



## Pemanfaatan *Unmanned Aerial Vehicle* (Uav) dalam Deteksi Goresan Lamun dengan Pendekatan *Machine Learning* di Pantai Terora, Tanjung Bena, Bali

I Putu Ryan Adnyana<sup>a</sup>, I Wayan Gede Astawa Karang<sup>a\*</sup>, I Putu Yogi Darmendra<sup>a</sup>

<sup>a</sup>Program Studi Ilmu Kelautan, Fakultas Kelautan dan Perikanan, Unuversitas Udayana, Bali, Indonesia

\*Corresponding author, email: [gedekarang@unud.ac.id](mailto:gedekarang@unud.ac.id)

### ARTICLE INFO

#### Article history:

Received: 19 April 2024

Received in revised form: 1 Juni 2024

Accepted: 7 Oktober 2024

Available online: 28 Februari 2025

#### Keywords:

*Seagrass propeller, seagrass damage, machine learning, unmanned aerial vehicle (UAV).*

#### Kata Kunci:

Goresan lamun, kerusakan lamun, *machine learning*, *unmanned aerial vehicle (UAV)*

### ABSTRACT

*Seagrass in the Tanjung Bena area spreads along the eastern part of the beach, including Terora Beach. Tourist activities such as water sports and the movement of fishing boats in the shallow waters of the beach contribute significantly to the damage to the seagrass meadow community. Seagrass scars are formed when boat propellers hit the shallow seagrass meadow floor, destroying the leaves, roots, and rhizomes of the seagrass. The purpose of this study is to determine the level of seagrass scar damage at Terora Beach using the absolute percent scarring formula and to compare the three best machine learning algorithm for segmenting seagrass scars, support vector machine (SVM), random forest (RF), and decision tree (DT). Data collection was carried out in November 2023 using a DJI 4 RTK drone, covering a 350x350 meter area. The machine learning SVM, RF, and DT play an important role in segmenting the level of seagrass damage through the use of unmanned aerial vehicles (UAVs). In addition to the machine learning algorithms, a Median filter is also applied to enhance model evaluation and reduce sand pixels in the middle of seagrass beds in the segmentation results. The SVM evaluation resulted in an Accuracy of 77.19%, Precision of 78.20%, Recall of 77.19%, and F1 Score of 77.30%, which are the highest values compared to the random forest and decision tree algorithms. The median filter will be reapplied, resulting in a map of seagrass scars at Terora Beach. The level of seagrass damage at Terora Beach was found to be 5.835%, categorizing it as moderate scarring.*

### ABSTRAK

Lamun di daerah Tanjung Bena menyebar di sepanjang pantai bagian timur salah satunya di Pantai Terora, aktivitas wisata seperti *water sport* dan lalu lalang perahu nelayan di lingkungan perairan dangkal pantai berkontribusi besar terhadap kerusakan komunitas padang lamun. Goresan Lamun terbentuk ketika baling-baling perahu menghantam dasar padang lamun yang dangkal dan menghancurkan daun, akar, dan rimpang lamun. Tujuan penelitian ini mengetahui tingkat kerusakan goresan lamun di Pantai Terora berdasarkan rumus *absolute percent scarring* dan membandingkan 3 algoritma *machine learning* yaitu *support vector machine* (SVM), *random forest* (RF), dan *decision tree* (DT) yang terbaik untuk mendeteksi dan melakukan segmentasi pada goresan lamun. Pengambilan data dilakukan pada bulan November 2023 dengan area 350x350 meter menggunakan *drone* DJI 4 RTK. Algoritma *machine learning* SVM, RF, dan DT berperan penting dalam melakukan segmentasi tingkat kerusakan lamun dengan memanfaatkan *unmanned aerial vehicle (UAV)*. Selain algoritma *machine learning* diterapkan juga *Median filter* untuk meningkatkan evaluasi *machine learning* dan mengurangi piksel pasir di tengah padang lamun pada hasil segmentasi. Evaluasi SVM mendapatkan *Accuracy* dengan persentase 77,19%, *Precision* 78,20%, *Recall* 77,19%, dan *F1 Score* 77,30% dimana nilai tersebut merupakan nilai tertinggi dibandingkan dengan algoritma *random forest* dan *decision tree* yang dimana akan diterapkan kembali *median filter* sehingga pada akhirnya dibuat menjadi peta goresan lamun di Pantai Terora. Tingkat kerusakan lamun yang terjadi di Pantai Terora mencapai 5,835% dan termasuk dalam kategori *moderate scarring*.

2025 JMRT. All rights reserved.

### 1. Pendahuluan

Lamun merupakan tumbuhan *angiospermae* yang mampu beradaptasi pada perairan bersalinitas tinggi. Seluruh hidupnya terendam di bawah air dan memiliki akar sejati, daun dan *rhizoma*. Komunitas ini tumbuh pada kedalaman tertentu selama sinar matahari dapat menjangkau kedalaman perairan tersebut dan diantara batas terendah pasang (Graha *et al.*, 2016).

Luasan area lamun di Indonesia dibagi menjadi 2 yaitu 4.409,48 ha di sebelah barat dan 146.283,68 ha di sebelah timur dengan total luasan mencapai 150.693,16 ha. Sekitar 50 jenis lamun tersebar di seluruh dunia dan 13 jenis di antaranya ditemukan di Indonesia (LIPI, 2017). Fungsi ekologis komunitas lamun sangat penting untuk manusia (Hartini & Lestari, 2019). Komunitas Lamun memiliki fungsi ekologis yaitu sebagai sumber produktivitas primer, menstabilkan dasar perairan dengan sistem

perakaran yang dapat merangkap sediment, menyediakan tempat berlindung, berkembang biak, pemeliharaan, sumber makanan bagi biota-biota perairan laut, pelindung pantai dengan meredam arus, serta mereduksi CO<sub>2</sub> dan penghasil oksigen pada dasar perairan. Penyerap CO<sub>2</sub> di daerah pesisir dapat mengurangi pemanasan global (Zurba, 2018). Tanjung Benoa adalah salah satu daerah di selatan Bali yang memiliki populasi lamun yang besar. Lamun tersebar di pantai bagian timur dan dikenal sebagai tempat wisata dengan banyak aktivitas pinggir pantai seperti berenang dan olahraga air. Nelayan lokal juga menyewakan perahu mereka di daerah tersebut. Aktivitas manusia yang meningkat di pesisir Tanjung Benoa tanpa memperhatikan daya dukung lingkungan dapat mempercepat kerusakan komunitas lamun di wilayah tersebut. Salah satu akibatnya potensi sumber daya alam laut dan penyerapan karbon akan berkurang (Santoso *et al.*, 2017). Kegiatan aktivitas perahu nelayan berkontribusi besar terhadap kerusakan padang lamun di lingkungan perairan pantai (LIPI, 2017). Salah satu faktor paling penting yang memengaruhi kerusakan lamun adalah kerusakan mekanis dari bekas luka baling-baling yang menyebabkan adanya goresan pada padang lamun dan biasanya disebabkan oleh kapal rekreasi dan komersial yang beroperasi di perairan dangkal (Hoque *et al.*, 2018).

Penelitian goresan lamun pernah diteliti oleh (Oguslu *et al.*, (2018) di Deckle Beach, Florida. Berdasarkan penelitian tersebut membahas mengenai deteksi bekas goresan baling-baling perahu memanfaatkan gambar pankromatik menggunakan satelit WorldView-2. Penelitian serupa juga pernah di laksanakan oleh UI Hoque *et al* (2018) penelitian ini mendeteksi goresan padang lamun menggunakan *deep learning* lebih spesifiknya lagi yaitu menggunakan *Deep Convolutional Neural Network* (CNN) untuk mendeteksi goresan pada padang lamun dengan memanfaatkan *panchromatic image* dan *multispectral image* yang beresolusi tinggi. Penelitian terbaru goresan lamun oleh Karang *et al.*, (2024) memanfaatkan *Unmanned Aerial Vehicle* (UAV) beresolusi tinggi untuk memetakan lamun dengan algoritma *multiresolution segmentation* dan goresan lamun dengan menggunakan teknik digitalisasi pada perangkat lunak QGIS.

Penggunaan *unmanned aerial vehicle* (UAV) untuk mengatasi keterbatasan resolusi spasial dan tutupan awan yang sering ditemui pada saat melakukan pemetaan spasial (Karang *et al.*, 2024). Wahidin dan Abdullah (2018), menyebutkan bahwa penggunaan *unmanned aerial vehicle* (UAV) atau drone komersial dan fotogrametri efektif dalam pemetaan substrat perairan dangkal. Tutupan awan menjadi salah satu hambatan bagi satelit pada studi kasus yang serupa dan drone mampu memetakan tanpa tutupan awan (Wijantara *et al.*, 2023). Pemanfaatan *Machine Learning* (ML) pada umumnya dapat memodelkan tanda tangan kelas yang kompleks, dapat menerima berbagai data prediktor input, dan tidak membuat asumsi tentang distribusi data (nonparametrik). Berbagai macam penelitian secara umum menemukan bahwa metode-metode ini cenderung menghasilkan akurasi yang lebih baik dibandingkan dengan pengklasifikasi parametrik tradisional, terutama untuk data yang kompleks dengan ruang fitur berdimensi tinggi, yaitu banyak variabel *predictor* (Maxwell *et al.*, 2018). *Machine learning* dapat untuk mengajari mesin cara menangani data dengan lebih efisien (Mahesh, 2020). Algoritma SVM (*Support Vector Mechine*) memiliki kemampuan yang baik untuk menangani data dengan jumlah yang sedikit dan dapat menghasilkan akurasi yang lebih baik dibandingkan dengan teknik klasifikasi lainnya pada bidang penginderaan jauh (Mountrakis *et al.*, 2011). Selain SVM, *Random Forest* (RF) juga dipilih karena dapat mengatasi hal yang sama seperti algoritma SVM. Selain itu dua algoritma ini juga banyak digunakan pada penelitian terdahulu dalam mengatasi

segmentasi (Sheykhmousa *et al.*, 2020). Selain SVM dan *random forest* algoritma *Decision Tree* (DT) dipilih karena merupakan algoritma *machine learning* yang efisien. DT terdiri dari diagram alir yang dibuat untuk mengelompokkan data secara efektif dengan menguji atribut dataset secara rekursif pada setiap *node* pohon, dengan cabang yang mewakili hasil yang berbeda yang mengarah ke node berikutnya, hingga sebuah daun (atau *node terminal*) dibuat, yang mewakili sebuah kelas (Tedros *et al.*, n.d.)

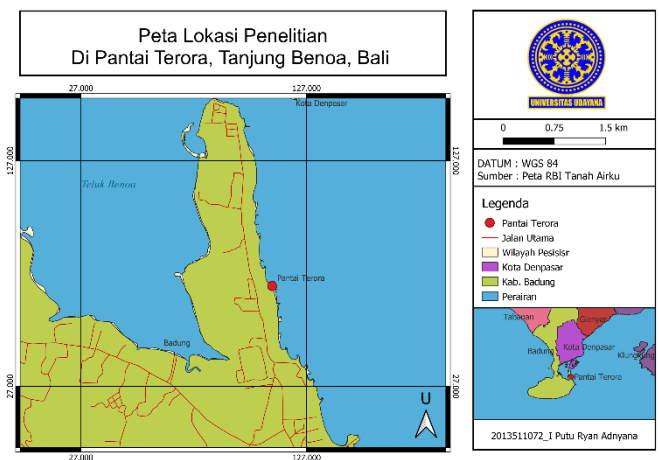
Penelitian goresan lamun sebelumnya sudah pernah dilaksanakan Karang *et al.*, (2024) dengan cakupan area yang lebih luas menggunakan UAV, penelitian sebelumnya belum menerapkan metode *machine learning* hanya mendigitasi secara manual dan lebih berfokus pada pemetaan jenis lamun. Penelitian mengenai goresan lamun di perairan dangkal dengan metode *machine learning* perlu dilakukan dengan tujuan memilih algoritma yang baik dalam memetakan goresan lamun dan mengidentifikasi tingkat kerusakan lamun di Pantai Terora. Hasil dari penelitian ini berupa pemilihan algoritma *machine learning* yang baik dalam mendeteksi goresan lamun dan mengetahui tingkat kerusakan lamun di Pantai Terora dengan harapan dapat dijadikan acuan untuk melakukan *monitoring* pada padang lamun di kemudian hari.

## 2. Metode Penelitian

### 2.1 Lokasi Penelitian

Penelitian dilaksanakan pada bulan November 2023 tanggal dan waktu menyesuaikan dengan kondisi surut dan cuaca di lokasi penelitian. Lokasi penelitian dilakukan di Pantai Terora, Tanjung Benoa, Badung Bali. Berikut merupakan peta lokasi penelitian pada Gambar 1.

Persiapan dilakukan yaitu dengan menentukan luasan area, dan jalur terbang *drone* yang diinginkan dengan posisi kamera *drone* tegak 90 derajat di atas permukaan laut (Wijantara *et al.*, 2023). Penentuan luasan area pemetaan UAV ditentukan berdasarkan area yang berpotensi memiliki goresan pada lamun, luasan area yang akan dilakukan *mapping* berukuran 350 x 350meter persegi. Berikut pada Gambar 2 merupakan penentuan luasan area.



Gambar 1. Peta Lokasi Penelitian



**Gambar 2.** Penentuan Luasan Area Penelitian

## 2.2. Orthomosaic

Sebelum *orthomosaic* dilakukan seleksi foto UAV (*Unmanned Aerial Vehicle*) dengan menyisihkan foto tingkat kemiringan tidak tegak 90 derajat, terdapat *blur* dan memfoto kaki UAV sehingga foto yang didapat siap diolah (Wijantara *et al.*, 2023). Menggabungkan seluruh foto udara (*Orthomosaic*) wilayah yang telah di foto dengan menggunakan kamera UAV yang disebut juga *Orthophoto* (Afrizal *et al.*, 2022). Berikut merupakan tahapan enggabungan Data menggunakan *Software Agisoft Metashape* yaitu:

- Aligning photo*, proses yang menghasilkan model 3d awal dan *sparse point clouds* dengan mengidentifikasi titik pada setiap foto dan melakukan penyatuan dua atau lebih titik pada foto yang sama, (Wijantara *et al.*, 2023).
- Build dense cloud*, proses memisahkan titik tinggi dan rendah yang terdiri dari berbagai bahan seperti tanah, vegetasi, air, dan bahan lain yang membedakan ketinggian tanah dari ketinggian tutupan area (Wijantara *et al.*, 2023).
- Build mesh*, membangun model 3D suatu objek menggunakan bidang yang terdiri dari *dense cloud*. Tujuannya adalah untuk memperbaiki hasil foto yang berlubang karena adanya bagian yang tidak terkena cahaya. (Wijantara *et al.*, 2023).
- Build DEM (Digital Elevation Model)*, proses membuat model elevasi digital dengan data yang diperoleh dari olahan model cloud atau mesh yang rapat (Wijantara *et al.*, 2023).
- Build Orthomosaic* merupakan tahapan menyatukan seluruh foto menjadi satu (Wijantara *et al.*, 2023).

## 2.3 Median Filter

Filtrasi gambar menggunakan *Median Filter*. Metode ini memanfaatkan teknik berbasis *median* dengan menggunakan korelasi antar piksel. Dalam metode ini, piksel yang rusak digantikan oleh nilai median dari piksel-piksel di sekitarnya. Namun, jika kepadatan *noise* cukup tinggi sehingga piksel di sekitarnya juga terpengaruh *noise*, metode ini menggunakan perbedaan *absolut* untuk mengestimasi kepadatan *noise* tersebut (George *et al.*, 2018). *Median Filter* (MF) adalah operasi yang sering digunakan untuk menghilangkan piksel yang menyimpang seperti *noise* garam dan merica serta untuk meratakan area tertentu tanpa menghilangkan detail tepi objek (Kim *et al.*, 2018).

$$\text{Median}(P) = \text{Med}\{P_i\}$$

$$\text{Median}(P) = \frac{P_i(k+1)}{2} \text{ Jika nilai } k \text{ ganjil}$$

$$\text{Median}(P) = 1/2[P_i\left(\frac{k}{2}\right) + P_i\left(\frac{k}{2} + 1\right)] \text{ Jika nilai } k \text{ genap}$$

$P_1, P_2, P_3 \dots P_k$  adalah urutan tetangga piksel. Semua piksel dalam gambar harus diatur dalam urutan naik atau turun sebelum melakukan pemfilteran. Setelah pengurutan, urutan piksel gambar yang dihasilkan akan menjadi  $P_1P_2P_3\dots P_k$ , dimana  $k$  umumnya ganjil (George *et al.*, 2018)


## 2.4 Pelabelan Data

Algoritma yang dipilih merupakan algoritma yang termasuk kategori klasifikasi *supervised learning* (Sodik *et al.*, 2020). Metode klasifikasi ini bekerja dengan mengklasifikasikan kelas yang tidak dikenal berdasarkan kumpulan data sebelumnya yang diberikan label (Roihan *et al.*, 2020). Jumlah kelas yang ditentukan pada penelitian ini berjumlah 3 yaitu pasir, goresan lamun, dan lamun. Pelabelan kelas dilakukan secara manual pada aplikasi QGIS dengan metode *purposive sampling, random sampling dan Multilabel Image* secara visual pada hasil *orthomosaic* UAV yang sudah difiltrasi. Metode *multi label image* dapat memprediksi beberapa kemungkinan yang paling mendekati, melebihi satu label sekaligus (Trisiawan *et al.*, 2022). Segmentasi *machine learning* akan membagi jumlah data label menjadi *training* data sebesar 80% dan *testing* data yaitu sebesar 20% pada masing masing kelas (Omary & Mtenzi, 2010).

## 2.5 Analisis Data

### 2.5.1 Support Vector Machine (SVM)

*Support Vector Machine* (SVM) adalah algoritma klasifikasi yang memiliki kemampuan untuk mencari *vector* atau garis yang berfungsi sebagai pemisah antar kelas dengan memaksimalkan jarak antara kelas tersebut. Algoritma SVM didasarkan pada dua puluh prinsip *linier* klasifikasi yang dikenal sebagai klasifikasi pembelajaran mesin (*Machine Learning*). SVM dapat digambarkan sebagai usaha mencari *hyperplane* terbaik, yang memisahkan antar kelas dari *input* ruang (Nugroho *et al.*, 2003). Skema SVM disajikan pada Gambar 3.




**Gambar 3.** Skema SVM (Nugroho *et al.*, 2003)

### 2.5.2 Random Forest

*Random Forest* adalah algoritma kombinasi dari berbagai pohon prediksi yang masing-masing bergantung pada contoh nilai *vektor* acak yang bebas. Nilai *vektor* acak ini didistribusikan secara sama pada setiap pohon prediksi yang ada di *Random Forest* (Triscowati *et al.*, 2021). *Random Forest* memiliki tahapan yang mirip dengan *bagging* dalam *resampling* dan *voting*, namun yang berbeda adalah dalam pembentukan *classifier*. *Random Forest* juga memiliki akurasi yang tinggi dan cepat dalam pengolahannya dalam mendeteksi tanaman (Tatsumi *et al.*, 2015). Skema *random forest* disajikan pada Gambar 4

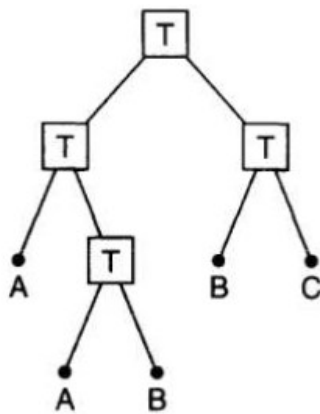




Gambar 4. Skema Random Forest (Liu et al., 2012)

2.5.3 Decision Tree

Algoritma Decision Tree biasanya digunakan untuk membuat percabangan dari pohon keputusan (Sartika & Senses, 2017). Standar yang dibentuk oleh setiap cabang algoritma Decision Tree akan memecah data ke dalam bagian yang lebih kecil (Nugroho et al., 2003). Struktur diagram setiap cabangnya nya merepresentasikan data beserta atributnya (S. Firmansyah, J. Gaol, 2019). Skema decision tree disajikan pada Gambar 5.



Gambar 5. Skema Decision Tree (Firmansyah & Gaol, 2019)

2.5.4 Perhitungan Luasan Goresan Lamun

Perhitungan luasan shp goresan lamun dilakukan setelah setiap shp goresan lamun disatukan menggunakan aplikasi QGIS. Kemudian, perhitungan luasan shp goresan lamun dilakukan menggunakan geometry calculation (Sasono & Susetyo, 2018). Menggabungkan beberapa polygon dengan menggabungkan fitur dari dua atau lebih theme menjadi satu adalah metode penggabungan (merge) (Kristiyanto et al., 2017).

2.5.5 Evaluasi Machine learning

Evaluasi 3 algoritma machine learning dengan Accuracy kemudian untuk menangani distribusi kelas dihitung dengan accuracy, precision, recall, dan F1 Score (Su et al., 2020) ditulis pada Tabel 1.

Tabel 1. Rumus Perhitungan

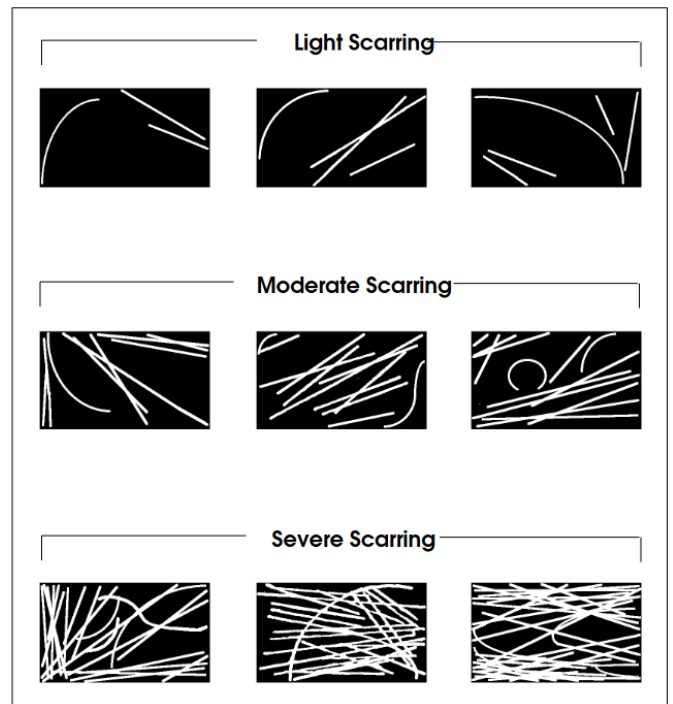
Nama Rumus	Rumus
Accuracy	$\frac{TP + TN}{TP + FP + FN + TN}$
Precision	$\frac{TP}{TP + FP}$
Recall	$\frac{TP}{TP + FN}$

$$F_1 \text{ Score} = \frac{2TP}{2TP + FP + FN}$$

Dalam machine learning nilai True Positive (TP) merupakan prediksi benar yang bernilai positive ; True Negative (TN) prediksi benar dengan nilai negative ; False Positive (FP) prediksi salah dengan nilai positive dan False Negative (FN) prediksi salah dengan nilai negative (Yang et al., 2020). Dengan empat parameter ini, berbagai jenis metrik dapat didefinisikan untuk mengevaluasi kinerja model (Su et al., 2020)

2.5.6 Penilaian Kerusakan Lamun

Goresan lamun yang digambarkan dengan poligon yang digambar secara acak dan kemudian diklasifikasikan secara visual (Sargent et al., 1995). Di dalam setiap poligon, pengukuran luas bekas goresan lamun absolut dengan mengalikan total panjang bekas luka dengan lebar bekas luka yang diperkirakan dalam analisis fotografi dan kemudian dihitung intensitas bekas luka di dalam setiap poligon [percent scarring = (total area bekas luka/total lamun) x 100]. Bekas goresan ringan didefinisikan sebagai <5% dari luas area dalam setiap poligon yang terluka, sedang 5-20% dan parah >20%, dapat representasikan pada Gambar 6 (Martin et al., 2008).




Gambar 6. Tiga Kategori Perkiraan Intensitas Goresan (Sargent et al., 1995)

3. Hasil dan Pembahasan

3.1 Orthomosaic UAV

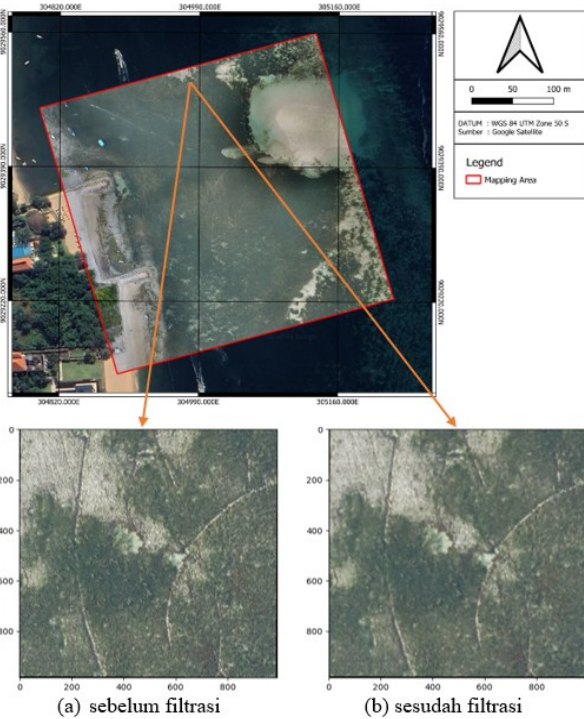
Penerbangan UAV pada area 350x350 meter menghasilkan 430 foto dengan ketinggian 73 meter, kecepatan terbang 5.8 m/s, overlapping 80% (horizontal dan vertical) dan durasi penerbangan selama 18 menit 59 detik menghasilkan foto udara dengan akurasi 2 cm per pixel. Penggabungan foto udara menggunakan software Agisoft Metashape, hasil orthomosaic disajikan pada Gambar 7.




Gambar 7. Orthomosaic UAV

3.2 Median Filter

Hasil filtrasi gambar *median filter* menggunakan nilai  $k=7$  dan dijalankan menggunakan *python* pada aplikasi *visual studio code*. Pemilihan nilai  $k=7$  merupakan hasil percobaan dengan pertimbangan hasil visual yang didapat pada nilai  $k$  tidak menghilangkan goresan, hanya mengurangi pasir pada area yang sangat kecil di tengah padang lamun. Hasil *median filter* dapat dilihat pada Gambar 8. Selain, secara visual perbandingan gambar sebelum difilter dan sesudah difilter dapat dilihat juga pada data histogram. Di mana distribusi *band* gambar UAV sebelum dengan keadaan setelah difilter, perubahan dalam distribusi intensitas piksel meningkat dapat dilihat pada Gambar 9.



Gambar 8. Hasil Median Filter



Gambar 9. Histogram Median Filter

Pada gambar 9 tersebut sumbu x histogram, terdapat rentang nilai sekitar 0 hingga 225, sedangkan sumbu y menunjukkan frekuensi dengan nilai hingga sekitar 25000. Garis merah pada histogram menunjukkan distribusi data setelah diterapkan *median filter*, sementara garis biru mewakili data mentah sebelum pemfilteran. Setelah proses pemfilteran, puncak pada histogram (*peaks*) mengalami peningkatan. Ini menunjukkan bahwa nilai-nilai piksel tertentu menjadi lebih sering muncul atau lebih intens pada citra yang telah difilter. Peningkatan ini mengindikasikan perubahan dalam distribusi intensitas dan mencerminkan efek dari proses pemfilteran.

3.3 Labeling Data

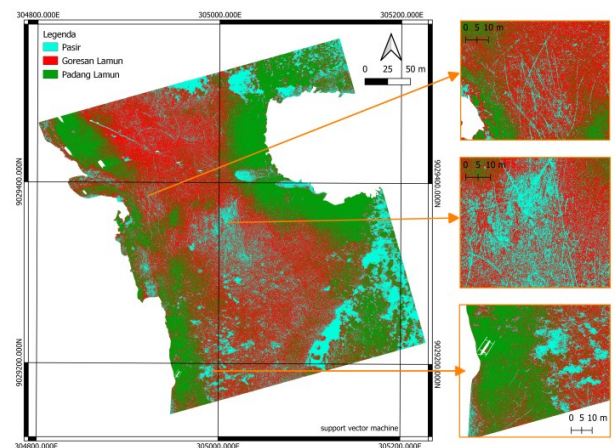
Sebelum dilakukan *labeling*, dilakukan pemotongan gambar UAV hasil *median filter* menggunakan software QGIS menjadi 4 poligon yaitu daratan, perahu, *tidal flat* dan lamun. Area yang akan dilakukan segmentasi *machine learning* hanya *area polygon* lamun titik label akan dijadikan file berformat *tif* menggunakan aplikasi QGIS dan disamakan meta datanya. *Labeling* data pada *polygon* lamun menggunakan *software* yang sama ditentukan jumlah kelas dan label per kelas, yang akan disegmentasikan berjumlah 3 yaitu pasir, goresan lamun, lamun. Adapun total label setiap kelas disajikan pada Tabel 2.

Tabel 2. Total kelas label

Nama Kelas	Total titik label
Pasir	6560 titik
Goresan Lamun	6560 titik
Lamun	6560 titik

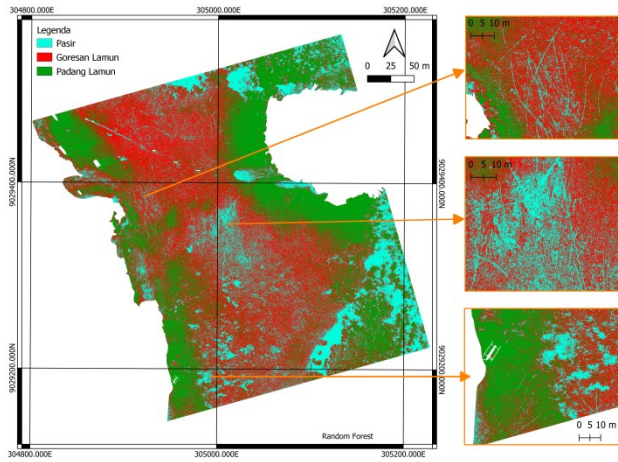
3.4 Segmentasi Machine Learning

Format data setelah dilakukan segmentasi yaitu *Geotiff* format ini akan di konversi ke format *vector* dan kemudian di-*dissolve* menjadi satu poligon utuh untuk setiap kelas sehingga kalkulasi dapat dilakukan pada tahap selanjutnya. Segmentasi *machine learning* yang telah dilakukan belum dapat membedakan objek pasir dan juga goresan lamun dikarenakan dua objek tersebut memiliki *value pixel* yang serupa sehingga sebelum menghitung tingkat kerusakan lamun akan dilakukan pemisahan objek pasir dan juga goresan lamun secara visual pada *software* QGIS. Hasil Segmentasi SVM, *Random Forest*, dan *Decision Tree* disajikan pada Gambar 10, 11, dan 12.



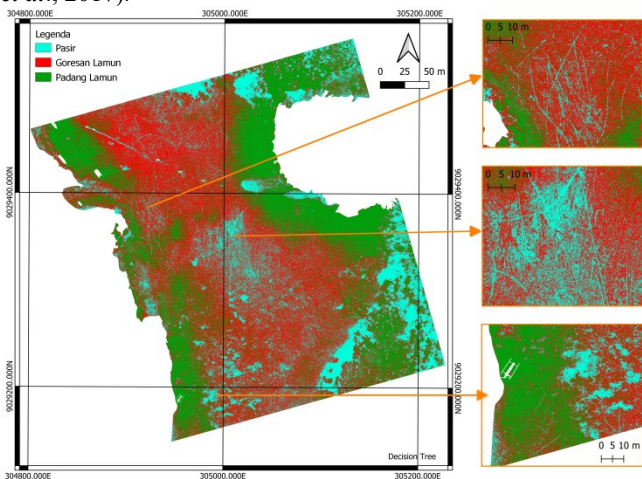
Gambar 10. Hasil Segmentasi Support Vector Machine (SVM)





Gambar 11. Hasil Segmentasi Random Forest (RF)

Hasil segmentasi algoritma (*support vector machine* (SVM), *random forest*, *decision tree* secara visual sangat sulit melihat perbedaannya tetapi pada evaluasi model akan terlihat perbedaan hasil *recall*, *precision*, *accuracy* dan *F1 score*. Segmentasi goresan kerusakan lamun sebelumnya pernah dilakukan dengan jangkauan yang lebih luas menggunakan teknik digitalisasi secara visual di layer (Karang *et al.*, 2024). Algoritma SVM, *random forest*, dan *decision tree* secara piksel belum dapat membedakan nilai piksel goresan lamun dengan pasir yang ada di sekitar lamun karena memiliki tingkat value piksel yang sama (*homogen*). Homogenitas umumnya berkaitan dengan data lokal yang ditarik dari gambar yang menunjukkan sejauh mana suatu daerah itu seragam, hal ini memiliki peran penting dalam pemisahan gambar karena hasil dari proses pemisahan akan menjadi beberapa daerah yang seragam (Rajan *et al.*, 2017).



Gambar 12. Hasil Segmentasi Decision Tree (DT)

### 3.5 Evaluasi Algoritma Machine Learning

Perhitungan *recall*, *precision*, *accuracy* dan *F1 score* model mendapatkan hasil yang bervariasi dan memiliki persentase angka 72% mendekati 74%, kemudian setelah di filtrasi menggunakan *median filter* persentase angka *recall*, *precision*, *accuracy* dan *F1 score* meningkat menjadi 76% mendekati 79% dapat dilihat pada Tabel 3.

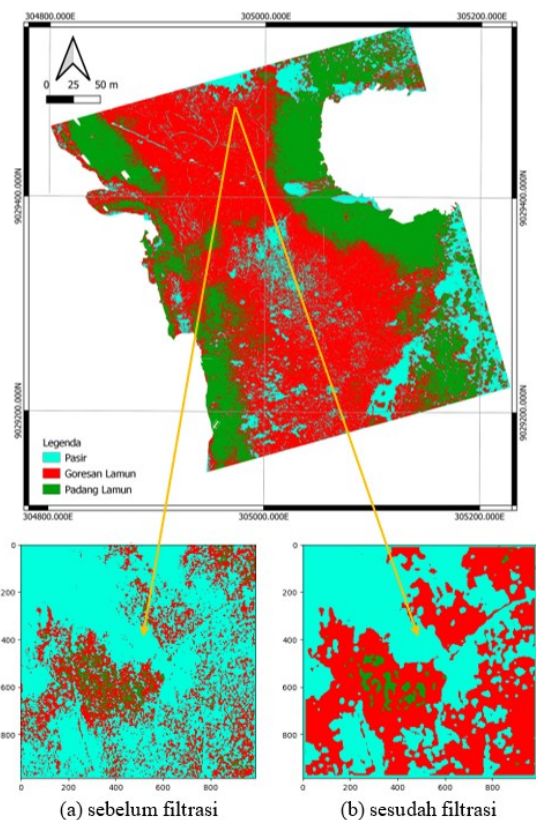
Tabel 3. Evaluasi Algoritma Machine Learning

Keterangan Algoritma	Recall	Precision	Accuracy	F1 Score
SVM w/RGB	73.73%	74.51%	73.73%	73.83%
RF w/RGB	73.09%	73.60%	73.09%	73.20%
DT w/RGB	72.88%	73.21%	72.88%	72.95%
SVM w/RGB+MedianFilter	77.19%	78.20%	77.19%	77.30%

Pada tabel 3 menunjukkan *recall*, *precision*, *accuracy* dan *F1 score* algoritma SVM lebih unggul dari pada *random forest* dan *decision tree*. Pada penelitian dengan menggunakan algoritma yang serupa juga mendapatkan hasil SVM mencapai hasil yang jauh lebih baik daripada pengklasifikasi-pengklasifikasi lainnya (Seeja & Suresh, 2019). Penelitian yang menggunakan model serupa juga dilakukan menggunakan UAV untuk pemetaan agrikultur, model SVM dan RF sangat mampu mengatasi segmentasi dari objek yang rusak pada skala yang lebih baik dibandingkan dengan kelas kelas lainnya. SVM secara konsisten lebih baik dibandingkan dengan yang diperoleh dari segmentasi lainnya (Li *et al.*, 2016).

### 3.6 Median Filter

Hasil filtrasi gambar *median filter* pada algoritma terbaik menggunakan nilai  $k=19$  dan dijalankan menggunakan *python* pada aplikasi *visual studio code*. Gambar 13 merupakan hasil *median filter* setelah dilakukan segmentasi.



Gambar 13. Hasil median filter setelah segmentasi SVM

Adapun hasil *training* masing-masing algoritma *machine learning* memiliki tingkat ketelitian algoritma (*classification report*) yang disajikan pada tabel 4 untuk algoritma SVM w/RGB, tabel 5 untuk algoritma SVM w/RGB+MedianFilter, tabel 6 untuk algoritma RF, tabel 7 untuk algoritma RF w/RGB+MedianFilter, tabel 8 untuk algoritma DT w/RGB dan tabel 9 untuk algoritma DT w/RGB+MedianFilter

RF w/RGB+MedianFilter	76.45%	77.40%	76.45%	76.59%
DT w/RGB+MedianFilter	76.35%	77.01%	76.35%	76.40%

Tabel 4. Classification report SVM w/RGB

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<b>Pasir</b>	0.82	0.68	0.75	5192
<b>Goresan Lamun</b>	0.81	0.86	0.83	5222
<b>Lamun</b>	0.61	0.67	0.64	5216
<i>Accuracy</i>			0.74	15630
<i>Macro avg</i>	0.75	0.74	0.74	15630
<i>Weighted avg</i>	0.75	0.74	0.74	15630

Tabel 5. Classification report SVM w/RGB+MedianFilter

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<b>Pasir</b>	0.87	0.71	0.78	5192
<b>Goresan Lamun</b>	0.83	0.88	0.85	5222
<b>Lamun</b>	0.65	0.72	0.68	5216
<i>Accuracy</i>			0.77	15630
<i>Macro avg</i>	0.78	0.77	0.77	15630
<i>Weighted avg</i>	0.78	0.77	0.77	15630

Tabel 6. Classification report RF w/RGB

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<b>Pasir</b>	0.79	0.70	0.74	5192
<b>Goresan Lamun</b>	0.81	0.84	0.83	5222
<b>Lamun</b>	0.60	0.65	0.62	5216
<i>Accuracy</i>			0.73	15630
<i>Macro avg</i>	0.74	0.73	0.73	15630
<i>Weighted avg</i>	0.74	0.73	0.73	15630

Tabel 7. Classification report RF w/RGB+MedianFilter

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<b>Pasir</b>	0.85	0.71	0.77	5192
<b>Goresan Lamun</b>	0.83	0.87	0.85	5222
<b>Lamun</b>	0.64	0.71	0.67	5216
<i>Accuracy</i>			0.76	15630
<i>Macro avg</i>	0.77	0.76	0.76	15630
<i>Weighted avg</i>	0.77	0.76	0.76	15630

Tabel 8. Classification report DT w/RGB

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<b>Pasir</b>	0.78	0.70	0.74	5192
<b>Goresan Lamun</b>	0.81	0.84	0.83	5222
<b>Lamun</b>	0.60	0.64	0.62	5216
<i>Accuracy</i>			0.73	15630
<i>Macro avg</i>	0.73	0.73	0.73	15630
<i>Weighted avg</i>	0.73	0.73	0.73	15630

Tabel 9. Classification report DT w/RGB+MedianFilter

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
<b>Pasir</b>	0.85	0.71	0.77	5192
<b>Goresan Lamun</b>	0.83	0.88	0.85	5222
<b>Lamun</b>	0.64	0.70	0.67	5216
<i>Accuracy</i>			0.76	15630
<i>Macro avg</i>	0.77	0.76	0.76	15630
<i>Weighted avg</i>	0.77	0.76	0.76	15630

### 3.7 Perhitungan Goresan Lamun

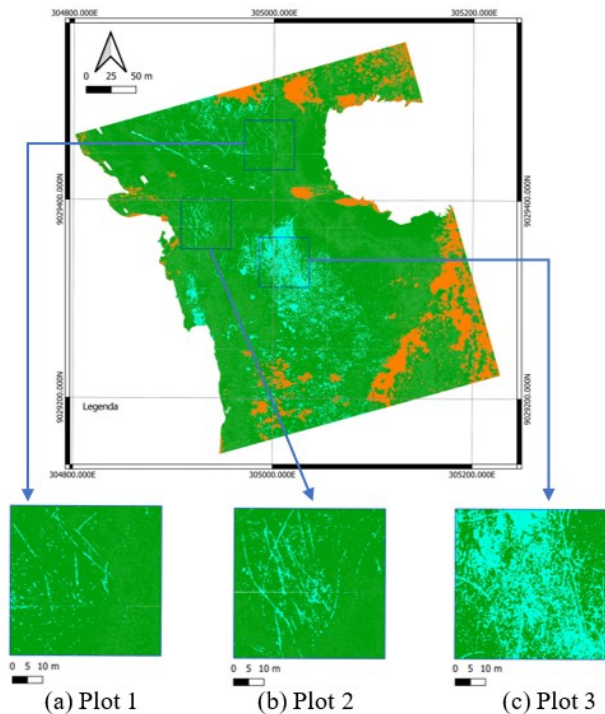
Sebelum dilakukan perhitungan goresan lamun, dilakukan perbaikan pada kelas goresan lamun dan pasir. Hasil segmentasi dan median filter dikonversikan ke format shp yang kemudian diperbaiki pada file shp tersebut pada aplikasi QGIS. Kelas pasir dilakukan

beberapa pemisahan poligon yang sebenarnya kelas goresan lamun tetapi terdeteksi pasir dan kelas goresan lamun tetapi terdeteksi lamun. Perbaikan yang dilakukan mengacu pada hasil gambar UAV awal sebelum dilakukan *median filter*. Total area pemetaan UAV adalah 122500meter persegi, perhitungan goresan lamun di area poligon lamun menggunakan rumus *percent scarring* oleh (Sargent *et al.*, 1995) berdasarkan hasil segmentasi SVM disajikan pada Tabel 3.

**Tabel 10** Hasil perhitungan polygon lamun

Poligon	Luas Area(m <sup>2</sup> )	Persentase (%)
Pasir	9856.544	10.783
Goresan lamun	5333.708	5.835
Lamun	76219.249	83.382
Total Area Lamun	91409.501	100

Goresan lamun menunjukkan hasil 5.835%, dimana nilai tersebut merupakan nilai terendah dibandingkan dengan data poligon pasir dan lamun. Selain itu, perhitungan goresan lamun juga dilakukan dengan memilih area secara *purposive* dengan cakupan area 50x50 meter dimana area lamun yang dipilih mewakili *light, morderate, severe scarring* dan area tersebut dapat termuat dalam cakupan area yang telah ditentukan. Area tersebut disajikan pada Gambar 13. Jumlah yang plot dipilih hanya sebagai gambaran jikalau penelitian ini di lakukan pada ukuran area yang lebih kecil. Hasil perhitungan plot 1, 2, dan 3 dijabarkan pada Tabel 11. Selain hasil pemetaan UAV, penulis melakukan wawancara dengan pihak wahana *watersport* dan hasil yang didapatkan bahwa aktivitas di Pantai Terora didominasi oleh wahana *watersport* seperti *banana boat, jet ski dan rolling donut*. Hasil wawancara ini dapat memberikan




**Gambar 14.** Peta plot yang ditentukan

Penilaian kerusakan lamun mendapatkan hasil 5.835% dari total area lamun. Luas meter persegi dari total area perairan yang dilakukan segmentasi adalah 91409.501meter persegi dari total area yang dipetakan oleh UAV yaitu (350m x 350m) atau 122.500meter persegi. Goresan lamun 5.835% termasuk kedalam kategori *moderate scarring*. Bekas goresan sedang (*moderate scarring*) didefinisikan sebagai 5-20%(Sargent *et al.*, 1995). Goresan lamun yang terjadi di Pantai Terora diduga adanya aktivitas *watersport* dikarenakan memiliki bentuk garis putus-putus dan mengelompok di area tertentu.

Hal ini merujuk pada (Karang *et al.*, 2024) yang menjelaskan bahwa agen *watersport* cenderung menggunakan

Gambaran dan pendugaan goresan lamun yang ada di Pantai terora di sebabkan oleh wahana *watersport*. Hasil penelitian ini berupa peta goresan lamun di Pantai Terora pada Gambar 15.



**Gambar 15.** Peta Goresan Lamun Di Pantai Terora

area tertentu untuk setiap olahraga, dan hal ini menyebabkan penurunan lamun lebih banyak terjadi di area tersebut. Berdasarkan kerusakan lamunya penelitian ini menyarankan agar area untuk wisata *watersport* diputuskan dengan mempertimbangkan pemulihan dan daya tahan lamun, serta pasang surut permukaan laut.

#### 4. Kesimpulan

Bedasarkan penelitian ini dapat disimpulkan bahwa:

1. Algoritma *machine learning SVM* memiliki akurasi *F1 Score* yang lebih tinggi dibandingkan dengan algoritma *Random Forest* dan *Decision Trees* dalam mendeteksi goresan lamun. Hal ini menunjukkan bahwa SVM merupakan pilihan baik untuk segmentasi goresan lamun berdasarkan performa *recall, precission, accuracy* dan *F1 score*.
2. Tingkat kerusakan goresan lamun di Pantai Terora dihitung menggunakan rumus *absolute percent* mendapatkan hasil 5.835% termasuk kedalam kategori *moderate scarring*. Hasil dari penelitian ini berupa peta goresan lamun yang dapat memberikan gambaran kerusakan lamun di Pantai Terora sehingga dapat digunakan sebagai dasar untuk pengambilan Keputusan terkait pemulihan atau perlindungan ekosistem lamun.

#### Ucapan Terimakasih

Penulis berterima kasih kepada kakak- kakak dan teman-teman *Centre for Remote Sensing and Ocean Sciences (CRoSOS)* dan teman-teman Ilmu Kelautan atas bantuan yang telah diberikan dalam menyelesaikan penelitian ini.



## DAFTAR PUSTAKA

- Firmansyah, S., Gaol, J., & 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. <https://doi.org/10.29244/jpsl.9.3.746-757>
- George, G., Oommen, R. M., Shelly, S., Philipose, S. S., & Varghese, A. M. (2018). A Survey on Various Median Filtering Techniques For Removal of Impulse Noise From Digital Image. *Proc. IEEE Conference on Emerging Devices and Smart Systems, ICEDSS 2018, March*, 235–238. <https://doi.org/10.1109/ICEDSS.2018.8544273>
- Graha, Y. I., Arthana, I. W., & Karang, I. W. G. A. (2016). Simpanan Karbon Padang Lamun di Kawasan Pantai Sanur, Kota Denpasar. *Ecotrophic*, 10(1), 46–53.
- Hartini, H., & Lestarini, Y. (2019). Pemetaan Padang Lamun Sebagai Penunjang Ekowisata Di Kabupaten Lombok Timur. *Jurnal Biologi Tropis*, 19(1), 1–7. <https://doi.org/10.29303/jbt.v19i1.927>
- Hoque, M. R. U., Islam, K. A., Perez, D., Hill, V., Schaeffer, B., Zimmerman, R., & Li, J. (2018). Seagrass Propeller Scar Detection using Deep Convolutional Neural Network. *2018 9th IEEE Annual Ubiquitous Computing, Electronics and Mobile Communication Conference, UEMCON 2018, November*, 659–665. <https://doi.org/10.1109/UEMCON.2018.8796636>
- Karang, I. W. G. A., Pravitha, N. L. P. R., Nuarsa, I. W., & Wicaksono, P. (2024). *High-Resolution Seagrass Species Mapping and Propeller Scars Detection in Tanjung Bena, Bali through UAV Imagery* (pp. 161–174). *Journal of Ecological Engineering*. <https://doi.org/10.12911/22998993/174943>
- Kim, D., Jang, H. U., Mun, S. M., Choi, S., & Lee, H. K. (2018). Median Filtered Image Restoration and Anti-Forensics Using Adversarial Networks. *IEEE Signal Processing Letters*, 25(2), 278–282. <https://doi.org/10.1109/LSP.2017.2782363>
- Kristiyanto, D. Y., Widiastuti, S., & Aryotejo, G. (2017). Pendekatan Geoprocessing pada GIS untuk Menentukan Pembangunan Infrastruktur Bisnis di Kota Semarang. *Jurnal Ilmiah KOMPUTASI*, 16(1), 1–10. <https://doi.org/http://dx.doi.org/10.32409/jikstik.16.1.2231>
- Li, M., Ma, L., Blaschke, T., Cheng, L., & Tiede, D. (2016). A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. *International Journal of Applied Earth Observation and Geoinformation*, 49, 87–98. <https://doi.org/10.1016/j.jag.2016.01.011>
- LIPI. (2017). *Status of Seagrass Meadows Indonesia 2017*.
- Liu, Y., Wang, Y., & Zhang, J. (2012). *New Machine Learning Algorithm : Random Forest*. 246–247.
- Nugroho, A. S., Witarto, A. B., & Handoko, D. (2003). Support Vector Machine. *Proceedings of the 2011 Chinese Control and Decision Conference, CCDC 2011*, 842–847. <https://doi.org/10.1109/CCDC.2011.5968300>
- Oguslu, E., Islam, K., Perez, D., Hill, V. J., Bissett, W. P., Zimmerman, R. C., & Li, J. (2018). *Remote Sensing of Environment Detection of seagrass scars using sparse coding and morphological filter*. 213(October 2016), 92–103. <https://doi.org/10.1016/j.rse.2018.05.009>
- Omary, Z., & Mtenzi, F. (2010). *Machine Learning Approach to Identifying the Dataset Threshold for the Performance Estimators in Supervised Learning*. 3(3), 314–325.
- Rajan, J. K., Shahil, D. F. D., Elakkiya, M. T., & Prasad, R. (2017). *Image Segmentation Using SVM Pixel Classification*. 3(3), 45–51.
- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). *Pemanfaatan Machine Learning dalam Berbagai Bidang : Review paper*. 5(April), 75–82.
- Santoso, B., Dharma, I. G. B. S., & Faiqoh, E. (2017). Pertumbuhan dan Produktivitas Daun Lamun *Thalassia hemprichii* (Ehrenb) Ascherson di Perairan Tanjung Bena, Bali. *Journal of Marine and Aquatic Sciences*, 4(2), 278. <https://doi.org/10.24843/jmas.2018.v4.i02.278-285>
- Sargent, F. J., Leary, T. J., Crewz, D. W., & Kruer, C. R. (1995). Scarring of Florida's Seagrasses: Assessment and Management Options. In *Florida Marine Research Institute Technical Reports* (Issue TR-1).
- Sasono, M. E. N., & Susetyo, C. (2018). Analisis Potensi Perubahan Pemanfaatan Lahan Berdasarkan Model Spasial Harga Lahan di Kecamatan Tembelang Kabupaten Jombang. *Jurnal Teknik ITS*, 7(1), 60–65. <https://doi.org/10.12962/j23373539.v7i1.25213>
- Seeja, R. D., & Suresh, A. (2019). Deep learning based skin lesion segmentation and classification of melanoma using support vector machine (SVM). *Asian Pacific Journal of Cancer Prevention*, 20(5), 1555–1561. <https://doi.org/10.31557/APJCP.2019.20.5.1555>
- Sodik, F., Dwi, B., & Kharisudin, I. (2020). *Perbandingan Metode Klasifikasi Supervised Learning pada Data Bank Customers Menggunakan Python*. 3, 689–694.
- Su, J., Coombes, M., Liu, C., Zhu, Y., Song, X., Fang, S., Guo, L., & Chen, W. H. (2020). Machine learning-based crop drought mapping system by UAV remote sensing RGB imagery. *Unmanned Systems*, 8(1), 71–83. <https://doi.org/10.1142/S2301385020500053>
- Tatsumi, K., Yamashiki, Y., Canales Torres, M. A., & Taibe, C. L. R. (2015). Crop classification of upland fields using Random forest of time-series Landsat 7 ETM+ data. *Computers and Electronics in Agriculture*, 115, 171–179. <https://doi.org/10.1016/j.compag.2015.05.001>
- Triscowati, D. W., Buana, W. P., & Marsuhandi, A. H. (2021). Mapping Corn Land Potential Using Satellite Imagery and Random Forest on Cloud computing Google Earth Engine. *Seminar Nasional Official Statistics*, 2021(1), 1001–1011. <https://prosiding.stis.ac.id/index.php/semnasoffstat/article/view/889>
- Trisiawan, I. K., Supegina, F., & Attamimi, S. (2022). *Penerapan Multi-Label Image Classification Menggunakan Metode Convolutional Neural Network (CNN) Untuk Sortir Botol Minuman*. 13(01), 48–54. <https://doi.org/10.22441/jte.2022.v13i1.009>

Wijantara, I. G. A., Karang, I. W. G. A., & Indrawan, G. S. (2023). Pemetaan Distribusi Lamun di Selat Ceningan Menggunakan Drone Komersial. *Journal of Marine and Aquatic Sciences*, 8(2), 279. <https://doi.org/10.24843/jmas.2022.v08.i02.p12>

*JMRT, Volume 8 No 1 Tahun 2025, Halaman: 94-103*

Yang, M. Der, Tseng, H. H., Hsu, Y. C., & Tsai, H. P. (2020). Semantic segmentation using deep learning with vegetation indices for rice lodging identification in multi-date UAV visible images. *Remote Sensing*, 12(4). <https://doi.org/10.3390/rs12040633>

Zurba, N. (2018). Pengenalan Padang Lamun Suatu Ekosistem yang Terlupakan. In *Unimal Press*.