

PEMETAAN MANGROVE MENGGUNAKAN ALGORITMA MULTIVARIATE RANDOM FOREST

Studi Kasus di Segara Anakan, Cilacap

(Mapping of Mangrove using Multivariate Random Forest Algorithm, Case Study in Segara Anakan, Cilacap)

Muhammad Rizki Nandika¹, A.A. Md. Ananda Putra Suardana¹, Nanin Anggraini²

¹Pusat Riset Oseanografi, Organisasi Riset Kebumihan dan Maritim, BRIN

²Pusat Riset Penginderaan Jauh, Organisasi Riset Penerbangan dan Antariksa, BRIN

Jl. Pasir Putih I, Ancol Timur, Jakarta 14430

E-mail: muhammad.rizki.nandika@brin.go.id

Diterima: 14 Juli 2022; Direvisi: 20 Maret 2023; Disetujui untuk Dipublikasikan: 27 Maret 2023

ABSTRAK

Potensi pengembangan dan pemanfaatan *Artificial Intelligence* (AI) dan *Machine Learning* (ML) terus meningkat untuk dimanfaatkan dalam pemrosesan data penginderaan jauh pada periode waktu terakhir. Teknologi penginderaan jauh telah terbukti dapat diandalkan untuk mendeteksi sebaran tutupan mangrove. Salah satu metode berbasis ML yang digunakan untuk melakukan deteksi sebaran tutupan mangrove adalah metode *Random Forest*. Penelitian ini berfokus pada pengujian akurasi klasifikasi *Random Forest* dalam mengidentifikasi mangrove di Segara Anakan, Cilacap. Seluruh pemrosesan data dan analisis dilakukan menggunakan platform berbasis cloud, *Google Earth Engine*. Data yang digunakan yaitu citra satelit Sentinel-2A akuisisi tanggal 1 Januari - 31 Desember 2020. Metode klasifikasi menggunakan algoritma RF dengan 12 kombinasi band dan indeks yang berbeda: biru, hijau, merah, *red edge*, NIR, SWIR-1, SWIR-2, NDVI, MNDWI, SR, GCVI, MMRI. Hasil penelitian menunjukkan bahwa hasil klasifikasi menggunakan 12 parameter mampu mengidentifikasi mangrove dengan nilai akurasi yang tinggi (OA = 0,892; kappa = 0,782). Hasil penelitian ini menunjukkan bahwa MMRI menjadi parameter yang diketahui memiliki kemampuan yang paling baik dalam memisahkan objek mangrove dan non-mangrove, diikuti selanjutnya oleh SWIR-2.

Kata kunci: akurasi, indeks vegetasi, mangrove, *random forest*, Sentinel-2

ABSTRACT

The potential of *Artificial Intelligence* (AI) and *machine learning* (ML) has also been utilized in remote sensing data processing in recent times. Remote sensing technology has been proved for mangrove detection. One of the most widely used ML-based methods for classifying is *Random Forest* (RF). This study focuses on examining the accuracy of RF classification to retrieve the information of mangroves in Segara Anakan, Cilacap. All data processing and analysis is carried out using a cloud-based platform, *Google Earth Engine*. The data used in this study is the Sentinel-2A satellite imagery acquired on January 1 - December 31, 2020. The RF classification uses 12 band and index combinations: blue, green, red, red edge, NIR, SWIR-1, SWIR-2, NDVI, MNDWI, SR, GCVI, and MMRI. The results showed that the classification results using 12 parameters could identify mangroves with a high accuracy value (OA = 0.892; kappa = 0.782). The results of this study indicate that MMRI is the parameter known to have the best ability to separate mangrove and non-mangrove objects, followed by SWIR-2.

Keywords: accuracy, vegetation index, mangrove, random forest, Sentinel-2

PENDAHULUAN

Mangrove merupakan suatu ekosistem yang sangat penting di wilayah pesisir, karena memberikan banyak manfaat dalam berbagai aspek. Dari segi ekologi, mangrove berperan sebagai tempat perlindungan bagi berbagai jenis flora dan fauna seperti burung, ikan, invertebrata, mamalia. Selain itu, habitat muara yang terdapat di dalam ekosistem mangrove juga merupakan tempat yang ideal untuk pemijahan biota laut seperti udang, kepiting, dan berbagai jenis ikan (Ouyang & Guo, 2021). Dalam aspek komersial,

pengembangan kawasan mangrove sebagai lokasi pariwisata juga memberikan manfaat ekonomi bagi masyarakat di sekitar (Arkwright & Kaomaneng, 2018; Henri & Ardiawati, 2020). Keberadaan mangrove sebagai pertahanan alami pantai juga berfungsi untuk mencegah erosi dan menjaga garis pantai tetap stabil, sehingga membantu dalam pencegahan keterpaparan gelombang laut (Menéndez et al., 2020). Dalam konteks perubahan iklim, mangrove juga dapat menangkap sejumlah besar emisi karbon dioksida dan gas rumah kaca lainnya dari atmosfer, lalu

menyimpannya dalam bentuk karbon (Rudianto et al., 2020)

Mangrove saat ini menghadapi berbagai bahaya yang mengancam keberlangsungan hidupnya. Kenaikan permukaan air laut akibat pemanasan global telah menjadi salah satu ancaman utama dalam proses terjadinya degradasi ekosistem mangrove (Mafi-Gholami et al., 2020). Selain itu, ancaman antropogenik seperti pembuangan limbah ke perairan juga memperparah keadaan yang menyebabkan polusi dan merusak habitat mangrove (Kesavan et al., 2021).

Hutan mangrove di Indonesia dinyatakan mengalami degradasi yang cukup besar, dimana pada tahun 1990 hingga 2000, terjadi penurunan luas hutan mangrove di Indonesia sebesar 17% (Giesen et al., 2007). Faturrohman & Marjuki (2017), melalui studinya juga menyebutkan bahwa dalam periode tahun 2000 hingga 2005, luas hutan mangrove mengalami penurunan sekitar 1,6% atau 50 ribu hektar. Berdasarkan laporan pemutakhiran Peta Mangrove Nasional yang dikeluarkan oleh Kementerian Lingkungan Hidup dan Kehutanan (KLHK) tahun 2021, diketahui luas mangrove Indonesia saat ini adalah 3.364.080 ha.

Beberapa tahun terakhir, banyak satelit yang diluncurkan dan menunjukkan kemampuan yang mumpuni dalam mengidentifikasi kondisi mangrove, seperti Landsat 5-9 (1984-sekarang), Sentinel-1 (2015-sekarang), Sentinel-2 (2015-sekarang), Worldview 1-4 (2007-sekarang), Pleiades (2011-sekarang), (Achmad et al., 2020; Cipta et al., 2021; Ghorbanian et al., 2021; Hu et al., 2020; Jamaluddin et al., 2022; Rahmandhana et al., 2022; Ridho et al., 2021; Ulqodry et al., 2021; Wang et al., 2018; Xue & Qian, 2022). Seluruh satelit tersebut dimanfaatkan untuk melakukan pemantauan kondisi mangrove di berbagai lokasi dan memberikan cakupan informasi spasial yang luas dengan resolusi temporal yang cukup panjang.

Salah satu metode yang saat ini banyak dimanfaatkan untuk melakukan pemantauan mangrove adalah klasifikasi tutupan lahan menggunakan algoritma *Random Forest* (RF) (Aviña-Hernández et al., 2023; Behera et al., 2021; Diniz et al., 2019; Ghorbanian et al., 2021; Jamaluddin et al., 2022; Jhonnerie et al., 2015; Purwanto et al., 2023). Beberapa studi telah dilakukan, dan menunjukkan potensi luar biasa yang dimiliki RF dalam melakukan identifikasi mangrove. Bahkan, beberapa penelitian mampu menghasilkan nilai *Overall Accuracy* (OA) yang tinggi hingga mencapai lebih dari 90% (Ghorbanian et al., 2021; Hu et al., 2020; Jhonnerie et al., 2015; Purwanto et al., 2023).

Fokus dari penelitian ini adalah melakukan pemetaan mangrove menggunakan algoritma RF dengan memanfaatkan beberapa kombinasi atribut. Penelitian ini mengambil lokasi di Segara Anakan, Kabupaten Cilacap, Jawa Tengah, dengan pertimbangan wilayah tersebut memiliki

keragaman spesies serta perubahan mangrove yang cukup dinamis.

METODE

Lokasi Penelitian

Penelitian dilaksanakan di Segara Anakan, Kabupaten Cilacap, Jawa Tengah (**Gambar 1**). Wilayah Segara Anakan merupakan lokasi dengan berbagai spesies mangrove dan tanaman lain. Melalui laporan yang diberikan oleh Hinrichs et al. (2009), terdapat 21 spesies dan 5 genus tanaman, dengan kerapatan pohon mencapai $0,80 \pm 0,99$ Ind./m². Namun, banyaknya aktivitas pembukaan lahan sawah telah menyebabkan terjadinya laju penurunan luas mangrove di Segara Anakan, dan kegiatan tersebut masih berlangsung hingga saat ini (Hariyadi & Madduppa, 2018).

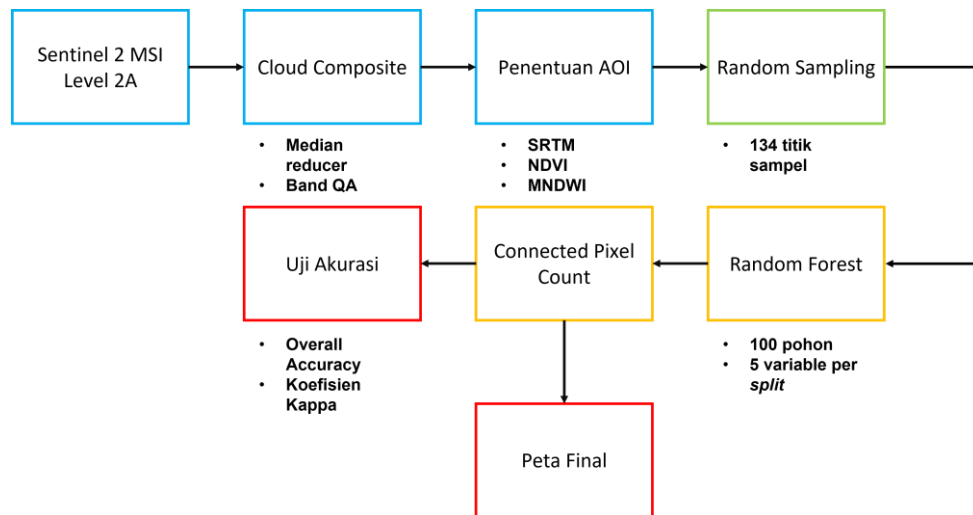


Gambar 1. Lokasi penelitian Segara Anakan, Kabupaten Cilacap, Jawa Tengah.

Citra yang digunakan untuk melakukan proses klasifikasi pada penelitian ini berasal dari data *European Space Agency* (ESA) Sentinel-2 MSI Level-2A yang merupakan data *Surface Reflectance* (SR) yang telah melalui proses koreksi geometrik dan atmosferik (**Tabel 1**). Sentinel-2 sendiri adalah citra satelit multispektral yang terdiri dari 13 *band*, meliputi *visible band*, *infrared band* dan *coastal aerosol band*.

Tabel 1. Spesifikasi citra satelit Sentinel-2 L2A, mencakup resolusi spasial dan resolusi spektral.

Resolusi Spasial (m)	Resolusi Spektral (nm)
10	4 band (Blue (~493 nm), Green (~560 nm), Red (~665 nm), NIR (~833))
20	6 band (4 band pada Vegetation Red Edge Band (~704nm, ~740nm, ~783nm dan ~865nm) dan 2 band SWIR (~1610nm dan ~2190nm))
60	3 band (Coastal Aerosol (~443 nm), Water Vapour (~945 nm) dan Cirrus band (~1374 nm))



Gambar 2. Diagram aliran pengolahan pada platform GEE. Langkah-langkah terkait dengan persiapan data (biru), desain sampel (hijau), prosedur klasifikasi (kuning) dan hasil akhir (merah).

Metode Penelitian

Seluruh proses pengolahan dan analisis data dilakukan di dalam platform Google Earth Engine (GEE). Secara umum proses identifikasi mangrove melalui 3 tahapan utama, meliputi 1) persiapan data; 2) pembuatan desain sampel; dan 3) klasifikasi. Seluruh hasil tersebut menghasilkan 2 keluaran meliputi peta mangrove dan nilai akurasi. Gambar 2 menunjukkan diagram detail mengenai proses pengolahan data.

Akuisisi Data Satelit

Kumpulan citra Sentinel-2 L2A dengan cloud cover kurang dari 20 persen digunakan untuk menghasilkan komposit periode tahunan yang bebas awan di wilayah Segara Anakan, dengan tanggal akuisisi dari 1 Januari hingga 31 Desember 2020. Proses cloud masking memanfaatkan QA band (Quality Assessment) dan fungsi reducer median yang tersedia di dalam GEE. Penggunaan QA band berfungsi untuk menghapus kontaminasi awan yang terdapat pada setiap citra, sedangkan fungsi reducer median digunakan untuk memilih nilai tengah piksel dari seluruh tumpukan citra yang digunakan. Dari hasil tersebut didapatkan satu citra yang terhindar dari nilai piksel terlalu terang (misalnya awan) atau terlalu gelap (misalnya bayangan).

Penentuan Lokasi Tumbuhnya Mangrove

Proses selanjutnya adalah mempersempit daerah kajian dengan menentukan lokasi tumbuhnya mangrove. Dengan mengasumsikan bahwa mangrove tumbuh pada wilayah pasang surut di ketinggian yang rendah, maka kami menggunakan beberapa kombinasi parameter yang terdiri data Digital Elevation Model (DEM), indeks vegetasi dan indeks air. DEM digunakan untuk wilayah daratan dengan elevasi yang rendah, sedangkan kombinasi indeks vegetasi dan

air digunakan untuk mengenali vegetasi pada wilayah pasang surut yang terendam air secara berkala. Kombinasi pengaturan ketiga parameter tersebut ditunjukkan pada Tabel 2.

Tabel 2. Kombinasi penentuan wilayah tumbuhnya mangrove

Parameter	Pengaturan
Ketinggian	SRTM dengan nilai elevasi kurang dari 50 meter
Indeks vegetasi	NDVI dengan nilai indeks lebih dari 0,25
Indeks air	MNDWI dengan nilai indeks lebih dari -0,5

Informasi ketinggian memanfaatkan data Shuttle Radar Topography Mission (SRTM) dengan resolusi spasial 30 meter. Sedangkan indeks vegetasi dan air masing-masing memanfaatkan nilai Normalized Difference Vegetation Index (NDVI) (Pettoirelli et al., 2011) dan Modified Difference Water Index (MNDWI) (Xu, 2006) yang didapatkan melalui transformasi digital citra dari data Sentinel-2 L2A, dengan analisis dilakukan pada resolusi spasial 10 meter.

Penentuan Sampel dan Klasifikasi Citra

Sebanyak 134 titik sampel yang terdiri dari perolehan data lapangan dan pengamatan visual citra diambil dengan menggunakan metode Cluster Random Sampling, dimana AOI dibagi ke dalam sebuah area kecil secara merata, kemudian titik sampel diambil secara acak dalam potongan area tersebut. Selanjutnya berdasarkan sampel yang dikumpulkan, 70% titik digunakan untuk proses klasifikasi, dan 30% titik untuk uji akurasi.

Sedangkan untuk proses klasifikasi, penelitian ini memanfaatkan metode klasifikasi RF untuk mengkategorikan tutupan lahan ke dalam dua kelas yang berbeda, yaitu mangrove (Mg) dan non mangrove (non Mg). Penelitian ini menggunakan

12 parameter yang digunakan sebagai input dalam proses klasifikasi (**Tabel 3**). Penggunaan RF didasarkan pada fakta bahwa metode ini dapat menghasilkan nilai akurasi yang tinggi dalam memprediksi hasil untuk masalah klasifikasi dan regresi (Breiman, 2001; Rodriguez-Galiano et al., 2012). Metode RF berjalan dengan menggabungkan sejumlah pohon keputusan (*decision tree*), dan masing-masing dilatih pada subset data yang berbeda. Studi ini memanfaatkan 100 pohon, dengan 5 variabel per *split* untuk melakukan proses klasifikasi. Dalam beberapa kasus, penggunaan 100 pohon pada metode RF dicatat mampu memberikan kinerja yang baik dalam melakukan klasifikasi, terutama untuk kumpulan data yang sedikit dan proses klasifikasi yang sederhana. Hal ini juga dikemukakan oleh Oshiro et al. (2012) yang menyebutkan bahwa metode RF bekerja baik untuk dijalankan pada jumlah pohon antara 64–128 pohon. Selain itu, pemilihan lima variabel per *split* dilakukan karena pengaturan ini dapat meningkatkan keanekaragaman dalam setiap pohon keputusan, menghasilkan kinerja yang lebih baik pada kumpulan data yang kompleks (Regier et al., 2023).

Tabel 3. Indeks yang digunakan dalam proses klasifikasi

Parameter	Formula	Sumber
Blue	B2	
Green	B3	
Red	B4	
NIR	B8	
NIR	B8A	
SWIR-1	B11	
SWIR-2	B12	
Simple Ratio (SR)	$\frac{NIR}{RED}$	(Jordan, 1969)
Normalized Difference Vegetation Index (NDVI)	$\frac{NIR - RED}{NIR + RED}$	(Pettorelli et al., 2011)
Modified Normalized Difference Water Index (MNDWI)	$\frac{GREEN - SWIR1}{GREEN + SWIR1}$	(Xu, 2006)
Greenness Chlorophyll Vegetation Index (GCVI)	$\frac{NIR}{GREEN} - 1$	(Gitelson et al., 2003)
Modular Mangrove Recognition Index (MMRI)	$\frac{ MNDWI - NDVI }{ MNDWI + NDVI }$	(Diniz et al., 2019)

Uji Akurasi

Langkah terakhir, dilakukan uji akurasi hasil klasifikasi dengan menggunakan metode *confusion matrix* (Congalton & Green, 2019). Langkah ini bekerja dengan cara membandingkan peta yang dihasilkan oleh klasifikasi citra dengan

data referensi. Matriks ini memberikan informasi mengenai *Overall Accuracy* (OA), dimana nilai ini menggambarkan seberapa akurat peta menggambarkan kenampakan nyata sesuai dengan data referensi (Congalton & Green, 2019). Perhitungan metode *confusion matrix* ditunjukkan pada **Persamaan (1)**.

$$Overall Accuracy = \frac{N \sum_{i=1}^k n_{ij}}{n} \dots\dots\dots(1)$$

- k : jumlah kelas
- n_{ij} : jumlah piksel sampel dalam sel (i,j)
- n_{+j} : jumlah piksel sampel dalam kolom kelas referensi
- n_{i+} : jumlah piksel sampel dalam baris kelas peta

Selanjutnya untuk mengukur nilai kesepakatan antara data referensi dan data hasil klasifikasi, dilakukan perhitungan statistik menggunakan metode Cohen Kappa yang dikembangkan pertama kali oleh Cohen (1960). Koefisien kappa Cohen bernilai antara -1 hingga 1, dengan nilai 1 menunjukkan kesepakatan sempurna, nilai 0 menunjukkan tingkat kesepakatan yang diharapkan secara kebetulan, dan nilai negatif menunjukkan kesepakatan yang lebih rendah dari tingkat kesepakatan yang diharapkan secara kebetulan. Perhitungan nilai Cohen Kappa menggunakan **Persamaan (2)**.

$$K = \frac{N \sum_{i=1}^k m_{ij} - \sum_{i=1}^n (G_i C_i)}{N^2 - \sum_{i=1}^n (G_i C_i)} \dots\dots\dots(2)$$


di mana:

- K : koefisien kappa
- N : jumlah nilai yang diklasifikasikan dibandingkan dengan nilai kebenaran
- m_{ij} : total nilai kebenaran kelas i yang telah diklasifikasikan ke dalam kelas i
- C_i : total nilai prediksi kelas i
- G_i : total nilai kebenaran kelas i

HASIL DAN PEMBAHASAN

Penampakan Visual Mangrove

Berdasarkan tampilan citra Sentinel-2 LC2A komposit *RGB false color* (NIR, SWIR, red) terlihat perbedaan antara objek mangrove dengan objek non-mangrove lainnya. Objek bangunan dan lahan terbuka ditunjukkan dengan warna hijau, yang terdapat pada sisi timur wilayah kajian. Sementara objek yang mengandung air, seperti badan air dan juga sawah tadah hujan, ditunjukkan dengan warna biru gelap dan hitam. Semakin tinggi kandungan air, maka semakin gelap warna yang dihasilkan. Objek vegetasi non mangrove menjadi objek yang paling sulit dibedakan diantara seluruh objek yang ada. Objek ini memiliki warna oranye terang, sementara objek mangrove memiliki warna oranye yang lebih tua (**Gambar 4**).



Gambar 4. Tampilan mangrove dari komposit untuk RGB *false color* (NIR, SWIR, red). Kotak kuning menunjukkan lokasi mangrove sejati, sedangkan kotak putih menunjukkan lokasi mangrove asosiasi.

Perbedaan warna ini disebabkan karena adanya perbedaan nilai yang cukup tinggi antara nilai mangrove dan non-mangrove yang terdeteksi oleh kanal NIR, SWIR, dan red. Kanal NIR dan red sensitif terhadap tingkat kehijauan vegetasi sedangkan SWIR sensitif pada tingkat kelembaban tanah. Reflektan kanal red, NIR, dan SWIR pada vegetasi non-mangrove memiliki pola yang hampir sama dimana nilai kanal NIR lebih tinggi dibandingkan dengan nilai pada kanal SWIR dan red. Pada vegetasi mangrove, pola ini tidak berlaku. Nilai reflektan kanal NIR pada mangrove lebih tinggi dibandingkan dengan kanal SWIR dan red bahkan nilai tersebut lebih tinggi dibandingkan dengan nilai NIR pada vegetasi non-mangrove. Adapun nilai reflektan kanal SWIR dan red mangrove berbanding terbalik dengan nilai NIR bahkan lebih rendah dibandingkan dengan nilai pada vegetasi non-mangrove. Hal ini disebabkan karena pengaruh dari kanal SWIR yang sensitif terhadap kelembaban dari permukaan tanah dimana lokasi tumbuh mangrove selalu lembab akibat adanya pasang surut.

Mangrove Segara Anakan tumbuh memanjang dari arah barat ke timur dengan berbagai variasi warna tampilan citra, terlihat dari warna oranye tua dan yang sedikit lebih cerah. Mangrove berwarna oranye muda terdeteksi di Segara Anakan bagian barat sedangkan warna oranye tua di bagian timur. Gradasi warna disebabkan oleh perbedaan spesies yang tumbuh di wilayah tersebut. Berdasarkan informasi dari berbagai literatur dan hasil survei yang telah dilakukan, diketahui bahwa mangrove yang tumbuh di bagian barat adalah mangrove asosiasi dan mangrove yang tumbuh di sisi bagian timur didominasi oleh mangrove sejati (Anggraini et al., 2019). Spesies mangrove asosiasi ini memiliki adaptasi khusus yang memungkinkannya tumbuh di tanah yang lebih kering dan tidak tergenang air laut secara terus-menerus. Sementara itu, mangrove sejati tumbuh di daerah yang lebih rendah di sepanjang garis pantai dan terendam air laut secara terus-menerus (Kandasamy & Bingham, 2001; Spalding et al., 2010; Tomlinson, 2016). Koswara et al. (2017) menyatakan bahwa mangrove di sisi bagian barat didominasi oleh

mangrove *Derris sp* dan *Acanthus sp*, bagian tengah dijumpai adanya mangrove sejati dan dominan mangrove ikutan lainnya, dan di bagian timur didominasi oleh mangrove sejati dengan kerapatan yang cukup tinggi.

Penentuan AOI Mangrove

Pembatasan AOI dengan DEM kurang dari 50 meter, NDVI lebih besar dari 0,25, dan MNDWI lebih besar dari -0,5 digunakan dengan asumsi bahwa mangrove berada pada wilayah pesisir, dimana mangrove merupakan salah satu jenis vegetasi yang hanya hidup pada wilayah dengan ketinggian kurang dari 50 meter dan masih tergenang oleh air. Melalui penggunaan tiga parameter tersebut sebagai pembatas dalam menentukan AOI, didapatkan wilayah kajian secara spesifik sebagaimana ditunjukkan pada **Gambar 5**.



Gambar 5. Hasil median komposit untuk RGB *false color* (NIR, SWIR, Red) setelah ditambahkan fungsi *masking* melalui 3 parameter (DEM, NDVI, MNDWI).


Penentuan AOI dalam rangkaian proses klasifikasi menjadi sebuah langkah yang penting untuk menghasilkan klasifikasi dengan nilai akurasi yang baik. Penggunaan AOI yang terlalu luas dapat menyebabkan banyaknya jenis tutupan lahan lain yang masuk ke dalam AOI, sehingga meningkatkan potensi adanya kesalahan klasifikasi (*misclassification*) yang cukup banyak. Pemotongan AOI secara spesifik di lokasi kajian dapat meminimalisir potensi kesalahan klasifikasi tersebut.

Proses Filtering

Proses *filtering* dilakukan untuk menghasilkan klasifikasi bebas *noise*, sehingga informasi yang didapatkan jauh lebih akurat. Melalui fungsi filter "*connectedPixelCount*" pada *platform* GEE, *noise* teridentifikasi dalam piksel yang tidak terhubung dengan kumpulan piksel (mangrove). **Gambar 6** menunjukkan hasil pengolahan data citra sebelum dan sesudah dilakukannya proses *filtering*.

Pada hasil klasifikasi sebelum dilakukannya *filtering*, terlihat adanya sebaran piksel di sekitar daratan yang terdeteksi sebagai mangrove (kotak kuning). Ini adalah *noise*, dimana citra satelit gagal mendeteksi objek tersebut, sehingga terjadi

kesalahan klasifikasi dalam pendeteksian objek mangrove. *Noise* yang diperoleh pada pengolahan ini mungkin disebabkan karena beberapa faktor, seperti gangguan atmosfer, resolusi citra yang kurang detail atau karena adanya pembiasan radiometrik (Kumar & Jebarani, 2019). Penurunan kualitas dari hasil klasifikasi inilah yang selanjutnya diperbaiki dengan melakukan proses *filtering*. Setelah dilakukannya proses *filtering*, dapat terlihat bahwa beberapa kesalahan klasifikasi yang terjadi sebelumnya dapat dihilangkan dengan baik.



Gambar 6. Hasil klasifikasi mangrove berbasis piksel sebelum diterapkan fungsi filter (a), hasil klasifikasi mangrove setelah diterapkan filter (b). Kotak kuning menunjukkan area yang terpengaruh dengan adanya proses *filtering*.

Hasil Uji Akurasi


Metode RF dengan 12 parameter berhasil melakukan klasifikasi objek mangrove dengan hasil yang memuaskan, dengan OA mencapai 0,892 (**Gambar 7**). Hasil klasifikasi tersebut menunjukkan bahwa citra Sentinel-2 dapat memberikan informasi yang akurat tentang objek mangrove di lokasi yang diuji. Koefisien kappa

yang mencapai 0,782 juga menunjukkan bahwa adanya tingkat kesepakatan yang baik antara titik uji dan hasil klasifikasi. Namun, perlu dicatat bahwa tingginya nilai akurasi dapat dipengaruhi oleh penggunaan kelas yang terbatas hanya Mangrove (Mg) dan Non-Mangrove (Non-Mg). Penggunaan kelas yang terbatas ini bertujuan untuk meminimalisir pemisahan data yang kompleks sehingga dapat menghasilkan klasifikasi dengan nilai akurasi yang lebih baik (Dwiputra et al., 2016).

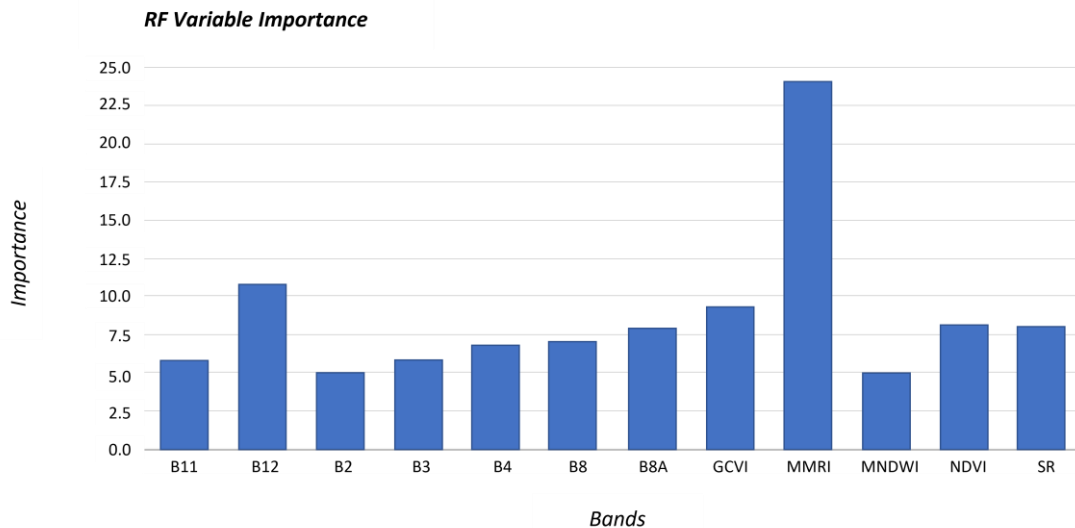
Melalui pengolahan RF juga dihasilkan informasi mengenai *variable importance*. Data ini selanjutnya dapat memberikan informasi yang penting dalam menentukan variabel mana yang memiliki pengaruh paling besar terhadap hasil klasifikasi. Dalam studi ini hasil *variable importance* menunjukkan bahwa beberapa input memiliki nilai penting yang tinggi dalam melakukan klasifikasi objek mangrove (**Gambar 8**).

Pada indeks vegetasi yang digunakan, diketahui MMRI memiliki pengaruh yang besar dalam membedakan antara area mangrove dan non-mangrove. Hal ini sesuai dengan apa yang telah dilakukan oleh Diniz et al., (2019), dimana melalui penelitiannya disebutkan bahwa indeks MMRI memiliki kemampuan yang lebih baik dalam memisahkan objek mangrove dan non-mangrove jika dibandingkan beberapa indeks lainnya, seperti NDVI, NDWI dan CMRI. Lebih lanjut, MMRI juga disebutkan mampu menghasilkan nilai OA yang lebih tinggi 1,5 kali lipat, dan nilai kappa yang lebih tinggi 4 kali lipat dibandingkan dengan nilai yang dilaporkan di indeks lainnya.

Selanjutnya jika dilihat dari masing-masing *band* yang dimiliki citra satelit Sentinel-2, diperoleh informasi bahwa *band* 12 (SWIR-2) memiliki kemampuan yang paling baik dalam memisahkan objek mangrove dan non-mangrove. Hal ini terjadi karena *band* tersebut memiliki tingkat reflektansi yang baik untuk objek vegetasi. MNDWI menjadi parameter yang memiliki nilai *variable importance* yang paling rendah. Ini terjadi karena satelit memiliki kesulitan untuk mendeteksi objek air di wilayah mangrove dengan tajuk yang lebat, sehingga informasi keberadaan air sedikit sulit diperoleh.



Gambar 7. Hasil klasifikasi RF menggunakan 12 parameter.



Gambar 8. Variable Importance dari 12 parameter yang digunakan dalam klasifikasi mangrove menggunakan metode Random Forest.

KESIMPULAN

Penelitian ini mengungkapkan bahwa algoritma RF memiliki kemampuan yang mumpuni dalam mengidentifikasi ekosistem mangrove. Klasifikasi menggunakan 12 parameter (*blue, green, red, red edge, NIR, SWIR-1, SWIR-2, NDVI, MNDWI, SR, GCVI, MMRI*) mampu menghasilkan nilai akurasi yang baik mencapai 0,892 dengan koefisien kappa mencapai 0,782. MMRI menjadi parameter yang diketahui memiliki kemampuan yang paling baik dalam memisahkan objek mangrove dan non-mangrove, diikuti selanjutnya oleh SWIR-2 (*band 12*).

UCAPAN TERIMA KASIH

Ucapan terima kasih Penulis ucapkan kepada Prof. Dr. M. Rokhis Khomarudin S.Si. M.Si., yang telah mendukung penelitian ini. Penulis juga mengucapkan terima kasih kepada seluruh petugas lapangan dan masyarakat lokal Segara

Anakan, Cilacap yang telah membantu dalam pengambilan data lapangan.

DAFTAR PUSTAKA

Achmad, E., Nursanti, N., Marwoto, Fazriyas, F. & Jayanti, D.P. (2020). Studi kerapatan mangrove dan perubahan garis pantai tahun 1989-2018 di Pesisir Provinsi Jambi. *Jurnal Pengelolaan Sumberdaya Alam dan Lingkungan (Journal of Natural Resources and Environmental Management)*, 10(2), 138-152. DOI: <https://doi.org/10.29244/jpsl.10.2.138-152>.

Anggraini, N., Julzarika, A. & Adawiah, S.W. (2019). Detection of true mangroves in Indonesia using satellite remote sensing. *Journal of Environmental Analysis and Progress*, 4(3), 157-167. DOI: <https://doi.org/10.24221/jeap.4.3.2019.2488.157-167>.

Arkwright, D. & Kaomaneng, I.S. (2018). Mangrove ecotourism development on Kakaralamo Island North Halmahera: Community perception, participation, and development strategies. *IOP Conference Series: Earth and Environmental*

- Science, 175(012232). IOP Publishing Ltd. DOI: <https://doi.org/10.1088/1755-1315/175/1/012232>.
- Aviña-Hernández, J., Ramírez-Vargas, M., Roque-Sosa, F. & Martínez-Rincón, R.O. (2023). Predictive performance of random forest on the identification of mangrove species in arid environments. *Ecological Informatics*, 75(102040). DOI: <https://doi.org/https://doi.org/10.1016/j.ecoinf.2023.102040>.
- Behera, M.D., Barnwal, S., Paramanik, S., Das, P., Bhattacharya, B.K., Jagadish, B., ... & Behera, S. K. (2021). Species-level classification and mapping of a mangrove forest using random forest—utilisation of AVIRIS-NG and Sentinel Data. *Remote Sensing*, 13(11), 1-17. DOI: <https://doi.org/10.3390/rs13112027>.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. DOI: <https://doi.org/10.1023/A:1010933404324>.
- Cipta, I.M., Sobarman, F.A., Sanjaya, H. & Darminto, M.R. (2021). Analysis of mangrove forest change from Multitemporal Landsat Imagery using Google Earth Engine Application: (Case Study: Belitung Archipelago 1990-2020). *2021 IEEE Asia-Pacific Conference on Geoscience, Electronics and Remote Sensing Technology, AGERS 2021-Proceeding*, 90-95. Institute of Electrical and Electronics Engineers Inc. DOI: <https://doi.org/10.1109/AGERS53903.2021.9617354>.
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37-46. DOI: <https://doi.org/10.1177/001316446002000104>.
- Congalton, R. & Green, K. (2019). *Assessing the accuracy of remotely sensed data: principles and practices. Third Edition*. DOI: <https://doi.org/10.1201/9780429052729>.
- Diniz, C., Cortinhas, L., Nerino, G., Rodrigues, J., Sadeck, L., Adami, M. & Souza-Filho, P.W.M. (2019). Brazilian mangrove status: Three decades of satellite data analysis. *Remote Sensing*, 11(7), 1-19. DOI: <https://doi.org/10.3390/rs11070808>.
- Dwiputra A.J., Suharyadi, R., & Danoedoro, P. (2016). Pengaruh jumlah kelas dan skema klasifikasi terhadap akurasi informasi penggunaan lahan hasil klasifikasi berbasis objek dengan teknik support vector machine di sebagian Kabupaten Kebumen Provinsi Jawa Tengah. *Majalah Geografi Indonesia*, 30(2), 120-133. DOI: <https://doi.org/https://doi.org/10.22146/mgi.15632>.
- Faturrohman, S. & Marjuki, B. (2017). *Identifikasi dinamika spasial sumberdaya mangrove di Wilayah Pesisir Kabupaten Demak Jawa Tengah*. Diakses dari <https://jurnal.ugm.ac.id/mgi>. [9 September 2022].
- Ghorbanian, A., Zaghian, S., Asiyabi, R.M., 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), 1-18. DOI: <https://doi.org/10.3390/rs13132565>.
- Giesen, W., Wulffraat, S., Zieren, M. & Scholten, L. (2007). *Mangrove guidebook for Southeast Asia*. FAO and Wetlands International. FAO Regional Office for Asia and the Pacific. Bangkok. Thailand.
- Gitelson, A.A., Vina, A., Arkebauer, T.J., Rundquist, D. C., Keydan, G. & Leavitt, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical Research Letters*, 30(5), 52-1-52-4. DOI: <https://doi.org/10.1029/2002gl016450>.
- Hariyadi, S. & Madduppa, H. (2018). Condition and mangrove density in Segara Anakan, Cilacap Regency, Central Java Province, Indonesia. *AACL Bioflux*, 11(4), 1055-1068.
- Henri, H. & Ardiawati, S. (2020). Ecotourism development of Munjang Mangrove Forest and Conservation Efforts based on community approach. *BIOLINK (Jurnal Biologi Lingkungan Industri Kesehatan)*, 7(1), 106-116. DOI: <https://doi.org/10.31289/biolink.v7i1.2952>.
- Hinrichs, S., Nordhaus, I. & Geist, S.J. (2009). Status, diversity and distribution patterns of mangrove vegetation in the Segara Anakan lagoon, Java, Indonesia. *Regional Environmental Change*, 9(4), 275-289. DOI: <https://doi.org/10.1007/s10113-008-0074-4>.
- Hu, L., Xu, N., Liang, J., Li, Z., Chen, L. & Zhao, F. (2020). Advancing the mapping of mangrove forests at national-scale using Sentinel-1 and Sentinel-2 time-series data with Google Earth Engine: A case study in China. *Remote Sensing*, 12(19). DOI: <https://doi.org/10.3390/RS12193120>.
- Jamaluddin, I., Chen, Y.-N., Ridha, S.M., Mahyatar, P. & Ayudyanti, A.G. (2022). Two decades mangroves loss monitoring using Random Forest and Landsat Data in East Luwu, Indonesia (2000–2020). *Geomatics*, 2(3), 282-296. DOI: <https://doi.org/10.3390/geomatics2030016>.
- Jhonnerie, R., Siregar, V.P., Nababan, B., Prasetyo, L.B. & Wouthuyzen, S. (2015). Random Forest classification for mangrove land cover mapping using Landsat 5 TM and ALOS Palsar Imageries. *Procedia Environmental Sciences*, 24, 215-221. DOI: <https://doi.org/https://doi.org/10.1016/j.proenv.2015.03.028>.
- Jordan, C.F. (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4), 663-666. DOI: <https://doi.org/10.2307/1936256>.
- Kandasamy, K. & Bingham, B. (2001). Biology of Mangroves and Mangrove Ecosystems. *Advances in Marine Biology*, 40, 81-251. DOI: [https://doi.org/10.1016/S0065-2881\(01\)40003-4](https://doi.org/10.1016/S0065-2881(01)40003-4).
- Kesavan, S., Xavier, K.A.M., Deshmukhe, G., Jaiswar, A.K., Bhusan, S. & Shukla, S.P. (2021). Anthropogenic pressure on mangrove ecosystems: Quantification and source identification of surficial and trapped debris. *Science of the Total Environment*, 794, 148677. DOI: <https://doi.org/https://doi.org/10.1016/j.scitotenv.2021.148677>.
- Koswara, S.D., Ardli, E.R. & Yani, E. (2017). The monitoring of mangrove vegetation community structure in Segara Anakan Cilacap for the Period of 2009 and 2015. *Scripta Biologica*, 4(2), 113. DOI: <https://doi.org/10.20884/1.sb.2017.4.2.414>.
- Kumar, L.A. & Jebarani, M.R. (2019). A comprehensive review on speckle denoising techniques in satellite images. *2019 International Conference on Communication and Signal Processing (ICCSP), Chennai, India, 2019*, 0245-0248. DOI: <https://doi.org/10.1109/ICCSP.2019.8697926>.
- Mafi-Gholami, D., Zenner, E.K. & Jaafari, A. (2020). Mangrove regional feedback to sea level rise and drought intensity at the end of the 21st century.

- Ecological Indicators*, 110(105972). DOI: <https://doi.org/10.1016/j.ecolind.2019.105972>.
- Menéndez, P., Losada, I.J., Torres-Ortega, S., Narayan, S., & Beck, M.W. (2020). The global flood protection benefits of mangroves. *Scientific Reports*, 10(4404), 1-11. DOI: <https://doi.org/10.1038/s41598-020-61136-6>.
- Oshiro, T.M., Perez, P.S. & Baranauskas, J.A. (2012). *How many trees in a random forest?* 154-168pp. In P. Perner (Ed.) *Machine Learning and Data Mining in Pattern Recognition*. Springer-Verlag. Berlin Heidelberg. Germany.
- Ouyang, X. & Guo, F. (2021). *Patterns of mangrove productivity and support for marine fauna*. 1783-1802pp. In Grigore, M.N. (Ed) *Handbook of Halophytes*. Springer Nature. Switzerland A.G. DOI: https://doi.org/10.1007/978-3-030-57635-6_70.
- Pettorelli, N., Ryan, S., Mueller, T., Bunnefeld, N., Jedrzejewski, B., Lima, M. & Kausrud, K. (2011). The Normalized Difference Vegetation Index (NDVI): Unforeseen successes in animal ecology. *Climate Research*, 46, 15-27. DOI: <https://doi.org/10.3354/cr00936>.
- Purwanto, A.D., Wikantika, K., Deliar, A. & Darmawan, S. (2023). Decision tree and random forest classification algorithms for mangrove forest mapping in Sembilang National Park, Indonesia. *Remote Sensing*, 15-16(1), 1-31. DOI: <https://doi.org/10.3390/rs15010016>.
- Rahmandhana, A.D., Kamal, M. & Wicaksono, P. (2022). Spectral reflectance-based mangrove species mapping from WorldView-2 Imagery of Karimunjawa and Kemujan Island, Central Java Province, Indonesia. *Remote Sensing*, 14(1), 1-17. DOI: <https://doi.org/10.3390/rs14010183>.
- Regier, P., Duggan, M., Myers-Pigg, A. & Ward, N. (2023). Effects of random forest modeling decisions on biogeochemical time series predictions. *Limnology and Oceanography: Methods*, 21(1), 40-52. DOI: <https://doi.org/https://doi.org/10.1002/lom3.10523>.
- Fariz, T.R., Permana, P.I., Daeni, F. & Putra, A.C.P. (2021). Pemetaan Ekosistem Mangrove di Kabupaten Kubu Raya Menggunakan Machine Learning pada Google Earth Engine. *Jurnal Geografi*, 18(2), 83-89. DOI: <https://doi.org/10.15294/jg.v18i2.30231>.
- Rodriguez-Galiano, V.F., Ghimire, B., Rogan, J., Chica-Olmo, M. & Rigol-Sanchez, J.P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93-104. DOI: <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2011.11.002>.
- Rudianto, R., Bengen, D.G. & Kurniawan, F. (2020). Causes and effects of mangrove ecosystem damage on carbon stocks and absorption in East Java, Indonesia. *Sustainability*, 12(10319), 1-17. DOI: <https://doi.org/10.3390/su122410319>.
- Spalding, M., Kainuma, M. & Lorna Collins, L. (2010). *World Atlas of Mangroves*. Routledge. Taylor & Francis Group. London. UK. DOI: <https://doi.org/10.4324/9781849776608>.
- Tomlinson, P.B. (2016). *The Botany of Mangroves* (2nd ed.). Cambridge University Press. Cambridge. UK. DOI: <https://doi.org/10.1017/CBO9781139946575>.
- Ulqodry, T.Z., Aprianto, A.E., Agussalim, A., Aryawati, R. & Absori, A. (2021). Analisis tutupan mangrove Taman Nasional Berbak–Sembilang melalui Citra Landsat-8 dan Pemantauan LAI. *Jurnal Kelautan Tropis*, 24(3), 393-401. DOI: <https://doi.org/10.14710/jkt.v24i3.12278>.
- Wang, M., Cao, W., Guan, Q., Wu, G., Jiang, C., Yan, Y. & Su, X. (2018). Potential of texture metrics derived from high-resolution Pleiades satellite data for quantifying aboveground carbon of Kandelia candel mangrove forests in Southeast China. *Wetlands Ecology and Management*, 26(5), 789-803. DOI: <https://doi.org/10.1007/s11273-018-9610-2>.
- Xu, H. (2006). Modification of Normalized Difference Water Index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033. DOI: <https://doi.org/10.1080/01431160600589179>.
- Xue, Z. & Qian, S. (2022). Generalized composite mangrove index for mapping mangroves using Sentinel-2 time series data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 5131-5146. DOI: <https://doi.org/10.1109/jstars.2022.3185078>.

Halaman Ini Sengaja Kami Kosongkan