Praćenje širenja amorfe (Amorpha fruticosa L.) na području Lonjskog polja korištenjem satelitskih snimaka

Skokić, Dorian

Master's thesis / Diplomski rad

2020

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:217:099964

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
BIOLOŠKI ODSJEK

Dorian Skokić

Praćenje širenja amorfe (*Amorpha fruticosa* L.) na području Lonjskog polja korištenjem satelitskih snimaka

Diplomski rad

Zagreb, 2020.

Ovaj rad, izrađen u Botaničkom zavodu Prirodoslovno-matematičkog fakulteta, pod mentorstvom prof. dr. sc. Svena Jelaske, predan je na ocjenu Biološkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu radi stjecanja zvanja mag. oecol. et prot. nat.

Ovim putem zahvaljujem se svom mentoru prof. dr. sc. Svenu Jelaski na pomoći pri odabiru teme, stručnoj pomoći, korekciji i sugestijama pri izradi ovog diplomskog rada.

Hvala svim prijateljima i kolegama koji su mi bili podrška i pomoć tokom studiranja.

I na kraju, posebno zahvaljujem svojoj obitelji na razumijevanju, podršci i pružanju mogućnosti da završim fakultetsko obrazovanje.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Biološki odsjek

Diplomski rad

Praćenje širenja amorfe (*Amorpha fruticosa* L.) na području Lonjskog polja korištenjem satelitskih snimaka

Dorian Skokić

Rooseveltov trg 6, 10000 Zagreb, Hrvatska

Amorfa (čivitnjača, lat. *Amorpha fruticosa* L.) je biljka iz porodice Fabaceae, kod nas znana i kao murvan, bagremac te divlji bagrem. Potječe iz Sjeverne Amerike, a u Europu je unesena u Englesku još 1724. U Hrvatsku se počela širiti iz Mađarske u prvoj polovini prošlog stoljeća i kod nas ima status invazivne vrste. Svrha rada je bila otkriti efikasne metode praćenja amorfe na području Parka prirode Lonjsko Polje. Za testiranje mogućnosti njenog praćenja daljinskim promatranjem, koristio sam Landsat satelitske snimke iz 2000., 2006. i 2017. godine. Kao referentnu kartu koristio sam kartu staništa Parka prirode Lonjsko polje iz 2006. godine. Na referentnoj karti staništa testirao sam točnost kontrolirane klasifikacije (MAXLIKE) satelitske snimke, vegetacijski indeks NDVI (*normalized difference vegetation index*) te spektralni potpis sastojina amorfe kroz sve kanale 30-metarske prostorne razlučivosti. Postupke kontrolirane klasifikacije, NDVI-a i spektralnih potpisa amorfe sam radio korištenjem programa IDRISI, QGis i SAGA. Najtočnijom se pokazala metoda spektralnih potpisa koja, za razliku od indeksa NDVI koji predstavlja omjer dva spektralna kanala, koristi 5 spektralnih kanala u vidljivom i blisko-crvenom dijelu spektra. Površine pod amorfom (uključujući i mješavine s drugim stanišnim tipovima) su se povećavale od predviđenih 12,9 % u 2000. godini, preko 45 % u 2006, i 58 % u 2017. godini. No, navedene površine sadržavale su i značajan udio pod šumama jasena i hrasta lužnjaka. Za dobivanje veće točnosti korištenjem Landsat satelitskih snimaka, bilo bi potrebno koristiti snimke iz više razdoblja tijekom vegetacijske sezone, što bi moglo povećati razlikovanje sastojina amorfe od mlađih sastojina jasenovih i lužnjakovih šuma te povećati njihovu primjenjivost u praćenju širenja amorfe.

(44 stranice, 18 slika, 16 tablica, 23 literaturnih navoda, jezik izvornika: hrvatski)

Rad je pohranjen u Središnjoj biološkoj knjižnici

Ključne riječi: amorfa, NDVI, satelitske snimke

Mentor: Dr. sc. Sven Jelaska, red. prof.

Ocjenjitelji: Dr. sc. Sven Jelaska, red. prof.

Dr. sc. Marko Miliša, izv. prof.

Dr. sc. Duje Lisičić, doc.

Rad prihvaćen: 19.2.2020.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Biology

Graduation thesis

Monitoring the spread of amorpha (*Amorpha fruticosa* L.) in the area of Lonja Field by usage of satellite imagery

Dorian Skokić

Rooseveltov trg 6, 10000 Zagreb, Croatia

Amorpha fruticosa is a species of flowering plant in the legume family (Fabaceae) known by several common names, including desert false indigo, false indigo-bush, and bastard indigobush. It originates from North America, being brought into Europe through England in 1724. In the beginning of the 19th century, it began to spread to Croatia from Hungary, and nowadays has a status of invasive species. The purpose of this work was to find out efficient ways of how to monitor the false indigo-bush in Lonjsko polje Nature park. To test the possibility of monitoring it by remote sensing techniques, I used Landsat satellite images from 2000, 2006 and 2017. As a reference map, I used the 2006 habitat map of the Lonjsko Polje Nature Park. On the habitat reference map, I tested the accuracy of the controlled classification (MAXLIKE) of satellite imagery, the NDVI (Normalized Difference Vegetation Index), and the spectral signature of Amorpha stands through all channels of 30-meter spatial resolution. I did the procedures of controlled classification, NDVI and spectral signatures of Amorpha using IDRISI, QGis and SAGA programs.The most accurate was the spectral signature method which, unlike the NDVI index that represents the ratio of two spectral channels, uses 5 spectral channels in the visible and near-infrared part of the spectrum. Predicted areas covered with indigo bush (including combination with other habitat types) continuously increased from 12.9 % in year 2000, 45 % in 2006 and 58 % in 2017. However, these areas contained significant misclassified areas covered with ash and pedunculate oak stands. To obtain greater accuracy using Landsat satellite imagery, it would be necessary to use images from multiple periods during the growing season, which could increase the distinction of Amorpha stands from younger stands of ash and pedunculate oak forests and increase their applicability in monitoring Amorpha spreading.

(44 pages, 18 figures, 16 tables, 23 references, original in: Croatian)

Thesis deposited in the Central Biological Library

Key words: Amorpha, NDVI, satellite imagery

Supervisor: Dr. Sven Jelaska, Prof.

Reviewers: Dr. Sven Jelaska, Prof.

Dr. Marko Miliša, Assoc. Prof.

Dr. Duje Lisičić, Assist. Prof.

Thesis accepted: 19th of February 2020.

Sadržaj:

1. Uvod 1
1.1. *Amorpha fruticosa* L. 1
1.2 Daljinska istraživanja 3
1.3 Landsat sateliti 5
1.4 Cilj istraživanja 7
2. Materijali i metode 8
2.1. Park prirode Lonjsko polje 8
2.2. Korištene prostorne podloge 8
2.2.1. Satelitske snimke 8
2.2.2. Karta staništa 10
2.3. Analiza referentne snimke iz 2006. godine 11
2.3.1. Kontrolirana klasifikacija (MAXLIKE) 11
2.3.2. Vegetacijski indeks (NDVI) 14
2.3.3. Spektralni potpis amorfe 17
3. Rezultati 23
3.1. Kontrolirana klasifikacija (MAXLIKE) 23
3.2. NDVI indeks iz 2006. godine 24
3.3. Spektralni potpisi iz 2006. godine 27
4. Rasprava 31
5. Zaključak 34
6. Literatura 35
7. Životopis 38

1. Uvod

1.1. *Amorpha fruticosa* L.

Amorfa ili čivitnjača (*Amorpha fruticosa* L.) je listopadni grm iz porodice mahunarki (Fabaceae). Prosječno raste do visine od 2 metra, a nekad može narasti i do 6 metara (Slika 1). Kora je glatka i siva dok su listovi neparno perasti. Dugi su do 30 cm i sastavljeni od 11-25 jajolikih lisaka. Liske su duge 15-40 mm, široke 8-20 mm sa malim šiljkom na vrhu. Grane su šibolike, a mlađi izboji su dlakavi. Cvjetovi su na jednogodišnjim izbojcima u obliku uspravnih metličastih cvatova i dugi su 10-15 cm. Može se naći i do 300 cvjetova u jednom cvatu. Čaška se sastoji do 5 zubića te je zvonastog oblika. Vjenčić je građen od jednog tamnoljubičastog listića dužine 4-6 mm, a prašnika ima 10 te su uspravni i narančaste boje. Amorfa cvate u razdoblju od svibnja do srpnja i tada privlači brojne kukce. Plod je žljezdasta mahunica veličine 7-8 mm koja sadrži jednu ili dvije smeđe, izdužene i zakrivljene sjemenke (http://www.plantea.com.hr/amorfa).



Slika 1. *Amorpha fruticosa* L. (https://www.pijanitvor.com/threads/civitnjaca-amorfa-amorpha-fruticosa.27020/)

Krpan i sur. (2015) u istom su radu opisali višegodišnji rast i razvitak amorfe. Za prvu godinu karakteristično je da nakon sječe amorfa potjera iz panja šibolike izdanke te time usmjerava svu energiju na visinski rast. Upravo zbog toga se prvoj vegetaciji ne zbiva ni granjanje, ni cvatnja ni pridonošenje plodova. Tada se pojavljuje krošnjica i

šiboliki izdanci dosežu prosječnu visinu od dva metra. Zbog svoje sposobnosti pozicioniranja prema svjetlu, amorfa ima puno veću prednost od najkvalitetnijih konkurentskih vrsta u poplavnim nizinskim šumama. Cvatnja i plodonošenje se odvijaju u drugoj i daljnim godinama vegetacije dok se istovremeno visinski prirast značajno smanjuje. Amorfa osvaja nova područja na način da se zreli plodovi truse i raznose vodom, naročito tijekom poplava.

Invazivne vrste su vrste koje nisu autohtone određenom području te se imaju namjeru proširiti do razine koja je štetna za okoliš, ljudsku ekonomiju ili ljudsko zdravlje (Ehrenfeld 2010). Amorfa je porijeklom iz Sjeverne Amerike, a u Europu je unešena u 18. stoljeću kao ukrasna biljka. Razmnožava se sjemenom i vegetativnim putem tjeranjem podzemnih podanaka. Značajna svojstva amorfe su laka klijavost sjemenki, njihovo lako širenje i brzi rast, čineći je opasnom invazivnom vrstom. Osim toga stvara guste skupine, ometajući razvoj lokalnih biljaka i smanjujući biološku raznolikost. Raste na tlima s umjereno bogatim dušikom i srednjom količinom humusa, uz rijeke ili na povremeno poplavljenim područjima. Mehaničko uklanjanje neželjene amorfe nije jednostavan posao jer u tlu i manji komadići podzemnih dijelova mogu ponovno niknuti (http://www.plantea.com.hr/amorfa).

Naspram svojih nepoželjnih invazivnih sposobnosti, amorfa je cijenjena kao medonosna biljka. Doprinos meda može biti i do 300 kg na površini od 1 ha. Svojstva amorfinog meda su ugodan okus, prozirnost, tamnocrvena boja, spora kristalizacija i sadrži otprilike 53 % šećera. Pčele sakupljaju i velike količine peluda koji je vrlo cijenjen i tražen za ljudsku upotrebu (http://www.plantea.com.hr/amorfa).

U projektu „Biopotencijal i energetske značajke amorfe“, Krpan i sur. (2015) su došli do rezultata kako amorfa ima potencijal za iskorištavanje biomase zbog njene bioproizvodnosti, normi za čvrsta goriva, uvjeta pridobivanja i tržišnih prilika.

Poplavna područja poput Lonjskog polja su optimalna staništa za invazivne vrste, naročito amorfu, jer u pravilu mogu izdržati učestale i jake poplave, suhe uvjete tijekom niske razine vode te ljudsko ometanje (neredovito čišćenje šuma, napuštanje nakon poljoprivrednog zemljišta). Invazivne vrste uzrokuju učestale probleme na poplavnim područjima, budući da ugrožavaju reprodukciju i regeneraciju autohtonih vrsta, te uzrokuju probleme u okolišu, ekonomiji i zdravstvenom stanju autohtonih vrsta (Tamas 2001). Na rijeci Tisi, u Mađarskoj, je zamijećen ubrzani rast amorfe jer šume nisu pravilno održavane. Pojavljuje se brzo rastuće, visoko (3-4 m), neprobojno grmlje na poplavnom području, sa 5-10 izbojaka iz svakog panja (Mihaly i Botta-dukat 2004). Zbog gustih, drvenastih stabljika tla prenapučena s amorfom mogu smanjiti brzinu protoka vode s 0,5 m/s na 0 m/s (Sandor i Kiss 2007).

Čišćenje zemljišta i ljudska staništa stavljaju značajan pritisak na lokalne vrste. Poremećena staništa su podložna invazijama, koje mogu imati negativne posljedice na lokalne ekosustave, mijenjajući funkcije ekosustava. Invazivne vrste biljaka je teško

iskorijeniti pošto imaju visoku moć reprodukcije. U područjima gdje se invazivna vrsta biljke naselila, autohtone vrste gube u borbi za resurse, dovodeći do njihove propasti. Reintegracija područja, putem pokušaja ponovnog naseljena autohtonih vrsta, je vrlo često neuspješna zbog dominantnih sposobnosti invazivne vrste nad drugim vrstama. S jedne strane to dovodi do propasti ekosustava, a s ekonomske strane dovodi do neiskoristivosti područja u ljudske svrhe, osim ako korisnost invazivne vrste nije jednaka, ili korisnija od, korisnosti druge vrste koja bi hipotetski i ekološki trebala naseljavati to područje i održavati u njemu ravnotežu.

1.2 Daljinska istraživanja

„Daljinska istraživanja su metode o istraživanju Zemljine površine, objekata i fenomena bez izravnog doticaja s njima. Senzori su glavni uređaji u daljinskim istraživanjima za otkrivanje, registraciju i mjerenje elektromagnetskog zračenja što ga emitira ili reflektira objekt promatranja. Senzori konvertiraju zabilježenu elektromagnetsku energiju u električne impulse, a izgrađeni su tako da mogu snimati uže ili šire spektralno područje.“ (Oluić 2001; prema Vela i sur. 2017).

Senzore možemo podijeliti prema načinu snimanja elektromagnetske energije te broju i širini spektralnog kanala. Prema načinu snimanja elektromagnetske energije razlikujemo aktivne senzore i pasivne senzore. Aktivni senzori šalju energiju prema objektu i registriraju dio koji se odbio, dok pasivni senzori samo primaju energiju koja dolazi od objekta.

Prema broju i širini spektralnoga kanala senzori mogu biti:

a) Pankromatski (mjere refleksije u jednom širokom dijelu elektromagnetskog spektra unutar širokog raspona valnih duljina)

b) Multispektralni (mjere energiju u višekanalnom detektoru i uskom rasponu valnih duljina)

c) Hiperspektralni (sadrže više od sto spektralnih kanala)

d) Ultra spektralni (još su u razvoju)

Dijelovi elektromagnetskog spektra koji se koriste u daljinskim istraživanjima su vidljivi, infracrveni i mikrovalni dijelovi. Ljudsko oko detektira vidljivi dio spektra od 0,4 do 0,7 μm, koji zauzima mali dio cjelokupnog spektra:

- ljubičasta: 0,4 – 0,446 μm
- plava: 0,446 – 0,500 μm
- zelena: 0,500 – 0,578 μm

- žuta: 0,578 – 0,592 μm
- narančasta: 0,592 – 0,620 μm
- crvena: 0,620 – 0,7 μm.

Svi satelitski podaci nastaju kao zapis elektromagnetskog zračenja koji se detektira na senzoru satelita. Produkt prikupljanja informacija u digitalnim istraživanjima je digitalna satelitska snimka koja je sastavljena od mreže piksela. Položaj svakog piksela određen je u Kartezijevu koordinatnom sustavu. Ishodište koordinatnog sustava se nalazi u gornjem lijevom kutu Landsat snimke. Svaki piksel ima tzv. digitalni broj (engl. *Digital Number* – DN), tj. vrijednost koja pokazuje razinu sivila (Vela i sur. 2017).

Daljinska istraživanja služe kao promatrač promjene šumskog pokrova u određenom vremenu, kako bi se mogle što bolje donositi smjernice očuvanja, gospodarenja i sličnih funkcija. Najčešće korištene tehnike praćenja promjena su diferenciranje snimki, analiza komponenata i klasifikacija snimki (Singh 1989). Za detekciju točnijih promjena u pokrovu se koristi analiza spektralnih kombinacija, integracija geografskih informacija s podacima daljinskih istraživanja te umjetne neuronske mreže koje su razvijene posljednjih godina. Vegetacijski indeksi pružaju detaljnije prostorno-vremenske informacije i mogu se izračunati iz multispektralnih satelitskih snimki. (Vela i sur. 2017).

Vegetacijski indeksi su podaci koji se računaju iz različitih kanala multispektralnih snimki na temelju apsorpcije, transmisije i refleksije energije vegetacije u različitim spektralnim kanalima (She i sur. 2015). Vegetacijski indeks normalizirane razlike (*Normalized Difference Vegetation Indeks* – NDVI) je jedan od načina detekcije invazije stranih vrsta i promjena u biljnom pokrovu (Slika 2). NDVI predstavlja omjer između razlike i zbroja bliskoinfracrvenog dijela spektra i crvenog dijela spektra (Deering 1978; prema Vela i sur. 2017). Pomoću njega se mogu pratiti sezonske i višegodišnje vegetacijske promjene (Jensen i Lulla 1987; prema Vela i sur. 2017).

Formula za izračun NDVI-a:

$$NDVI = (NIR - RED) / (NIR + RED)$$

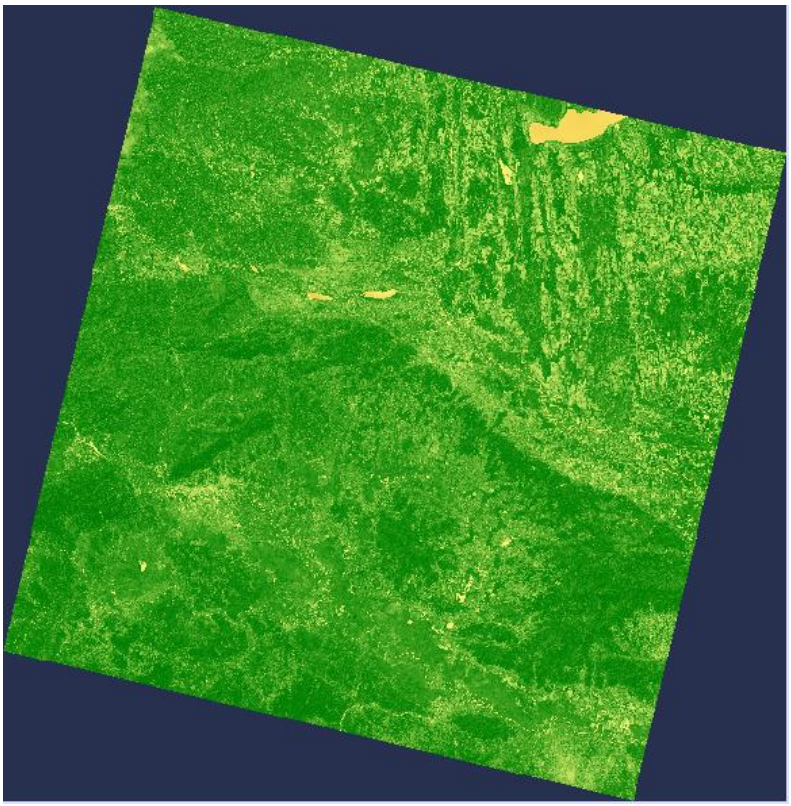
Gdje su:

NIR – dio spektra $\lambda \approx 0,8$ μm

RED – dio spektra $\lambda \approx 0,6$ μm

Vrijednosti NDVI-a su između minus jedan (-1) i plus jedan (+1). Vrijednosti blizu 1, predstavljaju područja sa velikom gustoćom vegetacije, dok vrijednosti blizu -1 predstavljaju vodu, snijeg i oblake. Vrijednosti blizu nule predstavljaju područja gologa tla ili kamena.

Podaci dobiveni daljinskim mjerenjima su korisni, u slučaju kada su biljne invazivne vrste već naseljene i dalje se šire, za ranu detekciju mogućih utjecaja te procjenu opsega invazivnosti. Time nadalje olakšavaju upravljanje s ciljem smanjenja utjecaja tih vrsta na funkcioniranje ekosustava (Bradley 2014).



Slika 2. Prikaz vegetacijskog indeksa normalizirane razlike, NDVI (preuzeto iz programa IDRISI Selva)

1.3 Landsat sateliti

Landsat misija, utemeljena davne 1972. godine, je najduža serija lansiranih satelita koji snimaju Zemljinu površinu. Od trenutka lansiranja do danas se pruža uvid u vizualne i znanstvene značajke našeg planeta putem prikupljanja i pohranjivanja podataka srednje rezolucije, stvarajući jedinstvenu povijesnu arhivu za procjenu i praćenje trendova i analiza promjena na Zemlji. Arhiva snimki Landsat često se

spominje kao jedna od najvećih dragocjenosti čovječanstva, postignuće koje donosi veliku korist u svim segmentima društva (Roy i sur. 2014; prema Vela i sur. 2017).

Parametri	Landsat 1-3 MSS	Landsat 4,5 TM	Landsat 7 ETM+	Landsat 8 OIL/TIRS
Trajanje misije	1972. – 1978. 1975. – 1983. 1978. – 1983.	1982. – 1993. 1984. – 2013.	1999. – …	2013. –…
Visina orbite (km)	915	705	705	705
Spektralni kanali	R, G, 2 NIR	R, G, B, 2 NIR, MIR, TIR	R, G, B, 2 NIR, TIR, MID, PAN	Obalni, R, G, B, NIR, SWIR-1, SWIR-2, TIR-1, TIR-2, PAN, cirus oblaci
Prostorna razlučivost (m)	80 MS	30 MS 120 TIR	15 PAN 30 MS 60 TIR	15 PAN 30 MS 100 TIR
Vremenska razlučivost (dana)	18	16	16	16
Površina snimke	185 km x 185 km			

Slika 3. Obilježja Landsat misija (preuzeto iz Vela i sur. 2017)

Landsat sateliti imaju ugrađene različite tipove senzora:

- Vidicon sustav s povratnim zrakama (engl. Return Beam Vidicon – RBV),
- multispektralni skener (engl. Multispectral Scanner System – MSS),
- tematski kartograf (engl. Thematic Mapper – TM),
- napredni tematski kartograf (engl. Enhanced Thematic Mapper Plus – ETM+).

ETM+ senzor satelita Landsat 7 je bolja verzija senzora TM Landsata 4,5, dok MSS senzor Landsata 1-3 je najstarija i najlošija verzija senzora od svih. Najnoviji senzori ugrađeni su na satelit Landsat 8. Riječ je o dva senzora nove generacije: operativni uređaj za snimanje Zemljine površine (engl. Operational Land Imager – OLI) i infracrveni termalni senzor (engl. Thermal Infrared Sensor – TIRS) s kojima se svaki dan dobije preko 500 snimki (Roy i sur. 2014; prema Vela i sur. 2017).

Područja elektromagnetskog zračenja će se detektirati različito, ovisno o različitosti senzora. Senzori Landsat satelita se ubrajaju pod pasivne senzore jer bilježe Sunčevo

zračenje koje se reflektira od oblaka, oceana i Zemljine površine, te infracrveno zračenje koje emitira Zemlja i njena atmosfera (Vela i sur. 2017).

1.4 Cilj istraživanja

Cilj ovog rada je:

- identificirati sastojine amorfe na području Lonjskog polja
- rekonstruirati rasprostranjenost amorfe iz različitih razdoblja putem prostornog preklapanja te odrediti njeno širenje
- provjeriti mogućnost i pouzdanost korištenja satelitskih snimaka za praćenje širenja invazivne vrste *Amorpha fruticosa* L.

2. Materijali i metode

2.1. Park prirode Lonjsko polje

Park prirode Lonjsko polje je najveće zaštićeno močvarno područje u Hrvatskoj i dunavskom porječju. Pokriva površinu od 505 kilometara kvadratnih, protežući se uz rijeku Savu od područja istočno od Siska, donjim tokom rijeke Lonje, sve do područja zapadno od Nove Gradiške. Lonjsko polje je proglašeno parkom prirode 1998. godine te spada u IBA – Important Birds Area (važna područja za ptice) zbog svoje raznolikosti ptičje populacije. U Lonjskom polju su sačuvane nizinske poplavne šume hrasta lužnjaka i poljskog jasena koje predstavljaju najreprezentativnije komplekse šuma listača u Europi. Park prirode Lonjsko polje je upisan na listu vlažnih staništa od međunarodnog značaja u skladu s Ramsarskom konvencijom. Potpisom konvencije Republika Hrvatska obvezala se na kontinuirano osiguranje zaštite močvarnih područja i ptica močvarica. Ovo područje je značajno kao zimovalište i odmorište za ptice selice te mjesto gniježđenja za gotovo 140 vrsta (https://www.pp-lonjsko-polje.hr/).

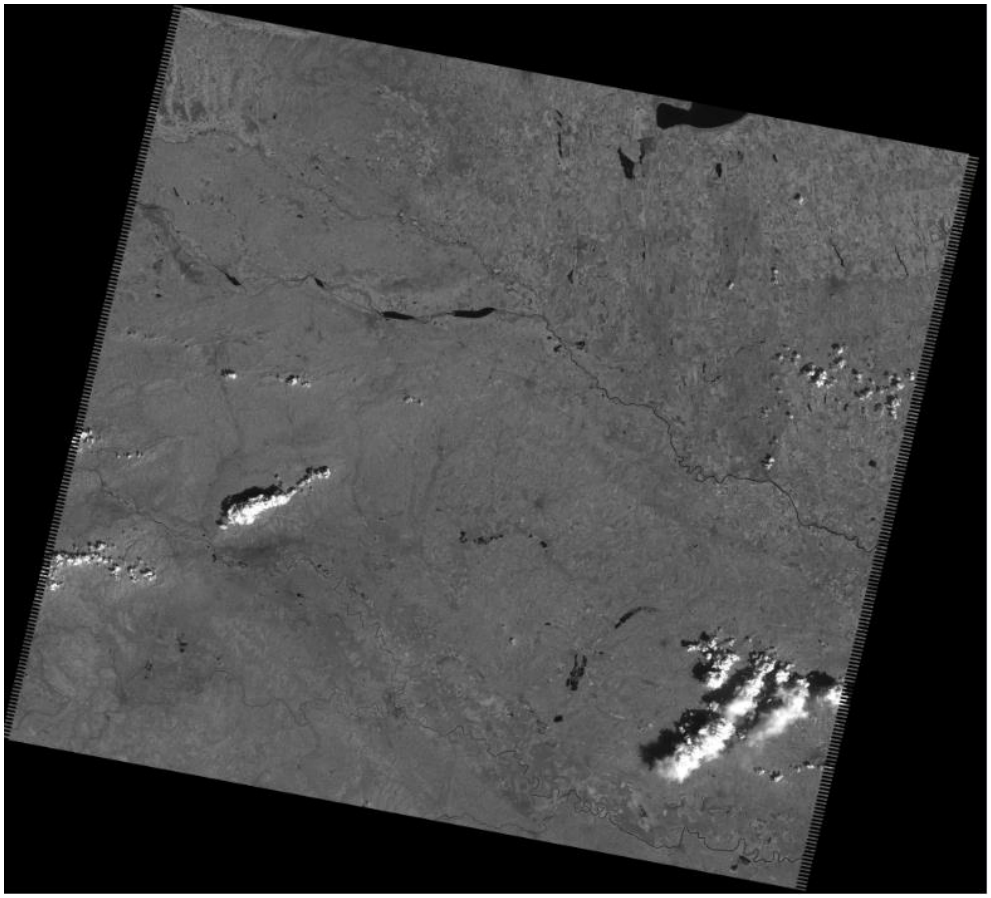
2.2. Korištene prostorne podloge

2.2.1. Satelitske snimke

Satelitske snimke Lonjskog polja su prikupljane sa stranice United States Geological Survey-a (USGS), putem programa Global Visualization Viewer (GloVis). Snimke su preuzete u GeoTIFF formatu, kako bi se pridobila snimka za svaki spektralni kanal (Slika 4). Referentne slike su uzete iz 2006. godine. Pošto su tražene snimke sa najmanje smetnji (npr. oblaka), naposljetku su obrađivane najpovoljnije snimke sljedeće navedenih datuma:

- 23.06.2000.
- 26.07.2006
- 25.08.2017.

Pošto su snimke snimljene sa različitim Landsat satelitima, slijedila je identifikacija svakog satelitskog kanala u snimci sa svojim spektralnim kanalom (Slika 5).



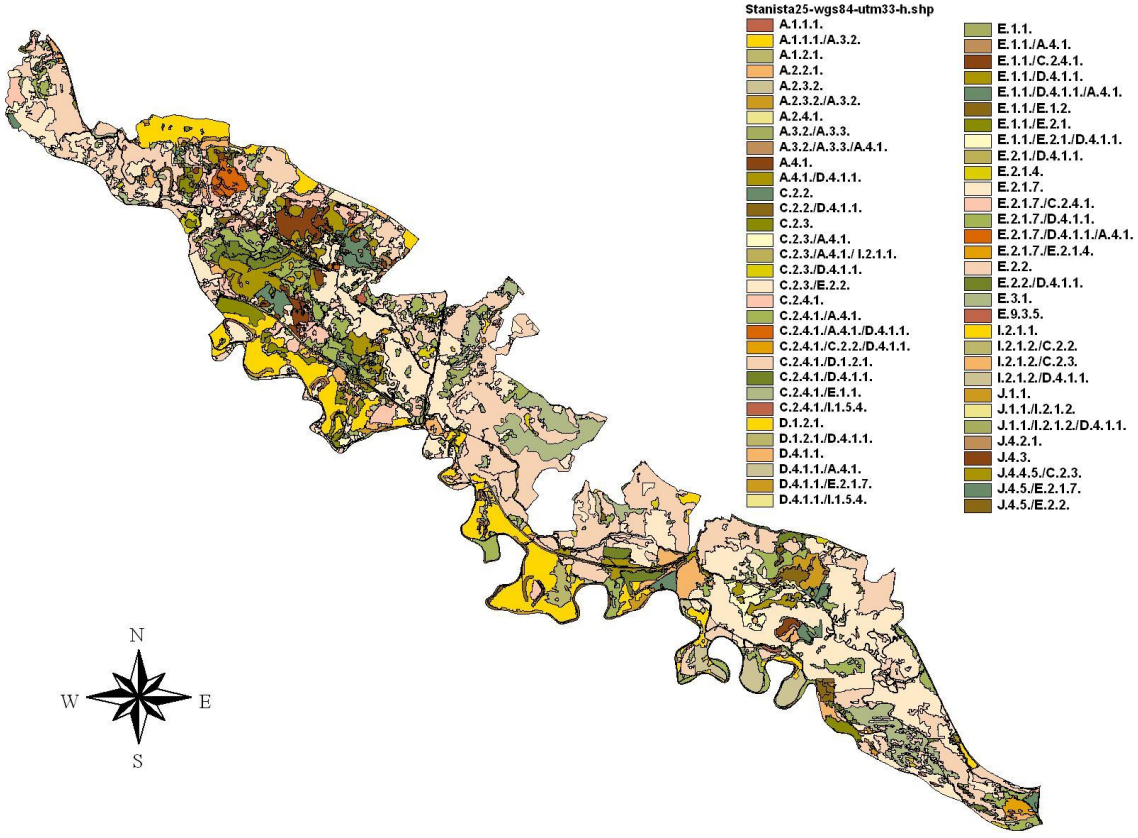
Slika 4. Snimka Lonjskog polja u blisko-infracrvenom spektru (preuzeto iz programa IDRISI Selva)

Landsat 4	Landsat 5	Landsat 7	Landsat 8
kanal 1 (plavi)	kanal 1 (plavi)	kanal 1 (plavi)	kanal 2 (plavi)
kanal 2 (zeleni)	kanal 2 (zeleni)	kanal 2 (zeleni)	kanal 3 (zeleni)
kanal 3 (crveni)	kanal 3 (crveni)	kanal 3 (crveni)	kanal 4 (crveni)
kanal 4 (NIR)	kanal 4 (NIR)	kanal 4 (NIR)	kanal 5 (NIR)
kanal 5 (SWIR)	kanal 5 (SWIR)	kanal 5 (SWIR)	kanal 6 (SWIR)
kanal 7 (SWIR)	kanal 7 (SWIR)	kanal 7 (SWIR)	kanal 7 (SWIR)

Slika 5. Spektralni kanali prostorne rezolucije 30 m Landsat satelita 4,5 7 i 8 (preuzeto iz Gašparević i sur. 2017)

2.2.2. Karta staništa

Kartiranje staništa u Parku prirode Lonjsko polje izvršeno je na kartama u mjerilu 1:25 000. Minimalna površina kartiranja (MPK) iznosila je 2,25 ha. Kartiranje staništa u Parku prirode Lonjsko polje izvršeno je kombiniranom metodom satelitskih snimaka spojenih s terenskim uzorkovanjem (Gugić i sur. 2006). U ovom radu sam koristio kartu staništa Lonjskog polja iz 2006. (Slika 6) i 2016. godine. Prema Nacionalnoj klasifikaciji staništa, u Lonjskom polju postoje površine sa čistim sastojinama amorfe (amorfa sensu stricto), čiji je kod D.4.1.1 (sastojine čivitnjače). Osim površina sa čistom čivitnjačom postoje i područja gdje se čivitnjača miješa sa drugim vrstama (amorfa sensu lato); to su područja tršćaca, rogozica, visokih šiljeva i visoki šaševa (A.4.1./D.4.1.1.), vlažnih livada Srednje Europe (C.2.2./D.4.1.1.), mezofilnih livada srednje Europe (C.2.3./D.4.1.1.), priobalnih poplavnih šuma vrbe i topole (E.1.1./D.4.1.1.), šuma poljskoga jasena s kasnim drijemovcem (E.2.1.7./D.4.1.1.), poplavnih šuma hrasta lužnjaka (E.2.2./D.4.1.1.), mozaika poljoprivrednih površina i prirodne vegetacije (I.2.1.2./D.4.1.1.) i drugih.



Slika 6. Poligonska karta staništa Lonjskog polja iz 2006. godine (preuzeto iz programa IDRISI Selva)

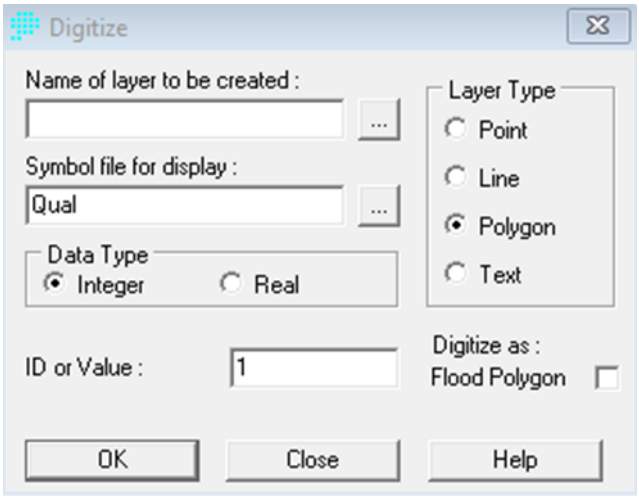
2.3. Analiza referentne snimke iz 2006. godine

2.3.1. Kontrolirana klasifikacija (MAXLIKE)

Spektralni kanali satelitskih snimki koje sam preuzeo sa GloVis-a su u GeoTIFF obliku, koji nije kompatibilan sa IDRISI i Saga programima. GeoTIFF podatke je bilo potrebno pretvoriti u raster (.rst) oblik putem funkcije pretvorbe u programu IDRISI. Time se omogućilo korištenje tih kanala u daljnje svrhe.

U programu IDRISI sam pomoću modula „Digitize“ napravio trening područja za 10 stanišnih tipova iz karte staništa kako bih mogao u daljnjim koracima napraviti klasifikaciju maksimalne vjerojatnosti. Funkcija „digitize“ služi za manualno stvaranje točaka, linija, poligona i vektorskih slojeva (Slika 7).

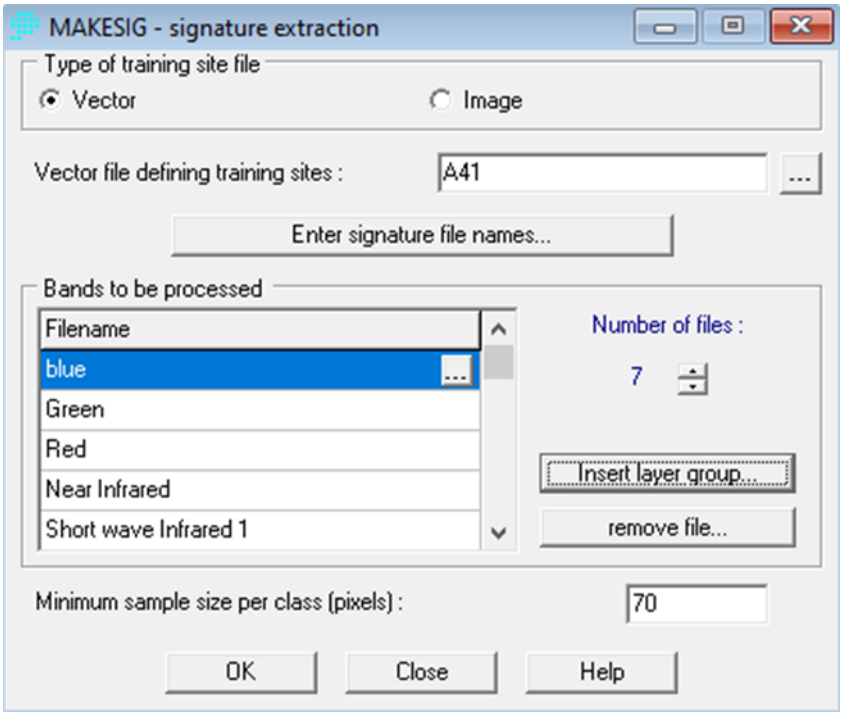
Stanišni tipovi za koja sam napravio trening područja su: A.4.1. (Tršćaci, rogoznici, visoki šiljevi i visoki šaševi), C.2.3. (Mezofilne livade Srednje Europe), C.2.4.1. (Nitrofilni pašnjaci i livade košanice nizinskog vegetacijskog pojasa), E.2.2. (Poplavne šume hrasta lužnjaka), E.2.1.7. (Šume poljskog jasena s kasnim drijemovcem E.3.1. (Mješovite hrastovo-grabove i čiste grabove šume), I.2.1.1. (Mozaične poljoprivredne površine), J.1.1. (Aktivna seoska područja) te spojena trening područja od čistih sastojina čivitnjača (D.4.1.1.), voda-tekućica (A.2.) i miješanih sastojina čivitnjača.



Slika 7. Modul „Digitize“ (preuzeto iz programa IDRISI Selva)

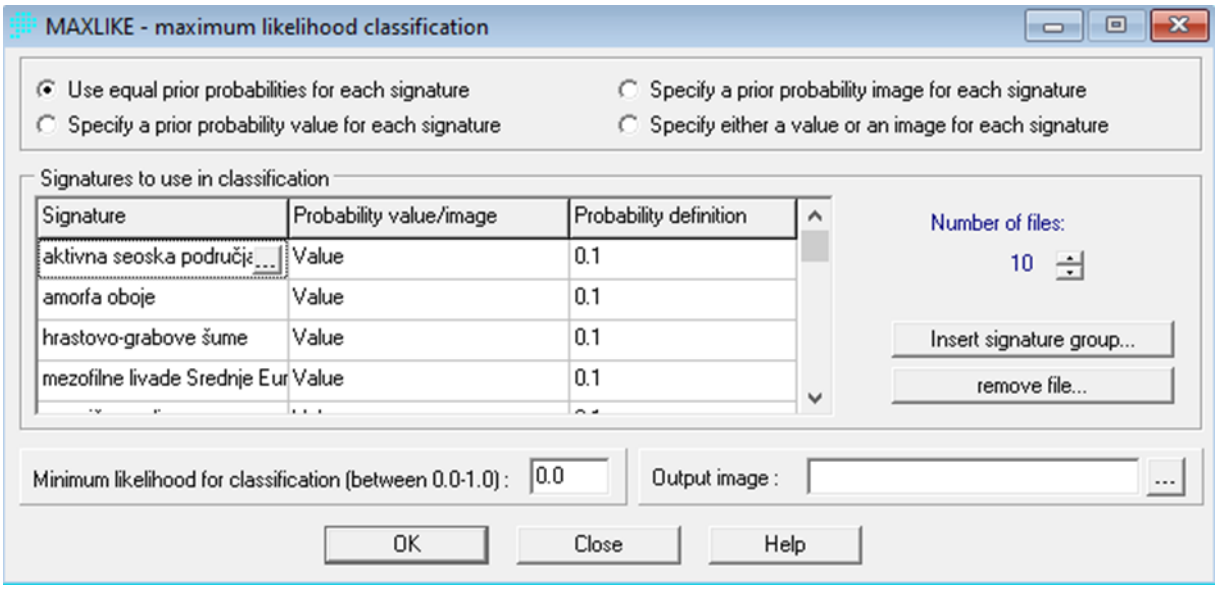
Sljedeći korak je bio stvaranje potpisa tih 10 poligonskih slojeva putem modula MAKESIG. Modul MAKESIG (Slika 8) stvara potpise iz informacija sadržanim u podacima trening područja i izvlači piksele iz svih odabranih kanala za svaku informacijsku klasu kako bih mogao izračunati statistiku potpisa. Ti potpisi kasnije služe kako bi se mogla napraviti neka kontrolirana klasifikacija.

Kako bi se dobili spektralni kanali koji će biti procesuirani u MAKESIG modulu, prvo je bilo potrebno pretvoriti kanale spektralnih snimki iz GeoTIFF oblika, u raster oblik pogodan IDRISI i SAGA programima.



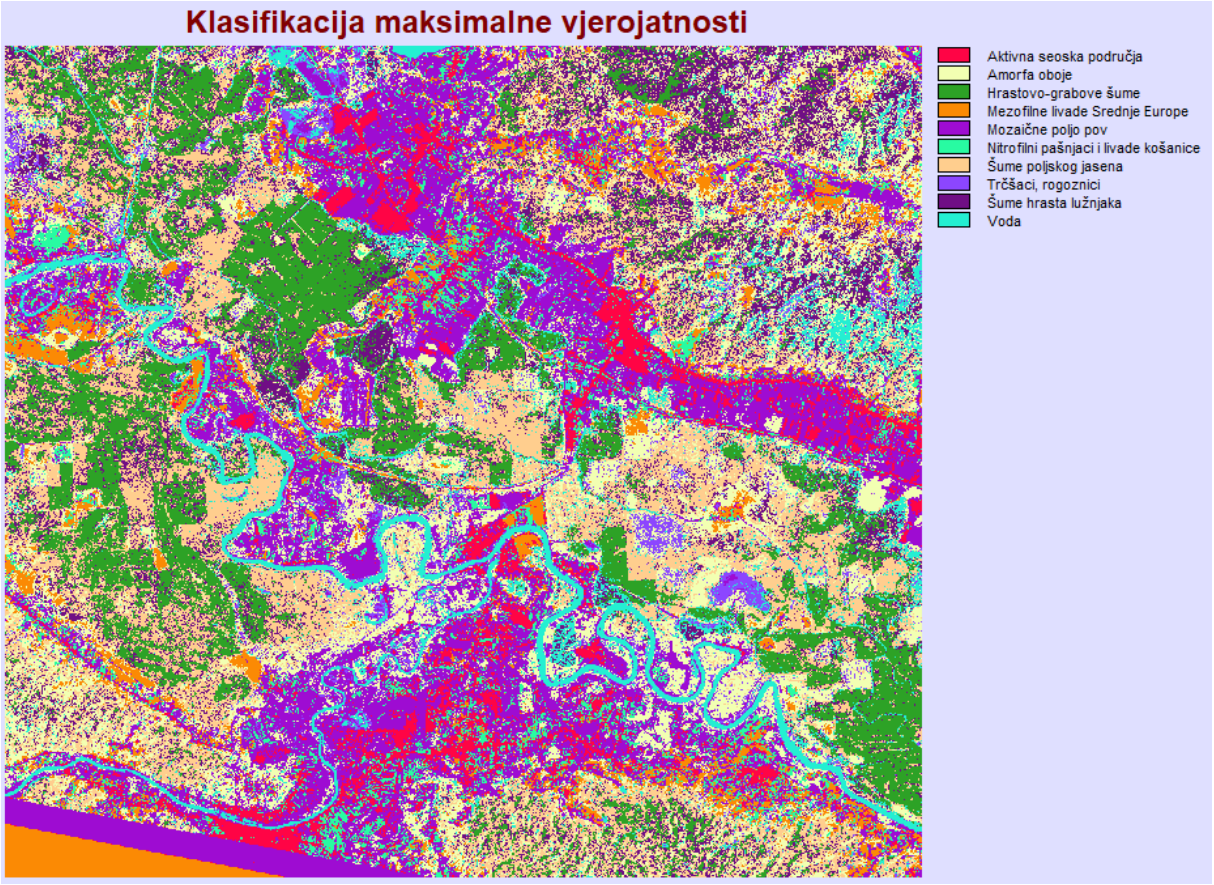
Slika 8. Modul „MAKESIG“ (preuzeto iz programa IDRISI Selva)

Naposljetku slijedi modul MAXLIKE koja radi klasifikaciju maksimalne vjerojatnosti, temeljenu na informacijama sadržanim u sklopu podataka potpisa (Slika 9). U klasifikaciji maksimalne vjerojatnosti su pikseli dodani najvjerojatnijoj klasi, temeljeno na usporedbi prijašnje vjerojatnosti da pikseli pripadaju svakom od razmatranih potpisa.



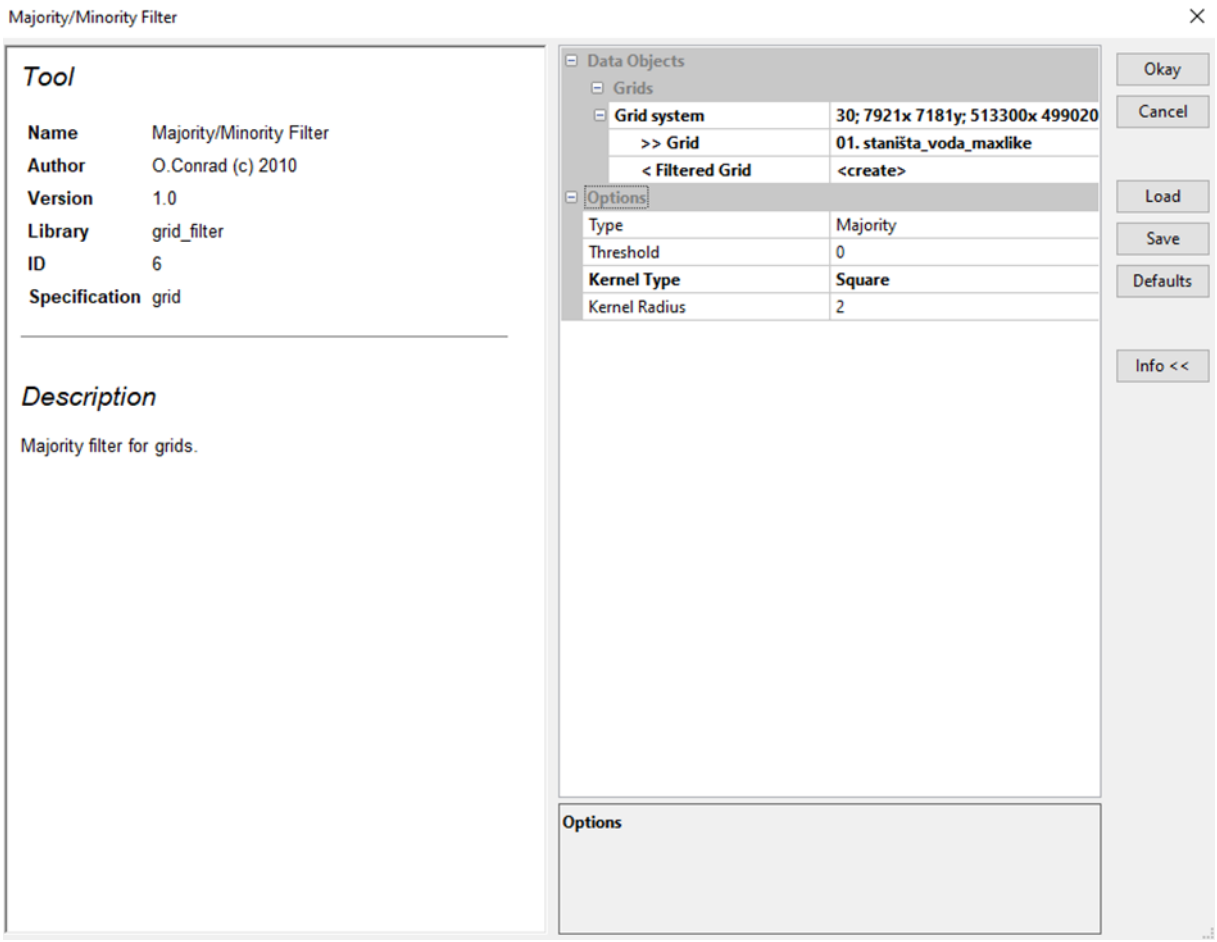
Slika 9. Modul „MAXLIKE“ (preuzeto iz programa IDRISI Selva)

Modul proizvede sliku u kojoj su ćelije dodane kodu klase koji je jednak položaju potpisa u listi potpisa te sa legendom koja prikazuje potpise po imenu (Slika 10).

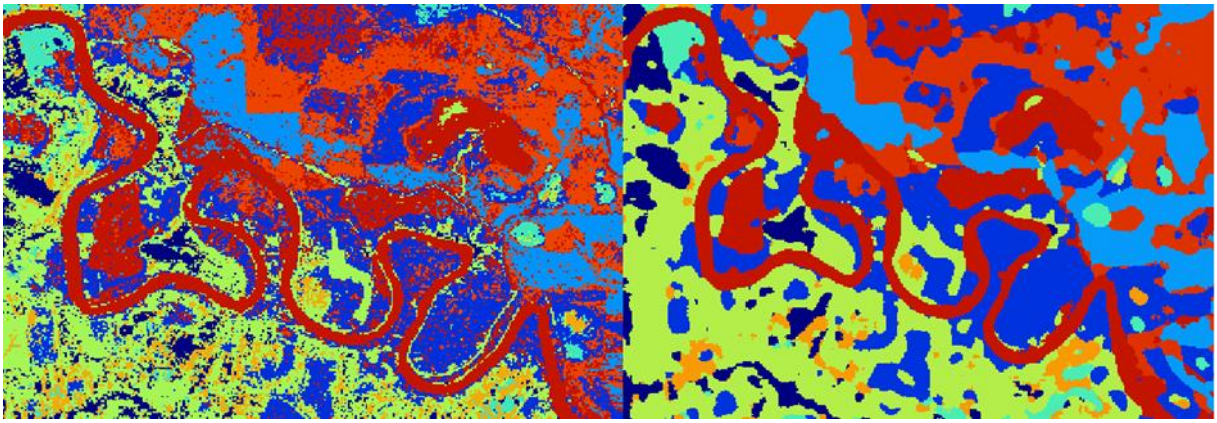


Slika 10. Rasterski sloj dijela Lonjskog Polja nakon klasifikacije maksimalne vjerojatnosti (preuzeto iz programa IDRISI Selva)

Kako bi dobili jasniju i bolju raspoređenost piksela u slici klasifikacije, koristili smo modul „Majority/Minority Filter“ (Slika 11) u sustavu SAGA (Sustav za automatizirane geoznanstvene analize). „Majority/Minority Filter“ služi za generalizaciju piksela i za smanjenje krivo klasificiranih pojedinačnih piksela na način da nerazvrstane piksele pridodjeljuje određenim klasama (Slika 12).



Slika 11. Modul „Majority/Minority Filter (preuzeto iz programa SAGA)



Slika 12. Usporedba normalnog rasterskog sloja i rasterskog sloja sa kockastim radijusom zrna od 3x3 (preuzeto iz programa SAGA)

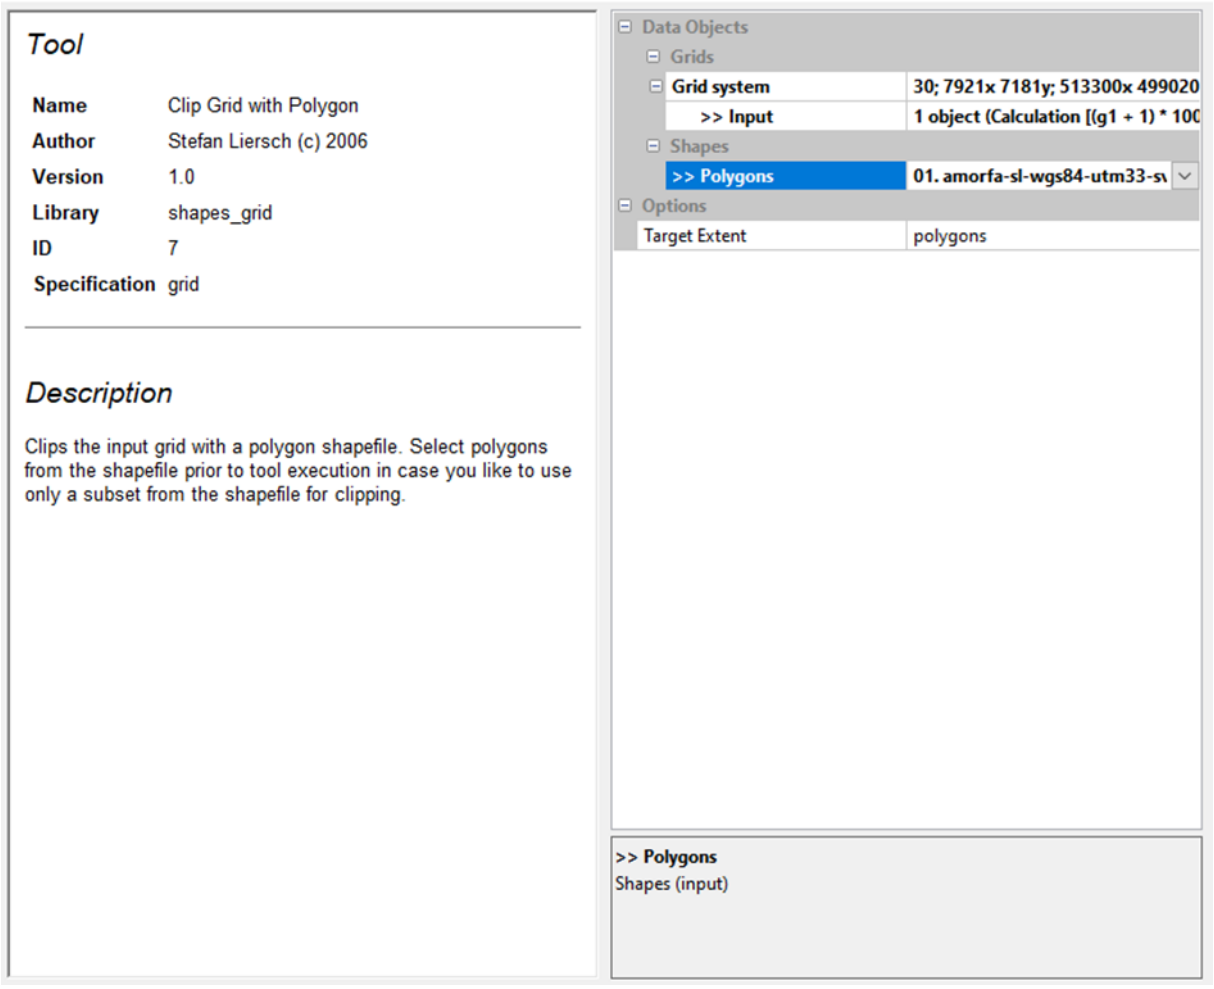
2.3.2. Vegetacijski indeks (NDVI)

Prethodnom pretvorbom GeoTIFF podataka u raster oblik se omogućilo korištenje spektralnih kanala i stvaranje rastera NDVI kanala.

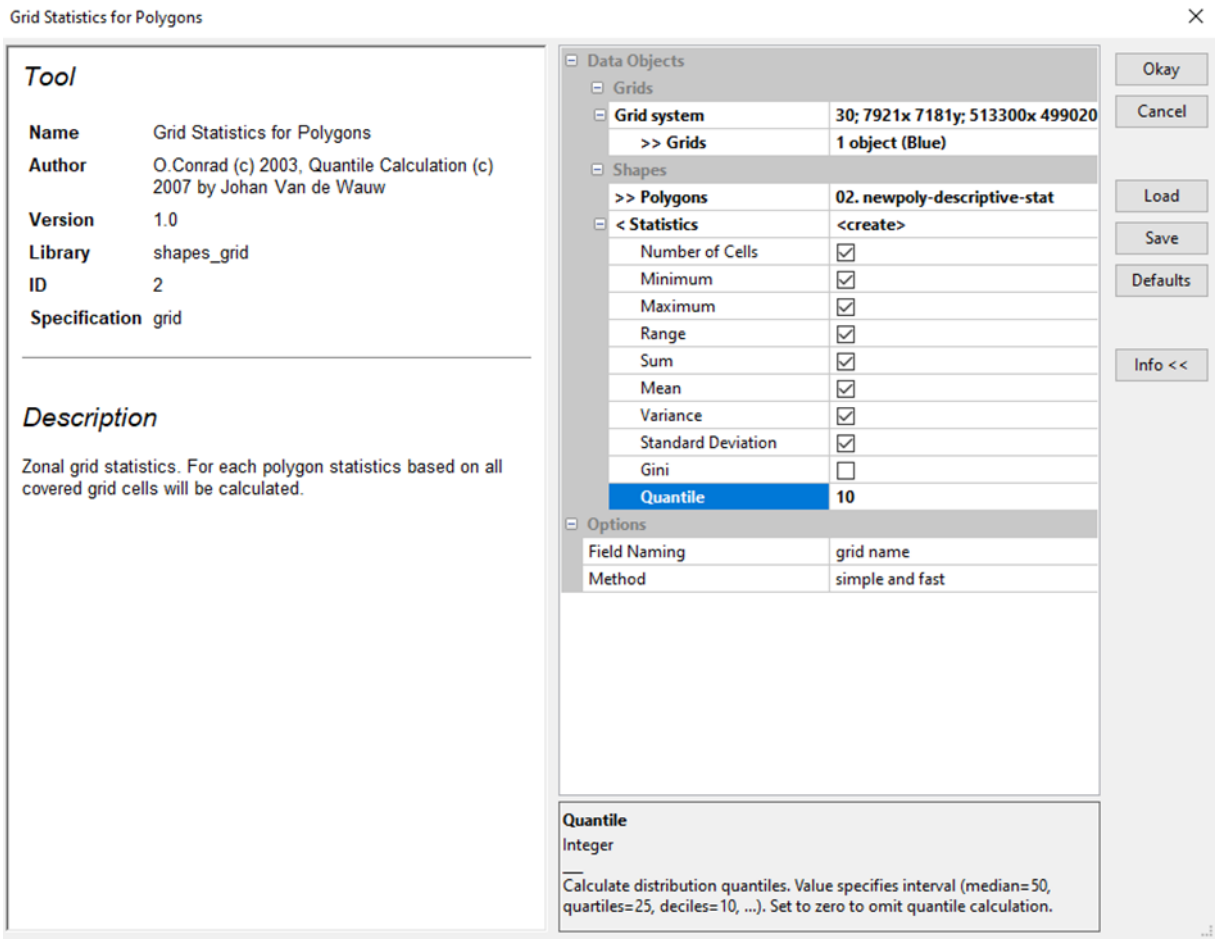
Raster NDVI kanala sam izračunao putem modula VEGINDEX , tj. formule navedene za izračun NDVI indeksa u uvodnom dijelu ovog rada.

Vrijednosti rastera NDVI kanala sežu od -1 do 1, tako da sam odlučio standardizirati raster NDVI kanala (sNDVI) da vrijednosti budu u rasponu od 0 do 200. To sam napravio u programu SAGA sa modulom „Grid Calculus“, sa formulom sNDVI=(NDVI + 1)* 100.

Sljedeći korak u SAGA-i je bio „rezanje“ rastera sNDVI kanala s poligonima čiste amorfe (amorpha sensu stricto) i poligonima miješane amorfe (amorpha sensu lato) pomoću modula „Clip Grid with Polygon“ (Slika 13). Navedeni modul „izreže“ uneseni rasterski sloj sa poligonskim slojem, dobivajući novi rasterski sloj samo za područja koja poligonski sloj obuhvaća u „rezanom“ rasterskom području (Slika 15). Tim putem smo „rezali“ sNDVI raster dva puta, pošto su dvije vrste poligona amorfe, te smo dobili po dva nova rasterska sloja. Cilj svega je bio dobiti deskriptivnu statistiku rasterskog sloja za poligone, a to smo dobili putem modula „Grid statistics for polygons“ (Slika 14), tako da smo računali deskriptivne statistike rasterskih slojeva za poligon koji u kvadratnom obliku prekriva staništa Lonjskog polja.



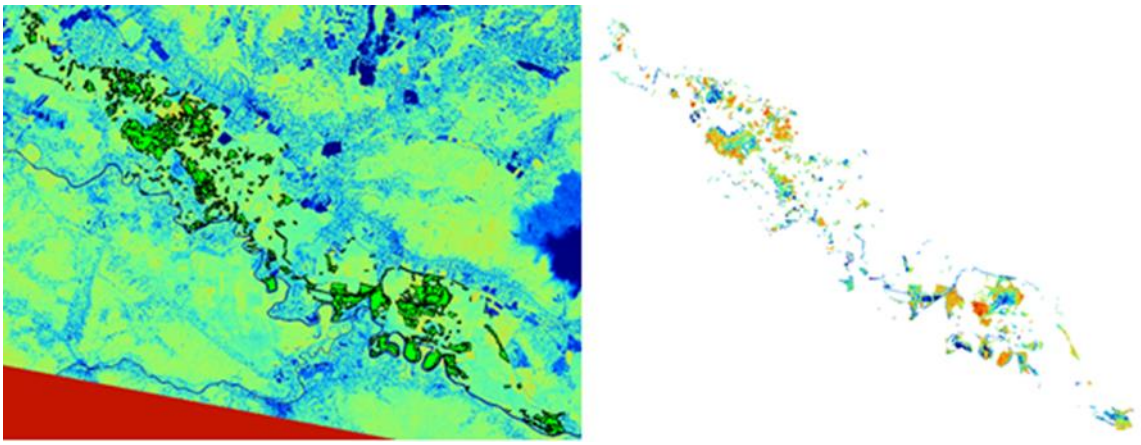
Slika 13. Modul „Clip Grid with Polygon“ (preuzeto iz programa SAGA)



Slika 14. Modul „Grid Statistics for Polygons“ (preuzeto iz programa SAGA)

Deskriptivna statistika sadrži informacije o poligonskom sloju u smislu broja ćelija, minimalnoj i maksimalnoj vrijednosti piksela, ukupnom broju, prosjeku, varijanci, standardnoj devijaciji i podjeli vrijednosti po kvantilima.

Klasifikacija pomoću kvantila je vrsta klasifikacije podataka gdje se skupina podataka distribuira u grupe koje sadrže jednak broj vrijednosti. Atributne vrijednosti se onda pridodaju pa podijele u predodređeni broj klasa.



Slika 15. Lijevo: rasterski sloj sNDVI-a s označenim poligonima miješane amorfe (sensu lato), Desno: rasterski sloj dobiven „rezanjem“ sNDVI rasterskog sloja i poligona miješane amorfe (sensu lato) (preuzeto iz programa SAGA)

U deskriptivnoj statistici sNDVI rastera su dobivene vrijednosti kvantila od Q10-Q90 za amorfu sensu lato u opsegu od 151.063828 – 166.197174 i za amorfu sensu stricto od 151.785721 – 166.433563. Vrijednosti unutar tog raspona ukazuju na postojanost površina poligona amorfe unutar rasterskih slojeva. Sa modulom „Reclassify grid values“ dobivam reklasificirane rastere, postavljajući kriterij da sve unutar gore navedenih vrijednosti računamo kao „1“ – područja pod amorfom – ili sve izvan gore navedenih vrijednosti kao „0“ – područja bez amorfe. sNDVI rasterski slojevi imaju vrijednost prostornih objekata od 0 do 1, gdje broj označava broj spektralnih kanala u kojem je preklapanje sa spektralnim vrijednostima koji su zabilježeni za područja pod amorfom (0 – nema preklapanja za vrijednosti s ni jednim ni drugim spektralnim kanalom; 1 – preklapanje za vrijednosti s jednim kanalom).

Dobivene reklasificirane rastere „režem“ sa poligonskom kartom staništa Lonjskog polja. Nadalje pretvaram te izrezane rastere u vektore putem modula „Vectorising Grid Classes“. Naposljetku radim ukrštenje vektoriziranih rastera sa poligonom karte staništa Lonjskog polja iz 2006. putem modula „Intersect“.

Putem modula „Polygon Properties“ smo saznali tipove staništa u svakom intersectu te površinu koliku svaki stanišni tip zauzima.

2.3.3. Spektralni potpis amorfe

Kao i u prethodna dva poglavlja, spektralne kanale satelitskih snimki iz 2006. godine smo prenijeli u oblik pogodan programima IDRISI i SAGA. Satelitske snimke iz 2006. godine se sastoje od sljedećih kanala:

- Plavi (Blue)
- Zeleni (Green)
- Crveni (Red)

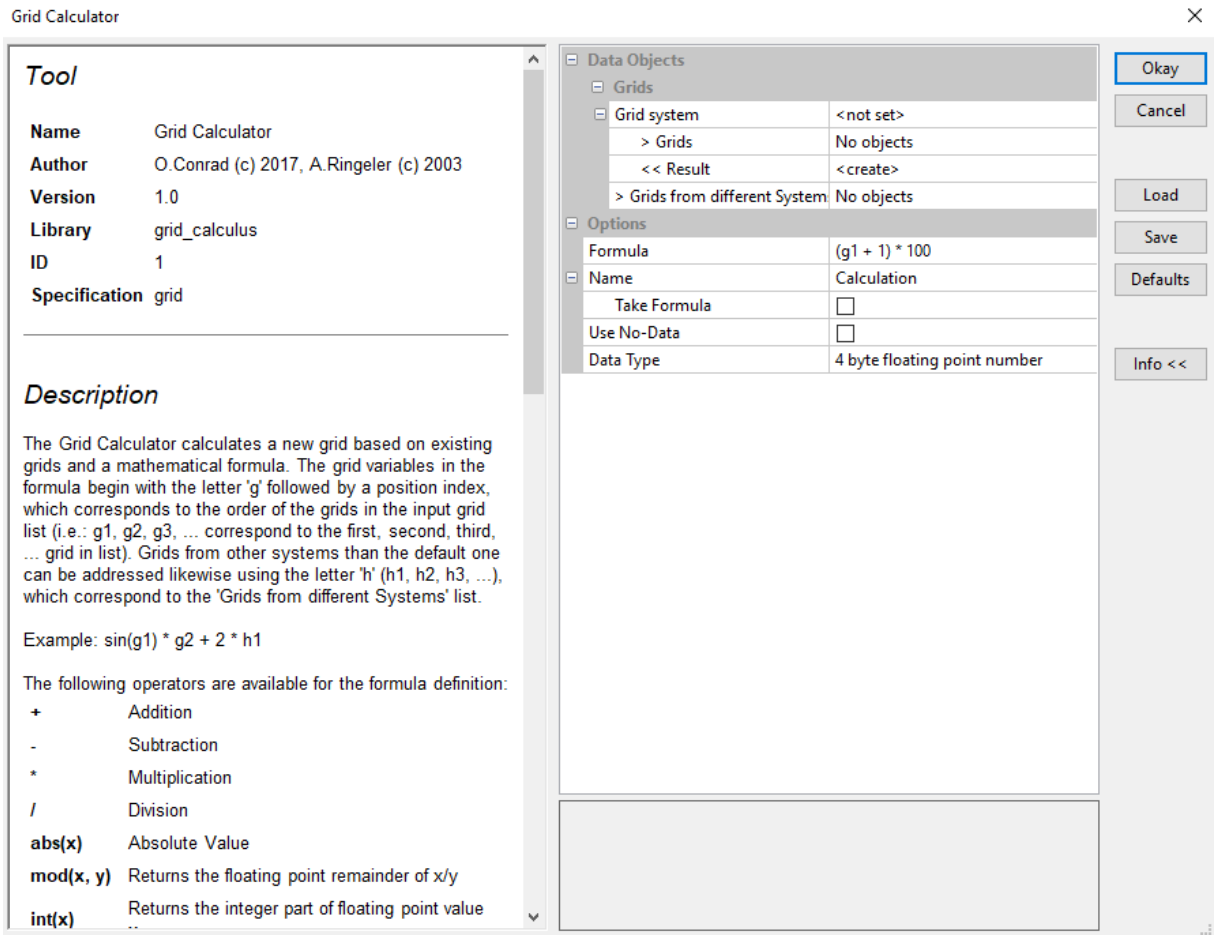
- Blisko Infracrveni (Near Infrared)
- Kratkovalni Infracrveni 1 (SWIR 1)
- Termalni Infracrveni (Thermal Infrared)
- Kratkovalni Infracrveni 2 (SWIR 2)

Ista procedura se napravila i za kanale iz 2000. i 2017. godine. Jedina razlika je što snimke iz 2017. imaju dodatna 3 kanala koja nisam uključio u ovaj rad, pošto smo htjeli dobiti spektralnu jednakost među svim godinama.

Kao i za NDVI, rastere svih spektralnih kanala iz 2006. godine sam „rezao“ sa poligonima čiste amorfe i poligonima miješane amorfe putem modula „Clip Grid with Polygon“. Novodobivene „rezane“ rastere sam podvrgnuo modulu „Grid Statistics for Polygons“ za jedan kvadratni poligon koji pokriva područje Lonjskog polja. Tim putem sam dobio deskriptivne statistike za svaki raster spektralnog kanala rezan za čistom ili miješanom amorfom.

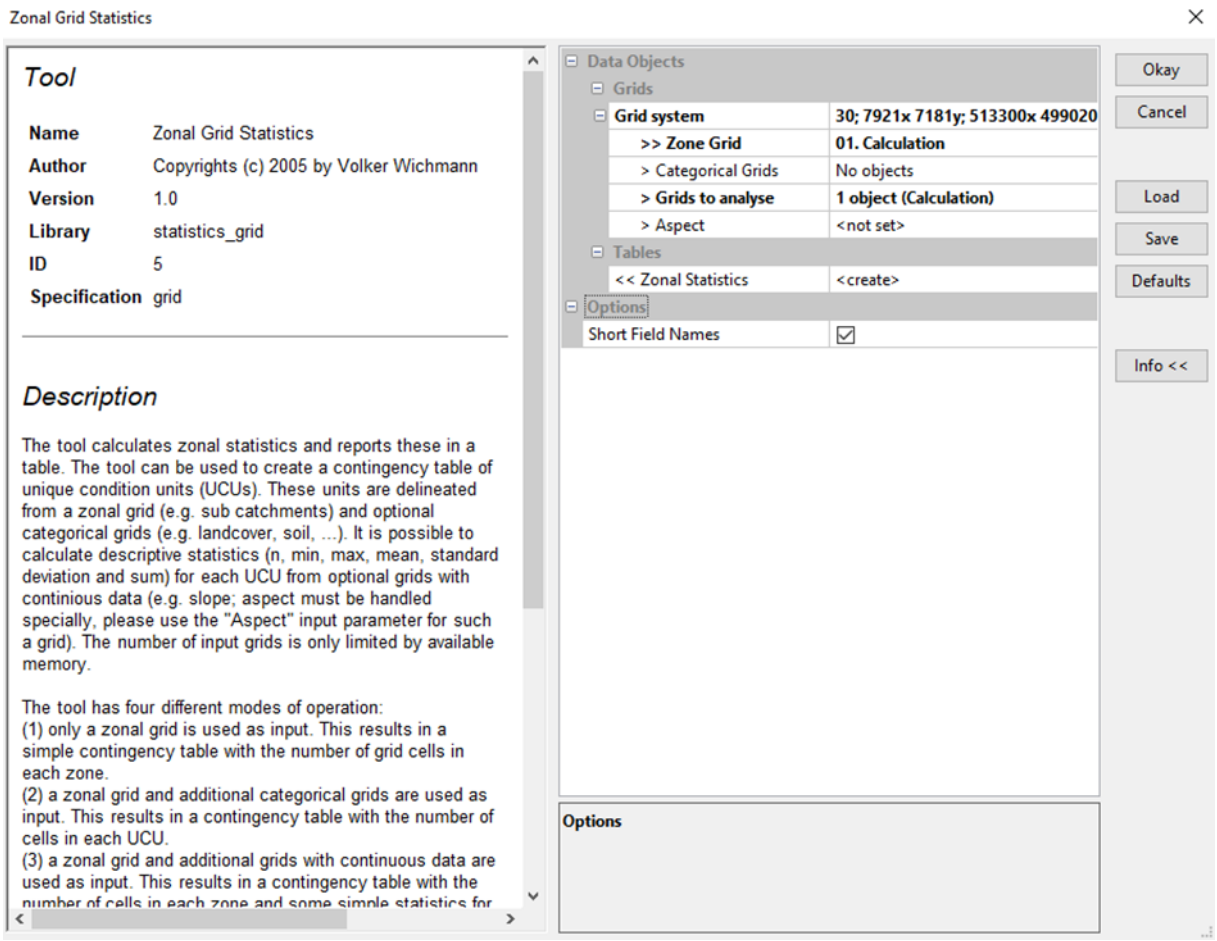
U deskriptivnoj statistici od rastera svakog spektralnog kanala su tako dobivene kvantilne vrijednosti od Q10-Q90 i Q20-80. Prema tim vrijednostima sam raster svakog kanala reklasificirao putem modula „Reclassify Grid Values“, kao i za NDVI – sve što je unutar granica kvantila ima vrijednost „1“ – postojanost amorfe, a sve izvan ima vrijednost „0“ – amorfa ne postoji.

Dobivene reklasificirane rastere spektralnih kanala sam zbrojio u četiri nova (sumirana) rasterska sloja putem modula „Grid Calculus“ (Slika 16), s obzirom na to u kojem rasponu kvantila se nalaze (Q10-Q90 ili Q20-Q80) i da li su „rezani“ sa poligonima čiste amorfe (amorfa sensu stricto) ili miješanim sastojinama amorfe (amorfa sensu lato). Tako sumirani slojevi su imali vrijednosti prostornih objekata u rasponu od 0 do 5, gdje broj označava broj spektralnih kanala u kojem je preklapanje sa spektralnim vrijednostima koji su zabilježeni za područja pod amorfom (0 – nema preklapanja za vrijednosti za niti jedan spektralni kanal; 1 – preklapanje za vrijednosti s jednim spektralnim kanalom itd.).



Slika 16. Modul „Grid Calculus“ (preuzeto iz programa SAGA)

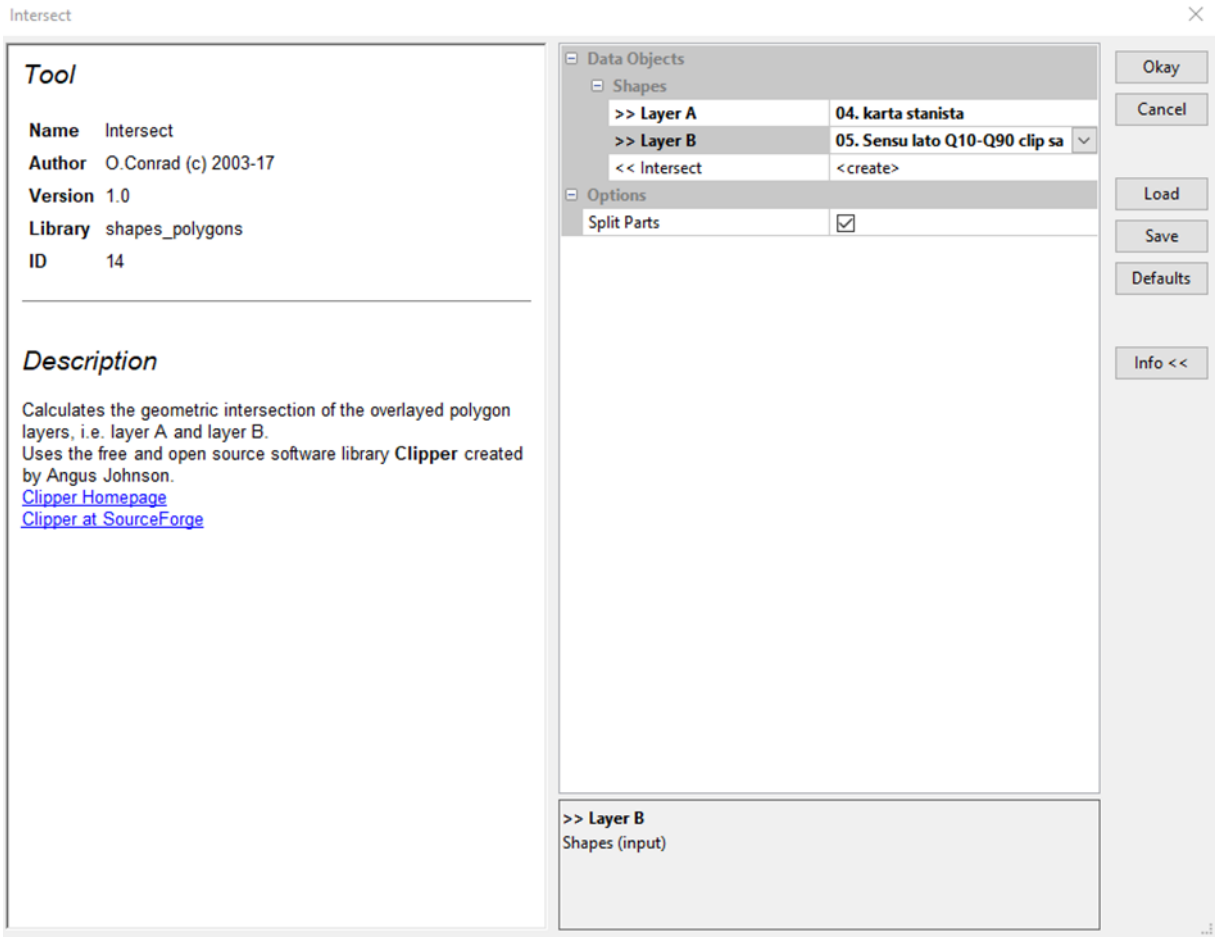
Na reklasificirane sumirane rasterske slojeve spektralnih kanala iz 2006. sam primjenio modul „Zonal Grid Statistics“ (slika 17), putem kojeg sam dobio deskriptivne statistike za svaku jedinstvenu jedinicu unutar zonalnog rasterskog sloja.



Slika 17. Modul „Zonal Grid Statistics“ (zonalne statistike rasterski sloj) (preuzeto iz programa SAGA)

Dobivene deskriptivne statistike smo iskoristili kako bi izračunali udio (tj. postotak) svake jedinstvene jedinice unutar zone.

Napravili smo „rez“ sumiranih rasterskih slojeva spektralnih kanala sa poligonskom kartom staništa Lonjskog polja iz 2006. godine. Nakon toga je slijedila pretvorba novodobivenih rasterskih slojeva u poligone putem vektorizacije. Naposljetku smo napravili „Intersect“ poligona karte staništa iz 2006. sa vektoriziranim rasterskim slojevima. Modul „Intersect“ (Slika 18) izračunava geometrijsko „ukrštenje“ dvaju prekrivenih poligonskih slojeva.



Slika 18. Modul „Intersect“ (preuzeto iz programa SAGA)

Putem modula „Polygon Properties“ smo saznali tipove staništa u svakom intersectu te površinu koliku svaki stanišni tip zauzima.

Spektralne kanale satelitskih snimki iz 2000. i 2017. sam preobratio u oblik koji radi u programima SAGA i IDRISI. Nakon toga je išla reklasifikacija rasterskih slojeva tih spektralnih kanala na temelju Q10-Q90 i Q20-Q80 vrijednosti po deskriptivnoj statistici kanala za 2006. godinu.

Za snimke iz 2017. godine je bilo potrebno promijeniti vrijednosti sa modulom „Grid Calculus“ u SAGI, tako da sam ukupne vrijednosti podijelio sa 257 kako bih dobio vrijednosti približne snimkama iz 2006. i 2000.

Reklasificirane rasterske slojeve spektralnih kanala iz 2000. i 2017. godine sam sumirao u nove rasterske slojeve, zbrajajući ih ovisno o tome da li su im vrijednosti vezane za poligone čiste amorfe ili miješane amorfe. Nadalje sam te sumirane rasterske slojeve „rezao“ sa poligonom parka.

Za 2000. godinu sam sumirane rasterske slojeve rezane sa poligonom parka filtrirao sa modulom „Majority Filter“ te vektorizirao.

Za rasterske slojeve iz 2017. sam napravio isti postupak, sa dodatkom da sam napravio „Intersect“ vektoriziranih rastera sa kartom staništa Lonjskog polja iz 2016. godine.

3. Rezultati

3.1. Kontrolirana klasifikacija (MAXLIKE)

Rezultati korištenja MAXLIKE kontrolirane klasifikacije prikazani su u Tablicama 1 i 2 s udjelima površina pojedinih stanišnih tipova u sastojinama miješane i čiste amorfe. U obje tablice najveći udio zauzimaju šume poljskog jasena: kod sastojina miješane amorfe zauzimaju površinu od 19,25%, a kod sastojina čiste amorfe zauzimaju 32,54%.

Tablica 1. Postotak površina određenih stanišnih tipova u sastojinama miješane amorfe za 2006. godinu

STANIŠNI TIPOVI	POVRŠINA (m^2)	POSTOTAK (%)	UKUPNA POVRŠINA (m^2)
Aktivna seoska područja	750050,7099	0,66	113268914,2
Amorfa	44783846,77	39,54	113268914,2
Hrastovo-grabove šume	4092799,092	3,61	113268914,2
Mezofilne livade Srednje Europe	2914691,464	2,57	113268914,2
Mozaične poljoprivredne površine	6487891,161	5,73	113268914,2
Nitrofilni pašnjaci i livade košanice	2602767,444	2,30	113268914,2
Šume poljskog jasena	21805948,53	19,25	113268914,2
Trščaci, rogoznici	11917092,13	10,52	113268914,2
Šume hrasta lužnjaka	13044355,07	11,52	113268914,2
Voda	4858129,921	4,29	113268914,2

Tablica 2. Postotak površina određenih stanišnih tipova u sastojinama čiste amorfe za 2006. godinu

STANIŠNI TIPOVI	POVRŠINA	POSTOTAK (%)	UKUPNA SUMA
Aktivna seoska područja	80276,13	0,67	12007963,85
Amorfa	4916661,97	40,95	12007963,85
Hrastovo-grabove šume	142339,57	1,19	12007963,85
Mezofilne livade Srednje Europe	204256,60	1,70	12007963,85
Mozaične poljoprivredne površine	1323485,29	11,02	12007963,85
Nitrofilni pašnjaci i livade košanice	157824,98	1,31	12007963,85
Šume poljskog jasena	3907332,31	32,54	12007963,85
Trščaci, rogoznici	509749,31	4,25	12007963,85
Šume hrasta lužnjaka	292143,58	2,43	12007963,85
Voda	473876,89	3,95	12007963,85

3.2. NDVI indeks iz 2006. godine

Tablica 3. Deskriptivne vrijednosti poligona miješanih (sensu lato) i čistih (sensu stricto) sastojina amorfe za rasterski sloj sNDVI-a.

Poligon	sNDVI [Q10]	sNDVI [Q20]	sNDVI [Q30]	sNDVI [Q40]	sNDVI [Q50]	sNDVI [Q60]	sNDVI [Q70]	sNDVI [Q80]	sNDVI [Q90]
Sensu lato	151,063828	154,545456	156,756760	158,620697	160,305344	161,764709	163,199997	164,615387	166,197174
Sensu stricto	151,785721	155,725189	158,399994	160,606064	162,204727	163,358780	164,444443	165,413528	166,433563

U tablici 3 je prikazan kvantilni raspon dobiven iz deskriptivne statistike rasterskog sloja sNDVI-a rezanog sa poligonima sastojina čiste i miješane amorfe iz 2006. Poligoni predstavljaju područja na snimci gdje se nalaze ili sastojine čiste amorfe (sensu stricto) ili sastojine miješane amorfe (sensu lato). Vrijednosti kvantila za poligone miješane i čiste amorfe su u rasponu od 151,06 do 166,19 i 151,78-166,43 za Q10-90, dok su za Q20-Q80 u rasponu od 154,54-164,61 i 155,72-165,41.

Tablica 4. Postotak površina poligona miješanih (sl) i čistih (ss) sastojina amorfe po vrijednostima „0“ - amorfa nije prisutna i „1“ - amorfa prisutna u reklasificiranim sNDVI rasterima iz 2006. godine

RASTER	SUMA MIJEŠANIH SASTOJINA AMORFE (m^2)	0 (m^2)	1 (m^2)	0/SUMA (%)	1/SUMA (%)
sNDVI sl 10-90	113077852,72	17481907,94	95595944,77	15,46	84,54
sNDVI sl 20-80	113080622,82	38024522,44	75063324,34	33,63	66,38
RASTER	SUMA ČISTIH SASTOJINA AMORFE (m^2)	0 (m^2)	1 (m^2)	0/SUMA (%)	1/SUMA (%)
sNDVI ss 10-90	11975758,94	3608609,01	8367149,93	30,13	69,87
sNDVI ss 20-80	11973906,06	3715402,42	8258503,63	31,03	68,97

U tablici 4 se može vidjeti kako postotak površina poligona miješanih (sl) i čistih (ss) sastojina amorfe po vrijednostima „1“ u reklasificiranim sNDVI rasterima iz 2006 godine zauzimaju puno veći udio površine (za 40-60 %) nego po vrijednostima „0“.

Tablica 5. Postotak određenih stanišnih tipova unutar vrijednosti „1“ - amorfa prisutna za reklasificirani sNDVI raster miješane amorfe iz 2006. godine po kvantilnim vrijednostima od Q10-Q90 (E.3.1. - mješovite hrastovo-grabove i čiste grabove šume; E.2.1.7./D.4.1.1. - Šuma poljskoga jasena s kasnim drijemovcem / sastojine čivitnjače; E.2.2. – Poplavne šume hrasta lužnjaka; E.2.1.7. – Šume poljskog jasena s kasnim drijemovcem)

TIP STANIŠTA	E.3.1.	E.2.1.7./D.4.1.1.	E.2.2.	E.2.1.7.
SUMA (m^2)	418341446,40	418341446,40	418341446,40	418341446,40
1 (m^2)	22231852,78	30025401,56	112685803,81	114814284,14
(1/SUMA) (%)	5,31	7,18	26,94	27,45

Tablica 6. Postotak određenih stanišnih tipova unutar vrijednosti „1“ - amorfa prisutna za reklasificirani sNDVI raster miješane amorfe iz 2006. godine po kvantilnim vrijednostima od Q20-Q80 (E.3.1. - mješovite hrastovo-grabove i čiste grabove šume; E.2.1.7./D.4.1.1. - Šuma poljskoga jasena s kasnim drijemovcem / sastojine čivitnjače; E.2.2. – Poplavne šume hrasta lužnjaka; E.2.1.7. – Šume poljskog jasena s kasnim drijemovcem)

TIP STANIŠTA	E.2.1.7./D.4.1.1.	E.2.2.	E.2.1.7.
SUMA (m^2)	321143678,30	321143678,30	321143678,30
1 (m^2)	24570362,70	83460207,36	99182178,91
(1/SUMA) (%)	7,65	25,99	30,88

Tablica 7. Postotak određenih stanišnih tipova unutar vrijednosti „1“ - amorfa prisutna za reklasificirani sNDVI raster čiste amorfe iz 2006. godine po kvantilnim vrijednostima od Q10-Q90 (E.3.1. - mješovite hrastovo-grabove i čiste grabove šume; E.2.1.7./D.4.1.1. - Šuma poljskoga jasena s kasnim drijemovcem / sastojine čivitnjače; E.2.2. – Poplavne šume hrasta lužnjaka; E.2.1.7. – Šume poljskog jasena s kasnim drijemovcem)

TIP STANIŠTA	E.3.1.	E.2.1.7./D.4.1.1.	E.2.2.	E.2.1.7.
SUMA (m^2)	385870342,30	385870342,30	385870342,30	385870342,30
1 (m^2)	21465587,29	27563172,11	107185019,82	108632350,68
(1/SUMA) (%)	5,56	7,14	27,78	28,15

Tablica 8. Postotak određenih stanišnih tipova unutar vrijednosti „1“ - amorfa prisutna za reklasificirani sNDVI raster čiste amorfe iz 2006. godine po kvantilnim vrijednostima od Q20-Q80 (E.3.1. - mješovite hrastovo-grabove i čiste grabove šume; E.2.1.7./D.4.1.1. - Šuma poljskoga jasena s kasnim drijemovcem / sastojine čivitnjače; E.2.2. – Poplavne šume hrasta lužnjaka; E.2.1.7. – Šume poljskog jasena s kasnim drijemovcem)

TIP STANIŠTA	E.1.1./D.4.1.1.	E.2.1.7./D.4.1.1.	E.2.2.	E.2.1.7.
SUMA (m^2)	291870786,90	291870786,90	291870786,90	291870786,90
1 (m^2)	15336030,24	23590962,99	70628455,16	93194237,50
(1/SUMA) (%)	5,25	8,08	24,20	31,93

Tablice 5,6,7 i 8 prikazuju kako najveći udio površine u reklasificiranom sNDVI rasteru miješane i čiste amorfe iz 2006. unutar vrijednosti „1“ - amorfa prisutna po svim kvantilnim vrijednostima zauzimaju poplavne šume hrasta lužnjaka (E.2.2.) (24,20-26,94 %) i šume poljskog jasena sa kasnim drijemovcem (E.2.1.7.) (27,45-31,93 %).

3.3. Spektralni potpisi iz 2006. godine

Tablica 9. Deskriptivne vrijednosti poligona miješanih i čistih sastojina amorfe za rasterske slojeve svih spektralnih kanala iz 2006.

Poligoni	[SPEKTRALNI KANALI]	[Q10]	[Q20]	[Q30]	[Q40]	[Q50]	[Q60]	[Q70]	[Q80]	[Q90]
Čista amorfa	Plavi	73,00	73,00	74,00	74,00	75,00	75,00	76,00	76,00	78,00
	Zeleni	29,00	29,00	30,00	30,00	30,00	31,00	31,00	32,00	34,00
	Crveni	23,00	23,00	24,00	24,00	24,00	25,00	26,00	27,00	29,00
	Blisko Infracrveni	88,00	93,00	98,00	102,00	105,00	108,00	111,00	113,00	117,00
	Kratkovalni infracrveni 1	63,00	66,00	69,00	70,00	71,00	73,00	74,00	76,00	82,00
	Termalni	131,00	132,00	132,00	132,00	132,00	133,00	133,00	134,00	136,00
	Kratkovalni infracrveni 2	18,00	19,00	19,00	20,00	20,00	21,00	22,00	24,00	28,00
Miješana amorfa	[SPEKTRALNI KANALI]	[Q10]	[Q20]	[Q30]	[Q40]	[Q50]	[Q60]	[Q70]	[Q80]	[Q90]
	Plavi	72,00	73,00	74,00	74,00	74,00	75,00	75,00	76,00	78,00
	Zeleni	29,00	29,00	30,00	30,00	31,00	31,00	32,00	32,00	34,00
	Crveni	23,00	23,00	24,00	24,00	25,00	25,00	26,00	27,00	29,00
	Blisko Infracrveni	83,00	89,00	93,00	97,00	101,00	104,00	108,00	112,00	118,00
	Kratkovalni infracrveni 1	61,00	65,00	69,00	71,00	73,00	74,00	77,00	80,00	85,00
	Termalni	131,00	132,00	132,00	132,00	132,00	133,00	133,00	134,00	136,00
	Kratkovalni infracrveni 2	18,00	19,00	20,00	21,00	21,00	22,00	23,00	25,00	28,00

Prikaz kvantilnih vrijednosti od Q10 do Q90 svih spektralnih kanala za poligone čiste i miješane amorfe iz 2006. godine (Tablica 9).

Tablica 10. Postotak površina miješanih (sl) i čistih (ss) sastojina amorfe po vrijednostima „4“ i „5“ (broj označava broj spektralnih kanala u kojem je preklapanje sa spektralnim vrijednostima koji su zabilježeni za područja pod amorfom) za kvantilne vrijednosti od Q10-Q90 i Q20-Q80 u reklasificiranim sumiranim rasterima iz 2006. godine

RASTER	sl 10-90	sl 20-80	RASTER	ss 10-90	ss 20-80
SUMA MIJEŠANIH AMORFI (m^2)	113081585,97	113080622,82	SUMA ČISTIH AMORFI (m^2)	11973159,02	11976785,49
4 (m^2)	26831793,16	32796849,95	4 (m^2)	26831793,16	32796849,95
5 (m^2)	63454395,11	25488312,51	5 (m^2)	63454395,11	25488312,51
4/SUMA (%)	23,73	29,00	4/SUMA (%)	30,91	30,37
5/SUMA (%)	56,11	22,54	5/SUMA (%)	45,35	32,46

Udio površina miješanih (sl) i čistih sastojina (ss) amorfe po vrijednostima „4“ u reklasificiranim sumiranim rasterima iz 2006. godine je poprilično sličan za sva četiri rastera (jedino je manji za raster miješane amorfe po Q10-Q90 gdje je 23,73 %, dok je u drugim slučajevima od 29-31 %). Kod vrijednosti „5“ se raster miješane i čiste amorfe po Q10-Q90 značajno ističu (56,11 % i 45,35 %) naspram miješanih i čistih amorfa po Q20-Q80 (22,54 % i 32,46 %) (Tablica 10).

Tablica 11. Postotak površina određenog stanišnog tipa unutar vrijednosti „4“ i „5“ za reklasificirani sumirani raster miješane amorfe iz 2006. po kvantilnim vrijednostima od Q10-Q90 (E.2.1.7. – Šuma poljskog jasena s kasnim drijemovcem; E.2.2. – Poplavne šume hrasta lužnjaka; D.4.1.1. – Sastojine čivitnjače; E.1.1. - Poplavne šume vrba; E.2.1. – Poplavne šume crne johe i poljskog jasena; I.2.1.1. – Mozaične poljoprivredne površine)

TIP STANIŠTA	SUMA (m^2)	4 (m^2)	5 (m^2)	(4/SUMA) (%)	(5/SUMA)(%)
E.2.1.7.	125180718,30	35529701,38		28,38	
E.2.1.7./D.4.1.1.	125180718,30	8426450,00		6,73	
E.2.2.	125180718,30	34958403,10		27,93	
D.4.1.1.	60224421,11		7657424,43		12,71
E.1.1./D.4.1.1.	60224421,11		13103264,88		21,76
E.1.1./E.2.1./D.4.1.1.	60224421,11		3268025,71		5,43
E.2.1.7.	60224421,11		32061369,34		53,24
E.2.2.	60224421,11		29976608,39		49,77
I.2.1.1.	60224421,11		9107100,40		15,12

Tablica 12. Postotak površina određenog stanišnog tipa unutar vrijednosti „4“ i „5“ za reklasificirani sumirani raster miješane amorfe iz 2006. po kvantilnim vrijednostima od Q20-Q80 (E.2.1.7. – Šuma poljskog jasena s kasnim drijemovcem; E.2.2. – Poplavne šume hrasta lužnjaka; D.4.1.1. – Sastojine čivitnjače; E.1.1. - Poplavne šume vrba; E.2.1. – Poplavne šume crne johe i poljskog jasena; I.2.1.1. – Mozaične poljoprivredne površine)

TIP STANIŠTA	SUMA (m^2)	4 (m^2)	5 (m^2)	(4/SUMA) (%)	(5/SUMA) (%)
E.1.1./D.4.1.1.	88549443,37	7020744,76		7,93	
E.2.1.7./D.4.1.1.	88549443,37	10255989,98		11,58	
E.2.2.	88549443,37	17207267,46		19,43	
E.2.1.7.	88549443,37	23424444,33		26,45	
D.4.1.1.	51962846,08		3887652,92		7,48
E.1.1./D.4.1.1.	51962846,08		5327155,09		10,25
E.2.2.	51962846,08		7415809,39		14,27
E.2.1.7./D.4.1.1.	51962846,08		7479812,63		14,39
E.2.1.7.	51962846,08		10091804,28		19,42

Tablica 13. Postotak površina određenog stanišnog tipa unutar vrijednosti „4“ i „5“ za reklasificirani sumirani raster čiste amorfe iz 2006. po kvantilnim vrijednostima od Q10-Q90 (E.2.1.7. – Šuma poljskog jasena s kasnim drijemovcem; E.2.2. – Poplavne šume hrasta lužnjaka; D.4.1.1. – Sastojine čivitnjače; E.1.1. - Poplavne šume vrba; E.2.1. – Poplavne šume crne johe i poljskog jasena; I.2.1.1. – Mozaične poljoprivredne površine)

TIP STANIŠTA	SUMA (m^2)	4 (m^2)	5 (m^2)	(4/SUMA) (%)	(5/SUMA)(%)
E.1.1./D.4.1.1.	120000450,00	6668467,60		5,56	
E.2.1.7./D.4.1.1.	120000450,00	10618635,82		8,85	
E.2.1.7.	120000450,00	30219108,36		25,18	
E.2.2.	120000450,00	30424697,95		25,35	
D.4.1.1.	100948179,40		5430333,67		5,38
E.1.1./D.4.1.1.	100948179,40		8974062,69		8,89
E.2.1.7./D.4.1.1.	100948179,40		12838223,60		12,72
E.2.2.	100948179,40		16099549,30		15,95
E.2.1.7.	100948179,40		21333355,06		21,13

Tablica 14. Postotak površina određenog stanišnog tipa unutar vrijednosti „4“ i „5“ za reklasificirani sumirani raster čiste amorfe iz 2006. po kvantilnim vrijednostima od Q20-Q80 (E.2.1.7. – Šuma poljskog jasena s kasnim drijemovcem; E.2.2. – Poplavne šume hrasta lužnjaka; D.4.1.1. – Sastojine čivitnjače; E.1.1. - Poplavne šume vrba; E.2.1. – Poplavne šume crne johe i poljskog jasena; I.2.1.1. – Mozaične poljoprivredne površine)

TIP STANIŠTA	SUMA (m^2)	4 (m^2)	5 (m^2)	(4/SUMA) (%)	(5/SUMA) (%)
E.1.1./D.4.1.1.	88549443,37	7020744,76		7,93	
E.2.1.7./D.4.1.1.	88549443,37	10255989,98		11,58	
E.2.2.	88549443,37	17207267,46		19,43	
E.2.1.7.	88549443,37	23424444,33		26,45	
D.4.1.1.	51962846,08		3887652,92		7,48
E.1.1./D.4.1.1.	51962846,08		5327155,09		10,25
E.2.2.	51962846,08		7415809,39		14,27
E.2.1.7./D.4.1.1.	51962846,08		7479812,63		14,39
E.2.1.7.	51962846,08		10091804,28		19,42

Unutar vrijednosti „4“ za reklasificirane sumirane rastere miješane amorfe iz 2006. po svim kvantilnim vrijednostima, najviši udio zauzimaju šume hrasta lužnjaka (19,43-27,99 %) i šume poljskog jasena s kasnim drijenovcem (25,35-27,93 %). Unutar vrijednosti „5“, kod reklasificiranog sumiranog rastera miješane amorfe iz 2006. po kvantilnim vrijednostima od Q10-Q90, značajan postotak zauzimaju šume poljskog jasena s kasnim drijenovcem (53,24 %) i poplavne šume rasta lužnjaka (49,77 %)

(Tablica 11). Kod ostalih reklasificiranih rastera sa drugim kvantilnim vrijednostima su udjeli površine poplavne šume hrasta lužnjaka (14,27-15,95 %) i šuma poljskog jasena s kasnim drijenovcem (19,42-21,13 %) značajno manji (Tablice 12, 13 i 14).

Tablica 15. Površine poligona sastojina miješane (sl) i čiste (ss) amorfe po kvantilima unutar vrijednosti „4“ i „5“ za 2000. godinu

POLIGON	4 (m^2)	5 (m^2)
sl10-90	38160000	27092700
sl20-80	7189200	1157400
ss10-90	32440500	14088600
ss20-80	1531800	539100

Tablica 16. Površine poligona sastojina miješane (sl) i čiste (ss) amorfe po kvantilima unutar vrijednosti „2“ i „3“ za 2017. godinu

POLIGON	2 (m^2)	3 (m^2)
sl10-90	145596817,15	296243088,56
sl20-80	388158642,27	1573908,48
ss10-90	5936882,30	215031199,55
ss20-80	388783994,33	739519,26

Tablice 15 i 16 prikazuju površine poligona miješane (sl) i čiste amorfe (ss) unutar određenih vrijednosti, s obzirom na reklasificirani sumirani raster koji predstavljaju po kvantilima.

4. Rasprava

Klasifikacijom maksimalne vjerojatnosti miješanih staništa amorfe iz 2006. se pokazalo da unutar sveukupne površine miješanih staništa amorfe, amorfa zauzima udio površine od 39,54 %. Slično je i za sastojine čiste amorfe, gdje je udio površine amorfe 40,95 %. Prema reklasificiranim sNDVI rasterima iz 2006., unutar vrijednosti „0“ i „1“ udio površine amorfe varira od najnižih 15,46 % pa sve do 84,54 %. Širok raspon tih vrijednosti ukazuje na to da korištenje NDVI indeksa za računanje rasprostranjenosti amorfe nije prikladno i precizno. Kod reklasificiranih sumiranih rastera iz 2006. godine se unutar vrijednosti „4“ javljaju približno podjednaki udjeli površine čiste i miješane amorfe (23,73-30,91 %). Unutar vrijednosti „5“ je odskok u udjelima miješane i čiste amorfe po kvantilima Q10-Q90 (56,11 % i 45,35 %), dok je u kvantilima Q20-Q80 za miješanu amorfu udio značajnije manji (22,54 %) nego za čistu amorfu (32,46 %).

Prema rezultatima klasifikacije maksimalnih vjerojatnosti iz 2006. godine, najveći postotak miješanja drugog staništa sa sastojinama miješane amorfe pokazuju šume poljskog jasena (19,25 %). Sljedeći u nizu su šume hrasta lužnjaka (11,52 %) i trščaci i rogoznici (10,52 %). Kod sastojina čiste amorfe je stanje prilično drugačije, gdje šume poljskog jasena zauzimaju skoro trećinu (32,54 %) cijele površine, dok je postotak šuma hrasta lužnjaka i trščaca i rogoznika irelevantan (2,43 % i 4,25 %). Drugačiji trend se javlja kod sNDVI rastera miješane i čiste amorfe iz 2006. unutar vrijednosti „1“ po kvantilnim vrijednostima od Q10-Q90 i Q20-Q80, gdje sastojine poplavne šume hrasta lužnjaka i šume poljskog jasena s kasnim drijemovcem zauzimaju slične postotke površina, od 25-32 %. Kod reklasificiranih sumiranih rastera miješane i čiste amorfe iz 2006. po kvantilnim vrijednostima se unutar vrijednosti „4“ iskazuju poplavne šume hrasta lužnjaka sa rasponom od 19-26% površine, dok šume poljskog jasena s kasnim drijenovcem zauzimaju 26-28% površine. Unutar vrijednosti „5“ se najviše ističu poplavne šume hrasta lužnjaka i poljskog jasena s kasnim drijemovcem za reklasificirani sumirani raster miješane amorfe iz 2006. po kvantilnim vrijednostima od Q10-Q90, gdje šume poljskog jasena s kasnim drijemovcem zauzimaju 53,24% površine, a poplavne šume hrasta lužnjaka zauzimaju 49,77 % površine. Kod ostalih rastera sa drugim kvantilnim vrijednostima unutar vrijednosti „5“ poplavne šume hrasta lužnjaka zauzimaju površinu od 14-16 %, a šume poljskog jasena s kasnim drijenovcem zauzimaju površinu od 19-22 %. Iako se postotci javljaju u različitim brojevima kod svih slučajeva, očigledno je da se u staništima amorfe najčešće klasificiraju poplavne šume hrasta lužnjaka i poljskog jasena s kasnim drijemovcem. Predviđene površine pod amorfom (uključujući i mješavine s drugim stanišnim tipovima), na temelju metode spektralnih potpisa su se povećavale od predviđenih 12,9 % u 2000. godini, preko 45 % u 2006, i 58 % u 2017. godini.

Korištene snimke svih godina su iz ljetnog, optimalnog stadija vegetacijske sezone. Amorfa cvate od svibnja do srpnja, a lista još ranije u proljeće. Mogućnost je da bolje

razlike između amorfe i susjednih sastojina bi se dobile zbog fenologije vrsta, ako bi se uzimale snimke iz cijelog vegetacijskog razdoblja. Potencijalno bi se mogao dobiti i razlučiviji vegetacijski indeks (NDVI), pošto bi se mogle usporediti sastojine amorfe i susjedne sastojine u različitim fenološkim fazama.

Iako često korištene metode u nizu kartografskih projekta, i kontrolirana klasifikacija i NDVI indeks imaju svoja ograničenja s obzirom na tematsku razlučivost kartiranih vegetacijskih tipova, gdje se njihova točnost smanjuje s povećanjem tematske razlučivosti (npr. šuma – travnjaci kao grublja razlučivost, a biljne zajednice na razini asocijacije kao primjer visoke tematske razlučivosti). Tako na primjer Jelaska i sur. (2005) pri kartiranju vegetacije Parka prirode Žumberak-Samoborsko gorje dobivaju 65% točnosti pri kartiranju, gdje su veću točnost zabilježili za šumsku vegetaciju (70 %) u odnosu na nešumsku (61 %) u kojoj se nalazi veći broj zajednica na razini asocijacija. Dirnbock i sur. (2003) dobivaju 69,4 % točnosti na razini biljnih asocijacija, a De Colstoun i sur. (2003) čak 99,5 % točnosti, ali pri kartiranju na grubljoj tematskoj razini šumska – nešumska vegetacija.

Multispektralni senzori Landsat satelita imaju prostornu razlučivost od 30 metara, što spada u kategoriju srednje prostorne razlučivosti. Općenito, snimke sa nižom rezolucijom se mogu koristiti samo kada se identificiraju visoki nivoi vegetacijskih klasa, dok se slike sa relativno većom rezolucijom koriste za detaljnije klasifikacije vegetacije (Xie i sur. 2008). Dok su multispektralni senzori Landsat satelita korisni za mapiranje vegetacije na nivou zajednice, Quickbird i IKONOS senzori, na primjer, imaju puno veću razlučivost (Quickbird na 2,4 - 0,6 metara, IKONOS na 4 metara) i mogu mapirati vegetaciju na razini vrsta. U istraživanju od Zhang i sur. (2009.) se pokazalo da putem IKONOS senzora se mogu mapirati vegetacijski tipovi u urbanom području sa sveukupnom preciznošću od 87,71 %

U pregledu literature korištenja snimaka daljinskog promatranja za potrebe kartiranja/praćenja stranih vrsta Skowronek i sur. (2018) pronalaze da su ove metode prikladnije za vrste drveća (npr. američki javor, pajasen i bagrem) nego za vrste manjeg habitusa (npr. jorgovan, pontski rododendron, prstasti troskot). Nadalje, Skowronek i sur. (2018) pronalaze da su u najvećem broju korištene snimke daljinskog promatranja veće prostorne razlučivosti nego što je ona kod LANDSAT snimaka.

Jedan od razloga manje točnosti raspoređenosti amorfe je veliki broj poligona u karti staništa Lonjskog polja iz 2006. godine. Osim velike rasprostranjenosti, poligoni su mozaično raspoređeni, što upućuje na veliku prostornu raznolikost. Sveukupno ima oko 40-ak stanišnih tipova u 1800 poligonskih objekata.

Korišteni su NDVI indeks i spektralni potpisi amorfe kako bi se dobila što bolja razlika između sastojina amorfe i ostalih šumskih sastojina. S obzirom na vegetacijsko razdoblje iz kojeg smo koristili snimku iz 2006., nema dovoljno razlike između amorfe i drugih stanišnih tipova/šumskih sastojina. Upotrebom NDVI kanala se pokazalo da

sastojine amorfe i ostale sastojine imaju veću sličnost nego kanali iz kojih smo uzimali spektralne potpise. Moguće objašnjenje je da je tome tako jer se NDVI izračunava na temelju spektralnih vrijednosti samo dva kanala (infracrveni i blisko infracrveni), dok spektralni potpisi sadrže cijeli spektralni raspon: plavi, zeleni, crveni, bliskoinfracrveni i dva kratkovalna infracrvena kanala. Zbog većeg broja kanala, naspram dva za NDVI, očekivano je veće razlučivanje razlika između amorfe i ostalih sastojina. Poželjno bi bilo i korištenje satelitskih snimaka iz različitih razdoblja vegetacijske sezone, što bi značajno povećalo potrebne računske resurse, što nije testirano u okviru ovog diplomskog rada.

5. Zaključak

- Metode kontrolirane klasifikacije (maxlike) i NDVI indeks, inače standardni za kartiranje vegetacije na grubljoj tematskoj razini nisu se pokazali prikladni za identifikaciju sastojina amorfe na području Lonjskog polja.

- Korištenje većeg broja spektralnih kanala u svrhu dobivanja jedinstvenog spektralnog potpisa amorfe pokazalo se kao najboljom od korištenih metoda. Dobiveni rezultati upućuju na kontinuirano širenje amorfe na području Parka. Međutim za veću točnost klasifikacije i samih površina, bilo bi dobro koristiti satelitske snimke iz različitih razdoblja vegetacijske sezone.

- Daljinska promatranja imaju veliki potencijal u praćenju širenja invazivnih vrsta, no potrebno je prilagoditi spektralnu, vremensku i prostornu razlučivost korištenih senzora vrsti od interesa, s obzirom na njenu fenologiju i fenologiju okolne zavičajne flore i vegetacije.

6. Literatura

- Bradley B.A., (2014): Remote detection of invasive plants: a review of spectral, textural and phenological approaches. Biological Invasions **16**: 1411–1425.

- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., and Boehner, J. (2015): System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. Geoscientific Model Development, 8, 1991-2007, doi:10.5194/gmd-8-1991-2015.

- De Coulston E.C.B., Story M. H., Thompson C., Commisso K., Smith T.G., Irons J.R. (2003): National Park vegetation mapping using multitemporal Landsat 7 dana and a decision teee classifier. Remote Sensing of Environment, **85**: 316-327

- Deering D. W. (1978): Rangeland reflectance characteristics measured by aircraft and spacecraft sensors. Ph.D. Thesis. Texas A&M University, College Station.

- Dirnbock T., Dullinger S., Gottfried M., Ginzler C., Grabherr G. (2003): Mapping alpine vegetation based on image analysis, topographic variables and Canonical Correspondence Analysis. Applied Vegetation Science, **6**: 316-327

- Eastman R.J., Clark Labs (2012): IDRISI: The Selva Edition. Clark University, Worcester MA.

- Ehrenfeld J. G. (2010): Ecosystem consequences of biological invasions. Annual Review of Ecology, Evolution, and Systematics, **41**: 59–80.

- Gašparević M., Zrinjski M, Gudelj M. (2017): Analiza urbanizacije grada Splita. Geodetski list, **3** (2017): 189-202

- Gugić G., Ilijanić LJ., Topić J., Anić I., Gottstein S., Hima V., Ivaštinović D. (2006): Priručnik za kartiranje i upravljanje staništima u Parku prirode Lonjsko Polje. Javna ustanova Park prirode Lonjsko polje, Krapje.

- 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**(2): 303-311

- Jensen J. R., Lulla K. (1987): Introductory digital image processing: A remote sensing perspective. Brigham Young University.

- Krpan A., Tomašić Ž., Zečić Ž., Vuletić D. (2015.): Bioproizvodnost amorfe (*Amorpha fruticosa* L.) u jednogodišnjoj, dvogodišnjoj i četverogodišnjoj ophodnji. Šumarski list, **3-4** (2015): 123-135.

- Mihály, B., Botta-Dukát, Z. (2004): Biological invasion in Hungary - Invasive plants. Genetic Resources and Crop Evolution, **52**: 641-643

- Oluić, M. (2001): Snimanje i istraživanje Zemlje iz Svemira: sateliti, senzori, primjena. Hrvatska akademija znanosti i umjetnosti (HAZU) i Geosat, Zagreb.

- Roy D. P., Wulder M. A., Loveland T. R., Woodcock C. E., Allen R. G., Anderson M. C., Helder D., Irons J. R., Johnson D. M., Kennedy R., Scambos T. A., Schaaf C. B., Schott J. R., Sheng Y., Vermote E. F., Belward A. S., Bindschadler R., Cohen W. B., Gao F., Hipple J. D., Hostert P., Huntington J., Justice C. O., Kilic A., Kovalskyy V., Lee Z. P., Lymburner L., Masek J. G., McCorkel J., Shuai Y., Trezza R., Vogelmann J., Wynne R. H., Zhu Z. (2014): Landsat 8: Science and product vision for terrestrial global change research. Remote Sensing of Environment, **145**: 154–172.

- Sándor, A., & Kiss, T. (2007): Floodplain sedimentation and its influencing factors after the 2006 spring flood along the Middle Tisza River, in Szolnok, Hungary. Hidrologiai Kozlony, **87**(4): 19–24.

- Singh, A. (1989): Review Article Digital change detection techniques using remotely-sensed data. International Journal of Remote Sensing, **10**(6): 989–1003.

- Skowronek S., Stenzel S, Feilhauer H. (2018): Detecting invasive species from above – How can we make use of remote sensing dana to map invasive plant species in Germany? Natur und Landschaft, **9**: 434-438

- She X., Zhang L., Cen Y., Wu T., Huang C., Baig M. H. A. (2015): Comparison of the continuity of vegetation indices derived from Landsat 8 OLI and Landsat 7 ETM+ data among different vegetation types. Remote Sensing, **7**(10), 13485–13506.

- Tamás, J. (2001): The regularity of the invasion of invasive species in a Hungarian case study. Botanikai Kozlemenyek, **86–87**(1–2): 169–181.

- Vela E., Medved I., Miljković V. (2017): Geostatistička analiza vegetacijskih indeksa na šumskom ekosustavu Česma. Geodetski list, **1** (2017): 25-40.

- Xie Y., Sha Z., Yu M. (2008): Remote sensing imagery in vegetation mapping: a review. Journal of Plant Ecology, **1**(1): 9-23

- Zhang X., Feng X., Jiang H. (2010): Object-oriented method for urban vegetation mapping using IKONOS imagery. International Journal of Remote Sensing, **31**(1): 177-196

Izvori s weba:

- Park prirode Lonjsko polje, <https://www.pp-lonjsko-polje.hr>, Pristupljeno 20.03.2019.

- Pijani tvor, <https://www.pijanitvor.com/threads/civitnjaca-amorfa-amorpha-fruticosa.27020/> , Pristupljeno 20.03.2019.

- Priroda i biljke, <http://www.plantea.com.hr/amorfa>, Pristupljeno 20.03.2019.

- U.S. Geological Survey <https://www.usgs.gov/media/images/landsat-4-5-tm-and-landsat-7-etm-bands-and-their-uses>, Pristupljeno 10.09.2018.

7. Životopis

Rođen sam 4.8.1993. u Zagrebu. Školovanje sam započeo 2000. godine u osnovnoj školi „Mladost“ u novozagrebačkom naselju Utrina.

Godine 2008. sam upisao IV (jezičnu) gimnaziju u Zagrebu, koju završavam 2012. godine.

Akademske godine 2012./2013. upisujem preddiplomski studij Urbano šumarstvo, zaštita prirode i okoliša na Šumarskom fakultetu, Sveučilišta u Zagrebu. Istog završavam akademske godine 2015./2016. sa titulom prvostupnika Urbanog šumarstva, zaštite prirode i okoliša.

Akademske godine 2016./2017. upisujem diplomski studij Ekologije i zaštite prirode na Biološkom odsjeku, Prirodoslovno-matematičkog fakulteta u Zagrebu.