

USPOREDBA ALGORITAMA ZA KARTIRANJE OBALNE CRTE SATELITSKIM METODAMA

Prof. dr. sc. Tea Duplančić Leder
Fakultet građevinarstva, arhitekture
i geodezije Sveučilišta u Splitu
Mätze hrvatske 15, 21000 Split
tleder@gradst.hr

Doc. dr. sc. Nenad Leder
Pomorski fakultet Sveučilišta u Splitu
Ruđera Boškovića 37, 21000 Split

U radu su prikazane metode određivanja obalne crte, a detaljnije je prikazana metoda korištenja algoritama daljinske detekcije. Analizirani su rezultati najčešće korištenih algoritama vodenih indeksa: NDWI, MNDWI, AWEI_nsh, AWEI_sh i WRI, koji se koriste za potrebe određivanja obalne crte ili općenito vodenih površina. Algoritmi su primjenjeni na Landsat 8 i Sentinel 2 satelitskim scenama, a kao testno područje je odabrana srednja Dalmacija. Nakon izračuna vodenih indeksa, na područjima je provedena nenadzirana klasifikacija, zatim reklassifikacija i na kraju je prikazana ocjena točnosti klasifikacije pojedinog indeksa. Rezultati su u krupnijem mjerilu prikazani na dva područja: ušće rijeke Jadro u Solinu i ušće rijeke Cetine u Omišu. Analiza rezultata je pokazala da najbolje rezultate daje NDWI, a najlošije AWEI_nsh vodići indeks.

Ključne riječi: vodeni indeksi, obalna crta, daljinska detekcija, Landsat 8, Sentinel 2

1. UVOD

Obalna crta je fizikalno-geografski pojam koji predstavlja granicu između mora i kopna te ovisi o oscilaciji razine mora. Prema Međunarodnoj hidrografskoj organizaciji (International Hydrographic Organization - IHO) većina pomorskih zemalja definira obalnu crtu kao presjek srednje razine visokih voda (SRW, eng. Mean High Water - MHW) (IHO, 2005) s kopnom. U Republici Hrvatskoj obalna je crta definirana kao ploha geoida određena srednjom razinom visokih voda na mareografima u Dubrovniku, Splitu, Bakru, Rovinju i Kopru u epohi 1971.5" i naziva se "Hrvatski referentni sustav obalne crte za epohu 1971.5 – skraćeno HRSOC71" (Domijan i dr., 2005.).

Obalno područje (prema Programu Ujedinjenih naroda za zaštitu okoliša) označava geomorfološko područje s obje strane obalne crte, u kojem se međudjelovanje pomorskih i kopnenih zona odvija kroz složene ekološke sustave (biotske i abiotske), životni prostor ljudskih zajednica i njihovih društveno-

gospodarskih aktivnosti. To područje je geografski definirano vanjskom granicom teritorijalnog mora i pojasom kopna do prve cestovne ili željezničke komunikacije u užem smislu, odnosno do vrha prve planine u širem smislu (UNEP, 2002.).

Obalna zona obično uključuje obalu mora (oceana), kao i dio kopna koji s njim graniči i na kojega more ima utjecaj (Duplančić Leder i Leder, 2009.). Obalna zona je dinamičan prostor intenzivne gradnje i eksploracije te se nalazi pod utjecajem intenzivnih klimatskih promjena (podizanje razine mora) koje utječu na njenu morfologiju.

Određivanje i praćenje položaja obalne crte važna je zadaća obalnog inženjerstva i koristi se za širok raspon aplikacija, ali i kao osnova za određivanje granice teritorijalnog mora (Duplančić Leder i dr., 2008.). Zbog prostorno-vremenskih varijacija kopna i oscilacija razine mora, obalne crte se moraju kontinuirano redefinirati i određivati.

Republika Hrvatska ima relativno dugu obalnu crtu koja se sastoji od 1880 km kopnene obale i 4398 km otočne obale ili ukupno 6278 km (Duplančić Leder i dr., 2004.), što je čini drugom najrazvedenijom obalom na Mediteranu, iza Grčke.

Obala ima četverodimenzionalni karakter, odnosno mijenja se u prostoru i vremenu. Dnevne ili poludnevne oscilacije nazivaju se morskim mijenama i predstavljaju oscilacije razine mora (visoka i niska voda), a rezultat su utjecaja Sunca i Mjeseca (slika 1). Najintenzivnije se promjene događaju kao posljedica ljudskog utjecaja kao što su izgradnja hidrotehničkih zahvata (luke, lučice, lukobrani itd.). Mehanički efekti valova i morskih struja mnogo sporije utječu na varijabilnost obale. Najsporije efekte uzrokuju klimatske promjene. Prema podatcima Hidrografskog instituta (podatci od 1955.-2009. godine) na Jadranu je nedavno uočeno značajnije podizanje razine mora (Leder i dr., 2010.) pa će se u skoroj budućnosti trebati uspostaviti novi vertikalni datum, odnosno preračunati na novu epohu, za razliku od epohe 1971.5, koja je trenutno na snazi.

Obalna se crta kod kopnenih podataka (Državna geodetska uprava) i kod pomorskih podataka (Hrvatski hidrografski institut) obično prikazuju u različitim koordinatnim sustavima, različitim projekcijama i datumima (horizontalnim i vertikalnim).

Nekoliko klasičnih (geodetskih) metoda koje su se koristile za određivanje obalne crte Republike Hrvatske

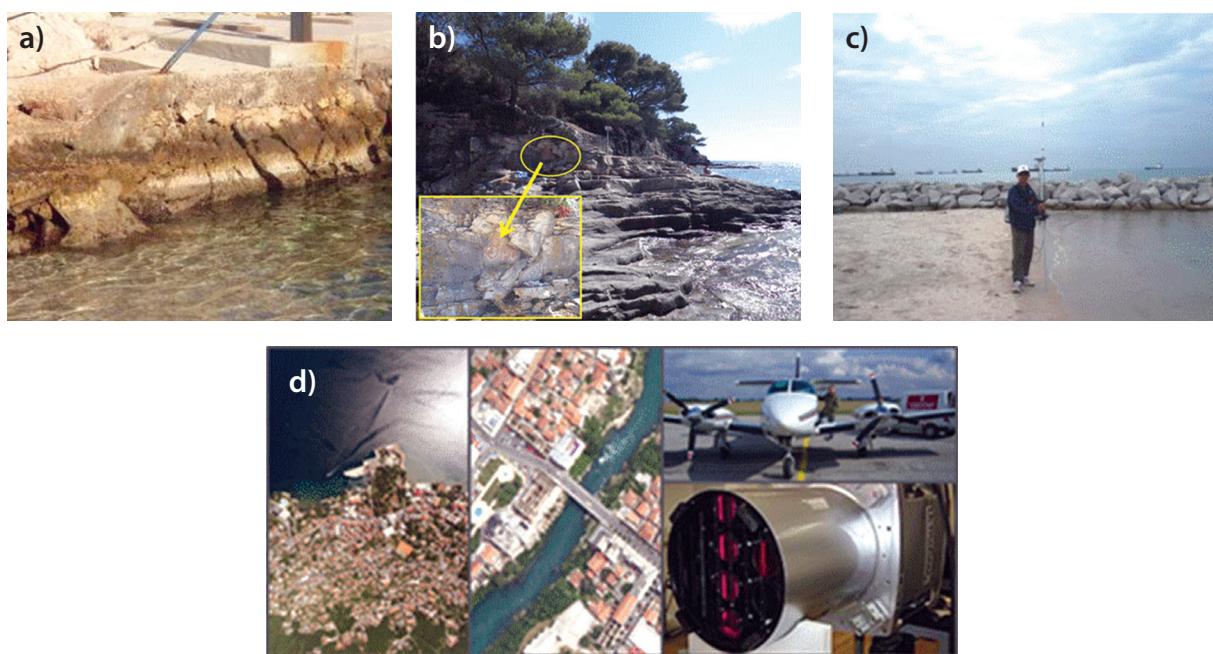
opisuju Jovanović (1978.) i Leder i Duplančić Leder (2011.):

- Topografska ili tahimetrijska je najjednostavnija metoda određivanja obalne crte prema tragovima algi na obalnom rubu (litoralna zona) pogodna za primjenu na strmim i blago nagnutim kamenim obalama (oko 90 % jadranske obale; slika 2a);
- Nivelmanska metoda određuje obalnu crtu dugotrajnim i preciznim mareografsko-nivelmanskim radovima (slika 2b);
- Obilježavanje obalne crte kolcima ili bojom u vremenskom periodu srednje razine visoke vode (SRVV), koji se nakon toga snimaju geodetskim metodama (slika 2c);
- snimanjem direktnim aerofotogrametrijskim metodama i naknadna korekcija za visinu morskih mijena (slika 2d).

Od klasičnih geodetskih metoda najtočnije rezultate pri određivanju obalne crte daje metoda obilježavanja obalne crte u vrijeme nastupa srednje razine visoke vode (SRVV). Velika točnost je prednost ove metode, pa seugo vremena koristila za izradu hidrografskih originala krupnog mjerila, a manje su dugotrajnost hidrografsko-geodetskih mjerena i njihovi veliki troškovi, budući se procjenjuje da bi njezinom primjenom trebalo oko 6,5 godina intenzivnih mjerena za određivanje obalne crte Republike Hrvatske (Jovanović, 1978.; Leder i Duplančić Leder, 2011.).



Slika 1: Oscilacije razine mora u vremenskom intervalu između visoke (crveno) i niske vode (žuto) na plaži Bačvice u Splitu (gore) i u uvali Čisti dol na otoku Hvaru (dolje)



Slika 2: Topografska ili tahimetrijska metoda (a); Nivelmanska metoda (b); Obilježavanje obalne crte za vrijeme srednje razine visokih voda (preuzeto od <https://www.usgs.gov>); c) i Aerofotogrametrijska metoda (preuzeto od <https://www.usgs.gov>; d)

Osim klasičnih (geodetskih) metoda, u posljednje se vrijeme koriste nove metode snimanja obalne crte i to:

- a) Registracija obale snimanjem video sustavima na obali koji kontinuirano prikupljaju podatke (*slika 3a*) te daju dobre rezultate na strmim, a lošije na ravnim obalama (Tappin i dr., 2012.). Identifikacija obale je automatizirana praćenjem vrijednosti nijansi (eng. hue) i zasićenosti (eng. saturation) prostornih piksela na vremenskom nizu uzastopnih slika. Postignuta točnost vertikalne komponente je 15 cm na 85% obale, što odgovara vodoravnom pomaku od 6 m. Koristi se u Nizozemskoj i Australiji;
- b) Metoda snimanja topografsko-batimetrijskim LiDAR-om (*slika 3b*) koja objedinjava dva osnovna niza podataka: digitalni model priobalne zone i podmorja s obalnom crtom (Quadros i Collier, 2008.). Digitalni model podmorja se dodatno matematički interpolira podacima mareografskih mjerena ili hidrodinamičkim modelom morskih mijena;

- c) Satelitske metode razvijene za automatizirano određivanje vodenih površina pomoću satelitskih scena daljinske detekcije. Metode dijelimo na metode aktivnih satelitskih misija (Guerrener Robinson i dr., 2013.; Čotar i dr., 2016.; Rubinčić, 2018.) i metode pasivnih satelitskih misija (Jiang i dr., 2014.).

Prednost navedenih novijih metoda određivanja obalne crte u odnosu na klasične metode je znatno kraće vrijeme prikupljanja podataka za isto područje istraživanja, a mana manja točnost. Iz tog se razloga, za potrebe sigurnosti plovidbe, novije metode mogu koristiti samo za izradu pomorskih navigacijskih karata sitnijeg mjerila i nikako se ne smiju koristiti za izradu službenih navigacijskih planova krupnog mjerila (krupnijeg od 1: 5000).

Autorima ovog rada nisu poznati rezultati usporedbе točnosti snimanja obalne crte koje postižu navedene novije metode snimanja.



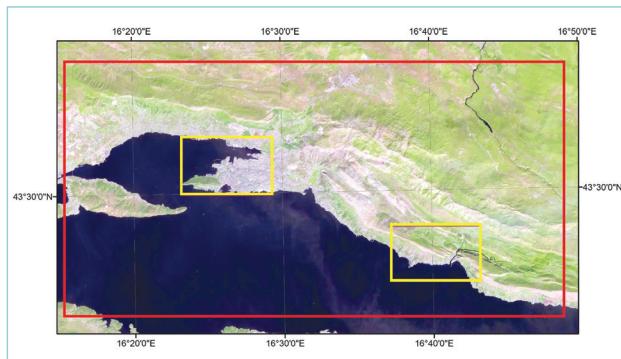
Slika 3: Registracija obale video snimanjem (a) preuzeto od <http://www.coastalwiki.org>) i Metoda snimanja topografskim i batimetrijskim LiDAR-om (b) (preuzeto od <https://oceanservice.noaa.gov/education/seafloor-mapping/lidar>.)

Cilj ovog rada je ukratko prikazati satelitske metode daljinske detekcije za određivanje obalne crte primjenom metoda izračuna vodenih indeksa. To su automatizirane i relativno jeftine i brze metode čiji se algoritmi zasnivaju na algebarskim operacijama s dva ili više spektralnih kanala. Metoda je testirana na području srednje Dalmacije, a kao podatci su u radu korištene besplatne satelitske scene Landsat 8 i Sentinel 2. Uspoređeni su rezultati točnosti određivanja obalne crte dobiveni primjenom odabranih vodnih indeksa te se preporučila njihova upotreba za različite kartografske namjene.

2. MATERIJALI I METODE

2.1. Područje istraživanja

Kao testno područje uzeto je srednje dalmatinsko područje šire okolice grada Splita (slika 4). Testno područje pokriva površinu 1.040 km² i proteže se na prostoru od 43°24'08" N geodetske širine i 16°15'15" E geodetske duljine do 43°36'09" N geodetske širine i 16°49'04" E geodetske duljine i prikazano je crvenom bojom na slici 4. Čitavo područje testirano je i ocijenjeno s pet vodnih indeksa, a rezultati su, radi boljeg uvida, prikazani na dva karakteristična krupnija područja ušća rijeke Jadro i ušća rijeke Cetine (žuti okvir) na kojima se može pratiti morski i riječni prostor. Rijeka Jadro se ulijeva u Jadransko more u Solinu (43°32'05" N; 16°28'34" E), dok se rijeka Cetina ulijeva u Jadransko more kod grada Omiša (43°26'36" N; 16°41'35" E). Za krupnija su područja odabrana dva utoka rijeka u more na kojima se može prikazati svršishodnost metode na dvama medijima, slanoj i slatkoj vodi.



Slika 4: Testno područje (crveno) te dva krupnija područja ušća Jadra i Cetine (žuto)

2.2. Podatci

Za potrebe ovog rada su se kao optimalan izbor podataka pokazale dvije besplatne satelitske misije: Landsat 8 i Sentinel 2. Za potrebe istraživanja koristile su se satelitske scene s početka rujna 2018. godine (tablica 1).

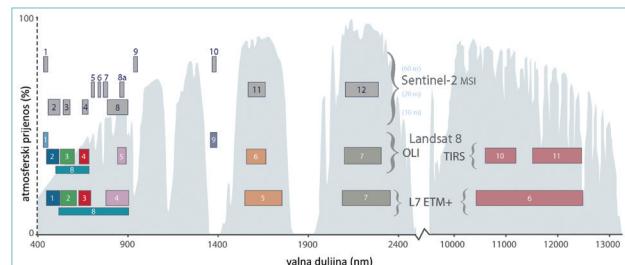
Posljednja od serije najdugovječnijih NASA-inih (National Aeronautics and Space Administration)

multispektralnih satelitskih promatračkih misija je Landsat 8 (lansirana početkom 2013.). Misija ima 2 senzora Operational Land Imager (OLI) i Thermal Infrared Sensor (TIRS). Vremenska rezolucija je 16 dana, a širina scene je 185 km. OLI omogućuje snimanje zemljine površine u 9 spektralnih kanala: 8 je spektralnih intervala u području vidljivog i infracrvenog elektromagnetskog zračenja prostorne rezolucije 30 m i širokopojasni pankromatski kanal prostorne rezolucije 15 m. TIRS u dva spektralna kanala prikuplja podatke u području daljeg ili termalnog infracrvenog dijela spektra, a prostorna rezolucija im je 100 m. (slika 5). Podaci misije su besplatno preuzeti putem USGS EarthExplorer pretraživača (<https://earthexplorer.usgs.gov/>).

Besplatna satelitska ESA (European Space Agency) promatračka misija Sentinel 2 (Sentinel-2A i Sentinel-2B, lansirane 2015. i 2017. godine) dio je Copernicus satelitskog programa (Sentinel 1-10). Sentinel 2 je satelit s ugrađenim multispektralnim senzorom koji registrira podatke u 13 spektralnih kanala u vidljivom, blizu infracrvenom (NIR) i kratkovalnom infracrvenom (SWIR) dijelu spektra (slika 5). Prostorna rezolucija kanala je 10, 20 i 60 m (slika 5), vremenska rezolucija je 5 dana, a širina scene je 290 km. Sentinel podatci su besplatno preuzeti na portalu Copernicus Open Access Hub (<https://scihub.copernicus.eu/>), dok se atmosferske, geometrijske i cirrus korekcije „sirovih“ scena mogu provesti SEN2COR programom otvorenog koda.

Tablica 1: Korištene satelitske snimke

Senzor	Datum	Izvor
Landsat 8	06-09-2018	USGS Earth Explorer
Sentinel 2A	10-09-2018	Copernicus Open Access Hub



Slika 5: Usporedba kanala, valnih duljina i rezolucije Landsat 8 i Sentinel 2 satelitskih misija (preuzeto od NASA, 2018.)

2.3. Metodologija

Automatizirane metode određivanja vodenih površina pomoći daljinske detekcije dijelimo na metode aktivnih satelitskih misija i metode najčešće korištene pasivnih satelitskih misija, koje dijelimo u tri kategorije (Jiang i dr., 2014.):

1. Metoda spektralnih kanala identificira vodene površine nalaženjem pragova na jednom ili više

- spektralnih kanala. Jednostavna je za primjenu, ali često pogrešno klasificira sjene nastale zbog topografije, urbanih područja ili drugih pozadinskih nepravilnosti (Rundquist i dr., 1987.);
2. Metoda klasifikacije primjenjuje nadzirane ili nenadzirane algoritme strojnog učenja (eng. machine learning) za izdvajanje vodenih površina (Otukei & Blaschke, 2010.).
 - a) Nadzirane klasifikacije najčešće koriste sljedeće metode: klasifikator najveće vjerojatnost (eng. maximum likelihood classifiers), stabla odluke (eng. decision trees), umjetne neuronske mreže (eng. artificial neural networks) te strojne vektorske podrške (eng. support vector machines);
 - b) Nenadzirane klasifikacije kao metode koriste: K-means i iterativnu samoorganizirajuću analizu podataka (eng. iterative self-organizing data analysis - ISODATA) (Lu & Weng 2007.; Otukei & Blaschke, 2010.).
- Klasifikacijom se postižu dobri rezultati, ali je prethodno potrebno iskustvo u poznavanju terena ili postojeći referentni podaci odabranih uzoraka, što otežava primjenu metoda na manje poznatom terenu;
3. Metoda vodenih indeksa kombinira različite algebarske operacije nad dva ili više spektralnih kanala za poboljšanje razlike između vode i tla (Jiang i dr., 2014.; Lu i Weng, 2007.; Horvat, 2014.). Za određivanje vodenih površina se najčešće koriste sljedeći indeksi:
 - a) Normalizirani diferencijalni vodeni indeks (Normalized Difference Water Index - NDWI) (McFeeters, 1996.);
 - b) Modificirani normalizirani diferencijalni vodeni indeks (Modified Normalized Difference Water Index - MNDWI) (Xu, 2006; Du i dr. 2016.);
 - c) Automatizirani indeks ekstrakcije vode (Automated Water Extraction Index – AWEI) (Feyisa i dr., 2014.);
 - d) Indeks vodenih omjera (Water Ratio Index - WRI) (Shen i Li, 2010.).

U posljednje se vrijeme mnogi autori bave poboljšanjem rezultata i kvalitete vodenih indeksa (Baiocchi i dr., 2014.; Maglione, i dr., 2014.; Elsahabi i dr., 2016., Mukherjee & Samuel, 2016.; Kaplan & Avdan, 2017.) na satelitskim senzorima. Neki su autori počeli uspoređivati više indeksa na više senzora, pa tako Kwang i dr. (2018.) uspoređuju točnost 4 vodena indeksa na 2 senzora, Zou i dr. (2017.) uspoređuju 9 indeksa na 3 senzora.

2.3.1. Normalizirani diferencijalni vodeni indeks (NDWI)

Normalizirani diferencijalni vodeni indeks (Normalized Difference Water Index - NDWI) prvi je predloženi vodeni indeks, koji je predložio McFeeters

(1996.), za kartiranja i isticanja značajki vodenih površina daljinskom detekcijom. Algoritam koristi blizu infracrvene (eng. near infrared - NIR) i zelene valne duljine (Green) za prikazivanje vodenog indeksa.

Matematički, normalizirani diferencijalni vodeni indeks prema McFeetersu je izražen kao:

$$\text{NDWI} = (\text{Green} - \text{NIR}) / (\text{Green} + \text{NIR}) \quad (1)$$

Algoritam koristi činjenicu da se infracrveno zračenje dobro reflektira od vodenih površina, dok zeleno zračenje dobro prodire u vodenim stupacima. Njime se smanjuju refleksije od površina kao što su vegetacija i golo tlo u NIR kanalu i istodobno maksimalizira refleksiju vode u zelenom kanalu. Vrijednost indeksa varira od -1 do 1, pri čemu pozitivne vrijednosti prikazuju vodene površine, a negativne vrijednosti pokazuju ostala područja. NDWI ima sposobnost otkrivanja zamućenosti vode (McFeeters, 1996.), a glavni mu je nedostatak nemogućnost odvajanja izgrađenog zemljišta od vodenih tijela, što dovodi do precjenjivanja svojstva ekstrakcije vode (Xu, 2006.; Yang i dr., 2017.).

2.3.2. Modificirani normalizirani diferencijalni vodeni indeks (MNDWI)

Xu (2006.) je modificirao McFeetersov indeks tako što je zamijenio blizu infracrveni (NIR) s kratkovalnim infracrvenim (eng. Shortwave Infrared - SWIR) kanalom i dobiva modificirani normalizirani diferencijalni vodeni indeks. Prema Xu, preporučeni model poboljšava ekstrakciju vodenih značajki, naročito nad izgrađenim područjima, odnosno reducira i uklanja šum izgrađenog područja.

MNDWI je Xu (2006.) matematički izrazio kao:

$$\text{MNDWI} = (\text{Green} - \text{SWIR}) / (\text{Green} + \text{SWIR}) \quad (2)$$

Tri se rezultata očekuju korištenjem MNDWI modela; (1) veće pozitivne vrijednosti za vodu, jer voda apsorbira više SWIR od NIR zračenja; (2) negativne vrijednosti za izgrađeno zemljište zbog više refleksije u SWIR području, nego u NIR području i (3) tlo i vegetacija imaju negativne vrijednosti (Xu, 2006.).

2.3.3. Automatizirani indeks vodene ekstrakcije (AWEI)

Automatizirani indeks vodene ekstrakcije (Automated Water Extraction Index - AWEI) predlažu Feyisa i dr. (2014.), koji daje bolje rezultate u područjima sa sjenama i tamnim površinama, kao i stabilnu vrijednost praga vodenih svojstava od ostalih površinskih značajki. AWEI primjenom različitih koeficijenata pojačava razliku vodenih od nevodenih površina. Predložena su dva automatizirana indeksa vodene ekstrakcije; jedan za učinkovito uklanjanje zasjenjenih piksela (AWEI_nsh)

i drugi (AWEI_sh) za uklanjanje nevodenih i tamnih urbanih površina (Feyisa i dr., 2014.) i mogu se koristiti u različitim okolišnim uvjetima.

Matematički, AWEI indeksi se prikazuju kao matematičke operacije nad dva vidljiva kanala Green i Blue te infracrvenim kanalima NIR i SWIR 1 i 2 (Landsat 8 kanali 6 i 7 i Sentinel 2 kanali 11 i 12; [slika 5](#)):

$$\text{AWEI_nsh} = 4 \times (\text{Green} - \text{SWIR1}) - (0,25 \times \text{NIR} + 2,75 \times \text{SWIR2}) \quad (3)$$

$$\text{AWEI_sh} = \text{Blue} + 2,5 \times \text{Green} - 1,5 \times (\text{NIR} + \text{SWIR1}) - 0,25 \times \text{SWIR2} \quad (4)$$

Primjeri korištenja: (1) AWEI_sh se koristi kod područja tamnih sjena poput snijega, leda i visokog albeda izgrađenih površina; (2) kod područja bez sjene se koristi AWEI_nsh; (3) korištenje AWEI_sh i AWEI_nsh kod visokog albeda površine i sjenovitih/tamnih površina; (4) kada nema sjene, nema tamnih gradskih pozadina i bez visokog albeda, preporuča se korištenje AWEI_sh ili AWEI_nsh (Feyisa i dr., 2014.).

2.3.4. Indeks vodenih omjera (WRI)

Indeks vodenih omjera (Water Ratio Index - WRI) predlažu Shen i Li (2010.) kao omjer između ukupne spektralne refleksije crvenih (Red) i zelenih (Green) valnih duljina u odnosu na ukupnu spektralnu refleksiju blizu infracrvenog (NIR) i kratkovalnog infracrvenog (SWIR) kanala.

WRI matematički izražava operacije nad vidljivim kanalima Green i Red te kanalima NIR i SWIR iz infracrvenog područja:

$$\text{WRI} = (\text{Green} + \text{Red}) / (\text{NIR} + \text{SWIR}) \quad (5)$$

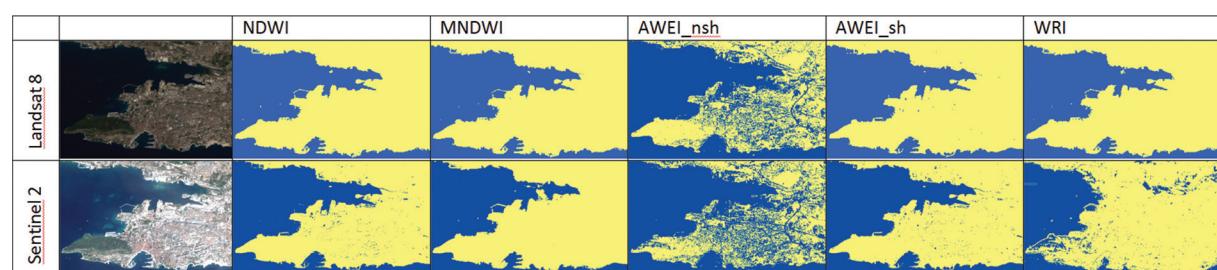
2.4. Nenadzirana klasifikacija

Nakon izračuna vodenih indeksa napravljena je nenadzirana klasifikacija, čime su slikovni elementi (pikseli) raspoređeni u razrede obzirom na njihovo prirodno združivanje u spektralnom prostoru. Za razliku od nadzirane klasifikacije, u prvom koraku nam nisu potrebna znanja o površini scene koju želimo klasificirati, što je pogodno za određivanje vodenih površina prostora koje ne poznajemo dovoljno. Postupak nenadzirane klasifikacije se izvodi u dvije faze: grupiranje (združivanje u razrede) i nakon toga prepoznavanje razreda. Prilikom klasifikacije se koristio matematički algoritam ISODATA klasifikacije, a dobivene su 2 osnovne klase površina: vodene i nevodene površine.

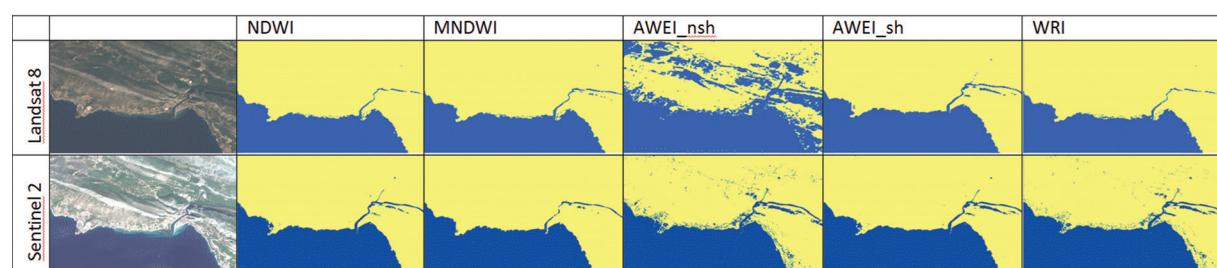
Nakon provedene klasifikacije ispitani su ukupna točnost (u %) i Kappa koeficijent izlazne klasifikacije za određeni voden indeks. Točnost klasifikacije izražena je pomoću parametara matrice pogrešaka ili konfuzije (Congalton i Green, 2009.). Kontrolni ili referentni skup, koji se sastoji od 100 nasumično stratificiranih uzoraka (uzetih s vektoriziranih topografskih i hidrografske karata krupnijeg mjerila) u dvije klase, uspoređen je s rezultatima klasifikacije u programu ArcGIS Desktop 10.6. Izračunate točnosti i Kappa koeficijenti iz matrice konfuzije prikazane su u [tablici 2](#) (Ayyanna i dr., 2018.; FAO, 2016.; Mohd Hasmadi i dr., 2009.; Pontus Olofsson i dr., 2014; Rwanga i Ndambuki, 2017.).

3. REZULTATI I DISKUSIJA

U radu je testirano 5 algoritama vodenih indeksa na Landsat 8 i Sentinel 2 satelitskim snimkama, što ukupno



Slika 6: Rezultati vodenih indeksa izračunati za testno područje ušća rijeke Jadro: a) NDWI; b) MNDWI; c) AWEI_nsh; d) AWEI_sh i e) WRI



Slika 7: Rezultati vodenih indeksa izračunati za testno područje ušća rijeke Cetine: a) NDWI; b) MNDWI; c) AWEI_nsh; d) AWEI_sh i e) WRI

Tablica 2: Ukupna točnost i Kappa koeficijent klasifikacije za Landsat 8 i Sentinel 2 scene

Landsat 8					
	NDWI	MNDWI	AWEI_sh	AWEI_nsh	WRI
točnost (%)	99,87	99,90	90,16	99,84	99,84
Kappa	0,98	0,98	0,64	0,95	0,88
Sentinel 2					
	NDWI	MNDWI	AWEI_sh	AWEI_nsh	WRI
točnost (%)	99,96	99,77	98,74	99,95	99,09
Kappa	0,98	0,98	0,86	0,99	0,98

čini 10 rezultata. Vodenii indeksi su izračunati na testnom području šire okolice grada Splita ([crveni okvir slika 4](#)), a detaljno su prikazani za dva ogledna područja: ušće rijeke Jadro ([žuti okvir na slici 4; slika 6](#)) i ušće rijeke Cetine u more ([žuti okvir slika 4; slika 7](#)), što ukupno čini 20 kombinacija rezultata. Satelitske snimke su snimljene početkom rujna s razmakom od 4 dana (Landsat 8 - 06.09.2018.; Sentinel 2 - 10.09.2018.), u sušno doba godine s ujednačenim dnevnim temperaturama (Landsat 8 - 20-28°C; Sentinel 2 - 20-31°C) bez velikih oscilacija.

Analiza dobivenih rezultata pokazuje da vrlo dobre vrijednosti kod objiju satelitskih scena daju NDWI, MNDWI, AWEI_nsh i WRI indeksi, dok AWEI_sh daje nešto slabije rezultate. Najbolji rezultati kod Landsat 8 scena dobili su se primjenom MNDWI indeksa, dok su kod Sentinel 2 scena najbolji rezultati dobiveni s NDWI indeksom. Od pet analiziranih vodenih indeksa, NDWI, MNDWI, AWEI_nsh i WRI daju preko 99 % točnosti, što su zadovoljavajući rezultati za potrebe računanja obalne crte, dok AWEI_sh daje nešto slabije rezultate od 90 % točnosti klasifikacije.

Ukupne točnosti ispitivanih algoritama su u rasponu od 90,16 do 99,96 %, a srednja vrijednost ukupne točnosti svih rezultata iznosi 98,71 %. Srednja vrijednost ukupne točnosti za Landsat 8 scena iznosi 97,92 %, a srednja vrijednost bez najgoreg rezultata (AWEI_sh) iznosi 99,87 %. Srednja vrijednost ukupne točnosti za Sentinel 2 iznosi 99,50 %, dok srednje vrijednosti bez najgoreg rezultata iznosi 99,69.

Kappa koeficijenti ispitivanih algoritama variraju od 0,64 do 0,99, a srednja vrijednost Kappa koeficijenata svih rezultata iznosi 0,92. Srednja vrijednost Kappa koeficijenata Landsat 8 scena iznosi 0,89, a srednja vrijednost bez najgoreg rezultata iznosi 0,95. Srednja vrijednost Kappa koeficijenata za Sentinel 2 iznosi 0,96, bez najgoreg rezultata iznosi 0,98.

Općenito se može reći da svi izračunati vodenii indeksi imaju vrlo visoku točnost, veću od 99 %, osim AWEI_sh indeksa. Važno je istaknuti da se upotrebo-

ma satelita postiže točnost veća od 99 %, osim za AWEI_sh indeks ([tablica 2](#)). Najbolji rezultati postignuti su upotrebom Sentinel 2 satelita i NDWI indeksa (99,96 %), a Landsat 8 je ostvario najbolji rezultat primjenom MNDWI indeksa (99,90 %). Dakle, radi se o normaliziranom diferencijalnom indeksu (NDWI) kojeg je predložio McFeeters (1996.) i njegovoj modificiranoj verziji MNDWI koju je predložio Xu (2006.).

Usporedba rezultata ovog rada s nekim dosada objavljenim radovima nije egzaktna, budući da autori ne koriste iste senzore, niti slična područja, a scene nisu nastale u jednakim meteorološkim situacijama niti godišnjim dobima, a neki od autora ne navode broj kontrolnih točaka. Tako npr. Kwang i dr., 2018. testiraju 4 vodenii indeksa na testnom području od 180x180 km rijeke Volta u Gani i dobiva nešto bolje rezultate. Zou i dr., 2017. testiraju 5 vodenih indeksa (4 su zajednička) na području 15x20 km, a rezultate prikazuju na unutarnjim vodama i plitkom obalnom području koja daju bolje rezultate, a ukupni rezultati su nešto lošiji. Dakle, općenito se može zaključiti da se rezultati ovog istraživanja podudaraju s rezultatima dosadašnjih istraživanja vodenih indeksa.

Za potrebe ekstrakcije vodene površine pomoću vodenih indeksa treba odabratи prikladne satelitske scene nastale u optimalnim atmosferskim prilikama. Za testno bi područje trebalo birati satelitske scene nastale nakon bure, kada imamo čiste snimke bez puno oblaka i vlage u zraku, kako bi imali čisti prijelaz između kopna i mora.

Problemi koji se javljaju korištenjem metode vodenih indeksa su pronalaženje malih vodenih površina koja se gube zbog prostorne rezolucije satelitskih scena (30 m kod Landsata i 10-20 m kod Sentinel-a), kao i lošiji rezultati metode u planinskim područjima (sjene) te u urbanim i izgrađenim područjima u kojima je prisutno dosta šumova u rezultatima.

Na odabranim se područjima, nadalje, može zapaziti da se nešto bolji rezultati postižu na određivanju morsko-kopnene od riječno-kopnene granice ([slike 6 i 7](#)).

4. ZAKLJUČAK

U suvremeno doba, kada se prostorne promjene događaju često, osobito u obalnom području, javlja se potreba za brzim i učinkovitim kartiranjem promjena na obalnoj crti. U prošlosti su se za određivanje obalne crte koristile klasične geodetske metode, a zadnjih desetak godina, zbog brzog napretka tehnologije, koriste se metode daljinske detekcije. Najnoviji pristup kartiranju obalne crte pomoću satelitskih snimaka se koristi u posljednjih nekoliko godina i pokazao se zadovoljavajući, posebno za upotrebu na kartama sitnih mjerila.

Za određivanje obalne crte satelitskim metodama koriste se specijalizirani algoritmi dobiveni kombiniranjem satelitskih spektralnih kanala u optičkom i infracrvenom dijelu spektra. Od pet analiziranih vodenih indeksa, NDWI, MNDWI, AWEI_nsh i WRI daju preko 99 % točnosti, što su zadovoljavajući rezultati za potrebe računanja obalne crte, dok AWEI_sh daje nešto slabije rezultate, od 90 % točnosti klasifikacije. Satelit Sentinel 2 je pokazao malo bolje rezultate zbog bolje prostorne rezolucije slike nego Landsat 8.

NDWI se pokazao kao najprikladniji vodni indeks za određivanje obalne crte. WRI i MNDWI indeksi se mogu koristiti za određivanje vodenih površina samo kod satelitskih scena koje imaju SWIR kanal. Jednako tako je MNDWI pogodan za određivanje poplavljjenih područja koje se nalaze u urbanim područjima, jer najbolje izbjegava pojave šumova u izgrađenim područjima.

Može se zaključiti da matematičke formulacije NDWI i MNDWI indeksa najbolje odražavaju procese rasprostiranja elektromagnetskog zračenja emitiranog sa satelita u pojedinim spektralnim intervalima (Green, NIR, SWIR) kod odvajanja kopnenih i vodenih površina.

Za određivanje obalne crte u području srednje Dalmacije, u kojem se nalaze i ušća rijeka, preporuča se korištenje metode daljinske detekcije upotrebom satelitskih snimaka i to: satelita Sentinel 2 i NDWI vodenog indeksa ili satelita Landast 8 i MNDWI vodenog indeksa (neznatno lošije točnosti).

U radu su korišteni samo besplatno dostupni podatci. Bolji rezultati mogu se postići koristeći iste formule na komercijalno dostupnim satelitskim slikama veće prostorne rezolucije (WorldView-2, RapidEye...). ■

LITERATURA

- Ayyanna, B.S.; Polisgowdar, M.S.; Ayyanagowdar, A. T.; Dandekar, G.S.: Bellakki, M.A.: (2018.): Accuracy Assessment of Supervised and Unsupervised Classification using Landsat-8 Imagery of D-7 Shahapur Branch Canal of UKP Command Area Karnataka. *Int.J.Curr.Microbiol.App.Sci.*, 7(07), 205-216.
- Congalton, R. G.; Green, K., (2009.): *Assessing the accuracy of remotely sensed data: principles and practices*, CRC Press, Boca Raton, London, New York.
- Čotar, K.; Oštir, K.; Kokalj, Ž. (2016.): Radar Satellite Imagery and Automatic Detection of Water Bodies. *Geodetski glasnik*, 50(47), 5-15.
- Domijan, N.; Leder, N.; Čupić, S. (2005.): Vertikalni datumi Republike Hrvatske. *Treći Hrvatski kongres o katastru* (ur. D. Medak, B. Pribičević, P. Nikolić), 345- 350.
- Du, Y.; Zhang, Y.; Ling, F.; Wang, Q.; Li, W.: & Li, X. (2016.): Water Bodies' Mapping from Sentinel-2 Imagery with Modified Normalized Difference Water Index at 10-m Spatial Resolution Produced by Sharpening the SWIR Band. *Remote Sensing*, 8, 354.
- Duplančić Leder, T.; Ujević, T.; Čala, M. (2004.): Coastline Lengths and Areas of Islands in the Croatian Part of the Adriatic Sea Determined from the Topographic Maps at the Scale 1:25 000. *Geoadria*, 9, 1; 5-32
- Duplančić Leder, T.; Leder, N.; Vranješ, M. (2008.): Primjena visinskih datuma Republike Hrvatske u hidrotehničkim projektima. *Hrvatska geodezija - izazovi strike u 21. stoljeću* (ur. D. Markovinović), 48-56.
- Duplančić Leder, T.; Leder, N. (2009.): Infrastruktura prostornih podataka o moru kao integralni dio nacionalne infrastrukture prostornih podataka, sažetak predavanja, 1. hrvatski NIPP i INSPIRE dan i Savjetovanje Kartografija i geoinformacije (ur. M. Lapaine), 39-40.
- Feyisa, G. L.; Meilby, H.; Fensholt, R.; Proud, S. R. (2014.): Automated Water Extraction Index: A New Technique for Surface Water Mapping Using Landsat Imagery. *Remote Sensing of Environment*, 140, 23-35.
- FAO (2016.): Map Accuracy Assessment and Area Estimation: A Practical Guide. Food and Agriculture Organization (FAO) of the United Nations, Rome, 69.
- Guerrenero Robinson, D.A.; Bijker, W; Tolpekin, V.A. (2013.): Shoreline detection using TerraSAR-X Quad polarization mode. *International Hydrographic Review*, 15-25.
- Horvat, B. (2014.): Kartiranje poplavljene površine korištenjem optičkih satelitskih snimaka. *Hrvatske vode*, 22(88), 166-171.
- IHO (2005): *Manual on Hydrography. Publication M-13*. International Hydrographic Organization, Monaco, 540.
- Jiang H.; Feng, M.; Zhu, Y.; Lu, N.; Huang, J.; Xiao, T. (2014.): An Automated Method for Extracting Rivers and Lakes from Landsat Imagery. *Remote Sensing*, 6, 5067-5089.
- Jovanović, B. (1978.): Izučavanje metoda mjerenja dubina mora, unapređenje obrada dubina i definiranje

- obalne linije sa hidrografskog, geodetskog i pomorskog gledišta. Doktorska disertacija, Sveučilište u Zagrebu Geodetski fakultet, 292.
- Leder, N.; Domijan, N.; Grzetić, Z. (2010.): Prognoziranje poplava hrvatske obale: zadaća operativne oceanologije. *Hrvatska platforma za smanjenje rizika od katastrofa*, 213–215.
- Leder, N.; Duplančić Leder, T. (2011.): Delineation of coastline and marine SDI in Croatia. *25th International Cartographic Conference – Enlightened View on Cartography and GIS*, (ur. A. Ruas) (USB).
- Lu, D., Weng, Q. (2007.): A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28, 823–870.
- Kwang, C; Osei, E.M.; Amoah, A.S. (2018.): Comparing of Landsat 8 and Sentinel 2A using Water Extraction Indexes over Volta River. *Journal of Geography and Geology*, 10(1), 1-7.
- McFeeters, S. K. (1996.): The Use of the Normalized Difference Water Index (NDWI) in the Delineation of Open Water Features. *International Journal of Remote Sensing*, 17 (7), 1425–1432.
- Mukherjee, N.R.; Samuel, C. (2016.): Assessment of the Temporal Variations of Surface Water Bodies in and around Chennai using Landsat Imagery. *Indian Journal of Science and Technology*, 9(18), 1-7.
- Mohd Hasmadi, I.; Pakhriazad, H.Z.; Shahrin, M.F. (2009.): Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing dana. *Malaysian Journal of Society and Space*, 5 (1), 1 – 10.
- NASA (2018.): Landsat Science, Sentinel-2A Launches—Our Compliments & Our Complements. <https://landsat.gsfc.nasa.gov/wp-content/uploads/2015/06/Landsat.v.Sentinel-2.png>
- Otupei, J.; Blaschke, T. (2010.): Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *Int.J. Appl. Earth Obs. Geoinf.*, 12, S27–S31.
- Rubinić, A. (2018.): Kartiranje poplave na Grobničkom polju u studenom 2016. na temelju Sentinel-1 satelitskog snimka. *Hrvatske vode*, 26(104), 129–134.
- Quadros, N.D.; Collier, P.A. (2008.): Delineating the Littoral Zone Using Topographic and Bathymetric Lidar. ABLOS Conference, (https://www.iho.int/mtg_docs/com_wg/ABLOS/).
- Shen, L.; Li C. (2010.): Water body extraction from Landsat ETM+ imagery using adaboost algorithm. IEEE. 18th International Conference on Geoinformatics (ur Y. Liu, A. Chen), 1–4.
- Tappin, D. R.; Evans, H. M.; Jordan, C. J.; Richmond, B.; Sugawara, D.; Goto, K. (2012.): Coastal changes in the Sendai area from the impact of the 2011 Tōhoku-oki tsunami: Interpretations of time series satellite images, helicopter-borne video footage and field observations. *Sedimentary Geology*, 282, 151–174.
- UNEP (2002.): United Nations Environment Programme. <http://wedocs.unep.org/handle/ 20.500.11822/8556>
- Xu, H. (2006.): Modification of Normalised Difference Water Index (NDWI) to Enhance Open Water Features in Remotely Sensed Imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033.
- Yang, X.; Zhao, S.; Qin, X.; Zhao, N.; & Liang, L. (2017.): Mapping of Urban Surface Water Bodies from Sentinel-2 MSI Imagery at 10 m Resolution via NDWI-Based Image Sharpening. *Remote Sensing*, 9, 569.
- Zhou, Y.; Dong, J.; Xiao, X.; Xiao, T.; Yang, Z.; Zhao, G.; Zou, Z.; & Qin, Y. (2017-): Open Surface Water Mapping Algorithms: A Comparison of Water-Related Spectral Indices and Sensors. *Water*, 9, 256.

A comparison of algorithms for coastline mapping using satellite methods

Abstract. The paper presents the methods of coastline determination and describes the method using remote sensing algorithms in more detail. It further analyses the results of the most widely used algorithms of the water indices NDWI, MNDWI, AWEI_nsh, AWEI_sh and WRI, which are used for determining coastlines and water surfaces in general. The algorithms were applied to the Landsat 8 and Sentinel 2 satellite imagery, with central Dalmatia selected as the test area. After the calculation of water indices, unsupervised classification and reclassification were conducted in these areas and, finally, the evaluation of the classification accuracy for each individual index was presented. The results were shown at larger scale for two areas – the Jadro river mouth in Solin and the Cetina river mouth in Omiš. The result analysis revealed that the best results were obtained using the NDWI water index and the poorest results using the AWEI_nsh water index.

Key words: water indices, coastline, remote sensing, Landsat 8, Sentinel 2

Vergleich von Algorithmen zur Kartierung der Küstenlinie mittels Satellitenmethoden

Zusammenfassung. Im Beitrag werden die Methoden zur Bestimmung der Küstenlinie und insbesondere die Anwendung von Algorithmen zur Fernerkundung dargestellt. Die Ergebnisse von am meisten genutzten Algorithmen zur Berechnung der für die Bestimmung von Küstenlinien oder allgemein von offenen Gewässern genutzten Wasserindices, d.h. NDWI, MNDWI, AWEI_nsh, AWEI_sh und WRI, werden analysiert. Die Algorithmen wurden auf die Landsat 8 und Sentinel 2 Satellitenszenen von in Mitteldalmatien befindlichen Testgebieten angewendet. Nach der Berechnung der Wasserindices wurden für die Testgebiete erstens unüberwachte Klassifizierung und zweitens Reklassifizierung durchgeführt, und schließlich wurde die Richtigkeit der Klassifikation einzelner Indices beurteilt. Die Ergebnisse werden für zwei Gebiete – die Mündung des Flusses Jadro in der Stadt Solin und die Mündung des Flusses Cetina in Omiš – in größerem Maßstab gezeigt. Die Analyse der Ergebnisse zeigte, dass die besten Ergebnisse mit NDWI und die schlechtesten mit AWEI_nsh erzielt wurden.

Schlüsselwörter: Wasserindex, Küstenlinie, Fernerkundung, Landsat 8, Sentinel 2