



Rancang Bangun Model Segmentasi Semantik U-Net untuk Monitoring Lingkungan Tambang Berbasis Citra Satelit Sentinel-2

Syahrul Fadholi Gumelar^{1*}, Abdullah Nur Aziz², R. Farzand Abdullatif³

¹Magister Fisika, Fakultas MIPA, Universitas Jenderal Soedirman, Purwokerto, Jawa Tengah, Indonesia, 53122

^{2,3}Jurusan Fisika, Fakultas MIPA, Universitas Jenderal Soedirman, Purwokerto, Jawa Tengah, Indonesia, 53122

Email: *syahrul.gumelar@mhs.unsoed.ac.id¹, abd.nur.aziz@unsoed.ac.id², farzand@unsoed.ac.id³

Korespondensi penulis: syahrul.gumelar@mhs.unsoed.ac.id

Abstract. Open-pit mining activities in Indonesia contribute significantly to the national economy but require stringent monitoring to mitigate environmental degradation. Conventional monitoring methods relying on terrestrial surveys are often constrained by vast coverage areas, high operational costs, and limited field accessibility. This study aims to develop an artificial intelligence model capable of automatically detecting and mapping mining areas to enhance surveillance efficiency. The applied method is Deep Semantic Segmentation utilizing the U-Net Convolutional Neural Network (CNN) architecture. The model was trained using Sentinel-2 satellite imagery, focusing exclusively on Red, Green, and Blue (RGB) spectral channels to replicate human visual perception. Experimental results demonstrate that the proposed model performs reliable segmentation of mining areas, achieving an Accuracy of 93.58% and a Global Intersection over Union (IoU) of 0.8067. These findings indicate that the U-Net architecture can effectively extract spatial features of mines even when utilizing standard visual data. This research contributes to the development of an efficient, cost-effective, and scalable digital monitoring prototype to support innovation in sustainable environmental governance.

Keywords: Deep Learning, Mining Monitoring, Semantic Segmentation, Sentinel-2, U-Net


Abstrak. Aktivitas pertambangan terbuka di Indonesia memberikan kontribusi ekonomi yang signifikan namun memerlukan pengawasan ketat untuk memitigasi dampak kerusakan ekosistem. Metode pemantauan konvensional berbasis survei terestris sering terkendala oleh luasnya area, biaya tinggi, dan sulitnya aksesibilitas lapangan. Penelitian ini bertujuan untuk merancang bangun model kecerdasan buatan yang mampu mendeteksi dan memetakan area tambang secara otomatis guna mendukung efisiensi pengawasan. Metode yang diterapkan adalah Deep Semantic Segmentation menggunakan arsitektur Convolutional Neural Network (CNN) jenis U-Net. Model dilatih memanfaatkan citra satelit Sentinel-2 dengan fokus eksklusif pada kanal spektral Red, Green, dan Blue (RGB) untuk mereplikasi persepsi visual manusia. Hasil eksperimen menunjukkan bahwa model yang dibangun mampu melakukan segmentasi area tambang dengan performa yang andal, mencapai Akurasi sebesar 93,58% dan Global Intersection over Union (IoU) sebesar 0,8067. Temuan ini mengindikasikan bahwa arsitektur U-Net mampu mengekstraksi fitur spasial tambang secara efektif meski hanya menggunakan data visual standar. Penelitian ini berimplikasi pada tersedianya purwarupa sistem monitoring digital yang efisien, murah, dan berskala luas untuk mendukung inovasi tata kelola lingkungan berkelanjutan.

Kata kunci: Deep Learning, Monitoring Tambang, Segmentasi Semantik, Sentinel-2, U-Net

1. LATAR BELAKANG

Indonesia merupakan negara dengan kekayaan sumber daya mineral yang melimpah, menjadikan sektor pertambangan sebagai salah satu pilar utama perekonomian nasional (Setiawan, 2025). Berdasarkan data Badan Pusat Statistik (BPS), sektor pertambangan dan penggalian secara konsisten memberikan kontribusi signifikan terhadap Produk Domestik Bruto (PDB), dengan angka mencapai lebih dari 10% dalam beberapa tahun terakhir sesuai

dengan diagram batang pada Gambar 1 dibawah ini (Barri, 2021; Irham, 2024). Namun, tingginya aktivitas ekstraksi sumber daya alam ini membawa konsekuensi lingkungan yang serius, terutama pada metode penambangan terbuka (Prasetyo, 2025). Metode ini mengharuskan pengupasan lapisan tanah penutup yang menyebabkan perubahan tutupan lahan secara drastis, deforestasi, dan pembentukan lubang-lubang galian raksasa (Alhabsyi dkk, 2024). Tanpa pengawasan yang ketat, area bekas tambang berpotensi menjadi lahan kritis yang merusak keseimbangan ekosistem (Putri, 2023). Tantangan utama saat ini terletak pada keterbatasan kapasitas pengawasan manual, di mana rasio jumlah inspektur tambang tidak sebanding dengan luas wilayah Izin Usaha Pertambangan (IUP) yang tersebar di ribuan pulau, menyebabkan proses pengawasan menjadi tidak efisien dan berbiaya tinggi (Sonic, 2024).



Sumber: Badan Pusat Statistik (2023).

Gambar 1. Diagram Kontribusi Sektor Usaha pada PDB Indonesia Tahun 2023

Untuk mengatasi kendala pengawasan konvensional, teknologi penginderaan jauh yang dipadukan dengan kecerdasan buatan (*Artificial Intelligence*) menjadi solusi yang menjanjikan (Hasyim, 2023). Dalam beberapa tahun terakhir, metode *Deep Learning* telah mendominasi tugas pengenalan pola otomatis (Fantin, 2022). Salah satu arsitektur yang menjadi standar emas dalam tugas segmentasi semantik adalah U-Net (Rajamani dkk, 2023). Namun, secara historis, arsitektur U-Net diperkenalkan dan dikembangkan secara spesifik untuk domain citra medis (Naraloka, 2024). Pada implementasi aslinya, U-Net dirancang untuk bekerja pada citra mikroskopis yang umumnya berskala keabuan (*grayscale*) atau satu dimensi kanal, dengan tujuan mendeteksi struktur selular mikro yang memiliki batas visual yang samar (Ayu, 2024).

Terdapat kesenjangan penelitian yang menarik untuk dieksplorasi ketika mengadaptasi arsitektur yang didesain untuk citra medis satu kanal ini ke dalam domain penginderaan jauh. Citra satelit, seperti Sentinel-2, memiliki karakteristik yang sangat berbeda dengan citra medis (El Hamdi dkk, 2024), yakni mencakup area makro yang sangat luas dan memiliki dimensi spektral yang lebih kaya, minimal terdiri dari kanal *Red*, *Green*, dan *Blue* (RGB) (Al Fathoni, 2025). Belum banyak studi yang secara spesifik menguji limitasi dan kemampuan adaptasi arsitektur U-Net, dari yang awalnya hanya memproses intensitas cahaya tunggal (*grayscale*) untuk menangani kompleksitas informasi warna pada citra satelit optis RGB dalam konteks deteksi tambang di wilayah tropis. Kebaruan penelitian ini terletak pada investigasi ketangguhan arsitektur medis tersebut dalam memetakan pola lingkungan yang kompleks tanpa memerlukan modifikasi arsitektur yang rumit atau penambahan data multispektral yang berat.

Berdasarkan analisis tersebut, penelitian ini bertujuan untuk merancang bangun dan mengevaluasi kinerja model segmentasi semantik U-Net yang diadaptasi untuk input citra satelit Sentinel-2 berbasis RGB. Penelitian ini berfokus pada pembuktian konsep bahwa arsitektur yang efisien pada citra medis juga dapat diandalkan untuk mendeteksi area tambang terbuka, sehingga dapat dimanfaatkan sebagai purwarupa sistem monitoring digital yang akurat, cepat, dan mudah diinterpretasikan secara visual oleh regulator lingkungan.

2. KAJIAN TEORITIS

A. Penginderaan Jauh dan Karakteristik Area Tambang

Pertambangan terbuka (*open-pit mining*) memiliki karakteristik spasial dan spektral yang unik dibandingkan dengan tutupan lahan lainnya (Li dkk, 2024). Secara visual, area tambang ditandai dengan hilangnya vegetasi, terbukanya lapisan tanah, serta terbentuknya pola geometris tertentu seperti jenjang dan kolam bekas galian (Kuzevic, 2022). Penginderaan jauh menggunakan citra satelit menjadi metode yang efektif untuk memantau perubahan ini (Santoso, 2025). Satelit Sentinel-2 yang diluncurkan oleh *European Space Agency* (ESA) seperti yang ditunjukkan pada Gambar 2 dibawah menyediakan data multispektral dengan resolusi spasial hingga 10 meter pada kanal visible (*Red*, *Green*, *Blue*) dan *Near-Infrared* (NIR) (Zhen dkk, 2023). Dalam penelitian ini, fokus diletakkan pada pemanfaatan kanal RGB untuk mereplikasi persepsi visual manusia dalam mengidentifikasi fitur tambang, memanfaatkan data Level-2A yang telah melalui koreksi atmosferik *Bottom-of-Atmosphere* (BOA) untuk meminimalkan gangguan bias atmosfer.




Sumber: European Space Agency

Gambar 2. Satelit Sentinel 2

B. Deep Semantic Segmentation dan Arsitektur U-Net

Semantic segmentation adalah tugas dalam *Computer Vision* yang bertujuan untuk mengklasifikasikan setiap piksel dalam citra ke dalam kelas tertentu (Mau dkk, 2022). Berbeda dengan klasifikasi citra standar yang hanya memberikan satu label untuk satu gambar utuh, segmentasi memungkinkan pemetaan batas wilayah yang presisi (Li dkk, 2022). Landasan utama penelitian ini adalah arsitektur U-Net, sebuah varian dari *Convolutional Neural Network* (CNN) yang diperkenalkan oleh Ronneberger dkk. (2015). Arsitektur ini dinamai U-Net karena bentuk simetrisnya yang menyerupai huruf "U". Struktur U-Net terdiri dari dua jalur utama, yaitu jalur kontraksi atau *encoder* dan jalur ekspansi atau *decoder*. *Encoder* berfungsi untuk menangkap konteks gambar dan mengekstraksi fitur melalui proses *convolution* dan *max pooling*. Pada tahap ini, dimensi spasial citra diperkecil secara bertahap. *Decoder* berfungsi untuk mengembalikan resolusi spasial citra (*upsampling*) agar sesuai dengan ukuran input, memungkinkan lokalisasi fitur yang presisi (Panda dkk, 2022).

Inovasi kunci dari U-Net adalah adanya *skip connections* yang menghubungkan lapisan pada *encoder* langsung ke lapisan *decoder* yang bersesuaian (Qian dkk, 2022). Fitur ini memungkinkan informasi spasial mendetail yang seringkali hilang saat proses *downsampling* untuk digabungkan kembali saat rekonstruksi citra. Secara teoritis, desain ini dikembangkan untuk segmentasi citra biomedis (seperti sel mikroskopis) yang umumnya berupa citra *grayscale* (1 kanal) seperti yang ditunjukkan pada Gambar 3. Adaptasi arsitektur ini ke dalam domain penginderaan jauh dengan input multispektral (3 kanal RGB) menjadi dasar eksplorasi dalam penelitian ini..



Sumber: Ronneberger, 2015

Gambar 3. Arsitektur Model U-Net 1 Kanal

C. Tinjauan Penelitian Terdahulu

Beberapa penelitian sebelumnya telah berupaya mengembangkan metode deteksi tambang otomatis. Pendekatan konvensional menggunakan algoritma *Machine Learning* klasik seperti *Support Vector Machine* (Purboyo, 2024) atau *Random Forest* (Waladi, 2025) berbasis indeks spektral (NDVI, NDBI) seringkali menghasilkan banyak *noise* atau *false positive* karena kemiripan spektral antara tanah tambang dan lahan pertanian kering (Marlina, 2022).


Penelitian lanjutan mulai mengadopsi *Deep Learning*. Studi yang dilakukan oleh peneliti lain menunjukkan bahwa CNN mampu mengungguli metode klasik dalam membedakan fitur tambang yang kompleks (Guetari, 2023). Namun, mayoritas penelitian tersebut menggunakan kombinasi band yang berat (seperti memasukkan kanal SWIR dan *Thermal*) atau arsitektur yang sangat dalam (seperti DeepLabV3+), yang menuntut komputasi tinggi (Ali dkk, 2022). Penelitian ini mengambil pendekatan berbeda dengan menyederhanakan input hanya menggunakan kanal RGB pada arsitektur U-Net yang ringan. Hipotesis implisit yang dibangun adalah bahwa kemampuan U-Net dalam mengekstraksi fitur konteks spasial (bentuk lubang tambang, tekstur jalan angkut) mampu mengkompensasi keterbatasan informasi spektral pada citra RGB, sehingga dapat menghasilkan model deteksi yang akurat namun tetap efisien secara komputasi.

3. METODE PENELITIAN

A. Desain dan Alur Penelitian

Penelitian ini menerapkan pendekatan eksperimental dengan kerangka kerja pengembangan sistem berbasis *Deep Learning*. Tahapan penelitian dirancang secara sistematis mulai dari persiapan, akuisisi data, pengembangan model, hingga evaluasi kinerja. Secara visual, alur penelitian yang dilakukan dapat dilihat pada Gambar 1.

Proses diawali dengan pengumpulan data citra satelit menggunakan *platform Google Earth Engine* (GEE), yang dilanjutkan dengan proses anotasi manual untuk memisahkan area tambang (objek) dan non-tambang (latar belakang) menggunakan perangkat lunak ArcGIS. Dataset yang telah dianotasi kemudian melalui tahap prapemrosesan sebelum digunakan untuk melatih model arsitektur U-Net.



Sumber: Penulis

Gambar 4. Diagram Alir Penelitian

B. Populasi dan Pengumpulan Data


Populasi data dalam penelitian ini adalah citra satelit Sentinel-2 Level-2A (*Bottom-of-Atmosphere*) yang meliputi area pertambangan terbuka di wilayah Indonesia. Instrumen pengumpulan data memanfaatkan *Application Programming Interface* (API) dari Google Earth Engine untuk mengunduh citra pada kanal *Red*, *Green*, dan *Blue* (RGB).

Teknik pengambilan sampel dilakukan dengan metode *purposive sampling*, memilih area yang bebas dari tutupan awan signifikan $<10\%$. Data citra asli yang memiliki dimensi spasial besar dipotong-potong menjadi ukuran seragam 256×256 piksel untuk menyesuaikan dengan input model. Proses ini menghasilkan pasangan data berupa citra asli dan citra topeng biner

yang merepresentasikan *ground truth*. Dataset kemudian dibagi dengan rasio 80:20 untuk data latih dan data uji.

C. Arsitektur Model U-Net

Model penelitian yang digunakan adalah *Convolutional Neural Network* (CNN) dengan arsitektur U-Net yang dimodifikasi untuk menerima input 3 kanal (RGB). Arsitektur ini terdiri dari dua jalur utama: jalur kontraksi (*encoder*) untuk ekstraksi fitur dan jalur ekspansi (*decoder*) untuk lokalisasi presisi. Detail spesifikasi lapisan yang diusulkan disajikan dalam Gambar 5 dibawah ini.



Sumber: Penulis

Gambar 5. Arsitektur Model U-Net 3 Kanal yang Diusulkan

Pada tahap *Encoder*, citra input berdimensi (256, 256, 3) diproses melalui empat blok konvolusi bertingkat. Setiap blok terdiri dari operasi konvolusi diikuti fungsi aktivasi ReLU dan *Max Pooling* 2×2 untuk mereduksi dimensi spasial namun meningkatkan kedalaman fitur (dari 64 hingga 512 filter). Bagian *Bridge* menghubungkan *encoder* dan *decoder* menggunakan 1024 filter. Pada tahap *Decoder*, dilakukan operasi *UpSampling* untuk mengembalikan dimensi spasial, yang digabungkan (*concatenation*) dengan peta fitur dari *encoder* yang bersesuaian (*skip connection*) guna mempertahankan informasi detail lokasi. Lapisan terakhir menggunakan konvolusi 1×1 dengan fungsi aktivasi *Sigmoid* untuk menghasilkan peta probabilitas biner (256, 256, 1) yang membedakan area tambang dan non-tambang.


D. Analisis Data dan Evaluasi

Pelatihan model dilakukan menggunakan fungsi kerugian *Binary Cross Entropy* dan pengoptimal *Adam*. Evaluasi kinerja model diukur menggunakan metrik standar untuk segmentasi semantik, yaitu akurasi, *intersection over union* (IoU), presisi dan *recall*. IoU menghitung rasio irisan antara area prediksi dan *ground truth* terhadap gabungan keduanya. Nilai metrik yang dihasilkan akan diinterpretasikan untuk menentukan tingkat keandalan model dalam mendeteksi area tambang.

4. HASIL DAN PEMBAHASAN

A. Hasil Akuisisi Data Citra Area Tambang

Tahap awal penelitian melibatkan pengunduhan dan seleksi citra satelit Sentinel-2 Level-2A melalui platform *Google Earth Engine*. Data yang diakuisisi difokuskan pada kanal *Red*, *Green*, dan *Blue* (RGB) untuk merepresentasikan kenampakan visual permukaan bumi secara natural. Gambar 6 menampilkan lima sampel citra *full scene* yang berhasil dikumpulkan dari lokasi studi. Secara visual, area pertambangan terbuka dapat diidentifikasi dengan jelas melalui rona warna yang kontras; area tambang cenderung memiliki warna coklat kemerahan hingga putih terang akibat pembukaan lahan (*bare soil*), yang sangat berbeda dengan area vegetasi atau hutan di sekitarnya yang berwarna hijau gelap.



Sumber: Sentinel 2 diolah oleh Penulis

Gambar 6. Visualisasi Data Citra Keseluruhan


Untuk melatih model agar mampu mengenali pola tambang tersebut, dilakukan proses anotasi manual oleh tenaga ahli untuk membuat label kebenaran dasar (*ground truth*). Gambar 7 memperlihatkan hasil visualisasi data *ground truth* yang bersesuaian dengan citra pada Gambar 6. Hasil anotasi ini berupa citra topeng biner (*binary mask*), di mana piksel berwarna putih (nilai 1) merepresentasikan kelas area tambang, sedangkan piksel berwarna hitam (nilai 0) merepresentasikan kelas latar belakang (*background*) atau non-tambang. Kualitas anotasi ini sangat krusial karena menjadi acuan utama model dalam mempelajari fitur spasial tambang.



Sumber: Sentinel 2 diolah oleh Penulis

Gambar 7. Visualisasi Data *Ground Truth* Area Tambang

Mengingat dimensi citra *full scene* yang sangat besar dan keterbatasan memori komputasi (*GPU Memory*), citra utuh tersebut tidak dapat langsung dimasukkan ke dalam jaringan saraf tiruan. Oleh karena itu, dilakukan proses pemotongan citra (*tiling*) menjadi ukuran patch 256×256 piksel. Gambar 8 menyajikan sampel hasil pemotongan tersebut, yang terdiri dari pasangan (a) Citra Asli RGB dan (b) Citra *Ground Truth*. Melalui proses ini, model U-Net dapat mempelajari detail tekstur dan batas pinggir tambang secara lebih spesifik pada resolusi lokal. Kumpulan *patch* citra inilah yang kemudian dibagi menjadi dataset pelatihan dan pengujian untuk tahap selanjutnya.




Sumber: Sentinel 2 diolah oleh Penulis

Gambar 8. Visualisasi Data Citra Hasil Pemotongan (a) Citra Asli (b) Citra *Ground Truth*

B. Evaluasi Proses Pelatihan Model

Proses pelatihan model U-Net dilakukan sebanyak 50 *epoch* untuk memastikan model memiliki waktu yang cukup dalam mempelajari fitur spasial area tambang. Dinamika pembelajaran model dipantau melalui tiga indikator kinerja utama, yaitu nilai *Loss*, metrik *Intersection over Union* (IoU), dan Akurasi, sebagaimana disajikan pada Gambar 9. Grafik tersebut menampilkan perbandingan performa model terhadap data latih (garis biru) dan data validasi (garis oranye) di setiap iterasinya.



Sumber: Penulis

Gambar 9. Grafik Evaluasi Proses Pelatihan Model


Berdasarkan grafik *Loss* (kiri), terlihat bahwa kurva *Train Loss* menurun secara konsisten dan stabil hingga mendekati angka 0,2 di akhir pelatihan. Hal ini mengindikasikan bahwa model berhasil meminimalkan kesalahan prediksi dan mampu mempelajari pola data latih dengan sangat baik. Namun, pada kurva *Validation Loss*, terlihat adanya fluktuasi yang cukup dinamis setelah *epoch* ke-10. Penurunan tajam terjadi pada awal pelatihan, tetapi kemudian mengalami osilasi (naik-turun). Fenomena ini wajar terjadi pada kasus segmentasi citra dengan dataset terbatas, yang mengindikasikan bahwa model sedang berusaha mencari generalisasi terbaik pada data baru yang belum pernah dilihat sebelumnya.

Pola serupa juga terlihat pada grafik *IoU Metric* (tengah) dan *Accuracy* (kanan). Pada 5 *epoch* pertama, nilai IoU validasi berada di angka 0, yang menunjukkan fase "cold start" di mana model belum mampu membentuk mask segmentasi yang bermakna. Namun, lonjakan signifikan terjadi setelah *epoch* ke-10, di mana akurasi validasi melesat naik mendekati 90% dan IoU mencapai kisaran 0,7-0,8. Meskipun kurva validasi terlihat bergerigi (*noisy*) ini menandakan adanya tantangan model dalam mengklasifikasikan beberapa *patch* validasi yang kompleks. Tren secara umum menunjukkan peningkatan performa. Untuk mendapatkan model terbaik, penelitian ini tidak mengambil model dari *epoch* terakhir, melainkan menggunakan teknik *Model Checkpoint* untuk menyimpan bobot model pada *epoch* dengan nilai *Validation IoU* tertinggi, yang pada akhirnya menghasilkan skor IoU global sebesar 0,8067.

C. Analisis Kinerja Model

Untuk memvalidasi kemampuan generalisasi model pada data uji yang belum pernah dilihat sebelumnya, dilakukan analisis komparatif antara hasil prediksi model dengan label *ground truth*. Gambar 10 menyajikan visualisasi hasil prediksi model pada beberapa sampel area uji. Secara kualitatif, model mampu mendelienasi batas area tambang dengan cukup presisi, mengikuti kontur bukaan lahan yang tidak beraturan. Kemampuan ini dikonfirmasi

melalui perhitungan piksel pada *Confusion Matrix* yang dirangkum dalam Tabel 1. Dari total jutaan piksel yang dievaluasi, model berhasil mengidentifikasi 1.071.717 piksel sebagai *True Positive* (TP), yang berarti area tambang terdeteksi dengan benar, dan 2.671.447 piksel sebagai *True Negative* (TN) atau latar belakang yang tepat diabaikan. Tingginya angka TN wajar terjadi mengingat dalam satu *scene* citra, area non-tambang (hutan/pemukiman) memang mendominasi luasan area (*class imbalance*).



Sumber: Penulis

Gambar 10. Visualisasi Hasil Prediksi Model

Tabel 1. Hasil Kinerja *Confusion Matrix* Model

Komponen	Nilai (piksel)
<i>True Positive</i> (TP)	1071717
<i>True Negative</i> (TN)	2671447
<i>False Positive</i> (FP)	136320
<i>False Negative</i> (FP)	120500

Sumber: Penulis


Berdasarkan komponen matriks kebingungan tersebut, dihitung metrik evaluasi standar sebagaimana ditampilkan pada Tabel 2. Model mencatatkan nilai Akurasi global yang sangat tinggi yaitu 93,58%. Namun, mengingat ketidakseimbangan kelas pada kasus ini, indikator utama yang menjadi rujukan adalah *Intersection over Union* (IoU). Model berhasil mencapai IoU sebesar 80,67%, sebuah capaian yang signifikan untuk input data yang hanya berbasis RGB tanpa bantuan kanal inframerah. Lebih lanjut, keseimbangan antara nilai *Precision* (88,72%) dan *Recall* (89,89%) menunjukkan stabilitas model. Nilai *Recall* yang mendekati 90% mengindikasikan bahwa model memiliki sensitivitas tinggi; dari seluruh area tambang yang ada di lapangan, hampir 90%-nya berhasil dideteksi oleh sistem. Hal ini sangat krusial untuk fungsi pengawasan, di mana meminimalkan area tambang yang terlewat (*missed detection*) lebih prioritas daripada menghindari sedikit alarm palsu.

Tabel 2. Hasil Kinerja Metrik Evaluasi Model

Komponen	Nilai
<i>Intersection over Union (IoU)</i>	80,67%
Akurasi	93,58%
Presisi	88,72%
<i>Recall</i>	89,89%

Sumber: Penulis

Meskipun kinerja model secara umum memuaskan, analisis mendalam terhadap kesalahan prediksi tetap diperlukan. Gambar 11 memvisualisasikan dua jenis kesalahan utama model. Pada kasus (a) Deteksi Berlebih (*False Positive*), model keliru mengklasifikasikan lahan pertanian kering atau tanah terbuka non-tambang sebagai tambang. Kesalahan ini menyumbang 136.320 piksel (FP) pada Tabel 1, yang kemungkinan disebabkan oleh kemiripan spektral warna tanah pada citra RGB. Sebaliknya, pada kasus (b) Deteksi Kurang (*False Negative*), model gagal mendeteksi sebagian area tambang, terutama pada bagian tepi yang mulai tertutup vegetasi semak atau area yang tertutup bayangan awan tipis. Sebanyak 120.500 piksel (FN) terlewatkan dalam skenario ini. Temuan ini menegaskan bahwa meskipun input RGB cukup andal untuk deteksi umum, tantangan spektral pada objek yang ambigu tetap menjadi batasan yang perlu diantisipasi.



Sumber: Penulis

Gambar 11. Visualisasi Kesalahan Model (a) Deteksi Berlebih (b) Deteksi Kurang

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan pembahasan, dapat disimpulkan bahwa penelitian ini berhasil merancang bangun model segmentasi semantik berbasis Deep Learning menggunakan arsitektur U-Net untuk mendeteksi area tambang terbuka di Indonesia. Hasil pengujian empiris menunjukkan bahwa meskipun hanya memanfaatkan informasi visual dasar dari kanal Red, Green, dan Blue (RGB) citra Sentinel-2, model mampu mengenali dan memetakan pola tambang dengan kinerja yang andal. Hal ini dibuktikan dengan capaian nilai Intersection over Union (IoU) global sebesar 0,8067 dan tingkat Akurasi mencapai 93,58%. Tingginya nilai Recall yang mendekati 90% juga mengindikasikan bahwa arsitektur U-Net sangat efektif dalam

mengekstraksi fitur spasial area tambang yang kompleks, menjadikannya solusi alternatif yang terbukti layak secara teknis untuk mengatasi keterbatasan jangkauan dan efisiensi metode pengawasan manual.

Implikasi praktis dari temuan ini adalah tersedianya purwarupa sistem pemantauan digital yang dapat direkomendasikan sebagai alat bantu (decision support tool) bagi regulator lingkungan maupun inspektur tambang. Sistem ini dapat diterapkan sebagai mekanisme deteksi dini (early warning system) untuk memindai wilayah konsesi yang luas secara cepat dan berbiaya rendah. Dengan adanya automasi deteksi, prioritas inspeksi lapangan dapat diarahkan secara lebih spesifik pada lokasi-lokasi yang terindikasi mengalami perubahan tutupan lahan, sehingga efisiensi waktu dan anggaran operasional pengawasan dapat ditingkatkan secara signifikan guna mendukung tata kelola pertambangan yang berkelanjutan.

Kendati memberikan hasil yang menjanjikan, penelitian ini masih memiliki keterbatasan yang perlu diperhatikan, terutama pada aspek resolusi spektral. Pembatasan input pada kanal RGB mengakibatkan model terkadang mengalami ambiguitas dalam membedakan area tambang dengan objek lain yang memiliki kemiripan warna, seperti lahan pertanian kering atau tanah terbuka non-tambang, yang berkontribusi pada munculnya false positive. Selain itu, kinerja model juga terindikasi menurun pada area yang tertutup bayangan awan tipis. Oleh karena itu, untuk penelitian mendatang sangat disarankan untuk mengeksplorasi integrasi kanal multispektral tambahan, khususnya Near-Infrared (NIR) dan Short-Wave Infrared (SWIR), guna meningkatkan kontras fitur antara vegetasi, tanah, dan mineral tambang. Perluasan variasi dataset latih dari berbagai kondisi geografis dan musim juga direkomendasikan agar model memiliki tingkat generalisasi yang lebih tangguh saat diterapkan pada skala nasional..

DAFTAR REFERENSI

- Alhabsyi, G. A. P., Rangu, R. B., Syamsuddin, S., & Sani, H. (2024). *Pengenalan Kegiatan Pertambangan*. PT. Sonpedia Publishing Indonesia.
- Ali, M., Roy, S., Saxena, U., Sharma, T., Raghunathan, A., & Roy, K. (2022). Compute-in-memory technologies and architectures for deep learning workloads. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 30(11), 1615-1630.
- Al Fathoni, H., Junaidi, A., & Aditiawan, F. P. (2025). Klasifikasi Tutupan Lahan Pada Citra Sentinel-2 Di Kawasan IKN Menggunakan Google Earth Engine. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(3), 4982-4991.
- Ayu, D. W., & Pradipta, G. A. (2024). Analisis Performansi Parameter pada Arsitektur U-Net untuk Segmentasi Nukleus pada Citra Kanker Serviks. *Jurnal Sistem dan Informatika (JSI)*, 18(2), 131-138.

- Barri, A. R. R., Zakaria, S., & Bidullah, T. (2021). Pengaruh Sektor Pertambangan Dan Penggalian Terhadap Produk Domestik Regional Bruto Kabupaten Banggai: The Influence of the Mining And Quarrying Sector on the Gross Regional Domestic Product of Banggai Regency. *Jurnal Ilmiah Produktif*, 9(1), 20-26.
- El Hamdi, B., Al-Fariziz, M. S., Safitri, M., Amalia, I. N., Nandi, N., & Ridwana, R. (2024). Perbandingan Penggunaan Citra Landsat 8 dan Sentinel 2 Terhadap Analisis Kesehatan Mangrove dengan Metode NDVI Di Teluk Jakarta. *Jurnal Warta Desa (JWD)*, 6(1), 15-24.
- Fantin Irudaya Raj, E., & Balaji, M. (2022). Application of deep learning and machine learning in pattern recognition. In *Advance Concepts of Image Processing and Pattern Recognition: Effective Solution for Global Challenges* (pp. 63-89). Singapore: Springer Singapore.
- Guetari, R., Ayari, H., & Sakly, H. (2023). Computer-aided diagnosis systems: a comparative study of classical machine learning versus deep learning-based approaches. *Knowledge and Information Systems*, 65(10), 3881-3921.
- Hasyim, A. W., & Pamungkas, Y. A. (2023). *Teknologi remote sensing dalam menjawab kebutuhan perencanaan*. Universitas Brawijaya Press.
- Irham, F., Fauzan, R. G., & Pramasha, R. R. (2024). Peran Sumber Daya Alam dalam Mendorong Perekonomian Nasional. *Jurnal Media Akademik (JMA)*, 2(11).
- Li, L., Zhou, T., Wang, W., Li, J., & Yang, Y. (2022). Deep hierarchical semantic segmentation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 1246-1257).
- Li, Z., Zhao, Y., Ren, H., & Sun, Y. (2024). A Novel Index for Detecting Bare Coal in Open-Pit Mining Areas Based on Landsat Imagery. *Remote Sensing*, 16(24), 4648.
- Kuzevic, S., Bobikova, D., & Kuzevicova, Z. (2022). Land cover and vegetation coverage changes in the mining area—A case study from Slovakia. *Sustainability*, 14(3), 1180.
- Marlina, D. (2022). Klasifikasi Tutupan Lahan pada Citra Sentinel-2 Kabupaten Kuningan dengan NDVI dan Algoritme Random Forest. *STRING (Satuan Tulisan Riset Dan Inovasi Teknologi)*, 7(1), 41-49.
- Mo, Y., Wu, Y., Yang, X., Liu, F., & Liao, Y. (2022). Review the state-of-the-art technologies of semantic segmentation based on deep learning. *Neurocomputing*, 493, 626-646.
- Naraloka, T., Kesuma, L. I., Sukmawati, A., & Cristianti, M. (2022). Arsitektur U-Net pada Segmentasi Citra Hati sebagai Deteksi Dini Kanker Liver. *Techno. com*, 21(4).
- Panda, M. K., Sharma, A., Bajpai, V., Subudhi, B. N., Thangaraj, V., & Jakhetiya, V. (2022). Encoder and decoder network with ResNet-50 and global average feature pooling for local change detection. *Computer Vision and Image Understanding*, 222, 103501.
- Prasetyo, M. H., Baderan, D. W. K., & Hamidu, M. S. (2025). Dampak Kerusakan Lingkungan Akibat Eksploitasi Sumber Daya Mineral dari Kegiatan Pertambangan. *Hidroponik: Jurnal Ilmu Pertanian Dan Teknologi Dalam Ilmu Tanaman*, 2(2), 01-11.
- Purboyo, A. A., Kurniawan, A., & Muta'ali, L. (2024). Identifikasi Tutupan Lahan Menggunakan Support Vector Machine di Kawasan Perkotaan Cekungan Bandung. *Jurnal Komtika (Komputasi dan Informatika)*, 8(1), 54-64.

- Putri, N. D., Selviana, D., Heryanti, E., & Sigit, D. V. (2025). Kajian Literatur: Dampak Aktivitas Penambangan Terhadap Biodiversitas dan Lingkungan. *Health Safety Environment Journal*, 4(2), 126-139.
- Qian, L., Zhou, X., Li, Y., & Hu, Z. (2022). Unet#: a Unet-like redesigning skip connections for medical image segmentation. *arXiv preprint arXiv:2205.11759*.
- Rajamani, K. T., Rani, P., Siebert, H., ElagiriRamalingam, R., & Heinrich, M. P. (2023). Attention-augmented U-Net (AA-U-Net) for semantic segmentation. *Signal, image and video processing*, 17(4), 981-989.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *ArXiv*. <https://arxiv.org/abs/1505.04597>
- Santoso, B. (2025). Pemanfaatan Teknologi Satelit untuk Monitoring Perubahan Ekosistem Mangrove dan Terumbu Karang. *Journal of Marine Fisheries*, 1(1), 15-21.
- Setiawan, E. B. (2025). Prinsip konstitusi ekonomi dalam hilirisasi nikel untuk mewujudkan pengelolaan sumber daya alam yang berkelanjutan. *Jurnal Rechts Vinding: Media Pembinaan Hukum Nasional*, 14(1).
- Sonic, L. T. (2024, September). Optimalisasi Sistem Perizinan Pertambangan di Indonesia: Menuju Tata Kelola yang Berkelanjutan dan Bermanfaat. In *Prosiding Seminar Nasional Program Doktor Ilmu Hukum* (pp. 21-34).
- Waladi, A. (2025). Peningkatan Akurasi Klasifikasi Tutupan Lahan Menggunakan Random Forest pada Data Sentinel-2 di Jambi. *JURNAL FASILKOM*, 15(1), 17-24.
- Zhen, Z., Chen, S., Yin, T., & Gastellu-Etchegorry, J. P. (2023). Globally quantitative analysis of the impact of atmosphere and spectral response function on 2-band enhanced vegetation index (EVI2) over Sentinel-2 and Landsat-8. *ISPRS Journal of Photogrammetry and Remote Sensing*, 205, 206-226.