

Seminar Nasional Rekatek (OPTIMASI MODEL CNN YOLOv8 UNTUK KLASIFIKASI BINER LIMBAH PLASTIK MENGGUNAKAN CITRA SATELIT SENTINEL 2A)

Ahmad Selao^{1,*}, Sudirman Sahidin², Fitri Indah Yani³, M Jabir Muhammadia⁴

¹Teknik informatika, Teknik, Universitas Muhammadiyah Parepare, Jl. Jend Ahmad Yani, 91113

² Teknik informatika, Teknik, Universitas Muhammadiyah Parepare, Jl. Jend Ahmad Yani, 91113

³Perikanan, Pertanian Perikanan Peternakan, Universitas Muhammadiyah Parepare, Jl. Jend Ahmad Yani, 91113

⁴Teknik Sipil, Teknik, Universitas Muhammadiyah Parepare, Jl. Jend. Ahmad Yani, 91113

ahmadselao@umpar.ac.id (Korespondensi)*

Abstrak: Akumulasi sampah plastik di lingkungan pesisir pada skala regional hingga global menuntut adanya sistem pemantauan otomatis berbasis satelit. Tantangan utama dalam klasifikasi biner plastik/non-plastik terletak pada fenomena *mixed-pixel* (piksel campuran) yang melekat pada sensor satelit beresolusi menengah. Tantangan ini mendorong penggunaan validasi *ground-truth* independen dan melalui citra drone atau Unmanned Aerial Vehicle (UAV). Penelitian ini bertujuan untuk mengembangkan kerangka kerja dan mengevaluasi kinerja model CNN untuk klasifikasi sampah plastik laut menggunakan citra *true-color*, Sentinel-2A di wilayah pesisir sekitar Parepare, Selat Makassar, Sulawesi Selatan, Indonesia (119,58°–119,68° BT, 3,95°–4,10° LS), dengan validasi independen yang dilakukan melalui survei UAV dan data indeks spektral, yaitu *Plastic Index*, (PI), *Floating Debris Index*, (FDI), dan *Normalized Difference Water Index*, (NDWI). Metodologi ini mengintegrasikan empat teknologi inti ke dalam alur kerja klasifikasi spasial otomatis: pemrosesan data citra Sentinel-2A, pemrograman Python 3, visualisasi dan konstruksi dataset, berbasis QGIS 4, serta arsitektur CNN klasifikasi YOLOv8 sebagai inti dari model, *deep learning*. Model dilatih menggunakan 387 ubin (*patch*) dari citra RGB *true-color*, Sentinel-2A pada bulan April 2026. Data NDWI, FDI, dan PI digunakan sebagai validator spektral independen pasca-klasifikasi, bukan sebagai fitur masukan model. Hasil penelitian menunjukkan kinerja model yang memuaskan dengan akurasi 94,8% (*macro F1-score*: 94,8%) Temuan ini mengindikasikan bahwa model tersebut mampu melakukan klasifikasi biner sampah plastik dan non-plastik secara memadai menggunakan citra RGB *true-color*, Sentinel-2A. Model ini diusulkan sebagai *benchmark* dalam pemantauan sampah plastik laut pesisir secara global.

Kata kunci: Klasifikasi-sampah-plastik; Citra Sentinel-2A; Convolutional Neural Network; Indeks spektral; UAV

Abstract: The accumulation of plastic waste in coastal environments at regional to global scales necessitates automated satellite-based monitoring systems. A major challenge in binary plastic/non-plastic classification lies in the *mixed-pixel* phenomenon inherent to medium-resolution satellite sensors. This research aims to develop framework and evaluated the performance a CNN model for marine plastic debris classification using Sentinel-2A *true-color* imagery, conducted the coastal area around of the Makassar Strait, South Sulawesi, Indonesia (119.58°–119.68°E, 3.95°–4.10°S), with independent validation performed through UAV surveys and spectral index data, namely the *Plastic Index* (PI), *Floating Debris Index* (FDI), and *Normalized Difference Water Index* (NDWI). The methodology integrates four core technologies into an automated spatial classification pipeline: Sentinel-2A image data processing, Python 3 programming, QGIS 4-based visualization and dataset construction, and the YOLOv8 Classification CNN architecture as the core of deep learning model. The model was trained using 387 patches of Sentinel-2A RGB *true-color* in April 2026. NDWI, FDI, and PI data were exclusively used as independent post-classification spectral validators, rather than as model input features. The results demonstrate satisfactory model performance with achieving accuracy of 94.8% (*macro F1-score*: 94.8%). These findings indicated that the model was capable of adequately binary classification of plastic and non-plastic debris from Sentinel-2A *true-color* RGB imagery.

Keywords: Plastic waste classification; Multispektral imagery; Sentinel-2A imagery; Convolutional neural network; Spectral index; UAV ground truth

1. Pendahuluan

Polusi plastik telah menjadi salah satu krisis lingkungan paling kritis pada abad ke-21, dengan perkiraan 8 juta metrik ton plastik masuk ke lautan global setiap tahunnya [1]. Pemantauan spasial yang efektif dalam skala luas memerlukan solusi penginderaan jauh yang otomatis, berbiaya rendah, dan dapat diulang. Satelit Sentinel-2A, yang dioperasikan di bawah program Copernicus milik European Space Agency, menyediakan citra multispektral dengan resolusi spasial 10 meter dan siklus kunjungan ulang 5 hari, menjadikannya platform utama untuk pemantauan sampah plastik secara operasional [2]. Penelitian yang ada sejauh ini sebagian besar mengandalkan indeks spektral klasik: Floating Debris Index (FDI) [1], Plastic Index (PI) [3], dan Normalized Difference Vegetation Index (NDVI). Indeks-indeks ini memanfaatkan reflektansi NIR dan SWIR untuk mengeksploitasi tanda serapan hidrokarbon yang bersifat diagnostik dari polimer sintetis pada panjang gelombang 931–2313 nm [4]. Benchmark MARIDA oleh Kikaki dkk. [5] menetapkan FDI dan NDVI sebagai fitur paling diskriminatif untuk klasifikasi sampah laut berbasis Sentinel-2, dan paradigma berbasis indeks ini terus mendominasi pemantauan satelit skala besar, sebagaimana dikonfirmasi oleh tinjauan sistematis terbaru yang mencakup periode 2024–2026 [2],[6],[7].

Penelitian yang lebih baru [8] memperkenalkan indeks spektral tambahan untuk meningkatkan keterpisahan antara plastik dan non-plastik di perairan pesisir. Secara paralel, deep Convolutional Neural Network (CNN) telah menunjukkan kemampuan pembelajaran fitur visual end-to-end tanpa memerlukan rekayasa fitur spektral secara manual. Arsitektur YOLOv8 Classification (Ultralytics) telah diterapkan untuk pengenalan sampah dan puing [9],[10],[11], namun belum ada penelitian sebelumnya yang secara sistematis mengevaluasi YOLOv8-clas pada patch True Color RGB berukuran 32×32 piksel dari data multispektral Sentinel-2A dengan indeks spektral yang digunakan murni sebagai validator independen pascaklasifikasi. Makalah ini memberikan tiga kontribusi utama: (1) kerangka kerja dua jalur (dual-pathway) yang secara tegas memisahkan proses pembelajaran CNN (hanya input True Color RGB) dari penjaminan kualitas berbasis indeks spektral independen (NIR/SWIR); (2) evaluasi multispektral sistematis pada tiga periode musiman yang mengungkap pengaruh atmosfer terhadap kinerja klasifikasi; dan (3) dataset benchmark yang dapat direproduksi sebanyak 1.234 patch yang divalidasi melalui ground truth UAV.

Metode Berbasis Indeks Spektral untuk Deteksi Plastik

Damayanti dkk. [3] menerapkan FDI (yang diadaptasi dari Floating Algae Index) dan PI bersama NDVI untuk mendeteksi bercak plastik pesisir menggunakan citra Sentinel-2 di perairan Indonesia, memvalidasi kedua indeks tersebut terhadap target plastik yang telah diketahui. Pendekatan fitur multi-indeks yang menggabungkan FDI, PI, dan NDVI sebagai input classifier SVM dan Random Forest pada Sentinel-2 [12] telah melaporkan peningkatan akurasi yang konsisten dibandingkan baseline berbasis band saja, mengonfirmasi keunggulan kumpulan fitur multi-indeks. Costa dkk. [13] menerapkan pendekatan serupa untuk deteksi plastik pesisir, sementara Sannigrahi dkk. [12] mencapai akurasi 99,0% pada kondisi terkontrol menggunakan SVC, ANN, dan RF dengan fitur multispektral penuh. Perbandingan multi-classifier terbaru [14] mengonfirmasi bahwa metode ensemble seperti RF dan SVC secara konsisten mengungguli classifier yang lebih sederhana, semakin memvalidasi efektivitas pendekatan berbasis indeks spektral pada data Sentinel-2. Tinjauan sistematis terbaru [8] mengidentifikasi bahwa FDI, ketika digunakan sendiri, sering menghasilkan positif palsu akibat material yang secara spektral mirip seperti rumput laut *Sargassum* dan buih alami, sehingga memerlukan NDVI sebagai diskriminator pelengkap. Temuan ini mendasari penggunaan beberapa indeks sebagai validator alih-alih mengandalkan satu indeks tunggal untuk penetapan kelas secara definitif — sebuah prinsip yang tertanam dalam desain dual-pathway yang diusulkan. Kikaki dkk. [15] memberikan tinjauan komprehensif terhadap pendekatan deep learning yang diterapkan pada Sentinel-2 untuk deteksi polusi laut, mencatat bahwa metode gabungan spektral-spasial umumnya mengungguli pendekatan yang murni spektral atau murni spasial.

Klasifikasi Sampah Berbasis CNN dan YOLO

Zhou dkk. [10] menerapkan YOLOv8 untuk klasifikasi sampah dan mencapai akurasi 90% pada dataset berisi 15.000 gambar dengan 44 kategori. Angdresey dkk. [11] membandingkan YOLOv8 untuk deteksi dengan MobileNetV2 dan EfficientNet untuk klasifikasi dalam konteks Indonesia, melaporkan akurasi EfficientNet sebesar 93% pada aliran data sampah dari kamera web. Di dkk. [16] mengusulkan ES-YOLOv8 dengan mekanisme atensi untuk deteksi sampah padat terapung, mengatasi tantangan deteksi objek kecil dalam konteks penginderaan jauh. Pendekatan YOLOv8 dua tahap yang menggabungkan deteksi dan klasifikasi berbutir halus (fine-grained) menunjukkan efektivitas dalam skenario pengelolaan sampah kota kognitif (cognitive city), menunjukkan fleksibilitas YOLOv8 di berbagai konteks penerapan.

CNN Berbasis Patch untuk Klasifikasi Penginderaan Jauh

Dataset benchmark berbasis patch terbaru untuk klasifikasi tutupan lahan [17] mengonfirmasi bahwa paradigma berbasis patch, yang diterapkan pada skala serupa dengan dimensi 32×32 piksel yang digunakan dalam penelitian ini, secara konsisten mencapai akurasi klasifikasi tinggi (di atas 90%) pada berbagai jenis lanskap. Le dkk. [18] menunjukkan CNN berbasis patch dengan akurasi melebihi 90% untuk klasifikasi tutupan lahan menggunakan citra beresolusi menengah. Abdelmonem dkk. [19] mencapai akurasi 94,28% pada benchmark NWPU-RESISC45 dengan arsitektur CNN khusus untuk klasifikasi skena penginderaan jauh, yang nilainya mendekati kinerja April 2026 yang dilaporkan dalam makalah ini. Lu dkk. [20] mengembangkan model deep learning gabungan indeks-fitur-atensi spasial (IFSA_DLM) untuk pemetaan lahan bermulsa plastik skala besar dari Sentinel-2, mencapai OA sebesar 94,48% dan F1-score sebesar 93,38% — menunjukkan bahwa penggabungan indeks spektral dengan fitur spasial CNN dapat menghasilkan akurasi tinggi bahkan untuk tugas deteksi material yang menantang dalam skala besar. Aksoy dkk. [21] menunjukkan bahwa penyisipan fitur spektral tradisional ke dalam model CNN meningkatkan efisiensi klasifikasi tanpa mengorbankan akurasi, memperkuat nilai integrasi pengetahuan domain dalam CNN penginderaan jauh.

Zaid dkk. [22] menunjukkan bahwa transfer learning dengan MobileNetV2 pada citra satelit Google mencapai akurasi 96%, menyoroti pentingnya pemilihan arsitektur maupun strategi transfer learning untuk klasifikasi penginderaan jauh. Tantangan ketidakseimbangan kelas dalam pelatihan CNN telah banyak didokumentasikan. Rezvani dan Wang [23] meninjau teknik-teknik pembelajaran untuk ketidakseimbangan kelas, mengonfirmasi adanya bias sistematis terhadap kelas mayoritas pada kondisi pelatihan yang tidak seimbang, serta menunjukkan bahwa fungsi loss standar menggeser batas keputusan menjauhi kelas minoritas — fenomena yang teramati langsung pada hasil model Februari 2026. Lebih lanjut, Rezvani dan Wang [23] memperluas basis bukti ini pada pendekatan berbasis sampling, algoritma, dan cost-sensitive, memperkuat bahwa metrik rata-rata makro (macro-averaged) tetap penting untuk evaluasi yang adil pada kondisi ketidakseimbangan kelas. Chraibi dkk. [24] menunjukkan bahwa koreksi atmosferik Sen2Cor dapat menunjukkan ketidakstabilan temporal yang cukup besar pada reflektansi bottom-of-atmosphere yang tidak dapat dijelaskan oleh perubahan sifat permukaan, memberikan dasar fisik yang masuk akal bagi penurunan kinerja temporal yang teramati pada Februari.

State-of-the-Art dan Perkembangan Terkait

Studi komparatif metode deep learning untuk peramalan — menggunakan LSTM, CNN-LSTM, LSTM-GRU, dan CNN-LSTM-GRU — dilakukan oleh Albi, Baginda, dan A. Rizal (2026) pada 1.269 observasi harian [31]. Pendekatan berbasis satelit tidak hanya digunakan untuk peramalan, tetapi juga untuk mendeteksi sampah plastik laut, dengan penelitian yang berkembang pada dua jalur metodologis yang sebagian besar terpisah. Jalur pertama mengandalkan indeks spektral yang secara fisik dapat diinterpretasikan — Plastic Index (PI), Floating Debris Index (FDI) [3], dan Normalized Difference Water Index — yang dihitung langsung dari reflektansi Sentinel-2. Tinjauan sistematis terbaru mengonfirmasi bahwa paradigma berbasis indeks ini tetap mendominasi pemantauan laut skala besar: Danilov dan Serdiukova [6] membandingkan classifier

berbasis indeks spektral dan machine learning pada berbagai studi deteksi plastik di wilayah perairan, dan menemukan bahwa indeks saja, meski dapat diinterpretasikan, sangat sensitif terhadap material yang muncul bersamaan seperti Sargassum dan buih alami, sejalan dengan strategi validasi multi-indeks yang diadopsi pada [8]. Upaya pelengkap, termasuk identifikasi plastik sungai berbasis SVC dengan akurasi 0,99 [14] dan pipeline puing terapung multispektral [2], mengonfirmasi bahwa classifier klasik mencapai kinerja tinggi pada kondisi terkontrol tetapi jarang mampu digeneralisasi lintas periode. Jalur kedua bergeser ke arah deep learning, khususnya detektor keluarga YOLO, yang mempelajari fitur visual diskriminatif langsung dari citra tanpa rekayasa spektral eksplisit. YOLOv8 dan penerusnya telah banyak diadaptasi untuk pengenalan sampah dalam konteks bawah air dan permukaan: YOLOTrashCan [10] dan SPPF-CGA [25] menyasar deteksi pada kondisi bawah air yang keruh dan berdinamika tinggi, sementara YOLOv8 yang ditingkatkan dengan RFACConv [26] meningkatkan sensitivitas objek kecil untuk puing di permukaan air. Selain deteksi objek, klasifikasi CNN berbasis patch telah tervalidasi sebagai alternatif yang tangguh dibandingkan pendekatan per-piksel untuk citra beresolusi menengah, dengan benchmark terbaru pada berbagai dataset tutupan lahan [17] memperkuat bahwa pembelajaran fitur pada level patch secara konsisten mengungguli klasifikasi per-piksel untuk target permukaan yang heterogen.

Kelompok penelitian ketiga yang bersifat komplementer menggunakan platform UAV untuk melakukan ground truth terhadap deteksi plastik yang dihasilkan oleh satelit atau model. Sozio dkk. [27] secara langsung membandingkan metodologi deteksi sampah berbasis UAV secara langsung dan tidak langsung di pantai, mengonfirmasi bahwa citra udara beresolusi tinggi secara substansial meningkatkan tingkat kepercayaan pada klasifikasi skala satelit, sejalan dengan komponen validasi UAV pada kerangka kerja penelitian ini. Proyek DEEP-PLAST [28] mencontohkan tren yang semakin berkembang menuju integrasi multi-model, menggabungkan YOLOv5 (UAV), U-Net++ (Sentinel-2), dan simulasi drift ke dalam satu pipeline operasional — namun bahkan sistem terintegrasi ini, seperti pada [12], memperlakukan bukti spektral dan visual sebagai tahapan yang berurutan, bukan sebagai tahapan yang divalidasi silang secara independen dalam satu keputusan klasifikasi yang sama.

Kesenjangan Penelitian dan Kebaruan

Meskipun aktivitas penelitian terbaru cukup luas, sejumlah temuan yang saling menguatkan dari literatur paling mutakhir (2024–2026) mendasari penelitian ini. Dua tinjauan komprehensif — tinjauan sistematis Potiracha dkk. 2026 [4] dan tinjauan kritis 2026 terhadap literatur deteksi plastik berbasis hiperspektral [7] — mengidentifikasi kurangnya integrasi lintas platform dan lintas metode sebagai persoalan yang masih terbuka, karena pendekatan berbasis indeks spektral dan deep learning umumnya dievaluasi secara terpisah, bukan digunakan untuk saling memvalidasi. Danilov dan Serdiukova [6] juga menunjukkan bahwa ketika indeks spektral dan classifier dibandingkan, tidak satu pun diperlakukan sebagai pemeriksa independen terhadap keluaran yang lain; klasifikasi dan konfirmasi spektral tetap digabungkan (concatenated), bukan dipisahkan menjadi tahap pembelajaran dan tahap validasi. Studi ground truth berbasis UAV seperti Sozio dkk. [27] memvalidasi deteksi pada titik akuisisi, tetapi belum memperluas logika ini ke pipeline satelit multispektral, sehingga konsistensi temporal lintas periode belum diperiksa.

Kekakuan (rigor) evaluasi juga menjadi perhatian pada set uji yang kecil dan tidak seimbang, yang lazim dijumpai pada domain ini: penelitian terbaru yang mengaitkan low-shot learning dengan evaluasi ketidakseimbangan kelas [29], bersama tinjauan yang lebih luas oleh Rezvani dan Wang [23], menunjukkan bahwa akurasi saja tidak memadai ketika set uji per periode berada di bawah kurang lebih seratus sampel — yang secara langsung berlaku pada partisi 58–67 sampel dalam penelitian ini — namun disiplin evaluasi semacam ini jarang diterapkan pada penelitian klasifikasi plastik berbasis Sentinel-2 sebelumnya. Terakhir, klasifikasi berbasis CNN oleh Fahmitra [30] terhadap plastik laut di perairan pesisir Indonesia (Tanjungpinang) mengonfirmasi


meningkatnya minat nasional pada topik ini, namun masih mengandalkan desain satu periode dan satu sumber validasi tanpa validasi silang spektral yang independen atau analisis multispektral.

Sintesis dari temuan-temuan ini mengungkap adanya kesenjangan metodologis spesifik yang belum ditangani hingga saat ini: belum ada penelitian yang ada — termasuk yang dipublikasikan tahun 2026 — yang menggabungkan jalur klasifikasi CNN yang hanya menggunakan True Color RGB, NDWI/FDI/PI yang sepenuhnya diposisikan sebagai validator independen pascaklasifikasi dan bukan sebagai fitur input, evaluasi multispektral sistematis pada periode akuisisi yang berbeda secara atmosferik, dan evaluasi berbasis macro-F1 yang sesuai untuk partisi uji yang kecil dan tidak seimbang, dalam satu kerangka kerja yang dapat direproduksi. Desain dual-pathway yang diusulkan dalam makalah ini secara langsung menjawab konvergensi kesenjangan tersebut.

2. Metode

Desain Penelitian dan Kerangka Konseptual

Alur kerja penelitian dimulai dengan akuisisi citra multispektral Sentinel-2A, yang dipilih untuk menangkap variabilitas temporal sampah plastik pada kondisi lingkungan yang berbeda-beda. Penggunaan observasi multispektral memungkinkan model mempelajari karakteristik spektral dan spasial sampah plastik yang beragam, sekaligus mengurangi pengaruh faktor lingkungan yang bersifat sementara seperti variabilitas iluminasi, kondisi pasang surut, dan dinamika gelombang permukaan.



Gambar 1. Kerangka kerja metodologis yang diusulkan untuk klasifikasi sampah plastik dan non-plastik laut pesisir secara end-to-end dari citra Sentinel-2A melalui integrasi CNN dan validasi multi-sumber dan multi-level yang independen.

Kerangka kerja ini dirancang untuk membangun alur kerja yang andal, yang menggabungkan pembelajaran pola spasial dari convolutional neural network (CNN) dengan penilaian konsistensi spektral dan verifikasi ground truth berbasis UAV. Strategi ini meningkatkan ketangguhan (robustness) dan generalisasi model klasifikasi dibandingkan analisis citra satu waktu (single-date). Komponen validasi kedua memanfaatkan citra UAV beresolusi tinggi dan data ground truth. Observasi UAV memberikan detail spasial yang jauh lebih halus dibandingkan citra Sentinel-2A, sehingga memungkinkan verifikasi visual langsung terhadap akumulasi plastik terapung dan mengurangi ketidakpastian akibat efek mixed-pixel. Integrasi observasi berbasis UAV memperkuat kredibilitas kerangka kerja yang diusulkan dengan menyediakan bukti lapangan yang independen sebagai pelengkap proses validasi spektral. Kombinasi validasi berbasis indeks spektral dan ground truth UAV membangun kerangka validasi multi-sumber yang komprehensif, yang mampu mengevaluasi baik fidelitas spektral maupun akurasi spasial dari prediksi CNN. Secara keseluruhan, kerangka kerja yang diusulkan mengintegrasikan observasi satelit multispektral, ekstraksi fitur berbasis deep learning, penilaian spektral independen, dan verifikasi lapangan berbantuan UAV ke dalam satu alur kerja terpadu untuk pemetaan sampah plastik laut. Penelitian ini menggunakan desain eksperimental kuantitatif untuk mengevaluasi kemampuan model Convolutional Neural Network (CNN) berbasis YOLOv8 Classification dalam membedakan objek plastik dan non-plastik pada citra True Color Sentinel-2A.

Kerangka penelitian dirancang menggunakan dua jalur analitis yang independen. Jalur pertama melibatkan proses deep learning, di mana model CNN dilatih hanya menggunakan patch citra True Color RGB sebagai input. Jalur kedua terdiri atas proses validasi independen yang memanfaatkan Normalized Difference Water Index (NDWI), Floating Debris Index (FDI), dan Plastic Index (PI) — indeks spektral yang dihitung secara terpisah dari proses pelatihan model.

Tabel 1. Peran Setiap Komponen dalam Kerangka Penelitian

Komponen	Fungsi	Bukan Berfungsi Sebagai
Patch True Color RGB	Input utama CNN	Validator independen
NDWI	Validasi pascaklasifikasi	Input CNN
FDI	Validasi sampah terapung	Fitur pembelajaran CNN
PI	Validasi karakteristik plastik	Bagian dari arsitektur CNN

Pendekatan ini dipilih untuk menjaga independensi antara proses pembelajaran dan proses validasi, guna memastikan bahwa kinerja model benar-benar mencerminkan kemampuan CNN dalam mempelajari informasi visual tanpa dipengaruhi oleh data spektral tambahan.

Akuisisi Data dan Penyusunan Dataset

Dataset penelitian disusun menggunakan citra Sentinel-2A Level-2A yang diperoleh melalui Copernicus Data Space Ecosystem untuk bulan Februari, April, dan Juni 2026. Akuisisi citra dilakukan dengan ambang batas tutupan awan maksimum 10% untuk meminimalkan gangguan atmosferik terhadap kualitas radiometrik citra. Citra kemudian dipotong menjadi patch berukuran $32 \times 32 \times 3$ piksel, dengan setiap patch mewakili area seluas kurang lebih 320×320 m di permukaan bumi. Ukuran patch ini dipilih untuk menyeimbangkan informasi spasial lokal, efisiensi komputasi, dan kemampuan model dalam mengenali pola visual objek plastik. Pelabelan plastik dan non-plastik dilakukan melalui interpretasi visual dalam lingkungan QGIS, dengan memanfaatkan citra UAV dan data ground truth. Titik pusat setiap patch ditentukan menggunakan python berdasarkan dominasi objek plastik atau non-plastik. Akuisisi awal menargetkan sekitar 450 patch per bulan (total 1.350 patch pada ketiga periode). Untuk meminimalkan kesalahan pelabelan, setiap sampel diberi tingkat keyakinan visual (visual confidence level), dan patch dengan tingkat keyakinan rendah dikeluarkan selama proses kontrol kualitas. Prosedur ini menghasilkan dataset akhir sebanyak 1.234 patch (447 pada Februari, 387 pada April, dan 400 pada Juni) yang memenuhi persyaratan kualitas untuk pelatihan dan evaluasi model.

Praproses Data

Seluruh tahap praproses dilakukan menggunakan Python, QGIS, dan GEE. Band B4, B3, dan B2 diekstraksi dan digabungkan menjadi citra RGB tiga kanal. Nilai reflektansi dinormalisasi ke rentang 8-bit melalui penskalaan linear dengan pemotongan (clipping) pada persentil ke-2 dan ke-98, sehingga mengurangi variasi kontras akibat nilai ekstrem tanpa kehilangan informasi visual yang penting. Koordinat hasil digitasi digunakan sebagai acuan untuk pemotongan patch citra secara otomatis. Secara bersamaan, band B6, B8, dan B11 diekstraksi untuk menghitung PI, FDI, dan NDWI menggunakan javascript pada GEE. Nilai-nilai indeks ini dihitung secara independen untuk setiap patch dan disimpan sebagai variabel validasi, serta tidak digunakan selama proses optimisasi jaringan.

Arsitektur CNN dan Strategi Pelatihan

Model klasifikasi dikembangkan menggunakan YOLOv8n-cls, dengan backbone CSP Darknet dan modul C2f yang dioptimalkan untuk klasifikasi citra berukuran kecil. Model ini menerima input tensor RGB berukuran $32 \times 32 \times 3$, yang berarti seluruh proses ekstraksi fitur sepenuhnya mengandalkan informasi visual True Color. Pelatihan dilakukan secara terpisah untuk setiap periode observasi selama 50 epoch, menggunakan optimizer Adam dengan learning rate awal

0,001 dan ukuran batch 16. Parameter beta mengikuti konfigurasi Adam standar, sementara augmentasi data — meliputi flip horizontal, random cropping dengan padding, dan color jitter ringan — diterapkan untuk meningkatkan kemampuan generalisasi tanpa secara signifikan mengubah karakteristik visual objek.

Pembagian Dataset dan Validasi Independen

Untuk setiap periode, dataset dibagi menjadi subset pelatihan 70%, validasi 15%, dan pengujian 15% menggunakan stratified sampling untuk menjaga distribusi kelas, yang dilakukan secara independen pada setiap periode untuk menghindari kontaminasi antarperiode. Setelah proses inferensi CNN, validasi independen dilakukan dengan membandingkan nilai NDWI, FDI, dan PI terhadap label klasifikasi menggunakan ambang batas yang diturunkan dari literatur. Untuk memprioritaskan verifikasi pada kelas yang paling relevan dengan tujuan klasifikasi penelitian ini, subsampel acak terstratifikasi sebesar 50% dari patch uji berlabel plastik diambil dari setiap periode sebelum dilakukan perbandingan spektral. Pendekatan ini menilai konsistensi semantik antara prediksi model dan karakteristik spektral tanpa memengaruhi pelatihan jaringan, sehingga CNN dan indeks spektral berfungsi sebagai sistem evaluasi yang saling melengkapi namun tetap independen secara metodologis.

Evaluasi Kinerja Model


Kinerja model dievaluasi menggunakan confusion matrix, yang menjadi dasar untuk menghitung akurasi, presisi, recall, F1-score, dan macro F1-score. Akurasi mengukur proporsi prediksi yang benar terhadap total sampel, sedangkan presisi mengevaluasi ketepatan prediksi kelas plastik. Recall mengukur kemampuan model dalam mendeteksi seluruh sampel plastik yang sebenarnya, dan F1-score memberikan keseimbangan antara presisi dan recall. Macro F1-score digunakan karena memberikan ukuran yang lebih representatif untuk dataset dengan distribusi kelas yang tidak seimbang. Selain evaluasi numerik, dinamika pelatihan dianalisis melalui kurva training loss, validation loss, dan validation accuracy sepanjang 50 epoch. Analisis ini membantu mengidentifikasi konvergensi, overfitting, dan underfitting, sehingga memungkinkan penilaian yang komprehensif terhadap stabilitas pembelajaran model. Kombinasi antara evaluasi kuantitatif dan validasi independen menggunakan NDWI, FDI, dan PI menciptakan kerangka evaluasi yang lebih tangguh dibandingkan hanya mengandalkan metrik klasifikasi semata; pendekatan ini tidak hanya mengukur kinerja prediktif, tetapi juga menilai konsistensi hasil klasifikasi dengan karakteristik spektral objek plastik pada citra Sentinel-2A.

3. Hasil dan Pembahasan

Kinerja Klasifikasi CNN Berbasis True Color RGB

Confusion Matrix Multitemporal

Bagian ini menyajikan confusion matrix untuk hasil klasifikasi model CNN YOLOv8 Classification — yang dilatih secara eksklusif menggunakan citra True Color RGB berukuran $32 \times 32 \times 3$ piksel — pada ketiga periode akuisisi, disertai visualisasi langsung untuk masing-masing periode.




Gambar 2. Confusion Matrix CNN True Color RGB April 2026

Confusion matrix menunjukkan akurasi sebesar 94,8% dengan hanya 3 kesalahan dari 58 sampel aktif, mengonfirmasi keterpisahan visual yang optimal untuk True Color RGB pada periode ini.

Dinamika Kurva Training Loss, Validation Loss, dan Validation Accuracy

Bagian ini menyajikan kurva dinamika pelatihan selama 50 epoch, menampilkan Training Loss dan Validation Loss (panel kiri), serta Validation Accuracy (panel kanan).



Gambar 3. Kurva Training/Validation Loss dan Accuracy menunjukkan konvergensi optimal dengan gap loss yang minimal

Kurva menunjukkan konvergensi paling ideal: training loss menurun secara halus dari ~0,73 menjadi ~0,21, sementara validation loss mengikuti tren serupa menuju ~0,28, menghasilkan gap akhir yang hanya ~0,07. Validation accuracy tetap stabil pada rentang 0,91–0,94 antara epoch 10 hingga 50, mengonfirmasi tidak adanya overfitting yang signifikan. Model menunjukkan konvergensi optimal, dengan loss minimal (~0,07) dan validation accuracy yang stabil (~0,92).

Hasil Validasi Indeks Spektral Independen menggunakan NDWI, FDI, dan PI

Hasil validasi independen antara label kelas patch dan karakteristik spektral — yang diukur melalui NDWI, FDI, dan PI, dihitung secara terpisah dari band NIR/SWIR Sentinel-2A dan tidak pernah dimasukkan sebagai input CNN — disajikan pada Tabel 2.

Tabel 2. Validasi Independen Label Patch terhadap NDWI, FDI, dan PI

Indeks	Validator Spektral Independen	Hasil Spektral Indeks Penelitian			Konsistensi dengan CNN
FDI	0,02 – 0,06	-0,002 – -0,49	-0,01 – 0,075	-0,05 – 0,07	Sebagian besar dalam rentang
PI	0,29 – 0,4	-0,05 – 0,48	0,29 – 0,41	0,35 – 0,42	Akurasi tinggi
NDWI	0,43 – 0,61	0,30 – 0,55	0,41 – 0,57	0,20 – 0,50	Sedang

4. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi YOLOv8 berbasis citra True Color RGB Sentinel-2A untuk mendeteksi sampah plastik di lingkungan perairan, sekaligus memvalidasi hasil klasifikasi menggunakan indeks spektral NDWI, FDI, dan PI sebagai validator independen. Hasil penelitian menunjukkan bahwa model berhasil mengidentifikasi sampah plastik dengan kinerja yang kuat pada seluruh periode observasi; kinerja terbaik dicapai dengan akurasi sebesar 94,8% dan macro F1-score sebesar 94,8%. Analisis dinamika pelatihan menunjukkan bahwa model mengalami proses konvergensi paling stabil pada periode tersebut, sementara validasi menggunakan NDWI, FDI, dan PI menunjukkan tingkat konsistensi tertinggi antara prediksi CNN dan karakteristik spektral objek. Temuan ini menunjukkan bahwa informasi visual dari citra True Color RGB sudah cukup untuk membangun representasi fitur yang diskriminatif bagi klasifikasi sampah plastik, tanpa memerlukan integrasi langsung fitur spektral ke dalam proses pembelajaran model. Kontribusi utama penelitian ini terletak pada pengembangan kerangka klasifikasi yang secara konseptual memisahkan proses pembelajaran visual berbasis RGB dari proses validasi berbasis indeks spektral, sehingga menghasilkan pendekatan yang lebih sederhana dan lebih mudah direplikasi namun tetap menghasilkan interpretasi hasil yang tangguh. Pendekatan ini berpotensi mendukung sistem pemantauan sampah plastik berbasis penginderaan jauh yang lebih efisien untuk pengelolaan lingkungan perairan. Meskipun demikian, penelitian ini masih memiliki keterbatasan dalam hal ukuran dataset, cakupan geografis, dan penggunaan satu jenis sensor optik saja. Oleh karena itu, penelitian selanjutnya disarankan untuk mengintegrasikan data multitemporal dan multisensor, serta pendekatan Explainable Artificial Intelligence (XAI), guna meningkatkan kemampuan generalisasi, interpretabilitas, dan akurasi klasifikasi pada berbagai kondisi lingkungan.

Ucapan Terima Kasih

1. Menteri Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia selaku pemberi dukungan dana penelitian ini.
2. Lembaga Penelitian dan Pengabdian kepada Masyarakat Universitas Muhammadiyah Parepare, atas dukungannya dalam menyetujui proposal penelitian ini.

Daftar Pustaka

- [1] Yu R-S, Yang Y-F, Singh S. Global analysis of marine plastics and implications of control measure strategies. *Front Mar Sci* 2023;10. <https://doi.org/10.3389/fmars.2023.1305091>.
- [2] Duarte MM, Azevedo L. Automatic Detection and Identification of Floating Marine Debris Using Multispectral Satellite Imagery. *IEEE Transactions on Geoscience and Remote Sensing* 2023;61:1–15. <https://doi.org/10.1109/TGRS.2023.3283607>.
- [3] Damayanti AD, Hanami ZA, Hirose K, Ainun S, Putra RD. Potential Marine Plastic Debris Detection using Sentinel-2 Multi-Spectral Instrument (MSI). *IOP Conf Ser Earth Environ Sci* 2022;1117:012054. <https://doi.org/10.1088/1755-1315/1117/1/012054>.

- [4] Potiracha Y, Baars RC. A review of remote sensing technology for plastic waste monitoring. *Environmental Science and Pollution Research* 2026;33:766–82. <https://doi.org/10.1007/s11356-025-37347-7>.
- [5] Kikaki K, Kakogeorgiou I, Mikeli P, Raitzos DE, Karantzalos K. MARIDA: A benchmark for Marine Debris detection from Sentinel-2 remote sensing data. *PLoS One* 2022;17:e0262247. <https://doi.org/10.1371/journal.pone.0262247>.
- [6] Danilov A, Serdiukova E. Review of Methods for Automatic Plastic Detection in Water Areas Using Satellite Images and Machine Learning. *Sensors* 2024;24:5089. <https://doi.org/10.3390/s24165089>.
- [7] Polák M, Kupková L. Advances and challenges in plastic detection: a critical review of studies employing hyperspectral data. *Int J Remote Sens* 2026;47:6228–87. <https://doi.org/10.1080/01431161.2026.2680715>.
- [8] Wu C, Chen Z, Peng C, An C. New spectral indices for identifying large plastic accumulations in coastal waters with sentinel-2 imagery. *Mar Pollut Bull* 2026;224:119009. <https://doi.org/10.1016/j.marpolbul.2025.119009>.
- [9] Di J, Xi K, Yang Y. An enhanced YOLOv8 model for accurate detection of solid floating waste. *Sci Rep* 2025;15:25015. <https://doi.org/10.1038/s41598-025-10163-2>.
- [10] Zhou Y, Lin L, Wang T. Garbage classification detection system based on the YOLOv8 algorithm. *AIP Adv* 2024;14. <https://doi.org/10.1063/5.0244795>.
- [11] Angdresey A, Kairupan IY, Mongkareng AG. Web-Based Waste Detection Using YOLOv8 and Classification Performance Comparison: MobileNet and EfficientNet. *International Journal of Image, Graphics and Signal Processing* 2025;17:1–18. <https://doi.org/10.5815/ijigsp.2025.06.01>.
- [12] Sannigrahi S, Basu B, Basu AS, Pilla F. Development of automated marine floating plastic detection system using Sentinel-2 imagery and machine learning models. *Mar Pollut Bull* 2022;178:113527. <https://doi.org/10.1016/j.marpolbul.2022.113527>.
- [13] Silva C de OF, Grego CR, Manzione RL, Oliveira SRDM, Rodrigues GC, Rodrigues CAG, et al. Summarizing soil chemical variables into homogeneous management zones – case study in a specialty coffee crop. *Smart Agricultural Technology* 2024;7:100418. <https://doi.org/10.1016/j.atech.2024.100418>.
- [14] Vadivel M, Alzaben N, Alamri MZ, Alshammerid M, Pammi SVN, Priya V. Machine Learning Based Identification of River Plastic Litter in Coastal Region Using Sentinel-2 Data: An Automated Approach for Marine Pollution Monitoring and Management. *Ocean Science Journal* 2025;60:48. <https://doi.org/10.1007/s12601-025-00246-6>.
- [15] Kikaki K, Kakogeorgiou I, Hoteit I, Karantzalos K. Detecting Marine pollutants and Sea Surface features with Deep learning in Sentinel-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing* 2024;210:39–54. <https://doi.org/10.1016/j.isprsjprs.2024.02.017>.
- [16] Di J, Xi K, Yang Y. An enhanced YOLOv8 model for accurate detection of solid floating waste. *Sci Rep* 2025;15:25015. <https://doi.org/10.1038/s41598-025-10163-2>.

- [17] Rengma NS, Yadav M. Generation and classification of patch-based land use and land cover dataset in diverse Indian landscapes: a comparative study of machine learning and deep learning models. *Environ Monit Assess* 2024;196:568. <https://doi.org/10.1007/s10661-024-12719-7>.
- [18] Le TD, Lee Y-J, Park E, Kim M-S, Eom TJ, Lee C. Synthetic polarization-sensitive optical coherence tomography using contrastive unpaired translation. *Sci Rep* 2024;14:31366. <https://doi.org/10.1038/s41598-024-82839-0>.
- [19] Abdelmonem AM, Ata MM, Atey AA, Shaalan AA, El-Sayed RA. High-performance scene classification in remote sensing imagery using a custom deep CNN architecture. *Sci Rep* 2026;16:5946. <https://doi.org/10.1038/s41598-025-34176-z>.
- [20] Lu L, Xu Y, Huang X, Zhang HK, Du Y. Large-scale mapping of plastic-mulched land from Sentinel-2 using an index-feature-spatial-attention fused deep learning model. *Science of Remote Sensing* 2025;11:100188. <https://doi.org/10.1016/j.srs.2024.100188>.
- [21] Aksoy MÇ, Sirmacek B, Ünsalan C. Land classification in satellite images by injecting traditional features to CNN models. *Remote Sensing Letters* 2023;14:157–67. <https://doi.org/10.1080/2150704X.2023.2167057>.
- [22] Abd Zaid MM, Mohammed AA, Sumari P. Remote Sensing Image Classification Using Convolutional Neural Network (CNN) and Transfer Learning Techniques. *Journal of Computer Science* 2025;21:635–45. <https://doi.org/10.3844/jcssp.2025.635.645>.
- [23] Rezvani S, Wang X. A broad review on class imbalance learning techniques. *Appl Soft Comput* 2023;143:110415. <https://doi.org/10.1016/j.asoc.2023.110415>.
- [24] Chraïbi E, de Boissieu F, Barbier N, Luque S, Féret J-B. Stability in time and consistency between atmospheric corrections: Assessing the reliability of Sentinel-2 products for biodiversity monitoring in tropical forests. *International Journal of Applied Earth Observation and Geoinformation* 2022;112:102884. <https://doi.org/10.1016/j.jag.2022.102884>.
- [25] Wang J, Han Q, Ge K, Sun L. SPPF-CGA: Marine Garbage Detection and Image Enhancement in Turbid and High-Dynamic Underwater Environments. *Journal of Ocean University of China* 2025;24:1301–14. <https://doi.org/10.1007/s11802-025-6087-5>.
- [26] Zhu W, Xu R. Research on an Improved YOLOv8 Algorithm for Water Surface Object Detection. *Electronics (Basel)* 2025;14:3615. <https://doi.org/10.3390/electronics14183615>.
- [27] Sozio A, Scarrica VM, Rizzo A, Aucelli PPC, Barracane G, Dimuccio LA, et al. Application of Direct and Indirect Methodologies for Beach Litter Detection in Coastal Environments. *Remote Sens (Basel)* 2024;16:3617. <https://doi.org/10.3390/rs16193617>.
- [28] Cernian A, Iliuta M-E. Empowering Sustainability Through AI-Driven Monitoring: The DEEP-PLAST Approach to Marine Plastic Detection and Trajectory Prediction for the Black Sea. *Water (Basel)* 2025;17:3318. <https://doi.org/10.3390/w17223318>.
- [29] Billion Polak P, Prusa JD, Khoshgoftaar TM. Low-shot learning and class imbalance: a survey. *J Big Data* 2024;11:1. <https://doi.org/10.1186/s40537-023-00851-z>.
- [30] Prayuda H, Rathomi MR, Fahmitra NF. Klasifikasi Sampah Laut Jenis Limbah Plastik Menggunakan Metode Convolutional Neural Network Backpropagation (Perairan Kota

Tanjungpinang). Jurnal Sains Dan Informatika 2025;11:130–9.
<https://doi.org/10.34128/jsi.v11i2.1644>.