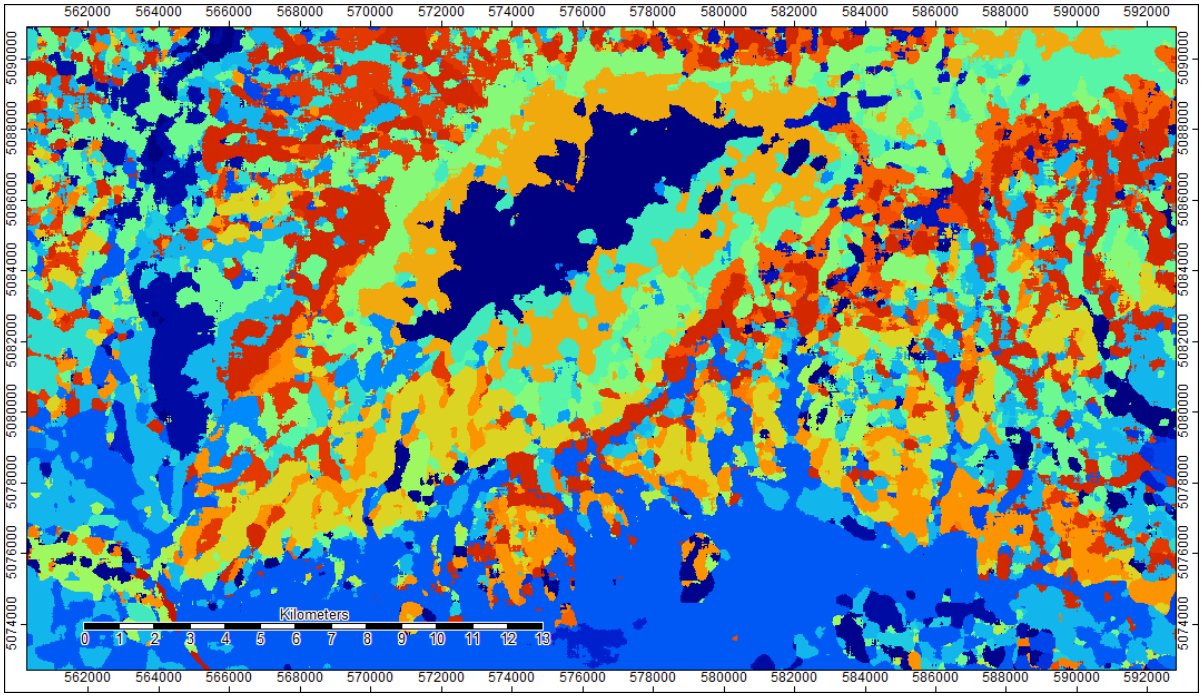

b)

Slika 11. Prikazi uvećanih detalja klasificiranih tematskih karata područja Medvednice a) klasificirane tematske karte bez primjene filtera i b) klasificirane tematske karte nakon primjene operacije *Majority Filter* 5x5.

3.4 Rezultati usporedbe ispravnosti klasifikacije

Iz vektorskih slojeva karte staništa za područje PP Medvednica prepoznato je 13 klasa biljnog pokrova (Tablica 2. i 3.), za područje PP Žumberak-Samoborsko gorje 4 (Tablica 4. i 5.), a za područje NP Krka 6 klasa biljnog pokrova (Tablica 6.-9.) koje su uspoređene s klasificiranim klasama.

Na temelju ukupnih kappa vrijednosti najpouzdanijim se pokazalo područje Samoborsko-Žumberačkog gorja s vrijednostima od 0,716 za maximum likelihood analizu (Tablica 12.) i 0,616 za minimum distance analizu (Tablica 13.).

Najmanje pouzdanom pokazala se klasifikacija područja Medvednice čije kappa vrijednosti iznose 0,121 za maximum likelihood (Tablica 10.) i 0,065 za minimum distance analizu (Tablica 11.).

Analiza pouzdanosti klasifikacije za područje rijeke Krke pokazala je kako je za obje satelitske snimke pouzdaniji algoritam maximum likelihood s vrijednostima od 0,620 za sjevernu (Tablica 14.) i 0,511 za južnu satelitsku snimku (Tablica 16.). Kappa vrijednosti pouzdanosti minimum distance algoritma za sjevernu satelitsku snimku iznosi 0,456 (Tablica 15.) , a za južnu 0,245 (Tablica 17.).

Tablica 2. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *maximum likelihood* za područje PP Medvednica

	Kontrolne klase karte staništa												
klasificirane klase	*Abieti-Fagetum*	*Arrhenatheretum elatioris*	*Bromo-Cynosuretum cristati*	*Bromo-Plantaginetum mediae*	*Fagetum montanum*	kulture	*Luzulo-fagetum*	*Luzulo-Quercetum petrae*	*Querco-Carpinetum*	*Querco-Carpinetum luzuletosum*	*Querco-Castaneetum croaticum*	*Querco-Ostryetum carpinifoliae*	nasadi bagrema
Abieti-Fagetum	12634	0	0	0	7179	119	231	0	617	0	156	88	25
Agrosti-Juncetum conglomerati	0	0	0	0	0	0	0	0	13	0	51	0	2
Arrhenatheretum elatioris	0	0	0	0	3	79	0	0	1	0	126	0	0
Betulo-Quercetum	0	0	0	0	393		0	0	106	0	135	0	12
Bromo-Cynosuretum cristati	0	0	0	0	0	6	0	0	0	0	0	0	0
Bromo-Plantaginetum	3	0	0	149	230	1101	42	0	314	0	0	0	0
Caricetum tricostatum vulpinae	0	0	0	0	0	0	0	0	0	0	0	0	0
Carici-Alnetum glutinosae	0	0	0	0	0	0	0	0	0	0	0	0	0
Carpino betuli-Quercetum roboris	0	0	0	0	22	0	0	0	1	0	50	0	0
Corno-Ligustretum	0	99	0	0	150	10	0	0	335	0	15	181	12
Deschampsietum caespitosae	0	0	0	0	0	0	0	0	0	0	0		0
Fagetum montanum	205	42	0	47	3941	4	209	18	1142	0	600	146	168
Genisto-Callunetum	0	0	0	0	272	6	30	0	64	0	100	1	0
kulture	0	10	0	0	36	213	22	0	91	0	1	0	16
Lolio-Plantaginetum	0	0	0	0	34	12	2	0	9	0	0	0	0
Leucoio-Fraxinetum angustifoliae	0	0	0	0	1562		130	21	580	0	96	0	0
Luzulo-Fagetum	1233	0	0	0	6779		249	191	890	0	253	39	0
Luzulo-Quercetum petrae	1	0	0	114	3701	198	304	869	2004	0	1543	23	217
Nardetum stricta campicolum	0	0	10	0	26	577	8	0	50	0	180	70	91
Molinio-Quercetum petrae	150	0	0	64	7036	1058	537	1688	2666	134	3215	96	187
Myriophyllo-Nupharetum	0	0	0	0	233	0	0	00	113	0	390	2	53
Oenantho-Alopecuretum	0	0	0	0	0	0	0	0	23	0	1	0	0
Querco-Carpinetum	0	0	0	0	0	0	0	0	2	0	12	0	0
Querco-Carpinetum luzuletosum	87	4	0	0	5646	22	101	699	4087	0	3324	183	471
Querco-Castaneetum	0	0	0	0	39	388	1		52	0	162	4	15
Querco-Ostryetum	3032	0	0	156	14411	69	870	1647	3776	299	1526	120	70
Salicion albae	2	53	0	0	2750	2	74	35	1225	0	1384	43	57
Salici-Populetum	0	16	0	0	39	34	24	0	49	0	129	0	8
Seslerietum kalnikensis	4	0	0	10	241	1703	0	0	200	0	104	0	76
Trifolio-Agrostietum	0	0	0	7	27	377	0	0	24	0	1	0	0
Robinia pseudoacaccia	12	0	0	0	3100	39	468	228	1365	0	879	0	93
voćnjak	0	6	0	0	236	3513	108	9	364	0	432	0	36
Vodene površine	0	0	0	0	1	0	0	0	0	0	0	0	0

Tablica 3. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *minimum distance* za područje PP Medvednica

	Kontrolne klase karte staništa												
Klasificirane klase	*Abieti-Fagetum*	*Arrhenatheretum elatioris*	*Bromo-Cynosuretum cristati*	*Bromo-Plantaginetum mediae*	*Fagetum montanum*	**kulture**	*Luzulo-fagetum*	*Luzulo-Quercetum petrae*	*Querco-Carpinetum*	*Querco-Carpinetum luzuletosum*	*Querco-Castaneetum croaticum*	*Querco-Ostryetum carpinifoliae*	**nasadi bagrema**
Abieti-Fagetum	10966	39	0	28	14770	545	282	606	3584	299	1178	274	181
Agrosti-Juncetum conglomerati	0	0	0	0	49	335	21	0	6	0	5	0	15
Arrhenatheretum elatioris	0	0	0	0	87	113	0	0	242	0	162	120	25
Betulo-Quercetum	0	0	0	0	0	0	0	0	3	0	0	0	0
Bromo-Cynosuretum cristati	0	0	0	0	219	469	14	0	161	0	14	00	
Bromo-Plantaginetum	0	0	0	0	0	0	0	0	0	0	0	0	0
Caricetum tricostatum vulpinae	17	0	0	0	0	0	0	0	0	0	0	0	0
Carici-Alnetum glutinosae	15	0	0	0	6	0	1	0	0	0	0	0	0
Carpino betuli-Quercetum roboris	140	67	0	9	8050	2487	673	755	2498	9	3317	23	246
Corno-Ligustretum	0	0	0	0	1	20	2	0	4	0	0	0	0
Deschampsietum caespitosae	0	0	0	0	22	49	0	0	7	0	10	0	5
Fagetum montanum	225	0	0	0	1235		249	121	38		91	0	
Genisto-Callunetum	0	0	0	0	0	0	0	0	0	0	16	0	0
kulture	0	70	0	0	7	44	15		65	0	0	0	0
Lolio-Plantaginetum	0	0	0	0	0	0	0	0	0	0	0	0	0
Leucoio-Fraxinetum angustifoliae	0	0	0	0	88	1	7	0	209	0	99	0	4
Luzulo-Fagetum	267	0	0	0	2055	18	204	26	505	0	141	0	11
Luzulo-Quercetum petrae	374	0	0	0	2466	9	98	666	1113	62	977	45	26
Nardetum stricta campicolum	0	17	10	448	3242	2724	127	260	2195	0	1428	263	559
Molinio-Quercetum petrae	0	0	0	0	110	1	24	149	58	0	64	0	3
Myriophyllo-Nupharetum	0	0	0	0	487	0	17	0	121	0	256	10	0
Oenantho-Alopecuretum	0	0	0	0	3	110	6	0	0	0	5	0	0
Querco-Carpinetum	0	0	0	0	35	0	0	0	0	0	3	0	0
Querco-Carpinetum luzuletosum	338	0	0	5	16853	939	955	2204	7351	12	5946	230	482
Querco-Castaneetum	0	0	0	0	199	0	18	2	85	0	65	0	0
Querco-Ostryetum	5021	0	0	57	7330	83	622	616	1539	51	566	31	24
Salicion albae	0	0	0	0	313	0	0	0	81	0	282	0	
Salici-Populetum	0	0	0	0	18	673	51	0	79	0	57	0	0
Seslerietum kalnikensis	0	0	0	0	16	9	0	0	0	0	0	0	0
Trifolio-Agrostietum	0	0	0	0	13	15	0	0	0	0	0	0	0
Robinia pseudoacaccia	0	0	0	0	84	0	20	0	36	0	23	0	0
voćnjak	0	37	0	0	56	886	4	0	127	0	160	0	26
vodene površine	0	0	0	0	278	0	0	0	46	0	0	0	2

Tablica 4. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *maximum likelihood* za područje PP Žumberak-Samoborsko gorje

	Kontrolne klase karte staništa			
klasificirane klase	***Fagetum montanum***	**kulture**	***Querco-Carpinetum***	***Salicion albae***
Abieti-Fagetum	14055	113	0	0
Agrosti-Juncetum conglomerati	104	4247	71	0
Arrhenatheretum elatioris	1724	1413	173	0
Betulo-Quercetum	0	252	1674	0
Bromo-Cynosuretum cristati	9	15645	63	0
Bromo-Plantaginetum	34884	9952	0	0
Caricetum tricostatum vulpinae	0	59	0	0
Carici-Alnetum glutinosae	0		132	0
Carpino betuli-Quercetum roboris	10	701	3460	0
Corno-Ligustretum	848	4834	429	42
Deschampsietum caespitosae	0	167	3	0
Fagetum montanum	63053	849	26	0
Genisto-Callunetum	1943	116		0
kulture	177	22024	755	0
Lolio-Plantaginetum	266	7630	271	0
Leucoio-Fraxinetum angustifoliae	6048	353	2859	0
Luzulo-Fagetum	39531	297	0	0
Luzulo-Quercetum petrae	20699	1123	0	0
Nardetum stricta campicolum	589	21043	865	0
Molinio-Quercetum petrae	35767	1599		0
Myriophyllo-Nupharetum	0	1080	111	0
Oenantho-Alopecuretum	8	3329	28	0
Querco-Carpinetum	64	0		0
Querco-Carpinetum luzuletosum	7029	2212	10919	0
Querco-Castaneetum	1175	364	144	0
Querco-Ostryetum	82681	740		0
Salicion albae	1090	1373	11017	168
Salici-Populetum	282	3202	537	40
Seslerietum kalnikensis	31547	10319		0
Trifolio-Agrostietum	939	725	233	0
Robinia pseudoacaccia	7416	725	1378	0
voćnjak	1095	5319	195	0
vodene površine	0	458	0	42

Tablica 5. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *minimum distance* za područje PP Žumberak-Samoborsko gorje

	Kontrolne klase karte staništa			
Klasificirane klase	***Fagetum montanum***	**kulture**	***Querco-Carpinetum***	***Salicion albae***
Abieti-Fagetum	76552	2324	462	0
Agrosti-Juncetum conglomerati	343	4369	191	0
Arrhenatheretum elatioris	10931	9143	473	3
Betulo-Quercetum	0	122	1266	0
Bromo-Cynosuretum cristati	9411	29650	255	0
Bromo-Plantaginetum	4045	33	0	0
Caricetum tricostatum vulpinae	0	100	0	0
Carici-Alnetum glutinosae	113	3	8	0
Carpino betuli-Quercetum roboris	27148	3684	6147	29
Corno-Ligustretum	36	1079	76	3
Deschampsietum caespitosae	2	385	7	0
Fagetum montanum	4390	4	0	0
Genisto-Callunetum	27	0	290	0
kulture	15	5888	238	0
Lolio-Plantaginetum	0	5	3	0
Leucoio-Fraxinetum angustifoliae	287	123	3953	0
Luzulo-Fagetum	14365	798	2247	0
Luzulo-Quercetum petrae	8759	164	2768	0
Nardetum stricta campicolum	96507	41832	2009	8
Molinio-Quercetum petrae	649	4	108	0
Myriophyllo-Nupharetum	4	365	327	0
Oenantho-Alopecuretum	13	3417	90	0
Querco-Carpinetum	0	6	363	0
Querco-Carpinetum luzuletosum	71286	3675	7201	0
Querco-Castaneetum	114	66	2287	0
Querco-Ostryetum	23257	211	0	0
Salicion albae	7	352	3548	54
Salici-Populetum	988	4315	588	13
Seslerietum kalnikensis	759	175	0	0
Trifolio-Agrostietum	307	235	152	0
Robinia pseudoacaccia	114	0	46	0
voćnjak	675	8718	240	15
Vodene površine	1929	1018	0	167

Tablica 6. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *maximum likelihood* sjeverne satelitske snimke područja NP Krka

	Kontrolne klase karte staništa					
klasificirane klase	***Festuco-Koelerietum splendentis***	***Querco-Carpinetum orientalis***	**ratarske površine**	***Orno-Quercetum ilicis***	***Pinus halepensis***	**rijeka**
Seslerio-Fagetum	0	1	0	0	7	2
Fagetum subalpinum	0	0	0	0	0	0
Seslerio-Ostryetum	1651	651	871	70	10	18
Festuco-Koelerietum splendentis	13	4	0	0	0	0
Querco-Carpinetum orientalis	102	6527	3559	105	49	141
Festucetum pseudovino vallesiaceae	2533	4388	8360	0	0	66
Quercu pubescens	12422	361	4544		655	516
ratarske površine	2611	2437	23119	9	58	71
Paliuretum adriaticum	47	1	0	0	24	
Orno-Quercetum ilicis	765	2340	104	627	339	164
Satureio-Edraianthetum	7482	895	5110	170		
Carici-Centauretum rupestris	520	1482	1759		43	51
Stipo-Salvietum	14	0	0	0	0	0
Pinus halepensis	633	808	920	121	6659	110
Juniperus oxycedrus	10396	2239	1637	29	1363	6
Ononidi-Brometum	3441	7687	3264	343	1978	1881
Scolymo-Marrubietum	5522	586	780	259	729	
Pinus nigra	0	0	0	0	0	0
Robinia pseudoacaccia	0	0	0	0	0	0
more	0	0	0	0	0	0
rijeka	370	501	216	323	175	8242
Vransko jezero	0	0	0	0	0	0
Bromo-Seslerietum interruptae	132	2	160	0	0	0

Tablica 7. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *minimum distance* sjeverne satelitske snimke područja NP Krka

	Kontrolne klase karte staništa					
klasificirane klase	***Festuco-Koelerietum splendentis***	***Querco-Carpinetum orientalis***	**ratarske površine**	***Orno-Quercetum ilicis***	***Pinus halepensis***	**rijeka**
Seslerio-Fagetum	0	874	58	89	89	222
Fagetum subalpinum	0	668	0	0	0	3
Seslerio-Ostryetum	123	529	187	49	49	229
Festuco-Koelerietum splendentis	84	2	0	0	0	0
Querco-Carpinetum orientalis	25	4580	2760	116	5	47
Festucetum pseudovino vallesiaceae	432	1159	1751	8	0	4
Quercu pubescens	12440	402	4551	0	650	527
ratarske površine	320	641	4284	0	35	33
Paliuretum adriaticum	0	0	0	0	0	0
Orno-Quercetum ilicis	530	5930	466	333	1049	388
Satureio-Edraianthetum	7945	1902	6270	394	204	19
Carici-Centauretum rupestris	110	882	2458	147	29	8
Stipo-Salvietum	0	0	0	0	0	0
Pinus halepensis	1037	1618	1122	132	6310	303
Juniperus oxycedrus	13507	2704	6463	67	1268	171
Ononidi-Brometum	3148	3229	5593	230	718	30
Scolymo-Marrubietum	1984	1155	1962	0	144	11
Pinus nigra	1	94	50	0	636	59
Robinia pseudoacaccia	0	14	0	0	0	22
more	0	0	0	0	0	0
rijeka	948	1094	306	437	347	9188
Vransko jezero	0	0	0	0	0	0
Bromo-Seslerietum interruptae	6020	3642	16122	54	449	4

Tablica 8. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *maximum likelihood* južne satelitske snimke područja NP Krka

	Kontrolne klase karte staništa					
Klasificirane klase	***Festuco-Koelerietum splendentis***	***Querco-Carpinetum orientalis***	**ratarske površine**	***Orno-Quercetum ilicis***	***Pinus halepensis***	**rijeka**
Ononidi-Brometum	5725	3096	2537	74	965	1007
ratarske povrsine	8381	2581	26191	12	356	81
Festuco-Koelerietum splendentis	15152	958	4192	172	30	8
Pinus halepensis	694	621	717	59	6361	67
Scolymo-Marrubietum	2889	120	426	228	521	0
Juniperus oxycedrus	8934	1505	975	11	1257	61
Orno-Quercetum ilicis	3359	4874	1036	812	1941	540
Paliuretum adriaticum	23	1247	91	0	0	36
Stipo-Salvietum	2207	702	230	16	436	11
Querco-Carpinetum orientalis	853	988	392	345	20	0
Quercus pubescens	0	179	203	0	0	0
Vransko jezero	0	0	0	0	0	0
rijeka	437	456	184	327	202	8152
more	0	13792	17229	0	0	1305

Tablica 9. Prikaz matrice usporedbe pobrojanih piksela po klasi nakon zbrajanja rasterskih slojeva tematske karte dobivene klasifikacijom i kontrolnih klasa karte staništa za algoritam *minimum distance* južne satelitske snimke područja NP Krka

	Kontrolne klase karte staništa					
Klasificirane klase	***Festuco-Koelerietum splendentis***	***Querco-Carpinetum orientalis***	**ratarske površine**	***Orno-Quercetum ilicis***	***Pinus halepensis***	**rijeka**
Ononidi-Brometum	6498	1300	2655	160	1389	55
ratarske povrsine	12614	3083	20331	170	148	3
Festuco-Koelerietum splendentis	5621	534	2697	5	30	15
Pinus halepensis	1574	2458	1166	217	7605	635
Scolymo-Marrubietum	498	18	90	0	38	0
Juniperus oxycedrus	14621	1819	5050	72	1348	123
Orno-Quercetum ilicis	911	2795	793	314	838	50
Paliuretum adriaticum	254	2910	240	254	144	342
Stipo-Salvietum	4482	340	679	204	161	17
Querco-Carpinetum orientalis	897	1195	3031	262	28	0
Quercus pubescens	28	74	27	0	0	0
Vransko jezero	0	0	0	0	0	0
rijeka	625	14593	17644	398	360	9986
more	31	0	0	0	0	42

Tablica 10. Prikaz rezultata izračuna kappa vrijednosti za algoritam *maximum likelihood* za područje PP Medvednica

		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	**13**	**kappa**
1	*Abieti-Fagetum*	12634	0	0	0	7179	119	231	0	617	0	156	88	25	0.577169
2	*Arrhenatheretum elatioris*	0	0	0	0	3	79	0	0	1	0	126	0	0	-0.00092
3	*Bromo-Cynosuretum cristati*	0	0	0	0	0	6	0	0	0	0	0	0	0	0
4	*Bromo-Plantaginetum mediae*	3	0	0	149	230	1101	42	0	314	0	0	0	0	0.122493
5	*Lamio orvale-Fagetum sylvaticum*	205	42	0	47	3941	4	209	18	1142	0	600	146	168	0.08795
6	kulture	0	10	0	0	36	213	22	0	91	0	1	0	16	0.156342
7	*Luzulo albidae-fagetum*	1233	0	0	0	6779		249	191	890	0	253	39	0	-0.00024
8	*Luzulo-Quercetum petrae*	1	0	0	114	3701	198	304	869	2004	0	1543	23	217	0.088398
9	*Epimedio-Carpinetum betuli*	0	0	0	0	0	0	0	0	2	0	12	0	0	-1.249
10	*Epimedio-Carpinetum betuli subas. Luzuletosum*	87	4	0	0	5646	22	101	699	4087	0	3324	183	471	-0.00614
11	*Querco-Castaneetum croaticum*	0	0	0	0	39	388	1	0	52	0	162	4	15	0.022567
12	*Querco-Ostryetum carpinifoliae*	3032	0	0	156	14411	69	870	1647	3776	299	1526	120	70	-0.00328
13	nasadi bagrema	12	0	0	0	3100	39	468	228	1365	0	879	0	93	0.006688
	Total : 96081	17207	56	0	466	45065	2238	2497	3652	14341	299	8582	603	1075	

$Kappa_{uk}$ =0.12066189

Tablica 11. Prikaz rezultata izračuna kappa vrijednosti za algoritam *minimum distance* za područje PP Medvednica

		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	**13**	**kappa**
1	*Abieti-Fagetum*	10966	39	0	28	14770	545	282	606	3584	299	1178	274	181	0.270256
2	*Arrhenatheretum elatioris*	0	0	0	0	87	113	0	0	242	0	162	120	25	-0.00196
3	*Bromo-Cynosuretum cristati*	0	0	0	0	219	469	14	0	161	0	14	0	0	0
4	*Bromo-Plantaginetum mediae*	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	*Lamio orvale-Fagetum sylvaticum*	225	0	0	0	1235	0	249	121	38	0	91	0	0	0.01422
6	kulture	0	70	0	0	7	44	15		65	0	0	0	0	0.032689
7	*Luzulo albidae-fagetum*	267	0	0	0	2055	18	204	26	505	0	141	0	11	0.044028
8	*Luzulo-Quercetum petrae*	374	0	0	0	2466	9	98	666	1113	62	977	45	26	0.086103
9	*Epimedio-Carpinetum betuli*	0	0	0	0	35	0	0	0	0	0	3	0	0	-0.00078
10	*Epimedio-Carpinetum betuli subas. Luzuletosum*	338	0	0	5	16853	939	955	2204	7351	12	5946	230	482	-0.008
11	*Querco-Castaneetum croaticum*	0	0	0	0	199	0	18	2	85	0	65	0	0	0.006399
12	*Querco-Ostryetum carpinifoliae*	5021	0	0	57	7330	83	622	616	1539	51	566	31	24	-0.01018
13	nasadi bagrema	0	0	0	0	84	0	20	0	36	0	23	0	0	-0.00276
	Total : 97426	17191	109	0	90	45340	2220	2477	4241	14719	424	9166	700	749	

$Kappa_{uk}$ = 0,065280761

Tablica 12. Prikaz rezultata izračuna kappa vrijednosti za algoritam *maximum likelihood* za područje PP Žumberak-Samoborsko gorje

		1	2	3	4	kappa
1	*Fagetum montanum*	63053	849	26	0	0.95254
2	kulture	177	22024	755	0	0.912719
3	*Querco-Carpinetum*	64	0	0	0	-0.00127
4	*Salicion albae*	1090	1373	11017	168	0.02109
	Total: 100596	64384	24246	11798	168	

Kappa$_{uk}$ = 0.716338

Tablica 13. Prikaz rezultata izračuna kappa vrijednosti za algoritam *minimum distance* za područje PP Žumberak-Samoborsko gorje

		1	2	3	4	kappa
1	*Fagetum montanum*	4390	4	0	0	0.995805
2	kulture	15	5888	238	0	0.914903
3	*Querco-Carpinetum*	0	6	363	0	0.12597
4	*Salicion albae*	7	352	3548	54	0.019874
	Total: 14865	4412	6250	4149	54	0.995805

Kappa$_{uk}$ = 0.616074

Tablica 14. Prikaz rezultata izračuna kappa vrijednosti za algoritam *maximum likelihood* za sjevernu satelitsku snimku područja NP Krka

		1	**2**	**3**	**4**	**5**	**6**	**kappa**
1	*Festuco-Koelerietum splendentis*	13	4	0	0	0	0	0.005222
2	*Querco-Carpinetum orientalis*	102	6527	3559	105	49	141	0.467017
3	ratarske površine	2611	2437	23119	9	58	71	0.676054
4	*Orno-Quercetum ilicis*	765	2340	104	627	339	164	0.203169
5	*Pinus halepensis*	633	808	920	121	6659	110	0.776351
6	rijeka	370	501	216	323	175	8242	0.868908
	Total: 62222	4494	12617	27918	1185	7280	8728	

$Kappa_{uk}$ = 0.620192

Tablica 15. Prikaz rezultata izračuna kappa vrijednosti za algoritam *minimum distance* za sjevernu satelitsku snimku područja NP Krka

		1	**2**	**3**	**4**	**5**	**6**	**kappa**
1	*Festuco-Koelerietum splendentis*	84	2	0	0	0	0	0.051883
2	*Querco-Carpinetum orientalis*	25	4580	2760	116	5	47	0.267215
3	ratarske površine	320	641	4284	0	35	33	0.530923
4	*Orno-Quercetum ilicis*	530	5930	466	333	1049	388	0.028754
5	*Pinus halepensis*	1037	1618	1122	132	6310	303	0.613216
6	rijeka	948	1094	306	437	347	9188	0.77137
	Total: 44470	2944	13865	8938	1018	7746	9959	

$Kappa_{uk}$ = 0.456903

Tablica 16. Prikaz rezultata izračuna kappa vrijednosti za algoritam *maximum likelihood* za južnu satelitsku snimku područja NP Krka

		1	**2**	**3**	**4**	**5**	**6**	**kappa**
1	*Festuco-Koelerietum splendentis*	15152	958	4192	172	30	8	0.476414
2	*Querco-Carpinetum orientalis*	853	988	392	345	20	0	0.110671
3	ratarske površine	8381	2581	26191	12	356	81	0.587229
4	*Orno-Quercetum ilicis*	3359	4874	1036	812	1941	540	0.083247
5	*Pinus halepensis*	694	621	717	59	6361	67	0.701537
6	rijeka	437	456	184	327	202	8152	0.862319
	Total: 91551	28876	10478	32712	1727	8910	8848	

Kappa$_{uk}$ = 0.511172

Tablica 17. Prikaz rezultata izračuna kappa vrijednosti za algoritam *minimum distance* za južnu satelitsku snimku područja NP Krka

		1	**2**	**3**	**4**	**5**	**6**	**kappa**
1	*Festuco-Koelerietum splendentis*	5621	534	2697	5	30	15	0.280449
2	*Querco-Carpinetum orientalis*	897	1195	3031	262	28	0	0.001466
3	ratarske površine	12614	3083	20331	170	148	3	0.216822
4	*Orno-Quercetum ilicis*	911	2795	793	314	838	50	0.070841
5	*Pinus halepensis*	1574	2458	1166	217	7605	635	0.636367
6	rijeka	625	14593	17644	398	360	9986	0.255318
	Total: 113626	22242	24658	45662	1366	9009	10689	

Kappa$_{uk}$=0.24518

4 RASPRAVA

Fitocenološka istraživanja izvođena tijekom 20. stoljeća kulminirala su provedbom projekta Kartiranje vegetacije Hrvatske koji je ostao nedovršen do danas. Ovo istraživanje je provedeno kako bi se testirala mogućnost dopune starih rukopisnih vegetacijskih karata koje bi mogle poslužiti kao referentno polazište za sva daljnja istraživanja poput praćenja procesa dinamike vegetacije (Sedlar 2012) ili praćenja poremećaja šumskih staništa (Senf i sur. 2017), odnosno kako bi se mogle pratiti promjene koje se događaju u našem okolišu.

Sa starih vegetacijskih karata područja sjeverozapadne Hrvatske zajednice *Aceri-Fraxinetum croaticum, Bromo-plantaginetum mediae, Corno-Ligustretum illyricum, Corno-Ligustretum croaticum, Equiseto-Scirpetum sylvatici, Festuco-Agrostidetum, Genisto elatae-Quercetum roboris, Genisto-Callustrae croaticum, Glycerietum maximae, Junco-Menthetum longifoliae, Koelerio-Brachypodietum, Lathyro-Quercetum petrae, Leucoio-Fraxinetum, Lolio-potentilletum anserinae, Ostryo-Fagetum, Querco-Fagetum, Querco-Ostryetum carpinifoliae, Scirpo-Phragmitetum* i *Tilio-Taxetum* nisu digitalizirane zbog male i fragmentirane površine koju ove biljne zajednice zauzimaju na analiziranom području. Neke su pak zajednice prepoznate kao sinonimi te su prethodno nomenklaturno usklađene. Zbog malene površine i otežane razlučivosti, iz analize su morale biti izbačene i kulture bora te sastojine sljedećih vrsta: *Castanea vesca, Pinus nigra, Pinus sylvestris, Pinus strobus, Larix europea, Picea abies, Fraxinus excelsior, Alnus glutinosa i Salix caprea.* Naime, minimalna površina trening područja mora iznositi 54 000 m^2, što nije bilo moguće postići u slučaju navedenih zajednica. Iz istog razloga, za područje sjeverne Dalmacije iz analize su izbačene sljedeće biljne zajednice: *Andropogini-Diplachnetum serotinae, Danthonio-Scorzoneretum villosae, Festuco-Koelerietum splendentis Caricetosum humilis, Laevi-Helianthemetum, Ononidi-Brometum condensati, Pinetum, Seslerio-Caricetum humilis* te homogene sastojine *Juniperus phoenica.* Za zajednicu *Pinetum* bilo je nemoguće odgonetnuti na koju točno zajednicu borova se ovaj naziv odnosi pa je iz tog razloga izbačena iz daljnje analize. Također, nasadi i sastojine pojedinih drvenastih vrsta izbačeni su iz analize zbog nemogućnosti stvaranja njihovog jedinstvenog spektralnog potpisa što je posljedica tehničkih specifikacija senzora Landsat TM satelita čija je moć razlučivanja ograničena.

Nadalje, neke od navedenih zajednica morale su biti izbačene iz analize zbog pojave pomaka od cca 150 metara koji se javlja zbog nepotpunog preklapanja starih, georeferenciranih topografskih vegetacijskih podloga i satelitskih snimaka. Unatoč pokušaju ponovnog georeferenciranja starih vegetacijskih karata, problem pomaka nije riješen te se s daljnjom analizom nastavilo uzimajući u obzir sam pomak, to jest pri iscrtavanju poligona vegetacijskih zajednica i digitalizaciji trening područja bilo je potrebno paziti da poligoni budu centrirani unutar označenog područja zajednice u radijusu od 200 m. Nepreciznosti starih vegetacijskih karata uvelike doprinosi i činjenica da su biljne zajednice na vegetacijske karte ucrtavane ručno. Shodno tome, pojava pomaka moguća je posljedica greške pri prvotnom georeferenciranju nakon čega je pogrešno georeferencirana karta digitalizirana i korištena u ovom istraživanju.

Prilikom digitalizacije trening područja, u nekim je slučajevima od velike koristi bila False Color Composite slika spektralnih kanala 3, 4 i 5 koja pojačava i ističe spektralne razlike biljnog

pokrova i prikazuje ih različitim bojama i karakterističnim uzorcima (Chen i sur. 2015) - rozim tonovima te kombinacijom rozih i zelenih tonova najčešće su označene nešumske, travnjačke zajednice kao i agrikulturne površine, a zelenom šumske zajednice pa je unutar šumskog poligona bilo lako uočiti granicu između šumske i nešumske vegetacije. Problem bi nastajao kada bi trebalo odrediti granicu između npr. dviju šumskih zajednica male površine koje se nalaze jedna do druge, a problem postaje još veći s obzirom na postojanje pomaka između vegetacijske karte i satelitske snimke. U tim slučajevima pokušavala bih, uspoređujući vegetacijsku kartu i satelitsku snimku, pronaći područje gdje se takva šumska zajednica najviše ističe, odnosno pokušavala bih pronaći elemente Zemljinog pokrova poput vodotokova, prometnica, naselja koji bi mi poslužili kao orijentir i potvrdili da je riječ baš o toj zajednici. Ako to ne bi uspjelo zajednica bi bila izbačena iz procesa digitalizacije i daljnje analize.

Poteškoćama pri analizi doprinjela je i nomenklaturna nedosljednost prisutna u legendama starih rukopisnih vegetacijskih karata. Zastarjela, nepotpuna i neusklađena nomenklatura prisutna u starim rukopisnim vegetacijskim kartama ne iznenađuje s obzirom da se kartiranje vegetacije Hrvatske provodilo tijekom dvadesetogodišnjeg perioda od strane različitih autora. Naime, tijekom 20. stoljeća na području bivše Jugoslavije, fitocenološka istraživanja provodila su se nesustavno te se prilikom imenovanja biljnih zajednica nije poštovao Međunarodni kodeks fitocenološke nomenklature tako da su u području sintaksonomije i dan-danas potrebna detaljna i sustavna istraživanja (Vojniković 2003, Vukelić i sur. 2010a, Vukelić i sur. 2010b). Kako bi se minimalizirala mogućnost pogreške u procesu klasifikacije biljnih zajednica, odnosno kako bi se spriječilo pogrešno klasificiranje biljnih zajednica zbog dodijeljivanja različitih imena područjima istih spektralnih vrijednosti, moralo se uskladiti imena biljnih zajednica navedenih u legendama starih vegetacijskih karata s recentnim i prihvaćenim nazivljem (Prilog 1. i 2.).

Rezultati istraživanja pokazali su kako područje PP Medvednica ima najveći broj klasificiranih biljnih zajednica i najveći broj odgovarajućih zajednica prepoznatih na vektorskoj podlozi karte staništa, ali i najveći broj pogrešno klasificiranih biljnih zajednica, odnosno najlošiju kappa vrijednost. S obzirom na kontrolne klase karte staništa, oba korištena algoritma su točno klasificirala zajednice *Festuco drymeiae-Abietetum* Vukelić et Baričević 2007 I *Omphalodo-Fagetum* Tregubov 1957, dok je algoritam *maximum likelihood* točno klasificirao i klasu poljoprivrednih kultura.

Za područje PP Medvednica algoritam *maximum likelihood* pogrešno je klasificirao sljedeće klase: *Luzulo-Fagetum, Luzulo-Quercetum petrae, Querco-Carpinetum luzuletosum, Querco-Ostryetum* i nasade bagrema. Sve navedene klase, točnije njihovi pikseli, pridruženi su klasi *Fagetum montanum,* odnosno šumi bukve s velikom mrtvom koprivom, koja je ujedno i jedna od najrasprostranjenijih šumskih zajednica na ovom području. Pogrešno su klasificirane i klase travnjačkih zajednica *Bromo-Cynosuretum cristati* te *Bromo-Plantaginetum* koje su pridružene klasi poljoprivrednih kultura. Jedna od mogućnosti ovakvog ishoda za travnjačke zajednice jest sušno ljeto, nakon čega bi vegetacija navedenih zajednica kao i polja na kojima se uzgajaju kulture bila suha te bi bilo nemoguće razlikovati njihove spektralne potpise. Za razdiobu na temelju spektralnih potpisa, odnosno klasifikaciju travnjačke vegetacije najoptimalniji su mjeseci srpanj i rujan, no tijekom rujna dolazi do smjene travnjačkih tipova koji preferiraju toplo i suho, odnosno hladno i vlažno vrijeme što dovodi do manje razlike u spektralnim potpisima, odnosno

smanjena je mogućnost razdiobe travnjačkih zajednica (Price i sur. 2002). Pošto su za područje Medvednice korištene snimke iz rujna zbog najmanje pokrivenosti oblacima i najveće kvalitete, bolji rezultati, odnosno bolja mogućnost razdiobe spektralnih potpisa travnjačke vegetacije mogla bi se postići korištenjem snimaka snimljenim u lipnju ili srpnju. Problematika klasifikacije travnjačkih zajednica vezana je i uz antropogeno djelovanje što za posljedicu nosi zaraštavanje travnjačkih površina, kao i prelazak jednog tipa travnjačke zajednice u drugi što je primjećeno na području PP Žumberak-Samoborsko gorje. Uz to, mozaična struktura i heterogenost biljnih zajednica prisutnih na području PP Žumberak-Samoborsko gorje doprinose prirodnom zaraštavanju travnjačkih površina. Ono što također predstavlja problem, jest raštrkana i malena površina koju travnjačke zajednice zauzimaju na području gdje pretežito prevladavaju šumske zajednice te ih je zbog toga teško razlučiti i razdvojiti na temelju spektralnog potpisa (Jelaska et al. 2005). Rezultati istraživanja Jelaske i sur. (2005) pokazali su višu pouzdanost pri klasifikaciji šumske od nešumske vegetacije, dok u ovom istraživanju nije primjećena znatna razlika te su šumske zajednice klasificirane s podjednakom pouzdanošću kao i one nešumske.

Klasi poljoprivrednih kultura također je pridružena zajednica *Querco-Castaneetum* što je vrlo vjerojatno posljedica nedovoljno precizne digitalizacije trening područja za klasu *Querco-Castaneetum,* a neprecizna digitalizacija je posljedica ranije spomenutog pomaka. Naime, južni obronci Medvednice poprilično su gusto naseljeni te se u nekim dijelovima šuma hrasta kitnjaka i pitomog kestena (*Querco-Castaneetum sativae* Ht. 1938.), koja se rasprostire na nižim nadmorskim visinama, nalazi u neposrednoj blizini površina obraslih kulturama poput vrtova. Nadalje, klase *Querco-Carpinetum* i *Arrhenatheretum elatioris* pridružene su klasi *Querco-Castaneetum*.

Algoritam *minimum distance* je za područje PP Medvednica klase *Luzulo-Fagetum, Luzulo-Quercetum petrae, Querco-Carpinetum, Querco-Carpinetum luzuletosum, Querco-Castaneetum, Querco-Ostryetum* te nasadi bagrema također pridružio klasi *Fagetum montanum*. Ovaj algoritam svrstao je klasu *Arrhenatheretum elatioris* pod *Querco-Carpinetum,* dok su poljoprivredne kulture svrstane u klasu *Arrhenatheretum elatioris*.

Za primijetiti je kako je najveći broj piksela korištenjem obaju algoritama svrstan u klasu *Fagetum montanum* koja označava zajednicu *Lamio orvalae-Fagetum sylvaticum* (Ht. 1938) Borhidi 1963, to jest šumu bukve s velikom mrtvom koprivom, karakterističnu za brdski vegetacijski pojas Hrvatske. Klasa *Luzulo-Fagetum* označava acidofilnu varijantu brdskih bukovih šuma i to šumu bukve s bjelkastom bekicom (*Luzulo -Fagetum* Meusel 1937). Dominantna vrsta u najgornjem sloju vegetacije – bukva, zajednička je objema zajednicama te se one razlikuju po prizemnom sloju biljaka i tipu tla na kojem rastu, stoga ovakav ishod klasifikacije nije neočekivan. Ono što iznenađuje jest da su oba algoritma u klasu bukovih šuma svrstala i klase šuma hrasta kitnjaka (*Luzulo-Quercetum petrae, Querco-Carpinetum, Querco-Carpinetum luzuletosum i Querco-Castaneetum)* koje su karakteristične za brežuljkasti vegetacijski pojas te klasu azonalne šume hrasta medunca (*Querco-Ostryetum).* Ovakvi rezultati ukazuju kako je metoda klasifikacije korištena u ovom istraživanju neuspješno razlučila dvije najzastupljenije i najučestalije listopadne vrste u šumskim zajednicama Hrvatske, dok rezultati usporedbe točnosti klasifikacije biljnih zajednica PP Medvednica upućuju na vrlo slabo podudaranje između klasificiranih i kontrolnih klasa.

Za područje PP Žumberak-Samoborsko gorje, oba algortima pogrešno su klasificirala svezu *Salicion albae* i pridružila ju klasi *Querco-Carpinetum orientalis* što je moguće zbog linijskog karaktera poligona trening područja za klasu *Salicion albae* (Slika 12.). Algoritam *maximum likelihood* je i klasu *Querco-Carpinetum orientalis* pogrešno smjestio u klasu *Fagetum montanum*.

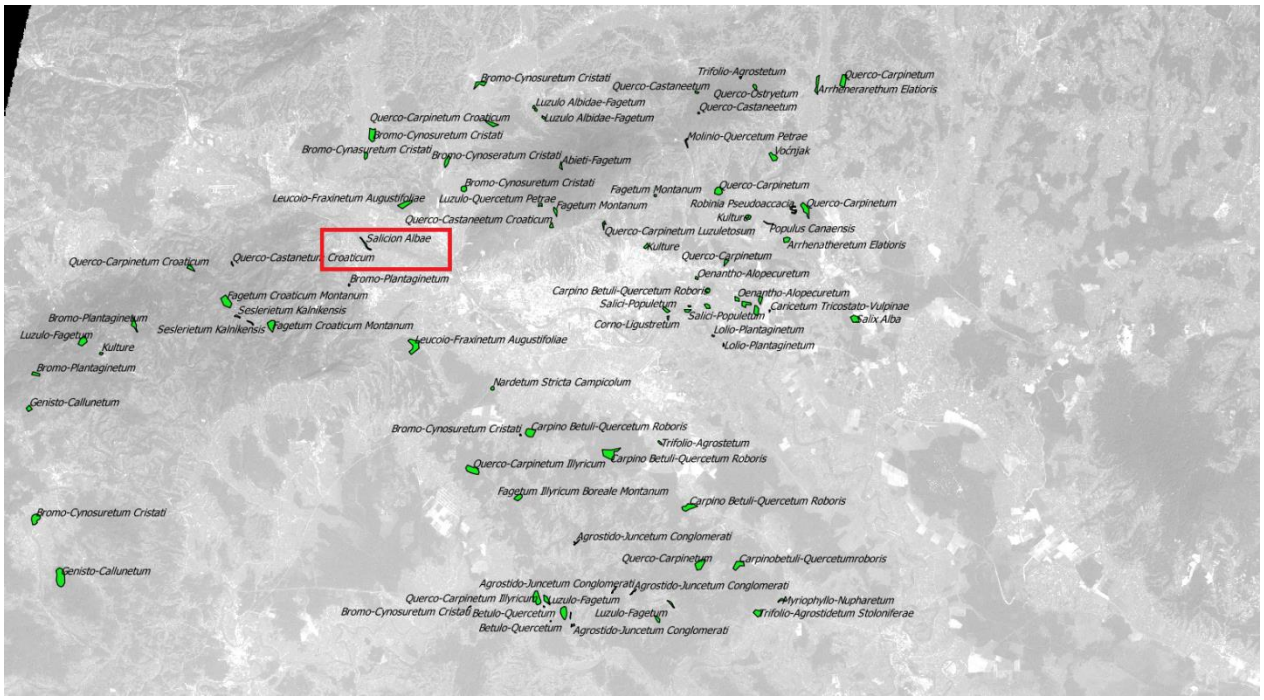

Slika 12. Prikaz poligona za trening područja sjevero-zapadne Hrvatske izrađenih u programu QGIS 2.18.14. Crvenim okvirom označen je linijski poligon klase *Salicion albae*.

Prema izračunu vrijednosti kappa koeficijenta, područje PP Žumberak-Samoborsko gorje pokazalo se najpouzdanijim. Razlog tomu je vjerojatno činjenica da je pri analizi ovog područja na karti staništa definiran najmanji broj klasa s kojima su se rezultati klasifikacije mogli usporediti, njih četiri. Naime, u istraživanju koje su proveli Mathieu i sur. 2007 smanjenjem broja klasa s prvotnih 15 na 10 povećala se ukupna kappa vrijednost za nešto više od 10%, odnosno povećala se točnost klasifikacije te su zaključili kako je manji broj klasa pogodan za pouzdano razlučivanje nekih viših, manje informativnih vegetacijskih kategorija.

Na području NP Krka u slučaju sjeverne satelitske snimke algoritam *minimum distance*, a u slučaju južne satelitske snimke oba algoritma, pogrešno su klasificirala zajednicu *Fraxino orni-Quercetum ilicis* Horvatić (1956) 1958 koja pripada kategoriji primorske vazdazelene šume i makije hrasta crnike s crnim jasenom i dolazi u eumediteranskoj zoni. Najviše zajedničkih piksela pronađeno je sa zajednicom *Querco-Carpinetum orientalis* Horvatić 1939 što je termofilna primorska šuma i šikara hrasta medunca i bijeloga graba i pripada zoni submediterana. Ove dvije zajednice možda bi se mogle razlučiti korištenjem satelitskih snimaka iz recimo listopada ili čak studenog, kada bi postojala izraženija razlika između ovih dviju zajednica, pošto

zajednica *Querco-Carpinetum orientalis* pripada listopadnom tipu šume. Neuspjeh klasifikacije sastojina *Pinus nigra* i *Robinia pseudacaccia* je očekivan s obzirom na prostornu gustoću ovih jedinki, koja nije pogodna za 30-metarsku razlučivost Landsat satelitskih snimaka. Poligoni vodenih površina na svim su snimkama digitalizirani i klasificirani kako ne bi došlo do misklasifikacije, odnosno kako algoritimi ne bi pogrešno pridružili piksele koji pripadaju vegetacijskim zajednicama područjima pokrivenima vodenim površinama. To se dogodilo jedino u slučaju kontrole točnosti južne satelitske snimke područja NP Krka za algoritam *maximum likelihood* gdje je najveći broj piksela klase more svrstan pod klasu *Querco-Carpinetum orientalis*.

U novije vrijeme, istraživanja vezana uz klasifikaciju biljnog pokrova putem metoda daljinskog snimanja usmjerena su ka postizanju što veće pouzdanosti, tj. točnosti dobivenih rezultata (Aldoski i sur. 2013). Kappa statistika je postala tradicionalna metoda procjene točnosti rezultata daljinskoga snimanja, no Pontius i Millones (2011) smatraju da uvriježena praksa koja se koristi ovim statističkim metodama daljinskoga snimanja u kojima stopa točnosti mora iznositi više od 85% nije prihvatljiva te zagovaraju primjenu novih statističkih modela za procjenu točnosti rezultata daljinskoga snimanja. Nadalje, u istraživanju provedenom radi usporedbe triju različitih metoda klasifikacije biljnog pokrova, tzv. *per-pixel* metoda, koja je korištena i u ovom istraživanju, pokazala se najmanje pouzdanom (Palm 2015). Kada bi se pokušalo sa drugom, npr. *object-based* metodom, rezultati bi možda ispali točniji. Manandhar i sur (2009) su također dobili loše rezultate u procjeni točnosti za *maximum likelihood* metodu, a kao zamjenu za tradicionalnu metodu kontrolirane klasifikacije i algoritam *maximum likelihood*, Hogland i sur. (2013) predlažu metodu politomne logističke regresije (PLR). Također, upotrebom druge, tzv. *fuzzy* metode klasifikacije, koja spada u *soft classifiers*, mogla bi se poboljšati pozdanost klasifikacije (Zhang i Foody 1998). Kako bi pospješili točnost klasifikacije travnjačkih zajednica Mongolije, Sha i sur. (2008) su razvili novu hibridnu metodu klasifikacije, tzv. *hybrid fuzzy classifier* koja se pokazala pouzdanijom od uobičajene kontrolirane klasifikacije.

Modernije metode poput Classification Trees i Random Forests pokazale su se pouzdanijima od konvencionalnih metoda poput *maximum likelihood*-a pri klasifikaciji vegetacije na razini 15 klasa (Sluiter i Pebesma 2010), no one zbog svoje kompleksnosti nisu korištene u ovom istraživanju.

5 ZAKLJUČAK

- Rezultati dobiveni ovim istraživanjem, pokazali su ograničenu mogućnost primjene arhivskih Landsat 5 TM satelitskih snimaka za potrebe retrospektivnog kartiranja vegetacije.

- S povećanjem broja kartiranih klasa, pouzdanost klasifikacije se smanjuje.

- Od dva korištena algoritma, *maximum likelihood* se pokazao pouzdanijim.

- Za povećanje pouzdanosti dobivenih rezultata pri većem broju klasa potrebno je koristiti složenije metode i/ili veći broj satelitskih snimaka snimljenih u različito vrijeme za isto područje, što oboje čini postupak tehnički zahtjevnijim i dugotrajnijim.

6 LITERATURA

Achard F., Hugh E., Hans-Jürgen S., Philippe M., Pinilla G., Javier F., Richards T., Malingreau J.P. (2002): Determination of Deforestation Rates of the World's Humid Tropical Forests. Science **297:** 999-1002

Al-doski J., Mansorl S.B., Shafri H.Z.M. (2013): Image classification in remote sensing. Journal of Environmental and earth Science **3**: 141-147

Antonić, O., Kušan, V., Jelaska, S., Bukovec, D., Križan, J., Bakran-Petricioli, T., Gottstein S., Pernar,R., Hećimović, Ž., Janeković, I., Grgurić, Z., Hatić, D., Major, Z., Mrvoš, D., Peternel, H., Petricioli, D., Tkalčec, S. (2005): Kartiranje staništa Republike Hrvatske (2000.-2004.) - pregled projekta. Drypis **1:** 1-2

Baghdadi N., Mallet C., Zribi M. (2018): QGIS in Remote Sensing: QGIS and generic tools **4**: 127-129

Braun-Blanquet J. (1932): Plant Sociology. New York , McGraw-Hill Book Company, str. 361-372

Campbell J.B. i Randolph H.W. (2011): Introduction to Remote Sensing. New York, Guilford Publications, str. 3-30

Chen J., Chen J., Liao A., Cao X., Chen L., Chen X., He C., Han G., Peng S., Lu M., Zhang W., Tong X., Mills J. (2015): Global land cover mapping at 30m resolution: A POK-based operational approach. ISPRS Journal of Photogrammetry and Remote Sensing **103**: 7-27

Eastman J.R. (2012): Idrisi Selva Tutorial, manual version 17. Clark University **4:** 209-216

Eastman J.R. (2012): Idrisi Selva Manual, manual version 17. Clark University **17:** 180-209

Fierens F., Rosin P.L. (1994): Filtering remote sensing data in the spatial and feature domains. Proceedings of SPIE – The International Society for Optical Engineering **2315:** 472-482

Franke J., Gebreslasie M., Bauwens I., Deleu J., Siegert, F. (2015): Earth observation in support of malaria control and epidemiology: MALAREO monitoring approaches. Geospatial Health **10**: 335

Franklin S., Wulder M., Skakun R.S., Carroll A.L. (2003): Mountain Pine Beetle Red-Attack Forest Damage Classification Using Stratified Landsat TM Data in British Columbia, Canada. Photogrammetric Engineering and Remote Sensing **69:** 283-288

Fretwell P.T., LaRue M.A., Morin P., Kooyman G.L., Wienecke B., Ratcliffe N, I sur. (2012): An Emperor Penguin Population Estimate: The First Global, Synoptic Survey of a Species from Space. PLoS ONE **7**: 10

Hogland J., Billor N., Anderson N. (2013): Comparison of standard maximum likelihood classification and polytomous logistic regression used in remote sensing. European Journal of Remote Sensing **46**: 623-640

Hrvatska agencija za okoliš i prirodu (2017): Bioportal. *http://www.bioportal.hr/*; pristupljeno: prosinac 2018

Jelaska S.D., Kušan V., Peternel H., Grgurić Z., Mihulja A., Major Z. (2005): Vegetation mapping of Žumberak-Samoborsko gorje Nature Park, Croatia, using Landsat 7 and field data. Acta Botanica Croatica **64**: 303-311

Jelaska S. D. (2009): Vegetation Mapping Applications. U: Hengl T., Reuter H.I. (ur.) Geomorphometry: Concepts, Software, Applications. Elsevier, str. 481-496

Kim, Do-Hyung & Sexton, Joseph & Noojipady, Praveen & Huang, Chengquan & Anand, Anupam & Channan, Saurabh & Feng, M & Townshend, J. (2014): Global, Landsat-based forest-cover change from 1990 to 2000. Remote Sensing of Environment **155**: 178-193

Küchler A.W.: Historical sketch. U: Küchler A.W. i Zonneveld I.S. (ur.) Vegetation mapping. Dordrecht, Kluwer Academic Publishers, str. 1-13

Lauer D.T., Morain S.A., Salomonson V.V (1997): The Landsat program: Its origins, evolution, and impacts. Photogrammetric Engineerind and Remote Sensing **63**: 831-838

Lobitz B.M., Beck L.R., Huq A., Wood B., Fuchs G., Abu F., Colwell, R. (2000): Climate and Infectious Disease: Use of Remote Sensing for Detection of Vibrio cholerae by Indirect Measurement. Proceedings of the National Academy of Sciences of the United States of America. **97**: 1438-43

Long, B.G., Poiner, I.R. i Harris, A.N.M. (1993): Method of estimating the standing stock of *Trochus niloticus* incorporating Landsat satellite data, with application to the trochus resources of the Bourke Isles, Torres Strait, Australia. Marine Biology **115**: 587

Luo, L., Mountrakis, G. (2011): Converting local spectral and spatial information from a priori classifiers into contextual knowledge for impervious surface classification. ISPRS Journal of Photogrammetry and Remote Sensing **66**: 579-587

Mathieu R., Aryal J., Chong A.K. (2007): Object-Based Classification of Ikonos Imagery for Mapping Large-Scale Vegetation Communities in Urban Areas. Sensors **7**: 2860-2880

Miller, D. (1984): Commercialization of The Landsat: Legal and Foreign Policy Implications. Proceedings of the ASIL Annual Meeting, **78**: 186-186

Mitić B., Topić J., Ilijanić Lj., Jasprica N., Milović M., Ruščić M., Pandža M., Bogdanović S., Dolina K. (2009): Kartiranje flore Dalmacije. Izvještaj u sklopu programa za Očuvanje i održivo korištenje biološke raznolikosti na dalmatinskoj obali – COAST. Zagreb, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, str. 30-60

Monserud R. A. i Leemans R. (1992): Comparing global vegetation maps with the Kappa statistic. Ecological Modelling, **62**: 275-293

Nacionalna klasifikacija staništa Republike Hrvatske, IV. verzija. Pravilnik o popisu stanišnih tipova, karti staništa te ugroženim i rijetkim stanišnim tipovima (NN 88/14)

Palm F. (2015): Urban Vegetation mapping using remote sensing techniques; A comparison of methods. Stockholm University, Faculty of Science, department of Physical Geography, str. 12-14

Pontius R., Millones M. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. International Journal of Remote Sensing **32** 4407-4429

Price K., Guo X., Stiles J.M. (2002): Optimal Landsat TM band combinations and vegetation indices for discrimination of six grassland types in eastern Kansas. International Journal of Remote Sensing **23**: 5031-5042

Sedlar Z. (2012): Dinamka vegetacije na otoku Molatu u razodblju od 1910. do 2010. godine. Doktorski rad. Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Biološki odsjek, str. 22-25

Senf C., Pflugmacher D., Hostert P., Seidl, R. (2017): Using Landsat time series for characterizing forest disturbance dynamics in the coupled human and natural systems of Central Europe. ISPRS journal of photogrammetry and remote sensing **130:** 453-463

Sluiter R. i Pebesma E.J. (2010): Comparing techniques for vegetation classification using multi- and hyperspectral images and ancillary environmental data. International Journal of Remote Sensing **31**: 6143-6161

Sha Z., Bai Y., Xie Y, Yu M., Zhang L. (2008). Using a hybrid fuzzy classifier (HFC) to map typical grassland vegetation in Xilin River Basin, Inner Mongolia, China. International Journal of Remote Sensing **29**: 2317-2337

Šegulja N, Hršak V. (1988): Priručnik za fitocenološka i ekološka istraživanja vegetacije. Zagreb, Hrvatsko ekološko društvo i dr. Ante Pelivan, str. 7

Šulc I. (2016): Digitalna kartografija, Priručnik za predmet Digitalna kartografija (2. razred opće gimnazije). Ivanec, Srednja škola Ivanec i Srednja Škola Matije Blažine, str. 1-14

Thorne J. H, Kelsey R., Honig J., Morgan B. (2006): The Development of 70-Year-Old Wieslander Vegetation Type Maps and an Assessment of Landscape Change in the Central Sierra Nevada. University of California Davis: Information Center for the Environment, str. 3-6

U.S. Geological Survey (2017): Earth Explorer. http://earthexplorer.usgs.gov/; pristupljeno: svibanj 2017

Vukelić, J., Alegro, A. i Šegota, V. (2010 a): Altimontanska-subalpska smrekova šuma s obrubljenim gladcem (*Laserpitio krapfii-Piceetum abietis ass. nova*) na sjevernom Velebitu (Hrvatska). Šumarski list, **134** (5-6): 211-226

Vukelić, J., Alegro, A., Šegota, V. i Šapić, I. (2010 b): Nomenklaturno-fitocenološka revizija asocijacije *Calamagrostio variae-Piceetum dinaricum* Bertović 1975 nom. illeg. u Hrvatskoj. Šumarski list, **134** (11-12): 559-566

Vojniković, S. (2003): Povijest i postojeći problemi fitocenološke nomenklature i klasifikacije. Šumarski list **3-4:**153

Wang K., Franklin S. E., Guo X., & Cattet M. (2010): Remote sensing of ecology, biodiversity and conservation: a review from the perspective of remote sensing specialists. Sensors **10**: 9647-9666

Zhang J, Foody G. M. (1998) A fuzzy classification of sub-urban land cover from remotely sensed imagery, International Journal of Remote Sensing, **19**: 2721-2738

Yichun Xie, Zongyao Sha, Mei Yu (2008): Remote sensing imagery in vegetation mapping: a review. Journal of Plant Ecology **1:** 9–23

7 Prilozi

Prilog 1. Popis biljnih kategorija prisutnih u legendama rukopisnih vegetacijskih karata za područje sjeverne Hrvatske, usklađeno s recentnom nomenklaturom prema Nacionalnoj klasifikaciji staništa (NKS) iz 2004.

Zajednica	sinonimi na karti	naziv prema NKS-u
Abieti-Fagetum		*Festuco drymeiae-Abietetum* Vukelić et Baričević 2007
Aceri-Fraxinetum croaticum		*Lunario redivivae-Aceretum pseudoplatani* Klika 1955
Agrostido-Juncetum conglomerati		*Agrostidi-Juncetum conglomerati* Šegulja 1974
Arrhenatheretum elatioris	*Arrhenatheretum elatioris alopecuretosum subas.*	*Arrhenathereum elatioris* Br.-Bl. Ex Scherrer 1925
Betulo-Quercetum		*Betulo-Quercetum* R. Tx. 1937
Bromo-Cynosuretum cristati	*Bromo-Cynosuretum*	*Bromo-Cynosuretum cristati* Horvatić 1930
Bromo-Plantaginetum mediae typiyum	*Bromo-Plantaginetum mediae typicum, Bromo-Plantaginetum*	*Bromo-Plantaginetum mediae* Horvat 1931
Caricetum tricostato-vulpinae		*Caricetum tricostato-vulpinae* Horvatić 1930
Carici-Alnetum glutinosae		*Carici brizoidis-Alnetum glutinosae* Ht. 1938
Carpino betuli-Quercetum roboris		*Carpino betuli-Quercetum roboris typicum* Rauš 1975
Corno-Ligustretum	*Corno-Ligustretum croaticum, Corno-Ligustretum illyricum*	*Corno-Ligustretum* Ht. 1962 corr. Trinajstićet. Zi. Pavletić 1991
Deschampsietum caespitosae		*Deschampsietum caespitosae* Horvatić 1930
Equiseto-Scirpetum sylvatici		*Equiseto-Scirpetum sylvatici* Šegulja 1974
Fagetum montanum	*Fagetum illyricum boreale montanum, Fagetum croaticum montanum*	*Lamio orvalae-Fagetum sylvaticum* (Ht. 1938) Borhidi 1963
Festuco-Agrostietum	*Festuco-Agrostetum typicum*	*Festuco-Agrostidetum* Ht. 1951
Genisto elatae-Quercetum roboris	*Genisto-Callustrae croaticum*	*Genisto elatae-Quercetum roboris* Ht. 1938
Genisto-Callunetum croaticum,		*Genisto sagittalis-Callunetum* Ht. 1931
Glycerietum maximae		*Acoro-Glycerietum maximae* Slavnić 1956

Junco-Menthetum longifoliae		*Junco-Menthetum longifoliae* Lohm. 1953
Koelerio-Brachypodietum		*Koelerio macranthae-Brachypodietum rupestris* Trinajstić 1981
Lathyro-Quercetum petrae		*Lathyro-Quercetum petrae* Ht. (1938) 1958
Leucoio-Fraxinetum angustifoliae	*Leucoio-Fraxinetum*	*Leucoio-Fraxinetum angustifoliae* Glavač 1959
Lolio-Plantaginetum		*Lolio-Plantaginetum majoris* Beger 1930
Lolio-Potentilletum		*Potentilletum anserinae* Rapaics 1927 em. Passarge 1964
Luzulo-Fagetum	*Luzulo albidae-Fagetum*	*Luzulo-Fagetum* Meusel 1937
Luzulo-Quercetum petreae		*Potentillo micranthae-Quercetum petreae* (Vukelić 1991) Vukelić, Baričević et Šapić 2010
Molinio-Quercetum petreae		*Molinio arundinaceae-Quercetum petreae* Šugar 1972
Myriophyllo-Nupharetum		*Myriophyllo-Nupharetum* W. Koch 1926
Nardetum stricta campicolum		*Festuco-Agrostetum* subas. *nardetosum* (Trinajstić 1972, Hršak i Ilijanić 1987
Oenantho-Alopecuretum		*Oenantho silaifoliae-Alopecuretum pratensis* Stančić 2005
Ostryo-Fagetum		*Ostryo-Fagetum* M. Wraber ex Trinajstić 1972
Pruno spinosae-Crataegetum		*Corno-Ligustretum* Ht. 1962 corr. Trinajstić et Zi. Pavletić 1991
Querco-Carpinetum	*Querco-Carpinetum croaticum*	*Epimedio-Carpinetum betuli* (Ht. 1938) Borhidi 1963
Querco-Carpinetum illyricum		*Epimedio-Carpinetum betuli* (Ht. 1938) Borhidi 1963
Querco-Carpinetum luzuletosum		*Luzulo-Quercetum petraeae* (Hillitzer 1932) Passarge 1953=*Hieracio racemosi-Quercetum* Vukelić 1991
Querco-Castaneetum	*Querco-Castaneetum croaticum*	*Querco-Castaneetum sativae* Ht. 1938
Querco-Fagetum		*Querco-Castaneetum sativae* Ht. 1938
Querco-Ostryetum	*Querco-Ostryetum carpinifoliae*	*Querco-Ostryetum carpinifoliae* Ht. 1938

Salicion albae		*Salicion albae* ili *Salicetum albaeIsller* 1926
Salici-Populetum		*Salici-Populetum nigrae* (R. Tx. 1931) Meyer Drees 1936
Scirpo-Phragmitetum		*Phragmitetum australis* Soó 1927
Seslerietum kalnikensis		*Seslerietum kalkinensis* Ht. 1942
Tilio-Taxetum		*Tilio-Taxetum* Glavač 1959
Trifolio-Agrostetum	*Trifolio-Agrostietum stoloniferae*	*Trifolio-Agrostidetum stoloniferae* Marković 1973
Kulture:		
kultura bagrema		
kultura bora	nasadi bagrema	
kulture	nasadi crnogorice	
voćnjak	ratarske površine	
Sastojine:		
Alnus glutinosa		
ariš		
bagrem		
borovac		
breza vrištine		
Castanea sativa		
Castanea vesca		
duglazija		
Fraxinus excelsior		
Juncus effusus		
Larix europea		
obični bor		
Picea abies		
Pinus nigra		
Pinus silvestris		
Pinus strobus		
Populus canadensis		
Robinia pseudoacaccia		
Salix alba		
Salix caprea		
smreka		
Populus italica		
Kombinacije zajednica:		
***Arrhenatheretum elatioris* i kulture**		
Bromo-Cynosuretum cristati i Agrostido-Juncetem condensati		
Bromo-Cynosuretum cristati i Deschampsietum caespitosae		
***Bromo-Cynosuretum cristati* i kulture**		

***Bromo-Plantaginetum* i kulture**
Nardetum stricta campicolum i Deschampsietum caespitosae
Salicion albae i Arrhenatheretum elatioris

Prilog 2. Popis biljnih kategorija prisutnih u legendama rukopisnih vegetacijskih karata za područje srednje Dalmacije i zaleđa s pripadajućom recentnom nomenklaturom prema NKS-u iz 2004. godine

Zajednica	sinonimi na karti	naziv prema NKS-u
Abieti-Fagetum dinaricum		*Omphalodo-Fagetum* Tregubov 1957
Bromo-Seslerietum interruptae		*Bromo-Seslerietum interruptae* Trinajstić 1965
Carici-Centaureetum rupestris		*Carici-Centaureetum rupestris* Ht. 1931
Carpinetum orientalis illyricum		*Querco-Carpinetum orientalis* H-ić. 1939
Cisto-Ericion		*Cisto-Ericion* Ht-ić. 1958
Danthonio-Scorzoneretum villosae		*Junco -Scorzoneretum candollei* H-ić. 1934
Fagetum croaticum subalpinum	*Fagetum subalpinum*	*Ranunculo platanifolii-Fagetum* Marinček et al. 1993
Fagetum montanum		*Lamio orvale-Fagetum sylvaticum*(Ht. 1938) Borhidi 1963
Festucetum pseudovino vallesiaceae		*Festucetum rupicolae-valesiacae* (Ht. 1962) (Trinajstić 2000) Allegro 2003, nom nov. hoc loco
Festuco-Koelerietum caricetum humilis		-
Festuco-Koelerietum splendentis		*Festuco-Koelerietum splendentis*Horvatić 1975
Laevi-Helianthenetum		*Carici kitaibelianae-Helianthemetum balcanici* Ht. 1930
Ononidi-Brometum condensati		*Ononidi-Brometum condensati* Horvatić (1934) 1962
Orno-Quercetum ilicis		*Fraxino orni-Quercetum ilicis*Horvatić (1956) 1958
Paliuretum adriaticum		*Rhamno-Paliuretum* Trinajstić 1995
Pinetum		-
Querco-Carpinetum orientalis		*Querco-Carpinetum orientalis* Horvatić 1939
Satureio-Edraianthetum		*Satureio-Edraianthetum*Horvat 1942

Scolymo-Marrubietum		*Scolymo-Marrubietum incani*Horvatić et. Hodak 1956
Seslerio-Caricetum humilis		*Seslerio-Caricetum humilis* Ht. 1930
Seslerio-Fagetum		*Seslerio autumnalis-Fagetum*M. Wraber ex Borhidi 1963
Seslerio-Ostryetum	*Seslerio-Ostryetum carpinifoliae*	*Seslerio autumnalis-Ostryetum* Ht. et H-ić in Ht. 1950
Stipo-Salvietum officinalis		*Stipo-Salvietum officinalis* Horvatić 1958
Kulture:		
kultura bagrema		
kultura crnog bora		
ratarske površine		
Sastojine:		
Juniperus oxycedrus		
Juniperus phoenicae		
Pinus halepensis		
Kombinacije zajednica:		
alepski bor i *Stipo-Salvietum officinalis*		
Festuco-Koelerietum splendentis* i *Brachypodietosum		
Festuco-Koelerietum splendentis* i *Paliuretum adriaticum		
***Ononidi-Brometum condensati* i kullture**		
Paliuretum adriaticum i Scolymo-Marrubietum		
Querco-Carpinetum orientalis i Andropogini-Diplachnetum serotinae		
Querco-Carpinetum orientalis i Danthonio-scorzoneretum villosae		
Querco-Carpinetum orientalis i Festuco-Koelerietum splendentis		
Querco-Carpinetum orientalis i Stipo-Salvietum officinalis		
Seslerio-Ostryetum i Danthonio-Scorzoneretum villosae		

ŽIVOTOPIS

Osobni podaci

Ime i prezime: Barbara Špadina

Adresa: Kušlanova 50b

Mobilni telefon: 00385 91 1533 968

e-mail: barbaraspadina@gmail.com

Datum rođenja: 9.12.1991.

Školovanje

rujan 2015.- danas diplomski studij Eksperimentalne biologije, modul Botanika na Prirodoslovno-matematičkom fakultetu u Zagrebu

rujan 2010. – rujan 2015. prediplomski studij Biologije na Prirodoslovno-matematičkom fakultetu u Zagrebu

rujan 2006. – lipanj 2010. III. opća gimnazija u Zagrebu

rujan 2001. – lipanj 2009. Škola za strane jezike SOVA, engleski jezik

Radno iskustvo

2013./2014. edukator i animator na znanstvenim radionicama i rođendanima za djecu (Fora radionice)

2014./2015. vodič na interaktivnoj izložbi „Volim matematiku“ u Galeriji Klovićevi dvori

2014./2015. inventarizacija Lorkovićeve zbirke leptira u Hrvatskom prirodoslovnom muzeju

2016. sudjelovanje u terenskim istražvanjima i monitoringu saproksilnih vrsta kornjaša na području PP Papuk i NP Plitvička jezera

2016. – 2018. honorarni posao vodiča/edukatora u PP Medvednica na lokacijama špilja Veternica, Medvedgrad i rudnik Zrinski

2018./2019. rad u penjačkoj dvorani Hive (rad na pultu, animator na dječjim penjačkim rođendanima)

Znanja i vještine

- Aktivno znanje engleskog jezika (položen FCE ispit 2009.godine)
- Pasivno znanje talijanskog jezika
- MS Office paket
- Položen tečaj ronjenja, SSI certifikat
- Speleolog pripravnik (SO HPD Željezničar)

Dodatne informacije:

- članica i voditeljica sekcije Coleoptera u sklopu studentske udruge BIUS (2013.-2015.)
- posebna Rektorova nagrada 2014. / 2015. za sudjelovanje u Istraživačko-edukacijskom projektu „Grabovača 2014. "
- sudjelovanje u terenskom kartiranju prema Nacionalnom programu monitoringa za ciljanu vrstu jelenak (*Lucanus cervus* L. 1875)
- tehnička podrška na 17. karabidološkom kongresu u Primoštenu 2015.
- odrađena stručna laboratorijska praksa u herbariju Botaničkog zavoda Prirodoslovno-matematičkog fakulteta u Zagrebu
- volontiranje na radionici "Knjige na meniju- kukci za stolom" održane povodom Noći knjige 2016. u Nacionalnoj i sveučilišnoj knjižnici u Zagrebu
- sudjelovanje u florističkim istraživanjima u sklopu ekspedicije „Crveno jezero 2017. "
- sudjelovanje u interdisciplinarnoj radionici o istraživanju potopljenih paleookoliša LoLADRIA 2017
- koautor u:
  Budisavljević, A., Terlević, A., Mihelić, P., Špadina, B., Papković, D., Nikolić, T. i Šegota, V. (2017). Vaskularna flora šume Dotrščina (Zagreb, Hrvatska). *Glasnik Hrvatskog botaničkog društva, 5* (1), 4-19
- Junior cave expert u sklopu međunarodnog ljetnog znanstvenog kampa Operation Wallacea 2018
- sudjelovanje u biospeleološkim istraživanjima i predavanjima održanim u sklopu 3. tjedna prirodoslovlja na Korčuli (2018)
- članica udruge ADIPA i članica SO HPD Željezničar