

## PEMETAAN HUTAN MANGROVE BERBASIS CITRA LANDSAT 9 MENGUNAKAN ALGORITMA MAXIMUM LIKELIHOOD CLASSIFIER DAN SUPPORT VECTOR MACHINE

### *LANDSAT 9 IMAGERY BASED MANGROVE FOREST MAPPING USING MAXIMUM LIKELIHOOD CLASSIFIER AND SUPPORT VECTOR MACHINE ALGORITHM*

Andrie Ridzki Prasetyo<sup>1\*</sup>, Niechi Valentino<sup>1</sup>, Hasyiyati Shabrina<sup>1</sup>

<sup>1</sup>Program Studi Kehutanan, Fakultas Pertanian, Universitas Mataram, Kota Mataram, Indonesia

\*Email Penulis korespondensi: [andrieridzki@unram.ac.id](mailto:andrieridzki@unram.ac.id)

#### Abstrak

Keberhasilan peluncuran Landsat 9 pada tahun 2021 mempertegas komitmen dalam kelangsungan misi Landsat untuk penyediaan rekaman satelit resolusi menengah global. Salah satu manfaat dari ketersediaan dataset landsat tersebut adalah ekstraksi informasi terkait tutupan hutan mangrove melalui pemetaan khususnya di Gili Lawang. Adapun tantangan utama dalam pemetaan mangrove adalah pemilihan metode klasifikasi yang memberikan hasil paling akurat. Penelitian ini bertujuan mengeksplorasi penggunaan algoritma Maximum Likelihood Classifier (MLC) dan Support Vector Machine (SVM) dalam konteks pemetaan mangrove menggunakan citra Landsat 9 di Gili Lawang. Kedua algoritma tersebut menunjukkan perbedaan dalam mendeteksi luas daerah bermangrove, non mangrove, serta badan air, secara berturut-turut untuk SVM 371,89 ha; 58,11 ha; 3,73 ha. Sedangkan algoritma MLC 328,88 ha; 98,41 ha; 6,45 ha. Algoritma MLC mengidentifikasi objek non mangrove pada batas terluar Gili Lawang, sedangkan SVM mengidentifikasi wilayah yang sama sebagai objek mangrove karena pengaruh dari training area yang dibuat dan keterpisahan yang rendah. Algoritma SVM memiliki akurasi yang lebih baik dengan Kappa statistic 0.85 dibanding MLC dengan nilai 0.73.

Kata Kunci: Gili Lawang, Landsat 9, Mangrove, Support Vector Machine, Maximum Likelihood Classifier

#### Abstract

The successful launch of Landsat 9 in 2021 emphasizes the commitment to the continuity of the Landsat mission to provide global medium resolution satellite records. The benefit of the availability of the Landsat dataset is the extraction of information related to mangrove forest cover through mapping, especially in Gili Lawang. The main challenge in mangrove mapping is selecting a classification method that provides the most accurate results. This research aims to explore the use of the Maximum Likelihood Classifier (MLC) and Support Vector Machine (SVM) algorithms in the context of mangrove mapping using Landsat 9 imagery on Gili Lawang. The two algorithms show differences in detecting the area of mangrove, non-mangrove and water bodies, respectively for SVM 371.89 ha, 58.11 ha, 3.73 ha; while the MLC algorithm is 328.88 ha, 98.41 ha, and 6.45 ha. The MLC algorithm identifies non-mangrove objects at the outer boundary of Gili Lawang, while SVM identifies the same area as mangrove objects due to the influence of the training area created and low separability. The SVM algorithm has better accuracy with a Kappa statistic of 0.85 compared to MLC with a value of 0.73.

Keywords: Gili Lawang, Landsat 9, Mangrove, Support Vector Machine, Maximum Likelihood Classifier

## PENDAHULUAN

Perkembangan keilmuan penginderaan jauh saat ini sangat didukung oleh ketersediaan data observasi bumi berupa citra satelit. Landsat adalah contoh salah satu citra satelit beresolusi menengah yang memiliki ketersediaan data yang sangat baik dan dapat diakses secara gratis. Juli 1972 merupakan titik awal kehadiran Landsat sebagai sensor digital pertama yang dikembangkan untuk pemantauan permukaan bumi. Hingga saat ini sudah ada delapan misi Landsat (Landsat 1, 2, 3, 4, 5, 7, 8 dan 9) yang menjadi catatan sejarah sebagai satelit pemantau bumi dengan perekaman data terpanjang selama periode interaksi manusia terhadap lingkungan

dan perubahan iklim (Crawford et al., 2023; Goward et al., 2022). Keberhasilan peluncuran Landsat 9 pada tahun 2021 mempertegas komitmen USGS, NASA, dan Tim Sains Landsat dalam kelangsungan misi Landsat untuk penyediaan rekaman satelit resolusi menengah global (Choate et al., 2022; Crawford et al., 2023; Goward et al., 2022).

Salah satu bentuk manfaat dari ketersediaan dataset landsat tersebut adalah ekstraksi informasi terkait tutupan hutan mangrove. Informasi terkait tutupan mangrove memiliki peran krusial dalam upaya konservasi ekosistem pesisir. Salah satu langkah penting dalam menjaga keberlanjutan ekosistem mangrove adalah dengan melakukan ekstraksi informasi terkait sebaran, luas dan kondisi mangrove melalui pemetaan (Purwanto et al., 2023; Segaran et al., 2023). Pemetaan ini memberikan gambaran detail tentang ekosistem tersebut, memungkinkan peneliti untuk mengidentifikasi area-area yang memerlukan perhatian khusus. Arkema et al., (2023) menyatakan informasi ini menjadi dasar untuk merancang strategi konservasi yang lebih efektif dan dapat diadaptasi, termasuk upaya restorasi dan perlindungan terhadap area mangrove yang rentan terhadap degradasi. Dengan pemetaan yang akurat, konservasi mangrove dapat lebih terarah dan berdampak positif bagi keberlanjutan ekosistem pesisir secara keseluruhan (Yu et al., 2023).

Konservasi mangrove sangat penting dilakukan, khususnya di wilayah pulau kecil yang akan terdampak sangat besar jika mangrovenya hilang. Salah satu contoh daerah yang akan terdampak yaitu Gili Lawang Kabupaten Lombok Timur Provinsi Nusa Tenggara Barat. Gili Lawang termasuk dalam kawasan Konservasi Laut Daerah (KKLD). Gili Sulat-Gili Lawang melalui SK Bupati Lombok Timur No 188.45/332/KP/2014 dicanangkan sebagai Pencadangan Kawasan Konservasi Perairan Daerah di Kabupaten Lombok Timur. Selain itu, Gili Lawang adalah salah satu cerminan ekosistem mangrove yang berbentuk pulau. Oleh karena itu, mangrove di Gili Lawang memerlukan pengelolaan yang baik. Salah satu tahapan penting dalam pengelolaan mangrove yaitu pemetaan mangrove itu sendiri.

Permasalahan utama dalam proses pemetaan mangrove adalah pemilihan metode klasifikasi atau identifikasi objek yang memberikan hasil yang akurat dan dapat diandalkan. Beberapa metode dan algoritma klasifikasi telah banyak dicoba oleh beberapa peneliti dalam sejumlah penelitian, namun studi komparatif tambahan diperlukan untuk menentukan pendekatan mana yang paling efektif (Al-Aayedi et al., 2023). Klasifikasi terbimbing (*supervised classification*) yang memanfaatkan piksel training area merupakan metode yang paling disukai dan banyak diterapkan oleh peneliti dalam mengklasifikasikan objek permukaan bumi (Ahmad et al., 2018). Beberapa algoritma yang digunakan dalam klasifikasi terbimbing tersebut diantaranya adalah *Maximum Likelihood Classifier* (MLC) dan *Support Vector Machine* (SVM). SVM merupakan algoritma non-parametrik yang penggunaannya tidak memerlukan persyaratan statistik. Berbeda dengan MLC yang merupakan algoritma parametrik yang cara kerjanya sangat tergantung dari peluang dan nilai-nilai statistiknya (Ahmad et al., 2018; Al-Aayedi et al., 2023).

Artikel ini akan mengeksplorasi dua algoritma tersebut dalam konteks pemetaan mangrove menggunakan citra Landsat 9. Kedua metode ini telah terbukti berhasil dalam klasifikasi objek pada citra satelit, namun perbandingan langsung mereka dalam pemetaan mangrove masih memerlukan kajian lebih lanjut. Dalam literatur ilmiah terkait, penelitian sebelumnya telah menunjukkan keberhasilan MLC dan SVM dalam pemetaan di berbagai lokasi. Yani et al. (2022) melakukan penelitian menggunakan algoritma MLC dan SVM dalam mengidentifikasi wilayah genangan banjir di Danau Tempe Sulawesi Selatan. Taati et al. (2015) menggunakan SVM dan MLC dalam klasifikasi penggunaan lahan di Iran dengan menggunakan citra Landsat 5 TM. Al-Aayedi et al. (2023) menggunakan algoritma SVM dan MLC untuk mengekstraksi informasi tutupan lahan di Iraq dengan menggunakan citra Sentinel 2A. Beberapa penelitian tersebut mengaplikasi algoritma SVM dan MLC, namun

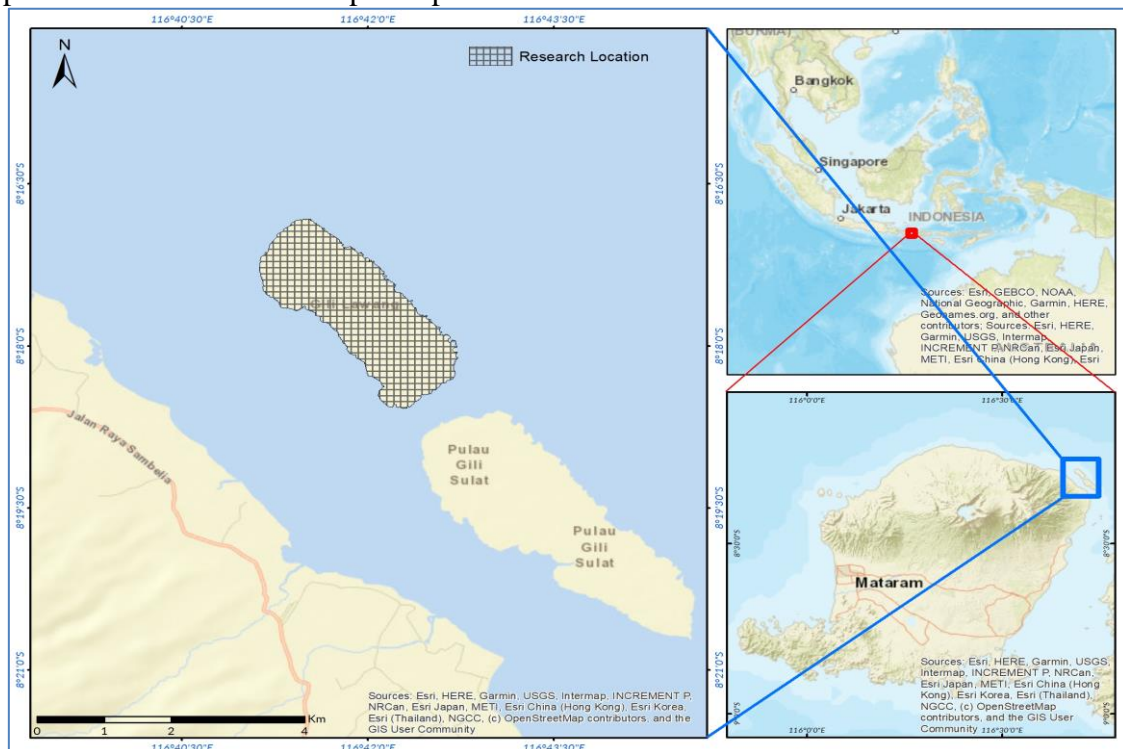
penggunaannya menggunakan citra Landsat 9 dan untuk pemetaan mangrove masih sedikit sekali dilakukan. Kemajuan teknologi citra satelit dan pengembangan algoritma ini memberikan peluang untuk meningkatkan akurasi dan efisiensi pemetaan mangrove.

Melalui penelitian ini, diharapkan dapat ditemukan metode yang optimal untuk pemetaan mangrove, yang dapat memberikan informasi spasial yang akurat dan mendukung upaya konservasi serta pengelolaan ekosistem mangrove secara berkelanjutan. Riset ini diharapkan menghasilkan pengetahuan yang menjadi dasar dan landasan bagi pengembangan metode pemetaan yang lebih canggih dan dapat diaplikasikan secara luas dalam pemantauan lingkungan pesisir. Artikel ini disusun dengan tujuan membandingkan akurasi pemetaan mangrove menggunakan algoritma SVM dan MLC. Fokus utama penelitian adalah mengidentifikasi seberapa baik kedua metode ini mampu mengklasifikasikan objek dalam citra Landsat 9, khususnya dalam konteks pemetaan mangrove Gili Lawang.

## METODE PENELITIAN

### Lokasi Penelitian

Ekosistem mangrove Gili Lawang di Kabupaten Lombok Timur menjadi lokasi penelitian. Secara geografis Gili Lawang berada pada  $8^{\circ}16'43,92''S$  -  $8^{\circ}18'39,20''S$  dan  $116^{\circ}41'24,21''E$  -  $116^{\circ}42'14''E$ . Gili Lawang berada pada posisi timur laut dari daratan pulau Lombok dengan jarak  $\pm 3$  Km dari daratan pulau Lombok. Merujuk kepada Perda Kabupaten Lombok Timur no 10 Tahun 2006, Gili Lawang bersama dengan Gili Sulat ditetapkan sebagai Kawasan Konservasi Laut Daerah (Huda & Sari, 2010; Rizal, 2019). Selanjutnya menurut Valentino et al. (2023) secara status dan fungsi Kawasan Hutan, Gili Lawang masuk kedalam wilayah pengelolaan KPHL Rinjani Timur dengan fungsi Hutan Lindung. Gili Lawang merupakan pulau tak berpenghuni yang didalamnya tumbuh beberapa jenis mangrove, diantaranya *Rhizophora mucronata*, *R. apiculata*, *R. stylosa*, *Ceriops tagal*, *Avicennia marina*, *Sonneratia alba* dan *Lumnitzera racemose* (Firmansyah et al., 2019; Rizal, 2019). Gambaran peta situasi lokasi riset ditampilkan pada Gambar 1.



Gambar 1. Peta situasi lokasi riset

## Dataset Satelit Landsat 9

Penelitian ini menggunakan dataset Landsat 9 OLI-2/TIRS-2. Citra satelit Landsat 9 dapat diunduh secara gratis melalui <https://earthexplorer.usgs.gov/>. Citra satelit ini dipilih karena tidak memiliki awan dan tidak terlalu terpengaruh oleh efek hamburan dan penyerapan atmosfer pada lokasi penelitian (Prasetyo et al., 2023). Hal tersebut dilakukan agar mereduksi kemungkinan bias yang dapat dihasilkan. Informasi spektral yang termuat dalam dataset Landsat 9 ini tersimpan dalam bentuk band/kanal. Kanal-kanal tersebut merepresentasikan berbagai spektrum elektromagnetik. Informasi terkait dataset Landsat 9 pada riset ini ditunjukkan pada Tabel 1.

**Tabel 1.** Dataset citra Landsat 9 yang dipakai pada penelitian

Identitas Data	Tanggal Akuisisi	Path	Row	Kanal/Saluran Spektral
LC09_L1TP_116066_20221104_20230323_02_T1	November 4th, 2022	116	66	Kanal 1 Coastal Aerosol (0.43 - 0.45 $\mu\text{m}$ ) 30 meter
				Kanal 2 Visible Blue (0.450 - 0.51 $\mu\text{m}$ ) 30 meter
				Kanal 3 Visible Green (0.53 - 0.59 $\mu\text{m}$ ) 30 meter
				Kanal 4 Visible Red (0.64 - 0.67 $\mu\text{m}$ ) 30 meter
				Kanal 5 Near-Infrared (0.85 - 0.88 $\mu\text{m}$ ) 30 meter
				Kanal 6 SWIR 1(1.57 - 1.65 $\mu\text{m}$ ) 30 meter
				Kanal 7 SWIR 2 (2.11 - 2.29 $\mu\text{m}$ ) 30 meter
				Kanal 8 Panchromatic (0.50 - 0.68 $\mu\text{m}$ ) 15 meter
				Kanal 9 Cirrus (1.36 - 1.38 $\mu\text{m}$ ) 30 meter
				Kanal 10 TIRS 1 (10.6 - 11.19 $\mu\text{m}$ ) 100 meter
				Kanal 11 TIRS 2 (11.5 - 12.51 $\mu\text{m}$ ) 100 meter

Sumber: <https://earthexplorer.usgs.gov/>

## Pre-processing

Tahapan pre-processing untuk Landsat 9 OLI-2/TIRS-2 pada penelitian ini meliputi *top of atmospheric reflectance*, dan *surface reflectance* yang merupakan bagian dari koreksi atmosferik. Dataset yang digunakan merupakan data landsat level 1(L1TP) yang masih membutuhkan koreksi secara atmosferik (Choate et al., 2022; Prasetyo et al., 2023). Semua tahapan pre-processing ini dilakukan dengan bantuan perangkat lunak QGIS plugin SCP. Menghilangkan pengaruh dan bias dari atmosfer adalah langkah penting untuk menghasilkan nilai reflektan permukaan. Nilai digital setiap piksel citra dikonversi menjadi reflektansi permukaan menggunakan DOS1 (*dark object subtraction*) yang ada pada plugin SCP di QGIS.

Penerapan DOS pada citra Landsat 9 dilakukan untuk mengekstrak nilai reflektansi permukaan. DOS bekerja pada keseluruhan band untuk mengidentifikasi piksel gelap (Ghayour et al., 2021). Diasumsikan bahwa benda gelap yang tidak memantulkan cahaya dan memiliki nilai lebih besar dari nol merupakan hasil hamburan atmosfer. Dengan mengurangi nilai ini untuk setiap piksel dari setiap band, hamburan kemudian dihilangkan (Santarsiero et al., 2022). Setelah koreksi atmosfer dilakukan nilai piksel yang ada menunjukkan reflektansi permukaan. Selanjutnya citra yang telah terkoreksi tadi di *extract* sesuai area fokus penelitian. Sehingga mempermudah proses analisis data.

## Training Area

Pembuatan training area merupakan tahapan selanjutnya yang dilakukan pada penelitian ini. Tahapan ini diawali dengan membuat citra komposit Landsat 9 dengan kombinasi band 564. Penggunaan kombinasi ini berdasarkan penelusuran beberapa penelitian sebelumnya yang menyatakan dalam kajian mangrove kombinasi 564 memberikan informasi yang paling baik (Dwiputra & Mustofa, 2021; Prasetyo et al., 2023; Wiguna et al., 2022). Selanjutnya dilakukan pembuatan sekumpulan training area kelas mangrove, non-mangrove, dan badan air. Training area dihasilkan secara manual dengan mengambil sampel dalam jumlah yang sesuai di setiap

kelas perwakilan. Sekumpulan training area tersebut dikonversi menjadi kelas penciri yang digunakan untuk melatih dan mengklasifikasikan citra. Pembuatan training area kemudian digunakan untuk menentukan kelas penciri (*variance-covariance, mean, minimum, dan maximum*). Pembuatan training area harus didasari oleh perbedaan yang jelas antara objek yang ada dipermukaan bumi. Proses yang dilakukan ini akan mempengaruhi kualitas dari hasil klasifikasi.

### Klasifikasi Terbimbing (SVM dan MLC)

Klasifikasi terbimbing mengelompokkan piksel pada citra berdasarkan kelas penciri (*signature class*). Kelas penciri ini merupakan dataset yang diperoleh dari pembuatan training area. Klasifikasi terbimbing digunakan pada penelitian ini yaitu dengan menerapkan algoritma SVM dan MLC. Training area yang telah dibangun diterapkan pada dua algoritma tersebut dan akan dibandingkan melalui matriks kesalahan. Dua algoritma yang paling umum digunakan dalam pemetaan dan klasifikasi data adalah *Support Vector Machine* (SVM) dan *Maximum Likelihood Classifier* (MLC). Metode ini juga digunakan dalam pemetaan hutan mangrove. Algoritma pembelajaran mesin yang dikenal sebagai SVM memiliki kemampuan untuk menemukan hiperplan terbaik yang dapat digunakan untuk memisahkan berbagai kelas dari data (Al-Aayedi et al., 2023; Firmansyah et al., 2019). Dalam kasus di mana data memiliki banyak dimensi atau ketika pemisahan antara kelas tidak linier, ini sangat bermanfaat.

Sebaliknya, MLC adalah teknik statistik yang berfokus pada menghitung kemungkinan bahwa setiap piksel dalam gambar termasuk dalam kelas tertentu berdasarkan distribusi nilai piksel kelas tersebut. MLC cocok untuk menyelesaikan masalah dengan campuran piksel dan distribusi kelas yang rumit. Algoritma MLC berbasis piksel yang didasarkan pada fungsi perhitungan probabilitas. MLC merupakan suatu algoritma klasifikasi yang secara statistik paling banyak digunakan dan merupakan salah satu algoritma parametrik (Ghayour et al., 2021).

### Matriks Kesalahan

Untuk mengukur kesalahan identifikasi atau klasifikasi objek mangrove, penting untuk mengevaluasi keakuratan citra yang diklasifikasikan. Terdapat beberapa metode yang mungkin diterapkan untuk menilai akurasi, salah satunya adalah *error matrix* atau matrik kesalahan. Dalam metode ini, tabulasi silang sederhana (Tabel 2) dari kelas yang diidentifikasi dengan data yang diamati di lapangan atau data referensi digunakan untuk sampel kasus di Gili Lawang.

**Tabel 2.** Matriks kesalahan yang digunakan untuk uji akurasi

Kelas	a	b	c	n	Jumlah
A	X <sub>a,a</sub>	X <sub>a,b</sub>	X <sub>a,c</sub>	X <sub>a,n</sub>	X <sub>a+</sub>
B	X <sub>b,a</sub>	X <sub>b,b</sub>	X <sub>b,c</sub>	X <sub>b,n</sub>	X <sub>b+</sub>
C	X <sub>c,a</sub>	X <sub>c,b</sub>	X <sub>c,c</sub>	X <sub>c,n</sub>	X <sub>c+</sub>
N	X <sub>n,a</sub>	X <sub>n,b</sub>	X <sub>n,c</sub>	X <sub>n,n</sub>	X <sub>n+</sub>
Jumlah	X <sub>+a</sub>	X <sub>+b</sub>	X <sub>+c</sub>	X <sub>+n</sub>	N

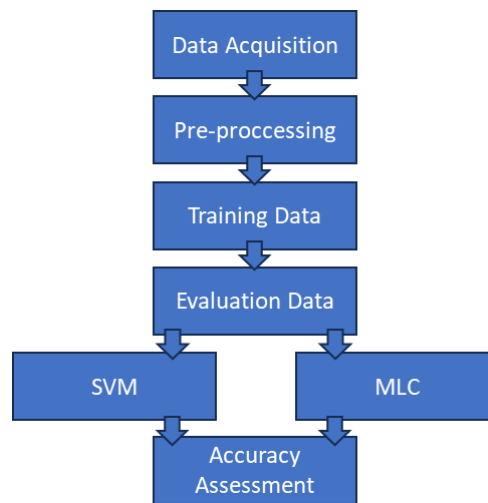
Sumber: (Jaya & Etyarsah, 2021)

Pada penelitian ini digunakan sebanyak 60 titik data referensi lapangan yang terdistribusi secara *stratified random sampling*. Pada masing-masing objek yang diidentifikasi (Mangrove, non-mangrove, dan badan air) terdistribusi 20 titik secara merata. Beberapa ukuran akurasi yang digunakan adalah *user accuracy, producer accuracy, overall accuracy* dan *kappa statistic*. Formula yang digunakan untuk mendapat beberapa ukuran akurasi tersebut disajikan pada tabel 3. Proses pembuatan titik tersebut dilakukan pada perangkat lunak pemroses peta. Langkah dan tahapan penelitian secara singkat disajikan pada Gambar 2.

**Tabel 3.** Perhitungan pada uji akurasi

No	Accuracy assessment	Formula	Keterangan
1	User Accuracy	$\frac{x_{ii}}{x_{+i}}100\%$	
2	Producer Accuracy	$\frac{x_{ii}}{x_{i+}}100\%$	$X_{ii}$ = nilai diagonal dari matrik kontingensi baris ke-i dan kolom ke-i $X_{+i}$ = jumlah piksel dalam kolom ke-i $X_{i+}$ = jumlah piksel dalam baris ke-i
3	Overall Accuracy	$\frac{\sum x_{ii}}{N}100\%$	$N$ = banyaknya piksel dalam contoh
4	Kappa Statistic	$\frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r X_{i+}X_{+i}}{N^2 - \sum_{i=1}^r X_{i+}X_{+i}} 100\%$	

Sumber: (Jaya & Etyarsah, 2021)

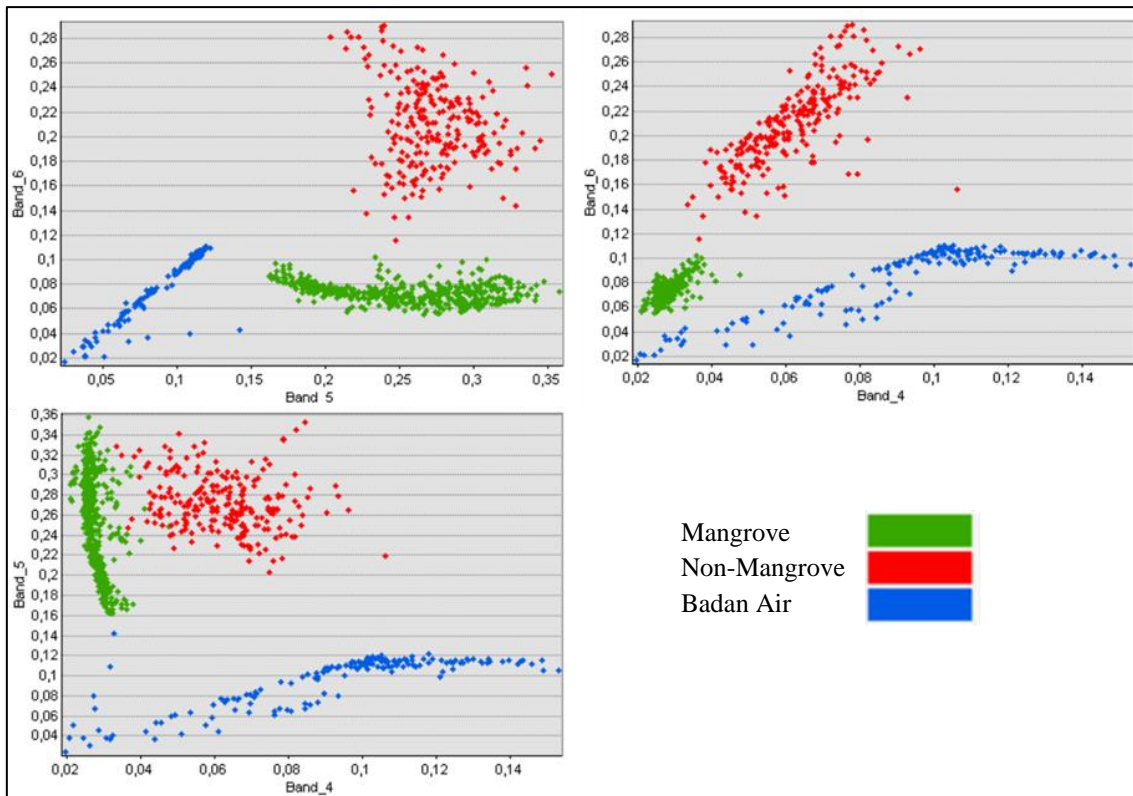


**Gambar 2.** Langkah dan Tahapan Penelitian

### HASIL DAN PEMBAHASAN

Tahapan pre-processing yang dilakukan bertujuan untuk mereduksi gangguan-gangguan atmosfer sehingga citra yang dihasilkan lebih jelas dan bersih. Citra yang telah terkoreksi selanjutnya diterapkan kombinasi 564 sehingga memudahkan dalam pengidentifikasian objek mangrove. Selanjutnya dilakukan pembuatan training area untuk objek Mangrove, Non-Mangrove, dan Badan Air. Untuk melakukan hal ini, lokasi sampel representatif dari tipe tutupan digunakan untuk menyusun kunci interpretasi numerik yang menggambarkan atribut spektral untuk setiap tipe objek yang diklasifikasikan. Evaluasi terhadap ukuran sampel, varian spektral, normalitas, dan identitas training area dilakukan dalam proses ini. Salah satu cara evaluasi training area adalah dengan melihat aspek keterpisahan antar objek. Keterpisahan antar objek yang bagus merupakan hasil dari proses pembuatan training area yang baik. Sehingga hasil klasifikasi objek menjadi baik.

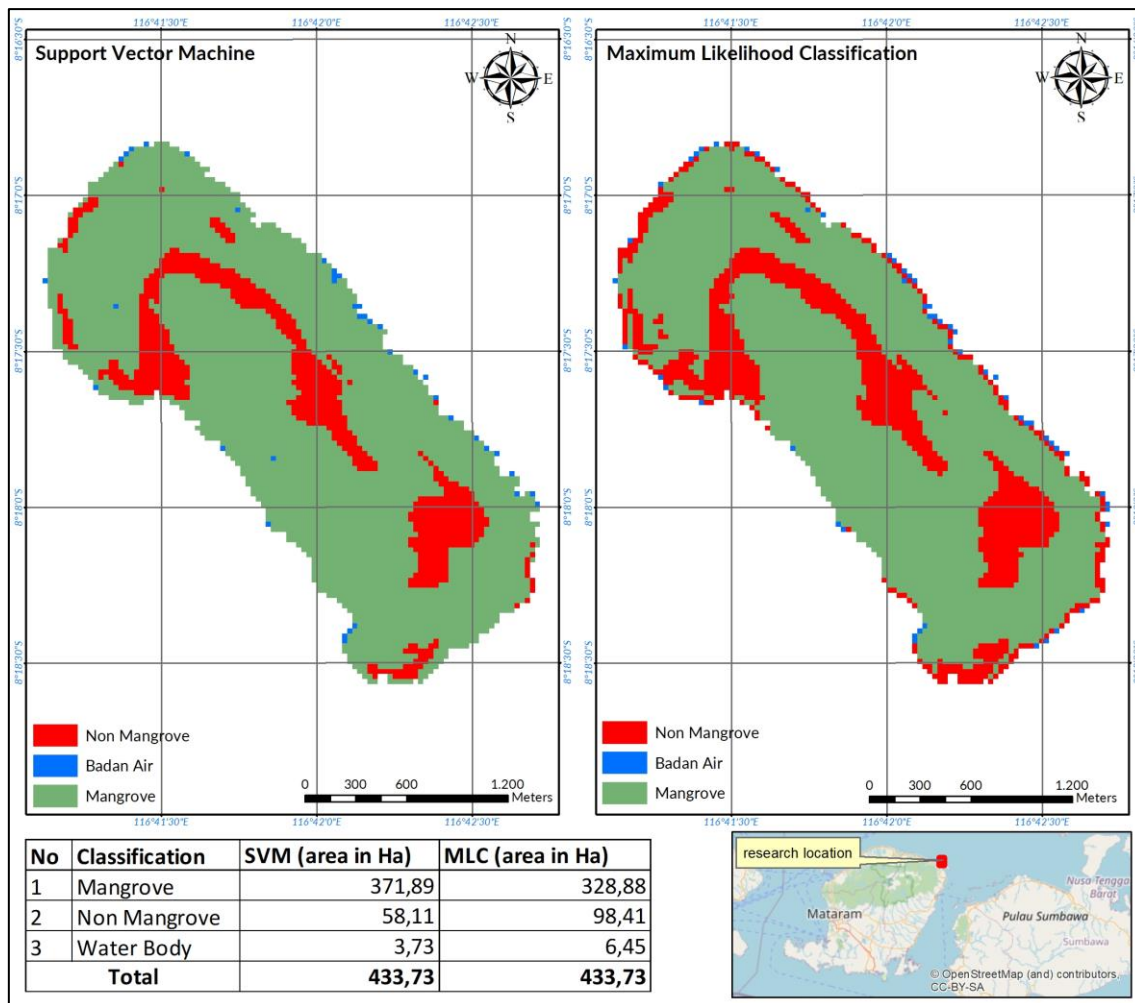
*Scatterplot* dari kanal 5, 6, dan 4 citra landsat 9 yang disajikan pada Gambar 3 menunjukkan keterpisahan masing-masing objek dari training area yang dibuat. Setiap nilai piksel telah diplot pada *scatterplot* yang menunjukkan kategori objek yang diketahui. Piksel dalam setiap kelas tidak memiliki nilai spektral tunggal yang berulang. Sebaliknya, mereka menggambarkan kecenderungan pemusatan alami namun variabilitas dari sifat spektral yang ditemukan dalam setiap objek yang diidentifikasi.



**Gambar 3.** Scatterplot beberapa kanal citra landsat dalam konteks evaluasi training area

Penerapan algoritma SVM dan MLC dilakukan pada citra Landsat 9 OLI-2/TIRS-2 akuisisi 4 November 2022. Training area yang telah dievaluasi digunakan sebagai dasar pengklasifikasian objek. Peta perbandingan hasil klasifikasi SVM dan MLC disajikan pada Gambar 4. Berdasarkan pengolahan data diketahui algoritma SVM mengidentifikasi Mangrove seluas 371,89 hektar, non-Mangrove seluas 58,11 hektar, dan badan air seluas 3,73 hektar. Sedangkan penerapan algoritma MLC memberikan hasil identifikasi yang berbeda dengan SVM. Penerapan MLC mengidentifikasi Mangrove seluas 328,88 hektar atau lebih kecil dari identifikasi Mangrove dengan SVM, namun hasil identifikasi non-mangrove dan badan air yang dihasilkan lebih besar dibandingkan dengan SVM.

Secara visual terlihat perbedaan hasil identifikasi algoritma SVM dan MLC. MLC mengidentifikasi objek non mangrove pada batas terluar Gili Lawang sedangkan SVM mengidentifikasi wilayah tersebut masih sebagai objek mangrove. Selain itu pada bagian tengah Gili Lawang, MLC mengidentifikasi sebaran objek non mangrovenya lebih besar dibanding SVM. Perbedaan hasil identifikasi kedua algoritma ini dipengaruhi oleh training area yang dibuat. Pada Gambar 3 *scatterplot* Band 4 dan 5 memperlihatkan bahwa objek mangrove dan non mangrove memiliki keterpisahan yang cukup rendah sehingga hal ini sangat mempengaruhi hasil identifikasi objek MLC. MLC merupakan *parametric based method* yang sangat tergantung kepada sebaran data yang normal dan probabilitasnya (Al-Aayed et al., 2023; Ghayour et al., 2021; Jaya & Etyarsah, 2021).



Gambar 4. Peta perbandingan hasil penerapan algoritma SVM dan MLC

**Matriks Kesalahan**

Alat analisis yang digunakan untuk menilai keterandalan hasil klasifikasi dari algoritma SVM dan MLC pada penelitian ini adalah matriks kesalahan. Matriks kesalahan dihasilkan melalui perhitungan antara hasil klasifikasi dengan 60 titik pengamatan lapangan. Melalui tabulasi silang antara hasil klasifikasi dengan data pengamatan lapangan diketahui beberapa ukuran akurasi, diantaranya *user accuracy*, *producer accuracy*, *overall accuracy* dan *kappa statistic*.

Tabel 4 dan 5 menunjukkan akurasi dari penerapan algoritma SVM dan MLC pada citra Landsat 9 OLI-2/TIRS-2. Berdasarkan pembuatan matriks kesalahannya diketahui penerapan algoritma SVM dan MLC pada citra Landsat 9 memiliki tingkat akurasi yang cukup baik secara umum. Kedua algoritma ini mampu mengidentifikasi objek mangrove, non-mangrove, dan badan air di wilayah Gili Lawang dengan cukup baik ditandai dengan nilai *overall accuracy* yang lebih besar dari 75%. Akan tetapi, penerapan algoritma SVM memiliki akurasi yang lebih baik dibanding penerapan algoritma MLC. Algoritma SVM memiliki *Kappa statistic* sebesar 0,85 sedangkan algoritma MLC sebesar 0,73.



**Tabel 4.** Rekapitulasi penilaian akurasi menggunakan algoritma SVM

No	Klasifikasi	Overall Accuracy	Kappa	User Accuracy	Producer Accuracy
1	Non-mangrove			90%	100%
2	Badan air	90%	0,85	85%	94%
3	Mangrove			95%	79%

Sumber: Pengolahan data (2023)

**Tabel 5.** Rekapitulasi penilaian akurasi menggunakan algoritma MLC

No	Klasifikasi	Overall Accuracy	Kappa	User Accuracy	Producer Accuracy
1	Non-mangrove			90%	82%
2	Badan air	82%	0,73	75%	94%
3	Mangrove			80%	73%

Sumber: Pengolahan data (2023)

Penerapan algoritma SVM menghasilkan klasifikasi dengan tingkat akurasi yang paling baik. Kondisi ini dipengaruhi oleh penerapan algoritma SVM yang melakukan klasifikasi dengan menetapkan piksel ke jenis objek yang benar menggunakan *hyperplane* dan margin maksimum. Hal ini menghasilkan penetapan piksel pada objek yang benar untuk meminimalkan kesalahan klasifikasi. Sebaliknya, MLC pada penelitian ini sangat terpengaruh oleh training area yang dibuat. Adanya kemiripan antara objek mangrove dan non mangrove membuat hasil identifikasi objek MLC memiliki nilai akurasi yang tidak lebih baik dibanding SVM. Penelitian Ahmad et al. (2018), Al-Ayedi et al. (2023), Ghayour et al. (2021), dan Yani et al. (2022) menunjukkan hasil yang secara umum sama, bahwa identifikasi objek menggunakan SVM memberikan hasil yang lebih baik. Begitu juga dengan penelitian Taati et al. (2015) pada konteks pengkategorisasian penutupan lahan dengan mendayagunakan citra Landsat 5 TM dimana penerapan algoritma SVM menghasilkan akurasi yang lebih tinggi dibandingkan dengan penerapan MLC.

## KESIMPULAN DAN SARAN

### Kesimpulan

Berdasarkan tujuan penelitian yaitu untuk mengeksplorasi penerapan algoritma SVM dan MLC dalam konteks pemetaan hutan mangrove di Gili Lawang menggunakan citra Landsat 9, maka dapat disimpulkan bahwa algoritma SVM mengidentifikasi Mangrove seluas 371,89 hektar, non-Mangrove seluas 58,11 hektar, dan badan air seluas 3,73 hektar. Sedangkan MLC mengidentifikasi mangrove seluas 328,88 ha, non mangrove seluas 98,41 ha, dan badan air seluas 6,45 ha. Penerapan algoritma SVM dan MLC pada penelitian ini menunjukkan tingkat keakurasian yang cukup baik ditandai dengan nilai *overall accuracy* yang lebih besar dari 75%. Namun penerapan algoritma SVM memberikan akurasi yang baik dibandingkan penerapan algoritma MLC. Hal ini ditunjukkan dengan nilai Kappa statistik untuk algoritma SVM adalah 0,85, sedangkan Kappa statistik untuk algoritma MLC adalah 0,73.

### Saran

Penelitian selanjutnya diharapkan dapat lebih banyak menggali algoritma *machine learning* yang tersedia seperti Decision Tree, Random Forest, dan Convolutional Neural Network. Selain itu, pada penelitian selanjutnya juga dapat diujicoba/diperbandingkan akurasi dari beberapa jenis citra satelit lain seperti sentinel 2A, Landsat 8, dan Landsat 9.

## DAFTAR PUSTAKA

- Ahmad, A., Hashim, U. K. M., Mohd, O., Abdullah, M. M., Sakidin, H., & Sufahani, S. F. (2018). Comparative analysis of support vector machine, maximum likelihood and neural network classification on multispectral remote sensing data. *International Journal of Advanced Computer Science and Applications*, 9(9).
- Al-Aayedi, N. B. S., Malik, M. I., & Taher, H. B. (2023). A Comparative Study of Support Vector Machine and Maximum Likelihood Classification to Extract Land Cover of Wasit Governorate-Iraq. *International Journal of Intelligent Systems and Applications in Engineering*, 11(5s), 93–102.
- Arkema, K. K., Delevaux, J. M. S., Silver, J. M., Winder, S. G., Schile-Beers, L. M., Bood, N., Crooks, S., Douthwaite, K., Durham, C., & Hawthorne, P. L. (2023). Evidence-based target setting informs blue carbon strategies for nationally determined contributions. *Nature Ecology & Evolution*, 1–15.
- Choate, M. J., Rengarajan, R., Storey, J. C., & Lubke, M. (2022). Landsat 9 Geometric Characteristics Using Underfly Data. *Remote Sensing*, 14(15), 3781.
- Crawford, C. J., Roy, D. P., Arab, S., Barnes, C., Vermote, E., Hulley, G., Gerace, A., Choate, M., Engebretson, C., & Micijevic, E. (2023). The 50-year Landsat collection 2 archive. *Science of Remote Sensing*, 8, 100103.
- Dwiputra, M. A., & Mustofa, A. (2021). The Comparison of RGB 564 and RGB 573 Band Composite of Landsat 8 for Mangrove Vegetation Distribution Identification on Pahawang Island, Lampung. *IOP Conference Series: Earth and Environmental Science*, 830(1), 012017.
- Firmansyah, S., Gaol, J. L., & Susilo, S. B. (2019). Perbandingan klasifikasi SVM dan Decision Tree untuk pemetaan mangrove berbasis objek menggunakan citra satelit Sentinel-2B di Gili Sulat, Lombok Timur. *Jurnal Pengelolaan Sumberdaya Alam Dan Lingkungan (Journal of Natural Resources and Environmental Management)*, 9(3), 746–757.
- Ghayour, L., Neshat, A., Paryani, S., Shahabi, H., Shirzadi, A., Chen, W., Al-Ansari, N., Geertsema, M., Pourmehdi Amiri, M., & Gholamnia, M. (2021). Performance evaluation of sentinel-2 and landsat 8 OLI data for land cover/use classification using a comparison between machine learning algorithms. *Remote Sensing*, 13(7), 1349.
- Goward, S. N., Williams, D. L., Arvidson, T., Rocchio, L. E. P., Irons, J. R., Russell, C. A., & Johnston, S. S. (2022). Landsat's Enduring Legacy: Pioneering Global Land Observations From Space. *Photogrammetric Engineering & Remote Sensing*, 88(6), 357–358.
- Huda, H. M., & Sari, Y. D. (2010). Pemanfaatan dan Pengelolaan Kawasan Konservasi Laut Daerah Gili Sulat dan Gili Lawang. *Jurnal Sosial Ekonomi Kelautan Dan Perikanan*, 5(2).
- Jaya, I. N. S., & Etyarsah, S. (2021). *Analisis Citra Digital Perspektif Penginderaan Jauh untuk Pengelolaan Sumber Daya Alam* (Vol. 1). PT Penerbit IPB Press.
- Prasetyo, A. R., Valentino, N., & Hadi, M. A. (2023). Identifikasi Sebaran Spasial dan Kerapatan Mangrove Gili Lawang menggunakan Citra Landsat 9 OLI-2/TIRS-2: Identification Gili Lawang Mangrove Spatial Distribution and Density with Landsat 9 OLI-2/TIRS-2 Imagery. *Jurnal Sains Teknologi & Lingkungan*, 9(2), 215–225.
- Purwanto, A. D., Wikantika, K., Deliar, A., & Darmawan, S. (2023). Decision tree and random forest classification algorithms for mangrove forest mapping in Sembilang National Park, Indonesia. *Remote Sensing*, 15(1), 16.

- Rizal, L. S. (2019). Identifikasi Jenis Mangrove Di Kawasan Konservasi Laut Daerah (KKLD) Gili Sulat–Gili Lawang Kabupaten Lombok Timur. *JUPE: Jurnal Pendidikan Mandala*, 4(5).
- Santarsiero, V., Nolè, G., Lanorte, A., Tucci, B., Cillis, G., & Murgante, B. (2022). Remote sensing and spatial analysis for land-take assessment in Basilicata Region (Southern Italy). *Remote Sensing*, 14(7), 1692.
- Segaran, T. C., Azra, M. N., Lananan, F., Burlakovs, J., Vincevica-Gaile, Z., Rudovica, V., Grinfelde, I., Rahim, N. H. A., & Satyanarayana, B. (2023). Mapping the Link between Climate Change and Mangrove Forest: A Global Overview of the Literature. *Forests*, 14(2), 421.
- Taati, A., Sarmadian, F., Mousavi, A., Pour, C. T. H., & Shahir, A. H. E. (2015). Land use classification using support vector machine and maximum likelihood algorithms by Landsat 5 TM images. *Walailak Journal of Science and Technology (WJST)*, 12(8), 681–687.
- Valentino, N., Prasetyo, A. R., & Hadi, M. A. (2023). Preliminary Study of Mangrove Eco-Structures and Natural Regeneration at Gili Lawang, East Lombok, West Nusa Tenggara. *Jurnal Penelitian Pendidikan IPA*, 9(1), 590–601.
- Wiguna, P. P. K., Sutari, N. W. S., Febriarta, E., Permatasari, A. L., Suherningtyas, I. A., Pulungan, N. A. H. J., Sukraini, T. T., & Gani, M. (2022). Spatial Analysis of Mangrove Distribution Using Landsat 8 Oli in Badung Regency and Denpasar City, Bali Province, Indonesia. *Forum Geografi*, 36(1).
- Yani, N., Sulistiawaty, S., & Usman, U. (2022). Perbandingan Metode Klasifikasi Maximum Likelihood dan Support Vector Machine dalam Pemetaan Genangan Banjir (Studi Area: Kawasan Danau Tempe). *Indonesian Journal of Fundamental Sciences Vol*, 8(2).
- Yu, C., Liu, B., Deng, S., Li, Z., Liu, W., Ye, D., Hu, J., & Peng, X. (2023). Using Medium-Resolution Remote Sensing Satellite Images to Evaluate Recent Changes and Future Development Trends of Mangrove Forests on Hainan Island, China. *Forests*, 14(11), 2217.