

Pemetaan Lamun dengan Teknologi Berbasis Machine Learning pada Kawasan Pantai Sanur

Dewa Febio Pujawan^a, I Wayan Nuarsa^a, I Wayan Gede Astawa Karang^{a*}

^aProgram Studi Ilmu Kelautan, Fakultas Kelautan dan Perikanan, Universitas Udayana, Bali, Indonesia

*Corresponding author, email: gedekarang@unud.ac.id

ARTICLE INFO

Article history:

Received: 9 Agustus 2023

Received in revised form: 29 September 2023

Accepted: 28 Desember 2023

Available online: 31 Oktober 2024

Keywords:

Seagrass mapping,

Random Forest,

SVM,

Naïve Bayes

Kata kunci:

Pemetaan lamun,

Random Forest,

Support Vector Machine,

Naïve Bayes

ABSTRACT

Mapping seagrass is essential for understanding the condition of seagrass beds along the coast. Utilizing remote sensing and machine learning techniques can enhance the quality of seagrass observations. This study aimed to analyze changes in the extent of seagrass coverage in the Sanur Beach area from 2019 to 2022 using Sentinel-2A satellite imagery and machine learning methods. The data used comprise field measurements and satellite imagery. Field data collection involved employing random sampling and establishing transect lines from Mertasari Beach to Segara Ayu Beach. The research methods used include Random Forest, Support Vector Machine (SVM), and Naïve Bayes classifiers, with model evaluation performed using a confusion matrix and accuracy assessment utilizing Cohen's Kappa. The results show a map of seagrass coverage changes, with the SVM method being identified as the best-performing classifier after accuracy testing. The SVM model achieved the highest average accuracy among the three methods, with an accuracy of 84.5%. The map of seagrass coverage changes indicates that the highest seagrass coverage was recorded in 2021 (268.52 ha), followed by 2019 (249.06 ha), 2020 (248.73 ha), and 2022 (240.49 ha). Future studies could consider employing classifications on coastal ecosystems with a broader range of classes for better ecosystem characterization.

ABSTRAK

Pemetaan lamun penting dilakukan untuk mengetahui kondisi padang lamun di pesisir. Pemanfaatan penginderaan jauh dan *machine learning* berguna untuk meningkatkan kualitas pengamatan lamun. Tujuan penelitian ini adalah untuk mengetahui perubahan luasan lamun di kawasan Pantai Sanur dari tahun 2019 sampai tahun 2022 dengan menggunakan citra satelit Sentinel-2A dan menggunakan *machine learning*. Data yang digunakan adalah data lapangan dan data citra. Pengambilan data lapangan dilakukan dengan *random sampling* dan transek garis dari Pantai Mertasari sampai Pantai Segara Ayu. Metode penelitian menggunakan klasifikasi *Random Forest*, *Support Vector Machine* (SVM), *Naïve Bayes* dengan evaluasi model menggunakan *confusion matrix* dan uji akurasi menggunakan *cohen kappa*. Hasil yang didapat berupa peta perubahan luasan lamun dengan menggunakan metode SVM yang merupakan metode terbaik setelah dilakukan uji akurasi, dimana SVM memiliki nilai rata – rata paling tinggi dibandingkan dengan dua metode lainnya sebesar 84,5%. Peta perubahan luasan lamun menunjukkan bahwa luasan lamun tertinggi diperoleh pada tahun 2021 (268,52 ha), tahun 2019 (249,06 ha), tahun 2020 (248,73 ha), dan tahun 2022 (240,49 ha). Untuk kedepannya diharapkan penelitian ini dapat melakukan klasifikasi terhadap ekosistem pesisir sehingga kelas yang digunakan lebih bervariasi.

2024 JMRT. All rights reserved.

1. Pendahuluan

Keragaman lamun yang ada di Indonesia terdapat 15 spesies dari 60 spesies lamun di dunia (Sjafrie *et al.*, 2018). Potensi yang besar pada padang lamun belum didukung dengan

pengelolaan yang baik. Pembangunan dan aktivitas yang tinggi oleh masyarakat di pesisir menyebabkan padang lamun rentan terhadap kerusakan. Selain itu, perubahan lingkungan juga dapat mempengaruhi pertumbuhan yang berdampak pada perubahan luasan lamun. Berdasarkan penelitian yang

dilakukan oleh Duarte *et al* (2008) terjadi pengurangan luasan lamun dunia rata-rata 2 - 5% setiap tahun. Selain pengurangan luasan, berdasarkan penelitian Pusat Penelitian Oseanografi Lembaga Ilmu Pengetahuan Indonesia (P2O-LIPI) melalui proyek *Coral Reef Rehabilitation and Management Program - Coral Triangle Initiative* (COREMAP-CTI) selama kurun waktu 2015-2017 (Sjafrie *et al.*, 2018).

Pantai di Kawasan Sanur merupakan daerah tujuan wisatawan sehingga banyak aktivitas yang dilakukan yang dapat menjadi ancaman bagi ekosistem Lamun. Berdasarkan penelitian yang dilakukan oleh Graha pada tahun 2015 lamun di Pantai Sanur tumbuh di sepanjang pesisir pantai sekitar 7 km yang terbentang dari Pantai Mertasari sampai Pantai Sanur dengan delapan spesies lamun yang ditemukan. Berdasarkan penelitian yang dilakukan oleh Pamungkas pada tahun 2016 dimana luasan lamun di kawasan Pantai Sanur pada tahun 2014 berkisar 354.51 ha dan pada tahun 2015 berkisar 472.58 ha dengan melakukan pengamatan menggunakan citra satelit Landsat 8.

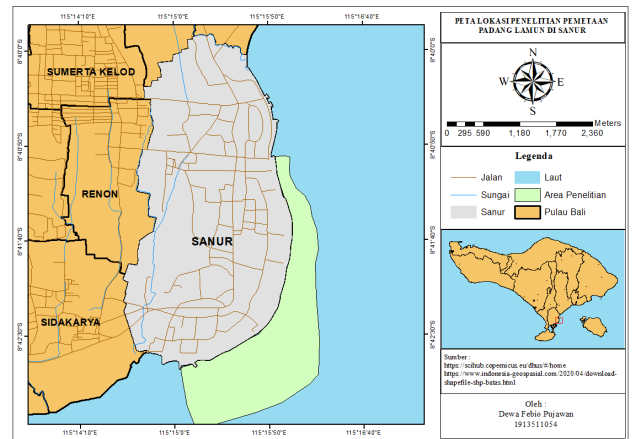
Teknologi penginderaan jauh dapat digunakan untuk pemetaan dan pemantauan padang lamun secara efektif dan efisien karena dapat menghasilkan informasi secara spasial dan temporal. Data penginderaan jauh mampu dalam menyediakan informasi luasan, persentase tutupan, spesies, biomasa, dan perubahan lamun (Fauzan *et al.*, 2017; Koedsin *et al.*, 2016). Pengamatan penginderaan jarak jauh menggunakan citra Sentinel-2A yang memiliki resolusi 10 meter dan dapat diunduh secara gratis (Hidayah, 2023). Berdasarkan penelitian yang dilakukan oleh Pramesti pada tahun 2019 terkait pemanfaatan citra satelit Landsat 8 dan Sentinel-2A terhadap pemetaan lamun di Pulau Pari, Kepulauan Seribu mendapati hasil bahwa pemetaan lamun dengan menggunakan citra satelit Sentinel-2A lebih baik dibandingkan dengan Landsat 8. Sehingga penggunaan citra satelit Sentinel-2A memungkinkan untuk melakukan pengamatan terhadap lamun di kawasan Pantai Sanur.

Pemetaan lamun menggunakan machine learning sudah populer sehingga penambahan beberapa metode *machine learning* pada proses pemetaan sangat penting untuk dilakukan agar dapat mengetahui tingkat keakurasian dari masing – masing metode. Adapun metode yang pernah digunakan untuk melakukan pemetaan lamun seperti *Random Forest*, dan *Decision tree* pada penelitian yang pernah dilakukan oleh Ginting pada tahun 2021 yang dilakukan di Nusa Lembongan dan penelitian lainnya yang dilakukan oleh Ilyas pada tahun 2020 menggunakan machine learning seperti SVM, *Naïve Bayes*, *K-Nearest Neighbour* (KNN), dan *Decision Tree* terhadap pemetaan ekosistem lamun di Sulawesi Selatan. Penggunaan machine learning terlihat lebih efektif untuk melakukan pemetaan jika dilihat dari penelitian yang pernah dilakukan sebelumnya, sehingga, penelitian ini bertujuan untuk mengetahui perubahan luasan lamun pada empat tahun yaitu pada tahun 2019, 2020, 2021, 2022 di Pantai kawasan Sanur dengan menggunakan metode terbaik dari tiga metode *machine learning*, yaitu *Random forest*, SVM, dan *Naïve Bayes*.

2. Metodologi

2.1 Waktu dan Tempat Penelitian

Penelitian ini berlokasi di Pantai daerah Sanur, Denpasar. Tepatnya dari Pantai Mertasari sampai Pantai Segara Ayu pada titik koordinat 8° 42' 47.462" LS hingga 8° 40' 52.936" LS dan 115° 15' 3.113" BT hingga 115° 16' 7.470" BT, dengan jarak kurang lebih empat kilometer. Pengambilan data akan dilakukan pada bulan September sampai Oktober tahun 2022. Peta lokasi penelitian dapat dilihat pada Gambar 1.




Gambar 2. Peta Lokasi Penelitian

2.2 Metode Penelitian

2.2.1 Pengambilan Data Lapangan

Metode pengambilan data lapangan yang dilakukan di Pantai kawasan Sanur yaitu dengan cara *random sampling* dan transek garis. *Random sampling* adalah suatu metode yang digunakan untuk mengambil data dengan cara acak (McLeod, 2019). Metode *random sampling* digunakan untuk menentukan labeling data yang dilakukan dengan *ground check* untuk mengambil koordinat tutupan lamun yang diambil sekitar 200 titik seperti pada (Gambar 2). Pengambilan titik koordinat dilakukan mulai dari Pantai Mertasari sampai Pantai Segara Ayu dengan transek garis berjarak 100 meter pada setiap titik koordinatnya, hasil dari *labeling* dimasukkan ke excel dan dijadikan *shapefile*. Untuk mendukung data yang digunakan, diperlukan data citra Sentinel-2A pada tahun 2019, 2020, 2021, dan 2022 yang diunduh secara gratis pada web.scihub.copernicus.eu.



Gambar 2. Titik Pengambilan Data Lapangan

2.2.2 Pengolahan Data

Tahapan pengolahan data pada penelitian ini meliputi pengolahan citra dengan melakukan koreksi *sun glint*, dan koreksi kolom perairan (Lyzenga). Koreksi *sun glint*, koreksi *glint* digunakan untuk memperbaiki kualitas citra dengan cara menghilangkan efek gangguan yang diakibatkan oleh pantulan sinar matahari yang mengenai gelombang laut secara tegak lurus (Hedley et al., 2005). *Band* yang digunakan pada saat koreksi *sun glint* adalah *Band* 2, 3, 4, 5, 6, 7, 8, 8a, 11, 12. Untuk *Band* 1, 9, dan 10 tidak digunakan karena resolusinya rendah (Marlina, 2022). Persamaan 1 digunakan untuk koreksi *sun glint*.

$$R_i'' = R_i - b \times (RNIR - MinNIR) \tag{1}$$

$$b = \frac{(b_i - b_j)}{(b_i + b_j)}$$

Keterangan :

- R_i'' : Nilai R setelah koreksi
- R_i : Nilai reflektan pada masing-masing *band* (*band* biru-*sunlint*, *band* hijau-*sunlint*, dan *band* merah-*sunlint*)
- b : Nilai *regression slope* hasil *statistic*
- RNIR : Nilai reflektan pada *band* inframerah dekat
- MinNIR : Nilai minimum reflektan *band* inframerah dekat dari seluruh sampel yang dipilih
- b_i : Nilai total reflektan pada masing – masing *band* RGB
- b_j : Nilai total reflektan *band* NIR

Pengolahan data dilanjutkan dengan koreksi kolom air bertujuan untuk mendapatkan informasi objek dibawah permukaan air yang sudah bebas dari pengrauh kedalaman air, kekeruhan, dan pergerakan muka air dengan membuat citra baru dari *Depth Invariant Index* (DII) (Lyzenga, 1981) (persamaan 2).

$$Y = (\ln L_i) + \left(\frac{k_i}{k_j} \times \ln L_j\right)$$

$$\frac{k_i}{k_j} = a + \sqrt{a^2 + 1}$$

$$a = \frac{(\sigma_{ii} - \sigma_{jj})}{2 \times \sigma_{ij}} \tag{2}$$

Keterangan :

- Y : Algoritma *Lyzenga*
- L_i : Nilai reflektan spektrum i (saluran dengan panjang gelombang lebih pendek)
- L_j : Nilai reflektan spektrum j (saluran dengan panjang gelombang lebih panjang)
- k_i/k_j : Rasio koefisien atenuasi band i dan j
- a : Nilai komponen utama
- σ_{ii} : Ragam atau varian band i
- σ_{jj} : Ragam atau varian band j
- σ_{ij} : Peragam atau covarian band i dan j

Pengolahan data setelah mendapatkan hasil *lyzenga* adalah memproses menggunakan metode *machine learning*, ada tiga metode *machine learning* yang digunakan, yaitu *Random Forest*, SVM, dan *Naïve Bayes* yang dilakukan dengan menggunakan *software Google Colaboratory*. Model *Random forest* sebenarnya merupakan gabungan dari beberapa *Decision tree*, dimana *Decision tree* (pohon keputusan) merupakan algoritma yang digunakan untuk klasifikasi dengan menggunakan pohon keputusan. Pohon keputusan bekerja dengan membagi data menjadi subset berdasarkan kelas-kelas tertentu dan mengambil keputusan pada setiap simpul berdasarkan hasil uji pada kelas tersebut. Pohon keputusan dihitung berdasarkan indeks gini (persamaan 3) (Amaliah, 2022).

$$Gini(D) = 1 - \sum_{i=1}^n (P_i)^2 \tag{3}$$

Keterangan :

- Gini(D) : Indeks gini untuk dataset (D)
- n : Jumlah kelas
- P_i : Proporsi data yang masuk pada kelas tertentu di dataset (D)

Pada SVM adalah sebuah algoritma pembelajaran mesin yang dapat digunakan untuk membangun model klasifikasi atau regresi. Model SVM menghasilkan sebuah fungsi pemetaan dari data input ke label output, yang dapat digunakan untuk memprediksi label untuk data baru. SVM untuk kasus klasifikasi dengan dua kelas dihitung dengan persamaan 4 (Lukmana, 2019).

$$f(x) = \text{sign}(w^T x + b) \tag{4}$$

Keterangan :

- x : Vektor fitur data input
- w : Vektor bobot yang diperoleh dari proses pelatihan model SVM
- w^T : *Tranpose* vektor bobot w

- b : Bias (offset) yang juga diperoleh dari proses pelatihan model SVM
- f(x) : Fungsi pemetaan yang menghasilkan label kelas untuk data input x
- sign() : Fungsi tanda yang menghasilkan nilai 1 jika argumen positif, dan -1 jika argumen negatif

Pada *Naive Bayes* sebuah algoritma klasifikasi probabilistik yang berdasarkan pada teorema *Bayes*. Algoritma ini menggunakan probabilitas sebagai dasar untuk memprediksi label kelas dari suatu data input. Dalam algoritma *Naive Bayes*, diasumsikan bahwa setiap fitur pada data input adalah independen secara bersyarat terhadap kelasnya. Hal ini disebut dengan asumsi naive (sederhana) (persamaan 5) (Rohmawati, 2021) :

$$P(y|x) = P(x|y) \cdot \frac{P(y)}{P(x)}$$

$$P(x|y) = P(x_1|y) * P(x_2|y) * \dots * P(x_n|y) \quad (5)$$

Keterangan :

- P(y|x) : Probabilitas kelas y, jika diberikan data input x
- P(x|y) : Probabilitas data input x, jika diberikan kelas y
- P(y) : Probabilitas prior kelas y
- P(x) : Probabilitas data input x
- P(x₁|y), P(x₂|y), ..., P(x_n|y) : Probabilitas setiap fitur pada data input, jika diberikan kelas y

2.3 Analisis Data

2.3.1 Evaluasi Model dengan Confusion Matrix

Evaluasi model dengan *Confusion matrix* dilakukan untuk mengetahui evaluasi kinerja metode *machine learning* yang digunakan, seperti *Random Forest*, *SVM*, dan *Naive Bayes* yang digunakan untuk melakukan klasifikasi perubahan luasan lamun dari tahun 2019 sampai tahun 2022. *Confusion matrix* merupakan tabel yang menampilkan klasifikasi jumlah data uji yang benar (True) dan jumlah data uji yang salah (False) (Nugroho, 2019). Contoh *confusion matrix* untuk klasifikasi biner seperti pada Gambar 3.

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) Type I Error
	0 (Negative)	FN (False Negative) Type II Error	TN (True Negative)

Gambar 3. Confusion Matrix

2.3.2 Uji Akurasi Kappa

Setelah melakukan evaluasi model, dilanjutkan dengan melakukan uji akurasi Kappa yang dilakukan dengan tujuan untuk mengetahui akurasi hasil klasifikasi dengan tiga metode *machine learning* yang digunakan. Akurasi Kappa adalah persentase akurasi yang menggunakan semua elemen matrik. Nilai akurasi yang dapat diterima untuk pemetaan habitat dasar perairan laut dangkal adalah sebesar $\geq 60\%$ (LIPI, 2014). Algoritma dari akurasi Kappa ini ditampilkan pada persamaan 6.

$$K = \frac{(P_a - P_e)}{(1 - P_e)} \quad (6)$$

Keterangan :

- K : Koefisien *Cohen Kappa*
- P_a ; Proporsi kesepakatan teramati
- P_e : Proporsi kesepakatan harapan
- 1 : Konstanta

3. Hasil dan Pembahasan

3.1 Hasil Komposit Citra Sentinel-2A

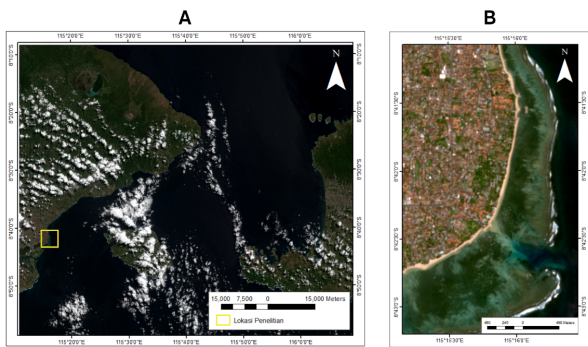
Komposit citra dilakukan pada citra Sentinel-2A yang diunduh melalui website Copernicus. Setelah data citra Sentinel-2A diunduh, dilanjutkan dengan melakukan komposit citra menggunakan *Band 4-3-2* yang merupakan *Band* untuk *Natural Color*. Komposit citra dilakukan pada aplikasi SNAP dengan hasil seperti pada (Gambar 4).



Gambar 4. Komposit Citra Sentinel-2A Tahun 2022

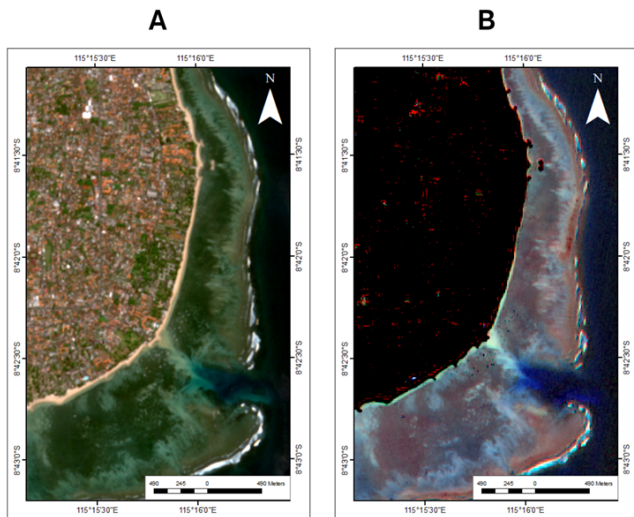
3.2 Hasil Pre Processing

Pada *preprocessing* dilakukan subset dan koreksi *sun glint* pada citra Sentinel-2A. Subsetting dilakukan untuk memperkecil citra agar lebih spesifik daerah yang ingin diteliti, seperti pada (Gambar 5) yang merupakan hasil dari subset citra.



Gambar 5. Subset Citra Sentinel-2A Tahun 2022. A : Sebelum dilakukan subset, B : Setelah dilakukan subset

Setelah dilakukan subset pada citra, dilanjutkan dengan melakukan koreksi *sun glint* yang bertujuan untuk mengoreksi atau mengurangi pantulan sinar matahari yang menimbulkan bias pada kolom perairan sehingga bisa menyulitkan dalam pengamatan objek di kolom perairan, seperti pada (Gambar 6) yang merupakan hasil dari koreksi *sun glint*.




Gambar 6. *Sun glint* Citra Sentinel-2A Tahun 2022. A : Sebelum dilakukan koreksi Sunglint, B : Setelah dilakukan koreksi *Sun glint*

3.3 Processing Citra

3.3.1 Lyzenga

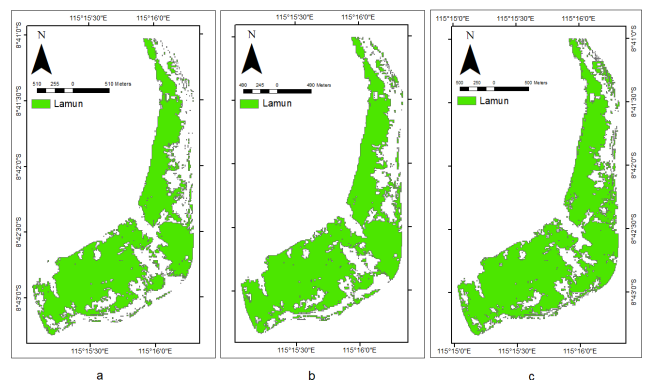
Pada processing citra dilakukan setelah mendapatkan hasil dari preprocessing, dimana processing citra melakukan koreksi kolom perairan atau *lyzenga*. *Lyzenga* merupakan koreksi untuk menghilangkan efek pantulan balik atmosfer pada citra yang diambil diatas permukaan air sehingga dapat meningkatkan visibilitas objek yang berada dibawah permukaan air seperti hasil pada (Gambar 7).



Gambar 7. Hasil *lyzenga* Citra Sentinel-2A Tahun 2022. A : Sebelum dilakukan koreksi, B : Setelah dilakukan koreksi

3.3.2 Klasifikasi Citra


Setelah dilakukan koreksi *lyzenga*, dilanjutkan dengan melakukan klasifikasi menggunakan *machine learning*, dimana *machine learning* yang digunakan ada tiga, yaitu *Random Forest*, *SVM* dan *Naïve Bayes* seperti pada (Gambar 8).




Gambar 8. Klasifikasi Lamun pada tahun 2022 dengan a. *Random Forest*, b. *SVM*, c. *Naïve Bayes*

3.3.3 Evaluasi Model


Hasil dari evaluasi model dengan *Confusion matrix* pada masing – masing metode memiliki akurasi yang berbeda, seperti *Random forest* dapat dilihat pada Gambar 9. Untuk *SVM* dapat dilihat pada Gambar 10. Untuk *Naïve Bayes* dapat dilihat pada Gambar 11.



Gambar 9. Confusion Matrix Random Forest Tahun 2022



Gambar 10. Confusion Matrix SVM Tahun 2022



Gambar 11. Confusion Matrix Naïve Bayes Tahun 2022

Berdasarkan hasil evaluasi model pada ketiga metode *machine learning* yang digunakan melalui *confusion matrix*, dari *confusion matrix* dapat diketahui seberapa akurat model membaca kelas yang sesuai seperti pada Gambar 9, Gambar 10, dan Gambar 11. Melalui gambar tersebut dapat diketahui bahwa

kesalahan dalam membaca kelas lebih banyak terdapat pada *Naïve Bayes*. Sedangkan keakuratan terbaik ada pada SVM jika dibandingkan dengan dua metode *machine learning* yang digunakan, sesuai dengan teori menurut Prabowo pada tahun 2018 dan Gunawan pada tahun 2020 dalam penelitiannya penggunaan SVM memiliki nilai akurasi lebih tinggi.

3.3.4 Uji Akurasi

Pemetaan lamun pada penelitian ini menggunakan tiga metode *machine learning*, dimana metode yang digunakan adalah *Random Forest*, SVM dan *Naïve Bayes*. Dari ketiga metode tersebut memiliki hasil pemetaan yang berbeda dengan akurasi yang beragam. Akurasi yang didapat dalam menggunakan metode *Random Forest*, SVM, dan *Naïve Bayes* tersebut dengan menggunakan *confusion matrix* dan akurasi kappa.

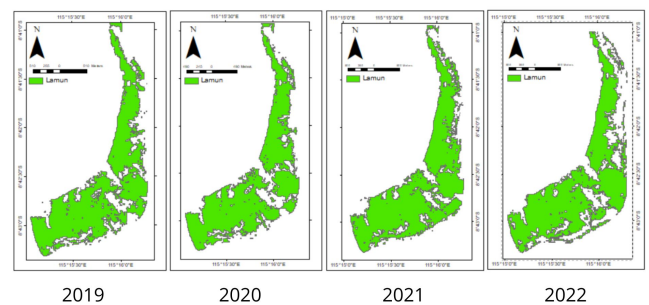
Tabel 1. Uji Akurasi Cohen Kappa (%)

Akurasi Kappa	<i>Random Forest</i>	SVM	<i>Naïve Bayes</i>
2019	86	83	70
2020	68	79	70
2021	78	93	75
2022	77	83	70

Berdasarkan Tabel 1 terlihat bahwa akurasi tertinggi pada tahun 2019 sebesar 93% pada *Random Forest*, pada tahun 2020 dengan akurasi tertinggi sebesar 79% pada SVM, pada tahun 2021 dengan akurasi tertinggi sebesar 93% pada SVM dan pada tahun 2022 nilai akurasi tertinggi sebesar 83% pada SVM. Dari ketiga metode yang digunakan, rata – rata akurasi tertinggi ada pada metode SVM dengan nilai rata – rata sebesar 84,5%.

3.3.4 Pemetaan Lamun dengan SVM

Setelah dilakukan uji akurasi, dapat dilihat bahwa nilai akurasi dengan rata – rata tertinggi ada pada SVM hal tersebut juga sama dengan pernyataan penelitian sebelumnya, sehingga langkah berikut adalah menampilkan hasil dari pemetaan lamun dengan SVM pada tahun 2019, 2020, dan 2021 seperti pada Gambar 12.

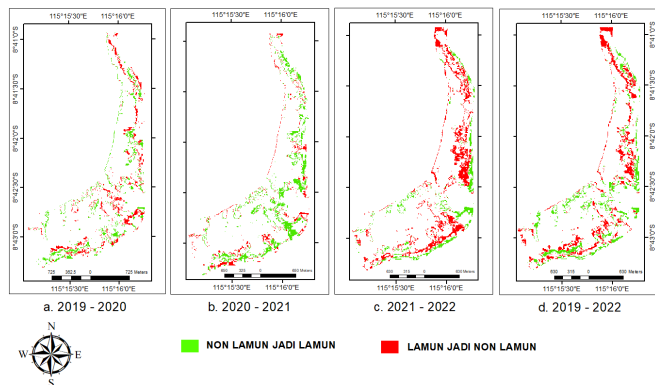


Gambar 12. Pemetaan Lamun dengan SVM

3.3.5 Perubahan Luasan Lamun

Setelah dilakukan pemetaan lamun dengan SVM, terlihat perbandingan luasan lamun pada pantai sanur dari tahun 2019, 2020, 2021, dan tahun 2022 pada (Gambar 12) tampak

perbedaan luasan yang terlihat jelas, namun masih tidak terlihat mana bagian lamun yang bertambah setiap tahun atau lamun yang berkurang setiap tahun, maka dari itu perubahan luasan lamun dapat dilihat pada Gambar 13.



Gambar 13. Perubahan Luasan Lamun a. Tahun 2020 Terhadap Luasan Lamun Tahun 2019, b. Tahun 2021 Terhadap Luasan Lamun Tahun 2020, c. Tahun 2022 Terhadap Luasan Lamun Tahun 2021, dan d. Perubahan Lamun Tahun 2022 Terhadap Lamun Tahun 2019.

Tabel 2. Perubahan Luasan Lamun

Tahun	Perubahan Luasan (ha)
2019 - 2020	-0.33
2020 - 2021	19.79
2021 - 2022	-28.03
2019 - 2022	-8.57

Pada Tabel 2 terlihat selisih perubahan luasan lamun, terlihat bahwa pada tahun 2019 – 2020 luasan lamun mengalami penurunan terhadap luasan lamun seluas 0,33 ha. Pada tahun 2020 – 2021 luasan lamun mengalami peningkatan dimana bertambah seluas 19,79 ha. Pada tahun 2021 – 2022 luasan lamun mengalami penurunan seluas 28,03 ha dan pada tahun 2019 – 2022 luasan lamu mengalami penurunan seluas 8,57 ha. Untuk tahun 2019 perubahan luasan lamun tidak dapat ditampilkan dikarenakan data pembanding merupakan tahun 2018, sedangkan pada penelitian ini hanya menggunakan tahun 2019 sampai 2022. Setelah mendapatkan hasil perubahan luasan lamun, didapati bahwa tahun 2021 merupakan tahun dimana luasan lamun paling banyak dari tahun lainnya. Berdasarkan penelitian sebelumnya yang dilakukan oleh Ihsan (2021) peningkatan luasan padang lamun pada tahun 2021 bisa dikarenakan oleh faktor alami maupun akibat pembatasan aktivitas manusia selama pandemi COVID-19. Akibat penurunan aktivitas manusia itulah kondisi lamun ikut terjaga dan semakin bertambah luasannya.

Perubahan luasan lamun dapat terjadi disebabkan oleh berbagai faktor, antara lain aktivitas manusia yang mempengaruhi keberadaan lamun tersebut. selain aktivitas manusia, kerusakan padang lamun juga diakibatkan oleh faktor alam seperti perubahan kualitas perairan tempat habitat hidupnya. Faktor lingkungan yang berpengaruh langsung bagi

kelangsungan hidup lamun diantaranya yaitu salinitas, suhu, kecerahan, dan kedalaman perairan. Sehingga, bila kualitas perairan lingkungan hidupnya mengalami perubahan, akan mengakibatkan perubahan atau bahkan kerusakan terhadap tumbuhan lamun itu sendiri (Pamungkas, 2016).

4.1 Kesimpulan

Berikut merupakan kesimpulan dari penelitian ini, sebagai berikut :

1. Hasil pemetaan dengan machine learning yang digunakan pada penelitian ini menggunakan tiga metode *machine learning*, yaitu *Random Forest*, *SVM*, dan *Naïve Bayes*. terlihat perbedaan dari ketiga *machine learning* tersebut, hal ini dapat terjadi karena ketiga metode *machine learning* yang digunakan menggunakan algoritma yang berbeda namun hasil yang dihasilkan hampir mirip satu sama lain. Ini membuktikan bahwa ketiga metode *machine learning* bisa digunakan untuk klasifikasi citra.
2. Hasil uji akurasi yang dilakukan, menunjukkan bahwa nilai akurasi tertinggi ada pada SVM, sehingga SVM memiliki akurasi yang lebih baik dibandingkan dua metode *machine learning* lainnya.
3. Berdasarkan uji akurasi yang terbaik, yaitu SVM. Kondisi perubahan luasan lamun dengan metode SVM di Pantai kawasan Sanur setelah dilakukan klasifikasi dapat disimpulkan perubahan luasan lamun meningkat pada tahun 2021 dengan total luasan lamun seluas 268.52 ha dimana ada sekitar 35.31 ha lamun yang bertambah, ada sekitar 15.52 ha lamun yang berkurang, sehingga tahun 2021 memiliki luasan lamun paling tinggi dibandingkan tahun lainnya.

4.2 Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada pihak pengelola Pantai Sanur yang telah memberikan akses untuk pengambilan data penelitian ini.

Daftar Pustaka

Amaliah, S., Nusrang, M. and Aswi, A. (2022). Penerapan Metode Random Forest Untuk Klasifikasi Varian Minuman Kopi Di Kedai Kopi Konjiwa Bantaeng. *VARIANSI: Journal of Statistics and Its application on Teaching and Research*, 4(3): 121-127.

Arthana, I.W., 2004. Jenis dan kerapatan padang lamun di pantai Sanur Bali. *Bumi Lestari Journal of Environment*, 5(2).

Astawa Karang, I. W. G. 2019. Pemetaan Habitatperairan Dangkal di Kawasan Padat Wisata Tanjung Benoa Bali menggunakan Data Remote Sensing.

Breiman, L. (2001). "Random Forests". *Machine Learning*. 45(1): 5–32. doi:1023/A:1010933404324.

Chan, J.C.W., & Paelinckx, D. (2008). Evaluation of Random Forest and Adaboost treebased ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112(6): 2999-3011.

Pramesti, C.S.B. (2019). Pemanfaatan Citra Satelit Untuk Pemetaan Persebaran Lamun di Pulau Pari, Kepulauan Seribu (Doctoral dissertation, Faculty of Fisheries and Marine Sciences).

Duarte, C.M., Dennison, W.C., Orth, R.J. & Carruthers, T.J. (2008). The Charisma of Coastal Ecosystems: Addressing the Imbalance. *Estuaries and Coasts*, 31(2): 233–238. doi: 10.1007/S12237-008- 9038-7.

Fauzan, M.A., Kumara, I.S.W., Yogyantoro, R., Suwardana, S., Fadhilah, N., Nurmalsari, I., Apriyani, S. & Wicaksono, P.

- (2017). Assessing the Capability of Sentinel-2A Data for Mapping Seagrass Percent Cover in Jerowaru, East Lombok. *Indonesian Journal of Geography*, 49(2): 195 – 203
- Ginting, D.N.B. and Arjasakusuma, S., 2021. Pemetaan Lamun Menggunakan Machine Learning Dengan Citra PlanetScope Di Nusa Lembongan. *Jurnal Kelautan Tropis*, 24(3): 323-332.
- Graha, Y.I., Arthana, I.W. dan Karang, I.W.G.A. (2015). Simpanan karbon padang lamun di kawasan pantai sanur, Kota Denpasar. *Ecotrophic*, 10(1): 46-53.
- Gunawan, D., Riana, D., Ardiansyah, D., Akbar, F. and Alfarizi, S. (2020). Komparasi Algoritma Support Vector Machine Dan Naïve Bayes Dengan Algoritma Genetika Pada Analisis Sentimen Calon Gubernur Jabar 2018-2023. V (1), 135–138.
- Haryati, R.N. and Kurniawan, D. (2021). Kondisi Ekosistem Padang Lamun di Perairan Tanjung Pisau Kabupaten Bintan. *Pena Akuatika: Jurnal Ilmiah Perikanan dan Kelautan*, 20(1).
- Hedley, J. D., Harborne, A. R., dan Mumby, P. J. (2005). Simple and robust removal of sun glint for mapping shallow water benthos. *Int. J. of Remote Sensing*, 26(10): 2107–2112.
- Hidayah, Z. and Rachman, H.A. (2023). Pemetaan kondisi hutan mangrove di kawasan pesisir Selat Madura dengan pendekatan Mangrove Health Index memanfaatkan citra satelit Sentinel-2. *Majalah Geografi Indonesia*, 37(1): 84-91.
- Koedsin, W., Intararuang, W., Ritchie, R.J. & Huete, A. (2016). An integrated field and remote sensing method for mapping seagrass species, cover, and biomass in Southern Thailand. *Remote Sensing*, 8(4): 292. doi: 10.3390/rs8040292
- Lembaga Ilmu Pengetahuan Indonesia (LIPI). (2014+). Panduan Teknis Pemetaan Habitat Dasar Perairan Laut Dangkal. Jakarta, Indonesia.
- Lukmana, D. T., Subanti, S., & Susanti, Y. (2019). Analisis Sentimen Terhadap Calon Presiden 2019 Dengan Support Vector Machine Di Twitter. In Seminar & Conference Proceedings of UMT.
- Lyzenga, D.R. (1981). Remote sensing of bottom reflectance and water attenuation parameters in shallow water using aircraft and Landsat data. *International journal of remote sensing*, 2(1): 71-82.
- Main, R., Cho, M.A., Mathieu, R., O’Kennedy, M.M., Ramoelo, A., Koch, S. (2011). An investigation into robust spectral indices for leaf chlorophyll estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(2011): 751-761.
- Marlina, D. (2022). Klasifikasi Tutupan Lahan pada Citra Sentinel-2 Kabupaten Kuningan dengan NDVI dan Algoritme Random Forest. *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, 7(1): 41-49.
- Maulana, F.F. and Rochmawati, N., 2019. Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science (JINACS)*, 1(02): 104-108.
- McLeod, S. A. (2019). Sampling methods. *Simply Psychology*. www.simplypsychology.org/sampling.html
- Nugroho, A.S., Witarto, A.B, dan Handoko, D. (2003). Support Vector Machine Teori dan Aplikasi dalam Bioinformatika. <https://asnugroho.net/papers/ikcsvm.pdf>. [Diakses pada tanggal 2 Maret 2023]
- Pamungkas, M.W.T. (2016). Studi Perubahan Habitat Padang Lamun Berdasarkan Kualitas Perairan Menggunakan Citra Landsat 8 [Thesis]. Surabaya: Fakultas Teknik Sipil dan Perencanaan, Institut Teknologi Sepuluh Nopember. 89 halaman.
- Prabowo, N. W., Siregar, V. P., & Agus, S. B. (2018). Klasifikasi habitat bentik berbasis objek dengan algoritma support vector machines dan decision tree menggunakan citra multispektral Spot-7 di Pulau Harapan dan Pulau Kelapa. *Jurnal Ilmu dan Teknologi Kelautan Tropis*, 10(1): 123-134.
- Putri, D.R., Sukmono, A. and Sudarsono, B. (2018). Analisis kombinasi citra sentinel-1a dan citra sentinel-2a untuk klasifikasi tutupan lahan (studi kasus: kabupaten demak, jawa tengah). *Jurnal Geodesi Undip*, 7(2): 85-96.
- Rohmawati, A., & Lestari, S. (2021). Pemetaan Peningkatan Kinerja UMKM Di Kabupaten Pesawaran Lampung Menggunakan Algoritma Naive Bayes. In Seminar Nasional Hasil Penelitian dan Pengabdian Masyarakat (p. 1).
- Sarinawaty, P., Idris, F. and Nugraha, A.H. (2020). Karakteristik morfometrik lamun *Enhalus acoroides* dan *Thalassia hemprichii* di Pesisir Pulau Bintan. *Journal of Marine Research*, 9(4): pp.474-484.
- Setiawan, A. (2022). CISE, Aplikasi Penghitung Stok Karbon Padang Lamun. <https://indonesia.go.id/kategori/budaya/6734/cise-aplikasi-penghitung-stok-karbon-padang-lamun?lang=1>. [Diakses Tanggal 20 September 2023]
- Sjafrie, N.D.M., Hernawan, U.E., Prayudha, B., Supriyadi, I.H., Iswari, M.Y., Rahmat., Anggaraini, K. & Rahmawati, S.S. (2018). Status Padang Lamun Indonesia. P2OLUPI.
- Tangke, U. (2010). Ekosistem padang lamun (manfaat, fungsi dan rehabilitasi). *Agrikan: Jurnal Agribisnis Perikanan*, 3(1): 9-29.
- Zulkifli dan Efriyeldi. (2003). Kandungan Zat Hara dalam Air Poros dan Air Permukaan Padang Lamun Bintan Timur Riau. *Natur Indonesia*, 5(2): 139-144.