

Segmentasi Tutupan Lahan Berbasis CNN pada Citra UAV Gumuk Pasir Parangtritis

Yonanta Dwi Hartanto^{1*}, Mutaqin Akbar²

^{1,2}Informatika, Universitas Mercu Buana Yogyakarta, Indonesia

^{1*}211110136@student.mercubuana-yogya.ac.id, ²mutaqin@mercubuana-yogya.ac.id

Abstrak: Pemantauan tutupan lahan di Zona Inti Gumuk Pasir Parangtritis secara berkala sangat penting untuk konservasi, namun metode anotasi manual pada citra UAV memakan waktu dan subjektif. Penelitian ini bertujuan mengimplementasikan arsitektur Standard U-Net untuk segmentasi semantik otomatis kelas pasir dan non-pasir pada citra UAV. Data latih merupakan integrasi anotasi manual (463 citra UAV tahun 2019) dengan anotasi semi-otomatis berbasis *Segment Anything Model* (SAM) pada 98 citra UAV tahun 2022, sementara data uji merupakan 80 citra UAV tahun 2022 yang belum pernah dilihat oleh model. Prapengolahan mencakup pemotongan citra dan masker menjadi ubin 256×256 piksel, serta augmentasi data berupa rotasi, zoom, penyesuaian kecerahan dan kontras, serta *horizontal flip*. Model dilatih dengan fungsi *loss* gabungan *Binary Cross Entropy* dan *Dice*, *optimizer Adam*, *learning rate* 10^{-4} , *batch size* 8, dan *threshold* tetap 0,45. Evaluasi pada 80 citra uji independen tahun 2022 menghasilkan *Pixel Accuracy* 73,31%, *Dice Coefficient* 83,28%, dan *Intersection over Union* (IoU) 71,35%. Secara kualitatif, model mampu menangkap bentuk umum area pasir dengan baik, meskipun *noise* muncul pada *scene* heterogen, akurasi tertinggi dicapai pada tekstur pasir homogen. Implikasi praktis dari penelitian ini adalah mempercepat penyediaan data spasial yang presisi bagi instansi terkait dalam memantau perubahan gumuk pasir. Penelitian lanjutan disarankan untuk memperbaiki kualitas *ground truth*, mengintegrasikan koreksi bayangan, mengeksplorasi arsitektur modern, serta menerapkan fungsi *loss* yang mampu menangani ketidakseimbangan kelas untuk meningkatkan akurasi segmentasi secara komprehensif.

Kata Kunci: *Deep Learning*; Gumuk Pasir; Segmentasi Semantik; UAV; U-Net; *Segment Anything Model*

Abstract: Periodic land cover monitoring in the Core Zone of Parangtritis Sand Dunes is crucial for conservation, but manual annotation of UAV imagery is time-consuming and subjective. This study implements a Standard U-Net for automatic semantic segmentation of sand and non-sand classes on UAV images. The training data consists of an integration of manual annotations (463 UAV images from 2019) and semi-automated annotations based on the *Segment Anything Model* (SAM) on 98 UAV images from 2022, while the test data comprises 80 UAV images from 2022 that the model has not previously encountered. Preprocessing included tiling images and masks into 256×256 patches, with data augmentation via rotation, zoom, brightness/contrast adjustment, and horizontal flip. The model was trained using a combined *Binary Cross Entropy* and *Dice* loss, *Adam* optimizer (*learning rate* 10^{-4}), *batch size* 8,

and a fixed threshold of 0.45. Evaluation on 80 independent 2022 test images yielded Pixel Accuracy of 73.31%, Dice Coefficient of 83.28%, and Intersection over Union (IoU) of 71.35%. Qualitatively, the model captured the general shape of sand areas well, though noise appeared in heterogeneous scenes, while the highest accuracy was achieved on homogeneous sand textures. The practical implication is accelerating precise spatial data provision for agencies monitoring sand dune changes. Further research is recommended to improve ground truth quality, integrate shadow correction, explore modern architectures, and apply loss functions handling class imbalance for comprehensive accuracy enhancement.

Keywords: Deep Learning; Sand Dunes; Semantic Segmentation; UAV; U-Net; Segment Anything Model

1. PENDAHULUAN

Kawasan Gumuk Pasir Parangtritis di Daerah Istimewa Yogyakarta merupakan bentang alam unik yang memiliki nilai ekologis dan warisan geologis (*geoheritage*) tinggi. Upaya konservasi kawasan ini, khususnya pada wilayah Zona Inti, membutuhkan pemantauan luasan dan perubahan tutupan lahan secara berkala[1], [2], [3]. Pemantauan perubahan tutupan lahan pada ekosistem pesisir yang dinamis telah terbukti sangat efektif ketika diotomatisasi menggunakan model pembelajaran mendalam (*deep learning*), karena algoritma ini mampu menangani gangguan dan heterogenitas lanskap secara adaptif, sebagaimana dibuktikan pada penelitian klasifikasi pesisir Tanjung Tiram[4]. Seiring dengan perkembangan teknologi, penggunaan *Unmanned Aerial Vehicle* (UAV) telah menjadi standar utama karena mampu menghasilkan citra beresolusi sangat tinggi (tingkat sentimeter) dengan efisiensi waktu perekaman dibandingkan citra satelit resolusi menengah[5]. Meskipun tahapan akuisisi data UAV telah berkembang pesat, proses ekstraksi informasi spasialnya masih menghadapi tantangan operasional yang signifikan.

Selama ini, metode pemetaan tutupan lahan di kawasan Gumuk Pasir umumnya masih mengandalkan interpretasi visual dan digitasi poligon secara manual. Pendekatan konvensional ini memakan waktu yang sangat lama, rentan terhadap subjektivitas manusia, dan memicu generalisasi poligon akibat kelelahan visual[6], [7]. Upaya otomatisasi menggunakan pendekatan segmentasi citra konvensional tanpa pengawasan, seperti *Fuzzy C-Means* (FCM) yang mengekstrak fitur warna tingkat rendah (*low-level features*), nyatanya juga masih rentan mengalami salah klasifikasi (*misclassification*) ketika dihadapkan pada lanskap alam yang heterogen[8]. Oleh karena itu, diperlukan terobosan otomasi berbasis kecerdasan buatan yang mengekstrak fitur semantik tingkat tinggi guna membedakan material pasir dan non-pasir secara objektif pada skala mikro. Urgensi ini sejalan dengan penelitian Diro (2025) yang menyimpulkan bahwa pendekatan segmentasi semantik berbasis *deep learning* sangat andal untuk menggantikan proses digitasi manual dalam mengekstrak batas geometris objek yang kompleks pada data penginderaan jauh resolusi tinggi[9].


Pada penelitian sebelumnya, arsitektur U-Net telah terbukti andal dalam mengekstrak fitur semantik tingkat tinggi pada berbagai objek bertekstur kompleks, seperti motif batik Yogyakarta[10] dan wayang kulit Pandawa[11]. Keberhasilan tersebut mengindikasikan potensi besar U-Net untuk mengatasi misklasifikasi akibat kemiripan warna dan tekstur pada lanskap gumuk pasir. Namun, studi sebelumnya di kawasan ini masih terbatas pada pendekatan konvensional *Fuzzy C-Means* yang rentan terhadap *noise* pada area heterogen[8]. Sepengetahuan penulis, belum ada penelitian yang menerapkan U-Net pada citra UAV untuk segmentasi pasir dan non-pasir di kawasan Zona Inti Gumuk Pasir Parangtritis, Bantul, Yogyakarta, terlebih yang memadukan data *multi-temporal* dengan anotasi semi-otomatis SAM untuk meningkatkan generalisasi model. Kesenjangan inilah yang mendorong dilakukannya penelitian ini.

Sebagai solusi atas permasalahan tersebut, arsitektur berbasis convolutional neural network (CNN) yaitu U-Net dipilih karena keandalannya yang menonjol untuk tugas segmentasi tingkat piksel[11]. Arsitektur ini memiliki struktur *encoder-decoder* simetris dengan *skip connections*[12], [13], yang menjadikannya andal dalam memulihkan informasi lokasi fitur spasial. Keandalan mekanisme simetris U-Net dalam mengekstrak batas objek yang rumit dengan tingkat akurasi tinggi juga telah dikonfirmasi oleh Malih dan Akbar (2026) pada pemrosesan citra[10]. Berbeda dengan pendekatan seperti *TernausNet* yang mengandalkan bobot prapenelitian eksternal[14], SegNet yang tidak perlu mempelajari parameter tambahan saat proses *upsampling*[15], maupun DeepLab Memanfaatkan *atrous convolution* dan modul *Atrous Spatial Pyramid Pooling* (ASPP) untuk menangkap konteks objek dalam berbagai ukuran skala[16].

Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi arsitektur berbasis CNN yaitu U-Net untuk melakukan segmentasi semantik tutupan lahan di Zona Inti Gumuk Pasir Parangtritis. Penelitian ini memposisikan diri sebagai solusi pemetaan untuk menjawab batasan presisi dan akurasi model dalam melokalisasi batas objek spasial, sekaligus menguji keandalan generalisasi model terhadap dataset citra udara di daerah Zona Inti Gumuk Pasir Parangtritis.

2. METODE PENELITIAN

Alur Penelitian ini merancang otomatisasi segmentasi semantik tutupan lahan berbasis algoritma *Deep Learning* secara sistematis. Tahapan penelitian mencakup pengumpulan dataset, prapengolahan citra, perancangan arsitektur jaringan, pelatihan, hingga tahapan evaluasi. Secara komprehensif, alur utama dari penyelesaian masalah pada penelitian ini divisualisasikan pada Gambar 1.



Gambar 1. Alur Penelitian

Pengumpulan Data

Data primer yang digunakan adalah citra udara RGB dari *Unmanned Aerial Vehicle* (UAV) yang meliputi kawasan Zona Inti Gumuk Pasir Parangtritis[17]. Dataset dibagi menjadi dua kelompok temporal:


- **Data Tahun 2019:** Terdiri dari 463 citra ortofoto yang telah dilengkapi *ground truth* hasil digitasi manual[18].
- **Data Tahun 2022:** Untuk menjembatani kesenjangan domain antar tahun, ditambahkan 98 citra tahun 2022, untuk dimasukkan sebagai data latih, yang dipilih

dari total 345 citra hasil akuisisi berdasarkan kualitas visual dan keterwakilan variasi spasial[19].

Anotasi *ground truth* untuk data tahun 2022 dilakukan secara semi-otomatis menggunakan *Segment Anything Model* (SAM)[20] dengan basis *prompt* titik tengah, yang kemudian diverifikasi dan dikoreksi secara manual menggunakan perangkat lunak pengolah citra. Secara keseluruhan, total data latih berjumlah 561 citra (kombinasi 463 citra tahun 2019 dan 98 citra tahun 2022). Sementara itu, untuk keperluan pengujian, disiapkan 80 citra tahun 2022 yang sama sekali belum masuk data latih demi menjaga objektivitas evaluasi.

Praproses Data


Seluruh matriks citra dan masker acuan dipotong menjadi *tiles* berukuran 256 x 256 piksel. Proses *tiling* ini bertujuan untuk menyeragamkan dimensi masukan jaringan konvolusi sekaligus mereduksi beban komputasi perangkat keras tanpa menghilangkan informasi tekstur spasial objek. Masker acuan direpresentasikan ke dalam format matriks biner, di mana piksel bernilai 1 merepresentasikan kelas pasir (putih) dan 0 untuk kelas non-pasir (hitam). Penelitian ini tidak menerapkan praproses tambahan seperti normalisasi warna atau koreksi bayangan, sehingga model diuji murni pada kondisi citra asli. Rincian tahapan prapengolahan hingga pembagian dataset ini diilustrasikan pada Gambar 2.



Gambar 2. Alur Praproses data

Perancangan Arsitektur U-Net

Jaringan Arsitektur segmentasi yang digunakan adalah *Standard U-Net* yang menerima tensor masukan berukuran $256 \times 256 \times 3$. Struktur jaringan beroperasi melalui dua jalur yang simetris, yaitu jalur ekstraksi fitur (*encoder*) dan jalur pemulihan spasial (*decoder*), sebagaimana divisualisasikan secara detail pada Gambar 3.



Gambar 3. Arsitektur U-Net

Jalur ekstraksi fitur atau *encoder* terdiri dari empat tingkat blok konvolusi[21]. Setiap blok mengaplikasikan dua operasi konvolusi berukuran 3×3 (Conv2D), yang masing-masing diikuti oleh fungsi aktivasi *Rectified Linear Unit* (ReLU) dan *Batch Normalization* untuk menstabilkan distribusi fitur selama pembaruan bobot. Pada akhir setiap blok *encoder*, dimensi spasial direduksi menjadi setengahnya menggunakan operasi *MaxPooling* berukuran 2×2 . Jumlah filter atau kedalaman peta fitur (*feature maps*) dilipatgandakan secara bertahap, dimulai dari 64, 128, 256, hingga 512 filter[13], [22]. Sebagai penghubung antara *encoder* dan *decoder*, terdapat lapisan *bottleneck* dengan kedalaman maksimal 1024 filter. Jalur pemulihan spasial atau *decoder* dilakukan melalui empat tingkat operasi *upsampling* menggunakan *Conv2DTranspose* berukuran 2×2 . Pada setiap tingkat ekspansi, kedalaman fitur dikurangi secara bertahap, yaitu 512, 256, 128, hingga 64 filter. Mekanisme *skip connections* memanfaatkan fungsi *concatenate* untuk menggabungkan peta fitur dari blok *encoder* secara langsung ke tingkat *decoder* yang bersesuaian, sehingga informasi lokasi spasial tingkat piksel yang hilang akibat *pooling* dapat dipulihkan. Pada lapisan akhir jaringan, konvolusi berukuran 1×1 diaplikasikan dengan fungsi aktivasi *Sigmoid* untuk memetakan matriks multidimensi menjadi probabilitas biner tunggal (0 hingga 1), yang merepresentasikan klasifikasi kelas pasir dan non-pasir.

Pelatihan Model

Proses pembaruan bobot jaringan dieksekusi menggunakan *optimizer* Adam dengan tingkat pembelajaran (*learning rate*) 10^{-4} . Model dilatih menggunakan fungsi galat *Binary Cross-Entropy* (BCE) dan *Dice Loss*, dengan formulasi sebagai berikut:

Yonanta Dwi Hartanto: *Penulis Korespondensi



Copyright © 2026, Yonanta Dwi Hartanto, Mutaqin Akbar.

$$Loss_{BCE - Dice} = BCE(y, y') + (1 - Dice(y, y'))$$

Kombinasi tersebut secara efektif memberikan penalti pada klasifikasi lokal sekaligus mempertahankan kohesi area segmentasi spasial. Proses komputasi dilakukan dengan alokasi *batch size* sebanyak 8 sampel dan siklus pelatihan maksimal 50 *epochs*. Untuk meningkatkan kemampuan generalisasi dan memperkaya variasi data, diterapkan teknik *augmentasi spasial* dan warna secara *real-time*, yang meliputi:

- Rotasi 90° secara acak.
- Perbesaran (*zoom*) dengan rentang skala 0,8 hingga 1,2.
- Penyesuaian kecerahan ($\alpha = 0,5 - 1,5$)
- kontras ($\beta = \pm 20$) dengan probabilitas 0,7.
- Pembalikan citra horizontal (*horizontal flip*).

Algoritma panggil balik (*callbacks*) disematkan untuk mengoptimalkan pelatihan. Fungsi *EarlyStopping* (*patience* = 10) digunakan untuk menghentikan pelatihan secara otomatis saat tidak ada lagi tren perbaikan metrik, sementara *ReduceLROnPlateau* (*patience* = 5, *factor* = 0,5) bertugas menurunkan *learning rate* secara adaptif. Bobot jaringan terbaik diamankan melalui *ModelCheckpoint* berdasarkan metrik *validation loss* terendah. Nilai ambang batas (*threshold*) biner ditetapkan sebesar 0,45 dan *tuning* data validasi yang mengonfirmasi stabilitas prediksi pada rentang 0,4 hingga 0,5.

Pengujian dan Evaluasi Model

Kinerja arsitektur hasil pelatihan dievaluasi pada 80 sampel citra uji independen tahun 2022 yang belum pernah dilihat oleh model. Kemampuan prediksi dianalisis secara kuantitatif berbasis matriks kebingungan (*confusion matrix*) yang merepresentasikan empat parameter piksel yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) [7], [12], [13]. Tiga metrik standar segmentasi semantik digunakan untuk menilai tingkat presisi jaringan.

Pertama, *Accuracy* digunakan untuk mengukur rasio keseluruhan piksel yang diklasifikasikan secara benar oleh model terhadap total keseluruhan piksel citra, dengan perumusan sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Kedua, *Dice Coefficient*, digunakan untuk menilai korelasi antara presisi dan sensitivitas prediksi spasial, yang diformulasikan sebagai:

$$Dice = \frac{2xTP}{(2xTP) + FP + FN} \quad (2)$$

Ketiga, *Intersection over Union* (IoU) digunakan sebagai parameter pengukuran paling ketat terhadap kesalahan lokalisasi batas area. Metrik ini mengevaluasi rasio area irisan antara prediksi dan *ground truth* terhadap total area gabungan keduanya:

$$IoU = \frac{TP}{TP + FP + FN} \quad (3)$$

Kemudian, evaluasi kualitatif dilakukan melalui komparasi luaran visual secara langsung antara matriks prediksi model dengan *ground truth* buatan manusia pada beberapa sampel citra representatif. Pendekatan kualitatif ini diaplikasikan untuk membedah kemampuan spasial model secara riil khususnya dalam menangani area kompleks seperti batas geometri infrastruktur dan gangguan radiometrik bayangan yang seringkali tidak dapat direpresentasikan secara utuh hanya melalui angka metrik matematis.

3. HASIL DAN PEMBAHASAN

Hasil Pelatihan Model

Pelatihan model dilakukan selama 50 *epoch* menggunakan 561 pasangan citra latih beserta masker acuannya (kombinasi 463 citra tahun 2019 dan 98 citra tahun 2022). Dataset tersebut dipisahkan dengan rasio pembagian 80% sebagai data latih dan 20%

Yonanta Dwi Hartanto: *Penulis Korespondensi



Copyright © 2026, Yonanta Dwi Hartanto, Mutaqin Akbar.


sebagai data validasi. Proses pelatihan terbukti berjalan stabil tanpa indikasi *overfitting*, meskipun arsitektur U-Net diimplementasikan murni tanpa penyematan lapisan *Dropout*. Kestabilan ini merujuk pada keberhasilan teknik *augmentasi* data dalam memperkaya representasi fitur.

Tabel 1. Hasil Pelatihan Model U-Net

Epoch	Trainin g Loss	Trainin g Acc	Training		Training IoU	Val Loss	Val Acc	Val		Val IoU
			Dice Loss	Dice (Acc)				Dice Loss	Dice (Acc)	
1	0.958	0.717	0.334	0.666	0.503	1.122	0.549	0.414	0.586	0.416
10	0.734	0.770	0.254	0.746	0.597	0.900	0.679	0.300	0.700	0.542
20	0.696	0.787	0.241	0.759	0.613	0.645	0.804	0.230	0.770	0.630
30	0.668	0.795	0.232	0.768	0.626	0.662	0.786	0.220	0.780	0.644
40	0.666	0.803	0.227	0.773	0.634	0.618	0.808	0.208	0.792	0.660
50	0.644	0.805	0.223	0.777	0.638	0.613	0.810	0.205	0.795	0.667

Berdasarkan Tabel 1, terlihat bahwa *training loss* dan *validation loss* mengalami penurunan yang konsisten tanpa menunjukkan tren divergensi. Nilai *Training IoU* meningkat dari 0,503 menjadi 0,638, sejalan dengan *Validation IoU* yang juga meningkat signifikan dari 0,416 menjadi 0,667. Kesenjangan (*gap*) yang sempit antara performa data latih dan validasi mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak sekadar menghafal data latih (*memorization*). Meskipun sempat terjadi anomali kecil pada *epoch* ke-3 di mana *validation loss* melonjak hingga 2,273, kondisi tersebut pulih dengan cepat pada siklus berikutnya, membuktikan bahwa penentuan *learning rate* dan struktur arsitektur beroperasi secara optimal.

Visualisasi pergerakan metrik diilustrasikan pada Gambar 4, yang menampilkan kurva akurasi dan *loss* sepanjang 50 *epoch*. Kedua kurva bergerak harmonis; metrik akurasi validasi berhasil mencapai 0,811 pada siklus akhir, berdampingan dengan akurasi pelatihan sebesar 0,805. Kestabilan capaian ini mengonfirmasi bahwa penerapan kombinasi fungsi objektif *BCE-Dice Loss* serta *augmentasi* data yang variatif berhasil menjaga ketahanan model secara menyeluruh.




Gambar 4. Grafik Akurasi/Accuracy (kiri) dan Grafik Galat/Loss (kanan)


Hasil Evaluasi

Arsitektur terbaik yang diekstraksi pada siklus pelatihan terakhir (*epoch* ke-50) dievaluasi kinerjanya menggunakan 80 sampel citra uji independen tahun 2022. Ringkasan hasil evaluasi kuantitatif disajikan pada Gambar 5. Berdasarkan pengujian tersebut, model mencatatkan perolehan *Pixel Accuracy* sebesar 73,31%, *Intersection over Union* (IoU) sebesar 71,35%, dan *Dice Coefficient* mencapai 83,28%. Ketiga metrik ini secara

komprehensif merepresentasikan tingkat keandalan dan kualitas segmentasi model. Capaian *Pixel Accuracy* sebesar 73,31% mengartikan bahwa sebagian besar piksel di dalam citra lanskap yang kompleks berhasil diklasifikasikan ke dalam kelas yang tepat oleh jaringan. Selanjutnya, perolehan metrik IoU sebesar 71,35% membuktikan bahwa luasan prediksi model memiliki tingkat tumpang-tindih (*overlap*) ruang dan lokalisasi batas tepi spasial yang sangat presisi jika dibandingkan dengan poligon *ground truth* buatan manusia. Tembusnya parameter evaluasi ketat ini pada angka 70% menegaskan ketangguhan arsitektur dalam memetakan luasan area. Terakhir, perolehan *Dice Coefficient* yang menyentuh angka 83,28% mengonfirmasi bahwa model U-Net memiliki keseimbangan yang sangat kuat antara presisi dan sensitivitas, sehingga terbukti mampu meredam tingkat kemunculan kesalahan deteksi (*False Positives* dan *False Negatives*) secara efektif saat membedakan karakteristik material pasir dengan objek lain di sekitarnya.



Gambar 5. Hasil Evaluasi Segmentasi Semantik Data Uji 2022



Gambar 6. Hasil Visual Segmentasi Data Uji

Evaluasi Visual Hasil Segmentasi

Gambar 6 mendemonstrasikan komparasi visual spasial antara citra asli RGB, *ground truth* buatan manusia, dan matriks prediksi model pada tiga skenario tutupan lahan berkarakteristik unik yaitu area heterogen campuran bangunan, pasir, dan vegetasi (baris

Yonanta Dwi Hartanto: *Penulis Korespondensi



Copyright © 2026, Yonanta Dwi Hartanto, Mutaqin Akbar.

pertama), transisi antara bangunan dan pasir (baris kedua), serta persinggungan antara hamparan pasir dan batas vegetasi (baris ketiga). Secara visual, hasil prediksi U-Net pada ketiga sampel menunjukkan model mampu menangkap bentuk umum area pasir dengan cukup baik, namun tingkat akurasi bervariasi sesuai karakteristik setiap skenario.

Pada baris pertama, model menghasilkan *noise* paling tinggi berupa bercak-bercak putih yang tidak beraturan. Fenomena ini disebabkan oleh kemiripan spektral antara atap bangunan berwarna terang dengan permukaan pasir, serta bayangan tajuk pohon yang menurunkan kontras lokal. Karena model hanya menerima masukan RGB tanpa informasi ketinggian, fitur warna semata tidak cukup untuk membedakan kedua objek tersebut. Temuan ini selaras dengan hasil Akbar et al. (2019) pada FCM, di mana misklasifikasi juga dominan terjadi pada area dengan karakteristik warna serupa[8]. Pada baris kedua, performa model membaik dengan bentuk segmentasi yang lebih mendekati *ground truth*, namun masih terdapat kesalahan signifikan berupa area putih besar yang terisolasi di kiri bawah. Kesalahan berbentuk pulau ini mengindikasikan bahwa model belum mampu menangkap dependensi spasial jarak jauh akibat terbatasnya *receptive field* pada ukuran *patch* 256×256 piksel, sehingga fragmen yang seharusnya terhubung tidak tersegmentasi secara utuh. Sementara itu, pada baris ketiga yang didominasi tekstur pasir homogen, model menghasilkan prediksi paling akurat dengan kesalahan minimal. Tingginya akurasi pada kondisi ini memperkuat bukti bahwa U-Net sangat andal ketika variasi intra-kelas rendah, sebagaimana dilaporkan pada segmentasi latar belakang seragam di citra wayang[11] dan motif batik[10].

Keterbatasan Penelitian

Meskipun model U-Net yang diusulkan menunjukkan kinerja yang cukup baik, terdapat beberapa keterbatasan teknis dalam penelitian ini yang perlu diakui. Pertama, keterbatasan kapabilitas perangkat keras komputasi, khususnya pada memori grafis (GPU NVIDIA GTX 1070 8GB VRAM) dan memori sistem (RAM 16GB dengan prosesor Ryzen 5 3400G), mengharuskan pemotongan citra (*tiling*) menjadi *patch* berukuran kecil yaitu 256×256 piksel untuk menghindari kendala *out-of-memory* saat pelatihan. Ukuran *patch* ini membatasi *receptive field* model, yang berdampak pada hasil segmentasi tepi objek geometris (seperti bangunan) yang cenderung bergerigi. Kedua, ketiadaan koreksi bayangan pada prapemrosesan menyebabkan munculnya *noise* deteksi pada area yang ternaungi. Ketiga, penggunaan hanya dua kelas segmentasi (pasir dan non-pasir) membuat variasi detail tutupan lahan lainnya tidak teridentifikasi. Keempat, *dataset* latih saat ini hanya mencakup dua variasi tahun, sehingga kemampuan generalisasi model terhadap citra dari periode dengan kondisi pencahayaan atau resolusi yang sangat berbeda belum teruji sepenuhnya. Kelima, terdapat variasi kualitas presisi *ground truth* pada *dataset* latih akibat penggabungan dua metode anotasi yang berbeda, yakni digitasi manual oleh manusia (data 2019) dan anotasi semi-otomatis menggunakan SAM (data 2022).

Berdasarkan keterbatasan tersebut, penelitian selanjutnya disarankan untuk menambah jumlah kelas tutupan lahan dan mengintegrasikan teknik koreksi bayangan. Penggunaan arsitektur berbasis *attention mechanism* juga sangat disarankan untuk memperbaiki batas geometris objek. Selain itu, diperlukan tahap standarisasi dan perbaikan kualitas *ground truth* untuk meminimalkan bias presisi antara anotasi manual dan luaran otomatis SAM, serta perlunya eksplorasi penggunaan fungsi objektif seperti *recall loss*[23] untuk menekan tingkat kesalahan (kasus *false negative*) pada kelas minoritas.

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan Standard U-Net untuk segmentasi semantik pasir dan non-pasir pada citra UAV *multi-temporal* di Zona Inti Gumuk Pasir

Parangtritis. Dengan total 561 pasang citra latih hasil perpaduan anotasi manual tahun 2019 (463 citra) dan anotasi semi-otomatis SAM untuk data tahun 2022 (98 citra), model mencapai IoU 71,35%, *Pixel Accuracy* 73,31%, dan *Dice Coefficient* 83,28%. Secara visual, model mampu menangkap bentuk area pasir secara memadai, terutama pada tekstur homogen. Kontribusi utama terhadap pengembangan ilmu pengetahuan adalah pembuktian bahwa integrasi anotasi berbasis SAM dapat menjembatani kesenjangan domain antar tahun sekaligus menajamkan akurasi segmentasi. Selain itu, penelitian ini menunjukkan bahwa arsitektur U-Net mampu menghasilkan generalisasi yang cukup baik. Secara praktis, model ini berpotensi mempercepat penyusunan peta tutupan lahan skala mikro oleh Balai Geospasial Pesisir dan Gumuk Pasir serta instansi terkait, sehingga mendukung pemantauan perubahan gumuk pasir yang lebih objektif dan efisien, selaras dengan kebijakan restorasi yang tertuang dalam Peraturan Bupati Bantul No. 47/2024.

5. REFERENCES

- [1] Dinas Pariwisata Kabupaten Bantul, "Dinas Pariwisata Kabupaten Bantul," Dinas Pariwisata Kabupaten Bantul. Diakses: 31 Mei 2026. [Daring]. Tersedia pada: <https://pariwisata.bantulkab.go.id/news/mengenal-lebih-dekat-gumuk-pasir-barchan-parangkusumo-bantul>
- [2] Kementerian ESDM, "Kementerian ESDM Tetapkan 20 Situs Geoheritage di DI Yogyakarta," Kementerian Energi dan Sumber Daya Mineral. Diakses: 31 Mei 2026. [Daring]. Tersedia pada: <https://www.esdm.go.id/id/media-center/arsip-berita/kementerian-esdm-tetapkan-20-situs-geoheritage-di-di-yogyakarta->
- [3] Bupati Bantul, *Peraturan Bupati Bantul Nomor 47 Tahun 2024 tentang Rencana Aksi Restorasi Gumuk Pasir Parangtritis Tahun 2024-2029*. 2024.
- [4] A. Nurfadilah, R. Saputra, dan M. I. Sarita, "Sistem Klasifikasi Perubahan Lahan pada Ekosistem Pesisir Berbasis Deep Learning Menggunakan Citra Sentinel-2: Studi Kasus: Tanjung Tiram, Sulawesi Tenggara," *Sudo J. Tek. Inform.*, vol. 5, no. 1, hlm. 108–125, Mar 2026, doi: 10.56211/sudo.v5i1.1635.
- [5] A. Wiratama dan T. H. Purwanto, "Penerapan Metode Deep Learning untuk Klasifikasi Penutup Lahan Menggunakan Citra Unmanned Aerial Vehicle (UAV)," *J. Bumi Indones.*, vol. 10, no. 4, hlm. 1–10, 2021.
- [6] D. S. Aji, L. M. S. L. M. Sabri, dan Y. Prasetyo, "ANALISIS AKURASI DEM dan FOTO TEGAK HASIL PEMOTRETAN dengan PESAWAT NIR AWAK DJI PHANTOM 4 (Studi Kasus : Bukit Perumahan Permata Hijau Tembalang Semarang)," *J. Geod. Undip*, vol. 8, no. 2, hlm. 8–18, Apr 2019, doi: 10.14710/jgundip.2019.23729.
- [7] D. Putra, *Pengolahan Citra Digital*. Penerbit Andi, 2010.
- [8] M. Akbar, A. Witanti, dan I. Susilawati, "GPU Accelerated Fuzzy C-Means (FCM) Color Image Segmentation," *Compiler*, vol. 8, no. 2, Okt 2019, doi: 10.28989/compiler.v8i2.455.
- [9] A. Diro, "Evaluasi Metode Segmentasi Semantik dan Objek Berbasis Deep Learning untuk Ekstraksi Bangunan secara Otomatis pada Citra Satelit Resolusi Tinggi," Skripsi, Universitas Gadjah Mada, Yogyakarta, 2025. [Daring]. Tersedia pada: <https://etd.repository.ugm.ac.id/penelitian/detail/258664>
- [10] Y. Z. Malih dan M. Akbar, "KLASIFIKASI DAN SEGMENTASI MOTIF BATIK YOGYAKARTA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK," vol. 10, no. 1, 2026.
- [11] K. Refiansyah dan M. Akbar, "Segmentasi Citra Wayang Kulit Pandawa Berkompleksitas Visual Tinggi Menggunakan Model U-Net Berbasis Convolutional Neural Network," *J. Inf. Syst. Res. JOSH*, vol. 7, no. 4, hlm. 818–829, Jul 2026, doi: 10.47065/josh.v7i4.10013.
- [12] H. angkawijana Tedja, "Konsep dan Implementasi U-Net model untuk Image Segmentation dengan Tensorflow," Medium. Diakses: 31 Juli 2026. [Daring].

- Tersedia pada: <https://medium.com/@haidhiangkawijana/konsep-dan-implementasi-u-net-model-untuk-image-segmentation-dengan-tensorflow-3de40171c5ac>
- [13] A. Pamungkas, "Segmentasi Semantik Menggunakan Convolutional Neural Network (CNN)," Pemrograman Matlab. Diakses: 7 Juni 2026. [Daring]. Tersedia pada: <https://pemrogramanmatlab.com/2023/07/22/segmentasi-semantik-menggunakan-convolutional-neural-network-cnn/>
 - [14] V. Iglovikov dan A. Shvets, "TernausNet: U-Net with VGG11 Encoder Pre-Trained on ImageNet for Image Segmentation," 17 Januari 2018, *arXiv*: arXiv:1801.05746. doi: 10.48550/arXiv.1801.05746.
 - [15] I. Nur Fahrudin dan M. Akbar, "IMAGE SEGMENTATION OF YOGYAKARTA BATIK PATTERN USING SEGNET," *J. Ris. Inform.*, vol. 8, no. 2, hlm. 309–320, Mar 2026, doi: 10.34288/jri.v8i2.491.
 - [16] I. Aulia dan M. Akbar, "Segmentasi Citra Rambu Lalu Lintas Menggunakan Arsitektur DeepLabV3+ Berbasis Convolutional Neural Network," *J. Sist. Inf. Tek. Inform. Dan Teknol. Pendidik.*, vol. 6, no. 1, hlm. 64–70, Jun 2026, doi: 10.55338/justikpen.v6i1.896.
 - [17] Balai Geospasial Pesisir dan Gumuk Pasir, "Batas Zonasi Gumuk Pasir Parangtritis." Balai Geospasial Pesisir dan Gumuk Pasir, 2015.
 - [18] Balai Geospasial Pesisir dan Gumuk Pasir, "Citra UAV Orthophoto Gumuk Pasir Parangtritis Tahun 2019." Balai Geospasial Pesisir dan Gumuk Pasir, 2020.
 - [19] Balai Geospasial Pesisir dan Gumuk Pasir, "Citra UAV Orthophoto Gumuk Pasir Parangtritis Tahun 2022." Balai Geospasial Pesisir dan Gumuk Pasir, 2023.
 - [20] A. Kirillov *dkk.*, "Segment Anything," 5 April 2023, *arXiv*: arXiv:2304.02643. doi: 10.48550/arXiv.2304.02643.
 - [21] O. Ronneberger, P. Fischer, dan T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," dalam *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, N. Navab, J. Hornegger, W. M. Wells, dan A. F. Frangi, Ed., Cham: Springer International Publishing, 2015, hlm. 234–241.
 - [22] M. Akbar, B. S. Jati, I. Susilawati, dan M. Ahsan, "Traffic Sign Image Segmentation using U-Net Architecture Based on Convolutional Neural Network," *JINAV J. Inf. Vis.*, vol. 7, no. 2, Jul 2026, doi: 10.35877/454RI.jinav4919.
 - [23] J. Tian, N. Mithun, Z. Seymour, H.-P. Chiu, dan Z. Kira, "Striking the Right Balance: Recall Loss for Semantic Segmentation," *arXiv.org*. Diakses: 6 Agustus 2026. [Daring]. Tersedia pada: <https://arxiv.org/abs/2106.14917v2>