

Pemetaan Mangrove Area Tergenang Menggunakan Google Earth Engine dan Random Forest

Moch Farid^{1*}, Taryono², Bambang Widigdo², Fery kurniawan^{2,3}

¹Program Studi Pengelolaan Sumberdaya Pesisir dan Lautan, Departemen Manajemen Sumberdaya Perairan, Fakultas Perikanan dan Ilmu Kelautan, IPB University

²Departemen Manajemen Sumberdaya Perairan, Fakultas Perikanan dan Ilmu Kelautan, IPB University
Kampus IPB Darmaga, Bogor 16680.

³Pusat Kajian Sumberdaya Pesisir dan Lautan, IPB University
Jl. IPB Baranangsiang No.1, Bogor 16129, Indonesia
Email: fariedmoch@gmail.com

Abstrak

Ekosistem mangrove memiliki peran strategis sebagai penyerap karbon, pelindung pantai dari abrasi, dan penyedia habitat bagi keanekaragaman hayati. Namun, pemetaan mangrove di area tergenang menghadapi tantangan serius akibat kompleksitas spektral yang tinggi. Penelitian ini bertujuan: (1) memetakan distribusi spasial mangrove di pesisir Brebes, Jawa Tengah, menggunakan algoritma Random Forest (RF) yang diimplementasikan pada platform Google Earth Engine (GEE) dengan 12 fitur spektral citra Sentinel-2A Level-2A; (2) mengevaluasi kinerja akurasi model dibandingkan pendekatan berbasis indeks tunggal; serta (3) mengidentifikasi variabel spektral paling berpengaruh dalam membedakan mangrove di area tergenang. Metode meliputi akuisisi citra periode Januari–September 2024, ekstraksi fitur spektral (6 band dan 6 indeks vegetasi), serta klasifikasi menggunakan 150 pohon keputusan. Hasil penelitian mengidentifikasi total sebaran mangrove seluas 1.023,28 ha, terbagi dalam kelompok hutan mangrove (531,87 ha) dan kelompok tambak berpola linier mengikuti pematang budidaya (491,41 ha). Validasi model menggunakan 237 titik uji menunjukkan akurasi sangat tinggi (Overall Accuracy 96,27%; Koefisien Kappa 0,925; F1-Score 0,962; User's Accuracy 96,64%), melampaui pendekatan indeks tunggal MVI sebesar 9,46%. Analisis variable importance mengungkapkan MMRI, B12 (SWIR2), dan NDVI sebagai fitur paling berpengaruh, menegaskan peran krusial indeks vegetasi-air gabungan dalam identifikasi mangrove di lingkungan jenuh air.

Kata kunci: *Google Earth Engine, Mangrove, Pemetaan, Random Forest*

Abstract

Mangrove Mapping in Flooded Areas Using Google Earth Engine and Random Forest

Mangrove ecosystems play a strategic role as carbon sinks, coastal protection barriers against abrasion, and biodiversity habitats. However, mapping mangroves in flooded areas presents serious challenges due to high spectral complexity. This study aimed to: (1) map the spatial distribution of mangroves on the Brebes coast, Central Java, using a Random Forest (RF) algorithm implemented on the Google Earth Engine (GEE) platform with 12 spectral features from Sentinel-2A Level-2A imagery; (2) evaluate model accuracy performance compared to single-index approaches; and (3) identify the most influential spectral variables in distinguishing mangroves in flooded areas. Methods included image acquisition from January to September 2024, spectral feature extraction (6 bands and 6 vegetation indices), and classification using 150 decision trees. Results identified total mangrove coverage of 1,023.28 ha, comprising a mangrove forest group (531.87 ha) and an aquaculture pond group with linear patterns along fish pond embankments (491.41 ha). Model validation using 237 test points demonstrated very high accuracy (Overall Accuracy 96.27%; Kappa Coefficient 0.925; F1-Score 0.962; User's Accuracy 96.64%), surpassing the single-index MVI approach by 9.46%. Variable importance analysis revealed MMRI, B12 (SWIR2), and NDVI as the most influential features,

*Corresponding author

DOI:10.14710/buloma.v15i3.81553

<http://ejournal.undip.ac.id/index.php/buloma>

Diterima/Received : 13-01-2026

Disetujui/Accepted : 13-07-2026

confirming the critical role of combined vegetation-water indices in identifying mangroves in waterlogged environments.

Keywords: Google Earth Engine, Mangrove, Mapping, Random Forest

PENDAHULUAN

Pemetaan ekosistem mangrove telah mengalami transformasi signifikan dalam era perkembangan teknologi geospasial yang pesat. Kemunculan platform komputasi berbasis *cloud* seperti *Google Earth Engine* (GEE) yang dikombinasikan dengan algoritma *machine learning* seperti *Random Forest* (RF) telah membuka peluang untuk pemetaan yang lebih efisien, akurat, dan dapat direproduksi pada skala yang luas (Gorelick *et al.*, 2017; Belgiu & Drăguț, 2016). Platform GEE menyediakan infrastruktur komputasi *cloud* yang mampu memproses data satelit multi-temporal berskala besar secara efisien tanpa memerlukan sumber daya komputasi lokal, sehingga menjadi fondasi yang ideal bagi implementasi algoritma *machine learning* untuk analisis tutupan lahan pesisir. Kemampuan ini memungkinkan *processing* data satelit secara masif, seperti citra Sentinel-2, untuk memetakan dan memantau objek kompleks di wilayah pesisir dengan tingkat keberhasilan yang tinggi.

Pemanfaatan platform GEE dan algoritma RF ini menjadi sangat krusial mengingat tingginya nilai strategis ekosistem mangrove sebagai penyerap karbon (*blue carbon*) andal, pelindung alami kawasan pesisir dari abrasi dan intrusi air laut, serta penyedia habitat vital bagi keanekaragaman hayati (Alongi, 2008; Menéndez *et al.*, 2020). Namun, keberlanjutan fungsi-fungsi ekologis ini terus berada di bawah tekanan akibat alih fungsi lahan dan degradasi yang masif (Goldberg *et al.*, 2020), sehingga menuntut pengelolaan yang lebih efektif yang berbasis pada data spasial yang kuat dan terkini.

Secara teknis, pemetaan mangrove di area tergenang menghadapi tiga tantangan utama yang bersifat spesifik: (1) *spectral confusion* antara kanopi mangrove dan badan perairan yang mengakibatkan *mixed pixels*, terutama pada mangrove bertajuk rendah atau muda; (2) respons NDVI yang tertekan akibat kondisi substrat berlumpur jenuh air sehingga menyerupai respons vegetasi non-mangrove; dan (3) variasi morfologi kanopi yang tinggi antara mangrove alami dan mangrove yang tumbuh di pematang tambak. Pendekatan konvensional yang mengandalkan satu

atau dua indeks vegetasi saja, seperti *Normalized Difference Vegetation Index* (NDVI) atau *Mangrove Vegetation Index* (MVI), seringkali kurang kuat untuk membedakan mangrove dari objek lain di wilayah pesisir. Sebagai bukti kuantitatif, Farahdillah *et al.*, (2025) yang menggunakan pendekatan MVI tunggal di lokasi yang berdekatan (Desa Kaliwlingi, Brebes) hanya mampu menghasilkan akurasi 86,81%, mengindikasikan adanya ruang peningkatan yang signifikan melalui pendekatan multi-fitur (Kuenzer *et al.*, 2011; Diniz *et al.*, 2019). Kondisi ini menuntut pendekatan klasifikasi yang mampu menangkap pola spektral non-linear dan multi-dimensi.

Menjawab permasalahan tersebut, penerapan algoritma RF pada platform GEE hadir sebagai solusi yang potensial. GEE menyediakan akses langsung ke arsip citra satelit global beserta kemampuan komputasi paralel yang memungkinkan analisis multi-temporal dan multi-fitur secara simultan (Gorelick *et al.*, 2017). RF mampu memanfaatkan dan menganalisis sejumlah besar variabel input seperti band spektral dan serangkaian indeks yang dirancang khusus, secara simultan, untuk membangun model klasifikasi yang *robust* dan akurat (Maxwell *et al.*, 2018; Belgiu & Drăguț, 2016). Kemampuan RF dalam menangani data berdimensi tinggi dengan karakteristik non-linear menjadikannya sangat sesuai untuk mengatasi tantangan klasifikasi mangrove di area tergenang yang heterogen (Pham *et al.*, 2019).

Penerapan RF pada platform GEE untuk pemetaan mangrove telah dilaporkan di beberapa lokasi di Indonesia, salah satunya oleh Nandika *et al.* (2023) di ekosistem laguna Segara Anakan, Cilacap. Namun, konteks ekosistem mangrove di kawasan pesisir Brebes menghadirkan tantangan spektral yang secara fundamental berbeda. Di Brebes, mangrove tidak hanya terdistribusi sebagai hutan kontinyu, tetapi juga tersebar dalam pola linier mengikuti pematang tambak pada area yang tergenang secara periodik. Kondisi mosaik mangrove-tambak ini menciptakan kompleksitas *spectral mixing* yang lebih tinggi dibandingkan mangrove di ekosistem laguna yang lebih tertutup dan stabil. Oleh karena itu, penelitian ini secara

spesifik mengevaluasi kemampuan RF dengan konfigurasi 12 fitur spektral, termasuk indeks gabungan vegetasi-air MMRI yang dirancang khusus untuk kondisi jenuh air (Diniz *et al.*, 2019), pada ekosistem mangrove-tambak tergenang yang belum banyak terdokumentasi secara kuantitatif di pesisir utara Jawa.

Mengacu pada kerangka pemikiran tersebut, penelitian ini bertujuan untuk: (1) memetakan distribusi spasial mangrove di pesisir Brebes, Jawa Tengah, menggunakan algoritma RF yang diimplementasikan pada platform GEE dengan 12 fitur spektral Sentinel-2A; (2) mengevaluasi kinerja akurasi model yang dihasilkan dibandingkan pendekatan berbasis indeks tunggal; dan (3) mengidentifikasi variabel spektral yang paling berpengaruh dalam membedakan mangrove dari kelas tutupan lahan lainnya di area tergenang. Luaran yang diharapkan adalah peta distribusi mangrove dengan akurasi tinggi melalui klasifikasi biner (mangrove dan non-mangrove) yang dapat menjadi basis data andal untuk mendukung perencanaan pengelolaan ekosistem mangrove yang tepat sasaran di wilayah pesisir Brebes.

MATERI DAN METODE

Penelitian dilakukan di wilayah pesisir Kecamatan Brebes, Kabupaten Brebes, Jawa Tengah (Gambar 1). Kawasan ini merupakan wilayah pesisir yang didominasi oleh aktivitas tambak intensif dan ekosistem mangrove yang terdistribusi dalam mosaik yang kompleks. Pemilihan lokasi didasarkan pada dinamika tutupan

mangrove yang tinggi serta karakteristiknya yang representatif sebagai kawasan pesisir dengan tekanan antropogenik yang tergolong tinggi, dicirikan oleh dominasi aktivitas budidaya tambak yang secara masif mengkonversi lahan mangrove menjadi kolam produksi, serta tekanan dari permukiman dan aktivitas pertanian di kawasan penyangga (Richards & Friess, 2016; Goldberg *et al.*, 2020). Selain tekanan antropogenik, dinamika hidrologis pesisir seperti pasang surut dan fluktuasi muka air musiman juga berkontribusi terhadap perubahan tutupan mangrove di wilayah ini. Batas area penelitian mengacu pada batas administrasi sesuai dengan Rupa Bumi Indonesia (RBI).


Metode pemetaan sebaran mangrove menggunakan integrasi GEE dan RF yang terbagi ke dalam tiga tahapan utama: (1) Pre-pemrosesan data, (2) Klasifikasi, dan (3) Post-pemrosesan serta analisis. Alur kerja komprehensif dari penelitian ini disajikan pada Gambar 2.

Data dan Pre-pemrosesan

Data citra satelit yang digunakan adalah Sentinel-2A Level-2A (*Surface Reflectance*) dari *European Space Agency* (ESA). Citra Level-2A telah terkoreksi atmosferik menggunakan algoritma Sen2Cor dan terkoreksi geometrik, sehingga siap untuk analisis klasifikasi (Drusch *et al.*, 2012). Periode akuisisi citra adalah dari 1 Januari hingga 30 September 2024, dengan kriteria tutupan awan kurang dari 15%. Pemilihan periode ini didasarkan pada kondisi musim kemarau di Jawa bagian utara yang umumnya memiliki tutupan awan lebih rendah.



Gambar 1. Peta lokasi penelitian



Gambar 2. Diagram alir metodologi penelitian

Seluruh proses akuisisi dan pre-pemrosesan citra dilakukan dalam platform *Google Earth Engine* (GEE) (Gorelick *et al.*, 2017), mencakup empat tahapan berurutan: (1) seleksi citra berdasarkan metadata persentase tutupan awan (<15%); (2) *cloud masking* menggunakan band SCL (*Scene Classification Layer*) untuk mengidentifikasi dan mengeliminasi piksel awan, cirrus, dan bayangannya (Zhu & Woodcock, 2012); (3) pembangunan komposit citra menggunakan metode *median reducer* — metode median dipilih karena lebih *robust* terhadap *outlier* seperti piksel awan residual dibandingkan nilai rata-rata (mean),

sehingga menghasilkan representasi kondisi permukaan aktual yang lebih stabil dari seluruh koleksi citra yang tersaring; dan (4) pemotongan (*clipping*) sesuai batas *Area of Interest* (AOI) berdasarkan batas administrasi studi.

Ekstraksi Fitur Spektral

Peningkatan akurasi klasifikasi dilakukan dengan menghitung enam indeks spektral dari band-band Sentinel-2 yang merepresentasikan karakteristik vegetasi dan air (Tabel 2). Keenam indeks ini dipilih secara terarah untuk memperkuat sinyal spektral unik dari mangrove yang seringkali

tercampur dengan kelas tutupan lahan lainnya di daerah pesisir, mencakup indeks berbasis air (NDWI, MNDWI), indeks berbasis vegetasi (GCVI, NDVI), dan indeks yang secara spesifik dirancang untuk ekosistem mangrove di lingkungan jenuh air (MMRI, MVI).

Data Training, Validasi, dan Klasifikasi

Data *training* dan validasi dikumpulkan sebanyak 792 titik sampel dengan distribusi yang seimbang antara kelas mangrove dan non-mangrove. Rincian distribusi titik sampel disajikan pada Tabel 3.

Tabel 2. Indeks Spektral yang Digunakan dalam Klasifikasi

Variabel	Formula	Fungsi dan Kegunaan Spesifik	Sumber
NDWI (Normalized Difference Water Indeks)	$\frac{GREEN-NIR}{GREEN+NIR}$	Mendeteksi kandungan air dalam vegetasi dan badan air, sensitif terhadap kelembapan	(McFEETERS, 1996)
MNDWI (Modified Normalized Difference Water Indeks)	$\frac{GREEN-SWIR1}{GREEN+SWIR1}$	Versi terbaru NDWI yang lebih efektif membedakan air dari tanah dan vegetasi menggunakan band SWIR	(Xu, 2006)
GCVI (Greenness Clorophyll Vegetation Indeks)	$\frac{NIR}{GREEN} - 1$	Mengestimasi kandungan klorofil dengan memanfaatkan respons vegetasi pada band green dan NIR	(Gitelson <i>et al.</i> , 2003)
NDVI (Normalized Difference Vegetation Indeks)	$\frac{NIR-RED}{NIR+RED}$	Mengidentifikasi kerapatan dan kesehatan vegetasi secara umum berdasarkan respons near-infrared dan red.	(Pettorelli <i>et al.</i> , 2011)
MMRI (Modular Mangrove Recognition Indeks)	$\frac{[MNDWI]-[NDVI]}{[MNDWI]+[NDVI]}$	Kombinasi optimal untuk memisahkan mangrove dari vegetasi terrestrial lainnya berdasarkan karakteristik vegetasi dan air	(Diniz <i>et al.</i> , 2019)
MVI (Mangrove Vegetation Indeks)	$\frac{NIR-GREEN}{SWIR1-GREEN}$	Indeks khusus mangrove yang memanfaatkan karakteristik spektral unik mangrove pada band green, NIR, dan SWIR	(Baloloy <i>et al.</i> , 2020)

Keterangan: Blue = B2 (Sensitif terhadap perairan dangkal & sifat optik air), Green = B3 (Merepresentasikan refleksi puncak vegetasi sehat), Red = B4 (Menyerap klorofil kuat), NIR = B8 (Reflektif untuk vegetasi sehat, pembeda utama antara vegetasi & bukan), SWIR = B11 (Sensitif terhadap kandungan air & kelembapan vegetasi), dan SWIR2 = B12 (Sangat sensitif terhadap kelembapan, membantu deteksi stres air & kondisi basah).

Tabel 3. Distribusi Data Titik Sampel Training dan Validasi

Kelas	Total Sampel	Training (70%)	Validasi (30%)	Sumber Data
Mangrove	396	276	120	Survei lapangan + Peta KLHK 2021
Non-mangrove	396	275	121	Peta KLHK 2021
Total	792	551	241	-

Keterangan: Non-mangrove mencakup kelas tambak, permukiman, lahan terbuka, dan badan air.

Data lapangan sebanyak 60 titik diperoleh dari survei lapangan pada Februari–April 2025, sementara titik tambahan diambil secara acak dari Peta Mangrove Nasional Kementerian Lingkungan Hidup dan Kehutanan (KLHK) 2021. Seluruh titik sampel kemudian dibagi secara acak dengan proporsi 70% (555 titik) untuk *training* model dan 30% (237 titik) untuk validasi akurasi.

Proses ekstraksi nilai piksel dilakukan terhadap seluruh titik *training*. Setiap titik secara individual mengekstrak nilai spektral dari 12 fitur dalam *image stack* (6 band spektral + 6 indeks vegetasi), menghasilkan satu baris data yang berisi nilai spektral lengkap dari semua fitur pada lokasinya.

Himpunan data tersebut kemudian digunakan untuk melatih model klasifikasi menggunakan algoritma RF (Breiman, 2001) yang diimplementasikan dalam GEE. Model RF dikonfigurasi dengan 150 pohon keputusan (*ntree* = 150) dan 3 variabel yang dipertimbangkan pada setiap percabangan (*mtry* = 3), yang merupakan akar kuadrat dari total 12 fitur yang digunakan. Dalam konteks dataset dengan $n=555$ sampel dan $p=12$ fitur, konfigurasi ini telah terbukti memberikan keseimbangan *bias-variance* yang optimal (Probst & Boulesteix, 2018) dan efektif untuk menghindari *overfitting* sekaligus menjaga stabilitas model.

Post-Processing dan Analisis Akurasi

Setelah klasifikasi awal, peta hasil klasifikasi disaring (*filtered*) untuk mengurangi *noise* dengan menghapus kelompok piksel yang terisolasi dan kecil. Piksel dari suatu kelas yang terhubung kurang dari 20 piksel (setara dengan 0,2 hektar) dianggap sebagai *noise* dan dikeluarkan dari peta akhir (Gandhi, 2021).

Akurasi klasifikasi dievaluasi menggunakan *confusion matrix* yang dihitung dari 30% data validasi yang disisihkan (Foody, 2002). Hasil *confusion matrix* dan metrik akurasi disajikan pada Tabel 4. Metrik akurasi yang dihitung meliputi: *Overall Accuracy* (OA), *Kappa Coefficient* (κ), *Producer's Accuracy* (PA), *User's Accuracy* (UA), dan *F1-Score* untuk setiap kelas. Nilai *Kappa Coefficient* diinterpretasikan berdasarkan skala Landis & Koch (1977).

Analisis Variable Importance

Analisis *variable importance* dilakukan menggunakan metode *Mean Decrease in Gini* (MDG) atau *Gini Importance* (Nembrini *et al.*,

2018). Metode ini mengukur total pengurangan ketidakmurnian (*Gini Impurity*) yang dihasilkan oleh suatu variabel di seluruh 150 pohon keputusan dalam RF. Nilai MDG yang ditampilkan merupakan nilai absolut akumulatif, bukan persentase relatif, sehingga perbandingan antar variabel bersifat ordinal: semakin tinggi nilai MDG suatu variabel, semakin signifikan kontribusinya dalam membedakan kelas mangrove dan non-mangrove.

HASIL DAN PEMBAHASAN

Akurasi Model Random Forest pada Peta Klasifikasi Mangrove

Hasil validasi model disajikan secara lengkap pada Tabel 5 yang menunjukkan *confusion matrix* dari 241 titik uji independen. Model berhasil mengklasifikasikan 115 titik mangrove secara benar dari 120 titik referensi mangrove, dan 117 titik non-mangrove secara benar dari 121 titik referensi non-mangrove. *Overall Accuracy* yang dihasilkan sebesar 96,27% dengan *Kappa Coefficient* 0,923 yang berdasarkan skala Landis dan Koch (1977) termasuk kategori "hampir sempurna" (*almost perfect agreement*). *User's Accuracy* kelas mangrove sebesar 96,63% mengindikasikan rendahnya tingkat *false positive*, sedangkan *Producer's Accuracy* kelas mangrove sebesar 95,83% menunjukkan rendahnya tingkat *false negative* dalam mendeteksi mangrove yang sesungguhnya ada di lapangan. Konsistensi kinerja model pada kedua kelas, mangrove maupun non-mangrove, memperkuat analisis peta yang dihasilkan secara akurat merepresentasikan kondisi ekosistem yang kompleks di area tergenang. Nilai hasil validasi model ini lebih besar dari penelitian Farahdillah *et al.*, (2025) yang menerapkan pendekatan MVI tunggal di lokasi berdekatan dengan selisih 9,46%. Pham *et al.*, (2019) dalam kajian komprehensifnya menyatakan bahwa pendekatan penginderaan jauh berbasis multi-fitur yang menggabungkan band spektral dan indeks vegetasi terbukti lebih efektif dalam pemetaan mangrove dibandingkan pendekatan indeks tunggal, karena mampu menangkap kekayaan informasi spektral yang diperlukan untuk membedakan mangrove dari kelas tutupan lahan lain yang secara spektral berdekatan di lingkungan pesisir yang kompleks. Keunggulan pendekatan multi-fitur dalam penelitian ini sejalan dengan pernyataan tersebut, di mana konfigurasi 12 fitur spektral yang mencakup band dan indeks vegetasi secara simultan mampu mengatasi kompleksitas *spectral mixing*

mangrove di area tergenang yang tidak dapat diatasi oleh indeks tunggal. Sebagai pembandingan, Nandika *et al.*, (2023) yang menggunakan RF dengan 12 fitur spektral pada platform GEE di ekosistem laguna Segara Anakan, Cilacap mencapai Overall Accuracy 0,892 dengan Kappa 0,782, yakni lebih rendah 4,07% dari hasil penelitian ini.

Perbedaan capaian akurasi tersebut dapat dijelaskan melalui tiga faktor utama. Pertama, kompleksitas spektral ekosistem. Laguna Segara Anakan bersifat lebih tertutup dan homogen secara spektral, sedangkan pesisir Brebes merupakan mosaik mangrove-tambak dengan variabilitas tutupan lahan yang lebih tinggi. Heterogenitas spektral yang lebih besar mengakibatkan *mixed pixels* yang menekan separabilitas antar kelas (Kuenzer *et al.*, 2011; Diniz *et al.*, 2019), dan konfigurasi fitur yang tepat pada penelitian ini mampu mengeksplorasi variabilitas tersebut untuk membangun batas keputusan yang lebih tajam. Kedua, relevansi fitur terhadap kondisi ekosistem. Penyertaan MMRI sebagai indeks gabungan vegetasi-air yang dirancang khusus untuk kondisi jenuh air terbukti menjadi pembeda kunci dalam ekosistem mosaik mangrove-tambak. Maxwell *et al.*, (2018) menegaskan bahwa keunggulan utama

machine learning dalam klasifikasi penginderaan jauh terletak pada kapasitasnya untuk menangani data berdimensi tinggi dan memetakan kelas dengan karakteristik yang sangat kompleks, di mana kesesuaian antara desain fitur spektral dan karakteristik ekosistem target menjadi kunci keberhasilan klasifikasi. Ketiga, ukuran dan distribusi data *training*. Phinzi *et al.*, (2023) membuktikan bahwa ukuran sampel *training* yang lebih besar secara signifikan meningkatkan akurasi dan menstabilkan model RF. Distribusi sampel yang seimbang antara kelas mangrove dan non-mangrove pada penelitian ini berkontribusi pada kinerja model yang konsisten dan minim *bias*. Belgiu dan Dragut (2016) memperkuat hal ini dengan menyimpulkan bahwa RF mampu menangani dimensionalitas data yang tinggi dan multikolinearitas secara efektif serta tidak rentan terhadap *overfitting*, namun sensitif terhadap desain pengambilan sampel *training*, sehingga distribusi sampel yang representatif dan seimbang menjadi prasyarat kritis bagi keberhasilan model. Ketiga faktor ini secara sinergis menjelaskan mengapa konfigurasi 12 fitur spektral yang mencakup MMRI dan band SWIR yang dirancang secara domain-spesifik untuk ekosistem mosaik mangrove-tambak

Tabel 4. Confusion Matrix dan Metrik Akurasi Hasil Klasifikasi

	Aktual: Mangrove	Aktual:Non-Mangrove	User's Accuracy
Prediksi: Mangrove	TP	FN	TP/(TP+FN)
Prediksi:Non-Mangrove	FP	TN	TN/(FP+TN)
Producer's Accuracy	TP/(TP+FP)	TN/(FN+TN)	

Keterangan : TP = True Positive, TN = True Negative, FP= False Positive dan FN= False Negative

Tabel 5. Hasil confusion matrix

	Kelas	Referensi		Total	User Accuracy
		Mangrove	Non-Mangrove		
Prediksi	Mangrove	115	4	119	0,9663
	Non-Mangrove	5	117	122	0,9590
	Total	120	121	241	
	Producer Accuracy	0,9583	0,9669		
	Overall Accuracy			0,9627	
	Kappa Coefficient			0,9230	


tergenang mampu melampaui pendekatan konvensional berbasis indeks tunggal secara signifikan.

Sebaran Spasial Mangrove

Berdasarkan model yang telah tervalidasi, analisis spasial pada peta hasil klasifikasi (Gambar 3) mengungkap total sebaran mangrove seluas 1.023,28 ha yang terbagi dalam dua kelompok dengan karakteristik morfologi berbeda secara fundamental. Kelompok A (Mangrove Hutan) mendominasi dengan luas 531,87 ha (51,98% dari total sebaran), membentuk formasi sabuk hijau yang padat dan kontinu sepanjang $\pm 8,2$ km dengan lebar 200–500 meter di sepanjang garis pantai utara. Kelompok B (Mangrove Tambak) mencapai 491,41 ha (48,02%), tersebar dalam pola linier sempit mengikuti jaringan pematang tambak di zona budidaya. Proporsi yang hampir seimbang antara kedua kelompok ini secara kuantitatif mencerminkan dualisme karakter pesisir Brebes sebagai kawasan yang sekaligus memiliki

ekosistem mangrove pantai alami dan sistem *silvofishery* yang telah berkembang luas.

Formasi mangrove Kelompok A yang mengelompok dan kontinu di zona pantai merupakan hasil kombinasi antara kondisi oseanografi yang mendukung dan intervensi rehabilitasi mangrove yang intensif. Solihuddin *et al.*, (2021) menyatakan bahwa pesisir utara Jawa dicirikan oleh pantai berlumpur dengan proses dominan berupa akresi sedimen yang disuplai oleh sungai-sungai aktif yang bermuara ke Laut Jawa, di mana lapisan lumpur intertidal terpapar hingga ± 2 km ke arah laut saat surut membentuk morfologi *tidal mudflat* yang menjadi habitat ideal bagi kolonisasi mangrove. Kondisi *mudflat* intertidal ini menyediakan substrat yang sesuai bagi *Avicennia marina* sebagai spesies pionir pada zona terdepan yang berhadapan langsung dengan energi gelombang. Sistem perakaran mangrove yang kompleks selanjutnya berperan aktif dalam mempercepat akumulasi sedimen; Krauss *et al.*, (2014) menjelaskan bahwa sistem perakaran udara



Gambar 3. Peta hasil sebaran mangrove di pesisir Brebes, (A) Kelompok Mangrove Hutan, (B) Kelompok Mangrove Tambak

mangrove menghasilkan hambatan terhadap aliran air yang memperlambat kecepatan arus, menciptakan kondisi yang lebih kondusif bagi deposisi dan retensi sedimen yang diangkut oleh pasang surut maupun aliran fluvial, dan efisiensi penangkapan sedimen ini bervariasi antar spesies sesuai dengan morfologi sistem perakarannya. Proses umpan balik biogeomorfik antara pertumbuhan mangrove dan penangkapan sedimen secara progresif memperluas substrat yang tersedia bagi kolonisasi lebih lanjut, mendorong terbentuknya formasi hutan yang berkesinambungan di sepanjang garis pantai.

Kondisi oseanografi yang mendukung tersebut diperkuat oleh dominasi program rehabilitasi mangrove berpola penanaman monokultur yang menjadi faktor penentu karakteristik spasial Kelompok A. Pimple *et al.*, (2022) menyimpulkan bahwa area hasil rehabilitasi umumnya bersifat monokultur dan secara struktural kurang kompleks dibandingkan mangrove alami, namun karakteristik inilah yang menghasilkan *signature* spektral yang lebih beragam, bersih, dan terprediksi sehingga lebih mudah terdeteksi secara akurat oleh model klasifikasi. Tran, Reef & Zhu (2022) dalam kajian komprehensif tentang indeks spektral mangrove menegaskan bahwa karakteristik tekstural dan spektral kanopi mangrove yang bersifat homogen atau heterogen sangat dipengaruhi oleh komposisi spesies, bentuk pertumbuhan, kerapatan, dan tinggi tegakan, sehingga penanaman monokultur yang menyeragamkan keempat variabel tersebut secara langsung menghasilkan pola spasial yang mengelompok dan mudah dibedakan dari kelas tutupan lahan lainnya. Secara ekologis, formasi kontinu Kelompok A memiliki nilai proteksi pesisir yang sangat signifikan. Menéndez *et al.*, (2020) melalui pemodelan hidrodinamik berskala global membuktikan bahwa mangrove menyediakan manfaat proteksi banjir melebihi 65 miliar dolar AS per tahun, dan tanpa keberadaan mangrove, 15 juta orang lebih akan terdampak banjir setiap tahunnya di seluruh dunia. Fungsi proteksi ini menjadikan formasi Kelompok A sangat relevan dalam konteks kerentanan pantai utara Jawa terhadap banjir *rob* dan kenaikan muka air laut yang semakin meningkat (Handiani *et al.*, 2022).

Mangrove Kelompok B menampilkan dinamika pembentukan yang berbeda secara diametral. Pola linier yang ketat mengikuti jaringan pematang tambak merupakan respons simultan terhadap dua tekanan yang saling berinteraksi: modifikasi hidrologi oleh infrastruktur tambak dan

strategi adaptif masyarakat dalam mempertahankan mangrove di tengah tekanan alih fungsi lahan. Pematang tambak mengubah pola sirkulasi dan genangan air secara lokal, menciptakan rezim hidrologi yang berbeda dari zona intertidal terbuka tempat Kelompok A berkembang. Solihuddin *et al.*, (2021) mencatat bahwa pesisir utara Jawa, termasuk kawasan Cirebon-Brebes, secara reguler mengalami banjir pasang (*rob*) yang merendam tambak dan lahan budidaya. Genangan periodik akibat *rob* ini menciptakan kondisi kelembapan substrat pematang yang mendukung pertumbuhan *Rhizophora mucronata*. Kathiresan dan Bingham (2001) dalam kajian komprehensif tentang biologi mangrove menyatakan bahwa distribusi dan dominasi spesies mangrove sangat ditentukan oleh *hidroperiod*, salinitas, dan karakteristik substrat, di mana *Rhizophora* spp. memiliki toleransi yang lebih tinggi terhadap fluktuasi salinitas dan penggenangan intermiten di zona yang secara hidrologi termodifikasi dibandingkan spesies pionir seperti *Avicennia*. Distribusi mangrove Kelompok B mengikuti geometri pematang tambak bukan gradien oseanografi alami, sehingga menghasilkan pola spasial yang sepenuhnya berbeda dari formasi intertidal Kelompok A.

Mangrove Kelompok B merupakan cerminan adaptasi sosial-ekologis masyarakat pesisir Brebes terhadap tekanan lingkungan yang berlangsung selama beberapa dekade. Ilman *et al.*, (2016) dalam kajian historis komprehensif tentang faktor pendorong kehilangan mangrove di Indonesia menyimpulkan bahwa eksploitasi mangrove untuk pengembangan tambak udang air payau telah berlangsung secara sistematis sejak tahun 1800, dan mengakibatkan hilangnya hampir 800.000 hektar mangrove dalam tiga dekade, dengan kehilangan terbesar terkonsentrasi di Jawa dan Sumatera. Konversi masif ini menempatkan pesisir Brebes dalam konteks tekanan antropogenik jangka panjang yang memaksa masyarakat lokal mengembangkan strategi adaptif untuk mempertahankan mangrove di tengah ekspansi tambak. Tekanan abrasi yang meningkat justru mendorong integrasi mangrove ke dalam sistem budidaya tambak sebagai stabilisator pematang dan pelindung lahan produktif, menghasilkan sistem silvofishery yang secara fungsional mempertahankan tutupan mangrove dalam konfigurasi linier mengikuti infrastruktur tambak. Pola adaptasi serupa juga dilaporkan oleh Richards dan Friess (2016) dalam analisis deforestasi mangrove di Asia Tenggara, yang menemukan


bahwa wilayah dengan dominasi akuakultur tradisional cenderung mempertahankan sisa tutupan mangrove dalam formasi sempit di sepanjang pematang, sebagai kompromi antara kebutuhan produksi budidaya dan fungsi ekologis mangrove sebagai pelindung tambak dari erosi. Goldberg *et al.*, (2020) dalam analisis global penurunan mangrove akibat aktivitas manusia menegaskan bahwa tekanan akuakultur merupakan pendorong utama konversi mangrove secara global, namun pada skala lokal menghasilkan lanskap mosaik mangrove-tambak yang berbeda secara fungsional dari kawasan yang mengalami konversi total akibat tekanan industri atau permukiman yang menghasilkan kehilangan mangrove secara permanen. Proporsi Kelompok B yang mencapai 491,41 ha (48,02% dari total sebaran) menegaskan bahwa sistem silvofishery ini bukan fenomena adaptasi marginal, melainkan komponen dominan lanskap mangrove pesisir Brebes dengan signifikansi ekologis dan sosial-ekonomi yang setara Kelompok A.

Perbandingan hasil klasifikasi dengan Peta Mangrove Nasional KLHK (2021) menunjukkan selisih luasan 51,84 ha lebih besar pada hasil penelitian ini. Disparitas tersebut tidak mencerminkan kesalahan pada salah satu sumber data, melainkan dapat dijelaskan melalui dua faktor utama. Pertama, perbedaan resolusi spasial: peta KLHK mengintegrasikan citra Sentinel dengan SPOT-6/7 pada resolusi 1,5 m, sehingga memiliki keunggulan dalam mengidentifikasi formasi mangrove yang sangat sempit dan terpecah yang tidak terdeteksi pada resolusi 10 m Sentinel-2A yang digunakan dalam penelitian ini. Hu *et al.*, (2020) membuktikan bahwa integrasi multi-sensor dengan resolusi tinggi secara signifikan meningkatkan kemampuan deteksi formasi mangrove skala kecil yang sering terlewatkan oleh

sensor resolusi menengah. Kedua, perbedaan temporal: jarak empat tahun antara kedua pemetaan (2021 vs. 2025) berpotensi mencerminkan dinamika tutupan mangrove yang nyata, baik berupa pertumbuhan alami maupun hasil program rehabilitasi yang berjalan kontinu. Giri (2021) menegaskan bahwa tutupan mangrove bersifat dinamis dan terus berubah akibat kombinasi faktor alam dan intervensi manusia, sehingga selisih temporal antara dua periode pemetaan harus diinterpretasikan sebagai cerminan perubahan nyata dan bukan sekadar artefak metodologi. Selain kedua faktor tersebut, resolusi spasial Sentinel-2A sebesar 10 meter berpotensi mengakibatkan *underestimation* pada formasi mangrove linier Kelompok B yang sangat sempit (<10 m), dan potensi misklasifikasi tetap ada pada area transisi antara mangrove dan tambak yang memiliki karakteristik spektral sangat berdekatan. Kuenzer *et al.*, (2011) mencatat bahwa area transisi ekosistem mangrove dengan tutupan lahan lain merupakan zona dengan tingkat ketidakpastian klasifikasi tertinggi dalam penginderaan jauh optik, dan kondisi ini menjadi limitasi inheren yang perlu diperhitungkan dalam interpretasi hasil pemetaan.

Kontribusi Variabel Spektral dalam Klasifikasi

Analisis *variable importance* berdasarkan tingkat kontribusi menunjukkan MMRI sebagai variabel paling dominan dalam membedakan kelas mangrove dan non-mangrove dengan nilai 52,06, diikuti oleh SWIR2 (B12) sebesar 50,48, NDVI sebesar 48,74, MNDWI sebesar 47,71, dan NDWI sebesar 43,92. Tujuh variabel lainnya menunjukkan kontribusi yang relatif lebih rendah. Pola ini mengindikasikan bahwa informasi yang berkaitan dengan vegetasi dan karakteristik perairan pesisir menjadi faktor utama dalam proses identifikasi mangrove di wilayah penelitian.



Gambar 4. Grafik Nilai *Variable Importance* dari 12 Fitur Input dalam Klasifikasi RF

Dominasi variabel yang berkaitan dengan vegetasi dan karakteristik perairan pesisir tidak terlepas dari kondisi biofisik ekosistem mangrove di pesisir Brebes. Mangrove tumbuh di zona intertidal yang secara periodik mengalami pasang surut, sehingga *signature* spektralnya tidak statis melainkan berubah mengikuti dinamika muka air. Genangan pasang surut memberikan dampak signifikan terhadap reflektansi spektral dan koefisien *backscatter* yang digunakan untuk memetakan mangrove, di mana kondisi pasang tinggi mengakibatkan penurunan respons spektral terutama pada mangrove yang jarang dan sebagian terendam di zona seaward. Kondisi ini menciptakan tantangan mendasar: pada saat pasang tinggi, mangrove yang tergenang sulit dibedakan dari badan air dan hamparan lumpur (*mudflat*) menggunakan indeks berbasis vegetasi murni seperti NDVI. Selama pasang tinggi, mangrove yang terendam sulit dibedakan dari latar belakang air dan hamparan lumpur menggunakan indeks vegetasi konvensional. Kompleksitas ini semakin diperparah di ekosistem mosaik mangrove-tambak Brebes, di mana genangan akibat pasang dan *rob* terjadi secara tidak seragam di antara kluster mangrove hutan dan linier pematang tambak, menciptakan variasi *signature* spektral yang tinggi dalam satu waktu akuisisi citra.

Dalam konteks inilah dominasi MMRI sebagai variabel paling berpengaruh menjadi sangat logis secara oseanografis. Diniz *et al.*, (2019) mengembangkan MMRI secara spesifik untuk membedakan ekosistem mangrove dari vegetasi sekitarnya dengan menggabungkan MNDWI sebagai representasi karakteristik akuatik dan NDVI sebagai representasi karakteristik vegetatif dalam struktur perbedaan ternormalisasi yang menggunakan nilai absolut masing-masing indeks. Konstruksi dual-komponen inilah yang menjadikan MMRI mampu mendeteksi mangrove tergenang sekalipun: ketika kondisi pasang menekan nilai NDVI akibat refleksi air yang menutupi kanopi, nilai MNDWI pada saat bersamaan meningkat dan perbedaan absolut antara keduanya tetap memberikan nilai MMRI yang dapat dibedakan dari kelas non-mangrove. Konsistensi temuan ini dengan Nandika *et al.*, (2023) yang juga menempatkan MMRI sebagai variabel paling berpengaruh di ekosistem laguna Segara Anakan memperkuat *robustness* indeks ini, meskipun nilai MDG yang lebih tinggi pada penelitian ini mengindikasikan bahwa kompleksitas oseanografi mosaik mangrove-tambak Brebes justru semakin

menegaskan relevansi indeks berbasis vegetasi-air gabungan.

Posisi SWIR2 (B12) pada urutan kedua menunjukkan pentingnya informasi kelembapan vegetasi dan kondisi substrat dalam proses klasifikasi. Kuenzer *et al.*, (2011) menyatakan bahwa komponen daun mangrove seperti kandungan air, protein, lignin, dan selulosa berinteraksi dengan radiasi elektromagnetik pada panjang gelombang lebih panjang di wilayah inframerah, dan sensitivitas wilayah inframerah menengah terhadap variabel-variabel ini berpotensi memberikan pembeda yang bahkan lebih efektif dibandingkan NIR. Dalam ekosistem mangrove yang tergenang, substrat berlumpur yang jenuh air memiliki reflektansi SWIR yang secara konsisten lebih rendah dibandingkan vegetasi darat atau lahan terbuka yang lebih kering. Bagi ekosistem lahan basah seperti mangrove, inklusi band SWIR dan inframerah menengah bersifat kritis karena wilayah spektral ini memungkinkan diskriminasi yang lebih baik antara vegetasi hidrik, hamparan lumpur, dan perairan terbuka, serta sangat sensitif terhadap kandungan air vegetasi dan kelembapan tanah, yang merupakan variabel kunci di lingkungan intertidal salin. Kondisi substrat berlumpur yang secara permanen jenuh air di pesisir Brebes menjadikan kontras SWIR antara mangrove dan kelas lainnya lebih tajam dan konsisten, menjelaskan posisi SWIR2 yang sangat kompetitif dengan MMRI dalam hierarki *variable importance*.

NDVI yang menempati posisi ketiga berperan sebagai indikator fundamental vegetasi hijau. Pettorelli *et al.*, (2011) menyatakan bahwa NDVI merupakan indeks yang paling luas digunakan untuk menilai kerapatan dan kesehatan vegetasi berdasarkan respons *near-infrared* dan *red*, yang secara konsisten membedakan vegetasi hijau dari objek non-vegetasi. Posisi NDVI di bawah MMRI dan SWIR2 justru memiliki makna oseanografis yang penting: pada kondisi pasang tinggi yang menekan respons NIR akibat refleksi air, kemampuan diskriminasi NDVI menurun signifikan. Baloloy *et al.*, (2020) dalam pengembangan MVI menyatakan bahwa band SWIR efektif dalam mengekspresikan absorpsi gelombang elektromagnetik yang dipengaruhi oleh tanah basah akibat pasang, sebuah karakteristik yang tidak dapat ditangkap oleh NDVI yang berbasis NIR-Red semata. Hal ini secara langsung menjelaskan mengapa pendekatan indeks tunggal berbasis vegetasi yang digunakan Farahdillah *et al.*, (2025) menghadapi keterbatasan struktural pada

kondisi ekosistem mosaik mangrove-tambak yang tergenang secara dinamis.

MNDWI dan NDWI sebagai dua variabel berbasis air memberikan kontribusi yang signifikan. Xu (2006) menyatakan bahwa MNDWI dikembangkan sebagai penyempurnaan dari NDWI dengan menggantikan band NIR dengan band SWIR, sehingga mampu menonjolkan fitur perairan terbuka secara lebih efektif sekaligus menekan gangguan dari lahan terbangun, vegetasi, dan tanah yang sering tercampur dalam NDWI konvensional. Dalam ekosistem mosaik mangrove-tambak yang secara periodik tergenang pasang, kemampuan MNDWI yang superior dalam membedakan badan air dari vegetasi pesisir menjadikannya komplemen yang tidak tergantikan bagi MMRI. Kontribusi sinergis antara MMRI, SWIR2, NDVI, MNDWI, dan NDWI dalam kerangka RF inilah yang membangun *decision boundary* yang akurat dan stabil untuk membedakan mangrove dari tambak, badan air, permukiman, dan lahan terbuka secara simultan (Belgiu dan Dragut 2016), bahkan pada kondisi oseanografi yang dinamis akibat fluktuasi pasang surut dan genangan *rob* yang menjadi ciri khas pesisir Brebes.

KESIMPULAN

Penelitian ini membuktikan bahwa algoritma *Random Forest* (RF) yang diimplementasikan pada platform *Google Earth Engine* (GEE) dengan 12 fitur spektral citra Sentinel-2A mampu memetakan distribusi spasial mangrove di pesisir Brebes secara akurat, menghasilkan *Overall Accuracy* 96,27% (*Kappa* 0,923) yang melampaui pendekatan indeks tunggal MVI sebesar 9,46%. Total sebaran mangrove teridentifikasi seluas 1.023,28 ha, terbagi dalam Kelompok Mangrove Hutan (531,87 ha) yang terbentuk oleh proses akresi intertidal dan program rehabilitasi monokultur, serta Kelompok Mangrove Tambak (491,41 ha) yang merupakan manifestasi sistem *silvofishery* sebagai respons adaptif sosial-ekologis masyarakat terhadap tekanan abrasi dan alih fungsi lahan. Analisis *variable importance* mengonfirmasi MMRI, SWIR2, dan NDVI sebagai variabel paling berpengaruh, di mana dominasi MMRI dan SWIR2 memiliki landasan oseanografis yang kuat: dinamika pasang surut yang menekan respons NIR pada kondisi genangan menjadikan konstruksi dual-komponen MMRI dan sensitivitas SWIR2 terhadap substrat berlumpur jenuh air sebagai kunci keberhasilan diskriminasi mangrove di area tergenang. Temuan ini memberikan implikasi

penting bagi pengelolaan ekosistem mangrove pesisir Brebes. Kelompok Mangrove Hutan perlu diprioritaskan sebagai zona perlindungan pantai dan penyerapan karbon, sementara Kelompok Mangrove Tambak membutuhkan pendekatan pengelolaan terpadu dalam kerangka *silvofishery* berkelanjutan yang menyeimbangkan produktivitas budidaya dengan keberlanjutan ekosistem. Basis data spasial yang dihasilkan menyediakan landasan kuantitatif yang akurat bagi perencanaan konservasi dan rehabilitasi mangrove yang tepat sasaran. Penelitian lanjutan disarankan mencakup tiga arah pengembangan utama. Pertama, integrasi data radar Sentinel-1 dengan data optik Sentinel-2 untuk mengatasi keterbatasan tutupan awan sekaligus memberikan informasi struktural kanopi yang tidak dapat diperoleh dari data optik semata. Kedua, penerapan analisis *time-series* multi-temporal untuk pemantauan dinamika perubahan tutupan mangrove secara berkelanjutan, khususnya dalam mendeteksi pergeseran batas antara Kelompok Mangrove Hutan dan Kelompok Mangrove Tambak akibat tekanan antropogenik yang terus berlangsung. Ketiga, kajian komparatif kinerja antara RF dan algoritma *machine learning* lainnya seperti *Support Vector Machine* (SVM), *Artificial Neural Network* (ANN), dan pendekatan *ensemble* multi-algoritma pada ekosistem mosaik mangrove-tambak yang tergenang, guna mengidentifikasi algoritma yang paling optimal untuk kondisi ekosistem pesisir yang kompleks di Indonesia.

DAFTAR PUSTAKA

- Alongi, D.M. 2008. Mangrove forests: resilience, protection from tsunamis, and responses to global climate change. *Estuarine, Coastal and Shelf Science*, 76(1):1–13. doi: 10.1016/j.ecss.2007.08.024
- Arifanti, V.B., Novita, N., Subarno, & Tosiani, A. 2021. Mangrove deforestation and CO₂ emissions in Indonesia. *IOP Conference Series: Earth and Environmental Science*, 874:012006. doi: 10.1088/1755-1315/874/1/012006
- Baloloy, A.B., Blanco, A.C., Sta. Ana, R.R.C., & 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*, 166:95–117. doi: 10.1016/j.isprsjprs.2020.06.001

- Belgiu, M. & Drăguț, L. 2016. Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114:24–31. doi: 10.1016/j.isprsjprs.2016.01.011
- Breiman, L. 2001. Random forests. *Machine Learning*, 45(1):5–32. doi: 10.1023/A:1010933404324
- 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):808. doi: 10.3390/rs11070808
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. and Bargellini, P. 2012. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120:25–36. doi: 10.1016/j.rse.2011.11.026
- Farahdillah, R.E., Pasaribu, R.A. & Gaol, J.L. 2025. Pemetaan luasan mangrove menggunakan algoritma Mangrove Vegetation Index (MVI) di Desa Kaliwlingi, Kabupaten Brebes, Jawa Tengah. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 12(1):11–20. doi: 10.25126/jtiik.2025121337
- Foody, G.M. 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1):185–201. doi: 10.1016/S0034-4257(01)00295-4
- Gandhi, U. 2021. End-to-End Google Earth Engine [kursus daring]. Spatial Thoughts. spatialthoughts.com/courses/google-earth-engine/ [Diakses 1 Desember 2025].
- Giri, C. 2021. Recent advancements in mangrove forest mapping and monitoring of the world using earth observation satellite data. *Remote Sensing*, 13(4):563. doi: 10.3390/rs13040563
- 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):1–4. doi: 10.1029/2002GL016450
- Goldberg, L., Lagomasino, D., Thomas, N. & Fatoyinbo, T. 2020. Global declines in human-driven mangrove loss. *Global Change Biology*, 26(10):5844–5855. doi: 10.1111/gcb.15275
- 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
- Handiani, D.N., Heriati, A. & Suciatty, F. 2022. Coastal vulnerability assessment along the north Java coastlines, Indonesia. *Jurnal Segara*, 18(1):1–12. doi: 10.15578/segara.v18i1.10664
- 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. *Remote Sensing*, 12(19):3120. doi: 10.3390/rs12193120
- Ilman, M., Dargusch, P., Dart, P. and Onrizal. 2016. A historical analysis of the drivers of loss and degradation of Indonesia's mangroves. *Land Use Policy*, 54:448–459. doi: 10.1016/j.landusepol.2016.03.010
- Kathiresan, K. & Bingham, B.L. 2001. Biology of mangroves and mangrove ecosystems. *Advances in Marine Biology*, 40:81–251. doi: 10.1016/S0065-2881(01)40003-4
- Krauss, K.W., McKee, K.L., Lovelock, C.E., Cahoon, D.R., Saintilan, N., Reef, R. & Chen, L. 2014. How mangrove forests adjust to rising sea level. *New Phytologist*, 202(1):19–34. doi: 10.1111/nph.12605
- Kuenzer, C., Bluemel, A., Gebhardt, S., Quoc, T.V. and Dech, S. 2011. Remote sensing of mangrove ecosystems: a review. *Remote Sensing*, 3(5):878–928. doi: 10.3390/rs3050878
- Landis, J.R. & Koch, G.G. 1977. The measurement of observer agreement for categorical data. *Biometrics*, 33(1):159–174. doi: 10.2307/2529310
- Maxwell, A.E., Warner, T.A. & Fang, F. 2018. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 39(9):2784–2817. doi: 10.1080/01431161.2018.1433343
- 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. doi: 10.1080/01431169608948714
- Menéndez, P., Losada, I.J., Torres-Ortega, S., Narayan, S. & Beck, M.W. 2020. The global flood protection benefits of mangroves. *Scientific Reports*, 10(1):4404. doi: 10.1038/s41598-020-61136-6

- Nandika, M.R., Suardana, A.A.M.A.P. & Anggraini, N. 2023. Pemetaan mangrove menggunakan algoritma Multivariate Random Forest: studi kasus di Segara Anakan, Cilacap. *Majalah Ilmiah Globe*, 25(1):21–30.
- Nembrini, S., König, I.R. & Wright, M.N. 2018. The revival of the Gini importance? *Bioinformatics*, 34(21):3711–3718. doi: 10.1093/bioinformatics/bty373
- Pettorelli, N., Ryan, S., Mueller, T., Bunnefeld, N., Jedrzejewska, B., Lima, M. & Kausrud, K. 2011. The Normalized Difference Vegetation Index (NDVI): unforeseen successes in animal ecology. *Climate Research*, 46:15–27. doi: 10.3354/cr00936
- Pham, T.D., Yokoya, N., Bui, D.T., Yoshino, K. and Friess, D.A. 2019. Remote sensing approaches for monitoring mangrove species, structure, and biomass: opportunities and challenges. *Remote Sensing*, 11(3):230. doi: 10.3390/rs11030230
- Phinzi, K., Ngetar, N.S., Pham, Q.B., Chakilu, G.G. & Szabó, S. 2023. Understanding the role of training sample size in the uncertainty of high-resolution LULC mapping using random forest. *Earth Science Informatics*, 16:3667–3677. doi: 10.1007/s12145-023-01117-1
- Pimple, U., Leadprathom, K., Simonetti, D., Sitthi, A., Peters, R., Pungkul, S., Pravinvongvuthi, T., Dessard, H., Berger, U., Siri-on, K., Kemacheevakul, P. and Gond, V. 2022. Assessing mangrove species diversity, zonation and functional indicators in response to natural, regenerated, and rehabilitated succession. *Journal of Environmental Management*, 318:115507. doi: 10.1016/j.jenvman.2022.115507
- Probst, P. & Boulesteix, A.L. 2018. To tune or not to tune the number of trees in random forest. *Journal of Machine Learning Research*, 18(1):1–18.
- Richards, D.R. & Friess, D.A. 2016. Rates and drivers of mangrove deforestation in Southeast Asia, 2000–2012. *Proceedings of the National Academy of Sciences*, 113(2):344–349. doi: 10.1073/pnas.1510272113
- Solihuddin, T., Husrin, S., Salim, H.L., Kepel, T.L., Mustikasari, E., Heriati, A., Ati, R.N.A., Purbani, D., Mbay, L.O.N. & Indriasari, V.Y. 2021. Coastal erosion on the north coast of Java: adaptation strategies and coastal management. *IOP Conference Series: Earth and Environmental Science*, 777:012035. doi: 10.1088/1755-1315/777/1/012035
- Tran, T.V., Reef, R. and Zhu, X. 2022. A review of spectral indices for mangrove remote sensing. *Remote Sensing*, 14(19):4868. doi: 10.3390/rs14194868
- 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. doi: 10.1080/01431160600589179
- Zhu, Z. & Woodcock, C.E. 2012. Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118:83–94. doi: 10.1016/j.rse.2011.10.028