

Perbandingan Kinerja Indeks CMRI dan MVI untuk Pemetaan Mangrove Menggunakan Citra Sentinel-2 pada Berbagai Kondisi Pesisir di Jawa, Indonesia

Ummu Salma^{1*} dan Ayu Wulansari Pramita²

¹Departemen Ilmu Kelautan, Fakultas Perikanan dan Ilmu Kelautan, Universitas Diponegoro
Jl. Prof. Jacob Rais Tembalang Semarang Jawa Tengah 50275 Indonesia

²Departemen Geografi, Fakultas Ilmu Sosial dan Ilmu Politik, Universitas Negeri Semarang
Kampus UNNES Sekaran Gunungpati Semarang Jawa Tengah, 50229 Indonesia
Corresponding author, e-mail: ummusalma@lecturer.undip.ac.id

ABSTRAK: Penelitian ini bertujuan untuk membandingkan kinerja *Combined Mangrove Recognition Index* (CMRI) dan *Mangrove Vegetation Index* (MVI) dalam pemetaan hutan mangrove menggunakan citra Sentinel-2 pada tiga tipe pesisir tropis di Jawa, Indonesia, yaitu Pulau Karimunjawa (perairan jernih), Pulau Pari (substrat karbonat cerah), dan Desa Ujungalang–Cilacap (delta keruh). Kedua indeks dievaluasi menggunakan metode threshold otomatis Otsu dan validasi berbasis *confusion matrix* dengan 200 titik referensi dari citra resolusi tinggi Maxar. Hasil penelitian menunjukkan bahwa CMRI secara konsisten memberikan akurasi lebih tinggi dibanding MVI, dengan *overall accuracy* berkisar antara 0,73–0,96 dan koefisien Kappa 0,47–0,91, sementara MVI hanya kompetitif di lingkungan berair jernih dan mengalami penurunan akurasi hingga 0,61 ($\kappa \approx 0,22$) di lingkungan berair keruh dan bersubstrat cerah. Analisis histogram menunjukkan bahwa reflektansi substrat terang di Pulau Pari meningkatkan threshold CMRI dan kesalahan omisi, sedangkan kekeruhan tinggi di Ujungalang menurunkan separabilitas spektral MVI. Sebaliknya, kondisi optik stabil di Karimunjawa memungkinkan kedua indeks beroperasi optimal. Hasil ini menegaskan bahwa CMRI lebih adaptif terhadap variasi optik dan geomorfologi pesisir, menjadikannya indeks yang lebih andal untuk pemetaan mangrove skala regional di Indonesia, meskipun kalibrasi ambang lokal tetap diperlukan untuk meningkatkan konsistensi antarwilayah sehingga dapat dimanfaatkan oleh pengelola pesisir dan instansi terkait sebagai dasar pemilihan indeks vegetasi yang lebih sesuai dengan kondisi optik lokal dalam pemantauan mangrove berbasis citra Sentinel-2, khususnya untuk mendukung perencanaan konservasi dan evaluasi perubahan tutupan mangrove di wilayah pesisir Indonesia

Kata kunci: Pemetaan mangrove; CMRI; MVI; Sentinel-2; Otsu

Comparative Performance of CMRI and MVI for Mangrove Mapping Using Sentinel-2 Imagery under Diverse Coastal Conditions in Java, Indonesia

ABSTRACT: This study compares the performance of the *Combined Mangrove Recognition Index* (CMRI) and *Mangrove Vegetation Index* (MVI) for mangrove mapping using Sentinel-2 imagery across three contrasting coastal environments in Java, Indonesia: Karimunjawa Island (clear oceanic water), Pari Island (bright carbonate substrate), and Ujungalang–Cilacap (turbid estuarine delta). Both indices were classified using the global Otsu thresholding method and validated through a confusion matrix based on 200 reference points from high-resolution Maxar imagery. Results indicate that CMRI consistently outperforms MVI, achieving overall accuracies between 0.73–0.96 and Kappa coefficients of 0.47–0.91, while MVI performs comparably only in clear-water environments but declines to 0.61 ($\kappa \approx 0.22$) in turbid or bright-substrate conditions. Histogram analyses reveal that high carbonate reflectance in Pari Island elevates CMRI thresholds and omission errors, whereas suspended sediments in Ujungalang reduce MVI's spectral separability. Conversely, stable optical conditions in Karimunjawa allow both indices to perform optimally. These findings demonstrate that CMRI is more resilient to optical variability and coastal geomorphology, making it a reliable baseline index for regional-scale mangrove mapping in Indonesia, although local threshold calibration remains necessary for consistent cross-site applications.

Keywords: Mangrove mapping; CMRI; MVI; Sentinel-2; Otsu

PENDAHULUAN

Ekosistem mangrove merupakan salah satu ekosistem pesisir yang paling bernilai secara ekologis dan ekonomis. Keberadaannya memberikan berbagai jasa lingkungan penting bagi masyarakat pesisir, antara lain perlindungan pantai, stabilisasi sedimen, habitat bagi biota perikanan, serta peningkatan produktivitas perairan (Alongi, 2012). Mangrove dapat menyimpan karbon dalam jumlah besar hingga 1.023 Mg C/ha, menjadikannya salah satu hutan penyimpan karbon tertinggi di dunia (Hakim *et al.*, 2022). Indonesia, dengan luas mangrove mencapai 3,36 juta hektar, merupakan negara dengan ekosistem mangrove terluas di dunia dan menyimpan sekitar 3,14 miliar ton karbon biru (Murdiyarso *et al.*, 2015; Donato *et al.*, 2011). Namun, data Kementerian Lingkungan Hidup dan Kehutanan (KLHK, 2021) menunjukkan bahwa lebih dari 50% hutan mangrove Indonesia telah mengalami degradasi akibat konversi lahan, sedimentasi, dan kenaikan muka air laut. Studi di Desa Bedono, Kabupaten Demak, misalnya, menunjukkan penurunan signifikan luasan vegetasi mangrove antara tahun 2009 dan 2019 akibat abrasi dan perubahan garis pantai, sebagaimana terdeteksi melalui analisis citra satelit Landsat (Pramudito *et al.*, 2020).

Kerusakan ini berdampak langsung terhadap penurunan keanekaragaman hayati dan potensi pelepasan karbon tersimpan ke atmosfer, yang dapat memperparah krisis iklim global. Sebagai contoh, penelitian di Segara Anakan, Cilacap menunjukkan bahwa sedimentasi dan konversi lahan menyebabkan penurunan luas mangrove sebesar >10.000 ha dalam satu dekade terakhir (Ardli *et al.*, 2022). Pemantauan kondisi dan tutupan mangrove secara berkala sangat penting untuk mendukung konservasi dan pengelolaan pesisir berkelanjutan (Maulani *et al.*, 2021). Namun, survei lapangan memiliki keterbatasan dari sisi waktu, biaya, dan cakupan spasial. Oleh karena itu, penginderaan jauh menjadi pendekatan utama dalam pemetaan ekosistem mangrove di Indonesia. Citra Sentinel-2 dengan resolusi 10 meter terbukti menghasilkan akurasi klasifikasi mencapai 84–89%, lebih tinggi dibanding Landsat-8 (65%).

Perkembangan metode penginderaan jauh telah menghasilkan berbagai indeks vegetasi untuk identifikasi mangrove, mulai dari NDVI, NDWI, SAVI hingga indeks khusus seperti *Mangrove Vegetation Index* (MVI) (Baloloy *et al.*, 2020) dan *Coastal Mangrove Recognition Index* (CMRI) (Gupta *et al.*, 2018). Studi perbandingan menunjukkan bahwa indeks seperti MVI dan CMRI mampu mencapai akurasi hingga 90–92%, terutama pada wilayah dengan perairan jernih (Zablan *et al.*, 2023). Namun, akurasi menurun pada area dengan substrat cerah atau kekeruhan tinggi, karena reflektansi air dan sedimen memengaruhi deteksi spectral (Baloloy *et al.*, 2020). Selain itu, kondisi geomorfologi pesisir dan pola hidrodinamika turut menentukan keberhasilan klasifikasi. Penelitian di Karimunjawa menunjukkan bahwa variabilitas pasang surut dan curah hujan sangat berpengaruh terhadap “greenness” mangrove yang diukur melalui NDVI dan NDMI (Prihantono *et al.*, 2022). Hal ini menegaskan pentingnya evaluasi indeks mangrove lintas kondisi perairan dari jernih hingga keruh, untuk memastikan konsistensi performa indeks di berbagai tipe pesisir tropis.

Selain dipengaruhi oleh kondisi optik perairan, pemetaan mangrove berbasis indeks vegetasi tunggal juga menghadapi tantangan dalam membedakan mangrove dengan vegetasi pantai non-mangrove (*coastal forest*), terutama pada wilayah pesisir Jawa yang memiliki transisi vegetasi yang gradual antara mangrove, hutan pantai, dan vegetasi darat. Beberapa studi menunjukkan bahwa nilai spektral mangrove sering tumpang tindih dengan vegetasi pantai seperti cemara laut dan hutan rawa pantai, khususnya pada indeks berbasis kehijauan seperti NDVI dan turunannya, sehingga meningkatkan kesalahan komisi dalam klasifikasi mangrove (Giri *et al.*, 2011; Pham *et al.*, 2019a; Kuenzer *et al.*, 2011). Kondisi ini semakin diperparah pada citra resolusi menengah seperti Sentinel-2, di mana heterogenitas tutupan lahan pesisir dan efek piksel campuran menjadi faktor pembatas utama dalam penerapan indeks tunggal untuk pemetaan mangrove yang akurat.

Berdasarkan latar belakang tersebut, penelitian ini dilakukan untuk mengevaluasi sensitivitas dua indeks mangrove (CMRI dan MVI) terhadap variasi kondisi optik dan geomorfologi pesisir di tiga lokasi di Pulau Jawa, yaitu Pulau Pari (perairan jernih dengan substrat cerah), Karimunjawa (perairan jernih dan stabil), dan Ujungalang–Cilacap (delta keruh dengan sedimentasi tinggi). Kedua indeks ini dipilih karena keduanya dirancang untuk meningkatkan akurasi deteksi mangrove di lingkungan pesisir dengan kondisi optik yang beragam, seperti perairan jernih, substrat cerah, dan

perairan keruh. Melalui penerapan metode *threshold* otomatis (Otsu) dan uji akurasi dengan *confusion matrix*, penelitian ini mencoba melihat seberapa akurat indeks CMRI dan MVI dalam memetakan mangrove di wilayah pesisir dengan karakteristik yang berbeda-beda. Diharapkan hasilnya dapat membantu menentukan metode yang paling tepat untuk pemetaan mangrove.

MATERI DAN METODE

Penelitian ini dilaksanakan pada tiga kawasan pesisir di Pulau Jawa, Indonesia, yang merepresentasikan variasi kondisi geomorfologi dan karakteristik optik perairan yang berbeda (Gambar 1). Lokasi pertama adalah Pulau Karimunjawa di Kabupaten Jepara, yang merupakan pulau samudera dengan perairan relatif jernih serta memiliki tutupan mangrove tipe *fringing* yang stabil. Lokasi kedua adalah Pulau Pari di Kepulauan Seribu, yang merupakan pulau karbonat dengan substrat pasir cerah dan vegetasi mangrove yang sempit. Sementara itu, Desa Ujungalang di Kabupaten Cilacap merepresentasikan kawasan delta estuari dengan tingkat kekeruhan perairan yang tinggi akibat masukan sedimen dari daratan serta memiliki sistem mangrove yang luas dan kompleks.

Perbedaan karakter optik dan geomorfologi di ketiga lokasi tersebut memungkinkan dilakukan evaluasi terhadap sensitivitas dua indeks mangrove, yaitu *Combined Mangrove Recognition Index (CMRI)* dan *Mangrove Vegetation Index (MVI)*, terhadap variasi kejernihan air, kecerahan substrat, serta dinamika hidrologi pesisir.

Data yang digunakan berasal dari citra Sentinel-2 MSI Level-2A (*surface reflectance*) yang diambil melalui katalog *Google Earth Engine (GEE) COPERNICUS/S2_SR_HARMONIZED* untuk periode 1 Juni 2023 – 31 Mei 2024, untuk memastikan konsistensi musim dan meminimalkan bias akibat tutupan awan. Spektral yang digunakan; *Blue* (B2) – 10 m; *Green* (B3) – 10 m; *Red* (B4) – 10 m; *NIR* (B8) – 10 m; dan *SWIR1* (B11) – 20 m yang diresample menjadi 10 m. Selain itu, NASA SRTM DEM (USGS/SRTMGL1_003) digunakan sebagai data elevasi.

Masking awan dan bayangan dilakukan dengan memanfaatkan *Scene Classification Layer (SCL)* dari citra Sentinel-2 Level-2A. Dalam proses ini, beberapa kelas pada layer SCL dikecualikan, yaitu bayangan awan (kelas 3), awan sedang (kelas 8), awan tinggi (kelas 9), awan *cirrus* (kelas 10), serta salju/es (kelas 11). Pendekatan ini memastikan bahwa hanya piksel dengan kualitas reflektansi baik yang digunakan dalam analisis.

Tahap berikutnya adalah perhitungan berbagai indeks spektral vegetasi dan air untuk mengekstraksi informasi vegetasi mangrove. Indeks-indeks yang digunakan meliputi *Normalized Difference Vegetation Index (NDVI)*, *Normalized Difference Water Index (NDWI)*, *Modified Normalized Difference Water Index (MNDWI)*, *Mangrove Vegetation Index (MVI)*, dan *Coastal Mangrove Recognition Index (CMRI)*. Masing-masing indeks dihitung berdasarkan persamaan berikut:

$$\begin{aligned} NDVI &= \frac{NIR - RED}{NIR + RED} \\ NDWI &= \frac{GREEN - NIR}{GREEN + NIR} \\ MNDWI &= \frac{GREEN - SWIR}{GREEN + SWIR} \end{aligned}$$

I

ndeks mangrove spesifik, yaitu MVI yang dikembangkan oleh (Baloloy *et al.*, 2020), dirumuskan sebagai:

$$MVI = \left(\frac{SWIR - RED}{SWIR + RED} \right) - \left(\frac{NIR - RED}{NIR + RED} \right)$$

Sementara itu, CMRI, yang diperkenalkan oleh (Gupta *et al.*, 2018), dihitung menggunakan kombinasi NDVI dan NDWI melalui persamaan:


$$CMRI = NDVI - NDWI$$

Masker air ini dibangun berdasarkan kombinasi ambang spektral yang meliputi $NDWI > -0,05$, $MNDWI > -0,20$, $NIR < 1200$, $SWIR < 400$, dan $BLUE > GREEN$, sehingga dapat menangkap baik perairan jernih maupun keruh.

Batas elevasi juga diterapkan untuk membatasi area klasifikasi pada zona intertidal dengan elevasi kurang dari 5–7 meter, dituliskan sebagai:

$$Elev \leq 5 - 7 \text{ meter}$$

Klasifikasi mangrove sangat dipengaruhi oleh kondisi optik dan geomorfologi pesisir, seperti tingkat kekeruhan air, kecerahan substrat, serta elevasi topografi. Untuk mengurangi kesalahan klasifikasi, digunakan *coastal habitat mask* yang memastikan analisis hanya dilakukan pada area yang secara ekologis memungkinkan bagi pertumbuhan mangrove.



Gambar 1. Lokasi Penelitian. (a) Pulau Pari, (b) Pulau Karimunjawa, (c) Ujungalang

Tahap akhir dari pra-pengolahan adalah pembuatan komposit median. Semua citra bebas awan dalam periode pengamatan (Juni 2023 – Mei 2024) dikombinasikan menggunakan nilai median untuk setiap piksel, dengan tujuan mengurangi *outlier temporer* dan menghasilkan representasi spasial yang stabil sepanjang musim pengamatan. Tahap awal dilakukan pemisahan area perairan melalui pembentukan *water mask*, yang dihitung menggunakan fungsi jarak terhadap perairan, yaitu:

$$Dist_{water} = distance(waterMask)$$

Parameter ambang batas selanjutnya ditentukan secara spesifik untuk tiap lokasi penelitian, dengan mempertimbangkan variasi kecerahan substrat dan tingkat kekeruhan perairan. Pada Pulau Karimunjawa digunakan nilai NDVI minimum 0,25, elevasi maksimum 5 meter, dan jarak maksimum 120 meter dari garis air. Pulau Pari memiliki NDVI minimum 0,55, elevasi maksimum 7 meter, dan jarak maksimum 50 meter, sedangkan Ujungalang (Cilacap) menggunakan NDVI minimum 0,30, elevasi maksimum 6 meter, dan jarak maksimum 250 meter.

Selain itu, diterapkan *mask korektif* khusus untuk Pulau Pari guna mengatasi pengaruh pantulan substrat karbonat yang tinggi. Masker ini diformulasikan untuk menyaring area dengan nilai NDVI di atas 0,55 dan jarak dari air tidak melebihi 50 meter, sebagaimana ditunjukkan oleh persamaan berikut:

$$Mask_{Pari} = (NDVI > 0.55) \cap (Dis_{water} \leq 50 m)$$

Langkah ini memastikan area dengan reflektansi tinggi akibat dasar perairan dangkal tidak salah diklasifikasikan sebagai vegetasi mangrove.

Kedua indeks (CMRI dan MVI) diklasifikasikan secara biner menggunakan Otsu global *thresholding*, dihitung hanya pada area yang lolos *coastal mask*. Otsu memilih ambang (t) yang memaksimalkan varians antar kelas:

$$\sigma_b^2(t) = w_1(t)(\mu_1(t) - \mu)^2 + w_2(t)(\mu_2(t) - \mu)^2$$

Nilai t yang memberikan σ_b^2 maksimum digunakan sebagai *threshold*. Jika histogram kosong, *threshold* diganti dengan nilai rata-rata indeks. Masker biner hasil klasifikasi CMRI dan MVI dihitung luasnya menggunakan:

$$Area_{ha} = \frac{\sum pixelArea}{10000}$$

Hasil akhirnya diekspor dalam bentuk CSV untuk ketiga lokasi. Validasi akurasi dilakukan menggunakan total 200 titik referensi yang diinterpretasikan secara manual dari citra resolusi tinggi Maxar. Titik tersebut mencakup 30 titik di Pulau Pari, 70 titik di Pulau Karimunjawa, dan 100 titik di Desa Ujungalang, dengan label kelas mangrove (1) dan non-mangrove (0) berdasarkan karakteristik kanopi dan konteks spasialnya. Pengambilan titik dilakukan menggunakan pendekatan *stratified random sampling* agar seluruh variasi tutupan lahan seperti mangrove *fringing*, *riverine*, *tidal flats*, vegetasi pantai, dan lahan terbangun terwakili (Plourde & Congalton, 2003). Setiap titik kemudian diekstrak nilai prediksinya dari hasil klasifikasi CMRI dan MVI. Seluruh pasangan nilai referensi–prediksi ini digunakan untuk membangun confusion matrix dan menghitung metrik akurasi (OA, PA, UA, dan Kappa) (Jin, 2013).

Evaluasi akurasi dilakukan untuk menilai ketepatan hasil klasifikasi terhadap data referensi (*ground truth*). Analisis dilakukan menggunakan *confusion matrix* yang membandingkan hasil klasifikasi (*prediksi*) dengan kondisi sebenarnya di lapangan. Pada matriks ini, setiap piksel hasil klasifikasi dikategorikan sebagai *True Positive (TP)* apabila terklasifikasi sebagai *mangrove* dan

benar-benar merupakan *mangrove* pada data referensi, *True Negative (TN)* apabila piksel terklasifikasi sebagai *non-mangrove* dan sesuai dengan data referensi, *False Positive (FP)* apabila piksel terklasifikasi sebagai *mangrove* namun sebenarnya *non-mangrove*, serta *False Negative (FN)* apabila piksel terklasifikasi sebagai *non-mangrove* namun sebenarnya merupakan *mangrove* (Plourde & Congalton, 2003).

Parameter yang digunakan dalam evaluasi akurasi meliputi *Overall Accuracy (OA)*, *Producer's Accuracy (PA)*, *User's Accuracy (UA)*, dan *Kappa Coefficient (κ)*. *Overall Accuracy (OA)* menggambarkan proporsi total piksel yang terklasifikasi dengan benar terhadap jumlah keseluruhan piksel, yang dihitung menggunakan persamaan berikut:

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

Producer's Accuracy (PA) menunjukkan kemampuan hasil klasifikasi dalam mengenali kelas yang sebenarnya terdapat di lapangan, dengan rumus:

$$PA_{mangrove} = \frac{TP}{TP + FN}$$

User's Accuracy (UA) menggambarkan tingkat keandalan hasil klasifikasi, yaitu kemungkinan bahwa piksel yang terklasifikasi sebagai *mangrove* benar-benar merupakan *mangrove* pada data referensi, dihitung dengan persamaan:

$$UA_{mangrove} = \frac{TP}{TP + FP}$$

Selain itu, *Kappa Coefficient (κ)* digunakan untuk mengukur tingkat kesesuaian antara hasil klasifikasi dan data referensi dengan mempertimbangkan peluang kesesuaian yang terjadi secara acak. Nilai κ dihitung menggunakan persamaan berikut:

$$\kappa = \frac{N(TP + TN) - [(TP + FP)(TP + FN) + (FN + TN)(FP + TN)]}{N^2 - [(TP + FP)(TP + FN) + (FN + TN)(FP + TN)]}$$

Nilai κ berkisar antara 0 hingga 1, di mana nilai mendekati 1 menunjukkan tingkat kesesuaian yang tinggi antara hasil klasifikasi dan data referensi, sedangkan nilai mendekati 0 menunjukkan kesesuaian yang rendah (Jin, 2013).


Seluruh proses mulai dari pra-pengolahan citra Sentinel-2, masking area pesisir, perhitungan indeks (CMRI dan MVI), penentuan ambang batas (*thresholding*) menggunakan metode Otsu, hingga perhitungan luas tutupan mangrove, diimplementasikan di *Google Earth Engine (GEE)* menggunakan bahasa JavaScript. Platform GEE memungkinkan pengolahan data spasial skala besar secara efisien dengan akses langsung ke citra satelit dan pustaka analisis spectral (Gorelick *et al.*, 2017). Hasil klasifikasi diekspor sebagai GeoTIFF untuk analisis lanjutan di ArcGIS.

HASIL DAN PEMBAHASAN

Sebaran spasial mangrove yang dihasilkan oleh indeks CMRI dan MVI pada ketiga lokasi (Pulau Karimunjawa, Pulau Pari, dan Ujungalang) menunjukkan pola yang konsisten dengan karakter geomorfologi dan kondisi optik perairan masing-masing kawasan. Di Pulau Karimunjawa, mangrove muncul sebagai sabuk yang relatif kontinu mengikuti garis pantai dan teluk-teluk dangkal, mencerminkan tipe fringing mangrove di pulau samudera dengan perairan jernih. Di Pulau Pari, mangrove hanya tampak sebagai petak-petak sempit dan terfragmentasi di beberapa segmen pantai

terlindung. Sementara di Ujungalang, mangrove berkembang luas pada zona delta estuari, membentuk mosaik dengan tambak dan lahan terbuka. Secara visual, CMRI dan MVI sama-sama mampu menonjolkan area mangrove yang rapat, namun mulai menunjukkan perbedaan di area transisi, seperti mosaik mangrove dan vegetasi pantai, mangrove dan tambak, serta mangrove berkanopi jarang.


Kondisi mangrove yang sempit dan terfragmentasi di Pulau Pari juga perlu dipahami dalam konteks keterbatasan resolusi spasial citra Sentinel-2 yang memiliki ukuran piksel 10 m. Pada pulau kecil, lebar sabuk mangrove sering kali lebih kecil atau sebanding dengan ukuran satu piksel, sehingga satu piksel dapat merepresentasikan campuran antara kanopi mangrove, vegetasi pantai non-mangrove, pasir karbonat cerah, dan perairan dangkal. Efek *mixed pixel* ini menurunkan ketelitian delineasi batas mangrove dan berpotensi menyebabkan *under-* atau *over-estimation* luasan, khususnya pada segmen pantai yang sangat sempit dan terfragmentasi. Beberapa studi menunjukkan bahwa resolusi 10 m masih memadai untuk pemetaan mangrove pada skala regional, namun memiliki keterbatasan dalam menangkap fitur mangrove sempit di pulau kecil, yang idealnya membutuhkan citra beresolusi lebih tinggi atau pendekatan berbasis objek (Pham *et al.*, 2019b; Tran *et al.*, 2022).



a) CMRI

b) MVI


Gambar 2. Sebaran mangrove di Pulau Karimunjawa berdasarkan hasil klasifikasi indeks (a) CMRI dan (b) MVI



a) CMRI

b) MVI

Gambar 3. Sebaran mangrove di Pulau Pari berdasarkan hasil klasifikasi indeks (a) CMRI dan (b) MVI



Gambar 4. Sebaran mangrove di Ujungalang, Cilacap berdasarkan hasil klasifikasi indeks (a) CMRI dan (b) MVI

Pola ini sejalan dengan temuan beberapa penelitian bahwa kesalahan klasifikasi paling sering terjadi di zona peralihan dan wilayah dengan heterogenitas spektral tinggi, terutama akibat kemiripan tanda spektral antara mangrove, vegetasi pantai, dan substrat basah (Chamberlain *et al.*, 2020; Neri *et al.*, 2021). Perbedaan respon indeks pada tiga tipe pesisir tersebut sejalan dengan tinjauan spektral mangrove global, di mana indeks yang menggabungkan informasi vegetasi dan air (seperti CMRI) cenderung memberikan hasil yang lebih stabil di berbagai kondisi optik, sementara indeks yang lebih menonjolkan perbedaan vegetasi (seperti MVI) memiliki sensitivitas lebih tinggi terhadap kekeruhan air, substrat terang, dan campuran kelas tutupan lahan (Tran *et al.*, 2022; Valderrama-Landeros *et al.*, 2024).

Ringkasan luas mangrove dan nilai *threshold* Otsu untuk masing-masing indeks disajikan pada Tabel 1. Di Pulau Karimunjawa, CMRI dengan *threshold* 1,289 menghasilkan luas mangrove 314,292 ha, sedangkan MVI dengan *threshold* -0,258 memetakan mangrove seluas 347,864 ha. Perbedaan sekitar 33,6 ha ini menunjukkan bahwa MVI cenderung lebih inklusif, terutama pada area dengan kerapatan kanopi sedang hingga rendah. Temuan ini konsisten dengan evaluasi oleh (Neri *et al.*, 2021), yang melaporkan bahwa MVI sering menghasilkan *overestimation* di area bervegetasi campuran dan mosaik karena perbedaan *contrast intensity* yang rendah antara mangrove dan vegetasi non-mangrove, terutama saat metode *Otsu thresholding* digunakan secara otomatis.

Di Pulau Pari, perbedaan antara kedua indeks menjadi lebih mencolok. CMRI ($t = 1,340$) hanya memetakan 10,090 ha mangrove, sedangkan MVI ($t = -0,310$) mengklasifikasikan 17,166 ha. Artinya, hasil MVI hampir 70% lebih besar dibanding CMRI. Mengingat Pulau Pari didominasi oleh substrat karbonat cerah dan perairan dangkal, hal ini menunjukkan bahwa reflektansi tinggi dasar perairan dan vegetasi pantai non-mangrove dapat meningkatkan nilai MVI secara keliru jika *threshold* tidak dikalibrasi secara lokal. Fenomena ini sejalan dengan laporan bahwa indeks berbasis *greenness* dan *moisture*, seperti MVI, rentan terhadap pengaruh substrat terang dan variabilitas kolom air di wilayah dangkal (Baloloy *et al.*, 2020; Chen *et al.*, 2023).

Di Ujungalang, pola berbalik di mana CMRI ($t = 1,227$) memetakan mangrove seluas 4.160,996 ha, lebih besar dibanding MVI (3.425,151 ha; $t = -0,230$). Pada lingkungan delta dengan kekeruhan tinggi dan beban sedimen besar, CMRI justru lebih mampu menangkap sebaran mangrove yang luas. Hal ini sejalan dengan desain CMRI yang mengombinasikan NDVI dan NDWI untuk mengekspresikan *greenness* dan kandungan air vegetasi mangrove sehingga lebih tahan terhadap pengaruh air keruh (Son *et al.*, 2022; Valderrama-Landeros *et al.*, 2024).


CMRI cenderung memberikan estimasi yang lebih konservatif di lingkungan ber-substrat cerah (Pulau Pari) namun lebih inklusif di delta keruh (Ujungalang), sementara MVI cenderung

memperluas klasifikasi di lingkungan optik yang kompleks. Ini sudah menjadi sinyal awal bahwa pemilihan indeks tidak bisa dilepaskan dari karakter optik setempat.

Histogram nilai CMRI dan MVI (Gambar 5) memberikan gambaran mengenai tingkat separabilitas spektral antara kelas mangrove dan non-mangrove. Metode Otsu bekerja dengan asumsi bahwa distribusi histogram bersifat bimodal dan relatif terpisah, sehingga nilai ambang optimal dapat ditentukan dengan memaksimalkan varians antar-kelas (Otsu, 1979). Pada Pulau Karimunjawa, histogram CMRI menunjukkan pola unimodal miring ke kanan dengan konsentrasi nilai tinggi (1,6–1,8), menandakan dominasi piksel mangrove berkanopi rapat dan tingkat pemisahan

Tabel 1. Ringkasan Luas Mangrove dan Threshold di Ketiga Lokasi Penelitian

Indeks	Lokasi	Luas Mangrove (ha)	Threshold
CMRI	Pulau Karimunjawa	314,292	1,289
MVI	Pulau Karimunjawa	347,864	-0,258
CMRI	Pulau Pari	10,090	1,340
MVI	Pulau Pari	17,166	-0,310
CMRI	Ujungalang	4160,996	1,227
MVI	Ujungalang	3425,151	-0,230



Gambar 5. Histogram Otsu CMRI dan MVI. (a) Histogram CMRI Pulau Karimunjawa; (b) Histogram MVI Pulau Karimunjawa; (c) Histogram CMRI Pulau Pari; (d) Histogram MVI Pulau Pari; (e) Histogram CMRI Ujungalang; (f) Histogram MVI Ujungalang

spektral yang baik terhadap non-mangrove. Sebaliknya, histogram MVI memperlihatkan bentuk simetris tunggal dengan puncak di sekitar $-0,25$, yang mengindikasikan homogenitas nilai indeks dan sensitivitas rendah terhadap variasi optik perairan jernih. Kondisi ini menjelaskan mengapa CMRI lebih efektif memisahkan mangrove dari air laut dan substrat terang, sebagaimana juga dilaporkan oleh (Gupta *et al.*, 2018) dan (Baloloy *et al.*, 2020).

Pada Pulau Pari, histogram CMRI memperlihatkan distribusi datar tanpa puncak jelas, yang menunjukkan rendahnya separabilitas spektral akibat reflektansi tinggi substrat karbonat dan pantulan dasar perairan dangkal. Sebaliknya, histogram MVI menampilkan puncak tunggal tajam di sekitar $-0,2$ dengan ekor memanjang ke kiri, menandakan sensitivitas tinggi terhadap pengaruh substrat terang dan vegetasi non-mangrove pesisir. Fenomena ini menjelaskan tingginya kesalahan klasifikasi di lingkungan perairan dangkal, sebagaimana diidentifikasi dalam penelitian mangrove pada wilayah tropis dengan dasar cerah (Chen *et al.*, 2023).

Pada Desa Ujungalang, histogram CMRI menunjukkan puncak tunggal dominan di sekitar $1,5$ dengan ekor memanjang ke arah nilai rendah, yang mencerminkan dominasi kanopi mangrove padat di lingkungan delta berlumpur dan berair keruh. Meskipun tidak bimodal, pola ini menunjukkan separabilitas spektral yang tetap kuat karena kombinasi NDVI dan NDWI dalam CMRI meningkatkan toleransi terhadap pengaruh kekeruhan (Son *et al.*, 2022). Sebaliknya, histogram MVI pada lokasi ini tampak sempit dan simetris di sekitar $-0,2$, menandakan penurunan sensitivitas terhadap variasi optik akibat tingginya turbidity, sebagaimana juga diamati oleh (Valderrama-Landeros *et al.*, 2024).

Hasil evaluasi akurasi (Tabel 2) menunjukkan bahwa indeks CMRI secara konsisten menghasilkan kinerja klasifikasi yang lebih baik dibandingkan MVI di ketiga lokasi penelitian. Penilaian akurasi dilakukan menggunakan beberapa parameter, yaitu *Overall Accuracy* (OA), *Producer's Accuracy* untuk kelas mangrove (PAM) dan kelas non-mangrove (PAN), *User's Accuracy* untuk kelas mangrove (UAM) dan kelas non-mangrove (UAN), *Expected Accuracy* (Pe), serta koefisien Kappa. Kombinasi parameter ini memberikan gambaran yang lebih lengkap mengenai proporsi piksel yang diklasifikasikan dengan benar, kecenderungan kesalahan omisi maupun komisi, serta tingkat kesesuaian klasifikasi terhadap data referensi di luar kebetulan (Foody, 2020).

Indeks CMRI di Pulau Karimunjawa menunjukkan performa terbaik dengan OA = 0,957 dan κ = 0,914, menandakan kesesuaian yang sangat tinggi antara hasil klasifikasi dan data referensi. Nilai UAM = 1,000 menunjukkan tidak ada kesalahan komisi, sementara PAM = 0,917 menandakan sebagian besar piksel mangrove berhasil teridentifikasi. MVI juga menunjukkan akurasi tinggi (OA = 0,886; κ = 0,772), namun sedikit lebih rendah karena pengaruh variasi optik perairan jernih. Hasil ini mendukung temuan bahwa indeks gabungan berbasis NDVI–NDWI seperti CMRI lebih unggul dalam lingkungan pesisir jernih (Heumann, 2011).

Pada Pulau Pari, akurasi kedua indeks menurun akibat kompleksitas optik perairan karbonat dangkal. CMRI menghasilkan OA = 0,733; κ = 0,467, dengan UAM = 0,889 (kesalahan komisi rendah) tetapi PAM = 0,533, menandakan banyak piksel mangrove tidak terdeteksi. Sebaliknya, MVI menunjukkan PAM lebih tinggi (0,667) namun UAM turun (0,625), menandakan perluasan area klasifikasi mangrove diiringi peningkatan kesalahan komisi. Kondisi ini serupa dengan laporan penurunan separabilitas spektral pada perairan dangkal dalam studi klasifikasi tutupan lahan berbasis Sentinel-2 (Toosi *et al.*, 2020).

Perbedaan paling jelas terlihat di Desa Ujungalang, di mana CMRI kembali unggul dengan OA = 0,880; κ = 0,760, PAM = 0,939, dan UAM = 0,836, menandakan ketahanan CMRI terhadap pengaruh turbidity dan variasi reflektansi substrat. Sebaliknya, MVI hanya mencapai OA = 0,610; κ = 0,221, dengan nilai PA dan UA kedua kelas berkisar 0,59–0,63, yang menunjukkan rendahnya kemampuan diskriminasi di lingkungan delta berlumpur. Hasil ini sejalan dengan penelitian mangrove di kawasan estuari yang menegaskan pentingnya integrasi indeks spektral multi-band dalam lingkungan keruh (Ghorbanian *et al.*, 2021).

Bila dibandingkan dengan kisaran akurasi yang umum dalam berbagai studi pemetaan mangrove berbasis Sentinel-2 pada kondisi spasial yang relatif bersih, nilai OA sekitar 0,85–0,95 dan Kappa 0,70–0,90 biasanya dianggap sangat baik terutama ketika digabungkan dengan algoritma pembelajaran mesin atau pendekatan berbasis objek (Srivastava *et al.*, 2022; Wang *et al.*, 2024). Kinerja CMRI di Pulau Karimunjawa dan Ujungalang sudah berada pada rentang atas,

Tabel 2. Nilai akurasi klasifikasi indeks CMRI dan MVI (*Overall Accuracy, Producer's Accuracy, User's Accuracy, Expected Accuracy, dan Kappa*)

Lokasi	Indeks	OA	Kappa	PAM	PAN	UAM	UAN
Pulau Pari	CMRI	0,733	0,467	0,533	0,933	0,889	0,667
Pulau Pari	MVI	0,633	0,267	0,667	0,600	0,625	0,643
Pulau Karimunjawa	CMRI	0,957	0,914	0,917	1,000	1,000	0,919
Pulau Karimunjawa	MVI	0,886	0,772	0,833	0,941	0,938	0,842
Ujungalang	CMRI	0,880	0,760	0,939	0,824	0,836	0,933
Ujungalang	MVI	0,610	0,221	0,633	0,588	0,596	0,625

sedangkan performa CMRI di Pulau Pari masih dapat diterima mengingat kompleksitas optik pulau karbonat dangkal dengan substrat cerah dan kolom air sangat dangkal. Nilai akurasi CMRI yang lebih rendah di Pulau Pari juga berkaitan erat dengan efek *mixed pixel* yang kuat pada garis pantai yang sempit dan dinamis. Interaksi antara pasang surut, perubahan posisi garis pantai, serta reflektansi tinggi substrat karbonat menyebabkan satu piksel Sentinel-2 sering kali mencakup kombinasi mangrove, pasir cerah, dan perairan dangkal secara bersamaan. Kondisi ini menurunkan separabilitas spektral mangrove berkanopi jarang, sehingga sebagian piksel mangrove tidak terdeteksi dan jatuh di bawah nilai ambang Otsu. Fenomena serupa telah dilaporkan dalam pemetaan mangrove berbasis Sentinel-2 di lingkungan pesisir heterogen, di mana efek mixed pixel dan resolusi spasial menengah menjadi faktor utama penurunan akurasi klasifikasi (Gupta *et al.*, 2018; Toosi *et al.*, 2020).

Perbedaan perilaku *threshold*, akurasi, dan distribusi histogram CMRI maupun MVI di tiga lokasi penelitian menunjukkan hubungan yang erat dengan kondisi lingkungan setempat. Kinerja indeks tidak hanya ditentukan oleh rumus matematisnya, tetapi juga oleh karakter optik perairan seperti kecerahan substrat, kedalaman dan kejernihan kolom air, serta tingkat kekeruhan (turbiditas) yang memengaruhi reflektansi spektral di kanal optik Sentinel-2 (Sankaran *et al.*, 2023).

Pada Pulau Pari, substrat karbonat yang sangat cerah dan kolom air dangkal menghasilkan reflektansi tinggi pada band hijau dan NIR, yang berpengaruh langsung terhadap NDWI dan indeks turunannya. Akibatnya, nilai NDWI cenderung tinggi bukan hanya pada perairan terbuka, tetapi juga pada piksel campuran antara pasir cerah dan vegetasi pantai non-mangrove. Ketika NDWI dikombinasikan dengan NDVI dalam CMRI, distribusi nilai CMRI bergeser ke arah lebih tinggi, sehingga metode Otsu menghasilkan *threshold* lebih besar dibanding lokasi lain. Ambang ini memang membantu mengurangi salah klasifikasi akibat substrat terang, tetapi juga menyebabkan piksel mangrove berkanopi jarang jatuh ke bawah *threshold*. Fenomena serupa diamati dalam studi habitat dasar di perairan optik kompleks, di mana reflektansi substrat terang menurunkan separabilitas spektral vegetasi bawah air (Wilson *et al.*, 2020).

Sebaliknya, Pulau Karimunjawa merepresentasikan lingkungan optik yang lebih stabil dengan kolom air jernih dan perbedaan spektral yang jelas antara mangrove, air, dan lahan terbuka. Dalam kondisi seperti ini, respon kanopi mangrove tidak terganggu oleh sinyal dasar perairan, sehingga histogram CMRI dan MVI memperlihatkan dua puncak yang terpisah jelas (bimodal). Nilai *threshold* Otsu pun berada di lembah antar-puncak, menghasilkan akurasinya tertinggi di antara ketiga lokasi. Temuan ini sesuai dengan studi Prihantono *et al.* (2022) di Karimunjawa yang menunjukkan bahwa NDVI dan NDWI memiliki korelasi kuat ($r = 0,94$) pada kondisi optik yang jernih, menandakan kestabilan sinyal vegetasi dan air di wilayah tersebut.

Sementara itu, Desa Ujungalang menunjukkan kondisi paling ekstrem dengan kekeruhan tinggi akibat sedimen tersuspensi dan aktivitas tambak. Reflektansi tinggi pada kanal hijau, merah, dan SWIR menyebabkan respon spektral air keruh menyerupai mangrove jarang, sehingga distribusi nilai MVI saling tumpang tindih antar kelas. Histogram MVI menjadi lebar dan tidak lagi bimodal, membuat Otsu sulit menemukan ambang optimal. Hasil ini sejalan dengan penelitian Trinh *et al.*

(2023) di Vietnam yang melaporkan bahwa turbidity menyebabkan penurunan separabilitas spektral dan menurunkan akurasi klasifikasi vegetasi pesisir hingga 8–10% (Trinh *et al.*, 2023).

Berbeda dengan MVI, CMRI masih mempertahankan performa baik di Ujungalang karena kontribusi NDVI di dalam formula membantu menjaga kontras spektral terhadap air keruh. Kondisi ini menegaskan bahwa CMRI lebih toleran terhadap pengaruh turbidity dan substrat berlumpur, sedangkan MVI memerlukan penyesuaian threshold lokal atau kalibrasi berbasis data lapangan agar tetap stabil di lingkungan optik ekstrem (Baloloy *et al.*, 2020).

KESIMPULAN

Penelitian ini membandingkan kinerja Combined Mangrove Recognition Index (CMRI) dan Mangrove Vegetation Index (MVI) dalam pemetaan mangrove berbasis Sentinel-2 di tiga tipe pesisir Jawa. Hasil menunjukkan bahwa CMRI lebih akurat dan stabil (OA 73–96%; κ 0,47–0,91) dibanding MVI, terutama di lingkungan optik kompleks seperti delta keruh dan pulau karbonat dangkal. Reflektansi substrat cerah dan turbidity tinggi terbukti menurunkan separabilitas spektral MVI, sedangkan kombinasi NDVI–NDWI pada CMRI tetap efektif memisahkan mangrove dari non-mangrove. Dengan demikian, CMRI lebih andal sebagai indeks regional, meskipun kalibrasi ambang lokal masih diperlukan untuk meningkatkan konsistensi antarwilayah.

DAFTAR PUSTAKA

- Alongi, D.M., 2012. Carbon sequestration in mangrove forests, *Carbon Management*, 3(3):313–322. DOI: 10.4155/cmt.12.20
- Ardli, E., Yuwono, E. & Purwanto, A., 2022. Land cover changes and impacts of massive siltation on the mangrove Segara Anakan Lagoon system, Cilacap Indonesia, *Journal of Ecological Engineering*, 23(7):196–204. DOI: 10.12911/22998993/149821
- Baloloy, A., Blanco, A., Sta. Ana, R.R. & Nadaoka, K., 2020. Development and application of a new mangrove vegetation index (MVI) for rapid and accurate mangrove mapping, *ISPRS Journal of Photogrammetry and Remote Sensing*, 167:37–52. DOI: 10.1016/j.isprsjprs.2020.06.001
- Chamberlain, D., Phinn, S. & Possingham, H., 2020. Remote sensing of mangroves and estuarine communities in Central Queensland, Australia, *Remote Sensing*, 12(1):197. DOI: 10.3390/rs12010197
- Chen, Z., Zhang, M., Zhang, H. & Liu, Y., 2023. Mapping mangrove using a red-edge mangrove index (REMI) based on Sentinel-2 multispectral images, *IEEE Transactions on Geoscience and Remote Sensing*, 61:1–11. DOI: 10.1109/TGRS.2023.3323741
- Donato, D.C., Kauffman, J.B., Murdiyarso, D., Kurnianto, S., Stidham, M. & Kanninen, M., 2011. Mangroves among the most carbon-rich forests in the tropics, *Nature Geoscience*, 4:293–297. DOI: 10.1038/ngeo1123
- Foody, G.M., 2020. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification, *Remote Sensing of Environment*, 239:111630. DOI: 10.1016/j.rse.2019.111630
- Ghorbanian, A., Zaghian, S., Asiyabi, R., Amani, M., Mohammadzadeh, A. & Jamali, S., 2021. Mangrove ecosystem mapping using Sentinel-1 and Sentinel-2 satellite images and random forest algorithm in Google Earth Engine, *Remote Sensing*, 13(13):2565. DOI: 10.3390/rs13132565
- Giri, C., Ochieng, E., Tieszen, L.L., Zhu, Z., Singh, A., Loveland, T., Masek, J. & Duke, N., 2011. Status and distribution of mangrove forests of the world using earth observation satellite data, *Global Ecology and Biogeography*, 20(1):154–159. DOI: 10.1111/j.1466-8238.2010.00584.x
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. & Moore, R., 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone, *Remote Sensing of Environment*, 202:18–27. DOI: 10.1016/j.rse.2017.06.031
- Gupta, K., Mukhopadhyay, A., Giri, S., Chanda, A., Datta Majumdar, S., Samanta, S., Mitra, D., Samal, R.N., Pattnaik, A.K. & Hazra, S., 2018. An index for discrimination of mangroves from

- non-mangroves using LANDSAT 8 OLI imagery, *MethodsX*, 5:1129–1139. DOI: 10.1016/j.mex.2018.09.011
- Hakim, M.G.A., Kamal, M. & Arjasakusuma, S., 2022. Mapping mangrove surface carbon stocks using multisensor imagery in Clungup Mangrove Conservation (CMC) Malang Regency, *Jurnal Geografi*, 14(2):85–95. DOI: 10.24114/jg.v14i2.33575
- Heumann, B.W., 2011. An object-based classification of mangroves using a hybrid decision tree – support vector machine approach, *Remote Sensing*, 3(11):2440–2460. DOI: 10.3390/rs3112440
- Jin, S., 2013. Accuracy assessment for classification and modeling, dalam: Foody, G.M. (ed.), *Remote Sensing Accuracy Assessment*, CRC Press, Florida, pp. 70–81. DOI: 10.1201/b15159-8
- Kementerian Lingkungan Hidup dan Kehutanan (KLHK), 2021. *Statistik Lingkungan Hidup dan Kehutanan Tahun 2021*, Kementerian Lingkungan Hidup dan Kehutanan, Jakarta.
- Kuenzer, C., Bluemel, A., Gebhardt, S., Quoc, T.V. & Dech, S., 2011. Remote sensing of mangrove ecosystems: A review, *Remote Sensing*, 3(5):878–928. DOI: 10.3390/rs3050878
- Maulani, A., Taufiq-SPJ, N. & Pratikto, I., 2021. Perubahan lahan mangrove di pesisir Muara Gembong, Bekasi, Jawa Barat, *Journal of Marine Research*, 10(1):55–63. DOI: 10.14710/jmr.v10i1.28396
- Murdiyarso, D., Purbopuspito, J., Kauffman, J.B., Warren, M.W., Sasmito, S.D., Donato, D.C., Manuri, S., Krisnawati, H., Taberima, S. & Kurnianto, S., 2015. The potential of Indonesian mangrove forests for global climate change mitigation, *Nature Climate Change*, 5:1089–1092. DOI: 10.1038/nclimate2734
- Neri, M., Baloloy, A. & Blanco, A., 2021. Limitation assessment and workflow refinement of the mangrove vegetation index (MVI)-based mapping methodology using Sentinel-2 imagery, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVI-4/W6:235–242. DOI: 10.5194/isprs-archives-xlvi-4-w6-2021-235-2021
- Otsu, N., 1979. A threshold selection method from gray-level histograms, *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1):62–66. DOI: 10.1109/TSMC.1979.4310076
- Pham, T.D., Bui, D.T., Yoshino, K. & Le, N.N., 2019a. A comparative study of different vegetation indices for mangrove mapping using Sentinel-2 imagery, *International Journal of Remote Sensing*, 40(6):2411–2428. DOI: 10.1080/01431161.2018.1533660
- Pham, T.D., Yoshino, K., Le, N.N. & Bui, D.T., 2019b. Mangrove mapping and change detection using Sentinel-2 imagery in tropical coastal areas, *Remote Sensing*, 11(8):907. DOI: 10.3390/rs11080907
- Plourde, L. & Congalton, R., 2003. Sampling method and sample placement: How do they affect the accuracy of remotely sensed maps?, *Photogrammetric Engineering and Remote Sensing*, 69(3):289–297. DOI: 10.14358/pers.69.3.289
- Pramudito, W.A., Suprijanto, J. & Soenardjo, N., 2020. Perubahan luasan vegetasi mangrove di Desa Bedono Kecamatan Sayung Kabupaten Demak tahun 2009 dan 2019 menggunakan citra satelit Landsat, *Journal of Marine Research*, 9(2):131–136. DOI: 10.14710/jmr.v9i2.26093
- Prihantono, J., Nakamura, T., Nadaoka, K., Wirasatriya, A. & Adi, N., 2022. Rainfall variability and tidal inundation influences on mangrove greenness in Karimunjawa National Park, Indonesia, *Sustainability*, 14(14):8948. DOI: 10.3390/su14148948
- Sankaran, R., Al-Khayat, J., Aravind, J., Chatting, M., Sadooni, F. & Al-Kuwari, H., 2023. Retrieval of suspended sediment concentration (SSC) in the Arabian Gulf water of arid region by Sentinel-2 data, *The Science of the Total Environment*, 166875. DOI: 10.1016/j.scitotenv.2023.166875
- Son, H., Quang, P.D., Hoa, N.T.H. & Truong, V.V., 2022. Using Sentinel-2 data for above-ground mangrove biomass and carbon stocks mapping over 7 years (2016–2022) in Tien Yen, Quang Ninh Province, *Journal of Forestry Science and Technology*, 14:153–165. DOI: 10.55250/jo.vnuf.2022.14.153-165
- Srivastava, A., Bharadwaj, S., Dubey, R., Sharma, V. & Biswas, S., 2022. Mapping vegetation and measuring the performance of machine learning algorithm in LULC classification in the large area using Sentinel-2 and Landsat-8 datasets of Dehradun as a test case, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2022:529–536. DOI: 10.5194/isprs-archives-xxiii-b3-2022-529-2022

- Toosi, N., Soffianian, A., Fakheran, S., Pourmanafi, S., Ginzler, C. & Waser, L., 2020. Land cover classification in mangrove ecosystems based on VHR satellite data and machine learning – an upscaling approach, *Remote Sensing*, 12(17):2684. DOI: 10.3390/rs12172684
- Tran, T., Reef, R. & Zhu, X., 2022. A review of spectral indices for mangrove remote sensing, *Remote Sensing*, 14(19):4868. DOI: 10.3390/rs14194868
- Trinh, X.T., Nguyen, L. & Takeuchi, W., 2023. Sentinel-2 mapping of a turbid intertidal seagrass meadow in Southern Vietnam, *Geocarto International*, 38(6):1512–1528. DOI: 10.1080/10106049.2023.2186490
- Valderrama-Landeros, L., Troche-Souza, C., Alcántara-Maya, J., Velázquez-Salazar, S., Vázquez-Balderas, B., Villeda-Chávez, E., Cruz-López, M., Ressler, R., Flores-Verdugo, F. & Flores-De-Santiago, F., 2024. An assessment of mangrove forest in northwestern Mexico using the Google Earth Engine cloud computing platform, *PLOS ONE*, 19(6):e0315181. DOI: 10.1371/journal.pone.0315181
- Wang, Y., Jin, S. & Dardanelli, G., 2024. Vegetation classification and evaluation of Yancheng coastal wetlands based on random forest algorithm from Sentinel-2 images, *Remote Sensing*, 16(7):1124. DOI: 10.3390/rs16071124
- Wilson, K., Wong, M. & Devred, E., 2020. Branching algorithm to identify bottom habitat in the optically complex coastal waters of Atlantic Canada using Sentinel-2 satellite imagery, *Frontiers in Environmental Science*, 8:579856. DOI: 10.3389/fenvs.2020.579856
- Zablan, C., Blanco, A., Nadaoka, K., Martinez, K. & Baloloy, A., 2023. Assessment of mangrove extent extraction accuracy of threshold segmentation-based indices using Sentinel imagery, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-4/W6-2022:391–398. DOI: 10.5194/isprs-archives-4-w6-2022-391-2023