

Artikel Penelitian

Sistem Klasifikasi Perubahan Lahan pada Ekosistem Pesisir Berbasis *Deep Learning* Menggunakan Citra Sentinel-2

Studi Kasus: Tanjung Tiram, Sulawesi Tenggara

Annisa Nurfadilah *, Rizal Adi Saputra, Muhammad Ihsan Sarita

Fakultas Teknik, Informatika, Universitas Halu Oleo, Kendari, Indonesia

INFORMASI ARTIKEL

Diterima Redaksi: 24 Februari 2026

Revisi Akhir: 16 Maret 2026

Diterbitkan Online: 20 Maret 2026

KATA KUNCI

Deep Learning

Ekosistem Pesisir

Klasifikasi Tutupan Lahan

Sentinel-2

UNet-ResNet34

KORESPONDENSI (*)

Phone: +62 852-1226-3727

E-mail: annisanurfadilah_e1e122004@student.uho.ac.id

A B S T R A K

Perubahan tutupan lahan pada ekosistem pesisir merupakan isu lingkungan global yang signifikan karena berdampak langsung terhadap fungsi ekologis dan keberlanjutan hayati. Tanjung Tiram, Sulawesi Tenggara, merupakan kawasan pesisir yang rentan terhadap degradasi akibat tekanan aktivitas antropogenik, sehingga memerlukan pendekatan pemantauan yang otomatis dan akurat. Penelitian ini mengembangkan sistem klasifikasi dan kuantifikasi perubahan tutupan lahan pesisir yang berfokus pada ekosistem *mangrove*, terumbu karang, dan padang lamun. Data utama menggunakan citra *Sentinel-2 Level-2A* yang diproses melalui *Google Earth Engine*, dengan penerapan arsitektur *Deep Learning hybrid UNet-ResNet34* untuk melakukan segmentasi semantik tingkat piksel. Hasil penelitian menunjukkan kinerja klasifikasi yang kuat dengan nilai akurasi sebesar 84,31% untuk *mangrove*, 95,99% untuk terumbu karang, dan 89,41% untuk padang lamun. Kemampuan segmentasi model dinilai representatif dengan capaian *Mean IoU* sebesar 0,6124 secara keseluruhan. Analisis multi-temporal periode 2018–2025 mengungkapkan dinamika spasial yang signifikan, ditandai dengan peningkatan luas *mangrove* sebesar 35,53% (95,20 ha), namun terjadi penurunan luas terumbu karang dan padang lamun masing-masing sebesar 32,39% (29,20 ha) dan 26,68% (98,76 ha). Temuan ini menegaskan bahwa integrasi *Sentinel-2* dan *Deep Learning* mampu menyediakan informasi spasial yang andal untuk mendukung pengelolaan pesisir berkelanjutan. Sistem ini dapat diadopsi oleh pemerintah daerah sebagai platform pemantauan ekosistem pesisir secara *real-time* guna mendukung pengambilan keputusan konservasi yang responsif dan berbasis data.

PENDAHULUAN

Pembangunan berkelanjutan global saat ini menghadapi tantangan lingkungan yang semakin meningkat, khususnya degradasi wilayah pesisir yang berlangsung cepat akibat intensifikasi aktivitas antropogenik serta dampak perubahan iklim [1][2]. Ekosistem pesisir, termasuk *mangrove*, terumbu karang, dan padang lamun, memiliki peran fundamental dalam menjaga keanekaragaman hayati laut dan keseimbangan ekologi. Ekosistem-ekosistem tersebut menyediakan berbagai jasa ekosistem, seperti penyerapan karbon, stabilisasi garis pantai, siklus nutrisi, serta habitat bagi beragam organisme laut [3][4]. Degradasinya tidak hanya mengancam keberlanjutan lingkungan, tetapi juga melemahkan stabilitas sosial-ekonomi masyarakat pesisir yang bergantung pada sektor perikanan, pariwisata, dan sumber daya ekosistem untuk mata pencaharian mereka.

Indonesia menjadi salah satu negara yang memiliki luasan hutan *mangrove* dan sistem terumbu karang terbesar di dunia, perlindungan dan pengelolaan ekosistem pesisir secara berkelanjutan telah menjadi prioritas nasional. Komitmen ini tercermin dalam berbagai kerangka regulasi terbaru, seperti Peraturan Pemerintah Nomor 27 Tahun 2025 tentang Pengelolaan Ekosistem *Mangrove*, yang menekankan strategi konservasi, rehabilitasi, dan pemantauan [5][6]. Pada skala regional, wilayah seperti Tanjung Tiram di Sulawesi Tenggara merupakan kawasan pesisir yang memiliki signifikansi

ekologis tinggi karena keberadaan *mangrove*, terumbu karang, dan padang lamun yang saling berdampingan serta menopang aktivitas ekonomi lokal. Namun demikian, ekosistem tersebut semakin terpapar perubahan tutupan lahan, pembangunan pesisir, sedimentasi, dan berbagai tekanan lingkungan lain yang berkontribusi terhadap fragmentasi habitat dan penurunan ketahanan ekosistem [7].

Pendekatan pemantauan konvensional, termasuk survei lapangan (*in situ*) dan pemetaan habitat secara manual, masih memiliki peran penting, tetapi sering kali dibatasi oleh tingginya biaya operasional, prosedur yang membutuhkan banyak tenaga kerja, serta keterbatasan cakupan spasial dan temporal [8][9]. Keterbatasan ini menghambat pengamatan berkelanjutan dan deteksi cepat terhadap perubahan ekosistem, khususnya pada lingkungan pesisir yang luas dan dinamis secara geografis. Oleh karena itu, diperlukan teknik pemantauan yang lebih efisien dan skalabel untuk menyediakan informasi spasial yang tepat waktu dan andal bagi pengelolaan lingkungan serta perumusan kebijakan.

Teknologi penginderaan jauh telah berkembang sebagai alternatif yang kuat untuk pemantauan ekosistem pesisir dalam skala besar. Misi *Copernicus Sentinel-2* menyediakan citra multispektral beresolusi tinggi dengan siklus kunjungan ulang yang relatif sering, sehingga memungkinkan observasi lingkungan pesisir dan laut secara konsisten dari waktu ke waktu [10][11]. Kendati demikian, klasifikasi habitat pesisir berbasis citra satelit masih menghadapi berbagai tantangan, antara lain atenuasi kolom air, variasi kekeruhan, kompleksitas reflektansi dasar perairan, serta kemiripan spektral antar tipe vegetasi yang berbeda [12][13]. Algoritma klasifikasi tradisional, seperti *Maximum Likelihood* dan *Random Forest*, telah banyak digunakan, namun sering mengalami kesulitan dalam menangkap tekstur spasial yang kompleks dan variasi spektral halus yang melekat pada lanskap pesisir yang heterogen [14][15].

Pendekatan *Deep Learning* (DL) semakin menonjol sebagai metode mutakhir dalam analisis geospasial dan klasifikasi berbasis citra. Berbagai arsitektur *Deep Learning* telah dikembangkan, dan salah satu yang paling menonjol adalah model *U-Net*. Model ini menunjukkan kinerja yang kuat dalam segmentasi semantik karena struktur *encoder-decoder*-nya mampu mengintegrasikan ekstraksi fitur lokal dengan informasi konteks global secara efektif [16][17]. Integrasi *backbone ResNet34* sebagai *encoder* semakin meningkatkan kemampuan pembelajaran fitur melalui mekanisme *residual connection*, sehingga mengurangi risiko *vanishing gradient* dan meningkatkan ketahanan klasifikasi pada skenario pemetaan tutupan lahan yang kompleks [18][19]. Sejalan dengan itu, *platform* geospasial berbasis komputasi awan seperti *Google Earth Engine* memungkinkan pemrosesan data satelit dalam skala besar secara efisien, mendukung analisis multi-temporal dan komputasi cepat untuk aplikasi pemantauan lingkungan [20][21].

Kendati teknologi telah berkembang secara signifikan, pengembangan sistem terintegrasi yang menyatukan pemantauan multi-temporal jangka panjang (2018–2025) dengan rekomendasi mitigasi dan pengelolaan otomatis tetap menyisakan kesenjangan krusial. Sebagian besar penelitian dan *platform* yang ada masih berfokus pada hasil klasifikasi spasial tanpa menerjemahkannya menjadi informasi konservasi yang operasional bagi pengambil keputusan. Penelitian yang secara sistematis mengaitkan keluaran klasifikasi dengan strategi mitigasi berdasarkan pedoman lingkungan internasional yang diakui masih relatif terbatas.

Penelitian ini bertujuan untuk menjembatani kesenjangan tersebut dengan mengembangkan sistem pemantauan ekosistem pesisir berbasis *Deep Learning* menggunakan arsitektur *U-Net* dengan *ResNet34* untuk mengklasifikasikan *mangrove*, terumbu karang, dan padang lamun di wilayah pesisir Tanjung Tiram. Strategi pelatihan multi-lokasi yang memanfaatkan data dari Tanjung Tiram, Teluk Kendari, dan Toronipa diterapkan untuk meningkatkan generalisasi model dan akurasi klasifikasi. Selain itu, sistem yang diusulkan mengintegrasikan rekomendasi mitigasi otomatis yang disusun berdasarkan pedoman konservasi internasional, sehingga hasil klasifikasi spasial dapat ditransformasikan menjadi kerangka pendukung keputusan yang praktis. Pendekatan ini diharapkan dapat berkontribusi terhadap pengelolaan pesisir berkelanjutan dengan mendukung kebijakan konservasi berbasis data serta memperkuat kapasitas pemantauan lingkungan di tingkat regional.

TINJAUAN PUSTAKA

Ekosistem Pesisir dan Penginderaan Jauh

Ekosistem pesisir yang terdiri dari *mangrove*, terumbu karang, dan padang lamun merupakan indikator penting kesehatan lingkungan laut. Pemantauan ekosistem ini secara tradisional memerlukan biaya besar dan waktu yang lama. Penggunaan citra satelit multispektoral, khususnya Sentinel-2, telah menjadi standar dalam pemetaan habitat pesisir karena resolusi

spasialnya yang mencapai 10 meter serta ketersediaan data temporal yang kontinu. Citra Sentinel-2 memungkinkan identifikasi perubahan tutupan lahan secara akurat melalui analisis reflektansi spektral pada pita *Visible* dan *Near-Infrared* (NIR).

Deep Learning dalam Klasifikasi Tutupan Lahan

Pemanfaatan kecerdasan buatan, khususnya *Deep Learning*, telah menunjukkan keunggulan signifikan dibandingkan metode klasifikasi tradisional seperti *Maximum Likelihood* atau *Random Forest*. Arsitektur *U-Net* banyak digunakan dalam segmentasi semantik citra medis dan satelit karena kemampuannya dalam menjaga detail spasial melalui mekanisme *skip connections*. Integrasi arsitektur *ResNet34* sebagai *backbone* atau ekstraktor fitur (*encoder*) pada model *U-Net* memungkinkan jaringan untuk mempelajari fitur tekstur yang lebih kompleks dan mengatasi masalah *vanishing gradient* pada model yang dalam. Hal ini sangat krusial dalam membedakan objek yang memiliki kemiripan spektral, seperti lamun dan terumbu karang di perairan dangkal.

METODOLOGI

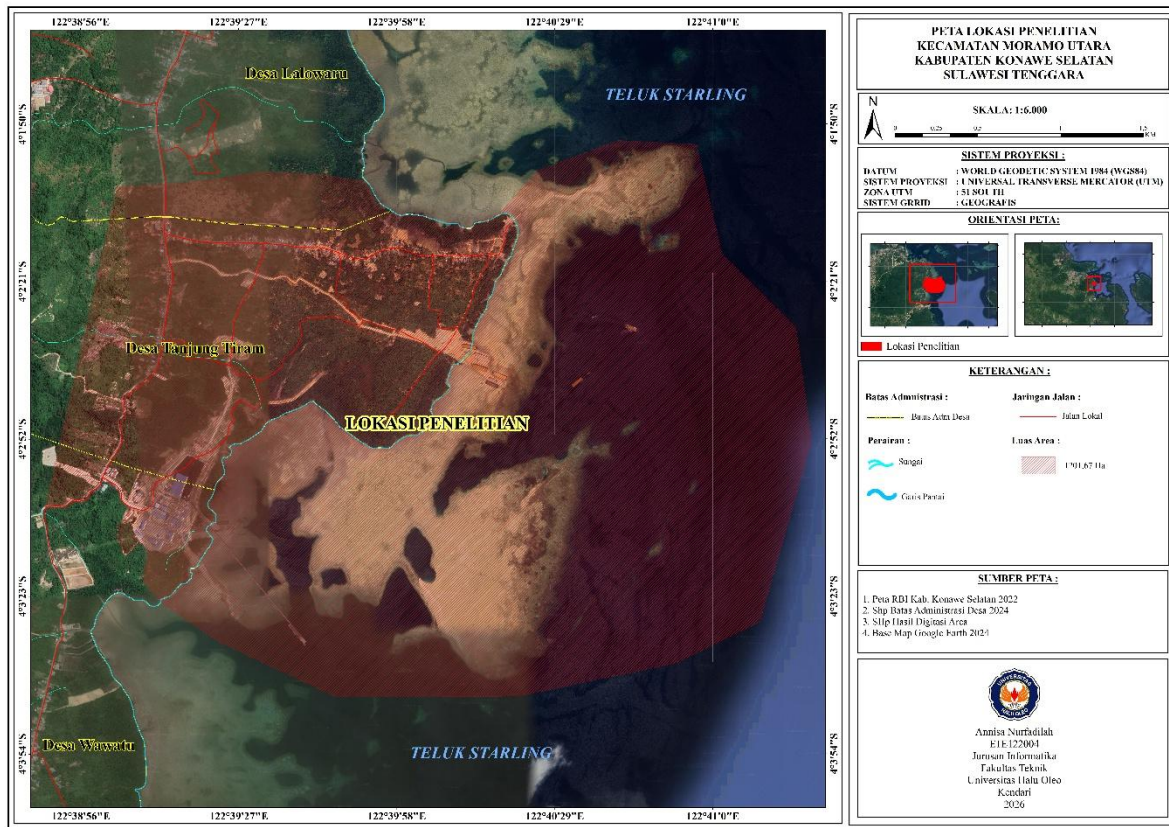
Wilayah Studi dan Akuisisi Data

Wilayah penelitian secara administratif terletak di Kecamatan Moramo Utara, Kabupaten Konawe Selatan, Provinsi Sulawesi Tenggara, dengan fokus utama pada kawasan Tanjung Tiram serta area pendukung di Teluk Kendari dan Pantai Toronipa. Secara spesifik, lokasi penelitian mencakup wilayah Desa Tanjung Tiram dan sebagian perairan Teluk Starling dengan total cakupan area mencapai 1201,07 Ha. Area ini merepresentasikan kesatuan ekosistem pesisir yang mencakup zona daratan pesisir, garis pantai, hingga zona perairan dangkal yang menjadi habitat bagi *mangrove*, terumbu karang, dan padang lamun.

Karakteristik geografis Tanjung Tiram memiliki keunikan sebagai berikut:

1. **Zona Transisi Strategis:** Secara hidrologis, wilayah ini dipengaruhi oleh massa air dari Teluk Kendari serta arus laut dari Selat Tiworo dan Laut Banda. Sifat geografis yang relatif terbuka memungkinkan sirkulasi air yang lebih baik dibandingkan bagian dalam teluk, sehingga mendukung pertumbuhan komunitas terumbu karang dan padang lamun yang memerlukan kejernihan perairan tinggi.
2. **Gradien Substrat dan Morfologi:** Pesisir wilayah ini dicirikan oleh morfologi yang landai dengan variasi substrat mulai dari lumpur berpasir di area hutan *mangrove* hingga dasar perairan berpasir dan berkarang di zona terbuka. Keberadaan ekosistem ini berfungsi secara sinergis; *mangrove* berperan sebagai perangkap sedimen, sementara terumbu karang berfungsi sebagai pemecah gelombang alami.
3. **Tantangan Spektral:** Kondisi geografis yang dinamis, termasuk variasi kedalaman (*bathymetry*) dan pengaruh pasang surut, memberikan tantangan dalam klasifikasi citra Sentinel-2. Variasi ini seringkali menyebabkan ambiguitas spektral antara vegetasi *mangrove* dengan vegetasi darat lainnya, serta antara objek lamun dengan ekosistem terumbu karang di bawah permukaan air.

Integrasi lokasi Tanjung Tiram, Pantai Toronipa, dan Teluk Kendari dalam penelitian ini bertujuan untuk menangkap gradien lingkungan yang lengkap, mulai dari area yang didominasi aktivitas antropogenik dan sedimentasi tinggi hingga area dengan biodiversitas yang masih terjaga. Pemetaan spasial-temporal yang akurat di wilayah ini sangat krusial mengingat meningkatnya tekanan dari aktivitas pelabuhan dan pariwisata di sepanjang garis pantai tersebut.



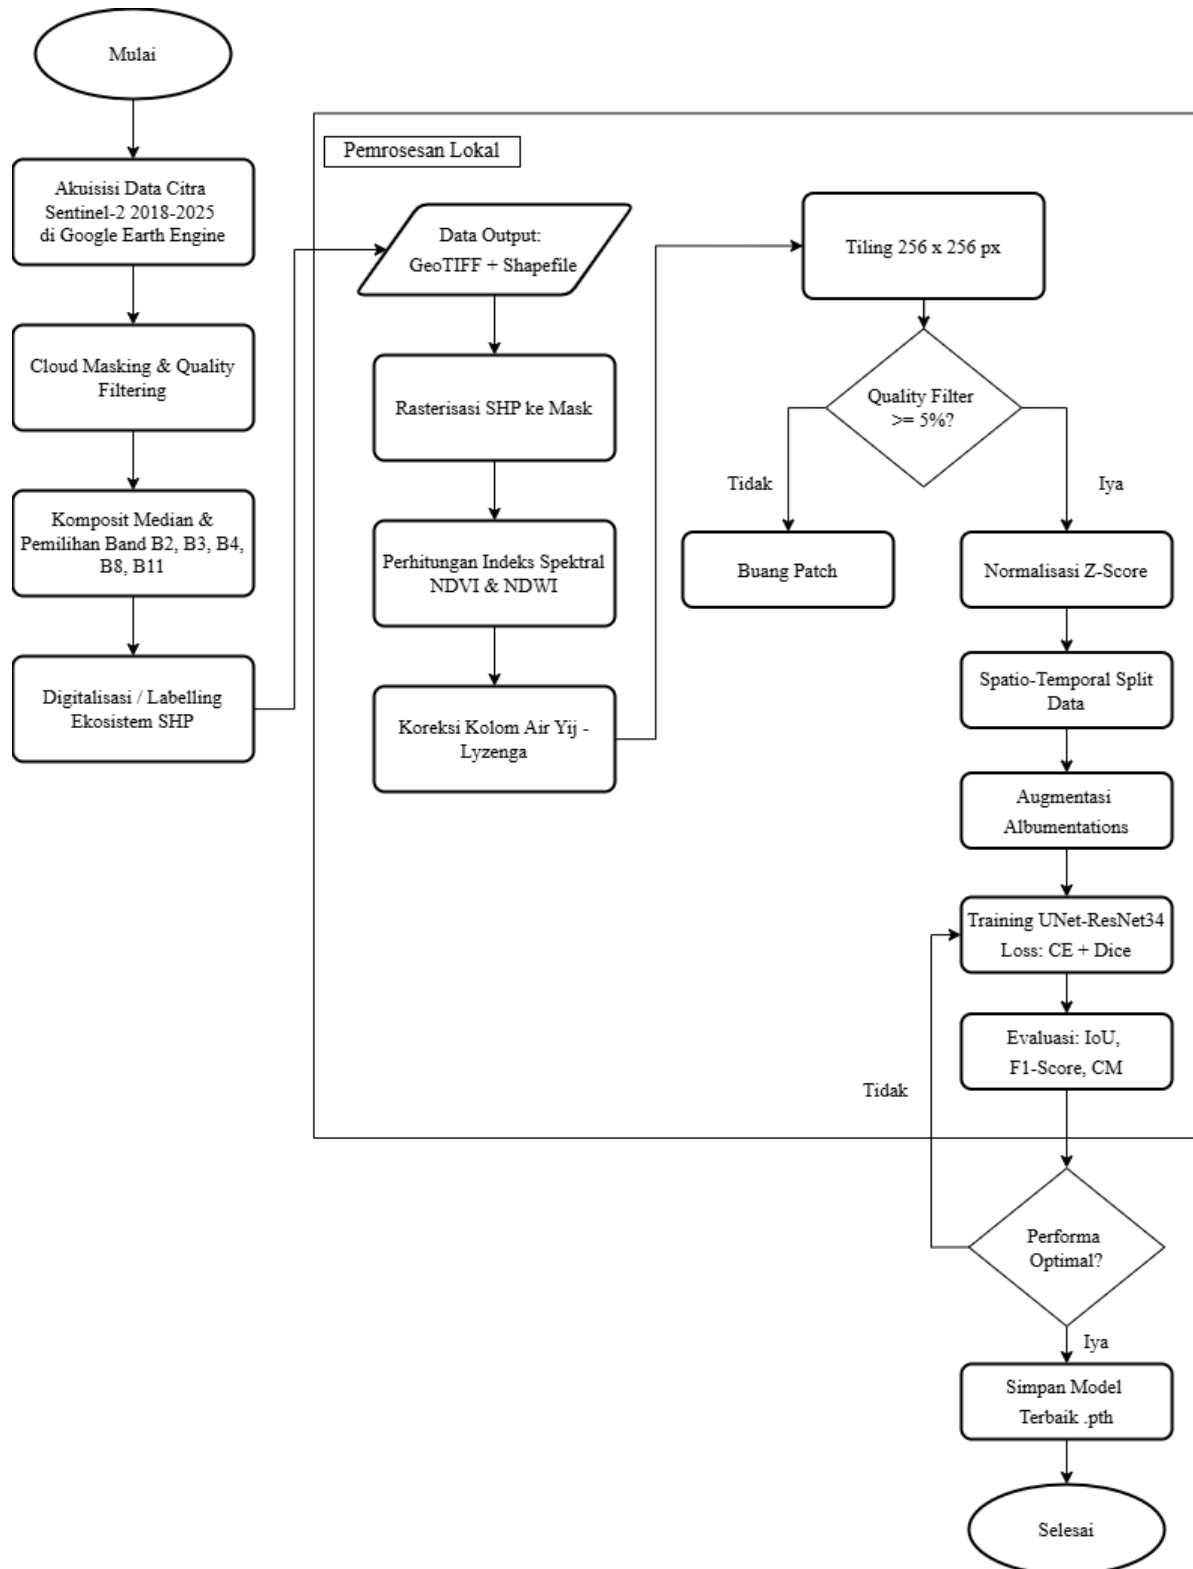
Gambar 1. Peta Administrasi dan Batas Wilayah Kajian Ekosistem Pesisir Tanjung Tiram, Kabupaten Konawe Selatan

Alur Kerja Penelitian (Workflow Sistem)

Penelitian ini dirancang sebagai suatu sistem terpadu untuk memantau dan mengklasifikasikan ekosistem pesisir berbasis citra satelit multi-temporal dan pendekatan *Deep Learning*. Sistem ini mengadopsi arsitektur *end-to-end* yang menjembatani pengolahan data spasial mentah hingga menjadi instrumen pengambilan keputusan digital. Secara umum, sistem mengintegrasikan proses akuisisi data penginderaan jauh, pra-pemrosesan citra tingkat lanjut untuk koreksi atmosfer dan kolom air, pembentukan dataset yang terstandarisasi, serta pelatihan dan evaluasi model segmentasi semantik.

Lebih lanjut, penelitian ini melampaui sekadar klasifikasi statis dengan mengimplementasikan visualisasi hasil dalam bentuk Sistem Informasi Geografis berbasis *web (Web-GIS)* yang bersifat interaktif. *Platform* ini dilengkapi dengan modul rekomendasi mitigasi berbasis kecerdasan buatan yang mampu menganalisis tren degradasi ekosistem secara otomatis. Pendekatan komprehensif ini bertujuan untuk menghasilkan informasi spasial yang memiliki tingkat akurasi tinggi dan relevansi praktis, sehingga dapat digunakan sebagai dasar pengambilan keputusan dalam strategi pengelolaan serta pelestarian ekosistem pesisir secara berkelanjutan.

Alur kerja penelitian ini secara keseluruhan ditunjukkan pada **Gambar 2**. Diagram alir tersebut menggambarkan tahapan utama secara sistematis, mulai dari akuisisi citra Sentinel-2 melalui *platform cloud computing*, standarisasi data melalui *tiling* dan augmentasi, pelatihan model menggunakan arsitektur *hybrid UNet-ResNet34*, hingga tahap evaluasi kinerja menggunakan metrik spasial dan penyimpanan model terbaik untuk *deployment* sistem.



Gambar 2. Alur Proses Modelling

Alur kerja sistem penelitian ini terdiri atas beberapa tahapan utama sebagai berikut:

1. Akuisisi Data Citra Satelit

Tahap awal penelitian dimulai dengan pengambilan data citra satelit Sentinel-2 Level-2A periode 2018–2025 melalui *platform Google Earth Engine* (GEE). Data ini dipilih karena memiliki resolusi spasial 10 meter dan cakupan temporal yang memadai untuk analisis perubahan ekosistem pesisir. Proses akuisisi

- mencakup pemilihan area studi, pengunduhan citra multi-temporal, serta penyimpanan data dalam format *raster (GeoTIFF)* dan data vektor referensi (*Shapefile*).
2. **Pra-pemrosesan dan Pengolahan Awal Data**
Data citra yang diperoleh kemudian melalui proses pra-pemrosesan yang meliputi *cloud masking*, *quality filtering*, serta komposit median tahunan untuk mengurangi pengaruh awan, kilau matahari (*sun glint*), dan variabilitas musiman. Pada tahap ini juga dilakukan pemilihan kanal spektral utama, yaitu B2 (biru), B3 (hijau), B4 (merah), dan B8 (NIR), serta perhitungan indeks spektral seperti NDVI dan NDWI. Selain itu, dilakukan koreksi kolom air menggunakan metode *Lyzenga* untuk meningkatkan kemampuan diskriminasi habitat bentik di perairan dangkal.
 3. **Digitalisasi dan Pembentukan Data Referensi (*Ground Truth*)**
Data referensi berupa peta ekosistem pesisir (*mangrove*, terumbu karang, lamun, dan non-vegetasi) diperoleh melalui proses digitalisasi manual berbasis citra resolusi tinggi dan survei lapangan terbatas. Data vektor tersebut kemudian dirasterisasi menjadi mask kelas yang digunakan sebagai label dalam proses pelatihan model *Deep Learning*.
 4. **Pembentukan *Dataset* dan Pematangan Citra (*Tiling*)**
Citra hasil pra-pemrosesan dipotong menjadi patch berukuran 256×256 piksel untuk mengurangi kompleksitas komputasi dan meningkatkan efektivitas pembelajaran fitur spasial oleh model. Selanjutnya dilakukan penyaringan kualitas (*quality filtering*) untuk menghilangkan *patch* yang masih mengandung awan, bayangan, atau derau berlebih. *Patch* yang lolos seleksi kemudian dinormalisasi menggunakan metode *Z-score* dan dibagi menjadi data pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*) secara spatio-temporal.
 5. **Augmentasi Data**
Keragaman data latih ditingkatkan dan risiko *overfitting* dikurangi melalui penerapan augmentasi data menggunakan pustaka *Albumentations*. Teknik augmentasi yang digunakan mencakup rotasi, *flipping*, penyesuaian kecerahan, serta berbagai transformasi geometrik lain yang tetap mempertahankan karakteristik spasial objek ekosistem pesisir.
 6. **Pelatihan Model *UNet-ResNet34***
Dataset yang telah disiapkan digunakan untuk melatih model segmentasi semantik berbasis arsitektur *UNet-ResNet34*. Proses pelatihan dilakukan dengan fungsi *loss* gabungan *Cross Entropy* (CE) dan *Dice Loss* untuk meningkatkan ketelitian klasifikasi pada kelas-kelas yang tidak seimbang. Model dilatih secara iteratif hingga mencapai kondisi konvergen berdasarkan performa pada data validasi.
 7. **Evaluasi Kinerja Model**
Kinerja model dievaluasi menggunakan data pengujian independen dengan metrik evaluasi berupa *Intersection over Union (IoU)*, *F1-score*, *confusion matrix*, dan *ROC-AUC*. Hasil evaluasi ini digunakan untuk menentukan apakah model telah mencapai performa optimal atau masih memerlukan penyesuaian parameter dan pengulangan proses pelatihan.
 8. **Penyimpanan Model Terbaik**
Apabila performa model telah memenuhi kriteria yang ditetapkan, model terbaik disimpan dalam format *file (.pth)* untuk digunakan pada tahap implementasi sistem *monitoring* dan visualisasi berbasis *Web-GIS*.
 9. **Implementasi Sistem dan Visualisasi *Web-GIS***
Model terlatih diintegrasikan ke dalam sistem *backend* berbasis *Flask* sebagai *Application Programming Interface* (API). Hasil klasifikasi kemudian divisualisasikan pada antarmuka *Web-GIS* menggunakan *Leaflet.js* dalam bentuk peta tematik dan analisis perubahan temporal ekosistem pesisir. Selain itu, sistem dilengkapi dengan modul rekomendasi mitigasi berbasis aturan (*rule-based*) yang menghubungkan hasil klasifikasi dengan kebijakan pengelolaan ekosistem pesisir.

Spesifikasi Data dan Distribusi *Dataset*

Pemrosesan citra Sentinel-2 dilakukan dengan menerapkan teknik komposit median tahunan untuk menekan nilai piksel anomali dan menghasilkan reflektansi spektral yang stabil. Kanal spektral yang digunakan dalam penelitian ini (B2, B3, B4, dan B8) diseragamkan pada resolusi spasial 10 meter untuk menjamin konsistensi fitur spasial, dengan rincian yang disajikan pada Tabel 1.

Tabel 1. Kanal Spektral Sentinel-2 dan Resolusi Spasial Pada Penelitian

Nomor <i>Band</i>	Panjang Gelombang Tengah (μm)	Nama <i>Band</i>	Resolusi Spasial (m)
B2	0.490	<i>Blue</i>	10
B3	0.560	<i>Green</i>	10
B4	0.665	<i>Red</i>	10
B8	0.842	<i>Near-Infrared (NIR)</i>	10

Setelah melalui tahapan pra-pemrosesan, diperoleh dataset yang terdiri dari **149 patch** citra representatif berukuran 256×256 piksel. Jumlah ini dihasilkan melalui teknik augmentasi spasial berbasis tumpang tindih (*sliding window overlap*) sebesar 64 piksel untuk memaksimalkan ekstraksi fitur dari area penelitian yang terbatas [22]. Penggunaan teknik *overlap* ini secara efektif meningkatkan variabilitas spasial pada setiap *patch*, yang sangat krusial untuk melatih model segmentasi semantik dalam mengenali batas-batas ekosistem yang kompleks. Pendekatan ini terbukti mampu mengoptimalkan representasi objek pada area studi dengan cakupan geografis yang spesifik sehingga model dapat mempelajari pola spasial secara lebih mendalam. *Dataset* kemudian dibagi secara sistematis menjadi tiga subset: pelatihan, validasi, dan pengujian. Pembagian dilakukan secara terstratifikasi guna memastikan representasi habitat mangrove, terumbu karang, dan padang lamun yang seimbang, serta meminimalkan risiko *overfitting*. Distribusi mendetail mengenai jumlah *patch* dirangkum dalam **Tabel 2**.

Tabel 2. Distribusi Patch Citra untuk Proses Pelatihan, Validasi, dan Pengujian Model

Kategori Dataset	Jumlah Patch	Persentase (%)	Tujuan
Data Pelatihan	99	66,4%	Pembaruan bobot model dan pembelajaran fitur.
Data Validasi	25	16,8%	Penyetelan hiperparameter dan pencegahan <i>overfitting</i> .
Data Pengujian	25	16,8%	Evaluasi kinerja akhir dan perhitungan metrik.
Total	149	100%	

Penerapan strategi *Transfer Learning* dengan bobot *pre-trained* ImageNet pada arsitektur ResNet34 dikombinasikan dengan teknik *overlap* ini memberikan stabilitas tinggi pada model. Hal ini memungkinkan model mencapai konvergensi yang optimal dan generalisasi yang kuat meskipun bekerja dengan volume dataset yang terkontrol.

Arsitektur Model: UNet–ResNet34

Penelitian ini menggunakan arsitektur *Deep Learning* hibrida yang mengintegrasikan kerangka segmentasi semantik *U-Net* dengan *encoder ResNet34* untuk meningkatkan kemampuan ekstraksi fitur dan akurasi klasifikasi spasial. Arsitektur *U-Net* memungkinkan segmentasi pada tingkat piksel secara presisi melalui kombinasi jalur *encoder* dan *decoder*, sehingga detail spasial dapat dipertahankan sekaligus mempelajari konteks semantik global. Integrasi *ResNet34* memperkuat kapasitas representasi *encoder* melalui mekanisme *residual learning*. Desain hibrida ini sangat sesuai untuk lingkungan pesisir yang kompleks, di mana karakteristik spektral dan pola spasial bersifat heterogen.

Backbone ResNet34 yang telah dilatih sebelumnya (*pre-trained*) menggunakan *dataset ImageNet* digunakan sebagai pengekstraksi fitur utama. Koneksi residual di dalam jaringan memungkinkan pembelajaran fitur yang lebih dalam dengan mengurangi permasalahan *vanishing gradient* serta menjaga stabilitas propagasi gradien antar lapisan. Kemampuan ini penting untuk mengidentifikasi tekstur kompleks dan variasi spektral yang berkaitan dengan *mangrove*, lamun, dan struktur terumbu karang pada citra multispektral. Sehingga, *encoder* mampu menangkap fitur diskriminatif yang diperlukan untuk klasifikasi habitat pesisir secara akurat [19].

Komponen *decoder* berfungsi merekonstruksi resolusi spasial citra masukan melalui serangkaian proses *up-sampling*. *Skip connection* digunakan untuk menggabungkan fitur spasial tingkat rendah dari *encoder* dengan representasi semantik tingkat tinggi dari lapisan yang lebih dalam, sehingga meningkatkan ketelitian batas kelas (*boundary delineation*) dan kontinuitas spasial. Mekanisme ini sangat membantu dalam segmentasi hutan *mangrove* dan padang lamun yang umumnya memiliki distribusi spasial terfragmentasi dan tidak beraturan. Lapisan segmentasi akhir menerapkan fungsi aktivasi *softmax* untuk menghasilkan probabilitas kelas pada setiap piksel untuk kategori *mangrove*, terumbu karang, lamun, dan area non-vegetasi.

HASIL DAN PEMBAHASAN

Kinerja Model Secara Keseluruhan dan Akurasi Klasifikasi

Kinerja model *UNet-ResNet34* dievaluasi secara ketat menggunakan *dataset* pengujian independen yang terdiri atas 25 *patch* citra untuk menjamin reliabilitas dan kemampuan generalisasi sistem klasifikasi. Model mencapai nilai akurasi keseluruhan sebesar 84,31% dan nilai *Macro ROC-AUC* sebesar 0,92, yang menunjukkan kemampuan tinggi dalam membedakan berbagai kelas tutupan lahan pesisir secara andal. Hasil ini membuktikan bahwa kerangka *Deep Learning* yang diusulkan mampu menangkap informasi spektral dan spasial yang terkandung dalam citra multispektral Sentinel-2 secara efektif. Kombinasi segmentasi berbasis piksel dan ekstraksi fitur hierarkis memungkinkan model bekerja secara stabil pada lingkungan pesisir yang bersifat heterogen.

Tabel 3. Metrik Kinerja Keseluruhan Model *UNet-ResNet34*

Ekosistem	Accuracy	ROC-AUC (Macro)
Mangrove	0,8431	0,9258
Terumbu Karang	0,9599	0,9810
Padang Lamun	0,8941	0,9681

Nilai *ROC-AUC* yang tinggi mengindikasikan bahwa arsitektur hibrida ini mampu memodelkan hubungan non-linear antara reflektansi spektral dan kelas habitat bentik secara efektif. *Backbone ResNet34* berperan penting dalam mengekstraksi fitur tekstural dan kontekstual yang mendalam, yang sangat dibutuhkan untuk membedakan kelas-kelas dengan karakteristik spektral yang saling tumpang tindih, seperti lamun, terumbu karang, dan substrat perairan dangkal. Selain itu, integrasi *skip connection* pada arsitektur *U-Net* mampu mengurangi fenomena *salt-and-pepper noise* yang umum dijumpai pada metode klasifikasi berbasis piksel konvensional. Temuan ini menegaskan bahwa koherensi spasial dan ketelitian batas kelas meningkat secara signifikan ketika jaringan saraf konvolusional diterapkan pada pemetaan ekosistem pesisir.

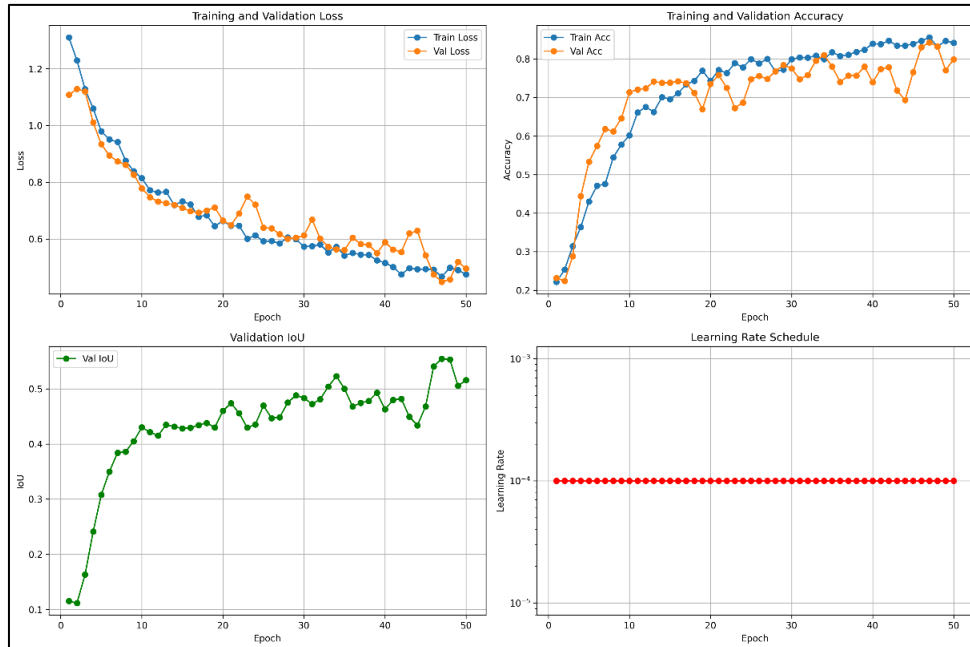
Apabila dibandingkan dengan pendekatan pembelajaran mesin konvensional, seperti *Random Forest* dan *Maximum Likelihood Classification*, capaian kinerja ini mencerminkan keunggulan metode *Deep Learning* dalam menangani pola spasial yang kompleks serta fenomena *mixed pixels* yang lazim ditemukan pada lingkungan pesisir. Metode konvensional umumnya mengandalkan informasi spektral per piksel secara independen, sehingga kurang mampu merepresentasikan hubungan spasial antar-piksel dan struktur morfologis objek bentik. Sebaliknya, jaringan saraf konvolusional pada arsitektur *UNet-ResNet34* mempelajari fitur hierarkis yang mencakup tekstur, bentuk, dan konteks lingkungan sekitar suatu piksel, sehingga meningkatkan kemampuan model dalam membedakan kelas-kelas yang memiliki karakteristik spektral serupa namun berbeda secara struktural.

Hasil penelitian ini juga menunjukkan bahwa kanal spektral yang digunakan, yaitu B2 (biru), B3 (hijau), B4 (merah), dan B8 (*Near Infrared*), mengandung informasi diskriminatif yang memadai apabila dikombinasikan dengan konteks spasial yang dipelajari oleh model. Kanal biru dan hijau berperan penting dalam penetrasi kolom air untuk mendeteksi substrat dangkal, sedangkan kanal merah dan NIR berkontribusi dalam identifikasi vegetasi pesisir seperti *mangrove* dan lamun. Integrasi keempat kanal ini memungkinkan model untuk menangkap variasi reflektansi yang dipengaruhi oleh kedalaman air, kekeruhan, serta komposisi substrat dasar, sehingga memperkuat kemampuan klasifikasi pada lingkungan perairan dangkal yang heterogen.


Lebih lanjut, stabilitas kinerja model pada berbagai kelas ekosistem menunjukkan bahwa *UNet-ResNet34* memiliki kemampuan generalisasi yang baik terhadap variasi kondisi lingkungan dan temporal. Hal ini sangat penting dalam pemetaan ekosistem pesisir berskala luas dan multi-temporal, di mana perubahan kondisi perairan, dinamika sedimen, serta variasi atmosfer dapat mempengaruhi kualitas citra satelit. Hal ini menunjukkan bahwa, *UNet-ResNet34* dapat dinyatakan sebagai arsitektur yang andal dan *robust* untuk klasifikasi ekosistem pesisir, baik untuk pemantauan jangka pendek maupun analisis perubahan jangka panjang.

Selain itu, capaian metrik *Mean Intersection over Union* (Mean IoU) sebesar 0,6124 menunjukkan bahwa hasil segmentasi model memiliki tingkat kesesuaian spasial yang baik terhadap data referensi (*ground truth*). Nilai ini mengindikasikan bahwa sebagian besar area ekosistem pesisir berhasil dipetakan dengan tingkat tumpang tindih yang kuat antara hasil prediksi dan kondisi aktual di lapangan. Pencapaian ini penting dalam konteks pemetaan ekosistem pesisir, karena

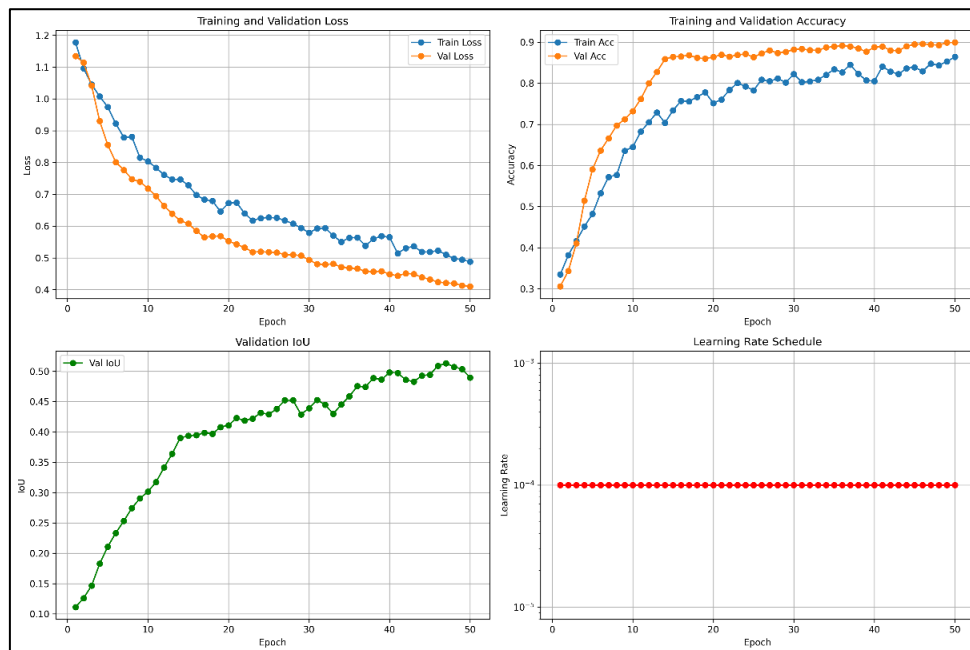
kesalahan kecil pada batas kelas (*boundary*) dapat berdampak signifikan terhadap estimasi luasan habitat. Integrasi antara arsitektur segmentasi semantik dan data multispektral Sentinel-2 memungkinkan sistem untuk berfungsi sebagai alat pemantauan yang sensitif terhadap dinamika ekosistem pesisir. Keunggulan ini memberikan dasar yang kuat bagi penerapan sistem dalam kerangka *monitoring* operasional, khususnya untuk mendukung analisis spasio-temporal, peringatan dini degradasi lingkungan, serta perumusan strategi konservasi berbasis data ilmiah yang konsisten dan terukur.



(a)



(b)



(c)

Gambar 3. (a) Metrik Pelatihan Kelas *Mangrove*; (b) Metrik Pelatihan Kelas Terumbu Karang; dan (c) Metrik Pelatihan Kelas Lamun

Dinamika proses pelatihan yang ditunjukkan pada Gambar 3 memberikan gambaran teknis mengenai perilaku konvergensi model pada masing-masing kelas ekosistem. Pada kelas *Mangrove* dan Terumbu Karang (Gambar 3a dan 3b), kurva akurasi menunjukkan peningkatan yang cepat pada fase awal pelatihan dan kemudian mencapai kondisi stabil (*plateau*). Pola ini mengindikasikan bahwa model mampu mempelajari representasi fitur secara konsisten tanpa mengalami fluktuasi signifikan pada fase validasi. Nilai *ROC-AUC* yang tinggi, masing-masing sebesar 0,9258 untuk *Mangrove* dan 0,9810 untuk Terumbu Karang, mencerminkan separabilitas kelas yang kuat serta kemampuan model dalam mengurangi kesalahan klasifikasi antar kategori yang memiliki kemiripan spektral.

Sebaliknya, metrik pelatihan untuk kelas Lamun (Gambar 3c) menunjukkan fluktuasi pada fase validasi yang berkorelasi dengan nilai *Macro F1-Score* sebesar 0,6236. Model menunjukkan performa yang relatif baik dalam mengidentifikasi lamun kategori jarang (*F1-Score* 0,7832), namun mengalami penurunan kinerja pada kategori lamun padat (*F1-Score* 0,2748). Variasi ini mengindikasikan bahwa objek terendam (*submerged features*) memiliki sensitivitas tinggi terhadap pengaruh kolom air, kekeruhan, serta derau spektral, sehingga menyulitkan proses pembelajaran fitur pada kelas dengan kepadatan vegetasi tinggi. Kondisi serupa juga ditemukan pada sub-kategori *mangrove* kerapatan sedang yang menunjukkan nilai deteksi rendah, yang menandakan adanya tantangan spesifik dalam membedakan kelas transisi dengan karakteristik spektral yang saling tumpang tindih.

Oleh karena itu, pencapaian konvergensi global serta nilai *Weighted F1-Score* yang relatif tinggi pada seluruh kelas ekosistem (rata-rata di atas 0,83) menunjukkan bahwa mekanisme ekstraksi fitur hierarkis pada arsitektur *U-Net* berhasil mengurangi ambiguitas klasifikasi secara signifikan. Akurasi global sebesar 84,31% menegaskan bahwa sistem yang dikembangkan memiliki reliabilitas yang cukup untuk diterapkan sebagai perangkat operasional pemantauan ekosistem pesisir multi-temporal di wilayah Sulawesi Tenggara.

Kinerja Klasifikasi Spesifik Ekosistem

Kinerja klasifikasi menunjukkan variasi yang signifikan antar kelas ekosistem pesisir, yang dipengaruhi oleh perbedaan karakteristik spektral, kondisi kolom air, serta kompleksitas lingkungan setempat. Setiap tipe habitat memiliki pola reflektansi yang berbeda sebagai fungsi dari kepadatan vegetasi, komposisi substrat dasar, dan tingkat kekeruhan perairan. Tabel 4 menyajikan ringkasan performa model untuk setiap ekosistem utama menggunakan nilai rata-rata tertimbang (*weighted average*) untuk memberikan gambaran stabilitas model secara menyeluruh.

Tabel 4 Metrik Kinerja Model untuk Setiap Kelas Ekosistem

Ekosistem	<i>F1-Score (Weighted)</i>	<i>Mean IoU</i>	Interpretasi
Mangrove	0,8352	0,5546	Stabil & Representatif
Terumbu Karang	0,9574	0,5361	Sangat Stabil
Padang Lamun	0,8944	0,5132	Stabil

Berdasarkan Tabel 4, ekosistem Terumbu Karang mempertahankan konsistensi tertinggi dengan *Weighted F1-Score* sebesar 0,9574. Meskipun demikian, nilai *Mean IoU* sebesar 0,5361 mencerminkan tantangan dalam mendelineasi batas tepi terumbu secara piksel-presisi, terutama pada sub-kelas "Rusak" yang memiliki *IoU* sangat rendah (0,0029) akibat kendala *data imbalance*. Keberhasilan dominan tetap terlihat pada kelas "Karang Baik" yang mampu mencapai *IoU* 0,9484, membuktikan efektivitas *UNet-ResNet34* dalam memetakan area inti terumbu. Pada ekosistem Padang Lamun, nilai *Weighted F1-Score* yang tinggi (0,8944) didorong oleh keberhasilan model dalam memisahkan objek perairan dari non-perairan (*F1-Score* 0,9738). Namun, sebagaimana terlihat pada fluktuasi grafik pelatihan sebelumnya (Gambar 3c), model menghadapi degradasi performa pada kelas "Padat" (*F1-Score* 0,2748; *IoU* 0,1593). Hal ini mengindikasikan bahwa meskipun model mampu mengenali keberadaan lamun secara umum, presisi dalam membedakan tingkat kerapatan di bawah kolom air masih dipengaruhi oleh gangguan atmosfer dan kedalaman perairan. Ekosistem Mangrove menunjukkan stabilitas dengan *F1-Score* 0,8352. Rendahnya nilai *IoU* pada sub-kategori "Sedang" (0,0000) menunjukkan adanya ambiguitas spasial pada zona transisi kerapatan. Namun, kemampuan model dalam memetakan "Mangrove Jarang" dengan *IoU* 0,7868 memberikan kompensasi yang signifikan terhadap total luasan habitat yang terdeteksi. Perbedaan kinerja antar kelas tersebut menegaskan bahwa faktor lingkungan perairan memiliki peran dominan dalam menentukan keberhasilan klasifikasi habitat bentik. Hasil ini menunjukkan bahwa pendekatan berbasis citra optik multispektral memiliki keterbatasan inheren dalam memetakan vegetasi terendam secara presisi, sehingga diperlukan strategi lanjutan seperti koreksi kolom air, integrasi data batimetri, atau pemanfaatan sensor tambahan untuk meningkatkan sensitivitas model terhadap variasi kondisi perairan.

Analisis Perubahan Spasio-Temporal (2018–2025)

Analisis multi-temporal menunjukkan terjadinya perubahan signifikan pada lanskap pesisir Tanjung Tiram selama periode pengamatan tujuh tahun. Integrasi hasil klasifikasi tahunan memungkinkan kuantifikasi dinamika ekosistem dan identifikasi tren jangka panjang. Analisis luas spasial kelas ekosistem periode 2018–2025 mengungkap pergeseran distribusi habitat secara kuantitatif, yang menjadi acuan dalam menilai ketahanan pesisir dan dampak aktivitas antropogenik.

Tabel 5 Perubahan Luas Tutupan Lahan di Tanjung Tiram (2018–2025)

Kelas Ekosistem	Luas 2018 (ha)	Luas 2025 (ha)	Perubahan Bersih (ha)	Perubahan (%)
Mangrove	267,95	363,15	+95,20	+35,53%
Terumbu Karang	90,15	60,95	-29,20	-32,39%
Lamun	370,18	271,42	-98,76	-26,68%

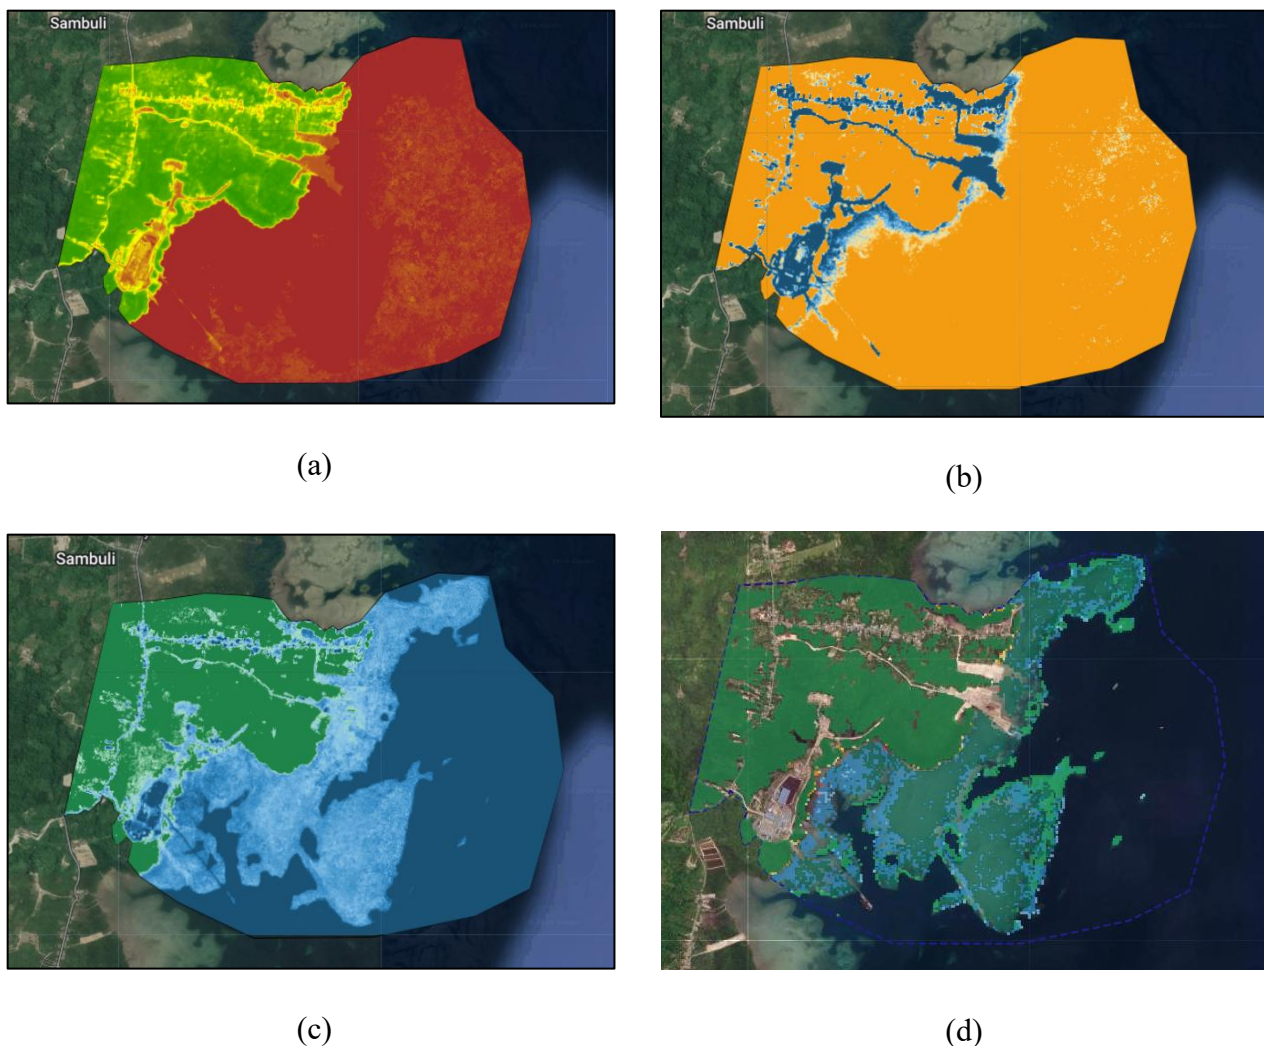
Peningkatan luas *mangrove* sebesar 35,53% dapat dikaitkan dengan proses regenerasi alami dan program rehabilitasi lokal. Tren ini sejalan dengan temuan Saputra et al. (2024) yang melaporkan bahwa penurunan mobilitas manusia selama pandemi COVID-19 secara signifikan mendukung pemulihan vegetasi pesisir di kawasan taman nasional Indonesia, sehingga mengindikasikan terjadinya periode "rehabilitasi alami" di wilayah Tanjung Tiram [23]. Ekspansi *mangrove* juga menunjukkan perbaikan stabilisasi sedimen dan pengurangan erosi pantai pada beberapa zona, yang menandakan tingkat ketahanan ekosistem *mangrove* relatif lebih tinggi dibandingkan habitat bentik ketika tekanan antropogenik berkurang.

Sebaliknya, penurunan luas terumbu karang sebesar 32,39% dan lamun sebesar 26,68% menunjukkan meningkatnya tekanan lingkungan. Penurunan ini berkaitan dengan sedimentasi akibat perubahan penggunaan lahan, pembangunan pesisir, serta intensifikasi aktivitas manusia di luar periode pandemi. Masukan sedimen menurunkan penetrasi cahaya dan menutupi organisme bentik, sehingga mempercepat degradasi habitat. Perbedaan tren antara *mangrove* dan ekosistem bentik mencerminkan respons yang tidak seragam terhadap tekanan alami maupun antropogenik, sehingga diperlukan strategi konservasi yang lebih terarah dan spesifik ekosistem.

Visualisasi Hasil Klasifikasi

Validitas spasial hasil klasifikasi dievaluasi melalui analisis kualitatif terhadap peta tematik yang dihasilkan. Proses visualisasi menggabungkan informasi spektral mentah dengan inferensi *Deep Learning*, sehingga memberikan perspektif berlapis terhadap lanskap pesisir Tanjung Tiram. Pemanfaatan indeks spektral seperti NDVI, *Coral Index*, dan *Seagrass Index* sebagai tahap *masking* awal memungkinkan sistem memfokuskan area analisis sekaligus mengurangi kesalahan klasifikasi pada wilayah daratan dengan reflektansi tinggi maupun perairan dalam. Pendekatan ini tidak hanya meningkatkan akurasi pemetaan, tetapi juga menegaskan pentingnya integrasi metode berbasis indeks dengan model pembelajaran mendalam dalam studi ekosistem pesisir.

Peta tematik menunjukkan konsistensi spasial yang tinggi antara kelas hasil prediksi dan data referensi, khususnya dalam pendelineasian garis pantai dan zona ekosistem utama. Inspeksi visual memperlihatkan bahwa arsitektur *UNet-ResNet34* mampu mempertahankan integritas struktural tambalan lamun yang terfragmentasi serta sabuk *mangrove* yang sempit, yang sering hilang pada metode klasifikasi resolusi rendah. Ketajaman delineasi kelas Non-Perairan (*F1-Score* 0,9738) menegaskan kemampuan sistem dalam mengidentifikasi posisi garis pantai secara akurat, yang merupakan prasyarat utama untuk analisis perubahan pesisir yang andal.



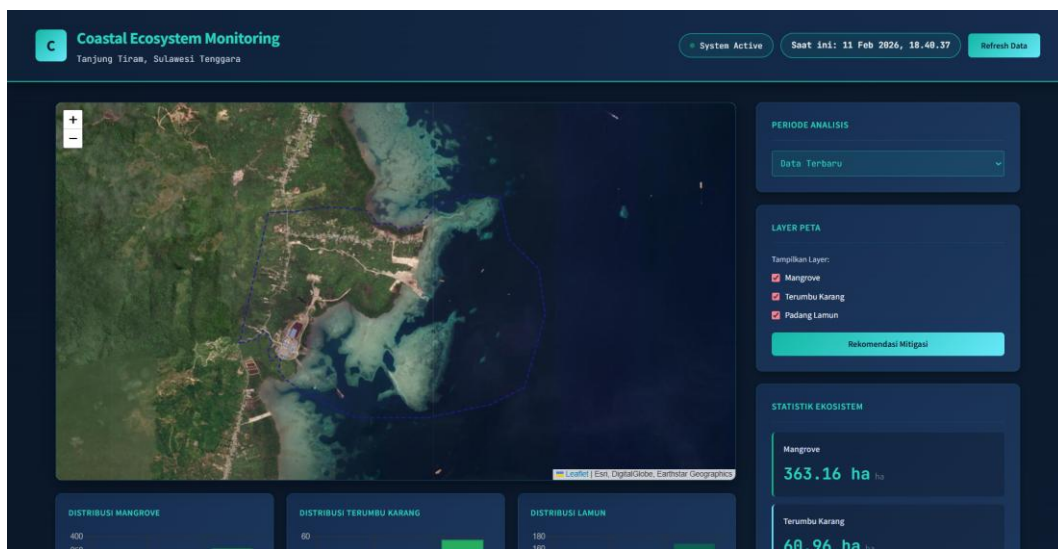
Gambar 4 (a) Masking *Mangrove* Berbasis NDVI; (B) Distribusi *Coral Index*; (C) Analisis *Seagrass Index*; dan (D) Peta Klasifikasi Tematik Terintegrasi dalam Dasbor Sistem Pemantauan

Selain itu, visualisasi memperlihatkan efektivitas model dalam menjaga kontinuitas spasial dan mengurangi derau klasifikasi. Batas kelas yang halus pada zona *mangrove* dan terumbu karang menunjukkan bahwa jaringan saraf berhasil mempelajari hubungan spasial kontekstual, bukan sekadar mengandalkan nilai piksel individual. Efek *spatial smoothing* ini merupakan hasil langsung dari mekanisme *skip connection* dalam kerangka *U-Net*, yang memungkinkan pemulihan detail spasial halus dari *encoder* ke peta segmentasi akhir. Integrasi otomatis inferensi *UNet-ResNet34* ke dalam dasbor *Web-GIS* menunjukkan efisiensi sistem dalam pemrosesan data secara hampir waktu nyata. Arsitektur *backend* memanfaatkan bobot model terlatih untuk menghasilkan lapisan tematik tanpa latensi signifikan, sehingga layak

digunakan untuk pemantauan operasional. Hasil kualitatif ini memperkuat temuan kuantitatif dan menegaskan bahwa sistem yang diusulkan memiliki potensi tinggi sebagai alat pemantauan pesisir berbasis data dan pendukung pengambilan keputusan secara ilmiah.

Implementasi Sistem

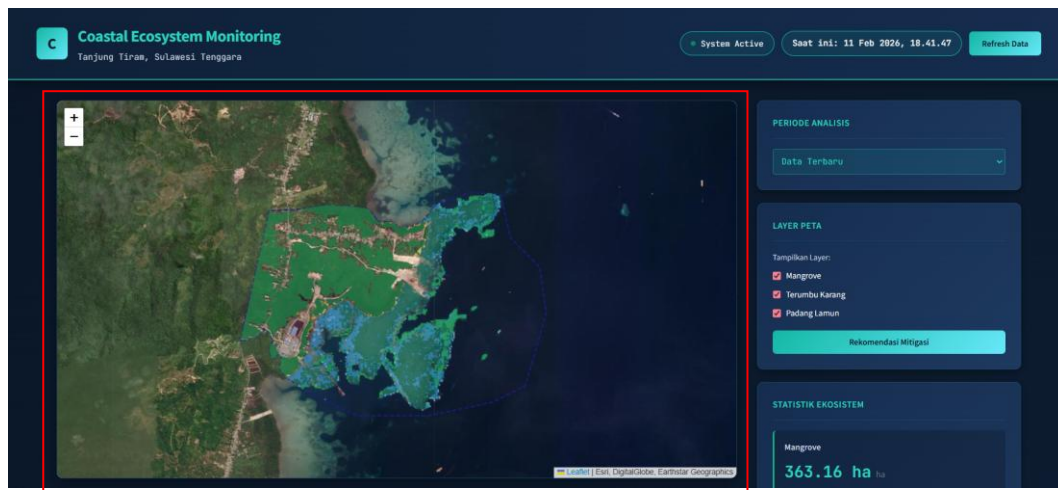
Penelitian ini berhasil mengimplementasikan sebuah sistem pemantauan ekosistem pesisir berbasis *web* yang mengintegrasikan model *UNet-ResNet34* untuk memantau tiga ekosistem utama di wilayah Tanjung Tiram, yaitu *mangrove*, terumbu karang, dan padang lamun. Sistem ini dirancang sebagai antarmuka dinamis berbasis *Web-GIS* dengan tema visual *dark mode* guna meningkatkan kontras tampilan peta dan kenyamanan visual pengguna dalam melakukan analisis spasial dan temporal. Sistem menyediakan kontrol interaktif kepada pengguna melalui panel pemilihan periode waktu (2018–2025) yang memungkinkan analisis perubahan ekosistem secara multi-temporal. Data citra satelit diproses secara otomatis oleh *backend* dan disajikan dalam bentuk peta tematik interaktif, grafik distribusi kondisi ekosistem, serta tren perubahan luasan wilayah secara kuantitatif.



Gambar 5. Tampilan Dashboard Utama Sistem Pemantauan Ekosistem

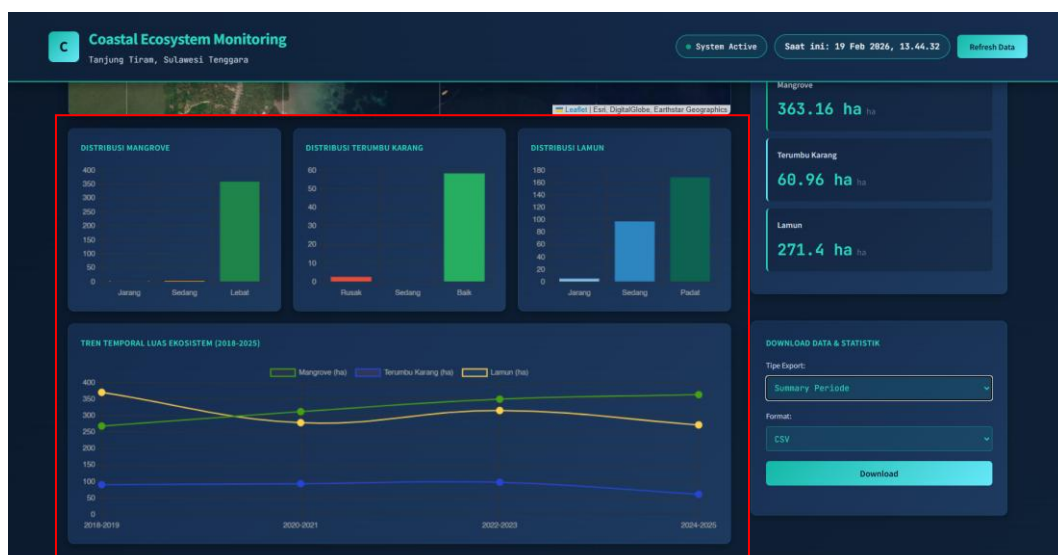
Gambar 5 menampilkan implementasi dashboard utama pada sistem pemantauan ekosistem pesisir yang dikembangkan dalam penelitian ini. Antarmuka dirancang dengan pendekatan *single-page interface*, di mana seluruh komponen informasi disajikan secara terpadu dalam satu tampilan terintegrasi yang mencakup peta spasial, statistik kuantitatif, serta rekomendasi mitigasi berbasis sistem cerdas. Pada bagian header ditampilkan indikator status operasional sistem (*System Active*) serta informasi waktu akses terakhir sebagai penanda bahwa data yang disajikan merupakan hasil pemrosesan terbaru. Penyusunan elemen antarmuka dilakukan secara hierarkis dan terstruktur guna meningkatkan keterbacaan informasi serta memudahkan pengguna dalam melakukan interpretasi kondisi ekosistem pesisir tanpa harus berpindah antar halaman tampilan.

Gambar 6 memperlihatkan fitur peta spasial interaktif yang menggunakan *base map* citra satelit resolusi tinggi sebagai referensi geografis wilayah kajian. Peta ini dilengkapi dengan panel kontrol layer yang bersifat interaktif, sehingga pengguna dapat mengaktifkan atau menonaktifkan visualisasi sebaran ekosistem *mangrove*, terumbu karang, dan padang lamun sesuai kebutuhan analisis. Setiap keluaran klasifikasi yang dihasilkan oleh model *UNet-ResNet34* ditampilkan dalam bentuk *overlay* semi-transparan dengan skema warna yang berbeda untuk masing-masing kelas ekosistem. Pendekatan visual ini memungkinkan identifikasi lokasi, pola distribusi spasial, serta hubungan antar ekosistem pesisir dilakukan secara langsung dan intuitif pada tingkat wilayah Tanjung Tiram.



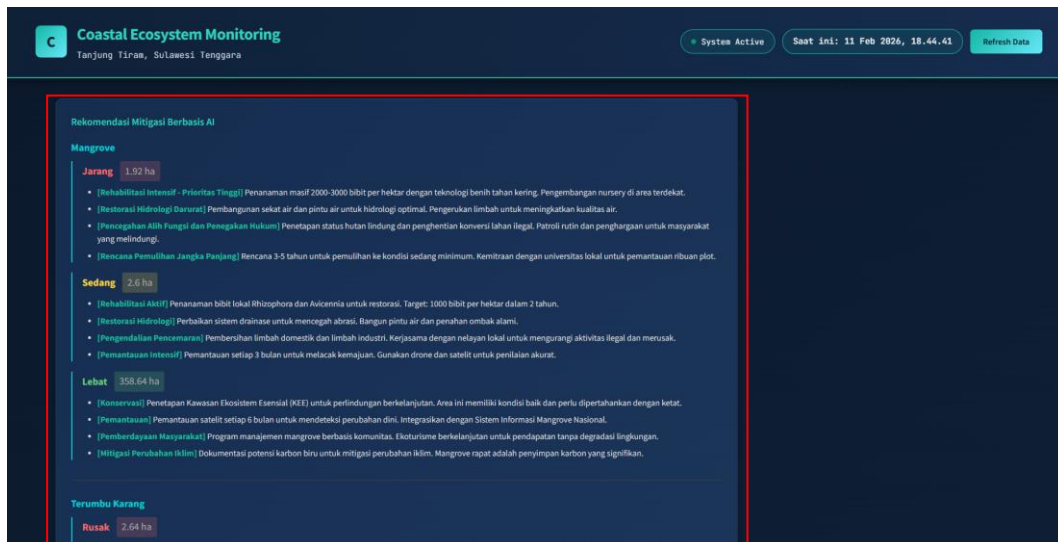
Gambar 6. Tampilan Peta Spasial dan Layer Interaktif

Pada Gambar 7, sistem menyajikan visualisasi statistik yang terstruktur ke dalam tiga komponen utama. Pertama, panel statistik numerik yang menampilkan besaran luasan ekosistem dalam satuan hektar (ha) untuk setiap kelas ekosistem hasil klasifikasi. Informasi ini memberikan gambaran kuantitatif mengenai kondisi aktual masing-masing ekosistem pada periode pengamatan tertentu. Kedua, grafik batang (*bar chart*) yang merepresentasikan distribusi kondisi kesehatan ekosistem ke dalam kategori tematik, seperti “Jarang”, “Sedang”, dan “Lebat” untuk ekosistem *mangrove* serta kategori “Baik”, “Sedang”, dan “Rusak” untuk terumbu karang, serta “Jarang”, “Sedang”, dan “Padat” untuk ekosistem lamun. Penyajian ini memungkinkan pengguna melakukan evaluasi komposisi kondisi ekosistem secara komparatif antar kelas dalam satu periode waktu. Ketiga, grafik garis (*line chart*) yang menggambarkan dinamika perubahan luasan ekosistem pesisir dari tahun 2018 hingga 2025. Visualisasi tren temporal ini berfungsi sebagai indikator awal (*early indicator*) terhadap kecenderungan degradasi maupun proses pemulihan lingkungan yang terjadi secara bertahap. Melalui pola fluktuasi grafik, pengguna dapat dengan mudah mengidentifikasi periode-periode kritis perubahan ekosistem serta mengaitkannya dengan potensi faktor penyebab, seperti tekanan antropogenik atau kebijakan rehabilitasi yang diterapkan. Demikian, integrasi ketiga komponen visualisasi ini tidak hanya mendukung interpretasi spasial, tetapi juga memperkuat analisis kuantitatif dan temporal dalam sistem pemantauan ekosistem pesisir berbasis *web*.



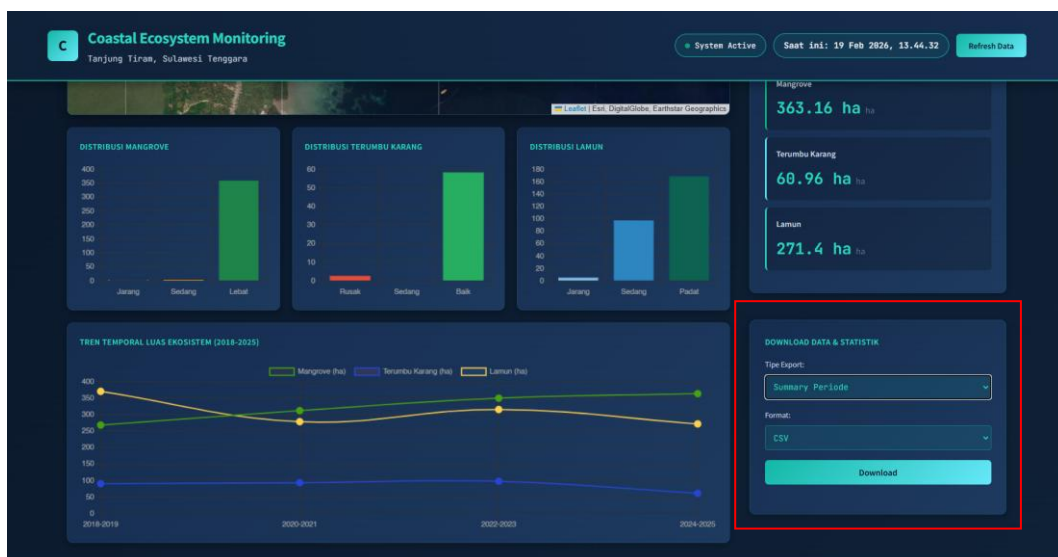
Gambar 7. Tampilan Grafik Distribusi Kondisi dan Tren Temporal

Bagian terpenting dari sistem ditunjukkan pada Gambar 8, yaitu implementasi panel Rekomendasi Mitigasi Berbasis AI. Panel ini berfungsi untuk menerjemahkan hasil analisis teknis menjadi informasi kebijakan yang operasional. Sistem secara otomatis menghasilkan narasi rekomendasi mitigasi berdasarkan kondisi ekosistem yang terdeteksi. Sebagai contoh, pada kategori *mangrove* dengan kondisi “Jarang”, sistem memberikan rekomendasi seperti rehabilitasi intensif, restorasi hidrologi, serta pencegahan alih fungsi lahan. Rekomendasi ini mencakup aspek perlindungan, pemulihan, dan pengelolaan berkelanjutan, yang dihasilkan berdasarkan logika inferensi dari luasan dan kondisi ekosistem hasil pemodelan AI.



Gambar 8. Tampilan Rekomendasi Mitigasi Berbasis AI Terintegrasi

Selanjutnya, Gambar 9 menampilkan fitur ekspor data dan laporan melalui panel *Download Data & Statistic*. Fitur ini dirancang untuk mendukung interoperabilitas data antar instansi, di mana pengguna dapat memilih jenis data yang akan diekspor serta format file yang diinginkan. Data yang diekspor meliputi ringkasan statistik luasan ekosistem dan hasil analisis temporal. Sehingga, hasil pemantauan tidak hanya berhenti pada visualisasi antarmuka, tetapi juga dapat dimanfaatkan untuk penyusunan laporan resmi, presentasi kebijakan, maupun analisis lanjutan menggunakan perangkat lunak Sistem Informasi Geografis (SIG) eksternal.



Gambar 9. Tampilan Fitur Ekspor Data dan Laporan

Implementasi antarmuka ini menunjukkan bahwa sistem yang dikembangkan tidak hanya mampu melakukan klasifikasi berbasis *Deep Learning*, tetapi juga menyediakan sarana visualisasi dan pengambilan keputusan yang praktis dan mudah digunakan. Integrasi antara model *UNet-ResNet34*, *Web-GIS*, serta modul rekomendasi mitigasi menjadikan sistem ini sebagai *platform* pemantauan ekosistem pesisir yang bersifat operasional dan mendukung pengelolaan wilayah pesisir secara berkelanjutan.

Integrasi Rekomendasi Mitigasi Berbasis Kecerdasan Buatan

Tahap akhir evaluasi sistem dilakukan melalui analisis korelasi antara perubahan spasio-temporal luasan ekosistem dan fitur mitigasi otomatis yang dihasilkan oleh *Decision Support System (DSS)*. Modul ini berfungsi sebagai instrumen interpretatif yang menerjemahkan keluaran klasifikasi menjadi rekomendasi pengelolaan yang berorientasi kebijakan dengan mengacu pada kerangka tata kelola pesisir internasional. Secara khusus, logika mitigasi diselaraskan dengan standar global restorasi ekosistem karbon biru yang ditetapkan oleh *Intergovernmental Oceanographic Commission of*

UNESCO serta pedoman *International Maritime Organization* terkait perlindungan *Particularly Sensitive Sea Areas* (PSSA). Melalui integrasi ini, sistem tidak hanya menghasilkan analisis spasial deskriptif, tetapi juga berkembang menjadi perangkat pendukung pengambilan keputusan lingkungan yang relevan secara kebijakan.

Berdasarkan tren temporal yang terdeteksi, sistem secara otomatis mengaktifkan modul mitigasi sesuai dengan ambang batas degradasi yang telah ditetapkan untuk setiap jenis ekosistem. Pada ekosistem terumbu karang yang menunjukkan penurunan bersih sebesar 32,39%, DSS memprioritaskan intervensi berbasis restorasi. Program rehabilitasi darurat melalui metode transplantasi fragmen karang direkomendasikan sejalan dengan pedoman restorasi IOC-UNESCO yang menekankan pemulihan keanekaragaman hayati pada kawasan ekologis kritis. Selain itu, mengacu pada regulasi IMO, sistem mengusulkan penetapan zona terbatas guna mencegah kerusakan fisik lanjutan akibat aktivitas jangkar kapal dan pencemaran operasional di wilayah terumbu yang terdegradasi di kawasan pesisir Tanjung Tiram.

Pada ekosistem padang lamun, penurunan luasan sebesar 98,76 ha memicu rekomendasi strategis yang berfokus pada pengelolaan sedimentasi dan perlindungan substrat dasar perairan. Pola mitigasi yang diusulkan mengadopsi prinsip *Nature-based Solutions* (NbS) yang dipromosikan oleh IOC-UNESCO, di mana konservasi lamun diarahkan untuk memperkuat fungsi perlindungan garis pantai serta mempertahankan perannya sebagai penyerap karbon aktif (*blue carbon sink*). Korelasi antara penurunan luas lamun dan peningkatan tingkat kekeruhan perairan semakin menegaskan bahwa pengendalian sedimen dari daratan merupakan prioritas utama dalam strategi pengelolaan ekosistem ini. Sebaliknya, ekosistem *mangrove* menunjukkan tren positif dengan peningkatan luasan sebesar 35,53%, sehingga sistem merekomendasikan strategi konservasi dan pemeliharaan jangka panjang, bukan restorasi darurat. Rekomendasi tersebut meliputi penetapan kawasan ekosistem esensial serta penerapan praktik pengelolaan berkelanjutan dalam kerangka *Integrated Coastal Area Management* (ICAM). Langkah-langkah ini sejalan dengan pendekatan yang diakui secara internasional untuk meningkatkan ketahanan ekosistem terhadap variabilitas iklim jangka panjang dan tekanan antropogenik.

Melalui analisis korelasi yang terintegrasi dengan standar tata kelola internasional, model *UNet-ResNet34* tidak hanya berfungsi sebagai alat klasifikasi statis, tetapi berkembang menjadi sistem peringatan dini yang operasional. Kemampuan untuk mengonversi keluaran kuantitatif *Deep Learning* menjadi strategi mitigasi yang terstruktur dan selaras dengan kebijakan menunjukkan tingkat reliabilitas sistem yang tinggi sebagai platform pendukung keputusan berbasis data. Integrasi ini memperkuat keterkaitan antara analitik penginderaan jauh dan kerangka pengelolaan laut global, sehingga mendukung perencanaan konservasi berbasis bukti ilmiah dan tata kelola ekosistem pesisir yang berkelanjutan di wilayah Tanjung Tiram.

KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini berhasil mengembangkan dan mengimplementasikan suatu kerangka pemantauan ekosistem pesisir terpadu berbasis arsitektur *Deep Learning* hibrida *UNet-ResNet34* dengan memanfaatkan citra multi-temporal Sentinel-2. Model yang diusulkan menunjukkan kinerja klasifikasi yang kuat dengan capaian akurasi keseluruhan sebesar 84,31% dan nilai *Macro ROC-AUC* sebesar 0,92. Integrasi *backbone ResNet34* memungkinkan ekstraksi fitur spektral dan tekstural yang kompleks secara efektif, sehingga mampu membedakan kelas ekosistem *mangrove*, terumbu karang, dan lamun secara andal meskipun terdapat ambiguitas spektral serta gangguan kolom air yang khas pada lingkungan pesisir tropis.

Analisis spasio-temporal periode 2018–2025 mengungkapkan dinamika ekologi yang signifikan di wilayah pesisir Tanjung Tiram. Luasan *mangrove* mengalami peningkatan sebesar 35,53% (+95,20 ha), yang sejalan dengan fenomena *natural rehabilitation* selama periode pandemi COVID-19 serta keberhasilan beberapa program rehabilitasi lokal. Sebaliknya, ekosistem terumbu karang dan lamun menunjukkan tren penurunan yang cukup besar, masing-masing sebesar 32,39% dan 26,68%. Perbedaan pola ini mengindikasikan bahwa meskipun vegetasi pesisir menunjukkan tingkat resiliensi yang relatif baik, ekosistem bentik masih sangat rentan terhadap proses sedimentasi serta tekanan antropogenik yang berasal dari aktivitas daratan.

Integrasi *platform Web-GIS* dengan modul rekomendasi mitigasi berbasis kecerdasan buatan (*AI-driven mitigation engine*) memungkinkan hasil klasifikasi kuantitatif diterjemahkan menjadi arahan pengelolaan yang operasional. Pendekatan ini menjembatani kesenjangan antara analisis berbasis *Deep Learning* dan kebutuhan pengambilan keputusan yang relevan secara kebijakan, sehingga sistem yang dikembangkan berpotensi menjadi alat yang skalabel, efisien, dan aplikatif untuk mendukung tata kelola pesisir yang berkelanjutan serta sejalan dengan Tujuan Pembangunan Berkelanjutan (*Sustainable Development Goal 14*).

Saran untuk Penelitian Selanjutnya

1. Peningkatan kualitas dan variasi data pelatihan
Peneliti menyarankan untuk menambah variasi *dataset* label melalui teknik augmentasi data, khususnya pada kelas dengan performa rendah seperti Terumbu Karang Rusak dan Lamun Padat. Selain itu, verifikasi lapangan (*ground check*) secara berkala menggunakan metode sampling yang representatif perlu dilakukan untuk meminimalkan misklasifikasi spektral serta menjaga stabilitas akurasi model dalam jangka panjang.
2. Integrasi parameter lingkungan perairan tambahan
Penelitian selanjutnya perlu mengintegrasikan variabel oseanografi seperti suhu permukaan laut (*Sea Surface Temperature*), tingkat kekeruhan (*turbidity*), dan konsentrasi klorofil-a. Pendekatan multi-parameter ini memungkinkan sistem tidak hanya mendeteksi perubahan luasan ekosistem, tetapi juga menganalisis faktor-faktor penyebab degradasi ekosistem bawah laut secara lebih komprehensif.
3. Optimasi performa sistem dan visualisasi *Web-GIS*
Perlu dilakukan peningkatan efisiensi sinkronisasi data pada sisi *backend* serta optimasi pemrosesan *tile* peta di *server*. Upaya ini bertujuan untuk mempercepat waktu muat visualisasi peta spasio-temporal berskala besar, sehingga aksesibilitas dan pengalaman pengguna (*User Experience*) pada dashboard monitoring berbasis *web* menjadi lebih responsif dan optimal.

Secara keseluruhan, penelitian ini menunjukkan bahwa integrasi citra satelit Sentinel-2 dan *arsitektur Deep Learning UNet-ResNet34* mampu menghasilkan informasi spasial yang andal untuk pemantauan ekosistem pesisir secara multi-temporal. Sistem yang dikembangkan memiliki potensi besar sebagai platform pendukung pengambilan keputusan berbasis data dalam perencanaan konservasi dan pengelolaan pesisir yang berkelanjutan di wilayah Tanjung Tiram dan kawasan pesisir lainnya dengan karakteristik serupa.

DAFTAR PUSTAKA

- [1] P. Pidella and E. Mokodompit, "Sustainable Development Goal 14: Menuju Pembangunan Berkelanjutan Berbasis Laut di Indonesia," *Kohesi: Jurnal Multidisiplin Saintek*, vol. 8, no. 11, pp. 1–8, 2025, doi: 10.8734/Kohesi.v1i2.365.
- [2] L. M. Salayan, H. Wulandari, and M. K. Huda, "Peran Ekosistem Laut dalam Konservasi Keanekaragaman Hayati di Indonesia," *Journal of Natural Sciences*, vol. 5, no. 3, pp. 234–244, Nov. 2024, doi: 10.34007/jonas.v5i3.717.
- [3] M Ambari, "Mangrove dan Lamun, Ekosistem Penting di Wilayah Pesisir Laut," Mongabay. Accessed: Oct. 13, 2025. [Online]. Available: <https://mongabay.co.id/2022/12/16/mangrove-dan-lamun-ekosistem-penting-di-wilayah-pesisir-laut/>
- [4] S. Adibrata, W. Adi, F. Angelia, and U. Komarullah, "Reef Fish Community Structure in The Waters of Small Islands Central Bangka Regency," *Nekton*, vol. 4, no. 1, pp. 1–15, Mar. 2024, doi: 10.47767/nekton.v4i1.724.
- [5] Peraturan BPK, "Peraturan Pemerintah Republik Indonesia Nomor 27 Tahun 2025 Tentang Pengelolaan Ekosistem Mangrove," 2025. Accessed: Oct. 13, 2025. [Online]. Available: <https://peraturan.bpk.go.id/Details/320198/pp-no-27-tahun-2025>
- [6] Yus Rusila Noor, "Mangrove Breakthrough Menjaga 20 Persen Hutan Mangrove Dunia Untuk Masa Depan," Wetlands International. Accessed: Oct. 13, 2025. [Online]. Available: <https://indonesia.wetlands.org/id/mangrove-breakthrough-menjaga-20-persen-hutan-mangrove-dunia-untuk-masa-depan/>
- [7] M. F. Purnama, A. G. Pratikino, A. Abdullah, L. O. A. Afu, and M. T. F. Erawan, "Niche Architecture of Thalassina Anomala in The Mangrove Ecosystem of Tanjung Tiram Village, South Konawe Regency - Southeast Sulawesi," *Jurnal Perikanan Budidaya Berkelanjutan*, vol. 4, no. 1, pp. 1–8, 2020.
- [8] E. Kurniawati, D. Apdillah, and J. Safitri, "Pemetaan Habitat Bentik Menggunakan Citra Sentinel-2a dengan Algoritma Maximum Likelihood Classification di Desa Pengudang," *J. Mar. Res.*, vol. 14, no. 2, pp. 263–276, May 2025, doi: 10.14710/jmr.v14i2.48946.
- [9] A. R. Basar and B. Irawan, "Rancang Bangun Aplikasi Absensi Berbasis Webcam dan Geolokasi Pada Badan Pengusahaan Batam," *JT-IBSI: Jurnal Teknik Ibnu Sina*, vol. 10, no. 1, pp. 144–155, Jun. 2025, doi: 10.36352/jt-ibsi.v10i1.1189.
- [10] European Space Agency, "S2 Mission," SentiWiki.
- [11] Valentina Boccia and Zoltan Szantoi, "Copernicus Sentinel-2 Mission: Calibration and Validation Activities," *GSICS: Global Space-based Inter-Calibration System*, vol. 52, no. 1, pp. 253–255, 2020.

- [12] P. Turissa *et al.*, “Sentinel-2A Multispectral Image Analysis for Seagrass Mapping in Bintan’s Shallow Water Ecosystem: A Case Study of Teluk Bakau, Malang Rapat, and Berakit villages,” *Kuwait Journal of Science*, vol. 51, no. 4, pp. 2307–4108, Oct. 2024, doi: 10.1016/j.kjs.2024.100286.
- [13] L. O. Alifatri, B. Prayudha, and K. Anggraini, “Klasifikasi Habitat Bentik Berdasarkan Citra Sentinel-2 di Kepulauan Kei, Maluku Tenggara,” *Jurnal Ilmu Pertanian Indonesia*, vol. 27, no. 3, pp. 372–384, Jul. 2022, doi: 10.18343/jipi.27.3.372.
- [14] R. Amelia and dan Darmansyah, “Potensi Google Earth Engine Untuk Identifikasi Objek Wilayah Perairan Pada Citra Satelit Sentinel-2,” *EQUIVA JOURNAL Journal of Mathematics & Information Technology*, vol. 1, no. 1, pp. 19–24, 2023, doi: <https://doi.org/10.35718/equiva.v1i1.759>.
- [15] N. C. I. Natun and S. Sumarlin, “Analisis Perbandingan Klasifikasi Supervised dan Unsupervised Citra Satelit Landsat Untuk Pemetaan Penutupan Lahan di Kabupaten Kupang,” *Jurnal Manajemen Informatika Jayakarta*, vol. 5, no. 2, pp. 142–152, Mar. 2025, doi: 10.52362/jmijayakarta.v5i2.1812.
- [16] H. Wang, J. Wu, and C. Chen, “Expanding Horizons: U-Net Enhancements for Semantic Segmentation of Ocean Remote Sensing Images,” *Journal of Remote Sensing*, vol. 4, pp. 1–5, 2024, doi: 10.34133/remotesensing.0196.
- [17] A. Ramdhani, Y. Widhiyasana, and S. Rachmat, “Perbandingan Model U-Net dan ELU-Net Untuk Segmentasi Semantik Citra Medis Kanker Pankreas,” *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 14, no. 1, pp. 44–51, Feb. 2025, doi: 10.22146/jnteti.v14i1.15262.
- [18] H. Fahmi, “Patch Based Classification Using ResNet for Land Cover Changes Detection of Batu City,” *MATICS: Jurnal Ilmu Komputer dan Teknologi Informasi*, vol. 14, no. 2, pp. 64–69, 2022.
- [19] D. Pamundi, Wiharto, and E. Suryani, “Power-Line Road Segmentation Menggunakan Improved Residual Networks,” *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 10, no. 2, pp. 237–244, 2024, doi: <https://doi.org/10.26418/jp.v10i2.77946>.
- [20] S. Darmawan, N. N. Nurulhakim, and R. Hernawati, “Kecerdasan Buatan Berbasis Geospasial (GeoAI) Menggunakan Google Earth Engine Untuk Monitoring Fenomena Urban Heat Island di Indonesia,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 12, no. 2, pp. 303–320, Apr. 2024, doi: 10.26760/elkomika.v12i2.303.
- [21] D. Apriyanti, I. Layali, M. Gomereuzzaman, N. W. Pratiwi, and R. D. Martasari, “Monitoring Perubahan Tutupan Lahan Kabupaten Klaten Tahun 2019 dan 2023 Selama Pembangunan Jalan Tol Yogyakarta – Solo Menggunakan Google Earth Engine (GEE),” *Jurnal Geodesi dan Geomatika*, vol. 08, no. 01, pp. 1–11, 2025, doi: <https://doi.org/10.14710/baf.v%v.%i.%Y.%p>.
- [22] D. Mirwansyah, A. Solichin, R. Hardi, N. Sari, N. Rizki, and D. Aldo, “Augmentasi Citra Pohon Kelapa Sawit untuk Deteksi Objek Berbasis Deep Learning,” *Metrik Jurnal*, vol. 9, no. 1, pp. 195–202, 2025, doi: 10.47002/metik.v9i1.1001.
- [23] R. A. Saputra, L. M. G. Jaya, and E. N. P. Hermas, “Using Support Vector Machine to Identify Land Cover Change Detection in Komodo National Park During COVID-19 Pandemic,” *Geodesy and Cartography*, vol. 75, no. 2, pp. 1–12, 2024, doi: 10.22364/geodesy.2.2024.