

EFEKTIVITAS APLIKASI ALGORITMA MACHINE LEARNING DALAM KLASIFIKASI TUTUPAN LAHAN DI PULAU NUSALAUT

EFFECTIVENESS OF MACHINE LEARNING ALGORITHMS FOR LAND COVER CLASSIFICATION ON NUSALAUT ISLAND

Mark Chara Papilaya¹, Gun Mardiatmoko^{2*}, Ronny Loppies³

^{1,2,3} Program Studi Kehutanan, Fakultas Pertanian Universitas Pattimura Ambon
Jalan. Ir. M. Putuhena, Kampus Poka – Ambon, 97233. Indonesia.

*Email Korespondensi: g.mardiatmoko@faperta.unpatti.ac.id

ABSTRAK

Pemantauan dan klasifikasi tutupan lahan hutan di pulau-pulau kecil memerlukan metode yang akurat dan efisien untuk mendukung pengelolaan sumber daya alam yang berkelanjutan. Penelitian ini bertujuan untuk mengevaluasi efektivitas algoritma Machine Learning, yaitu Classification and Regression Tree (CART), Support Vector Machine (SVM), dan Random Forest (RF), dalam mengklasifikasikan lahan hutan di Pulau Nusalaut, Provinsi Maluku, serta membandingkan kinerjanya berdasarkan tingkat akurasi, efisiensi, dan kebutuhan sumber daya komputasi. Data yang digunakan berupa citra satelit Sentinel-2 Level-2A tahun 2025 yang diolah menggunakan platform Google Earth Engine. Klasifikasi dilakukan secara supervised dengan empat kelas tutupan lahan, yaitu badan air, infrastruktur, lahan terbuka, dan vegetasi. Evaluasi kinerja model dilakukan menggunakan confusion matrix untuk memperoleh nilai Overall Accuracy (OA) dan koefisien Kappa. Hasil penelitian menunjukkan bahwa ketiga algoritma mampu menghasilkan klasifikasi dengan akurasi tinggi, di mana SVM dan RF memberikan performa terbaik dengan nilai OA sebesar 98% dan Kappa 0,97, sedangkan CART memperoleh OA sebesar 94% dan Kappa 0,90. SVM unggul dalam pemisahan kelas dengan karakteristik spektral yang jelas, sementara RF lebih robust terhadap noise data. Temuan ini menunjukkan bahwa algoritma Machine Learning, khususnya SVM dan RF, sangat efektif untuk klasifikasi lahan hutan di wilayah pulau kecil seperti Pulau Nusalaut.

Kata Kunci: Google Earth Engine, Klasifikasi Tutupan Lahan, Machine Learning, Pulau Nusalaut

ABSTRACT

Monitoring and classification of forest land cover on small islands require accurate and efficient methods to support sustainable natural resource management. This study aims to evaluate the effectiveness of Machine Learning algorithms, namely Classification and Regression Tree (CART), Support Vector Machine (SVM), and Random Forest (RF), in classifying forest land cover on Nusalaut Island, Maluku Province, and to compare their performance in terms of accuracy, efficiency, and computational resource requirements. The study utilized Sentinel-2 Level-2A satellite imagery from 2025, processed using the Google Earth Engine platform. Supervised classification was applied to four land cover classes, namely water bodies, built-up areas, open land, and vegetation. Model performance was evaluated using a confusion matrix to obtain Overall Accuracy (OA) and the Kappa coefficient. The results indicate that all three algorithms produced high classification accuracy, with SVM and RF achieving the best performance, attaining an OA of 98% and a Kappa value of 0.97, while CART achieved an OA of 94% and a Kappa value of 0.90. SVM demonstrated superior class separation for land cover types with distinct spectral characteristics, whereas RF was more robust to data noise. These findings suggest that Machine Learning algorithms, particularly SVM and RF, are highly effective for forest land cover classification in small island environments such as Nusalaut Island.

Keywords: Google Earth Engine, Land Cover Classification, Machine Learning, Nusalaut Island

PENDAHULUAN

Pulau-pulau kecil memiliki karakteristik ekosistem yang unik namun sangat rentan terhadap perubahan lingkungan akibat keterbatasan luas wilayah, isolasi geografis, serta sensitivitas tinggi

terhadap perubahan iklim dan aktivitas antropogenik. Hernández-Delgado (2015) menjelaskan bahwa pulau-pulau kecil menghadapi ancaman kompleks yang berpotensi mengganggu keseimbangan ekologi, kesejahteraan masyarakat, dan stabilitas ekonomi lokal.

Hutan di pulau-pulau kecil memainkan peran ekologis yang krusial. Borges et al. (2018) menyatakan bahwa kawasan hutan tidak hanya berfungsi sebagai penyimpan keanekaragaman hayati, tetapi juga berperan sebagai infrastruktur ekologi yang mencakup pencegahan erosi, regulasi hidrologi, pengendali iklim mikro, dan penyedia jasa ekosistem yang menopang kehidupan komunitas lokal. Monitoring kondisi hutan secara berkala dan akurat menjadi esensial dalam pengelolaan sumber daya alam berkelanjutan. Sudmeier-Rieux et al. (2021) menekankan bahwa pendekatan berbasis ekosistem merupakan strategi multifungsi yang mengintegrasikan konservasi, mitigasi risiko bencana, dan pemberdayaan masyarakat lokal.

Metode konvensional dalam pemantauan hutan memiliki keterbatasan signifikan. Survei lapangan membutuhkan investasi waktu, biaya, dan tenaga kerja yang besar, sementara interpretasi manual citra satelit rentan terhadap subjektivitas, inkonsistensi hasil, dan keterbatasan cakupan area. Rodriguez-Galiano et al. (2012) menegaskan bahwa pendekatan tradisional seringkali gagal memberikan gambaran komprehensif dan aktual tentang dinamika tutupan lahan.

Perkembangan teknologi penginderaan jauh dan Machine Learning (ML) telah merevolusi klasifikasi tutupan lahan. Teknologi ini menyediakan data citra satelit dengan variasi resolusi spasial, temporal, dan spektral yang beragam. Algoritma machine learning mampu mengenali pola kompleks dalam dataset citra dan melakukan klasifikasi otomatis dengan akurasi tinggi. Zhang et al. (2020) membuktikan bahwa teknik deep learning, khususnya Convolutional Neural Networks (CNNs), telah melampaui metode konvensional dalam menganalisis citra beresolusi tinggi, membuka peluang baru dalam monitoring ekosistem hutan.

Support Vector Machines (SVM) telah menjadi algoritma terdepan dalam klasifikasi penggunaan lahan. Zhang et al. (2023) menunjukkan bahwa SVM mencapai akurasi hingga 95,8% menggunakan data multispektral Sentinel-2. Keunggulan SVM meliputi kemampuan menangani data berdimensi tinggi, memisahkan kelas dengan batas optimal, dan resistensi terhadap overfitting. Xie et al. (2019) mengonfirmasi bahwa SVM menunjukkan performa superior dibanding algoritma konvensional, terutama dalam identifikasi kelas penutupan lahan kompleks.

Random Forest (RF) juga terbukti sangat efektif dalam klasifikasi lahan hutan dengan mengkombinasikan banyak decision tree independen untuk menghasilkan model prediksi yang robust. Rodriguez-Galiano et al. (2012) mencatat bahwa RF unggul dalam mengatasi noise data dengan akurasi mencapai 92%. Kelebihan RF mencakup kemampuan mengestimasi kepentingan variabel, menangani fitur non-linier, dan memberikan estimasi kesalahan klasifikasi internal.

Namun, tidak ada algoritma tunggal yang universal untuk semua konteks klasifikasi. Xie et al. (2019) dan Hagner & Reese (2007) menekankan pentingnya pendekatan berbasis keahlian yang mempertimbangkan karakteristik wilayah, kualitas data, dan tujuan penelitian. Faktor seperti resolusi citra, ketersediaan data latih, kompleksitas lanskap, dan variabilitas musiman memainkan peran penting dalam pemilihan algoritma.

Pulau-pulau kecil menghadapi risiko bencana alam yang serius. Hutan berfungsi sebagai infrastruktur hijau efektif dalam mereduksi dampak bencana seperti banjir dan tsunami. Tembata et al. (2020) dan Osti et al. (2009) menunjukkan bahwa efektivitas perlindungan hutan bergantung pada jenis, struktur, dan kondisi vegetasi. Perubahan iklim juga memberikan tantangan eksistensial. Hernández-Delgado (2015) mengidentifikasi ancaman kumulatif yang berdampak pada jasa ekosistem, kesehatan masyarakat, dan ekonomi lokal, termasuk kenaikan muka air laut, perubahan pola hujan, dan intensitas fenomena ekstrem.

Partisipasi masyarakat lokal memiliki peran strategis dalam pengelolaan hutan. Vigna et al. (2021) menunjukkan bahwa keterlibatan masyarakat, khususnya dalam manajemen risiko kebakaran hutan, meningkatkan efektivitas konservasi. Pengetahuan lokal turun-temurun memberikan perspektif unik dalam memahami dinamika ekosistem setempat.

Pulau Nusalaut merupakan pulau kecil di Provinsi Maluku, Indonesia, yang secara administratif termasuk Kabupaten Maluku Tengah. Pulau ini memiliki luas terbatas dengan topografi didominasi perbukitan dan pesisir. Ekosistem hutannya memiliki signifikansi ekologis tinggi sebagai bagian integral kepulauan Maluku yang kaya biodiversitas. Isolasi geografis menciptakan mikrohabitat unik yang mendukung spesies endemik dan sistem ekologi kompleks.


Pulau Nusalaut terbagi dalam beberapa desa dengan struktur sosial yang erat terkait sumber daya alam. Mata pencaharian utama meliputi pertanian, perikanan, dan pengelolaan hutan tradisional. Karakteristik iklim tropis dengan variasi musiman menciptakan tantangan unik dalam pemantauan dan klasifikasi penutupan lahan karena perubahan musiman dapat mempengaruhi interpretasi citra satelit.

Penelitian ini menjadi upaya menjawab tantangan pengelolaan pulau-pulau kecil yang rentan terhadap perubahan. Pemantauan dinamis dan efektif diperlukan untuk mengatasi kerentanan terhadap degradasi. Penelitian berjudul "Efektivitas Aplikasi Algoritma Machine Learning dalam Klasifikasi Lahan Hutan di Pulau Nusalaut, Provinsi Maluku" bertujuan mengintegrasikan teknologi mutakhir, analisis ilmiah, dan pengetahuan lokal untuk mengembangkan strategi adaptif dalam menjaga keseimbangan ekologis dan mendukung kesejahteraan masyarakat.

METODE PENELITIAN

Lokasi dan Waktu Penelitian

Penelitian dilakukan di Pulau Nusalaut, kabupaten Maluku Tengah provinsi Maluku. Pulau Nusalaut memiliki luas 32.50 km². Penelitian ini akan berlangsung dari bulan Juni hingga Juli 2025.



Gambar 1. Peta lokasi penelitian

Alat dan Bahan

Alat yang digunakan dalam penelitian ini adalah perangkat keras Laptop yang sudah disertai dengan software ArcGIS 10.8 dan *Google Earth Engine* (GEE). Bahan utama yang diolah dalam penelitian ini adalah Citra satelit Sentinel-2 dalam rekaman tahun 2025.

Metode Penelitian

Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini merupakan jenis data primer dan data sekunder. Data primer yang digunakan adalah Citra Sentinel-2 MSi: MultiSpectral instrument, Level-2A. Citra Sentinel-2 yang digunakan dalam rekaman tahun 2025, yang tersedia pada *Google Earth Engine* (GEE) dan dapat diakses melalui <https://code.earthengine.google.com/>. Sedangkan, data sekunder atau data pendukung lainnya didapat dari studi literatur lainnya yang relevan dengan penelitian seperti buku, jurnal, makalah ilmiah, internet, dll.

Teknik Pengumpulan Data

Dalam mengevaluasi efektivitas Algoritma Machine Learning yang representatif pada pulau Nusalaut, maka yang dilakukan adalah dengan mengumpulkan data citra Sentinel-2 yang mencakup area studi pada periode 2025. Validasi hasil klasifikasi menggunakan citra resolusi tinggi. Data image yang diseleksi oleh *Google Earth Engine* (GEE) adalah yang sudah non atau bebas awan. Untuk menganalisis suatu faktor kesalahan pada hasil klasifikasi, dilakukan pengambilan sampel yang

berbeda untuk dilakukan pengujian ulang. Dalam metode ini dapat mengetahui persen akurasi pada klasifikasi yang dilakukan. Hasil perbandingan dalam klasifikasi untuk membangun matriks dan menghitung akurasi masing-masing metode klasifikasi.

Analysis Data

Klasifikasi Tutupan Lahan

- 1) **Komposisi dataset:** Proses pengumpulan data dimulai dengan mengakses citra Sentinel-2 level 2A melalui Google Earth Engine yang sudah terkoreksi geometrik dan radiometrik, dilanjutkan dengan cloud masking untuk menghilangkan gangguan awan (dengan kriteria tutupan awan <30%), kemudian dilakukan filtering berdasarkan tanggal dan Area of Interest (AOI) untuk memastikan konsistensi temporal dan relevansi area studi.
- 2) **Klasifikasi:** Proses klasifikasi dilakukan dengan mengumpulkan titik sampel untuk mengekstrak piksel sebagai data training untuk enam kelas tutupan lahan (hutan, pertanian, semak belukar, pemukiman, badan air, dan lahan terbuka), yang kemudian diklasifikasikan menggunakan tiga algoritma machine learning yaitu CART (Classification and Regression Tree), SVM (Support Vector Machine), dan RF (Random Forest).

Uji Akurasi

Uji Akurasi Matriks Kesalahan dalam Algoritma *Machine Learning* adalah salah satu metode evaluasi yang digunakan untuk mengukur kinerja model klasifikasi. Matriks kesalahan, atau yang sering disebut sebagai *Confusion Matrix*, adalah tabel yang menunjukkan hasil prediksi model dibandingkan dengan data sebenarnya. Uji akurasi ini penting untuk memahami bagaimana model machine learning menangani data dan sejauh mana prediksinya sesuai dengan kenyataan.

Tabel 1. Matriks kesalahan

		Data acuan				Total baris
		I	II	III	IV	
Hasil klasifikasi	I	A	a	b	c	$\sum$ baris 1
	II	d	B	e	f	$\sum$ baris 2
	III	g	h	C	i	$\sum$ baris 3
	IV	j	k	l	D	$\sum$ baris 4
		$\sum$	$\sum$	$\sum$	$\sum$	$\sum$ Total
Total kolom		Kolom 1	Kolom 2	Kolom 3	Kolom 4	kolom/baris

Keterangan : $A, B, \dots, F$ = jumlah piksel benar dari hasil interpretasi dan cek lapangan; $a, b, c, \dots, d'$ = jumlah piksel dalam satu kelas hasil pengujian lapangan.

Confusion matriks ini yang akan menghasilkan uji akurasi dengan parameter:

- *overall accuracy*: Persentase piksel yang berhasil dilakukan

- *producer accuracy*: Probabilitas rata-rata (%) piksel yang menampilkan distribusi setiap kelas yang telah diklasifikasikan di lapangan
- *user accuracy*: Peluang rata-rata (%) piksel yang benar-benar mencerminkan kelas-kelas tersebut.

Secara matematis akurasi tersebut dapat dinyatakan sebagai berikut :

$$User's\ accuracy = \frac{X_{ii}}{X_{+i}} \times 100\%$$

$$Producer's\ accuracy = \frac{X_{ii}}{X_{i+}} \times 100\%$$

$$Overall's\ accuracy = \frac{\sum_i^r X_{ii}}{N} \times 100\%$$

Dimana:

X_{ii} = Nilai diagonal matriks kontingensi baris ke-i dan kolom ke-i

X_{i+} = Jumlah piksel dalam baris ke-i

X_{+i} = Jumlah piksel dalam kolom ke-i

N = Jumlah seluruh pixel sampel dalam confusion matrix

$$\hat{k} = \frac{N \sum_{i=1}^k X_{ii} - \sum_{i=1}^k X_{i+} X_{+i}}{N^2 - \sum_{i=1}^k (X_{i+} X_{+i})}$$

Dimana:

$\hat{k}$ = Kappa

N = Jumlah seluruh pixel sampel dalam confusion matrix

X_{ii} = Pixel pada diagonal utama (klasifikasi yang benar) confusion matrix

X_{i+} = Jumlah pixel seluruh kolom pada suatu baris

X_{+i} = Jumlah pixel seluruh baris pada suatu kolom

HASIL DAN PEMBAHASAN

Kondisi Tutupan Lahan di Pulau Nusalaut

Pra pengolahan citra

Tahap awal dalam pengolahan gambar, yaitu pra-pengolahan, memiliki peran krusial sebelum memasuki proses klasifikasi. Di fase ini, biasanya dilaksanakan berbagai langkah untuk memperbaiki mutu serta ketepatan data visual. Terdapat dua langkah penting yang umumnya dilakukan, yaitu perbaikan geometrik dan radiometrik. Namun, karena analisis dilakukan melalui Google Earth Engine, proses tersebut tidak lagi diperlukan. Platform ini menyediakan citra satelit yang telah melewati tahap koreksi standar, dengan data yang diolah oleh institusi pengelola satelit seperti NASA

atau ESA, sehingga kualitas dan ketepatannya telah terjamin. Berikut ini merupakan proses analisis citra pada *Google Earth Engine*.

1. Penentuan Wilayah Studi (*Region of Interest/ROI*)

Langkah pertama yang sangat krusial dalam proses pra-pengolahan citra adalah penentuan *Region of Interest* (ROI), yaitu batas area yang menjadi fokus penelitian. Dalam penelitian ini, ROI difokuskan pada Pulau Nusalaot yang berada di Kabupaten Maluku Tengah, Provinsi Maluku, Indonesia dengan mengunggah *shapefile* yang telah tersedia. Proses ini bertujuan untuk memfokuskan seluruh proses analisis hanya pada wilayah yang relevan.

2. *Cloud masking*


Citra Sentinel-2 seringkali mengalami gangguan akibat tutupan awan yang mengaburkan permukaan bumi, sehingga perlu dilakukan proses *cloud masking* untuk meningkatkan akurasi interpretasi data. Dalam analisis ini digunakan dataset *Sentinel-2 Surface Reflectance* (COPERNICUS/S2_SR) yang menyediakan band klasifikasi pemandangan (*Scene Classification Layer* atau SCL). Band ini sangat berguna untuk mengidentifikasi piksel yang terindikasi awan, bayangan awan, dan cirrus. Proses masking dilakukan dengan memfilter nilai SCL agar hanya menyisakan piksel bersih. Hasil dari tahap ini pada gambar berupa citra bersih yang siap untuk dianalisis lebih lanjut, dengan gangguan atmosfer yang sudah diminimalkan secara signifikan.

3. Visualisasi citra

Setelah data citra dibersihkan dari gangguan awan, langkah berikutnya adalah proses visualisasi untuk keperluan inspeksi visual dan validasi. Di *Google Earth Engine*, citra Sentinel-2 bisa divisualisasikan dalam berbagai kombinasi band sesuai tujuan. Pada penelitian ini digunakan Kombinasi *band 4 (red)*, *3 (green)*, dan *2 (blue)* untuk menampilkan *true color* seperti tampilan mata manusia, yang sangat berguna untuk peninjauan awal.

4. *Filtering*

Citra Sentinel-2 tersedia dalam koleksi waktu yang luas, namun tidak semua waktu memberikan hasil yang optimal oleh karena itu pemilihan waktu merupakan hal yang penting. Di GEE, *filtering* ini dilakukan dengan fungsi filter Data agar hanya citra dari periode tertentu yang dianalisis Berikut ini pada Gambar 3 merupakan hasil citra 2025 yang telah melalui tahapan pra- pengolahan.



Gambar 2. Citra 2025

Klasifikasi citra

Klasifikasi citra merupakan tahapan lanjutan setelah pra-pengolahan, yang bertujuan untuk mengelompokkan piksel citra ke dalam kelas-kelas tutupan/penggunaan lahan tertentu berdasarkan karakteristik spektral dan spasialnya. Pada penelitian ini, klasifikasi citra dilakukan dengan metode *supervised*, dimulai dari pemilihan training area berdasarkan jenis tutupan/penggunaan lahan. Setelah itu, proses klasifikasi dilanjutkan menggunakan algoritma *Classification and Regression Tree* (CART), *Support Vector Machine* (SVM), *Random Forest* (RF). Dalam proses klasifikasi tutupan lahan ini, ditetapkan empat kelas utama yaitu badan air, pemukiman, vegetasi, dan lahan terbuka. Proses pengambilan sampel training area dilakukan secara sistematis dengan mempertimbangkan representasi spasial dan variasi spektral di setiap kelas. Jumlah sampel pada masing – masing algoritma berbeda.

Tabel 2. Training sampel CART & SVM


	Kelas Tutupan	Jumlah Sampel
1	Badan air	14
2	Infrastruktur	12
3	Lahan Terbuka	13
4	Vegetasi	14
	Total	53

Tabel 3. Training sampel RF

No	RandomForest	
	Kelas Tutupan	Jumlah Sampel
1	Badan air	14
2	Infrastruktur	12
3	Lahan Terbuka	13
4	Vegetasi	14
Total		53


Klasifikasi Tutupan Lahan di Pulau Nusalaut

Klasifikasi terbimbing dengan algoritma *Classification and Regression Trees* (CART) merupakan metode pengelompokan berbasis pohon keputusan yang secara sistematis membagi data citra berdasarkan nilai-nilai spektral dan variabel penjelas lainnya (Walidaroyani & Kadir, 2022).




Gambar 3. Klasifikasi Algoritma CART

Random forest (RF) merupakan kombinasi dari tree predictors (prediksi pohon) sedemikian rupa sehingga setiap pohon bergantung pada nilai-nilai dari vektor acak yang dipilih secara independen dan dengan distribusi yang sama untuk semua pohon dalam hutan. Generalisasi error untuk hutan menyatu ke batas tertentu seiring bertambahnya jumlah pohon dalam hutan. (Breiman, 2001).



Gambar 4. Klasifikasi Algoritma RF

Support Vector Machine (SVM) merupakan suatu teknik untuk menemukan hyperplane yang bisa memisahkan dua set data dari dua kelas yang berbeda (Vapnik, 1999). SVM memiliki kelebihan diantaranya adalah dalam menentukan jarak menggunakan support vector sehingga proses komputasi menjadi cepat (Vapnik, 1995).



Gambar 5. Klasifikasi Algoritma SVM

Klasifikasi tutupan dan penggunaan lahan (*Land Use/Land Cover* - LULC) adalah bagian penting dalam mengawasi sumber daya alam, merencanakan pembangunan yang berkelanjutan, serta mengelola lingkungan. Pulau Nusulaut, yang termasuk dalam Kepulauan Maluku, merupakan pulau strategis dengan bentuk geografis dan penggunaan lahan yang kompleks. Tutupan lahan (*Land Cover*) merujuk pada karakteristik fisik permukaan lahan yang dapat dideteksi melalui penginderaan jauh, seperti vegetasi, air, tanah terbuka, dan bangunan. Penggunaan lahan (*Land Use*) merujuk pada fungsi atau aktivitas manusia pada suatu area, misalnya pertanian, pemukiman, industri, dan pariwisata.

Uji Akurasi

Dalam mengevaluasi seberapa akurat hasil klasifikasi maka digunakan matriks kesalahan (*confusion matrix*). *Confusion matrix* merupakan sebuah tabel yang merepresentasikan performa algoritma klasifikasi dengan menampilkan jumlah prediksi yang benar dan salah berdasarkan kategori aktual dan kategori hasil prediksi (Sathyanarayanan & Tantri, 2024).

Tabel 4. Matriks kesalahan (*Confusion Matrix*) CART

Confusion Matrix		CART				Total	UA	CE
		Data						
		badan_air	Infrastruktur	lahan_terbuka	vegetasi			
Accuracy Result	Badan_air	34	0	0	0	34	0,9189	0
	Infrastruktur	0	3	0	0	3	1	0
	Lahan_terbuka	3	0	8	0	11	0,8889	0,273
	Vegetasi	0	0	1	17	18	1	0,056
Total		37	3	9	17	66		
PA		1	1	0,72727	0,944	OA	94	
OE		0.081	0	0.111	0	k	90	

Received: 19 Desember 2025; Revised: 13 Januari 2026; Accepted: 16 Februari 2026; Published: 20 Maret 2026

Vol. 2 No. 12. Maret 2026 | **MARSEGU: Jurnal Sains dan Teknologi**

860

Berdasarkan hasil perhitungan confusion matrix pada tabel, dapat dilihat bahwa klasifikasi tutupan/penggunaan lahan dengan metode *Classification and Regression Tree* (CART) menggunakan GEE dapat menghasilkan hasil yang sangat baik karena memiliki nilai 94% untuk *overall accuracy* dan 0,90 (90%) untuk *kappa accuracy*. Nilai akurasi klasifikasi sebesar 94% menunjukkan bahwa hasil klasifikasi telah memenuhi standar ketelitian yang disyaratkan, yaitu di atas 85% berdasarkan *United States Geological Survey* (USGS) untuk klasifikasi LULC. Selain itu, nilai Kappa yang diperoleh sebesar 0,90 menunjukkan tingkat kesepakatan yang sangat tinggi antara hasil klasifikasi dan data validasi.

Tabel 5. Matriks kesalahan (*Confusion Matrix*) SVM

Confusion Matrix		SVM				Total	UA	CE
		Data						
		badan_air	Infrastruktur	lahan_terbuka	vegetasi			
Accuracy Result	Badan_air	34	0	0	0	34	1	0
	Infrastruktur	0	2	1	0	3	1	0
	Lahan_terbuka	0	0	11	0	11	0,916	0,333
	Vegetasi	0	0	0	18	18	1	0
Total		34	2	12	18	66		
PA		1	0,66667	1	1	OA	0,98	
OE		0	0	0,083	0	k	0,97	

Berdasarkan hasil perhitungan confusion matrix pada tabel, dapat dilihat bahwa klasifikasi tutupan/penggunaan lahan dengan metode *Support Vector Machine* (SVM) menggunakan GEE dapat menghasilkan hasil yang sangat baik karena memiliki nilai 98% untuk *overall accuracy* dan 0,97 (97%) untuk *kappa accuracy*. OA 98% dan Kappa 0.97 menunjukkan SVM sangat efektif untuk dataset ini. Kelas seperti badan_air, lahan_terbuka, dan vegetasi memiliki UA dan PA sempurna (1.0), menandakan model mampu membedakan fitur-fitur ini dengan baik, karena ciri-ciri spektral yang jelas dalam data citra (misalnya, air memiliki reflektansi rendah, vegetasi tinggi di NIR). Dalam remote sensing, akurasi ini cocok untuk pemantauan lingkungan, seperti deteksi badan air untuk pengelolaan sumber daya atau vegetasi untuk perubahan lahan.

Tabel 6. Matriks Kesalahan (*Confusion Matrix*) RF

Confusion Matrix		RANDOM FOREST				Total	UA	CE
		Data						
		badan_air	Infrastruktur	lahan_terbuka	vegetasi			
Accuracy Result	badan_air	8	0	0	0	8	1	0
	infrastruktur	0	1	0	0	1	1	0
	lahan_terbuka	0	0	7	0	7	0,875	0
	vegetasi	0	0	1	25	26	1	0,038
Total		8	1	8	25	42		
PA		1	1	1	0,9615	OA	98	
OE		0	0	0,125	0	k	97	

Received: 19 Desember 2025; Revised: 13 Januari 2026; Accepted: 16 Februari 2026; Published: 20 Maret 2026

Vol. 2 No. 12. Maret 2026 | **MARSEGU: Jurnal Sains dan Teknologi**

861

Berdasarkan hasil perhitungan confusion matrix pada tabel, dapat dilihat bahwa klasifikasi tutupan/penggunaan lahan dengan metode *Random Forest* (RF) menggunakan GEE dapat menghasilkan hasil yang sangat baik karena memiliki nilai 98% untuk *overall accuracy* dan 0,97 (97%) untuk *kappa accuracy*. OA sebesar 98% dan Kappa 0.97 menunjukkan bahwa model *Random Forest* sangat efektif untuk dataset ini. Kelas seperti badan air, infrastruktur, dan lahan terbuka memiliki UA dan PA sempurna (1), yang menunjukkan model mampu menghadapi variasi data dengan baik. Kemungkinan karena model menggunakan ensemble dari banyak pohon keputusan yang mengurangi risiko overfitting. Dalam pemrosesan citra jauh, akurasi ini cocok untuk tugas klasifikasi yang membutuhkan ketahanan terhadap noise, seperti mengenali vegetasi atau infrastruktur dari citra satelit. *Random Forest* biasanya lebih tahan daripada SVM dalam menangani data dengan fitur non-linier atau adanya outlier.

KESIMPULAN

Evaluasi efektivitas algoritma Machine Learning menunjukkan bahwa ketiga algoritma (SVM, RF, dan CART) yang diimplementasikan melalui Google Earth Engine terbukti sangat efektif dalam mengklasifikasikan lahan hutan di Pulau Nusalaut dengan tingkat akurasi keseluruhan yang melebihi standar USGS (85%), di mana SVM dan RF mencapai akurasi tertinggi sebesar 98% dengan nilai Kappa 0,97, sementara CART mencapai akurasi 94% dengan nilai Kappa 0,90. Perbandingan kinerja algoritma menunjukkan bahwa SVM dan RF memberikan performa terbaik dengan akurasi dan efisiensi yang setara (OA 98%, Kappa 0,97), di mana SVM unggul dalam memisahkan kelas dengan batas keputusan optimal terutama untuk badan air dan vegetasi, sementara RF lebih robust terhadap noise data pada kelas infrastruktur dan lahan terbuka, sedangkan CART meskipun menghasilkan akurasi sedikit lebih rendah (OA 94%, Kappa 0,90) tetap menjadi pilihan layak karena kesederhanaan model dan kebutuhan sumber daya komputasi yang lebih efisien. Hasil klasifikasi tutupan lahan tahun 2025 menunjukkan bahwa Pulau Nusalaut didominasi oleh vegetasi berupa hutan lahan kering sekunder dan semak belukar yang berhasil diidentifikasi dengan presisi tinggi menggunakan data Sentinel-2A melalui pemanfaatan band Near-Infrared (NIR) yang sensitif terhadap kerapatan vegetasi.

DAFTAR PUSTAKA

Borges, P., Cardoso, P., Kreft, H., Whittaker, R., Fattorini, S., Emerson, B., Gil, A., Gillespie, R., Matthews, T., Santos, A., Steinbauer, M., Thébaud, C., Ah-Peng, C., Amorim, I., Aranda, S., Arroz, A., Azevedo, J., Boieiro, M., Borda-de-Água, L., ... & Gabriel, R. 2018. *Global*

- Island Monitoring Scheme (GIMS): a proposal for the long-term coordinated survey and monitoring of native island forest biota.* Biodiversity and Conservation, 27(10), 2567-2586.
- Breiman, L. 2001. Random forests. *Machine Learning*, 45(1), 5–32.
- Cortes, C., & Vapnik, V. 1995. *Support-vector networks.* Machine Learning, 20(3), 273–297.
- Hagner, O., & Reese, H. 2007. *A method for calibrated maximum likelihood classification of forest types.* Remote Sensing of Environment, 110(4), 438-444.
- Hernández-Delgado, E. 2015. *The emerging threats of climate change on tropical coastal ecosystem services, public health, local economies and livelihood sustainability of small islands: Cumulative impacts and synergies.* Marine Pollution Bulletin, 101(1), 5-28.
- Osti, R., Tanaka, S., & Tokioka, T. 2009. *The importance of mangrove forest in tsunami disaster mitigation.* Disasters, 33(2), 203-213.
- Rodriguez-Galiano, V., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sánchez, J. 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.
- Sudmeier-Rieux, K., Arce-Mojica, T., Boehmer, H., Doswald, N., Emerton, L., Friess, D., Galvin, S., Hagenlocher, M., James, H., Laban, P., Lacambra, C., Lange, W., McAdoo, B., Moos, C., Mysiak, J., Narvaez, L., Nehren, U., Peduzzi, P., Renaud, F., ... & Walz, Y. 2021. *Scientific evidence for ecosystem-based disaster risk reduction.* Nature Sustainability, 4(9), 803-810.
- Sathyanarayanan, S., & Tantri, B. R. 2024. *Confusion Matrix-Based PerformanceEvaluation Metrics.* November. <https://doi.org/10.53555/AJBR.v27i4S.4345>
- Tembata, K., Yamamoto, Y., Yamamoto, M., & Matsumoto, K. 2020. *Don't rely too much on trees: Evidence from flood mitigation in China.* Science of the Total Environment, 732, 138410.
- Vigna, I., Besana, A., Comino, E., & Pezzoli, A. 2021. *Application of the Socio-Ecological System Framework to Forest Fire Risk Management: A Systematic Literature Review.* Sustainability, 13(4), 2121.
- Walidaroyani, A., & Kadir, S. F. 2022. *Analisis Tutupan Lahan Menggunakan GEE Dengan Metode Supervised classification (Studi Kasus Bendungan Karangates Kab. Malang).* Jurnal Riset Mahasiswa Bidang Teknologi Informasi, 6(1), 99 – 104.
- Xie, Z., Chen, Y., Lu, D., Li, G., & Chen, E. 2019. *Classification of Land Cover, Forest, and Tree Species Classes with ZiYuan-3 Multispectral and Stereo Data.* Remote Sensing, 11(2), 164.
- Zhang, C., Liu, Y., & Tie, N. 2023. *Forest Land Resource Information Acquisition with Sentinel-2 Image Utilizing Support Vector Machine, K-Nearest Neighbor, Random Forest, Decision Trees and Multi-Layer Perceptron.* Forests, 14(2), 254.

Zhang, X., Han, L., Han, L., & Zhu, L. 2020. *How Well Do Deep Learning-Based Methods for Land Cover Classification and Object Detection Perform on High Resolution Remote Sensing Imagery?* Remote Sensing, 12(3), 417.