

Pemetaan Distribusi Hutan Mangrove Menggunakan Algoritma *Machine Learning* di Kawasan Hutan Mangrove Petengoran

ANGGUN TRIDAWATI, ARMIJON, FAJRIYANTO, TIKA CHRISTY NOVIANTI

Teknik Geodesi, Universitas Lampung, Bandar Lampung, Indonesia
Email: anggun.tridawati@eng.unila.ac.id

ABSTRAK

Hutan mangrove Petengoran adalah ekowisata mangrove di Provinsi Lampung yang terancam punah karena meningkatnya aktivitas pengunjung. Sehingga, informasi persebaran mangrove sangat diperlukan untuk tujuan konservasi. Dewasa ini, banyak peneliti memanfaatkan teknologi penginderaan jauh untuk pemetaan mangrove menggunakan algoritma *machine learning*. Penelitian ini bertujuan untuk membandingkan algoritma *support vector machine* (SVM) dan *random forest* (RF) untuk pemetaan mangrove menggunakan komposit RGB dan NDVI pada citra Sentinel 2A. Hasil penelitian menunjukkan bahwa algoritma RF memberikan akurasi yang lebih tinggi dibandingkan dengan SVM dibuktikan dengan nilai akurasi keseluruhan dan indeks kappa RF sebesar 92,68% dan 0,88, sedangkan pada SVM sebesar 91,86% dan 0,87. Meski demikian, terdapat kesalahan klasifikasi hutan mangrove di kedua algoritma. Hal tersebut disebabkan oleh kemiripan spektral jenis tanaman dan tidak adanya efek topografi. Sehingga, penelitian selanjutnya diharapkan dapat menambahkan efek topografi untuk mendapatkan akurasi yang lebih baik.

Kata kunci: mangrove, SVM, *random forest*, indeks kappa

ABSTRACT

The Petengoran is mangrove ecotourism in Lampung Province which is threatened with extinction due to increased community activity. Thus, information on the distribution of the Petengoran mangroves is needed for conservation. Many researchers use remote sensing technology to map mangroves using machine learning algorithms. This study aims to compare SVM and random forest RF algorithms for mapping mangroves using RGB and NDVI composites on Sentinel 2A imagery. The results showed that the RF algorithm provides higher accuracy compared to SVM. This is evidenced by the overall accuracy value and RF kappa index of 92.68% and 0.88, while the SVM is 91.86% and 0.87. However, there is a misclassification of mangrove forests in both algorithms. This is due to the spectral similarity of vegetation and no topographical effect. Thus, future research is expected to add topographical effects to obtain higher accuracy.

Keywords: mangrove, SVM, *random forest*, kappa index

1. PENDAHULUAN

Mangrove adalah tanaman intertidal yang hidup di daerah tropis maupun non-tropis (**Baran, 1999**)(**Barbier, 2000**)(**Nagelkerken dkk., 2008**) dan tumbuh dengan subur dalam kondisi lingkungan yang keras seperti salinitas tinggi, suhu tinggi, pasang ekstrem, dan sedimentasi tinggi (**Alongi, 2009**), serta mampu bertahan pada genangan pasang surut sekitar 0,4–1,27 m (**Clarke & Hannon, 1969**)(**Primavera dkk., 2012**). Vegetasi mangrove memberikan banyak manfaat bagi manusia dan ekosistem sekitarnya yaitu: melindungi manusia dari badai dan tsunami (**Dahdouh-Guebas, dkk, 2005**)(**Primavera, dkk, 2012**), mencegah erosi dan abrasi (**Primavera, dkk, 2012**), sebagai penyerap CO₂ (**Purwanto dkk, 2022**), menyediakan habitat bagi organisme di sekitar kawasan mangrove seperti burung dan ikan (**Hernández-Blanco, dkk, 2021**)(**Mumby, dkk, 2004**), berperan penting dalam mencegah perubahan iklim, karena mampu menyerap 1.023 Mg karbon per hektar (**Donato, dkk, 2011**) dan mengandung lima kali lipat karbon hutan tropis, boreal, dan subtropis (**Paillon, dkk, 2014**).

Menurut Giri (**Giri, 2021**), hutan mangrove dunia tersebar di 118 negara dengan luasan 13,7 juta Hektar (ha). Asia Tenggara merupakan benua yang memiliki hutan mangrove dengan variasi spesies yang luar biasa seluas 63,2 × 10⁵ ha dan merupakan 34,9% dari total luas hutan mangrove dunia yaitu 181,1 × 10⁵ ha (**Giesen, 1998**)(**Mohamed Hatha & Chacko, 2012**). Di sisi lain, menurut Organisasi Pangan dan Pertanian (**FAO, 14**), hutan mangrove juga merupakan bagian dari ekosistem dunia yang hampir punah karena sekitar sepertiga luasan mangrove dunia berkurang pada tahun 1980 hingga 2005, dengan kehilangan terbesar terjadi di Asia (**FAO, 2007**). Di Asia Tenggara, lebih dari 110.000 hektar hutan mangrove ditebangi, dimana sekitar 97.000 hektar mangrove hilang pada tahun 2000 dan 2012 (**Richards & Friess, 2016**). Kepunahan hutan mangrove disebabkan oleh faktor alam dan antropogenik seperti perubahan iklim, kenaikan permukaan laut (**Feller, dkk, 2017**)(**Lovelock, dkk, 2015**)(**Saintilan dkk., 2020**) dan konversi kawasan mangrove menjadi pemukiman (**Valiela, dkk, 2001**).

Negara-negara yang memiliki hutan mangrove, harus berupaya menghentikan laju kepunahan mangrove, salah satunya adalah Indonesia. Menurut Ulqodri (**Ulqodry, dkk, 2021**), Indonesia dikenal sebagai 'rumah terbesar' bagi kawasan mangrove, karena mencakup sekitar 18-23% dari hutan mangrove dunia (**Marlianingrum, dkk, 2021**) dan 59.8% dari hutan mangrove Asia Tenggara (**Darmawan, dkk, 2020**). Permasalahannya saat ini adalah sekitar 48% hutan mangrove di Indonesia mengalami kerusakan akibat ulah manusia dan faktor lain (**Haya, dkk, 2015**). Hutan mangrove Petengoran adalah lokasi ekowisata mangrove yang berada di Desa Gebang, Kecamatan Teluk Pandan, Kabupaten Pesawaran yang telah disahkan oleh Peraturan Desa (Perdes) Nomor 1 Tahun 2016 (Dinas Pariwisata Kabupaten Pesawaran, 2021). Pada tahun 2020 dan 2021, ekowisata mangrove di Petengoran mengalami peningkatan pengunjung yang mengakibatkan meningkat pula berbagai aktivitas sosial ekonomi masyarakat yang berakibat terancamnya ekosistem mangrove (**Pattimahu, dkk, 2020**). Oleh sebab itu, informasi distribusi spasial mangrove Petengoran merupakan hal yang penting untuk mengidentifikasi kawasan mana saja yang perlu mendapat perhatian untuk konservasi mangrove.

Pemetaan mangrove yang cepat dan akurat dapat membantu pengelolaan dan pemantauan hutan mangrove secara efektif. Luasnya sebaran hutan mangrove menyebabkan pemantauan secara konvensional tidak mungkin dilakukan karena membutuhkan banyak tenaga, waktu dan biaya (**Zhang, dkk, 2017**). Pengindraan jauh adalah metode monitoring hutan dengan waktu dan biaya yang murah, serta memberikan kemudahan dalam proses identifikasi hutan

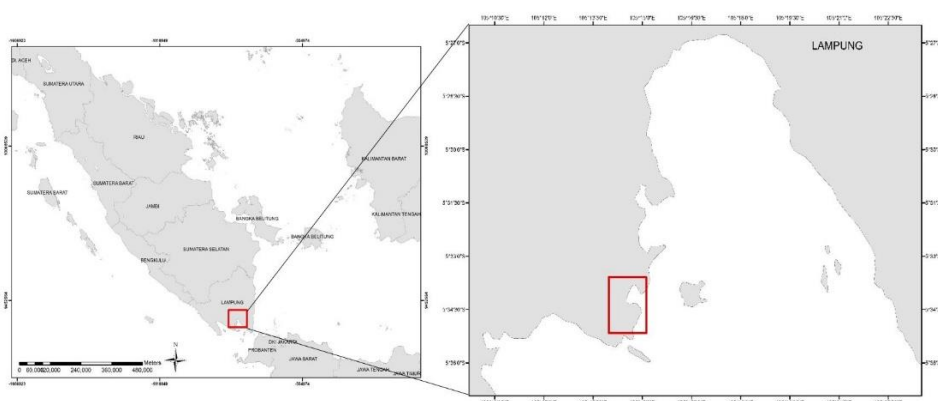
mangrove (**Jamaluddin, dkk, 2022**). Dalam beberapa dekade, beberapa peneliti memanfaatkan teknologi penginderaan jauh untuk pemetaan mangrove menggunakan teknik klasifikasi terawasi, seperti *maksimum likelihood* (**Rahmadi, dkk, 2022**) dan *orientasi object* (**Artika, dkk, 2019**). Keterbatasan dari teknik ini adalah asumsi data yang terdistribusi normal dan melibatkan expert dalam menentukan kriteria *sampling* (**Mountrakis, dkk, 2011**). Kondisi ini menjadikan *machine learning* sebagai solusi untuk mengatasi keterbatasan tersebut agar menghasilkan model klasifikasi yang lebih akurat (**Adugna, dkk, 2022**).

Algoritma *machine learning* adalah teknik terawasi non-parametrik yang tidak mengharuskan data terdistribusi normal (**Adugna, dkk, 2022**). Dewasa ini, penggunaan algoritma *machine learning* untuk memetakan hutan mangrove terus berkembang. Khususnya algoritma *machine learning support vector machine* (SVM) dan *random forest* (RF) yang menjadi perhatian dalam penginderaan jauh karena kemampuannya yang baik dalam menangani data multidimensi dan memberikan akurasi klasifikasi yang memuaskan (**Dabija, dkk, 2021**). Beberapa penelitian telah membandingkan dua algoritma ini dengan menggunakan dataset penginderaan jauh dan tujuan yang berbeda, misalnya (**Meraj, dkk, 2022**)(**Pelletier, dkk, 2016**)(**Wei, dkk, 2022**) menyatakan bahwa RF mengungguli SVM, berbeda dengan temuan (**Dabija, dkk, 2021**)(**Sahin, dkk, 2020**)(**Thanh Noi & Kappas, 2017**) melaporkan bahwa SVM memiliki kinerja lebih baik daripada RF. Dapat disimpulkan bahwa akurasi klasifikasi terbaik antara RF dan SVM masih belum konsisten. Oleh sebab itu, penelitian ini bertujuan untuk membandingkan algoritma SVM dan RF untuk pemetaan mangrove di Desa Gebang, Kabupaten Pesawaran, Provinsi Lampung.

2. METODE

2.1 Lokasi penelitian

Lokasi penelitian adalah kawasan hutan mangrove Petengoran, secara geografis terletak pada koordinat $5^{\circ}56'17''S$ dan $105^{\circ}24'10.20''E$ di Desa Gebang, Kecamatan Teluk Pandan, Kabupaten Pesawaran, Provinsi Lampung, Indonesia. Hutan mangrove Petengoran adalah kawasan ekowisata yang mampu menarik pengunjung menikmati keindahan pemandangan alam. Lokasi penelitian dapat dilihat pada Gambar 1.

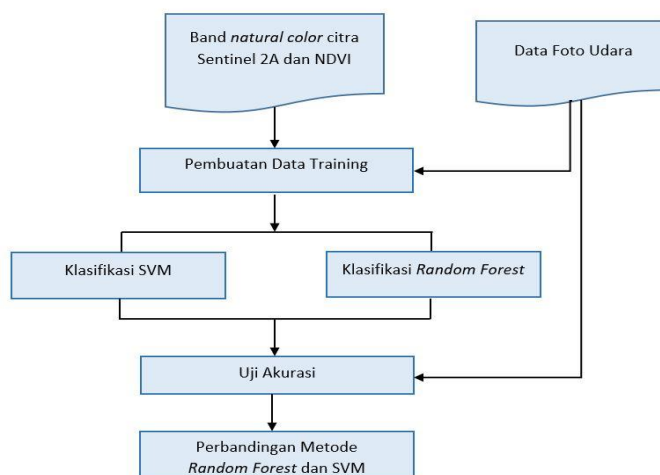


Gambar 1. Lokasi Penelitian

2.1 Metode

Secara umum, metodologi dalam penelitian ini dibagi menjadi beberapa tahapan, yaitu: 1) pengumpulan data 2) pembuatan titik *training* dan titik uji, 3) Klasifikasi, 4) uji akurasi, dan 5) analisis perbandingan algoritma. Adapun diagram alir dapat dilihat pada Gambar 2.

Pemetaan Distribusi Hutan Mangrove Menggunakan Algoritma *Machine Learning* di Kawasan Hutan Mangrove Petengoran



Gambar 2. Metodologi Penelitian

2.1.1 Pengumpulan Data

1. Citra satelit

Penelitian ini menggunakan citra sentinel 2A yang diakuisisi pada tanggal 9 November 2022. Citra Sentinel 2A dianggap mampu memberikan hasil akurasi yang lebih baik dibandingkan Landsat 8 untuk monitoring hutan, deteksi perubahan lahan, dan mitigasi bencana (ESA, 2015). Menurut Purwanto, komposit RGB (*red green blue*) dari citra Sentinel 2A memberikan akurasi yang terbaik untuk memetakan mangrove (Purwanto, dkk, 2022) sehingga dalam penelitian ini menggunakan komposit RGB.



Gambar 3. Citra Sentinel 2A di Lokasi Penelitian

2. NDVI

Data sentinel 2A diekstrak menjadi indeks vegetasi NDVI (*Normalized Difference Vegetation Index*) merupakan salah satu indeks vegetasi yang paling banyak digunakan (Wicaksono,

dkk, 2016). Rentang nilai NDVI adalah -1 hingga 1. Indeks vegetasi NDVI diaplikasikan pada citra Sentinel-2 di wilayah studi. NDVI diperkenalkan oleh Rouse dkk, **(Rouse, 1947)** dengan formula sebagai berikut:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (0.1)$$

Dimana, NIR adalah nilai DN dari piksel saluran inframerah dekat, sedangkan *Red* adalah nilai DN dari piksel saluran merah.

3. Foto Udara

Perekaman data foto udara menggunakan drone DJI *Phantom 4 Pro*, sedangkan pengolahan foto udara menggunakan perangkat lunak *Agisoft Photoscan*. Adapun tahapannya meliputi: 1) pembuatan jalur terbang, 2) *align photo* adalah tahapan menyamakan titik-titik yang sama antar foto untuk membangun *point cloud*, 3) *build dense cloud* adalah tahapan menginterpolasi *point cloud* pada hasil *align photos* agar membentuk suatu objek, 4) *build mesh*, adalah membangun model 3D yang akan digunakan untuk proses pembentukan orthofoto.



Gambar 4. Data Foto Udara

2.1.2 Pembuatan titik *training* dan titik uji

Secara umum, sebelum melakukan klasifikasi harus melalui dua fase, yaitu pembuatan titik *training* dan titik uji. Titik *training* adalah data yang digunakan untuk merekonstruksi model klasifikasi, sedangkan titik uji adalah data yang digunakan untuk menguji model yang dibangun dengan data lain (*data independen*). Pembuatan titik *training* dan titik uji pada penelitian ini mengacu pada data foto udara sebagai data referensi.

2.1.3 Klasifikasi Citra

Klasifikasi adalah tahapan pengelompokan piksel berdasarkan nilai spektral untuk menghasilkan peta tematik. Pada penelitian ini, pemetaan hutan mangrove dilakukan dengan membandingkan algoritma klasifikasi SVM dan RF.

1. SVM

SVM pertama kali dikembangkan oleh Boser, Guyon, dan Vapnik pada tahun 1992 untuk menghandel data non linear (**Vapnik, 1999**). SVM merupakan salah satu algoritma klasifikasi terawasi yang sebelumnya digunakan untuk klasifikasi biner (**Talukdar, dkk, 2020**). Baru-baru ini, berbagai bidang menggunakan algoritma SVM karena kemampuannya dalam memberikan akurasi klasifikasi yang lebih tinggi dibandingkan dengan metode konvensional (**Mantero, dkk, 2005**).

SVM pada dasarnya bekerja dengan menentukan *hyperplane* terbaik dengan margin optimal antara *support vector* yang berbeda (**Talukdar, dkk, 2020**). Algoritma SVM membutuhkan fungsi kernel untuk membangun *hyperplane* secara akurat dan meminimalkan kesalahan. Ada empat jenis kernel fungsi basis linier, polinomial, sigmoid, dan basis radial (RBF) (**Hsu, dkk, 2003**). RBF adalah kernel yang paling efektif dan umum digunakan dalam berbagai klasifikasi karena dapat mengurangi *overfitting* dan *outlier* (**Hsu, dkk, 2003**). Oleh karena itu kernel ini digunakan dalam penelitian ini. Persamaan fungsi basis radial dapat dilihat pada persamaan berikut:

$$\text{Radial Basis Function (RBF): } K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$$

Performa model SVM menggunakan kernel RBF sangat dipengaruhi oleh dua parameter: C dan γ (**Huang, dkk, 2014**). Surya Prangga melakukan *adjustmen* untuk pemilihan parameter SVM yaitu C = (0.5, 0.75, 1, 10, 100) dan γ = (0.005, 0.05, 0.1, 0.5, 0.75) dengan menggunakan metode Taguchi dan diperoleh C: 100 dan γ = 0,005 sebagai parameter optimal. Oleh karena itu, parameter optimal yang dihasilkan oleh Surya Prangga diadopsi untuk membangun model SVM dan dibandingkan dengan model RF pada penelitian ini yaitu C:100, dan γ = 0,005.

2. Random Forest

RF pertama kali diusulkan oleh Tin Kam Ho, (**Ho, 1995**) pada tahun 1995. Pada tahun 2001, RF dikembangkan oleh Leo Breiman (**Breiman, 2001**) terkait proses *bootstrap aggregating* atau yang lebih populer dengan sebutan *bagging*. *Bagging* adalah singkatan dari *bootstrap aggregating* yaitu metode untuk meningkatkan hasil klasifikasi *machine learning* dengan menggabungkan prediksi klasifikasi dari beberapa model.

RF Menurut Wezel dan Potharst (**Van Wezel & Potharst, 2007**) adalah salah satu metode ansambel untuk meningkatkan akurasi dengan menggabungkan banyak pohon untuk mendapatkan hasil akhir melalui *voting* (**Sun & Schulz, 2015**). Algoritma RF telah diaplikasikan dalam berbagai bidang, salah satunya untuk spesies tanaman (**Burai, dkk, 2015**), biomassa tanaman (**Adam, dkk, 2014**), dan perkebunan kopi (**Tridawati, dkk, 2020**). Dalam menjalankan klasifikasi RF, perlu ditentukan dahulu tuning parameternya yaitu jumlah pohon (*n_{tree}*), jumlah variabel prediktor (*m_{try}*), dan jumlah ukuran sampel minimum (**Rodriguez-Galiano, dkk, 2012**). Tridawati melakukan tuning parameter menggunakan algoritma RF untuk pemetaan mangrove dengan membangun 126 model klasifikasi, menghasilkan tuning parameter terbaik adalah *n_{tree}* 1000, *minimum node size* 6, dan *m_{try}* =

k (*all variables*). Sehingga parameter tersebut juga digunakan dalam penelitian ini untuk membangun model klasifikasi RF dan dibandingkan dengan SVM.

2.1.4 Uji Akurasi

Uji akurasi diperlukan untuk mengetahui ketepatan hasil klasifikasi. Akurasi dari hasil klasifikasi menunjukkan kemampuan model dalam memprediksi kelas target. Keakuratan hasil klasifikasi dievaluasi dengan membuat matriks kesalahan (*confusion matrix*). Matriks kesalahan adalah matriks persegi yang digunakan untuk menunjukkan penyimpangan klasifikasi seperti kelebihan piksel dari kelas lain atau kekurangan piksel di setiap kelas. Idealnya, semua elemen matriks di luar diagonal harus nol, yang berarti matriks bebas dari distorsi (**Lillesand dan Kiefer, 1990**). Persentase ketepatan hasil klasifikasi dilihat dari nilai akurasi pengguna, akurasi produser, akurasi keseluruhan, dan statistik kappa (**Congalton, 1991**).

3. HASIL DAN PEMBAHASAN

Distribusi spasial tanaman mangrove di Desa Gebang, Kecamatan Teluk Pandan, Kabupaten Pesawaran, Provinsi Lampung, Indonesia pada penelitian ini diperoleh dari pemanfaatan citra Sentinel 2A. Citra sentinel 2A dilakukan pemotongan area menyesuaikan sebaran mangrove yang ada di Desa Gebang. Selain itu, dilakukan juga pengambilan foto udara untuk mendapatkan gambaran lokasi penelitian yang lebih detail dengan akurasi 3 cm. data foto udara tersebut digunakan sebagai referensi dalam penentuan titik *training* dan titik uji. Selanjutnya pembuatan model klasifikasi distribusi spasial hutan mangrove menggunakan algoritma RF dan SVM.

A. Perbandingan Hasil Klasifikasi

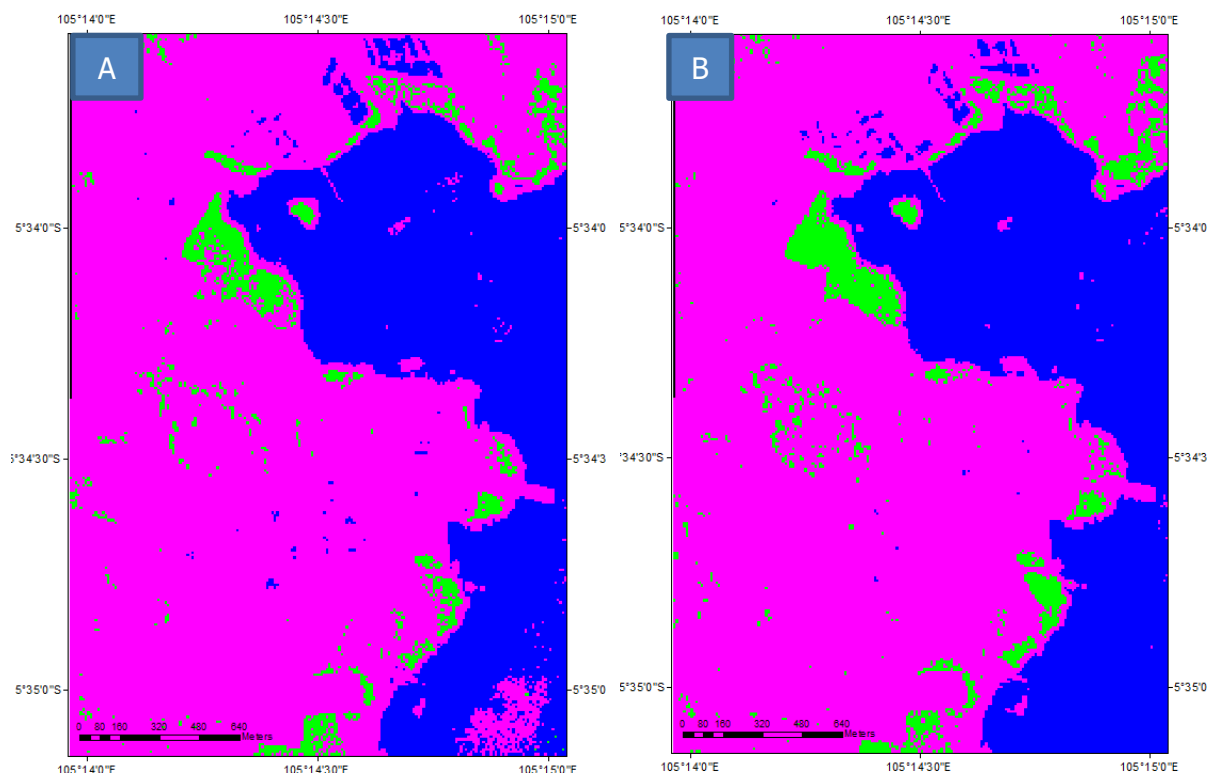
Hasil klasifikasi menggunakan algoritma RF dan SVM di wilayah kajian terbagi menjadi tiga kelas penutup lahan yaitu kelas air, mangrove, dan non-mangrove. Adapun penjelasan terkait kelas tersebut dapat dilihat pada Tabel 1.

Tabel 1. Deskripsi Kelas Tutupan Lahan

Kelas	Definisi
Non-mangrove	Tanah, lahan kosong, lahan terbangun, jalan, semak belukar, tumbuh-tumbuhan, habitat bakau lainnya selain mangrove dan air
Mangrove	Tanaman yang hidup di air payau dan sepanjang garis pantai.
Air	Perairan di wilayah tertentu, baik statis maupun dinamis, seperti laut, sungai, danau.

Distribusi spasial mangrove dianalisis berdasarkan klasifikasi algoritma SVM menggunakan parameter $C:100$ dan $\gamma = 0,005$ dan algoritma RF menggunakan parameter *tree* 1000, *mtry*: seluruh variabel, dan node 6 menggunakan band RGB citra sentinel 2A dan NDVI. Klasifikasi SVM menghasilkan akurasi keseluruhan sebesar 91,86%, statistik kappa sebesar 0,87, akurasi produser sebesar 84,88%, dan akurasi pengguna sebesar 98,65%, sedangkan algoritma RF menghasilkan akurasi keseluruhan sebesar 92,68%, statistik kappa sebesar 0,88, akurasi produser sebesar 84,88%, dan akurasi pengguna sebesar 97,33%. Hasil klasifikasi model ini dapat dilihat pada Gambar 5 dan *confusion matrix* pada Tabel 2 dan 3.

Pemetaan Distribusi Hutan Mangrove Menggunakan Algoritma *Machine Learning* di Kawasan Hutan Mangrove Petengoran



Gambar 5. Hasil Klasifikasi a) SVM dan b) RF

Hasil klasifikasi antara algoritma SVM dan RF, tidak menunjukkan perbedaan yang signifikan pada kelas mangrove dibuktikan dari nilai produser akurasi yang sama yaitu 84,88% (Tabel 2 dan 3). Hutan mangrove tersebar di lokasi yang relatif sama pada dua algoritma yang berbeda, namun yang membedakan adalah kepadatan hutan mangrove pada RF lebih tinggi dibandingkan dengan algoritma SVM. Hasil pengamatan lapangan menunjukkan bahwa klasifikasi RF yang paling mendekati kondisi sebenarnya. Di sisi lain, hutan mangrove juga terlihat berada di tengah-tengah non-mangrove. Hal tersebut kemungkinan disebabkan oleh dua faktor: 1) Kesamaan spektral antara mangrove dengan tanaman lain, karena menurut **(Moran, dkk, 1997)**, kemiripan spektral jenis tanaman sangat sulit dihindari, 2) tidak adanya efek topografi, mangrove adalah tanaman yang tumbuh di sepanjang garis pantai yang memiliki ketinggian lebih rendah dibandingkan daratan, sehingga dengan adanya penambahan data topografi diharapkan dapat lebih membedakan antara mangrove dengan tanaman lain pada kelas non-mangrove. Hal ini selaras dengan penelitian **(Tridawati, dkk, 2020)** dimana penambahan variabel topografi menunjukkan adanya peningkatan akurasi keseluruhan sebesar 2,21%, akurasi produser meningkat sebesar 2,58% dan akurasi pengguna meningkat sebesar 2,37%. Hal serupa juga pada penelitian yang dilakukan oleh **(Kelley, dkk, 2018)** penambahan data topografi dapat meningkatkan akurasi klasifikasi tanaman menggunakan *machine learning*.

Selanjutnya dilakukan uji akurasi dengan membandingkan model klasifikasi dengan titik uji yang didapat dari data foto udara. Hasil uji akurasi tersebut disajikan dengan tabel *confusion matrix*. Terdapat empat parameter penyusun *confusion matrix* yaitu akurasi keseluruhan, akurasi pengguna, akurasi produser, dan indeks kappa.

Tabel 2. Confusion Matrix Hasil Klasifikasi SVM

Klasifikasi SVM	Kelas	Data Ground Truth				Akurasi Pengguna
		Air	Mangrove	Non-mangrove	Total	
	Air	48	0	1	49	97,96
	Mangrove	0	73	1	74	98,65
	Non-mangrove	3	13	105	121	86,78
	Total	51	86	109	Akurasi Keseluruhan	91,86%
	Produser Akurasi	94,12	84,88	96,33	Indeks Kappa	0,87

Tabel 3. Confusion Matrix Hasil Klasifikasi RF

Klasifikasi RF	Kelas	Data Ground Truth				Akurasi Pengguna
		Air	Mangrove	Non-mangrove	Total	
	Air	51	0	1	52	98,08
	Mangrove	0	73	2	75	97,33
	Non-mangrove	0	13	104	117	88,89
	Total	51	86	109	Akurasi Keseluruhan	92,68%
	Produser Akurasi	100	84,88	95,41	Indeks Kappa	0,88

Confusion matrix (Tabel 2 dan 3) menunjukkan bahwa kedua metode menghasilkan akurasi yang relatif sama dilihat dari parameter akurasi pengguna dan akurasi produser. Namun, klasifikasi RF memberikan akurasi keseluruhan dan indeks kappa yang lebih tinggi dibandingkan SVM. Akurasi keseluruhan yang dihasilkan oleh algoritma RF sebesar 92,68%, sedangkan akurasi keseluruhan yang dihasilkan oleh algoritma SVM sebesar 91,86%.

Pada algoritma SVM, dari total 51 piksel kelas air, 48 piksel air terklasifikasi dengan benar di kelas air juga, namun 3 piksel terklasifikasi sebagai kelas mangrove. Hal ini disebabkan karena mangrove hidup di air payau, sehingga sebagian objek mangrove teridentifikasi sebagai air. Produser akurasi kelas air yang dihasilkan sebesar 94,12%. Pada kelas non-mangrove, dari 109 sampel sebanyak 105 sampel terklasifikasi sebagai kelas non-mangrove, 1 sampel terklasifikasi sebagai kelas mangrove, dan 1 sampel mangrove terklasifikasi sebagai kelas air dengan produser akurasi yang dihasilkan sebesar 96,33%. Pada kelas mangrove, dari 86 sampel sebesar 73 terklasifikasi ke dalam kelas mangrove, sedangkan 13 sampel terklasifikasi sebagai kelas non-mangrove. Hal ini disebabkan karena mangrove dan non-mangrove memiliki kemiripan spektral sehingga sulit untuk diidentifikasi (**Moran, dkk, 1997**).

Pada model klasifikasi RF, menghasilkan akurasi keseluruhan sebesar 92,68% dan statistik kappa sebesar 0,88. Hasil menunjukkan bahwa dari total 51 piksel kelas air, terklasifikasi sebesar 51 piksel di kelas air juga, yang berarti bahwa kelas air terklasifikasi dengan sangat baik dengan produser akurasi yang dihasilkan sebesar 100%. Pada kelas non-mangrove, dari 109 sampel sebanyak 104 sampel terklasifikasi sebagai kelas non-mangrove, 2 sampel

terklasifikasi sebagai kelas mangrove, dan 1 sampel mangrove terklasifikasi sebagai kelas air dengan produser akurasi yang dihasilkan sebesar 95,41%. Pada kelas mangrove, dari 86 sampel sebesar 73 terklasifikasi ke dalam kelas mangrove, sedangkan 13 sampel terklasifikasi sebagai kelas non-mangrove.

Menurut **(Landis & Koch, 1977)**, indeks kappa lebih mutakhir dalam menyatakan akurasi klasifikasi. Penyebabnya adalah pada indeks kappa memperhitungkan variasi akurasi dari setiap kelas tutupan lahan sedangkan pada akurasi keseluruhan hanya memperhitungkan akurasi secara keseluruhan tanpa melibatkan variasi akurasi setiap kelas tutupan lahan. Merujuk pada **(Landis & Koch, 1977)**, *indeks agreement* dikategorikan ke dalam 6 kelas indeks kappa dapat dilihat pada Tabel 4.

Tabel 4. Indeks Kappa

No.	Indeks Kappa	Tingkat kesesuaian (<i>agreement</i>)
1	< 0	<i>No agreement</i>
2	± 0,20	<i>Slight agreement</i>
3	0,21 ± 0,40	<i>Fair agreement</i>
4	0,41 ± 0,60	<i>Moderate agreement</i>
5	0,61 ± 0,80	<i>Substantial agreement</i>
6	0,81 ± 1	<i>Almost perfect agreement</i>

Berdasarkan hasil klasifikasi tutupan lahan mangrove menggunakan algoritma SVM, indeks kappa yang dihasilkan sebesar 0,87 (*almost perfect agreement*) yang berarti tingkat kesesuaian antara model klasifikasi dengan data referensi mendekati sempurna yaitu sebesar 87%. Hasil klasifikasi menunjukkan sensitivitas metode SVM dalam pemetaan mangrove di lingkungan yang heterogen ditinjau dari akurasi keseluruhan, akurasi pengguna, dan akurasi produk. Penelitian ini didukung oleh **(Tridawati & Darmawan, 2017)** yang menyatakan bahwa SVM adalah algoritma yang baik diterapkan di lingkungan yang heterogen. Sedangkan, hasil klasifikasi tutupan lahan mangrove menggunakan algoritma RF, menghasilkan indeks kappa sebesar 0,88 (*almost perfect agreement*) yang berarti tingkat kesesuaian antara model klasifikasi dengan data referensi mendekati sempurna yaitu sebesar 88%. Indeks kappa yang dihasilkan RF meningkat 1% dibandingkan algoritma SVM. Hal ini disebabkan karena RF adalah algoritma yang mampu mengatasi ketidakstabilan pada model yang kompleks dengan kumpulan data yang relatif kecil **(Tridawati, dkk, 2020)**. Penelitian ini selaras dengan **(Kelley, dkk, 2018)** yang menyatakan bahwa RF adalah algoritma yang handal dalam pemetaan tutupan lahan.

B. Prediksi Luasan Mangrove

Berdasarkan akurasi yang telah dilakukan pada penelitian ini metode yang paling tepat dan akurat dalam deteksi dan klasifikasi tutupan lahan mangrove adalah RF. Hal ini disebabkan Indeks kappa yang dihasilkan RF meningkat dibandingkan algoritma SVM.

Persebaran mangrove merupakan distribusi luasan mangrove di lokasi penelitian. Persebaran mangrove dihitung berdasarkan analisis klasifikasi terbaik, yaitu RF berdasarkan citra Sentinel 2A. Prediksi luasan mangrove dapat dilihat pada Tabel 5.

Tabel 5. Prediksi Luasan Tutupan Lahan

Kelas	Definisi	Luas (Ha)
Non-mangrove	Tanah, lahan kosong, lahan terbangun, jalan, semak belukar, tumbuh-tumbuhan, habitat bakau lainnya selain mangrove dan air	391
Mangrove	Tanaman yang hidup di air payau dan sepanjang garis pantai.	35,15
Air	Perairan di wilayah tertentu, baik statis maupun dinamis, seperti laut, sungai, danau.	196,63

Informasi sebelumnya mengenai tutupan lahan di kawasan Petengoran belum ditemukan. Penelitian sebelumnya hanya berfokus pada nilai ekowisata mangrove (**Aswenti, 2020**). Berdasarkan hasil klasifikasi menggunakan algoritma RF, diperoleh hasil prediksi luasan mangrove di lokasi penelitian. Algoritma RF menghasilkan luasan mangrove sebesar 35,15 ha, non-mangrove sebesar 391 ha, dan badan air sebesar 196,63 ha.

4. KESIMPULAN

Penelitian ini membandingkan algoritma SVM dan RF, yaitu dua algoritma *machine learning* yang sangat efektif untuk pemetaan mangrove di sebagian kawasan ekowisata Mangrove, Petengoran, menggunakan komposit RGB pada sentinel 2A dan NDVI. Hasil penelitian menunjukkan bahwa algoritma RF memberikan akurasi yang lebih tinggi dibandingkan dengan SVM hal ini dibuktikan dengan nilai akurasi keseluruhan dan indeks kappa RF sebesar 92,68% dan 0,88, sedangkan akurasi keseluruhan dan indeks kappa SVM sebesar 91,86% dan 0,87. Meski demikian, masih terdapat kesalahan dalam hasil klasifikasi di kedua algoritma yaitu hutan mangrove terlihat berada di tengah-tengah non-mangrove. Hal tersebut kemungkinan disebabkan oleh dua faktor: 1) kemiripan spektral jenis tanaman sangat sulit dihindari, 2) tidak adanya efek topografi. Sehingga, penelitian selanjutnya sebaiknya dapat menambahkan efek topografi agar mendapatkan hasil akurasi yang lebih baik.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Fakultas Teknik Universitas Lampung yang telah mendanai penelitian ini melalui program DIPA FT skema Penelitian Dasar Tahun 2023 dengan no **kontrak: 5542/UN26.15/LK.03/2023** hingga penelitian ini bisa berjalan dengan lancar.

DAFTAR RUJUKAN

Adam, E., Mutanga, O., Abdel-Rahman, E. M., & Ismail, R. (2014). Estimating standing biomass in papyrus (*Cyperus papyrus* L.) swamp: Exploratory of in situ hyperspectral indices and random forest regression. *International Journal of Remote Sensing*, 35(2), 693-714.

- Adugna, T., Xu, W., & Fan, J. (2022). Comparison of random forest and support vector machine classifiers for regional land cover mapping using coarse resolution FY-3C images. *Remote Sensing*, 14(3), 574.
- Alongi, D. (2009). *The energetics of mangrove forests*. Springer Science & Business Media.
- Artika, E., Darmawan, A., & Hilmanto, R. (2019). Perbandingan Metode Maximum Likelihood Clasification (MLC) dan Object Oriented Classification (OOC) dalam Pemetaan Tutupan Mangrove di Kabupaten Lampung Selatan. *Jurnal Hutan Tropis*, 7(3), 267-275.
- Baran, E. (1999). A review of quantified relationships between mangroves and coastal resources.
- Barbier, E. B. (2000). Valuing the environment as input: review of applications to mangrove-fishery linkages. *Ecological economics*, 35(1), 47-61.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Burai, P., Deák, B., Valkó, O., & Tomor, T. (2015). Classification of herbaceous vegetation using airborne hyperspectral imagery. *Remote Sensing*, 7(2), 2046-2066.
- Clarke, L. D., & Hannon, N. J. (1969). The mangrove swamp and salt marsh communities of the Sydney district: II. The Holocoenotic complex with particular reference to physiography. *The Journal of Ecology*, 213-234.
- Dabija, A., Kluczek, M., Zagajewski, B., Raczko, E., Kycko, M., Al-Sulttani, A. H., Tardà, A., Pineda, L., & Corbera, J. (2021). Comparison of support vector machines and random forests for corine land cover mapping. *Remote Sensing*, 13(4), 777.
- Dahdouh-Guebas, F., Jayatissa, L. P., Di Nitto, D., Bosire, J. O., Seen, D. L., & Koedam, N. (2005). How effective were mangroves as a defence against the recent tsunami? *Current biology*, 15(12), R443-R447.
- Darmawan, S., Sari, D. K., Wikantika, K., Tridawati, A., Hernawati, R., & Sedu, M. K. (2020). Identification before-after forest fire and prediction of mangrove forest based on Markov-cellular automata in part of Sembilang national park, Banyuasin, South Sumatra, Indonesia. *Remote Sensing*, 12(22), 3700.
- Donato, D. C., Kauffman, J. B., Murdiyarso, D., Kurnianto, S., Stidham, M., & Kanninen, M. (2011). Mangroves among the most carbon-rich forests in the tropics. *Nature geoscience*, 4(5), 293-297.
- FAO, U. (2007). The world's mangroves 1980–2005. *FAO forestry paper*, 153, 77.
- Feller, I. C., Friess, D. A., Krauss, K. W., & Lewis III, R. R. (2017). The state of the world's mangroves in the 21st century under climate change. *Hydrobiologia*, 803(1), 1-12.

- Giesen, W. (1998). Indonesian Mangroves. Part 1: Plant diversity and vegetation. *Tropical Biodiversity*, 5(2), 11-23.
- Haya, N., Zamani, N. P., & Soedharma, D. (2015). Community analysis of mangrove ecosystem in the village of islands Jorong Kukupang District. *Jurnal Teknologi Perikanan dan Kelautan*, 6(1), 79-89.
- Hernández-Blanco, M., Costanza, R., & Cifuentes-Jara, M. (2021). Economic valuation of the ecosystem services provided by the mangroves of the Gulf of Nicoya using a hybrid methodology. *Ecosystem Services*, 49, 101258.
- Ho, T. K. (1995). Random decision forests. Proceedings of 3rd international conference on document analysis and recognition,
- Huang, M.-L., Hung, Y.-H., Lee, W., Li, R.-K., & Jiang, B.-R. (2014). SVM-RFE based feature selection and Taguchi parameters optimization for multiclass SVM classifier. *The Scientific World Journal*, 2014.
- 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.
- Kelley, L. C., Pitcher, L., & Bacon, C. (2018). Using Google Earth engine to map complex shade-grown coffee landscapes in Northern Nicaragua. *Remote Sensing*, 10(6), 952.
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 159-174.
- Lovelock, C. E., Cahoon, D. R., Friess, D. A., Guntenspergen, G. R., Krauss, K. W., Reef, R., Rogers, K., Saunders, M. L., Sidik, F., & Swales, A. (2015). The vulnerability of Indo-Pacific mangrove forests to sea-level rise. *Nature*, 526(7574), 559-563.
- Mantero, P., Moser, G., & Serpico, S. B. (2005). Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on geoscience and remote sensing*, 43(3), 559-570.
- Marlianingrum, P. R., Kusumastanto, T., Adrianto, L., & Fahrudin, A. (2021). Valuing habitat quality for managing mangrove ecosystem services in coastal Tangerang District, Indonesia. *Marine Policy*, 133, 104747.
- Meraj, G., Farooq, M., Singh, S. K., Islam, M. N., & Kanga, S. (2022). Modeling the sediment retention and ecosystem provisioning services in the Kashmir valley, India, Western Himalayas. *Modeling Earth Systems and Environment*, 8(3), 3859-3884.

- Moran, M. S., Inoue, Y., & Barnes, E. (1997). Opportunities and limitations for image-based remote sensing in precision crop management. *Remote sensing of Environment*, *61*(3), 319-346.
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS journal of photogrammetry and remote sensing*, *66*(3), 247-259.
- Mumby, P. J., Edwards, A. J., Ernesto Arias-Gonzalez, J., Lindeman, K. C., Blackwell, P. G., Gall, A., Gorczyńska, M. I., Harborne, A. R., Pescod, C. L., & Renken, H. (2004). Mangroves enhance the biomass of coral reef fish communities in the Caribbean. *Nature*, *427*(6974), 533-536.
- Nagelkerken, I., Blaber, S., Bouillon, S., Green, P., Haywood, M., Kirton, L., Meynecke, J.-O., Pawlik, J., Penrose, H., & Sasekumar, A. (2008). The habitat function of mangroves for terrestrial and marine fauna: a review. *Aquatic botany*, *89*(2), 155-185.
- Pailion, C., Wantiez, L., Kulbicki, M., Labonne, M., & Vigliola, L. (2014). Extent of mangrove nursery habitats determines the geographic distribution of a coral reef fish in a South-Pacific archipelago. *PloS one*, *9*(8), e105158.
- Pattimahu, D. V., Litolily, L. I., & Mardiatmoko, G. (2020). Analysis of vegetation and mangrove biomass to tackle climate change in Eastern Indonesia. *Asian J Microbiol Biotech Environ Sci*, *22*(3), 528-534.
- Pelletier, C., Valero, S., Inglada, J., Champion, N., & Dedieu, G. (2016). Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sensing of Environment*, *187*, 156-168.
- Primavera, J., Savaris, J., Bajoyo, B., Coching, J., Curnick, D., Golbeque, R., Guzman, A., Henderin, J., Joven, R., & Loma, R. (2012). Manual on community-based mangrove rehabilitation. *Mangrove Manual Series*, *1*, 240.
- Purwanto, A. D., Wikantika, K., Deliar, A., & Darmawan, S. (2022). Decision Tree and Random Forest Classification Algorithms for Mangrove Forest Mapping in Sembilang National Park, Indonesia. *Remote Sensing*, *15*(1), 16.
- Rahmadi, M. T., Yuniastuti, E., Hakim, M. A., & Suciani, A. (2022). Pemetaan Distribusi Mangrove Menggunakan Citra Sentinel-2A: Studi Kasus Kota Langsa. *Jambura Geoscience Review*, *4*(1), 1-10.
- 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.

- 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.
- Rouse, J. T. (1947). The Absaroka volcanic field.
- Sahin, E. K., Colkesen, I., & Kavzoglu, T. (2020). A comparative assessment of canonical correlation forest, random forest, rotation forest and logistic regression methods for landslide susceptibility mapping. *Geocarto International*, *35*(4), 341-363.
- Saintilan, N., Khan, N., Ashe, E., Kelleway, J., Rogers, K., Woodroffe, C. D., & Horton, B. P. (2020). Thresholds of mangrove survival under rapid sea level rise. *Science*, *368*(6495), 1118-1121.
- Sun, L., & Schulz, K. (2015). The improvement of land cover classification by thermal remote sensing. *Remote Sensing*, *7*(7), 8368-8390.
- Talukdar, S., Singha, P., Mahato, S., Pal, S., Liou, Y.-A., & Rahman, A. (2020). Land-use land-cover classification by machine learning classifiers for satellite observations—A review. *Remote Sensing*, *12*(7), 1135.
- Thanh Noi, P., & Kappas, M. (2017). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. *Sensors*, *18*(1), 18.
- Tridawati, A., & Darmawan, S. (2017). Investigation of classification algorithm for land cover mapping in oil palm area using optical remote sensing. *FoITIC*.
- Tridawati, A., Wikantika, K., Susantoro, T. M., Harto, A. B., Darmawan, S., Yayusman, L. F., & Ghazali, M. F. (2020). Mapping the distribution of coffee plantations from multi-resolution, multi-temporal, and multi-sensor data using a random forest algorithm. *Remote Sensing*, *12*(23), 3933.
- 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.
- Valiela, I., Bowen, J. L., & York, J. K. (2001). Mangrove Forests: One of the World's Threatened Major Tropical Environments: At least 35% of the area of mangrove forests has been lost in the past two decades, losses that exceed those for tropical rain forests and coral reefs, two other well-known threatened environments. *Bioscience*, *51*(10), 807-815.
- Van Wezel, M., & Potharst, R. (2007). Improved customer choice predictions using ensemble methods. *European Journal of Operational Research*, *181*(1), 436-452.
- Vapnik, V. (1999). *The nature of statistical learning theory*. Springer science & business media.

- Wei, S., Xu, T., Niu, G.-Y., & Zeng, R. (2022). Estimating Irrigation Water Consumption Using Machine Learning and Remote Sensing Data in Kansas High Plains. *Remote Sensing*, *14*(13), 3004.
- Wicaksono, P., Danoedoro, P., Hartono, & Nehren, U. (2016). Mangrove biomass carbon stock mapping of the Karimunjawa Islands using multispectral remote sensing. *International journal of remote sensing*, *37*(1), 26-52.
- Zhang, X., Treitz, P. M., Chen, D., Quan, C., Shi, L., & Li, X. (2017). Mapping mangrove forests using multi-tidal remotely-sensed data and a decision-tree-based procedure. *International journal of applied earth observation and geoinformation*, *62*, 201-214.