

SVEUČILIŠTE U ZAGREBU
GEODETSKI FAKULTET

Ivan Majić

*Detekcija urbane vegetacije snimanjem georeferenciranog
videozapisa modificiranom GoPro kamerom*

Zagreb, 2016.

Ovaj je rad izrađen na Geodetskom fakultetu, Zavodu za geomatiku, Katedri za geoinformatiku pod vodstvom prof. dr. sc. Damira Medaka i predan je na natječaj za dodjelu Rektorove nagrade u akademskoj godini 2015./2016.

Sadržaj

1.	Uvod.....	1
1.1.	Prethodna istraživanja.....	4
2.	Opći i specifični ciljevi rada	8
3.	Materijal i metode.....	10
3.1.	Prikupljanje podataka.....	10
3.1.1.	Oprema korištena za prikupljanje podataka.....	10
3.1.2.	Snimanje georeferenciranog video zapisa.....	14
3.2.	Obrada video zapisa pomoću programskog jezika Python	20
3.3.	Računanje vegetacijskih indeksa	21
3.4.	Klasifikacija snimki metodom binarne klasifikacije	26
3.4.1.	Uzorkovanje.....	27
3.4.2.	Statistička obrada uzoraka i određivanje granica klasa	28
3.4.3.	Klasifikacija snimki.....	31
3.5.	Analiza rezultata klasifikacije pomoću matrice konfuzije	32
3.6.	Izrada karte vegetacije za snimljeno područje.....	36
4.	Rezultati	37
4.1.	Prikupljeni podaci	37
4.2.	Rezultati uzorkovanja.....	38
4.3.	Rezultati klasifikacije	42
4.4.	Ocjena točnosti klasifikacije i usporedba vegetacijskih indeksa.....	58
4.5.	Karta vegetacije	76
4.6.	Problemi uočeni tijekom obrade i analize podataka	78
5.	Rasprava.....	80
6.	Zaključak.....	83
7.	Prilozi	84

Zahvale	95
Popis literatury	96
Sažetak	101
Summary.....	102

1. Uvod

Kada se govori o vegetaciji u gradovima većina će ljudi prvenstveno pomisliti na parkove i drvorede koji predstavljaju veće i zapaženije vegetacijske strukture u gradu. Taj se pojam u znanstvenoj literaturi naziva urbana šuma (eng. Urban Forest). Može se reći da se urbane šume u širem smislu odnose na pojedinačno drveće, drvorede, parkove i šume (Ostojić et al. 2013; Konijnendijk 2003). Ako taj pojam proširimo i na ostalu vegetaciju koja uključuje grmlje, raslinje i travnjake, onda govorimo o urbanoj vegetaciji (eng. Urban Vegetation).

Činjenica je da se svijet danas suočava s brojnim ekološkim problemima. Također, ukoliko se nastave dosadašnji trendovi urbanizacije do 2050. godine u gradovima bi moglo živjeti čak 75% svjetskog stanovništva ili 6 milijardi stanovnika (Blaschke et al. 2011; Bakici et al. 2013; Hancke et al. 2013) te možemo reći da su gradovi u tom smislu posebno ugroženi.

Problematikom održivog razvoja gradova bavi se koncept pametnih gradova, koji obuhvaća i problem očuvanja i upravljanja gradskim okolišem. To je koncept prema kojem se probleme današnjeg svijeta, koji se nosi s brojnim ekološkim i društvenim problemima, nastoji riješiti na pametan, učinkovit i održiv način koristeći suvremena tehnološka rješenja. Jedan od najvećih problema današnjih brzorastućih gradova je onečišćenje zraka i okoliša. Ono se nastoji smanjiti povećanjem ekološke svijesti građana, smanjenjem emisije štetnih plinova te pametno osmišljenom i upravljanom urbanom vegetacijom.

Opažanje vegetacije je od iznimne važnosti za razumijevanje korelacija između klimatskih promjena, stanja okoliša, zdravlja i produktivnosti vegetacije. Nadalje,

stanje vegetacije utječe i na druge ekosustave kao što su staništa brojnih životinjskih vrsta uključujući insekte, ptice i velike biljojede (Nijland et al. 2014).

Urbana vegetacija ima i druge, specifične funkcije u gradskom ekosustavu. Ona tako ublažava utjecaje toplinskih otoka, pruža prirodni hlad te ublažava štetni utjecaj oborinskih voda koje mogu uzrokovati klizišta. Također treba spomenuti ulogu urbane vegetacije u životu građana koji zelene površine koriste za razne sportske, rekreativske i druge aktivnosti. Urbana vegetacija tako izravno utječe na kvalitetu života građana (Ostović et al. 2013). Možemo reći da će u budućnosti urbana vegetacija biti važnija nego ikada te treba pronaći pametno rješenje za opažanje, nadzor i upravljanje urbanom vegetacijom.

Danas se opažanje vegetacije uglavnom veže uz daljinska istraživanja iz zraka ili svemira. Već od prvih satelitskih misija opažanje zemljine površine i njene vegetacije je bilo područje kojem se pridavala velika važnost. Veliki iskorak u tom području bio je razvoj i upotreba multispektralnih senzora u daljinskim istraživanjima. Ti senzori mogu opažati elektromagnetske valove u velikom rasponu valnih duljina i tako znanstvenicima pružaju veliku količinu podataka na temelju kojih su razvijene brojne metode za analiziranje zemljine površine.

Iako su usvojena kao glavna metoda opažanja vegetacije, daljinska opažanja imaju neke nedostatke kada je riječ o opažanju urbane vegetacije. Urbana vegetacija ima specifičnu strukturu tako da varira širinom područja pokrivenog vegetacijom i slojevitom strukturom vegetacijskog pokrova. Može se dogoditi da zbog niske prostorne razlučivosti senzora za daljinsko istraživanje neka uska područja koja su pokrivena vegetacijom (npr. drvoredi, živice i dr.) na snimkama ne budu prikazani kao područje pokriveno vegetacijom. Također treba shvatiti da je zbog prirode daljinskih opažanja, takvim opažanjima moguće detektirati samo najviši sloj vegetacije. Na taj

se način izostavljaju niži slojevi vegetacije na područjima gdje je vegetacija slojevita (npr.drvored ispod kojeg se nalazi grmlje i trava), a takvih je područja u gradovima mnogo. Vremenska razlučivost daljinskih opažanja vegetacije je još jedan ograničavajući čimbenik, zbog činjenice da se takva opažanja vrše periodično. Za neke bi primjene vegetaciju trebalo snimati na dnevnoj razini ili po potrebi, što nije moguće izvesti daljinskim opažanjima. Također, snimke iz svemira imaju vrlo ograničenu rezoluciju koja se kreće od 10 m do 50 m, ovisno o odabranom senzoru pojedinog satelita.

Zbog navedenih razloga, u svijetu se opažanje vegetacije amaterskim digitalnim kamerama prepoznaje kao cjenovno prihvatljiva metoda prikupljanja podataka visoke vremenske razlučivosti. Međutim, takvo je opažanje do sada uglavnom korišteno za praćenje usjeva ili nekih drugih vegetacijskih struktura van urbanih sredina. Kao platforma za kameru najčešće je korištena bespilotna letjelica, a u gradu bi za nju trebalo ishodovati dozvolu. Također je, zbog kompleksnosti vegetacijskih struktura te ograničenog dometa i duljine leta, upitna mogućnost bespilotnih letjelica da budu platforma za opažanje urbane vegetacije.

S druge se pak strane u posljednje vrijeme ulaze mnogo sredstava u razvoj autonomno upravljenih vozila (automobili, istraživački roboti i sl.). Oni bi se, po definiciji, trebali biti sposobni sami navigirati kako na cesti tako i na drugim terenima. Vozilo bi u oba slučaja trebalo biti svjesno svoje okoline, a posebna se važnost pridaje detekciji vegetacije. Pri terenskoj (eng. offroad) vožnji vozilo treba prepoznati vegetaciju i njezinu visinu kako bi moglo zaobilaziti grmlje i drveće, a u isto vrijeme prepoznati nisku vegetaciju kao podlogu po kojoj je moguće voziti (Bradley et al. 2007). Kod gradskih je prometnica čest slučaj da se uz njih nalazi vegetacija (trava,

grmlje, drvoredi), pa tako detekcija vegetacije uz prometnice može poslužiti vozilu da lakše razazna cestu od ostalog terena i tako pomoći pri navigiranju.

Jedan od načina na koje je moguće pratiti i analizirati urbanu vegetaciju je pomoću georeferenciranog multispektralnog videozapisa. Georeferencirani multispektralni videozapis je tehnika kojom je svakom kadru videozapisa dodijeljena geografska koordinata. Pomoću multispektralnog video zapisa, moguće je izračunati različite vegetacijske indekse. U ovom radu istražit će se mogućnost ovakvog prikupljanja podataka o urbanoj vegetaciji te koji vegetacijski indeks najbolje razlučuje vegetaciju od ostalih objekata unutar gradova.

1.1. Prethodna istraživanja

(Milton 2002) je proveo istraživanje u kojem je pokazao kako se amaterske digitalne kamere mogu koristiti za prikupljanje podataka iz blisko-infracrvenog dijela elektromagnetskog spektra. Njegova se metoda sastoji od snimanja iste scene dva puta. Prvi prvom se snimanju scene preko leće kamere postavi filter koji propušta energiju iz blisko-infracrvenog dijela elektromagnetskog spektra, a blokira sve druge vrijednosti. Pri korištenju takvog filtera na mjestu crvenog kanala prikupljaju se vrijednosti iz blisko-infracrvenog dijela spektra, a ostali se kanali, iako mogu sadržavati neke podatke, ne koriste u daljnjoj obradi. Filter se nakon toga skida i ista se scena snima po drugi put kako bi se dobila RGB snimka scene. Konačno se dobiju dvije fotografije gdje jedna sadrži blisko-infracrveni kanal, a druga crveni, zeleni i plavi kanal. Te se fotografije dalje mogu obrađivati u nekom računalnom programu kako bi se analizirala snimljena scena. Glavni nedostatak ove metode je što se scena mora snimati dva puta. Također, kamera i scena moraju biti statični, pa se ta metoda ne

može koristiti za opažanje scene koja je u pokretu niti se može opažati s platforme koja se kreće.

(Dare 2008) je u svom istraživanju ispitao mogućnost korištenja amaterskih digitalnih kamera za multispektralno snimanje. On se orijentirao na snimanje iz zraka te je s geometrijskog, radiometrijskog i logističkog gledišta usporedio komercijalnu kameru posebno namijenjenu za multispektralno snimanje sa sustavom amaterskih digitalnih kamera kojem je određenim preinakama također omogućeno multispektralno snimanje. Komercijalna kamera koju je koristio u istraživanju je Redlake MS4100, a u drugom je sustavu koristio Canon 350D kamere. Sustav amaterskih digitalnih kamera se, kao i kod prethodnog istraživanja, zasniva na snimanju iste scene dva puta, ali se ovdje ta dva snimanja vrše istovremeno s dvije kamere. Jedna je kamera modificirana tako da je uklonjen tvornički postavljeni filter koji blokira blisko-infracrvenu svjetlost te je na njegovo mjesto postavljen Schott RG715 filter koji blokira svu svjetlost valne duljine manje od 700nm. Na taj je način dobivena kamera osjetljiva samo na blisko-infracrvenu svjetlost. Druga kamera nije modificirana. Rezultati istraživanja su pokazali da ova dva sustava imaju približno jednaka geometrijska i radiometrijska svojstva, ali je pokazano da je komercijalna kamera logistički mnogo zahtjevnija za korištenje. Razlog tome je što komercijalna kamera korištena u istraživanju zahtjeva vanjski izvor napajanja i vanjsku jedinicu za pohranu podataka te ju je za snimanje potrebno spojiti na stolno računalo. Sustav amaterskih kamera, s druge strane, može samostalno vršiti snimanje te ne zahtjeva vanjsko napajanje i pohranu podataka. Autor je također naglasio da je komercijalna kamera s cijenom od \$ 30 000 višestruko skuplja od sustava amaterskih digitalnih kamera koji ima cijenu oko \$ 5 000.

(Lebourneis et al. 2008) su proveli petomjesečno istraživanje u kojem su koristili tri amaterske digitalne kamere za opažanje polja šećerne trske. Jedna je kamera ostala

neizmjenjena i snimala je RGB snimke, druga je kamera modificirana da prikuplja podatke iz blisko-infracrvenog dijela elektromagnetskog spektra, a treća je modificirana da prikuplja Red-Edge podatke. Modifikacija kamere je izvršena slično kao i kod prethodnog istraživanja, uklanjanjem tvornički postavljenog filtera i postavljanjem drugih filtera koji propuštaju samo valne duljine od interesa. Kamere su zatim postavljene na letjelicu iz koje su vršena snimanja. Postavke kamera ostale su iste za vrijeme cijelog istraživanja, a snimke su pohranjivane u JPEG i RAW formatima. Autori su zatim, u naknadnoj obradi, vršili korekcije kako bi eliminirali efekte vinjetiranja i normalizirali snimke između različitih datuma snimanja. Rezultati istraživanja pokazuju da format snimki (RAW i JPEG) ne utječe na kvalitetu rezultata, da vinjetiranje ima značajan utjecaj, osobito kod modificirane kamere te da je korištenje normaliziranih vegetacijskih indeksa sa snimkama na kojima je prethodno korigiran utjecaj vinjetiranja dosta dobro za ispravljanje nepravilnosti uzrokovanih uvjetima osvjetljenja na sceni.

(Rabatel et al. 2011) su opisali metodološki pristup prikupljanju podataka iz blisko-infracrvenog dijela spektra pomoću amaterskih digitalnih kamera. Glavna prednost njihove metode u odnosu na prethodna istraživanja je u tome da se svi kanali potrebni za računanje vegetacijskih indeksa dobiju iz jedne snimke te scenu nije potrebno opažati dva puta. Kao i autorи u prijašnjim istraživanjima, iskoristili su činjenicu da su senzori koji se koriste u modernim digitalnim kamerama osjetljivi i na blisko-infracrveni dio spektra, ali većina proizvođača postavlja filter koji ne dopušta da ta svjetlost dođe do senzora. Metoda korištena u istraživanju se zasniva na uklanjanju tog filtera kako bi se omogućilo da kamera prikuplja podatke iz blisko-infracrvenog dijela spektra. Glavni dio istraživanja se bavi optimizacijom filtera niskog šuma (eng. Low-pass filter) koji se koristi u naknadnoj obradi snimki. Naime, uklanjanjem blisko-infracrvenog

filtera, crveni, zeleni i plavi kanal opterećuju se šumom kojeg uzrokuje blisko-infracrvena svjetlost. Autori koriste filter niskog šuma kako bi na mjestu plavog kanala dobili samo iznos blisko-infracrvene svjetlosti te dalje tu vrijednost oduzimaju od druga dva kanala. Konačno se dobije snimka koja sadrži blisko-infracrveni, zeleni i crveni kanal.

(Bradley et al. 2007) su u svom istraživanju ispitali mogućnost korištenja podataka iz blisko-infracrvenog dijela eletromagnetskog spektra za detekciju vegetacije. Cilj je poboljšati autonomnu navigaciju robotiziranog vozila pri terenskoj vožnji tako da vozilo vegetaciju prepozna kao prepreku koju može pregaziti. Takva vozila inače koriste laserske skenere za stvaranje oblaka točaka čijom analizom dobijaju informacije o svojoj okolini. Za opažanje vegetacije koristili su modificiranu kameru sa CCD senzorom na temelju čijih su snimaka računali NDVI. Te su rezultate povezali s ostatkom sustava i dokazali da se tako može poboljšati točnost autonomne navigacije vozila.

(Wurm et al. 2009) bavili su se problemom autonomne navigacije robota van zatvorenog prostora. Takvim je robotima uspješna detekcija vegetacije od iznimne važnosti zato što im pruža sigurnost i bolju učinkovitost pri autonomnoj navigaciji na otvorenom području. Za opažanje vegetacije koristili su laserski skener čije zrake imaju valnu duljinu u blisko-infrarvenom području. Mjeri se povratni signal laserske zrake koji je modeliran kao funkcija udaljenosti, kuta i svojstava materijala. Sustav je treniran pomoću podataka o vibraciji očitanih na senzoru robota. Kada bi robot vozio po travi, vibracije bi bile jače i sustav bi tada opažane laserske vrijednosti povezao s vegetacijom. Nakon takvog nenadziranog učenja testirana je sposobnost sustava da detektira vegetaciju. U testovima koje su proveli njihova je metoda pokazala točnost detekciranja klasifikacije veću od 99%.

2. Opći i specifični ciljevi rada

Na raspolaganju imamo modificiranu GoPro kameru kojom je moguće prikupljati podatke iz blisko-infracrvenog dijela elektromagnetskog spektra. Odlučili smo tu kameru postaviti na automobil te pomoću takvog sustava vršiti snimanje urbane vegetacije. Osim kamere, automobil je opremljen i GNSS uređajem koji služi za određivanje položaja u svakom trenutku snimanja.

Prvi korak u ovom istraživanju je snimanje urbane vegetacije gore navedenim sustavom. To se može vršiti na više načina, npr. snimanjem pojedinačnih fotografija, snimanjem niza fotografija ili snimanjem video zapisa. Mi smo se odlučili za snimanje video zapisa zato što tom metodom prikupljamo najveći broj podataka, tj. ta nam metoda daje najviše fotografija u sekundi. Nakon snimanja vrši se naknadna obrada prikupljenih podataka na računalu i upravo je na tom koraku naglasak ovog istraživanja. Cilj naknadne obrade je iz prikupljenih podataka dobiti što bolju i vjerniju klasifikaciju scene kako bi se na sceni izdvojila vegetacija. To se ostvaruje računanjem raznih vegetacijskih indeksa, a mi smo izabrali četiri koje smo u literaturi prepoznali kao najčešće. Na temelju tih vegetacijskih indeksa izvršena je binarna klasifikacija na razini piksela za svaki vegetacijski indeks zasebno kako bi se na sceni detektirala zelena vegetacija. Zatim su pomoću matrice konfuzije analizirani rezultati klasifikacije i na temelju te analize uspoređene su mogućnosti korištenih vegetacijskih indeksa za detekciju zelene vegetacije. Postupak analize i usporedbe vegetacijskih indeksa izvršen je na skupu odabranih snimki. Konačno je na temelju vegetacijskog indeksa koji je pokazao najbolje rezultate izvršena klasifikacija svih snimki te su rezultati te klasifikacije iskorišteni za izradu karte vegetacije snimljenog područja.

U tijeku je modernizacija sustava za upravljanje i nadzor resursa kao što su zrak, voda i vegetacija. Urbana vegetacija je također važan resurs čije se upravljanje i nadzor treba unaprijediti radi njenog očuvanja i razvoja. Metode opažanja i nadzora vegetacije koje su danas u primjeni su skupe te nisu prilagođene za snimanje manjih skupova vegetacije kakvi se mogu naći u urbanim sredinama. Cilj ovog rada je ispitati mogućnost korištenja amaterske digitalne kamere postavljene na automobil za opažanje, detekciju i nadzor vegetacije u urbanim sredinama. Ta bi metoda trebala pružiti jeftino i fleksibilno rješenje za opažanje vegetacije na manjim područjima.

3. Materijal i metode

Podaci za ovo istraživanje prikupljeni su snimanjem videozapisa na odabranom području Zagreba iz automobila. Ti su podaci obrađeni na način da su iz prikupljenih snimki izračunata četiri vegetacijska indeksa i na temelju tih podataka napravljena je binarna klasifikacija prikupljenih snimki. Zatim je određena točnost pojedine klasifikacije i konačno je na temelju vegetacijskog indeksa koji je kroz klasifikaciju pokazao najbolje rezultate napravljena karta vegetacije snimljenog područja. Gotovo cijeli postupak obrade je automatiziran korištenjem skripti napisanih u programskom jeziku Python koje su kreirane tijekom ovog istraživanja.

3.1. Prikupljanje podataka

Prikupljanje podataka izvršeno je pomoću modificirane GoPro kamere. Kamera i drugi uređaji instalirani su na automobil te je snimljen georeferencirani videozapis. Svi podaci obrađeni u istraživanju rezultat su jednog snimanja.

3.1.1. Oprema korištena za prikupljanje podataka

Za prikupljanje podataka korištena je GoPro Hero 4 Black digitalna kamera (slika 1), Garmin GLO GNSS prijamnik (slika 2) i Samsung Galaxy Tab Active tablet (slika 3).



Slika 1. GoPro Hero 4 Black kamera



Slika 2. Garmin GLO GNSS prijamnik



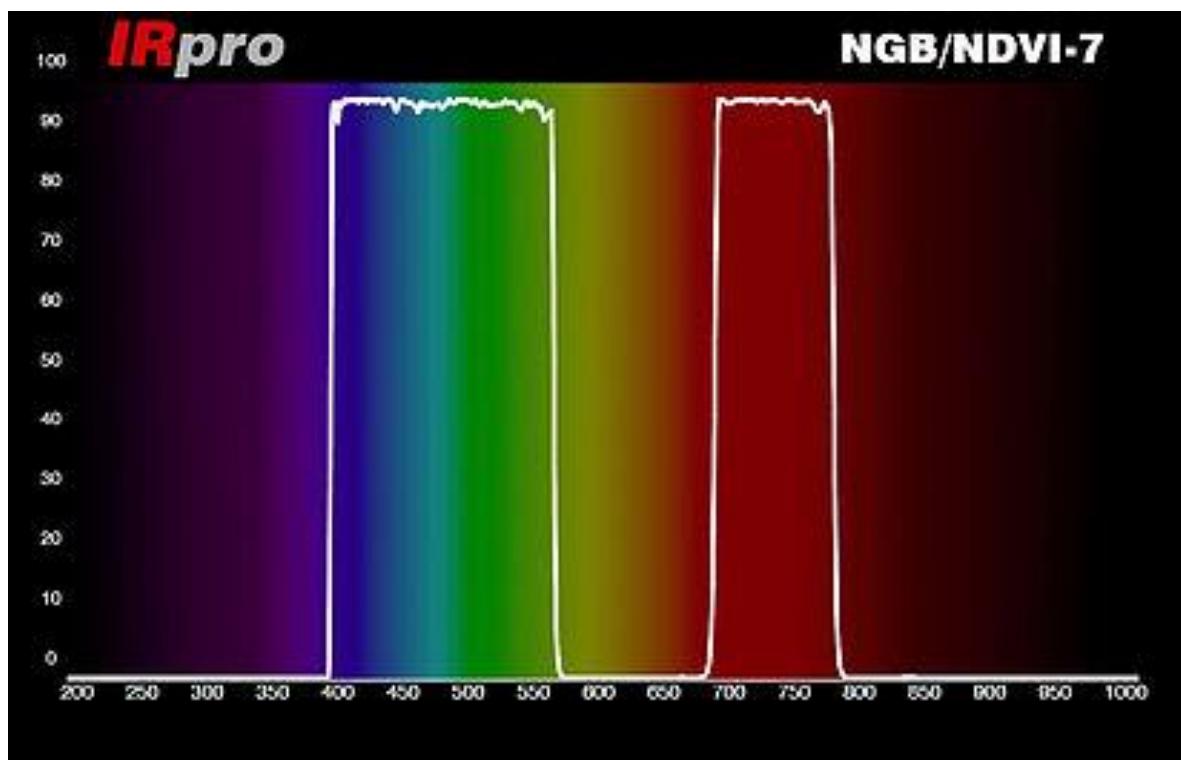
Slika 3. Samsung Galaxy Active tablet

GoPro Hero 4 Black je amaterska digitalna kamera tvrtke GoPro, namijenjena širokoj lepezi korisnika i trenutno je najpopularnija akcijska kamera u svijetu (URL 1). Težinom od samo 89g i malim dimenzijama, pogodna je za korištenje s raznim platformama, pa se tako može montirati i na kacigu, bespilotnu letjelicu ili automobil. Kamera može snimati video zapise u rezoluciji do 3840x2160 piksela (4K rezolucija), opremljena je bluetooth i Wi-Fi tehnologijama za bežično povezivanje te se prostor za pohranu podataka može proširiti korištenjem microSD kartice. Potpune specifikacije kamere prikazane su u tablici 1.

Tablica 1. Tehničke specifikacije GoPro Hero 4 Black Kamere (URL 2; URL 3)

Težina	89 g
Visina	71,3 mm
Širina	71,1 mm
Dubina	39,0 mm
Vrsta senzora	CMOS
Maksimalna rezolucija videa	3840x2160
Broj kadrova po sekundi (fps) pri maksimalnoj rezoluciji	30
Format video zapisa	H.264, mp4
Maksimalna rezolucija fotografije	4000x3000 (12MP)
Format fotografije	JPEG
Povezivost	Mini USB, Micro HDMI, bluetooth, Wi-Fi
Cijena	529,99 € ≈ 4000 kn

Kamera je modificirana tako da je standardna leća kamere zamijenjena s NDVI-7 lećom. NDVI-7 leća je proizvod tvrtke IRpro koja se bavi proizvodnjom i modificiranjem opreme za fotografiju i snimanje. Leća je opremljena posebnim NGB (eng. Near-Infrared, Green, Blue) filterom koji blokira crvenu svjetlost, a na mjestu crvenog kanala prikuplja podatke o blisko-infracrvenoj svjetlosti (slika 4). Instaliranjem te leće dobije se modificirana kamera koja prikuplja plavi, zeleni i blisko-infracrveni kanal. NDVI-7 leća se može koristiti za modificiranje GoPro, UAV DJI Inspire 1 te Phantom 3 kamera. Cijena leće iznosi oko \$ 300 (URL 4).



Slika 4. Spektralne karakteristike NDVI-7 leće (izvor: URL 4)

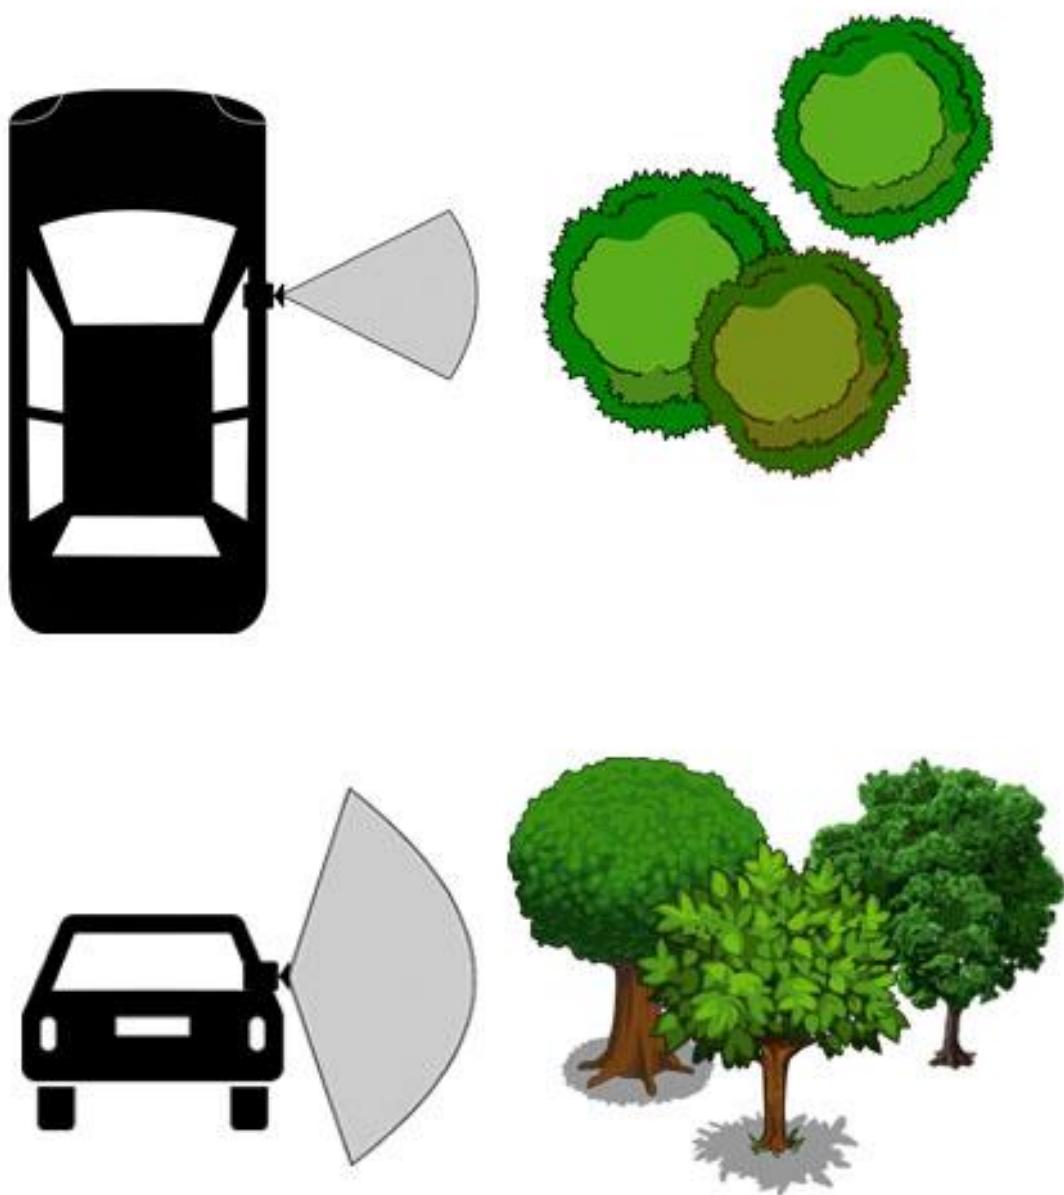
Garmin GLO je GNSS prijamnik tvrtke Garmin, namijenjen poboljšanom pozicioniranju pomoću mobilnih uređaja. Osigurava točnost određivanja položaja od 3m, a opažanja vrši 10 puta u sekundi. Prijamnik je opremljen bluetooth tehnologijom pomoću koje se povezuje na mobilni uređaj, a podržava GPS i GLONASS satelite. Potpune specifikacije prijamnika prikazane su u tablici 2.

Tablica 2. Specifikacije Garmin GLO GNSS prijamnika (izvor: URL 5)

Težina	60,1 g
Visina	17,8 mm
Širina	41,9 mm
Dubina	77,2 mm
Podržani sateliti	GPS, GLONASS
Podrška za WAAS	Da
Frekvencija opažanja	10 Hz
Točnost	3 m
Trajanje baterije	12 h
Cijena	99 € ≈ 750 kn

3.1.2. Snimanje georeferenciranog video zapisa

Za potrebe snimanja postavili smo kameru na osobni automobil. Kameru je moguće postaviti tako da njeno područje zahvata zahvaća područje ispred automobila i da se snima u smjeru kretanja automobila te se može postaviti bočno na automobil i snimati okomito na smjer kretanja automobila. Mi smo se odlučili za drugu metodu zato što se naš objekt snimanja, urbana vegetacija, uglavnom pruža uz gradske prometnice (slika 5). Na taj smo način izbjegli prostornu neodređenost koja je moguća pri uzdužnom snimanju, gdje se može dogoditi da snimka zahvaća vegetaciju s obje strane prometnice te se automatskom metodom ne može odrediti s koje se strane vegetacija nalazi. Konačno, bočnim je snimanjem smanjena redundancija prikupljenih podataka koja se može pojaviti pri uzdužnom snimanju ako se niz prometnicu nalazi veće stablo koje je vidljivo i na snimkama koje prethode toj lokaciji.

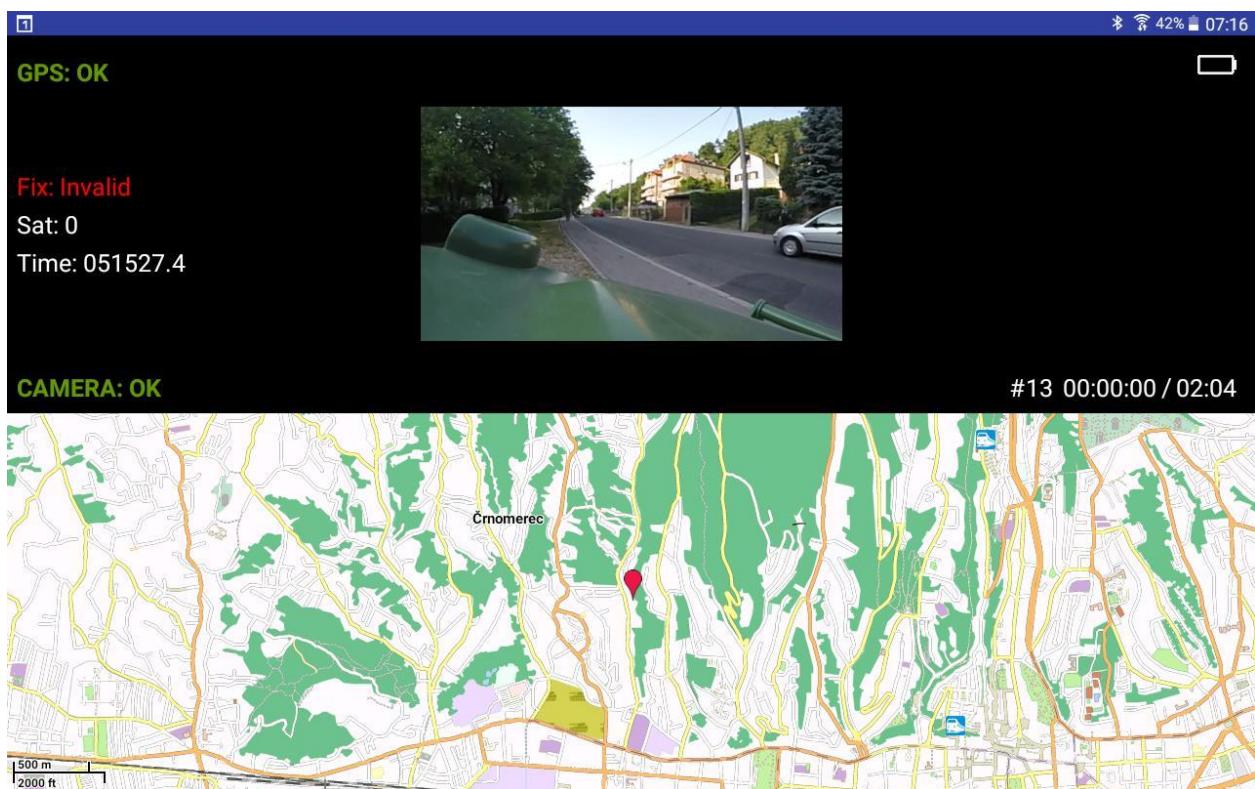


Slika 5. Ilustracija opažanja vegetacije kamerom postavljenom bočno na automobil

Kako bi snimanje georeferenciranog video zapisa bilo moguće, trebalo je upariti kameru i GNSS uređaj. Za to smo koristili PiP VideoKit mobilnu aplikaciju za android uređaje koju smo prethodno instalirali na tablet.

Pip VideoKit je besplatna mobilna aplikacija tvrtke Promet i prostor d.o.o. i dostupna je za preuzimanje na *Google Play* servisu. Aplikacija sinkronizira podatke o položaju koji se prikupljaju GNSS prijamnikom i videozapis digitalne kamere te tako omogućuje

snimanje georeferenciranog videozapisa u realnom vremenu. Od ostalih značajki pruža još i stvaranje, uređivanje i organizaciju projekata snimanja, korištenje offline karte tijekom snimanja (slika 6), preklapanje slojeva podataka preko karte, dodavanje bilješki za određenu lokaciju te mogućnost izbora između vanjskog ili ugrađenog GNSS prijamnika.



Slika 6. Prikaz sučelja PiP VideoKit mobilne aplikacije

Koristeći aplikaciju, povezali smo kameru i GNSS prijamnik s tabletom. Cjelokupno povezivanje ovih uređaja izvršeno je putem bežične tehnologije tako što smo kameru povezali koristeći Wi-Fi tehnologiju, a GNSS prijamnik koristeći bluetooth tehnologiju. To je uvelike olakšalo instalaciju sustava na osobni automobil.

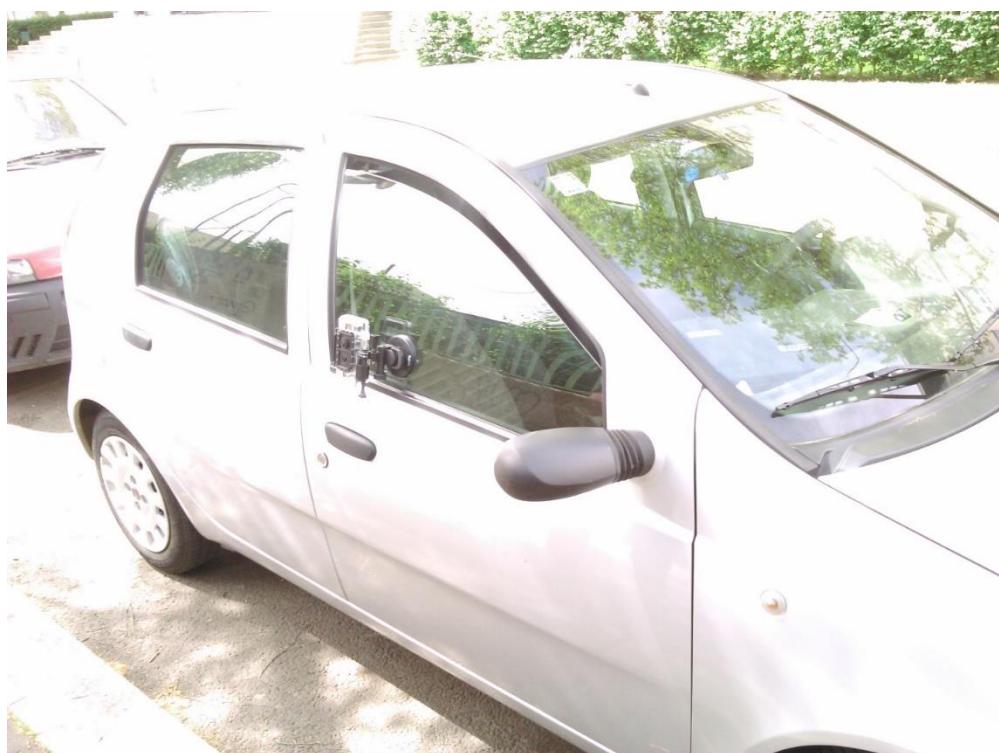
Snimanje je izvršeno u nedjelju 17.04.2016. između 12 i 14 sati. Taj je termin odabran zbog pretpostavke da je, s obzirom da je snimanje vršeno u centru Zagreba, tada najmanji broj automobila na cestama. To nam je omogućilo da se što je više moguće

vozimo konstantnom brzinom od oko 60 km/h i da smanjimo mogućnost da snimljena scena bude zaklonjena drugim vozilom. Tijekom snimanja vremenski uvjeti su bili povoljni (sunčano i povremena naoblaka). Kamera je postavljena u plastično kućište koje je kupljeno kod ovlaštenog prodavača GoPro opreme te je prianjajućim mehanizmom pričvršćena na vanjsku stranu suvozačevih vrata (slike 7 i 8). Osim modificirane, za snimanje je korištena i nemodificirana GoPro kamera koja snima RGB snimke, ali podaci prikupljeni tom kamerom nisu obrađeni u ovom istraživanju, već su korišteni kao orijentir za proučavanje snimljenih scena. GNSS uređaj je postavljen s vanjske strane auta kako bi imao što je više moguće otvoren horizont i nesmetano primao signale satelita (slika 9). Videozapis je sniman rezolucijom od 1920x1080 piksela frekvencijom od 25 zapisa u sekundi, a snimanjem su obuhvaćene sljedeće ulice (slika 10):

- *Ulica Andrije Kačića Miošića, u smjeru sjevera*
- *Ulica Vjekoslava Klaića, u smjeru zapada*
- *Hochmanova ulica, u smjeru juga*
- *Jukićeva ulica, u smjeru istoka*
- *Savska cesta, u smjeru juga*
- *Ulica Grada Vukovara, u smjeru istoka (do križanja s Heinzlovom ulicom)*
- *Ulica Grada Vukovara, u smjeru zapada*
- *Ulica Florijana Andrašeca, u smjeru sjevera*
- *Brozova ulica, u smjeru sjevera*
- *Adžijina ulica, u smjeru sjevera*
- *Ulica Izidora Kršnjavog, u smjeru istoka*
- *Ulica Andrije Kačića Miošića, u smjeru sjevera*



Slika 7. Prikaz postavljanja kamere na automobil



Slika 8. Prikaz postavljanja kamere na automobil



Slika 9. Prikaz postavljanja GNSS uređaja na automobil



Slika 10. Prikaz trase snimanja (žuta boja)

3.2. Obrada video zapisa pomoću programskog jezika Python

Rezultat snimanja je video zapis u MP4 formatu pohranjen u memoriju kamere te zapisnik položaja i sinkronizacijski zapisnik pohranjeni u memoriju tableta. Nakon prebacivanja tih datoteka na računalo, pokrenuta je skripta koja spajanjem tih datoteka stvara georeferencirani video zapis.

Georeferencirani video zapis smo dalje obradili kako bi iz podataka koji su nam dostupni izvršili klasifikaciju svake snimljene scene i odredili količinu vegetacije na njima. Obradu smo automatizirali tako što smo napisali skriptu u programskom jeziku Python koja vrši obradu video zapisa. Python je dinamički pisani programski jezik namijenjen za opću primjenu. Nastao je ranih 1990. godina na CWI-u (the Centrum voor Wiskunde and Informatica) kao jezik namijenjen za poduku. Danas je izrazito popularan zbog svoje jednostavnosti i fleksibilnosti. Korisniku pruža mogućnost korištenja objektno orijentiranog ili proceduralnog pristupa, a dostupan je za sve veće operativne sustave kao što su Windows, Linux/Unix, Mac OS X i drugi. Osim standardnih biblioteka, Python sadrži i veliki broj modula treće strane (eng. third party modules) kojima pokriva rješavanje skoro svih zadataka. Također ga je moguće povezati s drugim programskim jezicima kao što su C, C++ ili Java ako za to postoji potreba (Pérez et al. 2011; URL 6).

Skripta za obradu video zapisa temelji se na upotrebi OpenCV biblioteke. Prvi korak je učitavanje video zapisa u skriptu nakon čega se zasebno uređuje svaki kadar iz video zapisa. Nakon učitavanja kadra, razdvajaju se blisko-infracrveni, plavi i zeleni kanal koji se zatim koriste za računanje vegetacijskih indeksa. Nakon što su izračunati vegetacijski indeksi, metodom piksel po piksel se vrši klasifikacija snimljene scene na temelju vrijednosti vegetacijskog indeksa za svaki pojedini piksel kako bi se definiralo

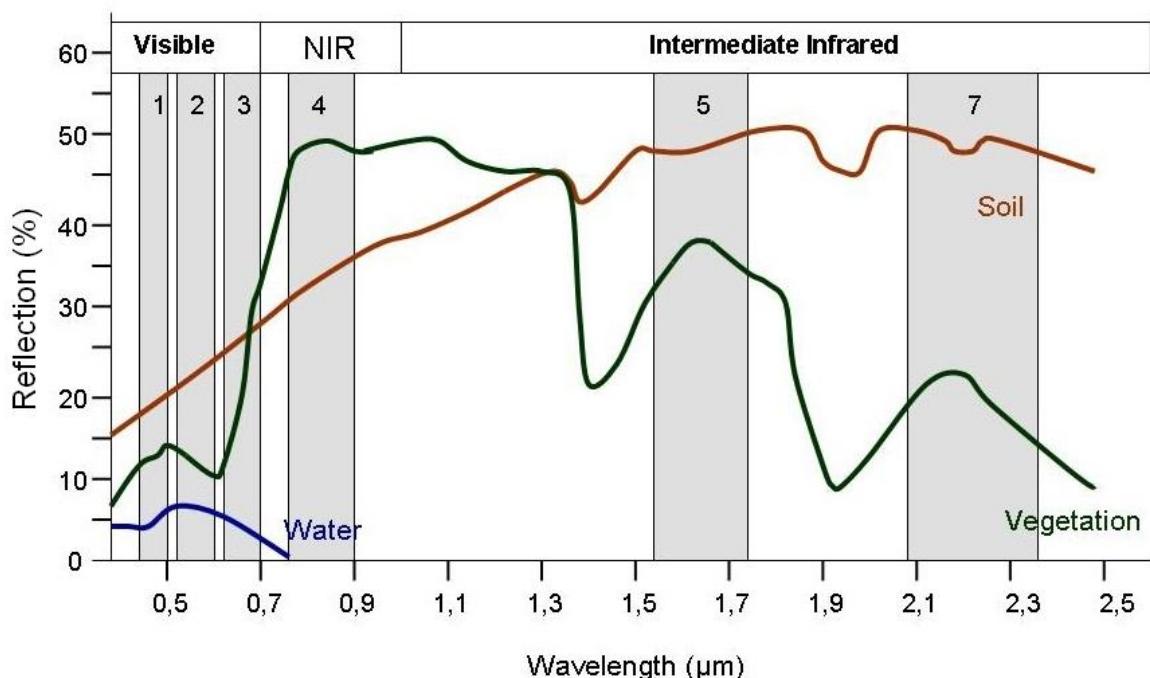
koji pikseli na sceni predstavljaju vegetaciju. OpenCV (eng. Open Source Computer Vision Library) je programska biblioteka (eng. Software library) otvorenog koda namijenjena rješavanju zadataka iz područja računalnog vida i strojnog učenja. Biblioteka sadrži više od 2500 optimiziranih algoritama koji uključuju osnovne i napredne algoritme. Ti se algoritmi mogu koristiti za prepoznavanje lica, identificiranje objekata, klasificiranje ljudskih radnji u video zapisima, praćenje pokretnih objekata, ekstrahiranje trodimenzionalnih modela objekata, izradu trodimenzionalnih oblaka točaka iz snimki stereokamera i brojne druge zadatke pri obradi video zapisa i fotografija. Primjene OpenCV biblioteke tako imaju široki raspon od spajanja fotografija kako bi se dobio pregled ulice, detektiranja provale pomoću sigurnosne kamere u Izraelu, nadzora rudarske opreme u Kini, pomaganja navigaciji i operativnosti robota u Willow Garageu, detekcije utapanja u bazenima u Europi, inspekciji oznaka na proizvodima u tvornicama diljem svijeta do brzog prepoznavanja lica u Japanu. OpenCV je podržan na Windows, Linux, Android i Mac OS X operativnim sustavima, a može se koristiti s C, C++, Python, Java i MATLAB programskim jezicima (URL 7).

3.3. Računanje vegetacijskih indeksa

Još od lansiranja prvog satelita za istraživanje Zemlje 1972. godine, uloženi su veliki napori kako bi se ustanovila veza između radiometrijskog odziva i vegetacijskog pokrova. NASA-in program "Monitoring the Vernal Advancement and Retrogradation of Natural Vegetation" jedan je od prvih u tom području, a kasniji LACIE (Large Area Crop Inventory Experiment) program je dozvolio da se u tom području dosegne još dalje. Te su istraživačke inicijative pokazale da je korištenje crvenog i blisko-

infracrvenog kanala multispektralnih senzora koji se koriste na satelitima izrazito pogodno za proučavanje vegetacije (Bannari et al. 1995).

Razni vegetacijski pokrovi mogu se razlikovati prema njihovom jedinstvenom ponašanju u vidu spektralnog odziva u odnosu na ostale elemente na zemljinoj površini. Klorofil apsorbira vidljivu svjetlost u crvenom dijelu elektromagnetskog spektra (valne duljine 630 – 690 nm), dok se blisko-infracrvena svjetlost (valne duljine 760 – 900 nm) snažno reflektira od staničnih struktura listova. Kada proučavamo spektralnu krivulju vegetacije (slika 11), devijacija između refleksije u crvenom i blisko-infracrvenom dijelu spektra predstavlja varijablu osjetljivu na prisustvo zelene vegetacije. Spektralni odziv vegetacije u crvenom dijelu spektra visoko je koreliran sa koncentracijom klorofila u promatranoj vegetaciji, dok je spektralni odziv u blisko-infracrvenom području ovisan o LAI-u (Leaf Area Index) i gustoći zelene vegetacije. Kombinacija tih dvaju spektralnih domena omogućuje razlikovanje vegetacije od ostalih elemenata i određivanje fotosintetski aktivne biomase preko gustoće vegetacijskog pokrova (Bannari et al. 1995; Myneni et al. 1995).



Slika 11. Spektralne krivulje vode, tla i vegetacije (izvor: URL 8)

Indeks je broj koji procjenjuje intenzitet neke pojave koja je suviše kompleksna da bi se mogla raščlaniti na poznate parametre. Iako je u dobro kontroliranom i dokumentiranom okruženju moguće odrediti koliko pojedini faktori zapravo utječu na pojavu koja se proučava, takvo što je teško postići u praktičnoj primjeni. Vegetacijski indeksi su kvantitativne mjere kojima se ocjenjuje stanje vegetacije. Oni pokazuju bolji stupanj osjetljivosti u odnosu na zasebne spektralne kanale pri detekciji biomasa. Naglasak se kod vegetacijskih indeksa stavlja na njihovu korisnost pri interpretaciji snimki daljinskih i drugih istraživanja gdje predstavljaju metodu za detekciju promjena korištenja zemljišta, procjenu gustoće vegetacijskog pokriva te razlikovanje i procjenu usjeva. U području tematskog kartiranja vegetacijski se indeksi uglavnom koriste za poboljšanje klasifikacije (Bannari et al. 1995).

R. L. Pearson i L.D. Miller su pioniri u povijesti vegetacijskih indeksa. Oni su 1972. razvili prve vegetacijske indekse u obliku omjera: RVI (eng. Ratio Vegetation Index) i VIN (eng. Vegetation Index Number).

$$RVI = \frac{R}{NIR}$$

$$VIN = \frac{NIR}{R}$$

gdje R predstavlja srednju vrijednost refleksije za crveni, a NIR srednju vrijednost refleksije za blisko-infracrveni kanal. Ti indeksi pojačavaju kontrast između zemlje i vegetacije, umanjuju efekte uzrokovane uvjetima osvjetljenja, ali su osjetljivi na optička svojstva tla (Bannari et al. 1995; Pearson & Miller 1972).

Također treba spomenuti i J. W. Rouse i njene suradnike koji su 1973. razvili danas najpoznatiji vegetacijski indeks NDVI (eng. Normalized Difference Vegetation Index).

$$NDVI = \frac{NIR - R}{NIR + R}$$

NDVI je osjetljiv na prisustvo zelene vegetacije, omogućuje praćenje poljoprivrednih usjeva i oborina u polu-sušnim predjelima, a danas se u svijetu koristi za proučavanje stanja vegetacije. Uspješnost NDVI-a za opisivanje promjena kod vegetacije unatoč utjecajima atmosfere i radiometrijske degradacije crvenog i blisko-infracrvenog kanala, krije se u normalizaciji koju on pruža (Bannari et al. 1995; Myneni et al. 1995).

S obzirom da smo za prikupljanje podataka koristili modificiranu digitalnu kameru i da na raspolaganju imamo samo plavi, zeleni i blisko-infracrveni kanal, nismo u mogućnosti koristiti NDVI ili neke druge vegetacijske indekse čije računanje zahtjeva

korištenje crvenog kanala. U skladu s tim, u literaturi su prepoznata četiri najčešće korištena vegetacijska indeksa koji ne zahitjevaju korištenje crvenog kanala:

- BNDVI (eng. Blue NDVI)
- GNDVI (eng. Green NDVI)
- BWDRVI (eng. Blue-wide dynamic range vegetation index)
- GBNDVI (eng. Green-Blue NDVI)

Svi se ovi indeksi temelje na NDVI-u u tome što su normalizirani. Također svi imaju raspon od -1 do 1, a računaju se prema sljedećim formulama:

$$\text{BNDVI} = \frac{\text{NIR} - \text{B}}{\text{NIR} + \text{B}}$$

$$\text{GNDVI} = \frac{\text{NIR} - \text{G}}{\text{NIR} + \text{G}}$$

$$\text{GBNDVI} = \frac{\text{NIR} - (\text{G} + \text{B})}{\text{NIR} + (\text{G} + \text{B})}$$

$$\text{BWDRVI} = \frac{0.1 \times \text{NIR} - \text{R}}{0.1 \times \text{NIR} + \text{R}}$$

BNDVI, GNDVI i GBNDVI korišteni su i u istraživanju (Wang et al. 2007), gdje su proučene veze između njih. Na slici 7 prikazani su koeficijenti korelacija među njima izračunati u sklopu tog istraživanja. Vidljivo je da je od spomenutih indeksa NDVI-u najsličniji GNDVI kojeg slijede GBNDVI te BNDVI. Ako se gleda međusobni odnos, najsličniji su GNDVI i GBNDVI, dok je najmanja korelacija između BNDVI-a i GBNDVI-a.

VNDVI	BNDVI	GNDVI	NDVI	GBNDVI	RBNDVI	GRNDVI	PNDVI
BNDVI	1.000000	0.981412	0.986607	0.985854	0.991225	0.976548	0.976641
GNDVI	0.981412	1.000000	0.989467	0.998583	0.994491	0.997938	0.996915
NDVI	0.986607	0.989467	1.000000	0.989107	0.996799	0.991181	0.987807
GBNDVI	0.985854	0.998583	0.989107	1.000000	0.996643	0.997488	0.998166
RBNDVI	0.991225	0.994491	0.996799	0.996643	1.000000	0.995384	0.994833
GRNDVI	0.976548	0.997938	0.991181	0.997488	0.995384	1.000000	0.999257
PNDVI	0.976641	0.996915	0.987807	0.998166	0.994833	0.999257	1.000000

Slika 12. Koeficijenti korelacije između različitih vegetacijskih indeksa (Wang et al. 2007)

Vegetacijski su indeksi računati pomoću skripte napisane u programskom jeziku Python. Prvo su računati vegetacijski indeksi na snimkama koje su korištene za uzorkovanje, a nakon toga je vegetacijski indeks koji je odabran kao najbolji izračunat i za ostale snimke.

3.4. Klasifikacija snimki metodom binarne klasifikacije

Nakon računanja vegetacijskih indeksa, snimke je na temelju dobivenih vrijednosti potrebno klasificirati kako bi se objekti na snimci razdijelili u zasebne klase. Kako je cilj ovog istraživanja detekcija vegetacije, za klasifikaciju su korištene samo dvije klase. U jednu su klasu svrstani svi objekti na sceni koji predstavljaju zelenu vegetaciju dok su ostali objekti svrstani u klasu nevegetacije.

Prvi i najvažniji korak svake klasifikacije je određivanje granica pojedinih klasa. Iako se u literaturi mogu pronaći brojne informacije o tome koje vrijednosti vegetacijskih indeksa ukazuju na vegetaciju, one se većinom odnose na NDVI i na snimke prikupljene daljinskim istraživanjima, tj. multispektralnim senzorima visoke kvalitete. Kako su u ovom istraživanju korišteni drugi vegetacijski indeksi za koje su podaci prikupljeni amaterskom kamerom, granice klasa su određene za svaki vegetacijski indeks zasebno na temelju uzorkovanja.

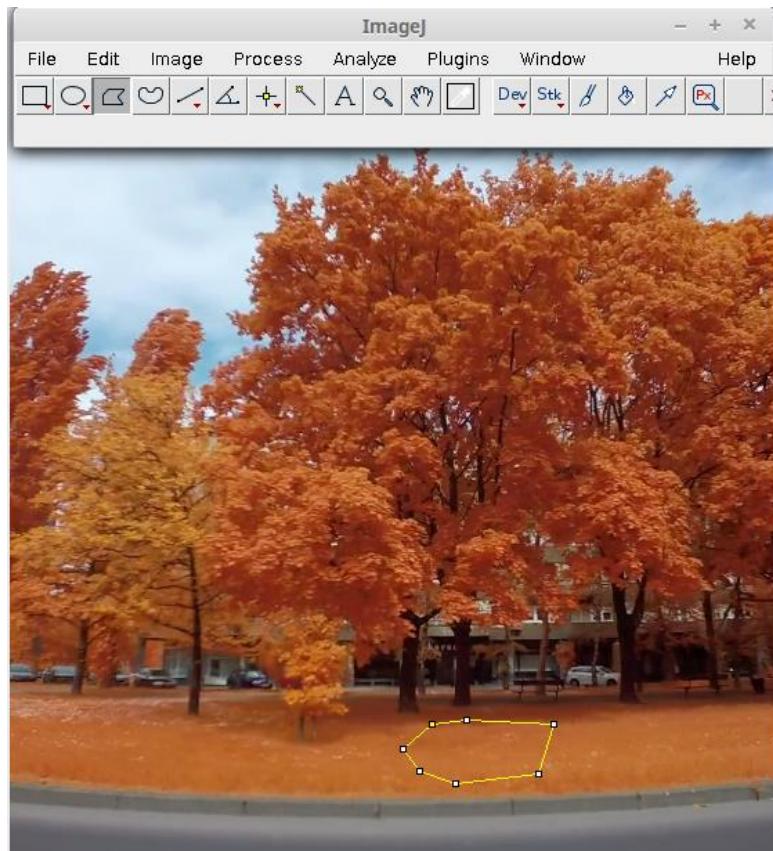
3.4.1. Uzorkovanje

Za prikupljanje uzoraka korišten je besplatni program ImageJ. Program je zasnovan na Java programskom jeziku, a dostupan je za Windows, OS X i Linux operativne sustave. Omogućuje prikazivanje, uređivanje, analizu, procesuiranje, pohranjivanje i ispis slika. Podržava brojne slikovne formate kao što su TIFF, GIF, JPEG, BMP, DICOM, FITS i „raw“. Podržava „stackove“, tj. serije slika koje dijele zajednički prozor. Također pruža mogućnost statističke obrade slika kao što su računanje minimalne, maksimalne i srednje vrijednosti piksela te računanje i prikaz histograma koji prikazuje razdiobu pojedinih vrijednosti piksela na slici.

Prije uzorkovanja izabrano je 8 scena na kojima će se vršiti uzorkovanje. Za te su scene zatim izračunati svi vegetacijski indeksi i pohranjeni u obliku slika u TIFF formatu što je ukupno rezultiralo s 32 slike. Kako u takvu slikovnu datoteku nije moguće pohraniti negativne vrijednosti, a također je poželjno da vrijednosti budu cijeli brojevi, izračunate vrijednosti vegetacijskih indeksa su pomnožene sa 100 i uvećane za 100. Tim se postupkom raspon vrijednosti vegetacijskih indeksa promijenio s -1 do 1 na 0 do 200, a vrijednosti vegetacijskih indeksa sačuvane su na dvije decimale.

Slikovne datoteke koje sadrže vrijednosti vegetacijskih indeksa učitane su u ImageJ gdje je za svaku scenu stvorena serija slika od četiri slike s vegetacijskim indeksima i jedne izvorne snimke. Uzorci su uzimani pomoću alata za odabir poligona (slika 8), a kao podloga za odabir uzoraka korištena je izvorna snimka. Prednost korištenja serije slika u ovom postupku je to što je područje odabранo na jednoj slici odabran i na svim drugim slikama te se može vršiti statistička analiza istog područja na svim snimkama. Nakon što je uzorak odabran, koristi se funkcija za računanje histograma za odabranu područje, za svaku sliku posebno. Te su vrijednosti pohranjene i kasnije iskorištene za računanje kumulativnog histograma svih uzoraka za pojedini vegetacijski indeks.

Na svakoj su snimci odabrana 3 uzorka što ukupno čini 24 uzorka za svaki vegetacijski indeks.



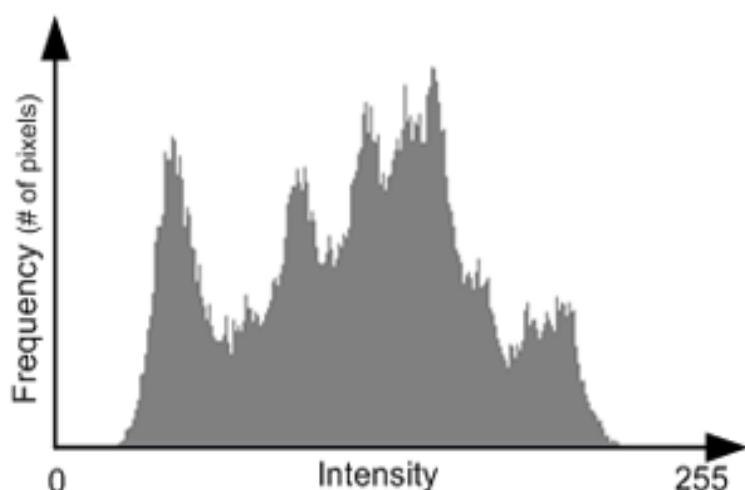
Slika 13. Primjer uzimanja uzorka u programu ImageJ

3.4.2. Statistička obrada uzorka i određivanje granica klasa

Vrijednosti svih piksela obuhvaćenih uzorkovanjem objedinjene su u jedan skup, a isti je postupak ponovljen za svaki vegetacijski indeks. Tako smo za svaku moguću vrijednost vegetacijskog indeksa dobili frekvenciju koja nam govori koliko se puta u svim uzorcima pojavljuje piksel s tom vrijednošću. Za svaki je vegetacijski indeks obrađeno ukupno 428 488 piksela prikupljenih u 38 uzoraka. Prije daljnje obrade raspon vegetacijskih indeksa, a tako i vrijednosti piksela korištene u daljinjoj obradi, obratnim su postupkom nego ranije vraćene na interval od -1 do 1. Nad tim su podacima izvršene osnovne statističke analize u obliku računanja i iscrtavanja

histograma, računanja minimalne i maksimalne vrijednosti te medijana i standardnog odstupanja.

Histogram je grafički prikaz distribucije vrijednosti u određenom skupu podataka. U fotografiji te vrijednosti predstavljaju tonove, a u 8-bitnom prostoru boja svaki kanal može imati jednu od 256 (0 – 255) mogućih vrijednosti. Horizontalna os histograma prikazuje totalni raspon vrijednosti piksela u slici, a vertikalna os prikazuje broj piksela koji imaju određenu vrijednost (slika 14). Konvencionalno, vrijednosti koje se nalaze bliže lijevoj strani histograma predstavljaju tamnije tonove (crna boja), dok one bliže desnoj strani predstavljaju svjetlijе tonove (bijela boja). Ukratko, histogram nam može mnogo reći o strukturi informacija koje određena fotografija sadrži (URL 9).



Slika 14. Primjer histograma (izvor: URL 10)

Medijan je vrijednost unutar nekog skupa podataka za koju vrijedi da je 50% podataka manje od ili jednako toj vrijednosti i da je 50% podataka je veće od ili jednako njoj. Tako će ako imamo skup vrijednosti x koje su uređene tako da je:

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$$

medijan biti vrijednost m :

$$m = x_{(k)} \quad \text{ako je } n=2k-1$$

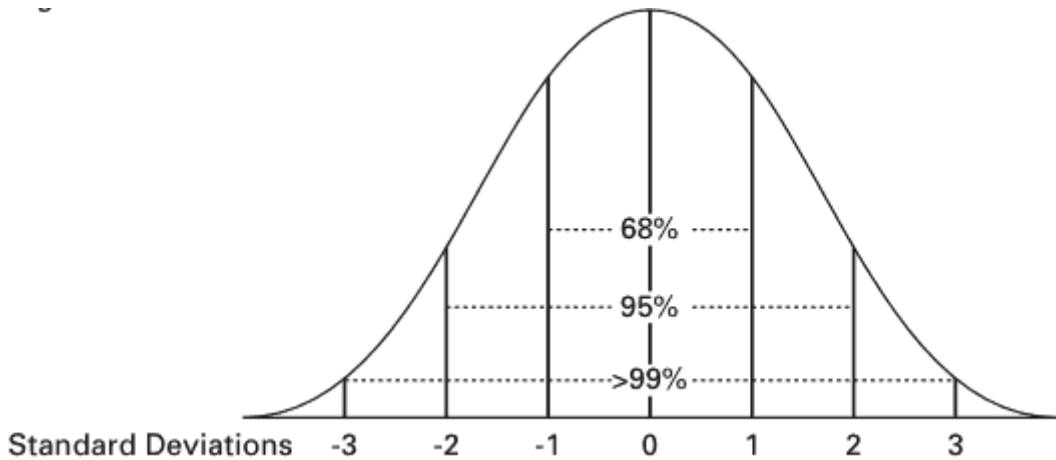
$$m = \frac{1}{2}(x_{(k)} + x_{(k+1)}) \quad \text{ako je } n=2k$$

Medijan se često koristi kada su osim grupiranih prisutni i neki ekstremni rezultati pa aritmetička sredina ne daje pravu sliku obrađenog skupa podataka (Huzak & Slijepčević n.d.; Mladinov n.d.).

Standardno odstupanje je mjera raspršenja vrijednosti unutar nekog skupa podataka. Računa se za svaku vrijednost u skupu kao:

$$\sigma = \sqrt{\frac{\sum (x - \bar{x})^2}{n - 1}}$$

gdje je σ oznaka za standardno odstupanje, \bar{x} aritmetička sredina svih vrijednosti unutar skupa, n broj vrijednosti u skupu te x vrijednost u skupu podataka (URL 11). Ako su podaci u skupu distribuirani prema normalnoj razdiobi, za taj se skup pomoću standardnog odstupanja mogu odrediti intervali pouzdanosti. S time se procjenjuje točnost odabranog intervala unutar skupa podataka koja je narušena utjecajem slučajnih pogrešaka koje se javljaju prilikom uzorkovanja. Slika 15 prikazuje primjer normalne razdiobe podataka i tri najčešće korištena intervala pouzdanosti s njima pripadnim vjerojatnostima (URL 12).



Slika 15. Prikaz normalne distribucije i intervala pouzdanosti (izvor: URL 13)

Cijela je statistička obrada uzorka izvršena pomoću skripte u programskom jeziku Python, a izračunate veličine pohranjene su u CSV formatu. Pod pretpostavkom da su vrijednosti koje na sceni predstavljaju zelenu vegetaciju, tj. vrijednosti unutar skupa podataka prikupljenog uzorkovanjem distribuirane prema normalnoj razdiobi, uzet je interval pouzdanosti od $\pm 3\sigma$ za određivanje granica klase vegetacija. Kao srednja vrijednost klase korištena je aritmetička sredina, donja je granica dobivena tako da je od aritmetičke sredine oduzet iznos 3σ , a gornja je granica dobivena dodavanjem iznosa 3σ aritmetičkoj sredini. Klasu nevegetacije na sceni tako predstavljaju sve vrijednosti koje se ne nalaze unutar granica klase vegetacija. Postupak statističke obrade uzorka i određivanja granica klasa ponovljen je za svaki od četiri korištena vegetacijska indeksa.

3.4.3. Klasifikacija snimki

Za klasifikaciju snimki korištena je binarna klasifikacija. Ona se uglavnom vodi kao nadzirana metoda klasifikacije zato što se u najvećem broju slučajeva granice klase definiraju prije izvođenja same klasifikacije. Naziv binarna potječe od činjenice da se ova metoda klasifikacije koristi onda kada podatke želimo definirati u dvije klase, a

čestu primjenu nalazi u medicinskoj dijagnozi kada je pacijente potrebno klasificirati prema rezultatima nekih testova na zdrave i bolesne. Binarna se klasifikacija također koristi u području strojnog učenja gdje se na velikom broju uzoraka pokušava „istrenirati“ algoritam koji će detektirati određenu pojavu u skupu podataka (URL 14).

Klasifikacija je vršena na razini piksela, odnosno metodom piksel po piksel. Ulazni podaci za klasifikaciju su slikovna datoteka u TIFF formatu koja sadrži izračunate vegetacijske indekse i prethodno izračunate vrijednosti granica klasa. Kako su slikovne matrice snimaka dimenzija 1920x1080 piksela, svaka snimka sadrži ukupno 2 073 600 piksela. Metoda piksel po piksel znači da klasifikator vrijednost svakog piksela uspoređuje s definiranim granicama klasa i sukladno tome svrstava taj piksel u odgovarajuću klasu. Rezultat klasifikacije je također slikovna datoteka koja na mjestu svakog piksela sadrži samo jednu od dvije moguće vrijednosti. Pikseli s vrijednošću 1 na klasificiranoj snimci predstavljaju vegetaciju, dok pikseli koji predstavljaju nevegetaciju imaju vrijednost 0. Proces klasifikacije također je automatiziran i izvršen pomoću skripte u programskom jeziku Python te je ponovljen za svaki vegetacijski indeks s njemu pripadajućim granicama klasa.

3.5. Analiza rezultata klasifikacije pomoću matrice konfuzije

Analiza rezultata klasifikacije izvršena je na pet različitih scena, a pri njihovom se odabiru pazilo da te scene nisu one korištene za uzorkovanje kako bi analiza bila neovisna. Također se zbog promjenjivih uvjeta prilikom snimanja pazilo da odabrane snimke reprezentativno predstavljaju te uvjete. Tako su izabrane dvije scene snimljene za vrijeme naoblake, dvije scene snimljene tako da se sunce nalazi ispred kamere i jedna scena snimljena tako da se sunce nalazi iza kamere. Za ocjenu točnosti klasifikacije korištena je matrica konfuzije, no kako ona uz rezultat klasifikacije

zahtjeva i referentne podatke, prvo je trebalo te podatke proizvesti. Referentni su podaci dobiveni ručnom klasifikacijom snimki korištenih za ocjenu točnosti. Ručna je klasifikacija izvršena pomoću slobodnog programa za obradu slika GIMP.

GIMP (eng. GNU Image Manipulation Program) je slobodni program za obradu slika. Program ima brojne mogućnosti, pa se tako može koristiti kao jednostavan program za crtanje, program za profesionalno retuširanje, program za konvertiranje formata slika i dr. Također sadrži brojne alate među kojima treba istaknuti one za odabiranje elemenata na slici u obliku četverokuta, zaobljenog četverokuta, elipse te fuzzy i slobodni odabir. GIMP je razvijen na UNIX platformi, ali je u istom obliku dostupan i za Windows i OS X operativne sustave (URL 15).

Za ovaj su postupak korištene neobrađene snimke, pa je prvi korak je učitavanje takve snimke u GIMP. Zatim je korištenjem alata za odabir na slici odabrana vegetacija. Za odabir su uglavnom korišteni fuzzy i alat za slobodni odabir. Nakon odabira vegetacije pikselima koji se nalaze unutar odabranog područja je pomoću alata za manipuliranje vrijednostima piksela postavljena vrijednost 1. Ostalim pikselima na slici koji predstavljaju nevegetaciju dodijeljena je vrijednost 0 kako bi raspon vrijednosti referentnih podataka odgovarao rasponu vrijednosti podataka nakon klasifikacije. Konačno, referentne su slike pohranjene u TIFF formatu kako bi se dalje mogle koristiti u skripti za ocjenu točnosti klasifikacije.

Matrica konfuzije je alat koji se često koristi za ocjenu točnosti binarne klasifikacije. Može se koristiti i za druge metode klasifikacije te će u tom slučaju umjesto 2x2 matrica biti formata $m \times m$, gdje m predstavlja broj klasa. Općenito, matrica konfuzije nam govori koliko se rezultati dobiveni klasifikacijom razlikuju od stvarnih ili referentnih podataka. Kako se broj ispravno klasificiranih podataka nalazi na dijagonali matrice,

klasifikacija je točnija što je determinanta matrice (zbroj svih vrijednosti na dijagonali matrice) veća u odnosu na elemente van dijagonale.

		Predviđanje	
		Nema promjene	Promjena
Razred uzorka	Nema promjene	TN	FP
	Promjena	FN	TP

Slika 16. Primjer matrice konfuzije (izvor: Oreški 2014)

Na slici 16 koja prikazuje primjer matrice konfuzije može se vidjeti da se ona sastoji od sljedećih elemenata:

- TN (eng. True Negative) – broj ispravno klasificiranih negativnih rezultata
- FP (eng. False Positive) – broj pogrešno klasificiranih pozitivnih rezultata
- FN (eng. False Negative) – broj pogrešno klasificiranih negativnih rezultata
- TP (eng. True Positive) – broj ispravno klasificiranih pozitivnih rezultata

Kod matrice konfuzije koriste se mjere:

- *Točnost* (eng. Accuracy) predstavlja omjer broja podataka koji su točno klasificirani i ukupnog broja podataka, a računa se kao:

$$\frac{TN + TP}{TN + FP + FN + TP}$$

- *Opoziv* (eng. Recall) je mjeru točno klasificiranih pozitivnih rezultata (TP) (eng. True positive rate), a računa se kao:

$$\frac{TP}{FN + TP}$$

- *Mjera pogrešno klasificiranih pozitivnih rezultata (PP)* (eng. False positive rate) je omjer broja rezultata koji pogrešno suvrstani u pozitivne rezultate i ukupnog broja negativnih rezultata:

$$\frac{FP}{TN + FP}$$

- *Mjera ispravno klasificiranih negativnih rezultata* (eng. True negative rate):

$$\frac{TN}{TN + FP}$$

- *Mjera pogrešno klasificiranih negativnih rezultata* (eng. False negative rate) je omjer broja rezultata koji su pogrešno suvrstani u negativne rezultate i ukupnog broja pozitivnih rezultata:

$$\frac{FN}{FN + TP}$$

- *Preciznost* (eng. Precision) je omjer ispravno klasificiranih pozitivnih rezultata i ukupnog broja pozitivnih rezultata u referentnim podacima(Oreški 2014):

$$\frac{TP}{TP + FP}$$

U ovom je radu korištena matrica konfuzije koje je malo izmijenjena u odnosu na onu prikazanu u primjeru. Matrica je izmijenjena tako da odgovara korištenim klasama i specifičnom slučaju ovog istraživanja, a prikazana je u tablici 3. Usporedba podataka dobivenih klasifikacijom i referentnih podataka, kao i elementi matrica konfuzije i gore opisane mjere, automatski su računate pomoću Python skripte. Ocjena točnosti klasifikacije napravljena je za svaki indeks zasebno kako bi se moglo usporediti sposobnosti indeksa za detekciju vegetacije.

Tablica 3. Matrica konfuzije kakva je korištena u ovom istraživanju

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	TP	FP	$\frac{TP}{TP+FP} [\%]$
	Nevegetacija	FN	TN	$\frac{TN}{FN+TN} [\%]$
		$\frac{TP}{TP+FN} [\%]$	$\frac{TN}{FP+TN} [\%]$	$\frac{TP+TN}{TP+FP+FN+TN} [\%]$

3.6. Izrada karte vegetacije za snimljeno područje

Nakon ocjene točnosti binarne klasifikacije napravljena je karta vegetacije na temelju vegetacijskog indeksa koji je ocijenjen kao najbolji. Karta vegetacije za snimljeno područje prikazuje koliki je postotak pojedine scene zapravo vegetacija. Za izradu karte korišten je prorijeđen set snimki koji je nastao tako da je svakih pola sekunde uzeta jedna snimka iz georeferenciranog videa. Te su snimke zatim klasificirane, a postotak vegetacije na sceni izračunat je kao omjer broja piksela koji predstavljaju vegetaciju i ukupnog broja piksela snimke. Te su vrijednosti izračunate i izvezene u CSV datoteku pomoću skripte.

Karta je izrađena u besplatnom programu QGIS. To je GIS (Geografski informacijski sustav) program otvorenog koda, licenciran GNU GPL (eng. General Public License) licencom. Program je službeni projekt OSGeo (eng. Open Source Geospatial Foundation) fundacije. Dostupan je na Linux, Unix, OS X, Windows i Android operativnim sustavima, a podržava brojne vektorske, rasterske i formate baza podataka (URL 16).

4. Rezultati

Podaci su prikupljeni snimanjem georeferenciranog videozapisa modificiranim GoPro Hero 4 Black kamerom. Svaki kadar georeferenciranog videozapisa predstavlja snimku scene koja sadrži plavi, zeleni i blisko-infracrveni kanal te ima određene prostorne koordinate. Cilj je iz tih podataka detektirati vegetaciju na snimljenoj sceni.

4.1. Prikupljeni podaci

Tablica 4. Metapodaci podataka korištenih u istraživanju

	Prikupljeni podaci	Reducirani podaci	Podaci za vizualizaciju
Vrsta datoteke	Videozapis	Videozapis	Slike
Format datoteke	MP4 video container H264 video codec	MP4 video container H264 video codec	JPEG
Veličina datoteke	4.9 GB	1.6 GB	617.7 MB
Rezolucija	1920x1080	1920x1080	1920x1080
Trajanje (hh:mm:ss)	00:23:09.60	00:23:09.60	-
Broj kadrova	50025	13896	2687
Kadrova u sekundi	36	10	2

Tablica 4 prikazuje metapodatke podataka prikupljenih i korištenih u ovom istraživanju. Vidi se da je kroz istraživanje kvaliteta (rezolucija) snimki ostala ista, ali je u dva navrata smanjen broj kadrova za obrađivanje kako bi se olakšao postupak i izbjegla redundancija podataka. Reducirani podaci korišteni su pri izboru snimaka za uzorkovanje te klasifikaciju i ocjenu točnosti. Podaci za vizualizaciju predstavljaju skup

slika ekstrahiranih iz videozapisa na temelju kojih je izrađena karta vegetacije snimljenog područja.

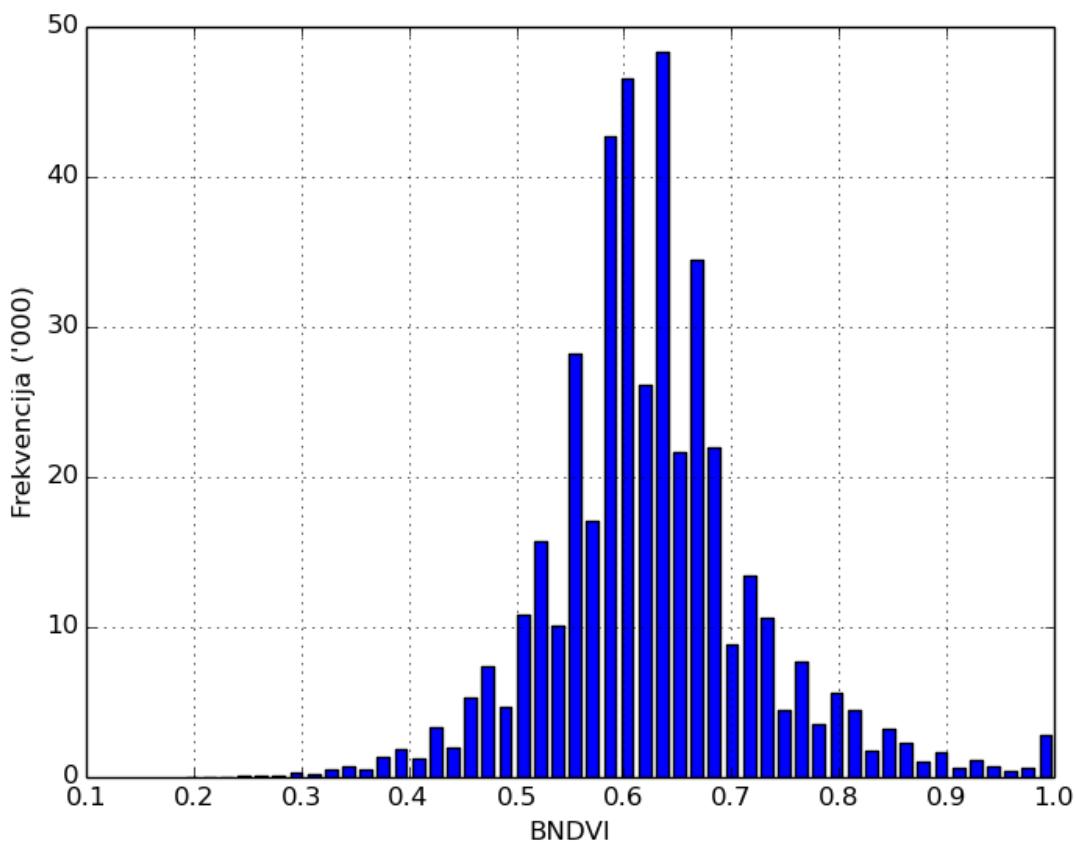
4.2. Rezultati uzorkovanja

Tablica 5. Statistički pokazatelji prikupljenih uzoraka za pojedini vegetacijski indeks

Naziv indeksa	BNDVI	GNDVI	BWDRVI	GBNDVI
Broj snimaka	8	8	8	8
Broj uzoraka	24	24	24	24
Broj piksela	428488	428488	428488	428488
Minimalna vrijednost	0.19	0.05	-0.74	-0.23
Maksimalna vrijednost	1.00	1.00	1.00	1.00
Raspon	0.81	0.95	1.74	1.23
Medijan	0.62	0.39	-0.40	0.20
Aritmetička sredina	0.63	0.40	-0.36	0.20
Varijanca	0.01	0.01	0.04	0.01
Standardno odstupanje	0.10	0.11	0.20	0.11
3σ	0.29	0.32	0.59	0.34
Donja granica	0.33	0.07	-0.95	-0.14
Gornja granica	0.92	0.72	0.22	0.55
Raspon granica	0.59	0.65	1.18	0.69

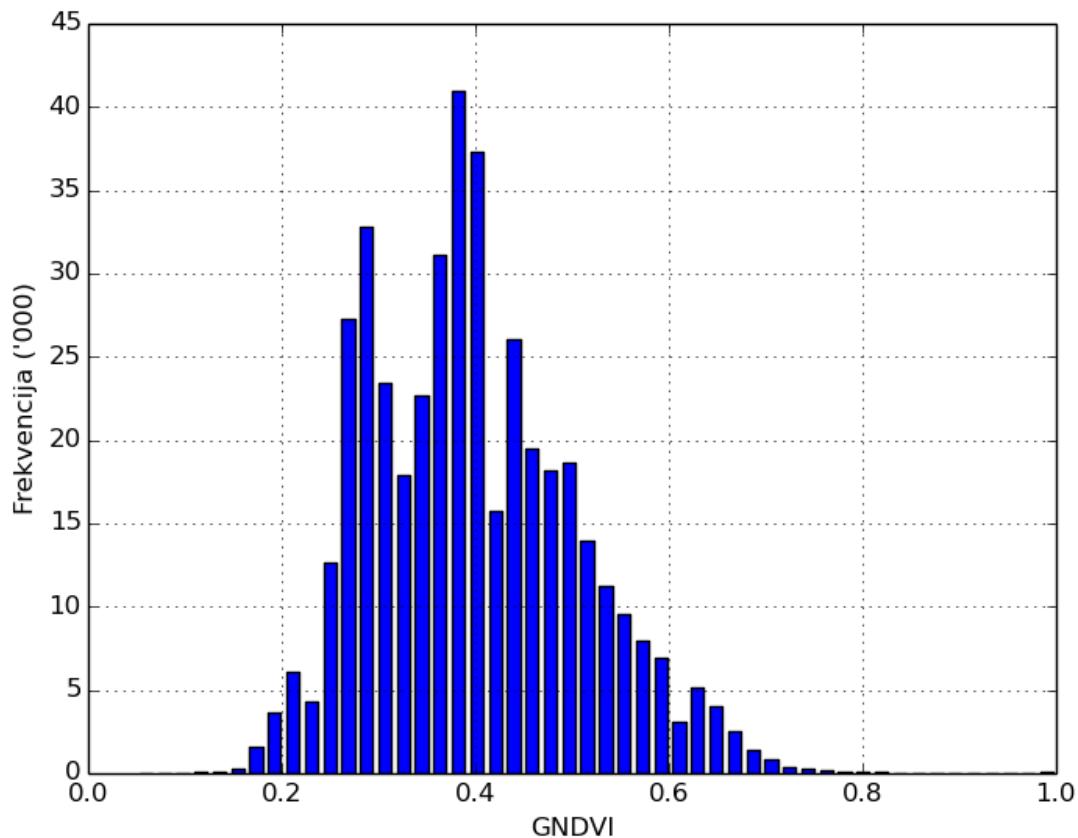
Tablica 5 prikazuje osnovne statističke pokazatelje podataka prikupljenih uzorkovanjem. Za svaki je indeks prikupljeno po 3 uzorka na 8 snimki što ukupno daje 24 indeksa, odnosno 428288 piksela po indeksu. Maksimalne su vrijednosti jednake i iznose 1 za sva četiri indeksa, dok BWDRVI pokazuje uvjerljivo najmanju minimalnu vrijednost od -0.74. Raspon između minimalne i maksimalne vrijednosti koje se pojavljuju u uzorku najveći je upravo kod BWDRVI-a i iznosi 1.74, dok je najmanja kod BNDVI-a gdje iznosi 0.81. Standardno odstupanje nam govori da su vrijednosti najbolje grupirane kod BNDVI-a (0.10) iako ni GNDVI i GBNDVI (0.11) ne odstupaju

mnogo. Jedini izuzetak je BWDRVI sa standardnim odstupanjem od 0.20 kod kojeg su vrijednosti najraspršenije. Oduzimanjem i dodavanjem vrijednosti 3σ aritmetičkoj sredini dobivene su donja i gornja granica klase vegetacija za svaki indeks. Prema rasponu obuhvaćenog tom klasom možemo očekivati da će BNDVI s najmanjim rasponom (0.59) imati najmanje problema sa svrstavanjem nevegatacije u klasu vegetacije, dok se kod BWDRVI (1.18) u tom segmentu očekuju najveći problemi.



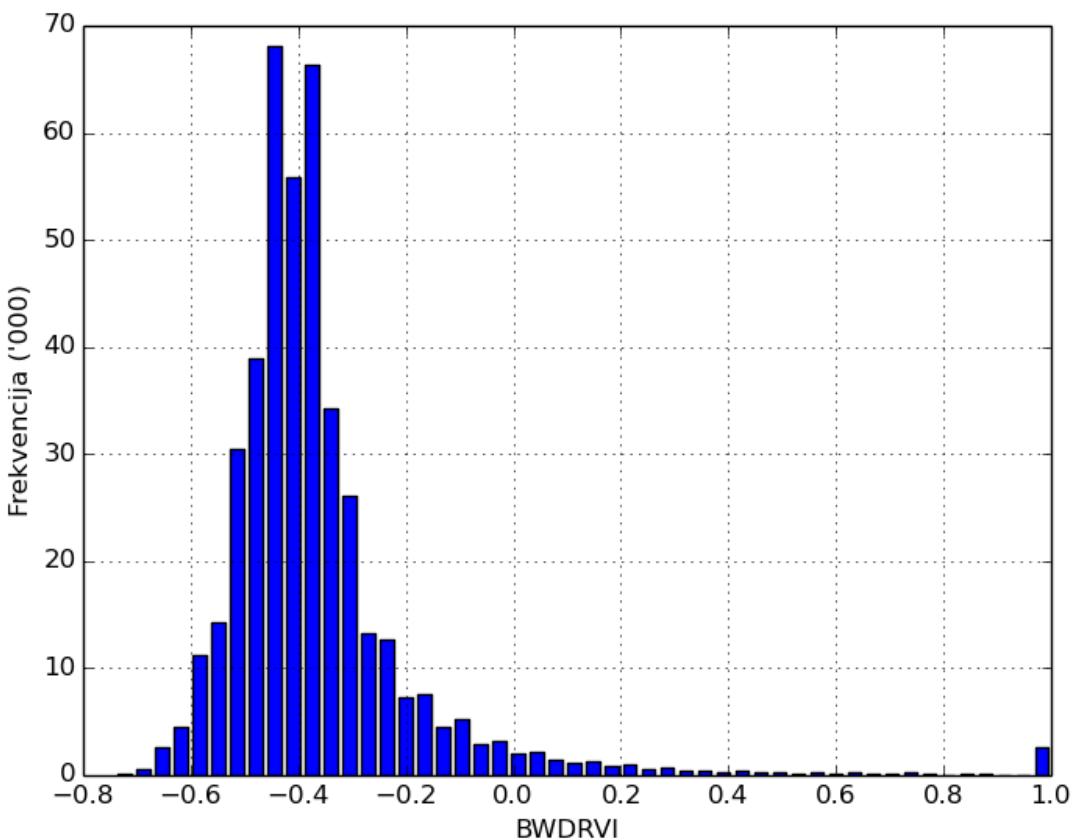
Slika 17. Histogram uzorka za BNDVI

Slika 17 prikazuje histogram vrijednosti obuhvaćenih uzorkovanjem za BNDVI. Može se vidjeti da su vrijednosti uglavnom grupirane oko aritmetičke sredine (0.63) te da opadaju prema krajevima intervala. Također treba napomenuti da se negativne vrijednosti uopće ne pojavljuju u uzorku, a veći broj piksela s vrijednošću blizu 1 je vjerojatno uzrokovani sjenom na krošnjama drveća.



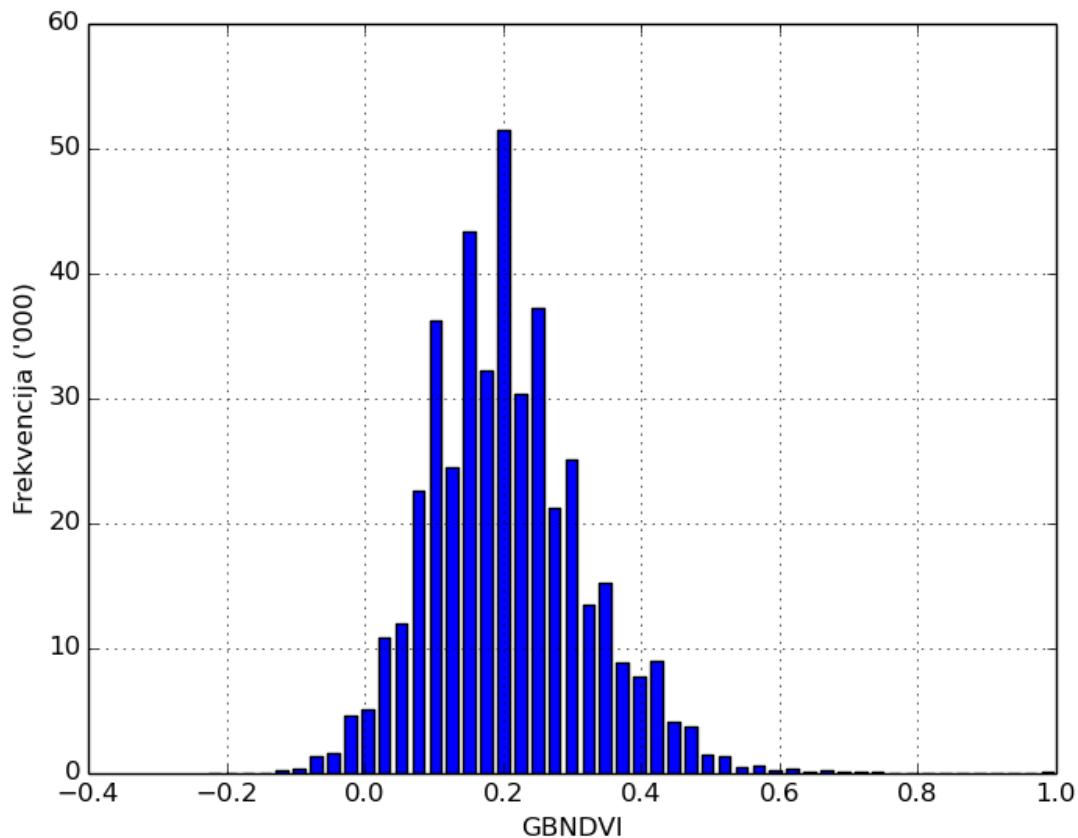
Slika 18. Histogram uzorka za GNDVI

Slika 18 prikazuje histogram vrijednosti obuhvaćenih uzorkovanjem za GNDVI. Može se primijetiti da ovaj histogram nema tako izrađen vrh u sredini intervala i da su značajne frekvencije prisutne na širem dijelu intervala nego kod BNDVI. Ipak, može se vidjeti da izvan raspona od 0.2 do 0.7 nema značajnih frekvencija i frekvencije na rubovima intervala su manje nego kod prethodnog indeksa.



Slika 19. Histogram uzorka za BWDRVI

Slika 19 prikazuje histogram vrijednosti obuhvaćenih uzorkovanjem za BWDRVI. Ovaj histogram ima najizraženiji vrh i veliki je dio vrijednosti grupiran oko njega. Međutim, problem predstavljaju ostale vrijednosti koje su raspršene preko cijele domene indeksa. Za sve se vrijednosti na ovom histogramu vjeruje da predstavljaju vegetaciju, pa je zbog činjenice da se vegetacija pojavljuje u gotovo cijeloj domeni BWDRVI-a teško odrediti granice klase koje će dobro detektirati vegetaciju, a eliminirati nevegetaciju. Također je zanimljivo da se većina vrijednosti, za razliku od drugih indeksa, nalazi u negativnom dijelu intervala. To je posljedica množenja vrijednosti blisko-infracrvenog kanala s 0.1 prilikom računanja indeksa.



Slika 20. Histogram uzorka za GBNDVI

Slika 20 prikazuje histogram vrijednosti obuhvaćenih uzorkovanjem za GBNDVI. Ovaj histogram je dosta „čist“ s vrijednostima grupiranim oko aritmetičke sredine (0.2). Iako su vrijednosti raspršene na velik interval, možemo vidjeti da se kod vrijednosti manjih od -0.1 i većih od 0.6 ne pojavljuju značajne frekvencije. Još se može vidjeti da je ovaj indeks kao i GNDVI ostao imun na vrijednosti bliske 1 koje se zbog sjena u uzorcima pojavljuju kod indeksa koji koriste plavi kanal.

4.3. Rezultati klasifikacije

Za klasifikaciju je iz snimljenog videozapisa izdvojeno pet kadrova. Kadrovi su izabrani tako da predstavljaju reprezentativni uzorak snimanja te se pazilo da se njima pokriju

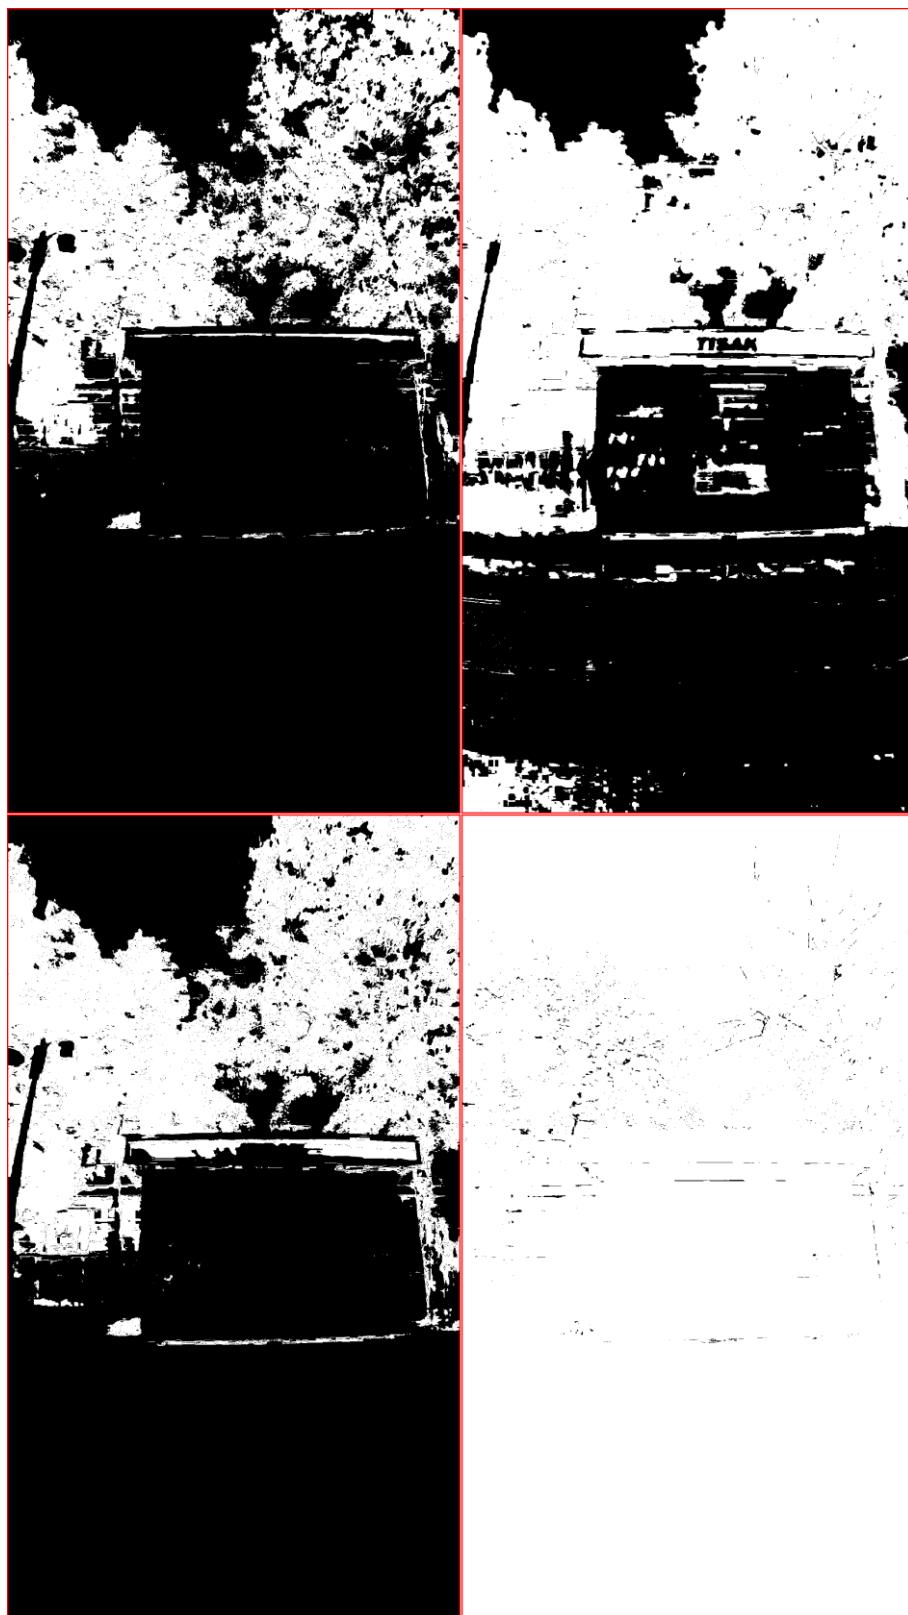
svi uvjeti osvjetljenja koji su prilikom snimanja bili prisutni. Tako su izabrana dva kadra koji prikazuju scene snimljene za vrijeme naoblake. Dva kadra prikazuju scene snimljene tako da je kamera usmjerenja prema suncu te jedan kadar prikazuje scenu snimljenu kada je kamera bila okrenuta od sunca. Klasificirane će scene u nastavku biti numerirane prema redoslijedu pojavljivanja (npr. scena 1). Korištena je binarna klasifikacija, a cilj je objekte na sceni što bolje razvrstati na vegetaciju i nevegetaciju.



Slika 21. Originalna snimka (lijevo) i prikaz ručno klasificirane (desno) scene 1

Slika 21 na lijevoj strani prikazuje scenu 1, a na desnoj rezultat njene ručne klasifikacije. Na tom su prikazu bijelom bojom prikazani objekti koji su klasificirani kao

vegetacija, a crnom su bojom prikazani objekti klase nevegetacija. Slike su prikazane na ovaj način kako bi se lako mogla procijeniti točnost ručne klasifikacije scena, a ti će podaci pri ocjeni točnosti biti korišteni kao referentni. Ručna je klasifikacija izvršena vektoriziranjem i drugim metodama izdvajanja vegetacije. Ona je podložna pogreškama zato što ovisi o sposobnosti operatera da na sceni prepozna vegetaciju, kao i o njegovoj preciznosti pri iscrtavanju granica poligona. Također, kada se gleda izvorni prikaz scene treba imati na umu da je to NGB snimka koja se sastoji od plavog, zelenog i blisko-infracrvenog kanala. Zbog toga će vegetacija na sceni biti prikazana zlatno-smeđom bojom, a ne zelenom kakva je u stvarnosti.



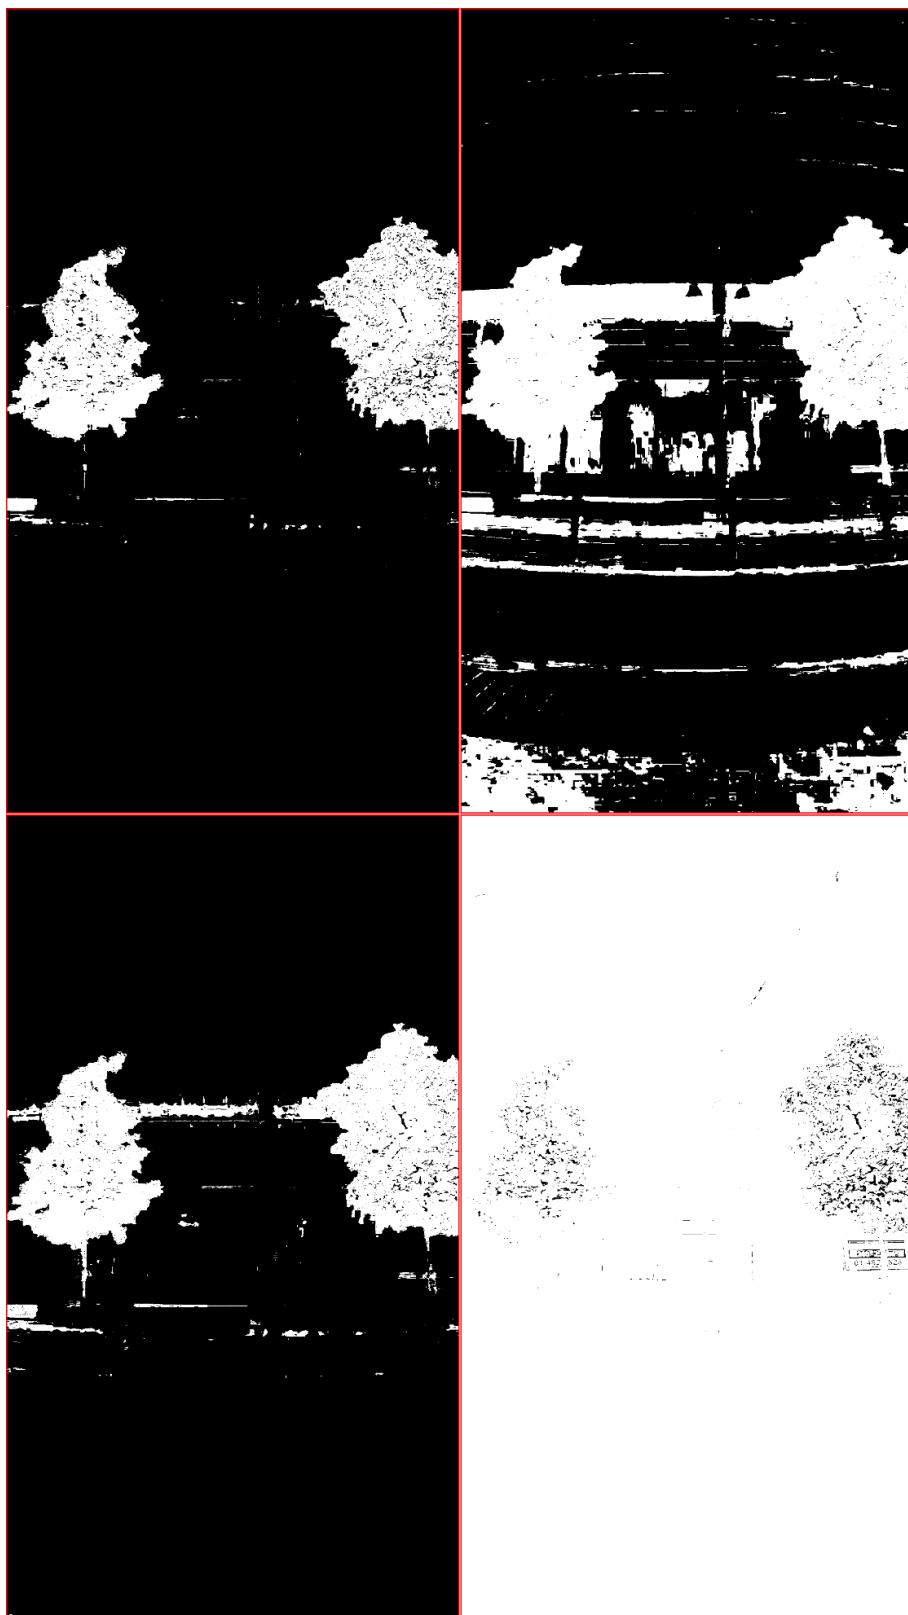
Slika 22. Rezultati klasifikacije scene 1 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo) i BWDRVI (dolje desno)

Na slici 22 prikazani su rezultati klasifikacije scene 1 za sva četiri vegetacijska indeksa. Rezultati su prikazani na ovakav način kako bi se brzo i intuitivno mogao dobiti dojam kvalitete pojedinog vegetacijskog indeksa u detektiranju vegetacije. Pikseli klasificirani kao vegetacija na slici su prikazani bijelom, a pikseli koji predstavljaju nevegetaciju crnom bojom. Iz slike se može zaključiti da je BNDVI najbolje razdvojio vegetaciju od nevegetacije na sceni. GNDVI i GBNDVI pokazuju slične rezultate, a BWDRVI pokazuje jako loš rezultat. Također se može primijetiti da su svi indeksi imali problema klasifikacijom površine crvene boje (reklama od Tiska). To može biti posljedica nedostatka crvenog kanala u obradi snimci te se ne može na temelju crvene boje detektirati nevegetacija kako to radi NDVI.



Slika 23. Originalna snimka (lijevo) i prikaz ručno klasificirane (desno) scene 2

Na slici 23 prikazana je scena 2 i rezultat njene ručne klasifikacije. Kod ove je scene karakteristično to što se iza vegetacije nalazi zgrada sa staklenim pročeljem koja daje odraz vegetacije.



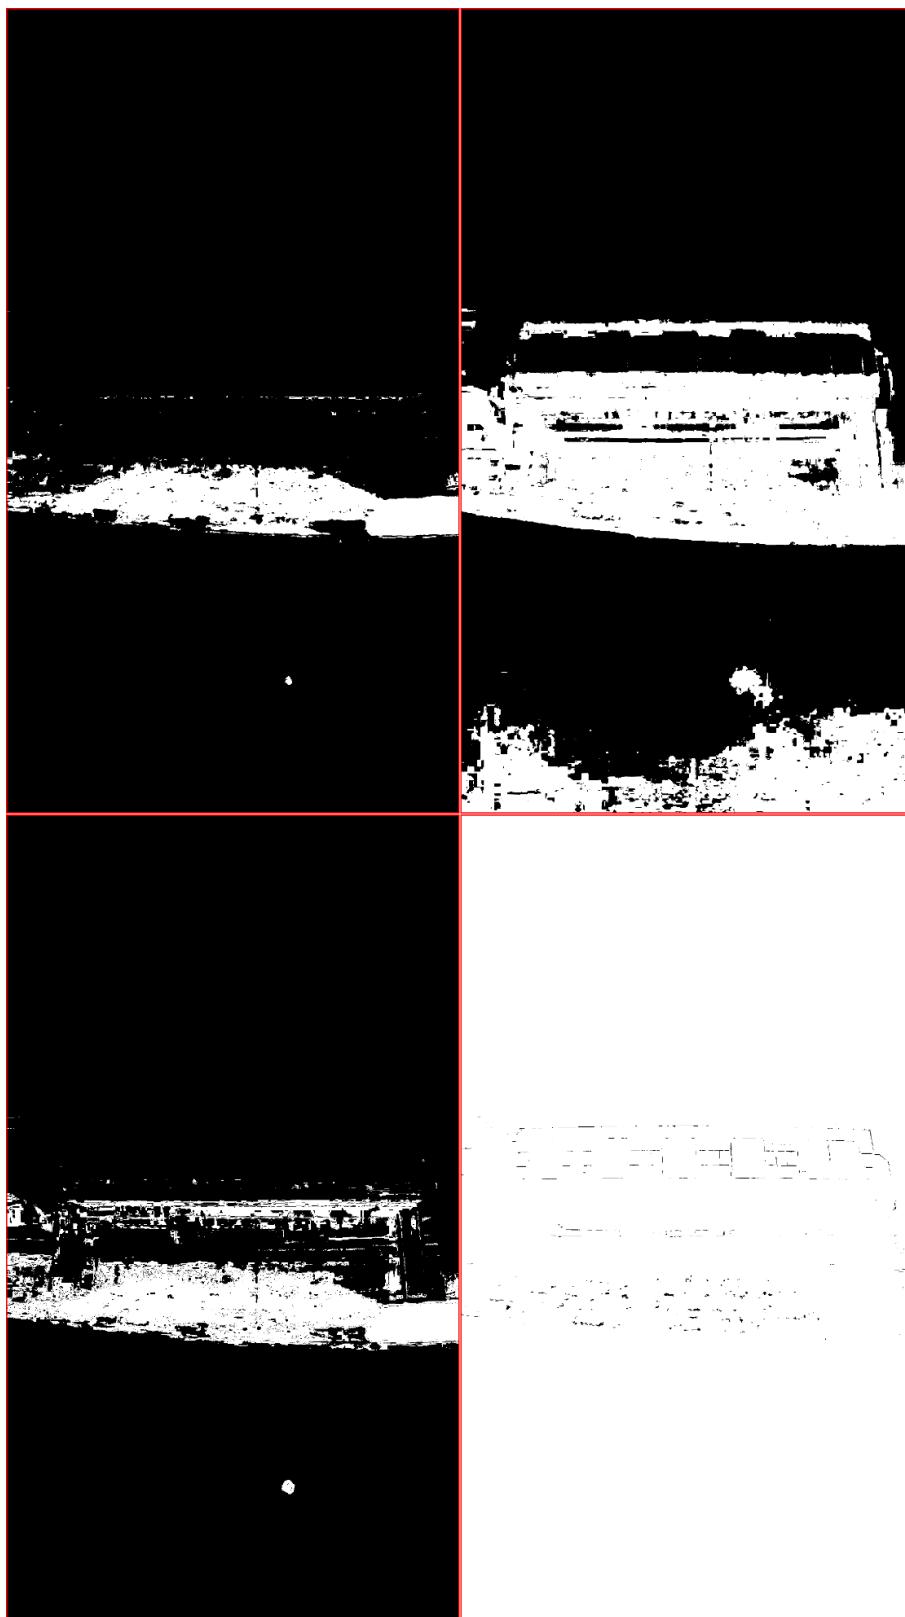
Slika 24. Rezultati klasifikacije scene 2 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo) i BWDRVI (dolje desno)

Na slici 24 koja prikazuje rezultate klasifikacije scene 2 može se vidjeti da je BNDVI ponovo dao najbolje rezultate. GNDVI je pokazao problem s područjima u sjeni koje je klasificirao kao vegetaciju iako to nisu, a čak je i dio ceste klasificirao kao vegetaciju. GBNDVI pokazuje drugi najbolji rezultat. On je pri klasifikaciji ove scene također imao problema s područjima u sjeni, ali znatno manje nego GNDVI. BWDRVI je i na ovoj sceni pokazao da nije sposoban razdvojiti vegetaciju od nevegetacije te je gotovo cijelu scenu klasificirao kao vegetaciju.



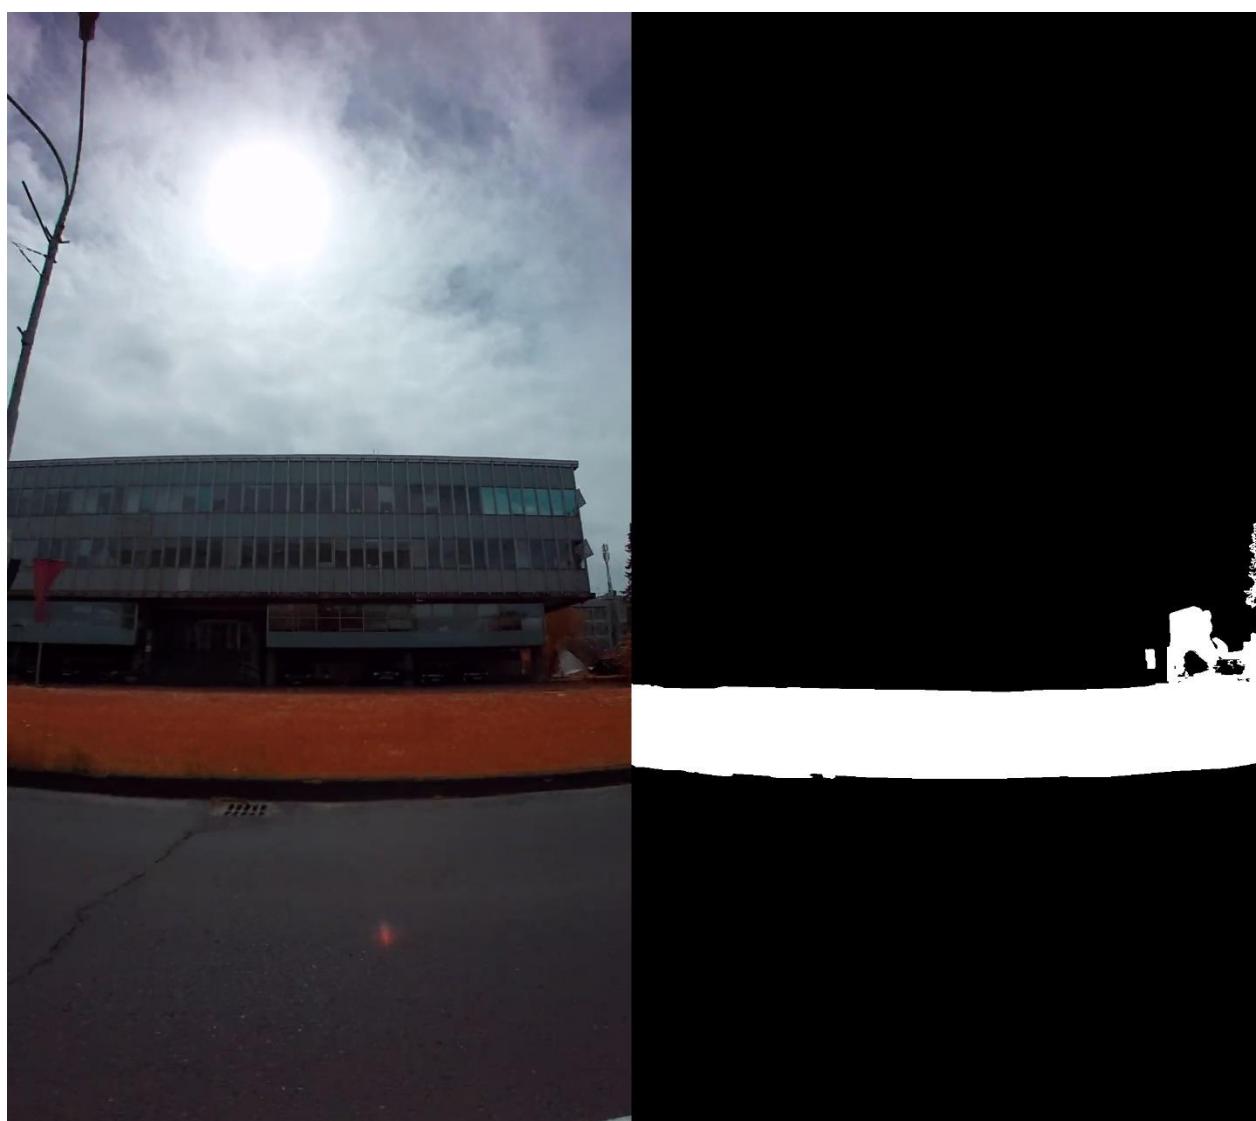
Slika 25. Originalna snimka (lijevo) i prikaz ručno klasificirane (desno) scene 3

Scena 3 prikazana je na slici 25, a karakteristična je zbog položaja kamere u odnosu na izvor svjetlosti. Scena je bogata sjenama, a od vegetacije sadrži samo travu i grmlje. Također se može vidjeti da se na donjem dijelu snimka pojavila anomalija u obliku crvenkaste točkice koja bojom sliči vegetaciji.



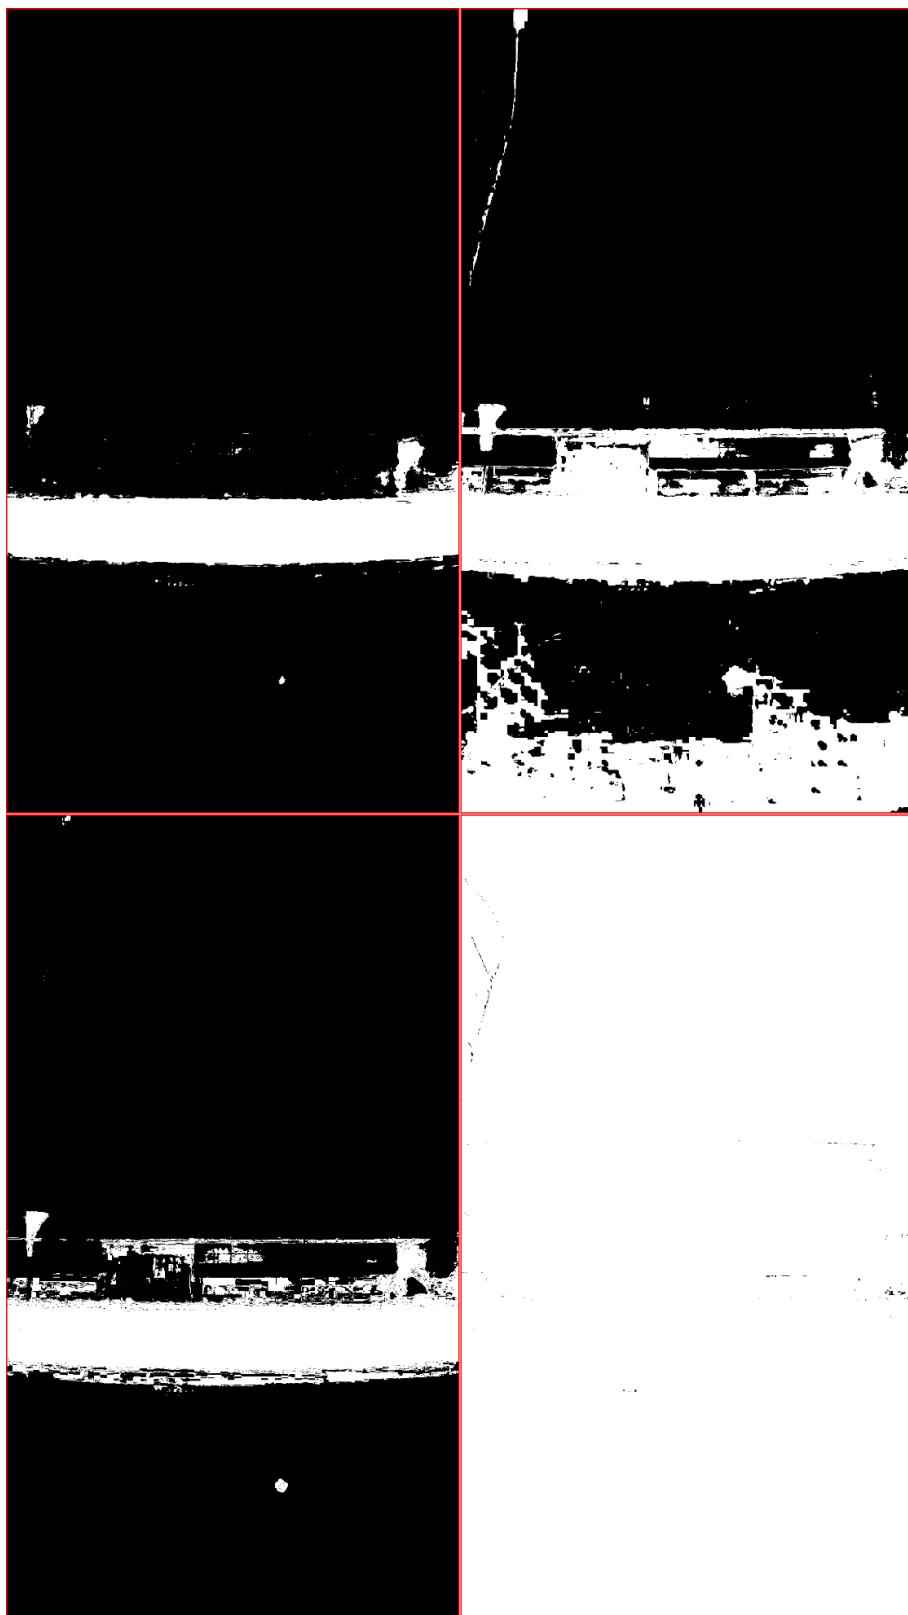
Slika 26. Rezultati klasifikacije scene 3 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo) i BWDRVI (dolje desno)

Rezultati klasifikacije scene 3 (slika 26) potvrđuju problem sa sjenama kod GNDVI-a i GBNDVI-a. BNDVI je kod ove scene također jedan dio zgrade klasificirao kao vegetaciju, ali je teško zaključiti da li je uzrok sjena ili staklena površina. GNDVI je ponovo dio ceste klasificirao kao vegetaciju, ali je, s obzirom da nema vidljive razlike između tog dijela i ostatka ceste, teško utvrditi uzrok te pogreške. Crvenkasta točkica koja se pojavila u donjem dijelu snimka je kod svih indeksa klasificirana kao vegetacija, a kod GNDVI-a je njen utjecaj dodatno raspršen na okolno područje.



Slika 27. Originalna snimka (lijevo) i prikaz ručno klasificirane (desno) scene 4

Slika 27 prikazuje scenu broj 4. Izvor svjetlosti je, kao i kod prethodne scene, ispred kamere. Scena je također bogata scenama ali i staklenim površinama. Posebnost ove scene je u vegetaciji koju sadrži, a koja je pravilnog oblika. Zbog toga je vegetaciju na ovoj sceni lako vektorizirati i pri tome izbjegći pogreške ručne klasifikacije. I na ovoj se sceni u donjem dijelu snimka pojavila crvenkasta točkica.



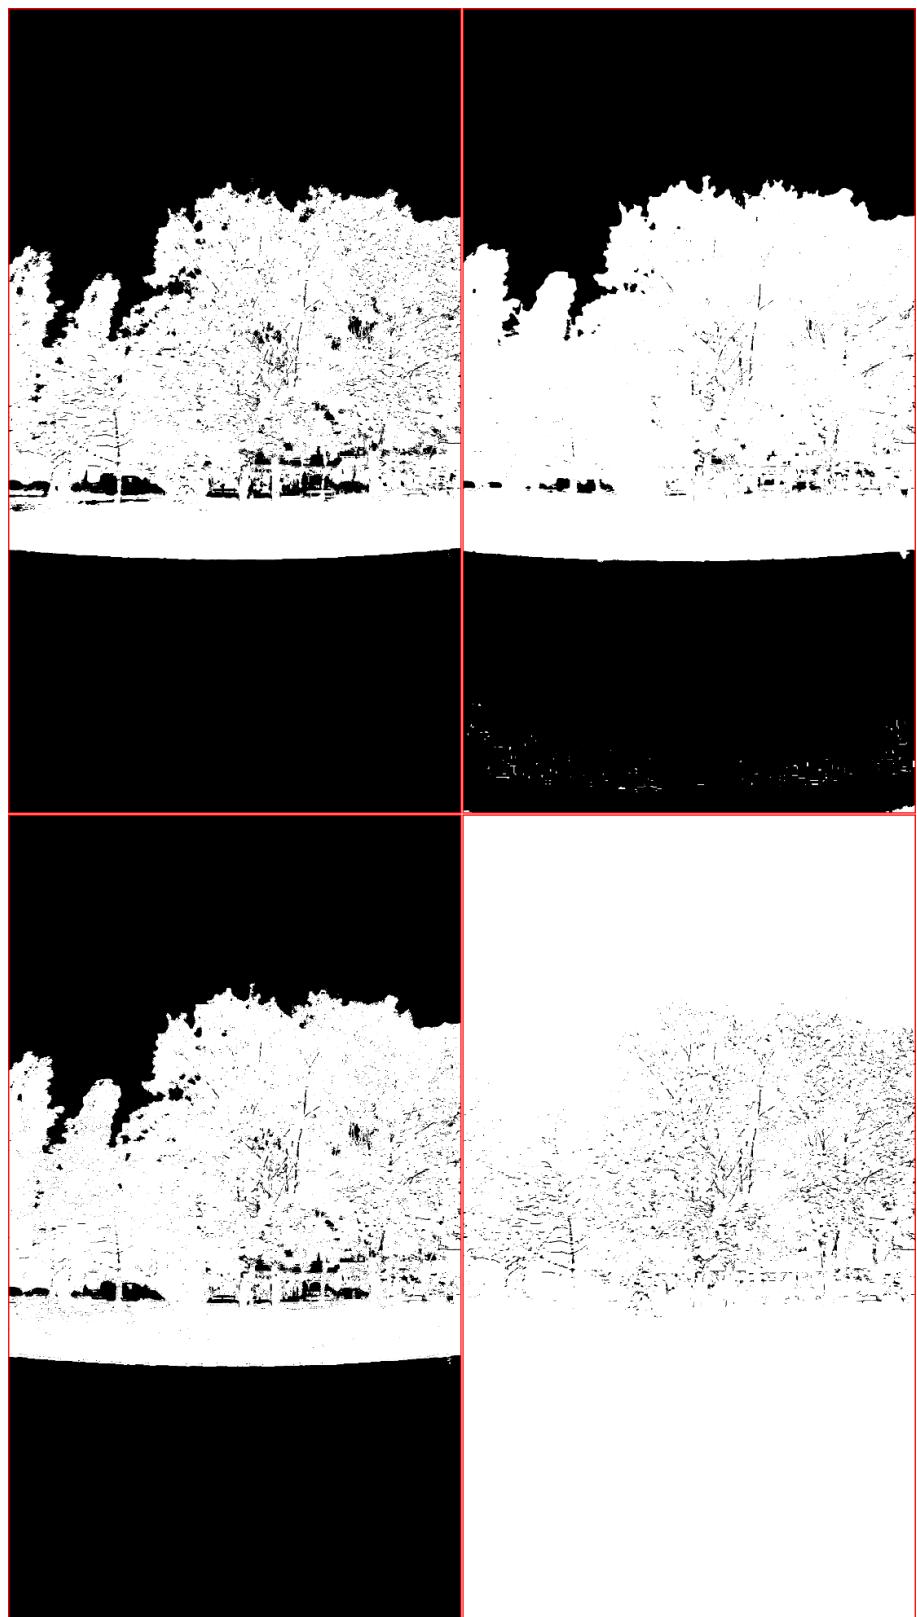
Slika 28. Rezultati klasifikacije scene 4 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo) i BWDRVI (dolje desno)

Slika 28 prikazuje rezultate klasifikacije scene 4 koji slijede karakteristike pokazane u svim prethodnim rezultatima. Kao i kod prijašnjih scena, svi su indeksi dobro klasificirali vegetaciju na sceni, a najbolju klasifikaciju nevegetacije i ovdje pokazuje BNDVI. Drugi najbolji rezultat postigao je GBNDVI koji je i kod ove scene imao problema sa sjenama. Za GNDVI je zanimljivo da je na ovoj sceni osim ceste i stup ulične rasvjete klasificirao kao vegetaciju. Ovi rezultati također potvrđuju problem uočen kod scene 1 gdje je objekt crvene boje pogrešno detektiran kao vegetacija. Crvena zastava koja se nalazi na lijevoj strani ove scene također je pogrešno klasificirana kao vegetacija, a ta je pogreška najmanja kod NDVI-a.



Slika 29. Originalna snimka (lijevo) i prikaz ručno klasificirane (desno) scene 5

Slika 29 prikazuje scenu 5. Ona je posebna zato što sadrži najviše vegetacije od svih obrađenih scena. Kamera je usmjerena od izvora svjetlosti, a sjene su slabije zbog djelomične naoblake u trenutku snimanja. Zbog velike količine i razvedenosti vegetacije, pretpostavlja se da je točnost ručnog klasificiranja kod ove scene najmanja.



Slika 30. Rezultati klasifikacije scene 5 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo) i BWDRVI (dolje desno)

Rezultati klasifikacije scene 5 prikazani su na slici 30. Kod ove je scene teško zaključiti koji je vegetacijski indeks najbolje poslužio za klasifikaciju scene. Pregledom rezultata se može zaključiti da su GNDVI i BWDRVI lošiji od ostalih indeksa, ali su rezultati BNDVI-a i GBNDVI-a na očigled skoro identični. Za oba se indeksa može reći da su dobro klasificirali scenu te nisu vidljive nikakve veće pogreške.

4.4. Ocjena točnosti klasifikacije i usporedba vegetacijskih indeksa

Tablica 6. Matrica konfuzije rezultata klasifikacije scene 1 koristeći BNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	487260	46644	91.26 %
	Nevegetacija	147543	1392153	90.42 %
		76.76 %	96.76 %	90.64 %

Tablica 7. Matrica konfuzije rezultata klasifikacije scene 1 koristeći GNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	628732	280282	69.17 %
	Nevegetacija	6071	1158515	99.48 %
		99.04 %	80.52 %	86.19 %

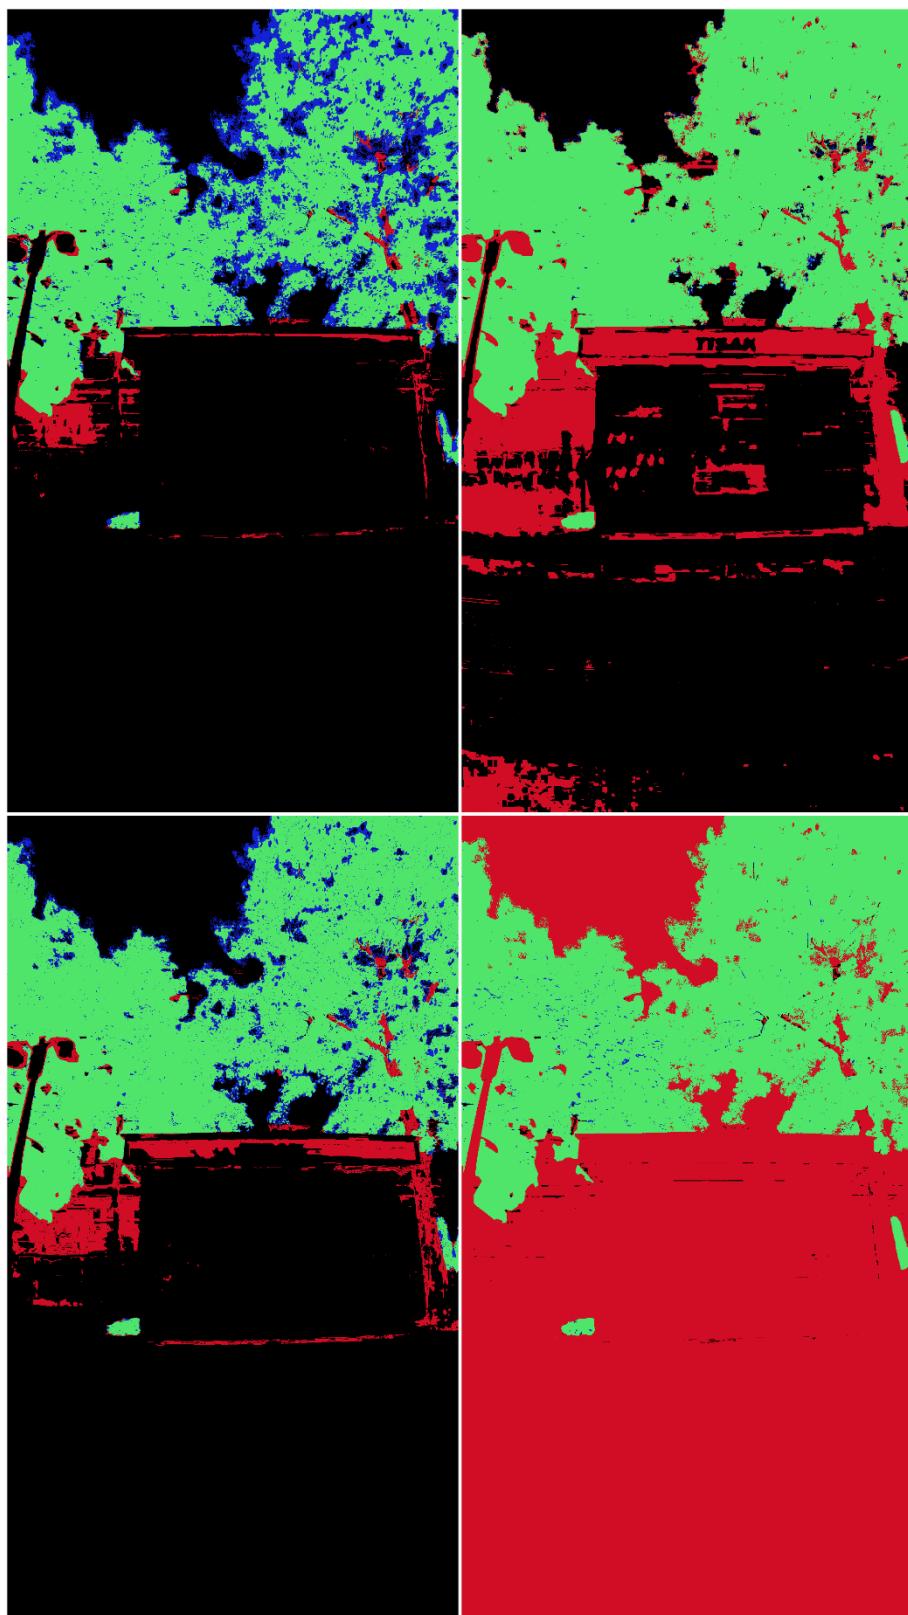
Tablica 8. Matrica konfuzije rezultata klasifikacije scene 1 koristeći GBNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	567032	98438	85.21 %
	Nevegetacija	67771	1340359	95.19 %
		89.32 %	93.16 %	91.98 %

Tablica 9. Matrica konfuzije rezultata klasifikacije scene 1 koristeći BWDRVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	629785	1434165	30.51 %
	Nevegetacija	5018	4632	48.00 %
		99.21 %	0.32 %	30.59 %

Tablice 6, 7, 8 i 9 prikazuju matrice konfuzije izračunate nakon klasifikacije scene 1 za svaki indeks. Ako pogledamo ukupnu točnost klasifikacije vidjet ćemo da je kod ove scene klasifikacija na temelju GBNDVI-a s 92%, a redom ju slijede BNDVI (91%), GNDVI (86%) i BWDRVI (31%). Razlike između točnosti klasifikacije su za prva tri indeksa relativno male, dok je BWDRVI potvrdio lošu točnost klasifikacije. Ako pogledamo koliko je piksela klasificiranih kao vegetacija ispravno klasificirano možemo vidjeti da je u tom segmentu najbolji BNDVI s 91%. BNDVI je kod ove scene imao problema s prepoznavanjem nevegetacije jer je od svih piksela klasificiranih u tu klasu samo 90% ispravno klasificirano. GBNDVI je u tome bio uspješniji (95%) te se tako pokazao kao najbolji indeks za klasifikaciju scene 1.



Slika 31. Vizualizacija matrice konfuzija za scenu 1 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo), BWDRVI (dolje desno)

Slika 31 prikazuje vizualizaciju elemenata pojedine matrice konfuzije i to tako da je svaka od četiri osnovne vrijednosti matrice prikazana zasebnom bojom:

- TP (ispravno klasificirana vegetacija) – zelena
- FP (nevegetacija klasificirana kao vegetacija) – crvena
- FN (vegetacija klasificirana kao nevegetacija) – plava
- TN (ispravno klasificirana nevegetacija) – crna

S prikaza se može vidjeti da je gore navedeni problem BNDVI-a zapravo najzastupljeniji u krošnjama drveća, gdje rubni i dijelovi oko šupljina na krošnjama nisu prepoznati kao vegetacija. Dapače, BNDVI je pokazao bolji rezultat od GBNDVI kod detekcije nevegetacije u donjem dijelu scene koji se sastoji od izgrađenih objekata. GNDVI je najbolje prepoznao vegetaciju na snimci, ali je imao problema u donjem dijelu snimke gdje je veći dio scene neispravno klasificirao kao vegetaciju. BWDRVI je cijelu scenu klasificirao kao vegetaciju.

Tablica 10. Matrica konfuzije rezultata klasifikacije scene 2 koristeći BNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	198876	6081	97.03 %
	Nevegetacija	34555	1834088	98.15 %
		85.20 %	99.67 %	98.04 %

Tablica 11. Matrica konfuzije rezultata klasifikacije scene 2 koristeći GNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	229505	235925	49.31 %
	Nevegetacija	3926	1604244	99.76 %
		98.32 %	87.18 %	88.43 %

Tablica 12. Matrica konfuzije rezultata klasifikacije scene 2 koristeći GBNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	211721	25456	89.27 %
	Nevegetacija	21710	1814713	98.82 %
		90.70 %	98.62 %	97.73 %

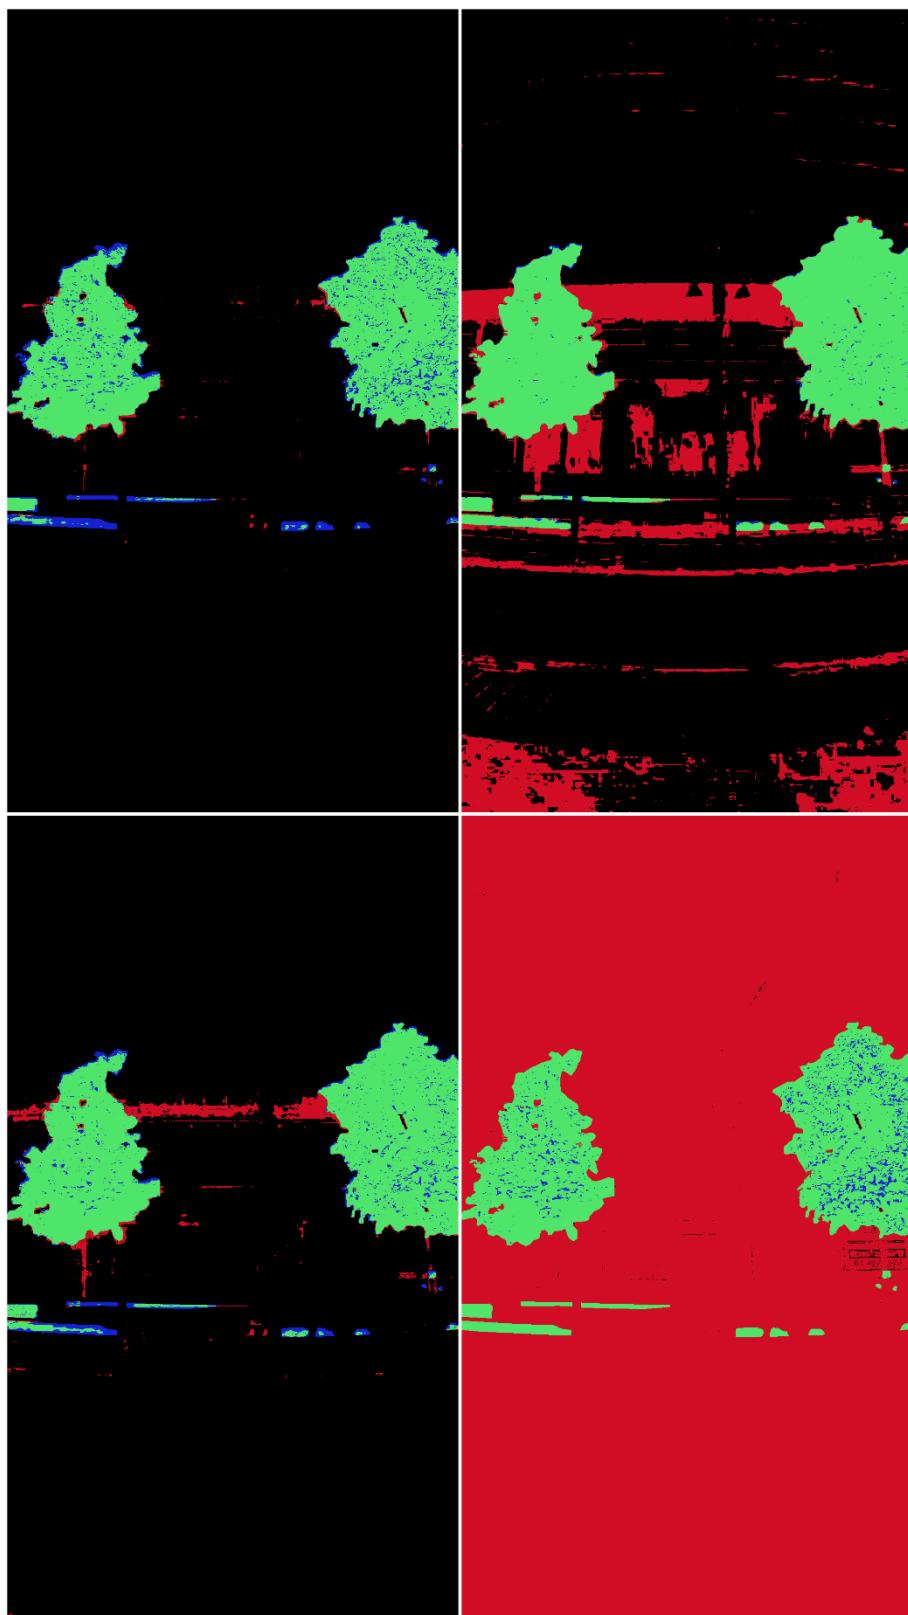
Tablica 13. Matrica konfuzije rezultata klasifikacije scene 2 koristeći BWDRVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	215247	1837757	10.48%
	Nevegetacija	18184	2412	11.71%
		92.21%	0.13%	10.50%

Tablice 10 do 13 prikazuju ocjenu točnosti klasifikacije scene 2 za pojedini indeks.

Odmah se može primjetiti da je scena 2 kod gotovo svih indeksa klasificirana uspješnije nego scena 1. Ovaj je puta BNDVI pokazao za nijansu bolju točnost od GBNDVI-a (98% oba), dok je ukupna točnost kod GNDVI-a primjetno niža (88%). GBNDVI je ovdje imao problema s klasifikacijom vegetacije jer je od svih piksela u klasi samo 89% ispravno klasificirano. BNDVI je ostavio uvjerljivo najbolji dojam jer je

kod njega u obje klase čak više 97% piksela ispravno klasificirano. Već sada možemo pretpostaviti da se bitka zapravo vodi između BNDVI-a i GBNDVI-a, dok GNDVI ima problema s prepoznavanjem nevegetacije, a BWDRVI pokazuje neiskoristive rezultate.



Slika 32. Vizualizacija matrice konfuzije za scenu 2 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo), BWDRVI (dolje desno)

Na vizualnom prikazu ocjene točnosti klasifikacije scene 2 (slika 32) može se vidjeti da je problem kod GNDVI-a u tome što je područja u sjeni prepoznao kao vegetaciju. BNDVI s tim nije imao problema, ali je zato lošije prepoznao travu u donjoj polovici scene. GNDVI i u ovom slučaju ima najmanje područja pod plavom bojom što nam govori da je dobro prepoznao vegetaciju, ali je isto tako i veliki dio nevegetacije klasificirao kao vegetaciju.

Tablica 14. Matrica konfuzije rezultata klasifikacije scene 3 koristeći BNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	97831	11805	89.23%
	Nevegetacija	8742	1955222	99.55%
		91.80%	99.40%	99.01%

Tablica 15. Matrica konfuzije rezultata klasifikacije scene 3 koristeći GNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	104960	452400	18.83%
	Nevegetacija	1613	1514627	99.89%
		98.49%	77.00%	78.11%

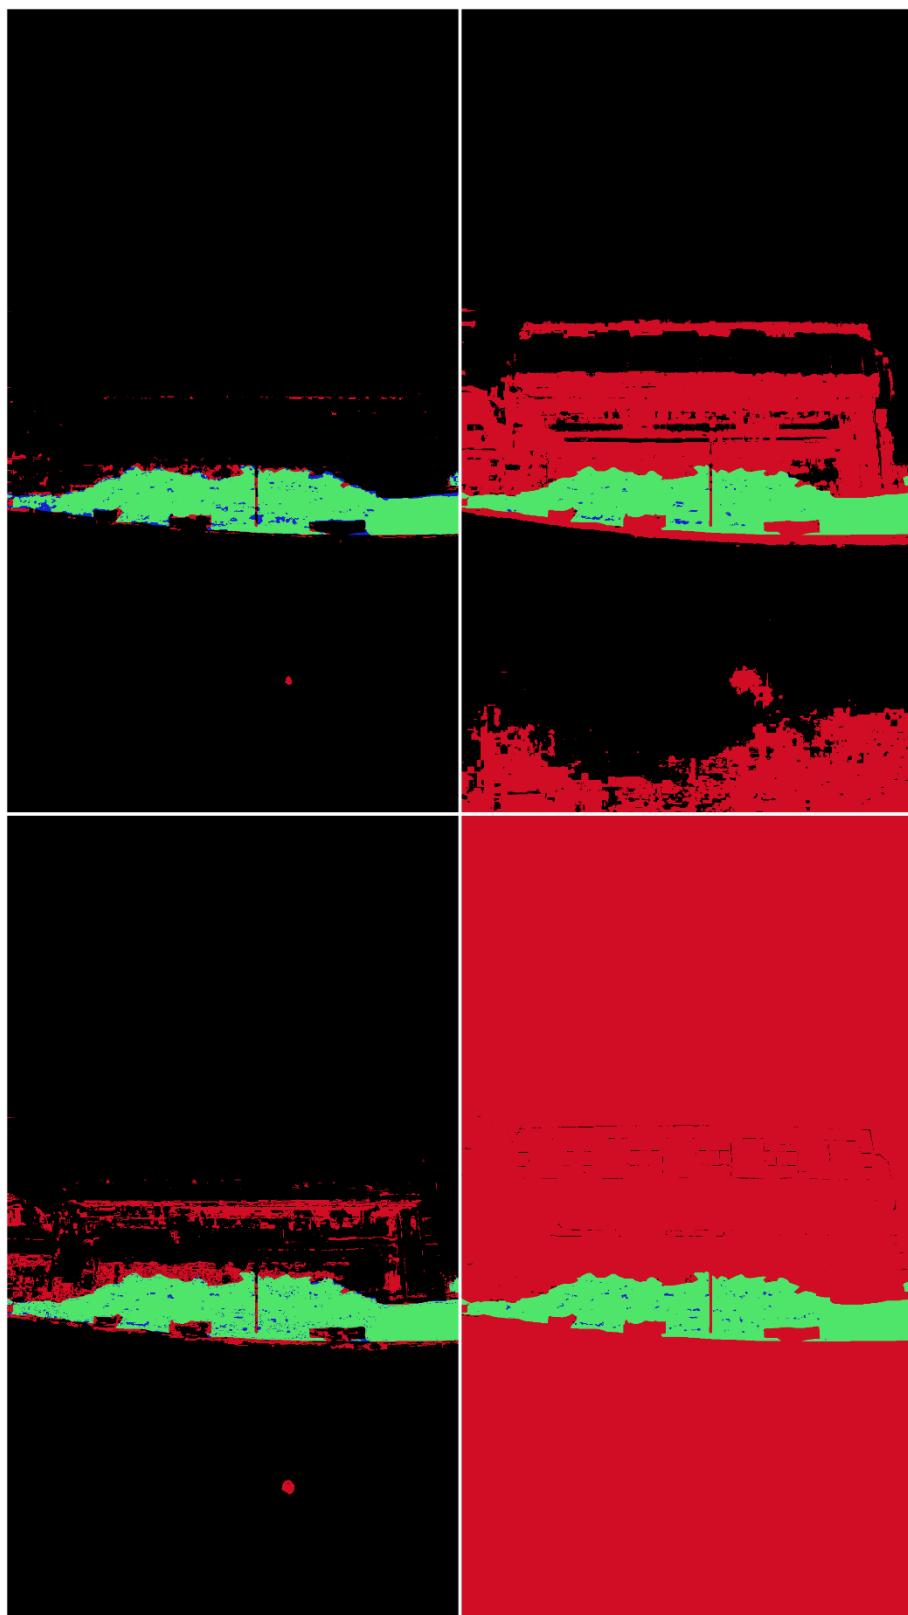
Tablica 16. Matrica konfuzije rezultata klasifikacije scene 3 koristeći GBNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	101979	76030	57.29%
	Nevegetacija	4594	1890997	99.76%
		95.69%	96.13%	96.11%

Tablica 17. Matrica konfuzije rezultata klasifikacije scene 3 koristeći BWDRVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	105015	1964412	5.07%
	Nevegetacija	1558	2615	62.66%
		98.54%	0.13%	5.19%

Ocjena točnosti klasifikacije scene 3 (tablice 14 do 17) pokazuje da je BNDVI još jednom najbolje klasificirao scenu s točnošću od 99%, a GBNDVI pokazuje točnost od 96%. Oba su indeksa imali problema u vidu da je od piksela u klasi vegetacija kod BNDVI njih 89%, a kod GBNDVI-a samo njih 57% ispravno klasificirano. Oba indeksa pokazuju izvrsnu detekciju nevegetacije tako da je gotovo 100% piksela svrstanih u tu klasu ispravno klasificirano. GNDVI i BWDRVI i na ovoj sceni s točnošću od 78% i 5% pokazuju da nisu sposobni razdvojiti vegetaciju od nevegetacije.



Slika 33. Vizualizacija matrice konfuzije za scenu 3 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo), BWDRVI (dolje desno)

Vizualni prikaz ocjene točnosti klasifikacije scene 3 (slika 33) pokazuje nam da su greške kod BNDVI-a grupirane uz granice vegetacije što znači da one mogu biti posljedica loše vektorizacije vegetacije na referentnoj snimci. GNDVI i GBNDVI su i na ovoj sceni veliki dio područja u sjeni klasificirali kao vegetaciju, a taj je problem izraženiji kod GNDVI-a. GNDVI je također i dio ceste u donjem dijelu scene neispravno klasificirao kao vegetaciju, što je bio slučaj i kod prethodnih scena.

Tablica 18. Matrica konfuzije rezultata klasifikacije scene 4 koristeći BNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	168529	7754	95.60%
	Nevegetacija	7606	1889711	99.60%
		95.68%	99.59%	99.26%

Tablica 19. Matrica konfuzije rezultata klasifikacije scene 4 koristeći GNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	175382	378387	31.67%
	Nevegetacija	753	1519078	99.95%
		99.57%	80.06%	81.72%

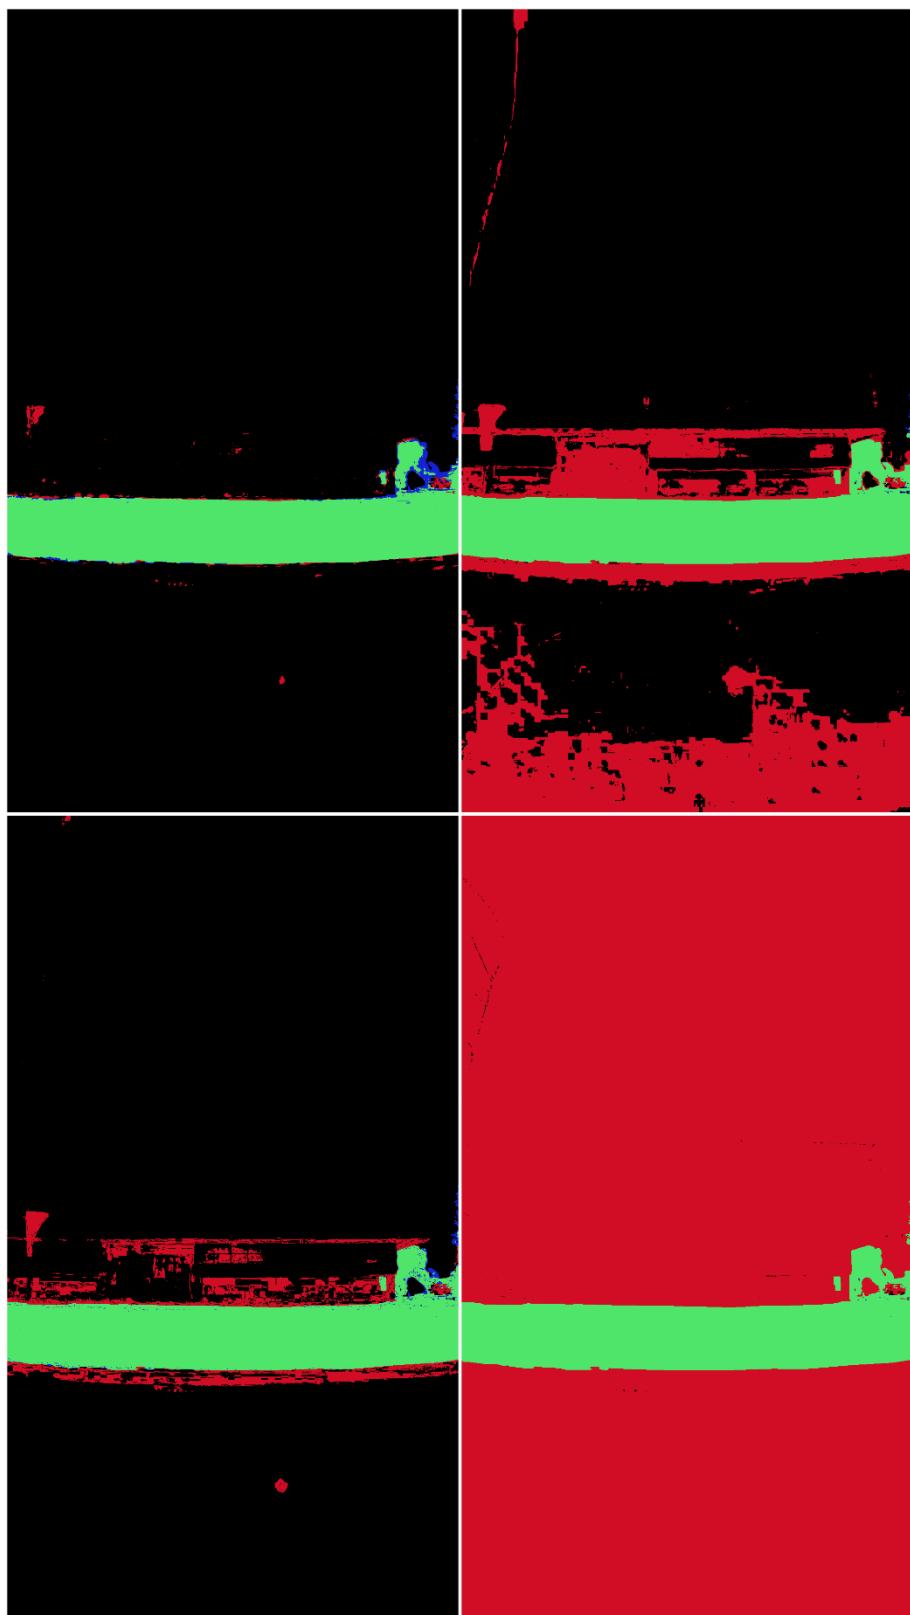
Tablica 20. Matrica konfuzije rezultata klasifikacije scene 4 koristeći GBNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	172539	70005	71.14%
	Nevegetacija	3596	1827460	99.80%
		97.96%	96.31%	96.45%

Tablica 21. Matrica konfuzije rezultata klasifikacije scene 4 koristeći BWDRVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	176068	1896559	8.49%
	Nevegetacija	67	906	93.11%
		99.96%	0.05%	8.53%

Ocjena točnosti klasifikacije scene 4 (tablice 18 do 21) pokazuju da je scenu najbolje klasificirao BNDVI s točnošću od preko 99%, a točnost u svim segmentima kod ovog indeksa prelazi 95%. Drugi najbolji rezultat još jednom pokazuje GBNDVI s ukupnom točnošću od 96%, a uzrok tome je svrstavanje velikog broja nevegetacije u klasu vegetacija. Također se može vidjeti da je točnost klase nevegetacija kod oba indeksa gotovo 100%.



Slika 34. Vizualizacija matrice konfuzije za scenu 4 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo), BWDRVI (dolje desno)

Vizualizacija matrica konfuzije (slika 34) nam pokazuje da su se greške kod BNDVI-a uglavnomjavljale na graničnom području između vegetacije i nevegetacije na sceni. Problemi se mogu uočiti tek kod crvenkaste točkice u donjem dijelu scene i crvene zastave na lijevom kraju scene koji su neispravno klasificirani kao vegetacija. Isti problemi vidljivi su i kod GBNDVI-a, a osim njih javljaju se i problemi sa svrstavanjem sjena u klasu vegetacija. Kod GNDVI-a se javljaju isti problemi kao i na prethodnim scenama.

Tablica 22. Matrica konfuzije rezultata klasifikacije scene 5 koristeći BNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	712658	47896	93.70%
	Nevegetacija	40597	1272449	96.91%
		94.61%	96.37%	95.73%

Tablica 23. Matrica konfuzije rezultata klasifikacije scene 5 koristeći GNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	749979	89186	89.37%
	Nevegetacija	3276	1231159	99.73%
		99.57%	93.25%	95.54%

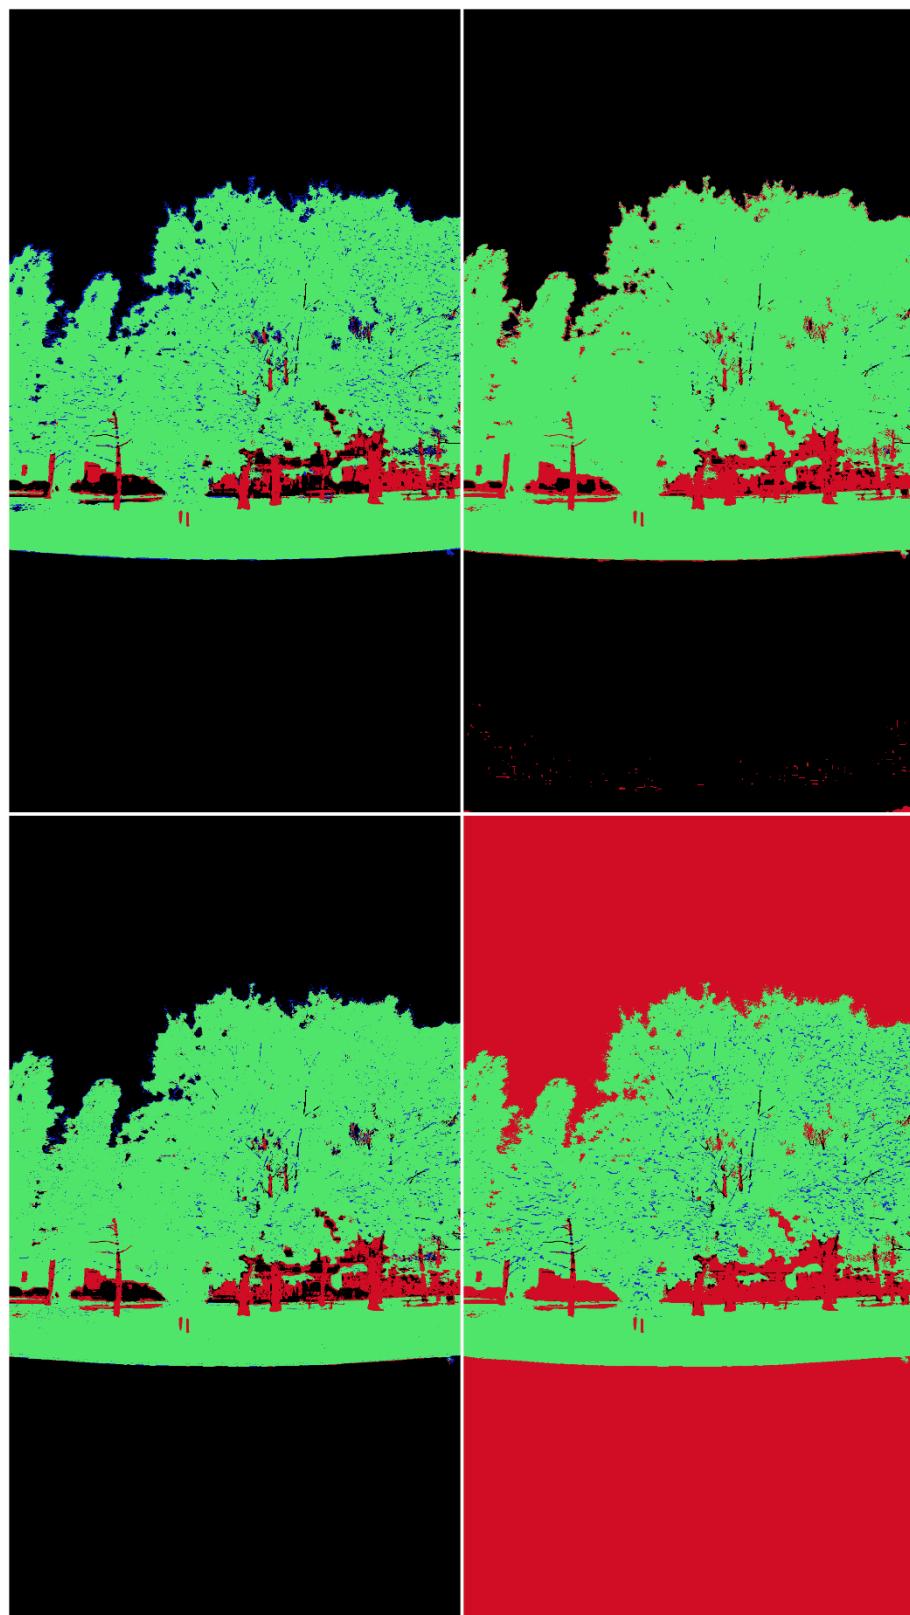
Tablica 24. Matrica konfuzije rezultata klasifikacije scene 5 koristeći GBNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	732760	58339	92.63%
	Nevegetacija	20495	1262006	98.40%
		97.28%	95.58%	96.20%

Tablica 25. Matrica konfuzije rezultata klasifikacije scene 5 koristeći BWDRVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	725827	1312204	35.61%
	Nevegetacija	27428	8141	22.89%
		96.36%	0.62%	35.40%

Tablice 22 do 25 prikazuju matrice konfuzije za scenu 5. Ocjena točnosti pokazuje da su čak tri indeksa scenu klasificirala točnošću većom od 95%, a najbolji rezultat pokazuje GBNDVI (96%). BNDVI pokazuje za nijansu bolju točnost klasificiranja vegetacije od GBNDVI-a koji je bolje klasificirao nevegetaciju. GNDVI je ovdje ostvario najbolju točnost od svih obrađenih scena (96%) što može biti posljedica snimanja u suprotnom smjeru od izvora svjetlosti.



Slika 35. Vizualizacija matrice konfuzije za scenu 5 za BNDVI (gore lijevo), GNDVI (gore desno), GBNDVI (dolje lijevo), BWDRVI (dolje desno)

Slika 35 prikazuje vizualizaciju matrica konfuzije za scenu 5. Može se vidjeti da su rezultati BNDVI-a i GBNDVI-a gotovo identični te je teško naći razlike među njima. GNDVI je kod ove scene puno manje griješio u vidu svrstavanja nevegetacije u klasu vegetacija, a problem klasificiranja ceste kao vegetacije gotovo je nestao. Međutim, pokazao je manju osjetljivost na razvedenost vegetacije gdje je većinu sjena i rupa u vegetaciji, za razliku od BNDVI-a i GBNDVI-a, klasificirao kao vegetaciju.

Tablica 26. Matrica konfuzije sumarnih rezultata klasifikacije koristeći BNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	1665154	120180	93.27%
	Nevegetacija	239043	8343623	97.21%
		87.45%	98.58%	96.54%

Tablica 27. Matrica konfuzije sumarnih rezultata klasifikacije koristeći GNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	1888558	1436180	56.80%
	Nevegetacija	15639	7027623	99.78%
		99.18%	83.03%	86.00%

Tablica 28. Matrica konfuzije sumarnih rezultata klasifikacije koristeći GBNDVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	1786031	328268	84.47%
	Nevegetacija	118166	8135535	98.57%
		93.79%	96.12%	95.69%

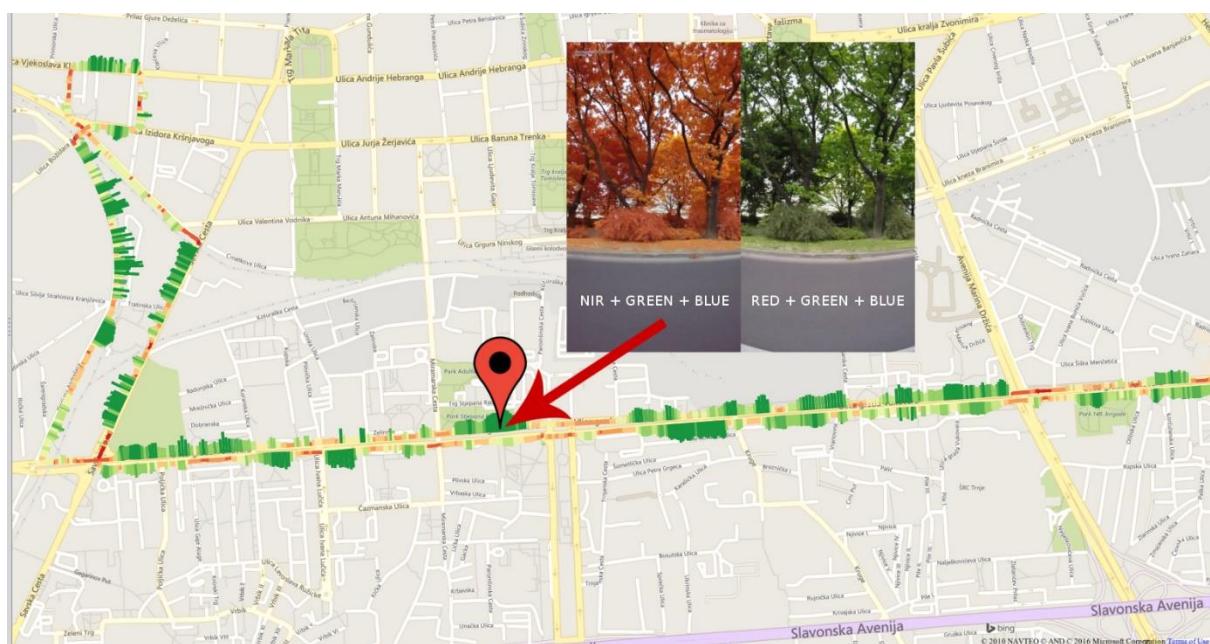
Tablica 29. Matrica konfuzije sumarnih rezultata klasifikacije koristeći BWDRVI

		Referentni podaci		
		Vegetacija	Nevegetacija	
Podaci dobiveni klasifikacijom	Vegetacija	1851942	8445097	17.99%
	Nevegetacija	52255	18706	26.36%
		97.26%	0.22%	18.04%

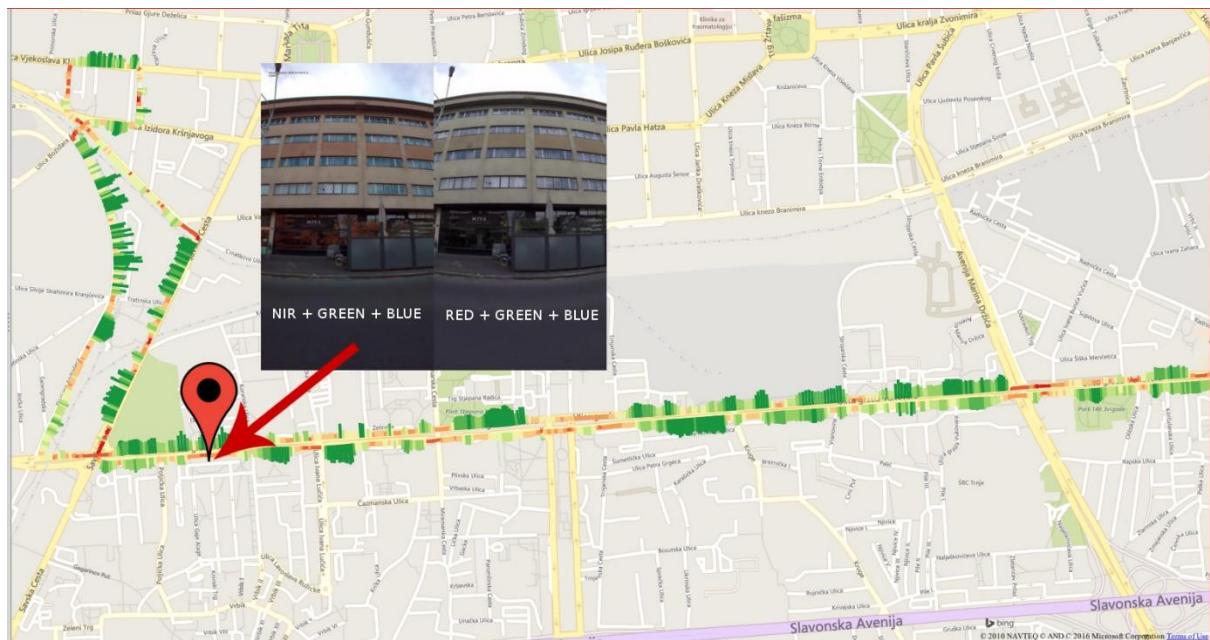
Tablice 26 do 29 prikazuju matrice konfuzije za sumarne rezultate klasifikacije za pojedini indeks. Elementi matrica dobiveni su sumiranjem tih elemenata za svih pet obrađenih scena za pojedini vegetacijski indeks. Može se reći da ove matrice konfuzije daju ukupnu ocjenu točnosti korištenih vegetacijskih indeksa. Najbolju ukupnu točnost od čak 97% pokazuje BNDVI, a slijede ga GBNDVI s 96%, GNDVI s 86% te BWDRVI s 18%. Osim ovih kvantitativnih, u obzir treba uzeti i rezultate vizualne analize izvršenih klasifikacija. Kada se sagledaju sve činjenice, možemo zaključiti da je BNDVI pokazao najbolje rezultate klasificiranja scene u klase vegetacija i nevegetacija. Na izvore grešaka, kao što su sjene, crvene površine i odsjaj, bio je otporniji od ostalih indeksa. Također treba napomenuti da je ovaj indeks pokazao da je najosjetljiviji na šupljine, grančice i druge nevegetacijske dijelove koji se mogu naći među vegetacijom. Zbog činjenice da su referentni podaci za ocjenu točnosti dobiveni ručnom klasifikacijom koja te dijelove ne može uvijek učinkovito eliminirati, ovaj je indeks također imao najviše FN vrijednosti (plava boja). BNDVI se kao vegetacijski indeks koji najtočnije vrši klasifikaciju dalje koristio za klasifikaciju snimaka pri izradi karte vegetacije.

4.5. Karta vegetacije

Podaci o vegetaciji za snimljeno područje, koji su rezultat ovog rada, vizualizirani su u obliku karte vegetacije. Karta se nalazi u prilozima, a prikazuje količinu vegetacije na svakoj snimljenoj sceni, tj. koliki je postotak scene detektiran kao vegetacija. Takvi nam podaci, iako ne predstavljaju apsolutnu kvantitativnu mjeru, mogu dati informaciju o tome na kojem se dijelu snimljenog područja nalazi više, a na kojem manje vegetacije. Takva bi karta također u slučaju praćenja nekog područja kroz određeno razdoblje mogla dati informaciju o povećanju ili smanjenju količine vegetacije na pojedinim lokacijama. Podaci na karti su raspodijeljeni u sedam klasa i sukladno tome obojeni.



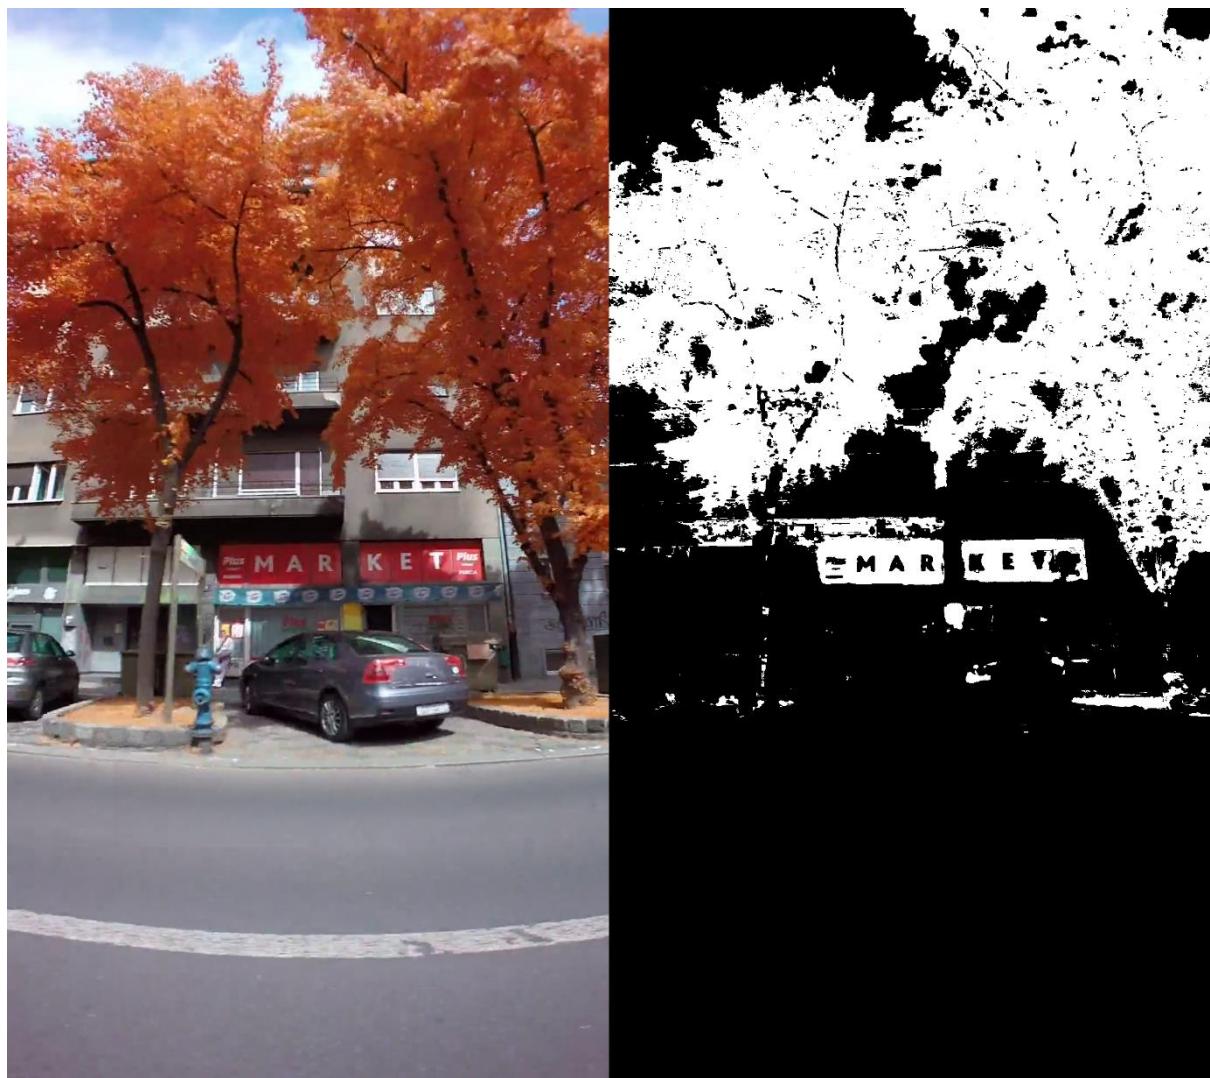
Slika 36. Prikaz scene s najvećim postotkom vegetacije



Slika 37. Prikaz scene s najmanjim postotkom vegetacije

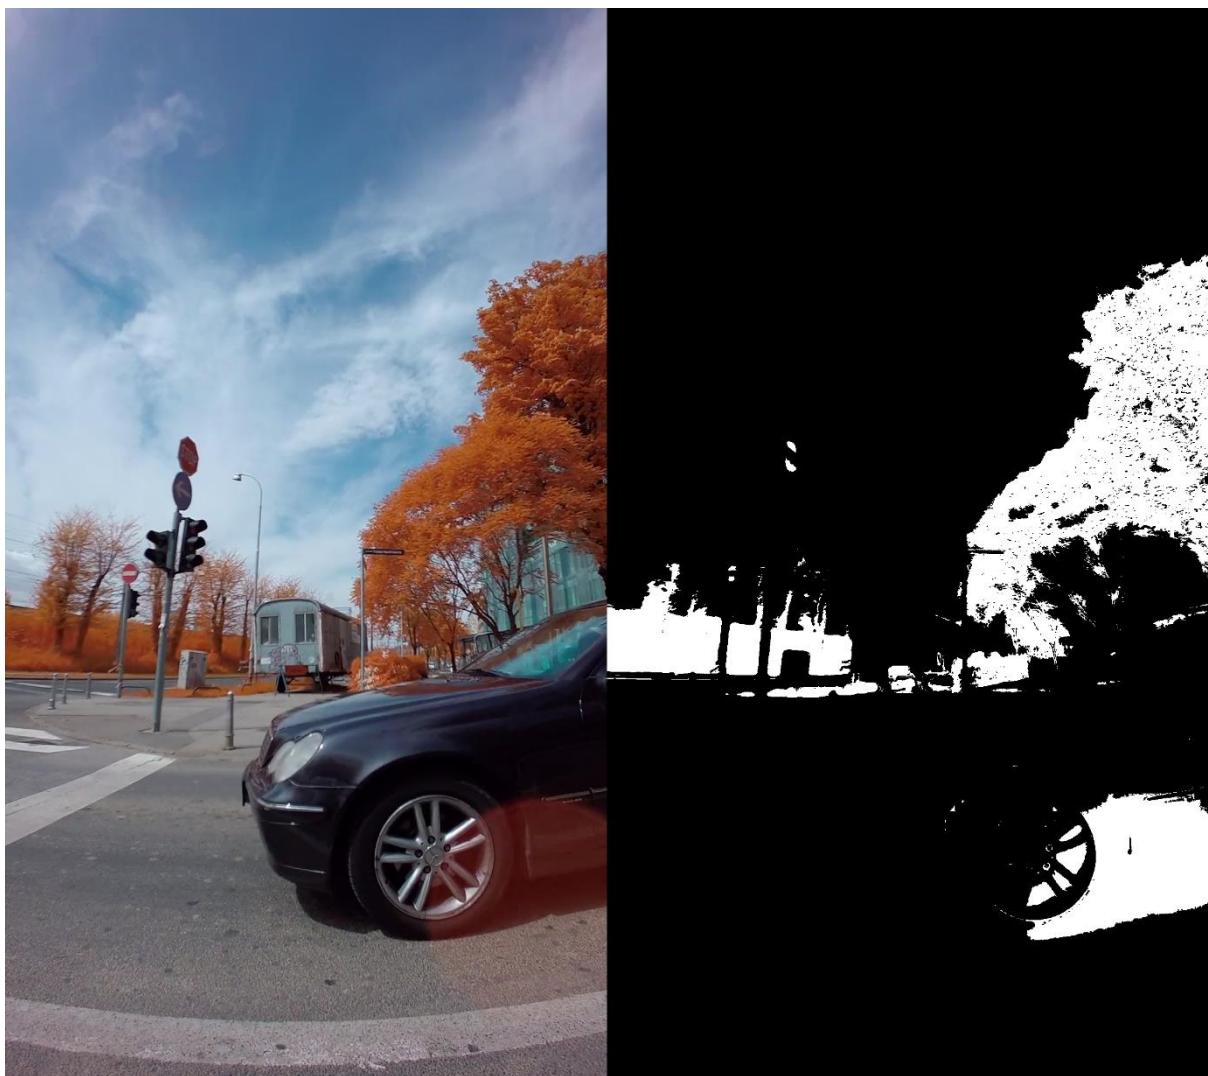
Slika 36 prikazuje scenu s najvećim postotkom vegetacije. Čak 74% te scene je detektirano kao vegetacija. Slika 37 prikazuje scenu na kojoj uopće nije detektirana vegetacija. Takvih scena ima više na snimljenom području što je i razumljivo s obzirom da je snimanje vršeno u gradu.

4.6. Problemi uočeni tijekom obrade i analize podataka



Slika 38. Prikaz problema s detekcijom objekata crvene boje

Tijekom obrade i analize prikupljenih podataka primijećeno je da se neki objekti crvene boje neispravno klasificiraju kao vegetacija. Ova je pojava prisutna kod sva četiri vegetacijska indeksa, a najbolju otpornost pokazuje upravo BNDVI. Problem je vjerojatno uzrok lošeg filtriranja crvene svjetlosti u NDVI-7 leći, pa se događa da se rubne vrijednosti crvenog dijela elektromagnetskog spektra očitavaju u blisko-infracrvenom kanalu snimke. Ovu bi pojavu bilo moguće eliminirati korištenjem druge kamere za opažanje crvenog kanala, ali se to na neki način može shvatiti kao korak unatrag u odnosu na prijašnja istraživanja.



Slika 39. Problem s odsjajem nastalim u leći

Slika 39 prikazuje snimku na kojoj se pojavila anomalija u obliku odsjaja koji je vjerojatno nastao u leći kamere. Problem je što je dio snimke na kojoj se preklapaju automobil i ta anomalija neispravno klasificiran kao vegetacija. Na sreću, ovakvih slučajeva nema mnogo, pa se mogu jednostavno eliminirati uklanjanjem takvih snimki.

5. Rasprava

Rezultati ovog istraživanja pokazuju da je modificirana GoPro kamera u kombinaciji s vegetacijskim indeksom BNDVI sposobna metodom binarne klasifikacije kvalitetno detektirati vegetaciju na sceni. Glavni nedostatak ove metode je podložnost pogreškama kada se na sceni pojavi objekt crvene boje čija je vrijednost BNDVI-a bliska vrijednosti vegetacije. To je uzrokovano nedostatkom crvenog kanala pri obradi snimke, a taj bi se nedostatak mogao izbjegći snimanjem još jedne RGB snimke. Dvije bi se snimke tada trebale alinirati kako bi se njihove slikovne matrice poklopile. Ipak, čak i uz takav nedostatak, ova je metoda superiorna u odnosu na metode opisane u (Milton 2002), (Dare 2008), (Lebourgeois et al. 2008) te (Rabatel et al. 2011). Nedostaci tih metoda su potreba za opažanjem iste scene dva puta, logistička zahtjevnost korištenja sustava te komplikiran postupak modifikacije kamere i obrade prikupljenih podataka. Sustav korišten u ovom istraživanju sastoji se od samo jedne kamere koja je bežično povezana s ostalim komponentama sustava. Kameru je lako i jednostavno modificirati zamjenom originalne s NDVI-7 lećom koja je dostupna u slobodnoj prodaji. Postupak naknadne obrade prikupljenih podataka u ovom istraživanju gotovo je u cijelosti automatiziran putem skripti u programskom jeziku Python te je zbog toga ova metoda pogodna za kontinuirano opažanje vegetacije i obradu veće količine podataka.

Još je jedan nedostatak ovog istraživanja to što nisu ispitana svojstva modificirane kamere. Za poboljšanje rezultata i bolje razumijevanje prikupljenih podataka, trebalo bi u kontroliranim uvjetima obaviti testno snimanje s modificiranom kamerom i utvrditi koje se valne duljine prikupljaju pojedinim kanalom. Taj je postupak uobičajen u daljinskim istraživanjima gdje se koriste multispektralne i hiperspektralne kamere, a zove se kalibracija kamere.

Kako nismo bili u mogućnosti tijekom ovog istraživanja izvršiti kalibraciju kamere, taj je nedostatak djelomično uklonjen uzorkovanjem. U tom smo postupku dobili dobar uvid u to koje vrijednosti prikupljene modificiranim kamerom predstavljaju vegetaciju. Osim uzorkovanjem, granice klasa mogu se odrediti i pomoću ROC krivulje. Ta se metoda često koristi pri određivanju granica klasa za binarnu klasifikaciju, a sastoji se od ocjene točnosti klasifikacije testnog skupa podataka s različitim granicama klasa.

Danas je nemoguće govoriti o detekciji objekata na slici ili videozapisu bez da se spomene koncept strojnog učenja. U području obrade videozapisa postoje brojne metode i algoritmi zasnovani na tom konceptu, a temelje se na uzimanju velikog broja uzoraka s kojima se algoritam „uči“ kako na svim budućim snimkama prepoznati objekt od interesa. Ti algoritmi najčešće osim boja koriste i druga svojstva za prepoznavanje objekata kao što su tekstura i oblik. U budućim bi istraživanjima bilo dobro ispitati kako se taj koncept može primijeniti na podatke prikupljene ovom metodom te hoće li se i koliko poboljšati točnost detektiranja vegetacije.

Prostorni podaci prikupljeni prilikom snimanja georeferenciranog videozapisa odnose se na položaj automobila, odnosno kamere. To znači da su podaci o vegetaciji koji su nastali kao rezultat ovog istraživanja samo djelomično georeferencirani zato što se vrijednosti sveukupne vegetacije na pojedinoj sceni svode na poziciju kamere. Da bi podaci o vegetaciji bili točno položajno određeni, trebalo bi kreirati stereoparove snimki. Tada se iz prostornog presjeka pravaca, ukoliko je poznata pozicija kamere za obje snimke, mogu izračunati prostorne koordinate pojedinog objekta na sceni. Mi zbog nedovoljne točnosti GNSS uređaja nismo bili u mogućnosti izvršiti taj postupak. Za tu bi primjenu najbolje bilo koristiti takozvanu stereokameru koja za svaku scenu snima dvije snimke, a prostorni odnos između njih je poznat. Tada bi se moglo dobiti

mjerne snimke na kojima bi se mogle mjeriti visine pojedinih objekata, pa tako i vegetacije.

Osim iz automobila, urbana se vegetacija pomoću bespilotnih letjelica može opažati i iz zraka. Mi smo se u ovom istraživanju odlučili za automobil zato što je taj način snimanja jednostavniji. Snimanje bespilotnom letjelicom u naseljenom području zahtjeva ishodovanje dozvole, a domet i vrijeme snimanja ograničeni su mogućnostima same letjelice. Snimanjem iz automobila mogu se također opažati dijelovi urbane vegetacije koji zbog zaklonjenosti nisu vidljivi iz zraka, a zbog perspektive snimanja se analizom snimki lako može zaključiti o kojoj se vrsti drveta ili vegetacije radi. Obje metode imaju svoje prednosti i nedostatke te možemo zaključiti da su one u biti komplementarne, tj. da prednosti jedne pokrivaju nedostatke druge i obratno. Ako bi se vegetacija snimala iz automobila i iz zraka, mogao bi se kreirati potpun i detaljan model vegetacije na nekom području.

Metoda korištena u ovom istraživanju također bi se mogla primijeniti na rješavanje problema autonomne navigacije robotiziranih vozila kojim su se bavili (Wurm et al. 2009). Oni su za potrebu autonomne navigacije robota koristili laserski skener kako bi detektirali vegetaciju. Robot bi na temelju tih podataka trebao zaobilaziti vegetaciju i voziti se po betonskoj površini. Korištenjem modificirane GoPro kamere robot bi mogao u kraćem vremenu snimiti cijelo svoje okruženje i iz klasificiranih podataka odlučiti kuda se može kretati. Osim toga, ova metoda ne zahtjeva dodatne senzore za treniranje sustava, već se granice klasa mogu lako odrediti uzorkovanjem.

6. Zaključak

Cilj rada je istražiti mogućnosti modificirane GoPro kamere da snimanjem georeferenciranog videozapisa iz automobila prikupi prostorno određene podatke o vegetaciji. Ovo je, prema mojim saznanjima, prvo takvo istraživanje u svijetu. Naknadna obrada prikupljenih podataka je izvršena pomoću besplatnih programa i dovedena do visokog stupnja automatizacije putem skripti u programskom jeziku Python.

U radu su uspoređeni rezultati dobiveni korištenjem BNDVI, GNDVI, GBNDVI i WDRV1 vegetacijskih indeksa. Ocjenom točnosti dokazano je da BNDVI dalje najbolja rješenja te je on dalje korišten pri izradi karte vegetacije snimljenog područja.

Tijekom obrade podataka primijećene su pogreške koje su većinom uzrok nedostatka podataka iz crvenog dijela elektromagnetskog spektra. To je ograničenje modificirane kamere i kao potencijalno rješenje predloženo je korištenje dodatne kamere za prikupljanje RGB snimki. Takav bi postupak uklonio te probleme, ali bi također dodao nove korake u prikupljanju i obradi podataka.

Konačno, može se zaključiti da je cilj uspješno ostvaren te je ustanovljena visoka točnost detekcije vegetacije ovom metodom. Za buduća je istraživanja predložena kombinacija snimanja iz automobila i s bespilotne letjelice, te obrada podataka zasnovana na strojnom učenju.

7. Prilozi

Skripte korištene u obradi podataka

[OpenCV_video.py](#)

```
import numpy
import cv2
import os
import sys
from PIL import Image
import processing_out

def nothing(x):
    pass

def end():
    cap.release()
    cv2.destroyAllWindows()
    sys.exit()

cv2.namedWindow('trackbar',cv2.WINDOW_NORMAL)
cv2.namedWindow('GNDVI',cv2.WINDOW_NORMAL)
cv2.namedWindow('BNDVI',cv2.WINDOW_NORMAL)
cv2.namedWindow('GBNDVI',cv2.WINDOW_NORMAL)
cv2.namedWindow('BWDRVI',cv2.WINDOW_NORMAL)

cap =
cv2.VideoCapture('/home/ivan/Desktop/Faks/dolje/NDVI/snimke/GOPR1198_M_20160417125714.mp
4')
length = int(cap.get(cv2.cv.CV_CAP_PROP_FRAME_COUNT))
global previousframe
previousframe = 0
pause = False
output = False

def toggle(trackbarValue):
    if pause == True:
        core()

def onChange(trackbarValue):
    if pause == True:
        cap.set(cv2.cv.CV_CAP_PROP_POS_FRAMES, trackbarValue)
        ret, frame = cap.read()
        core()
        currentframe = int(cap.get(cv2.cv.CV_CAP_PROP_POS_FRAMES))
    else:
        if abs(trackbarValue - previousframe) >= 25:
            cap.set(cv2.cv.CV_CAP_PROP_POS_FRAMES, trackbarValue)

### Traka za trackbar. prozor #####
#####
cv2.createTrackbar( 'framepos', 'trackbar', 0, length, onChange)
speedvalue = 1
# create switch for ON/OFF functionality
switch = '0 : raw \n1 : NDVI'
cv2.createTrackbar(switch, 'trackbar',0,1,toggle)
# create NIR/Green switch for ON/OFF functionality
```

```

NG = '0 : OFF \n1 : NG'
cv2.createTrackbar(NG, 'trackbar', 0, 1, toggle)
# create NIR/Blue switch for ON/OFF functionality
NB = '0 : OFF \n1 : NB'
cv2.createTrackbar(NB, 'trackbar', 0, 1, toggle)

def obrada(platno, indeks):
    framefloat = frame.astype('float')
    B,G,R = cv2.split(framefloat)
    ng = cv2.getTrackbarPos(NG, 'trackbar')
    nb = cv2.getTrackbarPos(NB, 'trackbar')
    if indeks == 'BNDVI':
        num = (R - B)
        if ng == 1:
            NIR_Green_Index = R/G
            num[NIR_Green_Index > 2.25] = 0
        if nb == 1:
            NIR_Blue_Index = B/G
            num[NIR_Blue_Index >= 1] = 0
        denum = (R + B)
        denum[denum==0] = 1
        NDVI = num/denum
        NDVI[NDVI < 0.332899] = 0
        NDVI[NDVI > 0.918800] = 0
        NDVI_rescale_factor = 255/0.9
        NDVI_rescaled = NDVI*NDVI_rescale_factor
        final_array = NDVI_rescaled.astype(numpy.uint8)
        Slika_col = cv2.applyColorMap(final_array, cv2.COLORMAP_JET)
        cv2.imshow(platno ,Slika_col)

    elif indeks == 'GBNDVI':
        num = (R - (G + B))
        if ng == 1:
            NIR_Green_Index = R/G
            num[NIR_Green_Index > 2.25] = 0
        if nb == 1:
            NIR_Blue_Index = B/G
            num[NIR_Blue_Index >= 1] = 0
        denum = (R + G + B)
        denum[denum==0] = 1
        NDVI = num/denum
        NDVI[NDVI < -0.138325] = 0
        NDVI[NDVI > 0.54776513] = 0
        NDVI_rescale_factor = 255/0.9
        NDVI_rescaled = NDVI*NDVI_rescale_factor
        final_array = NDVI_rescaled.astype(numpy.uint8)
        Slika_col = cv2.applyColorMap(final_array, cv2.COLORMAP_JET)
        cv2.imshow(platno ,Slika_col)

    elif indeks == 'BWDRVI':
        num = 0.1 * R - B
        if ng == 1:
            NIR_Green_Index = R/G
            num[NIR_Green_Index > 2.25] = 0
        if nb == 1:
            NIR_Blue_Index = B/G
            num[NIR_Blue_Index >= 1] = 0
        denum = 0.1 * R + B
        denum[denum==0] = 1
        NDVI = num/denum

```

```

NDVI[NDVI < -0.9537062] = 0
NDVI[NDVI > 0.22439474] = 0
NDVI_rescale_factor = 255/0.9
NDVI_rescaled = NDVI*NDVI_rescale_factor
final_array = NDVI_rescaled.astype(numpy.uint8)
Slika_col = cv2.applyColorMap(final_array, cv2.COLORMAP_JET)
cv2.imshow(platno ,Slika_col)

elif indeks == 'GNDVI':
    num = (R - G)
    if ng == 1:
        NIR_Green_Index = R/G
        num[NIR_Green_Index > 2.25] = 0
    if nb == 1:
        NIR_Blue_Index = B/G
        num[NIR_Blue_Index >= 1] = 0
    denum = (R + G)
    denum[denum==0] = 1
    NDVI = num/denum
    NDVI[NDVI < 0.073847] = 0
    NDVI[NDVI > 0.71985] = 0
    NDVI_rescale_factor = 255/0.9
    NDVI_rescaled = NDVI*NDVI_rescale_factor
    final_array = NDVI_rescaled.astype(numpy.uint8)
    Slika_col = cv2.applyColorMap(final_array, cv2.COLORMAP_JET)
    cv2.imshow(platno ,Slika_col)

def core():
    s = cv2.getTrackbarPos(switch, 'trackbar')
    if s == 0:
        cv2.imshow('BNDVI',frame)
        cv2.imshow('GBNDVI',frame)
        cv2.imshow('BWDRV1',frame)
        cv2.imshow('GNDVI',frame)
    else:
        obrada('BNDVI', 'BNDVI')
        obrada('GBNDVI', 'GBNDVI')
        obrada('BWDRV1', 'BWDRV1')
        obrada('GNDVI', 'GNDVI')

while(cap.isOpened()):
    if pause == False:
        ret, frame = cap.read()
        core()
        currentframe = int(cap.get(cv2.cv.CV_PROP_POS_FRAMES))

        key = cv2.waitKey(speedvalue)
        if key == ord(','):
            speedvalue = speedvalue+10
        elif key == ord('.'):
            speedvalue = speedvalue-10
            if speedvalue < 1:
                speedvalue = 1
        elif key == ord('q'):
            end()
        elif key == ord(' '):
            if pause == False:
                pause = True
            else:
                pause = False

```

```

        elif key == ord('o'):
            if pause == True:
                processing_out.process_out(frame, str(int(cap.get(cv2.cv.CV_CAP_PROP_POS_FRAMES))),
                'rezultati')

            if abs(currentframe - previousframe) >= 20:
                cv2.setTrackbarPos("framepos", "trackbar", currentframe)
                previousframe = currentframe
    end()

```

[processing_out.py](#)

```

import matplotlib.pyplot as plt
import matplotlib.ticker as ticker
import numpy as np
import cv2
import os
import csv

def plot_histogram(index_name, index, framenum, finaldir):
    hist, bins = np.histogram(index, bins=50)
    width = 0.7 * (bins[1] - bins[0])
    center = (bins[:-1] + bins[1:]) / 2
    fig = plt.figure()
    ax = fig.add_subplot(111)
    ax.yaxis.set_major_formatter(ticker.FuncFormatter(lambda y, pos: int(y*1e-3)))
    ax.set_ylabel("Frekvencija ('000)")
    ax.set_xlabel(index_name)
    ax.grid(True)
    plt.bar(center, hist, align='center', width=width)

    finalname = finaldir+'/'+index_name+'_'+framenum+'_hist.png'

    fig.savefig(finalname)
    plt.clf()
    plt.close()

def stats_calc(index_name, index):
    minimum = index.min()
    maximum = index.max()
    spread = maximum - minimum
    med = np.median(index)
    std = np.std(index)
    return ({'Naziv indeksa': index_name, 'Minimalna vrijednost':minimum, 'Maksimalna
    vrijednost':maximum, 'Raspon':spread, 'Medijan':med, 'Standardno odstupanje':std})

def process_out(img, framenum, outputdir):
    finaldir = outputdir+'/frame_'+framenum
    try:
        os.mkdir(finaldir)

        #NORMAL
        filenamenormal = finaldir+'/NORMAL_'+framenum+'.jpeg'
        cv2.imwrite(filenamenormal, img)

        #BNDVI
        framefloat = img.astype('float')
        B,G,R = cv2.split(framefloat)
        BNDVI_num = (R - B)

```

```

BNDVI_denum = (R + B)
BNDVI_denum[BNDVI_denum==0] = 1
BNDVI = (BNDVI_num/BNDVI_denum)
BNDVI100 = BNDVI*100 + 100
BNDVlout = BNDVI100.round().astype('int')
filename = finaldir+='/BNDVI_'+framenum+'.tiff'
cv2.imwrite(filename, BNDVlout)

plot_histogram('BNDVI', BNDVI, framenum, finaldir)

#GNDVI
GNDVI_num = (R - G)
GNDVI_denum = (R + G)
GNDVI_denum[GNDVI_denum==0] = 1
GNDVI = (GNDVI_num/GNDVI_denum)
GNDVI100 = GNDVI*100 + 100
GNDVlout = GNDVI100.round().astype('int')
filename = finaldir+='/GNDVI_'+framenum+'.tiff'
cv2.imwrite(filename, GNDVlout)

plot_histogram('GNDVI', GNDVI, framenum, finaldir)

#GBNDVI
GBNDVI_num = (R - (G + B))
GBNDVI_denum = (R + G + B)
GBNDVI_denum[GBNDVI_denum==0] = 1
GBNDVI = (GBNDVI_num/GBNDVI_denum)
GBNDVI100 = GBNDVI*100 + 100
GBNDVlout = GBNDVI100.round().astype('int')
filename = finaldir+='/GBNDVI_'+framenum+'.tiff'
cv2.imwrite(filename, GBNDVlout)

plot_histogram('GBNDVI', GBNDVI, framenum, finaldir)

#BWDRVI
BWDRVI_num = 0.1 * R - B
BWDRVI_denum = 0.1 * R + B
BWDRVI_denum[BWDRVI_denum==0] = 1
BWDRVI = (BWDRVI_num/BWDRVI_denum)
BWDRVI100 = BWDRVI*100 + 100
BWDRVlout = BWDRVI100.round().astype('int')
filename = finaldir+='/BWDRVI_'+framenum+'.tiff'
cv2.imwrite(filename, BWDRVlout)

plot_histogram('BWDRVI', BWDRVI, framenum, finaldir)

#NGI
with np.errstate(divide='ignore'):
    NGI = R/G
    NGI[np.isnan(NGI)] = 0
filename = finaldir+='/NGI_'+framenum+'.tiff'
cv2.imwrite(filename, NGI)

#NBI
with np.errstate(divide='ignore'):
    NBI = R/B
    NBI[np.isnan(NBI)] = 0
filename = finaldir+='/NBI_'+framenum+'.tiff'
cv2.imwrite(filename, NBI)

```

```

        csvname = finaldir+'/statistika_'+framenum+'.csv'
        with open(csvname, 'w') as csvfile:
            fieldnames = ['Naziv indeksa', 'Minimalna vrijednost', 'Maksimalna vrijednost',
'Raspon', 'Medijan', 'Standardno odstupanje']
            writer = csv.DictWriter(csvfile, fieldnames=fieldnames)

            writer.writeheader()
            writer.writerow(stats_calc('BNDVI', BNDVI))
            writer.writerow(stats_calc('GNDVI', GNDVI))
            writer.writerow(stats_calc('GBNDVI', GBNDVI))
            writer.writerow(stats_calc('BWDRVI', BWDRVI))

    except Exception as e:
        print e

```

[uzorci_processing.py](#)

```

import matplotlib.pyplot as plt
import matplotlib.ticker as ticker
import numpy as np
import cv2
import os
import csv

def plot_histogram(index_name, index, outdir):
    hist, bins = np.histogram(index, bins=50)
    width = 0.7 * (bins[1] - bins[0])
    center = (bins[:-1] + bins[1:]) / 2
    fig = plt.figure()
    ax = fig.add_subplot(111)
    ax.yaxis.set_major_formatter(ticker.FuncFormatter(lambda y, pos: int(y*1e-3)))
    ax.set_ylabel("Frekvencija ('000")")
    ax.set_xlabel(index_name)
    ax.grid(True)
    plt.bar(center, hist, align='center', width=width)

    finalname = outdir+'/statistika_'+index_name+'_uzorci.png'

    fig.savefig(finalname)

def stats_calc(index_name, index, outdir):
    minimum = index.min()
    maximum = index.max()
    spread = np.ptp(index)
    med = np.median(index)
    avg = np.average(index)
    var = np.var(index)
    std = np.std(index)
    sigma_3 = 3*std
    donja_granica = avg - sigma_3
    gornja_granica = avg + sigma_3
    raspon_granica = gornja_granica - donja_granica
    stat_rez = ({'Naziv indeksa': index_name, 'Minimalna vrijednost':minimum, 'Maksimalna
vrijednost':maximum, 'Raspon':spread, 'Medijan':med, 'Average':avg, 'Varijanca':var, 'Standardno
odstupanje':std, '3 sigma':sigma_3, 'Donja granica':donja_granica, 'Gornja granica':gornja_granica,
'Raspon granica':raspon_granica})
    csvname = outdir+'/statistika_'+index_name+'_uzorci.csv'
    with open(csvname, 'w') as csvfile:

```

```

        fieldnames = ['Naziv indeksa', 'Minimalna vrijednost', 'Maksimalna vrijednost',
'Raspon', 'Medijan', 'Average', 'Varijanca', 'Standardno odstupanje', '3 sigma', 'Donja granica', 'Gornja
granica', 'Raspon granica']
writer = csv.DictWriter(csvfile, fieldnames=fieldnames)
writer.writeheader()
writer.writerow(stat_rez)

file = 'R_BWDRVI_uzorci.csv'
name = 'BWDRVI'
outdir = '/home/ivan/Desktop/Faks/dolje/NDVI/mojprojekt/projekt/main/rezultati/uzorci'
data = np.genfromtxt(file, delimiter=",")
plot_histogram(name, data, outdir)
stats_calc(name, data, outdir)

```

[ocjena_tocnosti.py](#)

```

import numpy as np
import cv2
import os
import sys
import csv

def usporedi(treba, index, naziv_indexa):
    # Pretvori ulazne podatke u int oblik
    ima = index.astype('int')
    # Kreiraj prazni array istog formata kao sto su slike koje se usporeduju (1920,1080)
    rez = np.zeros(shape = ima.shape, dtype = 'int')
    # Stavi 1 gdje je vegetacija na obje slike
    rez[(ima==1) & (treba==1)]=1
    # Stavi 2 gdje je nevegetacija na ima, a vegetacija na treba
    rez[(ima==1) & (treba==0)]=2
    # Stavi 3 gdje je vegetacija na ima, a nevegetacija na treba
    rez[(ima==0) & (treba==1)]=3
    # Stavi 4 gdje je na obje slike nevegetacija
    rez[(ima==0) & (treba==0)]=4

    ## Kreiraj RGB ispis rezultata u obliku slike
    # Kreiraj 3 prazna arraya
    b = np.zeros(shape = ima.shape, dtype = 'int')
    g = np.zeros(shape = ima.shape, dtype = 'int')
    r = np.zeros(shape = ima.shape, dtype = 'int')
    ## Dodijeli boje za odredjene vrijednosti
    # Rez = 1
    r[rez==1]=78
    g[rez==1]=229
    b[rez==1]=106
    # Rez = 2
    r[rez==2]=208
    g[rez==2]=13
    b[rez==2]=36
    # Rez = 3
    r[rez==3]=21
    g[rez==3]=34
    b[rez==3]=212
    # Rez = 4
    r[rez==4]=0
    g[rez==4]=0
    b[rez==4]=0
    # Spoji kanale kako bi dobio RGB sliku
    rez_colored = cv2.merge((b,g,r))

```

```

## Ispisivanje rezultata usporedbe u obliku slike
# Ispisi rezultatnu sliku u tiff formatu
cv2.imwrite(outdir+'/usporedba_'+naziv_indexa+'_'+str(frame)+'.tiff',rez)
# Ispisi obojanu resultantnu sliku u tiff formatu
cv2.imwrite(outdir+'/usporedba_'+naziv_indexa+'_'+str(frame)+'_colored.tiff',rez_colored)

## Kreiraj rezultat klasifikacije u obliku slike
# Vegetacija (Rez = 1 & Rez = 2), Nevegetacija (Rez = 3 & Rez = 4)
## Dodijeli boje za odredjene vrijednosti
# Rez = 1
r[rez==1]=255
g[rez==1]=255
b[rez==1]=255
# Rez = 2
r[rez==2]=255
g[rez==2]=255
b[rez==2]=255
# Rez = 3
r[rez==3]=0
g[rez==3]=0
b[rez==3]=0
# Rez = 4
r[rez==4]=0
g[rez==4]=0
b[rez==4]=0
# Spoji kanale kako bi dobio RGB sliku
klasifikacija_colored = cv2.merge((b,g,r))

## Ispisivanje rezultata klasifikacije u obliku slike
# Ispisi rezultatnu sliku u tiff formatu
cv2.imwrite(outdir+'/klasifikacija_'+naziv_indexa+'_'+str(frame)+'_bw.tiff',klasifikacija_colored)

## Ispisivanje rezultata usporedbe u obliku tablice
# Kreiraj novi csv file
with open(outdir+'/usporedba_'+naziv_indexa+'_'+str(frame)+'.csv', 'w') as csvfile:
    writer = csv.writer(csvfile)
    # Izracunaj vrijednosti c1, c2, c3 i c4
    c1 = float(np.sum(rez==1))
    c2 = float(np.sum(rez==2))
    c3 = float(np.sum(rez==3))
    c4 = float(np.sum(rez==4))
    # Napravi listu koja ce se ispisati u csv
    lista = [",","Referentna snimka",",",",","Vegetacija","Nevegetacija",'%',[],'Klasificirana snimka','Vegetacija',int(c1),int(c2),(c1/(c1+c2))*100],["Nevegetacija",int(c3),int(c4),(c4/(c3+c4))*100],['%',(c1/(c1+c3))*100,(c4/(c2+c4))*100,((c1+c4)/(c1+c2+c3+c4))*100]]
    # Ispisi vrijednosti iz liste u csv file
    writer.writerows(lista)

#####
####
## Za koristenje skripte treba samo upisati frame, sve se drugo automatski odradjuje
#####
####
frame = 24068
folder = '/home/ivan/Desktop/Faks/dolje/NDVI/mojprojekt/projekt/main/rezultati/ocjena tocnosti/frame_'+str(frame)

# Kreiraj folder u kojem ce se pohranjivati rezultati usporedbe

```

```

outdir = folder+'/ocjena_tocnosti_rezultat'
os.mkdir(outdir)

# Ucitaj sliku rucno klasificiranu u GIMPu
treba_jpeg = cv2.imread(folder+'/NORMAL_'+str(frame)+'_klasificirano.jpeg')

# Razdvoji kanale i iskoristi samo prvi kanal, posto su sva 3 iste vrijednosti.. ostale obrisi
treba,u,v = cv2.split(treba_jpeg)
del(u)
del(v)

# Svedi sve vrijednosti u referentnoj slici na 0 i 1
treba[treba<100]=0
treba[treba>100]=1

# Ucitavanje originalne snimke koja ce se koristiti za racunanje indeksa i razdvajanje kanala
orig_jpeg = cv2.imread(folder+'/NORMAL_'+str(frame)+'.jpeg')
orig_jpeg_float = orig_jpeg.astype('float')
B,G,R = cv2.split(orig_jpeg_float)

# Racunanje BNDVI indeksa i svoddjenje na 1 i 0
num = (R - B)
denum = (R + B)
denum[denum==0] = 1
BNDVI = num/denum
BNDVI[BNDVI < 0.33] = 0
BNDVI[BNDVI > 0.92] = 0
BNDVI[BNDVI != 0] = 1

## Ocjena tocnosti
usporedi(treba, BNDVI, 'BNDVI')

# Racunanje BWDRVI indeksa i svoddjenje na 1 i 0
num = 0.1 * R - B
denum = 0.1 * R + B
denum[denum==0] = 1
BWDRVI = num/denum
BWDRVI[BWDRVI < -0.95] = 0
BWDRVI[BWDRVI > 0.22] = 0
BWDRVI[BWDRVI != 0] = 1

## Ocjena tocnosti
usporedi(treba, BWDRVI, 'BWDRVI')

# Racunanje GBNDVI indeksa i svoddjenje na 1 i 0
num = (R - (G + B))
denum = (R + G + B)
denum[denum==0] = 1
GBNDVI = num/denum
GBNDVI[GBNDVI < -0.14] = 0
GBNDVI[GBNDVI > 0.55] = 0
GBNDVI[GBNDVI != 0] = 1

## Ocjena tocnosti
usporedi(treba, GBNDVI, 'GBNDVI')

# Racunanje GNDVI indeksa i svoddjenje na 1 i 0
num = (R - G)
denum = (R + G)
denum[denum==0] = 1

```

```

GNDVI = num/denum
GNDVI[GNDVI < 0.07] = 0
GNDVI[GNDVI > 0.72] = 0
GNDVI[GNDVI != 0] = 1

## Ocjena točnosti
usporedi(treba, GNDVI)

```

[Priprema_podataka_za_kartu.py](#)

```

import numpy as np
import cv2
import os
import sys
import csv

## Varijable koje zadaje korisnik
# Ulazna putanja je putanja do direktorija koji sadrži snimke za obradu
ulazna_putanja = '/home/ivan/Desktop/export po vremenu'
# Izlazna putanja je putanja do direktorija gdje će se spremiti rezultat u obliku CSV datoteke
izlazna_putanja = '/home/ivan/Desktop/Faks/dolje/NDVI/mojprojekt/projekt/main'
# Naziv izlazne datoteke govori kako će se nazvati izlazna CSV datoteka
naziv_izlazne_datoteke = 'podaci_za_kartu'

with open(izlazna_putanja+'/'+naziv_izlazne_datoteke+'.csv', 'w') as csvfile:
    fieldnames = ['Latitude', 'Longitude', 'Vegetacija(%)']
    writer = csv.DictWriter(csvfile, fieldnames=fieldnames)
    writer.writeheader()
    for naziv_datoteke in os.listdir(ulazna_putanja):
        ulazna_snimka = cv2.imread(ulazna_putanja+'/'+naziv_datoteke)
        ulazna_snimka_float = ulazna_snimka.astype('float')
        B,G,R = cv2.split(ulazna_snimka_float)

        # Racunanje BNDVI indeksa i svodnjene na 1 i 0
        num = (R - B)
        denum = (R + B)
        denum[denum==0] = 1
        BNDVI = num/denum
        BNDVI[BNDVI < 0.33] = 0
        BNDVI[BNDVI > 0.92] = 0

        broj_vegetacija = float(np.sum(BNDVI!=0))
        ukupno_piksela = float(BNDVI.size)
        postotak = broj_vegetacija/ukupno_piksela*100
        postotak_int = int(round(postotak))

        lon = float(naziv_datoteke.split('_')[2].replace('-', '.'))
        lat = float(naziv_datoteke.split('_')[3][:-5].replace('-', '.'))

        dict_za_zapis = ({'Latitude':lat, 'Longitude':lon, 'Vegetacija(%)':postotak_int})
        writer.writerow(dict_za_zapis)

```

2. Karta vegetacije snimljenog područja



Zahvale

Želio bih se zahvaliti profesoru Damiru Medaku i asistentu Mariju Mileru što su mi omogućili izradu ovog rada. Asistentu Mileru također veliko hvala na ustupljivanju automobila i pomoći pri snimanju, te savjetima i znanju prenesenom tijekom izrade rada. Hvala i Geodetskom fakultetu koji je ustupio GoPro kameru. Konačno, hvala Luki Rumori na savjetima i konstantnoj motivaciji te ostalim članovima sobe 64 na ustupljenom prostoru i ugodnoj radnoj atmosferi.

Popis literature

Bakici, T., Almirall, E. & Wareham, J., 2013. A Smart City Initiative: The Case of Barcelona. *Journal of the Knowledge Economy*, 4(2), pp.135–148.

Bannari, A. et al., 1995. A review of vegetation indices. *Remote Sensing Reviews*, 13(1), pp.95–120. Available at: <http://dx.doi.org/10.1080/02757259509532298>.

Blaschke, T. et al., 2011. Collective sensing: Integrating geospatial technologies to understand urban systems-An overview. *Remote Sensing*, 3(8), pp.1743–1776.

Bradley, D.M., Unnikrishnan, R. & Bagnell, J., 2007. Vegetation detection for driving in complex environments. In *Proceedings - IEEE International Conference on Robotics and Automation*. pp. 503–508.

Dare, P.M., 2008. Small Format Digital Sensors for Aerial Imaging Applications. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVII(B1), pp.533–538.

Hancke, G.P., de Silva, B. de C. & Hancke, G.P., 2013. The role of advanced sensing in smart cities. *Sensors*, 13(1), pp.393–425.

Huzak, M. & Slijepčević, S., Opisna statistika. Available at: <https://web.math.pmf.unizg.hr/nastava/stat/files/StatOpisnastat2.pdf>.

Konijnendijk, C.C., 2003. A decade of urban forestry in Europe. *Forest Policy and Economics*, 5(2), pp.173–186.

Lebourgeois, V. et al., 2008. Can commercial digital cameras be used as multispectral sensors? A crop monitoring test. *Sensors*, 8(11), pp.7300–7322.

Milton, E.J., 2002. Low-cost ground-based digital infra-red photography. *International Journal of Remote Sensing*, 23(5), pp.1001–1007. Available at:

[http://www.tandfonline.com/doi/abs/10.1080/01431160110104746.](http://www.tandfonline.com/doi/abs/10.1080/01431160110104746)

Mladinov, V., Osnove statističke obrade. Available at:
http://www.azoo.hr/images/stories/dokumenti/V_Mladinov_Osnove_statisticke_obrane.ppt.

Myneni, R.B. et al., 1995. Interpretation of spectral vegetation indexes. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), pp.481–486.

Nijland, W. et al., 2014. Monitoring plant condition and phenology using infrared sensitive consumer grade digital cameras. *Agricultural and Forest Meteorology*, 184, pp.98–106. Available at: <http://dx.doi.org/10.1016/j.agrformet.2013.09.007>.

Oreški, D., 2014. *Evaluacija tehnika otkrivanja kontrasta za potrebe selekcije atributa radi klasifikacije*.

Ostović, S.K. et al., 2013. Pregled Literature O Vrednovanju Koristi Od Urbanih šuma. *Radovi*, 45(2), pp.161–173.

Pearson, R.L. & Miller, L.D., 1972. Remote Mapping of Standing Crop Biomass for Estimation of the Productivity of the Shortgrass Prairie. *Remote Sensing of Environment*, VIII, -1, p.1355. Available at: <http://adsabs.harvard.edu/abs/1972rse..conf.1355P\npapers2://publication/uuid/4ABE1403-D3C3-40B7-B0A7-6C2C1BFDA6E1>.

Pérez, F., Granger, B.E. & Hunter, J.D., 2011. Python: An ecosystem for scientific computing. *Computing in Science and Engineering*, 13(2), pp.13–21.

Rabatel, G., Gorretta, N. & Labbe, S., 2011. Getting NDVI spectral bands from a single standard RGB digital camera : a methodological approach. In *14th Conference of the Spanish Association for Artificial Intelligence, CAEPIA 2011*. pp. 333–342.

Wang, F.M. et al., 2007. New vegetation index and its application in estimating leaf area index of rice. *Rice Science*, 14(3), pp.195–203. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S1672630807600274>.

Wurm, K.M. et al., 2009. Improving robot navigation in structured outdoor environments by identifying vegetation from laser data. In *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS 2009*. pp. 1217–1222.

URL 1: Most Popular Action Camera: GoPro Hero Black,

<http://lifehacker.com/five-best-action-cameras-1711022789/1711802009>,
(12.04.2016.)

URL 2: GoPro Hero 4 Black,

<http://shop.gopro.com/EMEA/cameras/hero4-black/CHDHX-401-EU.html>,
(12.04.2016.)

URL 3: GoPro Hero4 Black Specifications,

<http://www.cnet.com/products/gopro-hero4-black/specs/>, (12.04.2016.)

URL 4: NDVI-7,

<http://www.irprostore.com/#!about-ndvi-7/fgyzk>, (12.04.2016.)

URL 5: Garmin GLO,

<https://buy.garmin.com/en-US/US/oem/sensors-and-boards/glo-prod109827.html>, (12.04.2016.)

URL 6: Python Programming Language,

<https://www.python.org/>, (13.04.2016.)

URL 7: OpenCV,

<http://opencv.org/about.html>, (13.04.2016.)

URL 8: SOES Introduction to Remote Sensing,

<http://www.seos-project.eu/modules/remotesensing/remotesensing-c01-p05.html>, (13.04.2016.)

URL 9: Fotografija,

<http://fotografija.hr/histogram/>, (26.04.2016.)

URL 10: Histogram,

<http://www.songho.ca/dsp/histogram/histogram.html>, (26.04.2016.)

URL 11: Leard statistics,

<https://statistics.laerd.com/statistical-guides/measures-of-spread-standard-deviation.php>, (26.04.2016.)

URL 12: IBM Knowledge Center,

http://www.ibm.com/support/knowledgecenter/SSEP7J_10.2.0/com.ibm.swg.ba.cognos.ug_cr_rptstd.10.2.0.doc/c_id_rs_stats.html%23id_rs_stats?lang=hr,
(26.04.2016.)

URL 13: PEP 6305 Measurement in Health & Physical Education,

<http://grants.hhp.coe.uh.edu/doconnor/PEP6305/Topic%20005%20Normal%20Distribution.htm>, (26.04.2016.)

URL 14: Binary Classification,

http://www.cse.iitk.ac.in/users/se367/10/presentation_local/Binary%20Classification.html, (26.04.2016.)

URL 15: GIMP,

<https://www.gimp.org/about/introduction.html>, (26.04.2016.)

URL 16: QGIS,

<https://www.qgis.org/en/site/about/>, (26.04.2016.)

Sažetak

Ivan Majić

Detekcija urbane vegetacije snimanjem georeferenciranog videozapisa modificiranim GoPro kamerom

Zbog brzorastućeg trenda urbanizacije, urbana je vegetacija danas od iznimne važnosti. Ako želimo da rast gradova bude održiv i ekologija očuvana, trebamo razviti pametan i iskoristiv sustav za bolje praćenje urbane vegetacije. Ovaj rad ispituje mogućnost korištenja modificirane GoPro kamere za detekciju urbane vegetacije. Kamera je modificirana tako da je standardna leća zamijenjena sa NDVI-7 lećom kako bi se mogli prikupljati plavi, zeleni i blisko-infracrveni kanal. Georeferencirani videozapis snimljen je iz automobila. Ispitane su performanse četiri odabrana vegetacijska indeksa: BNDVI, GNDVI, GBNDVI i BWDRVI. Na temelju izračunatih vrijednosti tih indeksa izvršena je binarna klasifikacija scene sa ciljem da se svi objekti razvrstaju u klase vegetacija i nevegetacija. Ocjena točnosti klasifikacije izvršena je pomoću matrice konfuzije, a pokazala je da BNDVI daje najbolje rezultate. Taj je indeks konačno korišten za klasifikaciju cijelog snimljenog područja kako bi se za njega izradila karta vegetacije.

Ključne riječi: urbana vegetacija, detekcija vegetacije, GoPro, BNDVI, georeferencirani video

Summary

Ivan Majić

Urban vegetation detection using georeferenced video captured by modified GoPro camera

Because of fast-growing urbanization, urban vegetation is nowadays particularly important. If we want these cities to have sustainable growth and well-kept ecology, we need to develop a smart and usable system for better urban vegetation monitoring. This paper examines the possibility of using modified GoPro camera for this task. The standard lens of the camera is replaced with NDVI-7 lens in order to obtain blue, green and near-infrared channel. Georeferenced video was captured from a car. Then the performance of four selected vegetation indices was tested: BNDVI, GNDVI, GBNDVI, BWDRVI. Based on the values of these indices, binary classification was made in order to classify all object in the scene as either vegetation or nonvegetation. After that, the accuracy rating of every index was carried out by the use of confusion matrix. The accuracy rating showed that BNDVI gives the best results. This index was ultimately used to classify the entire surveyed area, so that the vegetation map could be made.

Key words: urban vegetation, vegetation detection, GoPro, BNDVI, georeferenced video