



Pemanfaatan Model *U-Net* Berbasis *Deep Learning* untuk Segmentasi Citra dalam Identifikasi Area Genangan Banjir

Application of a Deep Learning-Based U-Net Model for Images Segmentation in Identifying Flooded Areas

Andriany¹, Nani Sulistianingsih^{2*}

^{1,2} Sistem dan Teknologi Informasi, Universitas Muhammadiyah Mataram

E-mail: ryaandriany556@gmail.com, nani.sulistianingsih@ummat.ac.id

Abstract— *Climate change and increased rainfall intensity are causing a higher frequency and magnitude of flood disasters in various regions. This situation necessitates an accurate, automated, and efficient monitoring system for the rapid detection of flood inundation areas to support emergency response. This study aims to implement and evaluate a U-Net-based image segmentation model for identifying flood inundation areas using aerial imagery. The dataset utilized in this study comprises 3,041 RGB images and 3,041 corresponding ground truth masks. The research methodology includes data acquisition, preprocessing (comprising image resizing, pixel value normalization, and data augmentation techniques such as rotation and flipping to enhance data variance), and data partitioning into training, validation, and testing sets. The model was trained using a batch size of 16, a learning rate of 0.001, and for 30 epochs. The model's performance was comprehensively evaluated using standard segmentation metrics: accuracy, precision, recall, Intersection over Union (IoU), and the Dice coefficient. The results indicate that the U-Net model can segment flood inundation areas with excellent performance. The model achieved a global accuracy of 0.908, precision of 0.895, recall of 0.883, an IoU of 0.800, and a Dice coefficient of 0.889. Analysis of the training and validation curves demonstrated stable convergence without significant indications of overfitting. Moreover, the visual segmentation results indicated a high degree of correspondence between the model's predictions and the actual ground truth masks. Consequently, it is concluded that the U-Net model is effective and robust for identifying flood areas from aerial imagery. It also holds significant potential for integration into artificial intelligence-based flood monitoring systems for disaster mitigation.*

Keywords—image segmentation, U-Net, flooded area, aerial images, deep learning

Abstrak— *Perubahan iklim dan peningkatan intensitas curah hujan menyebabkan frekuensi serta magnitudo bencana banjir yang semakin tinggi di berbagai wilayah. Kondisi tersebut menuntut adanya sistem pemantauan yang akurat, otomatis, dan efisien untuk mendeteksi area genangan banjir secara cepat, guna mendukung respons darurat. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi model segmentasi citra berbasis U-Net dalam mengidentifikasi area genangan banjir menggunakan citra udara. Dataset yang digunakan dalam penelitian ini terdiri atas 3.041 citra RGB dan 3.041 citra mask (ground truth) yang bersesuaian. Tahapan penelitian meliputi akuisisi data, pra-pemrosesan (meliputi penyesuaian ukuran citra, normalisasi nilai piksel, dan augmentasi data seperti rotasi dan flipping untuk meningkatkan variasi data), serta pembagian data menjadi himpunan training, validation, dan testing. Pelatihan model dilakukan dengan parameter batch size 16, learning rate 0,001, dan jumlah epoch sebanyak 30. Evaluasi model dilakukan secara komprehensif menggunakan metrik standar segmentasi: akurasi, presisi, recall, Intersection over Union (IoU), dan Dice coefficient. Hasil penelitian menunjukkan bahwa model U-Net mampu melakukan segmentasi area genangan banjir dengan performa yang sangat baik. Model menghasilkan nilai akurasi global sebesar 0,908, presisi*

*Andriany

E-mail: ryaandriany556@gmail.com

0,895, recall 0,883, IoU 0,800, dan Dice coefficient 0,889. Analisis kurva training dan validation memperlihatkan konvergensi yang stabil tanpa indikasi overfitting yang signifikan. Selain itu, hasil visual segmentasi menunjukkan kesesuaian yang tinggi antara prediksi model dengan citra mask sebenarnya. Dengan demikian, dapat disimpulkan bahwa model U-Net efektif dan robust untuk mengidentifikasi area banjir dari citra udara, serta berpotensi besar untuk diintegrasikan dalam sistem pemantauan banjir berbasis kecerdasan buatan untuk mitigasi bencana.

Kata Kunci— segmentasi citra, U-Net, genangan banjir, citra udara, deep learning

I. PENDAHULUAN

Banjir merupakan salah satu bencana alam yang paling sering terjadi di dunia dan berdampak besar terhadap kehidupan sosial, ekonomi, dan lingkungan. Peristiwa ini menimbulkan ancaman signifikan secara global, khususnya di Indonesia. Data menunjukkan bahwa banjir menyumbang 1.298 dari 3.092 total peristiwa bencana di Indonesia pada tahun 2021 [1]. Kondisi ini menunjukkan tingginya tingkat kerentanan wilayah terhadap dampak hidrometeorologis. Indonesia sering mengalami banjir besar yang memengaruhi area luas, seperti 794.100 hektare wilayah terdampak di Kabupaten Katingan pada tahun 2021 [1], serta kawasan perkotaan padat seperti Tamalanrea di Kota Makassar yang rawan akibat perluasan perkotaan [2]. Mengingat dampak yang masif, identifikasi cepat area banjir menjadi aspek krusial dalam penanggulangan bencana karena mendukung respons tanggap darurat dan distribusi sumber daya secara efisien [3]. Namun, metode konvensional seperti pengamatan lapangan dan teknik thresholding manual memiliki keterbatasan signifikan, di antaranya ketergantungan pada kondisi cuaca dan waktu, serta tingginya potensi kesalahan manusia [1]. Sebagai alternatif, kemajuan teknologi penginderaan jauh dan pembelajaran mendalam (*deep learning*) memberikan solusi modern. Melalui penginderaan jauh, data dapat diperoleh secara cepat dan objektif, bahkan di wilayah yang sulit diakses. Penggunaan citra SAR *Sentinel-1*, misalnya, memungkinkan pengamatan sepanjang waktu tanpa terkendala cuaca [4]. Dalam konteks ilmiah, identifikasi area genangan banjir merupakan proses pemetaan wilayah terdampak menggunakan data ini untuk mendukung mitigasi bencana dan pengelolaan sumber daya.

Pendekatan deep learning, khususnya *Convolutional Neural Network* (CNN), telah menjadi pendekatan utama untuk segmentasi citra—proses mengklasifikasikan setiap piksel dalam gambar ke dalam kategori tertentu, termasuk area tergenang air. Kemajuan teknologi segmentasi citra berbasis pembelajaran mendalam telah berkembang pesat, menggantikan teknik tradisional karena kemampuannya mengekstraksi fitur hierarkis langsung dari citra tanpa rekayasa fitur manual. Berbagai turunan CNN seperti Faster R-CNN dan YOLOv3 telah berhasil diterapkan dalam analisis banjir [5], [6]. Salah satu model yang paling menonjol adalah U-Net, yang dirancang khusus untuk tugas segmentasi berbasis piksel dengan kemampuan tinggi dalam lokalisasi dan penangkapan konteks. U-Net terbukti lebih unggul dibandingkan model lain seperti FCN dan SegNet, terutama dalam aplikasi citra bencana dan pengamatan area tergenang [5], serta menunjukkan keberhasilan dalam mendeteksi genangan air secara real-time [7]. Meskipun berbagai penelitian telah membuktikan efektivitas model deep learning seperti *DeepLabV3+*, *DB-SEN1FloodNet*, dan U-Net [4], [8], sebagian besar studi masih berfokus pada wilayah tertentu dan tidak mencakup kondisi topografi serta dinamika hidrologi yang beragam. Penelitian mengenai segmentasi citra untuk pemetaan area genangan banjir masih menghadapi sejumlah tantangan, terutama pada tahap validasi model di wilayah tropis dengan tingkat tutupan awan yang tinggi. Selain itu, penerapan model segmentasi dalam sistem manajemen bencana masih terbatas, sehingga belum sepenuhnya mampu mendukung proses pengambilan keputusan yang cepat dan berbasis data [4], [8]. Tantangan lain yang juga dihadapi mencakup kebutuhan dataset beranotasi dalam jumlah besar, kebutuhan daya komputasi yang tinggi [7].

Oleh karena itu, penelitian ini menawarkan *novelty* berupa penerapan dan evaluasi model U-Net berbasis *deep learning* untuk segmentasi citra penginderaan jauh dalam konteks identifikasi

area genangan banjir. Penelitian ini bertujuan untuk memanfaatkan model U-Net untuk mengelompokkan area tergenang menggunakan citra satelit dan mask. Dengan menggunakan pendekatan evaluasi kuantitatif berbasis metrik *Intersection Over Union* (IoU) dan akurasi spasial, kontribusi yang diharapkan mencakup peningkatan akurasi pemetaan banjir, penyediaan dasar bagi sistem deteksi dini, serta dukungan bagi perumusan kebijakan mitigasi. Tujuan akhirnya adalah menghasilkan model yang akurat, adaptif, dan aplikatif dalam mendukung sistem deteksi dini banjir serta pengambilan keputusan mitigasi bencana secara efektif.

II. LANDASAN TEORI

Perkembangan teknologi penginderaan jauh dan kecerdasan buatan memberikan kontribusi besar dalam analisis wilayah terdampak banjir [9]. Citra satelit menjadi sumber data penting yang digunakan untuk memantau perubahan kondisi permukaan bumi secara spasial dan temporal. Dalam penelitian ini, citra satelit dimanfaatkan untuk proses identifikasi area genangan melalui teknik segmentasi citra. Penerapan metode berbasis pembelajaran mendalam, seperti *Convolutional Neural Network* (CNN) dan arsitektur *U-Net*, menjadi pendekatan yang efektif dalam meningkatkan akurasi hasil segmentasi. Oleh karena itu, bab ini menjelaskan teori-teori yang mendasari penelitian, mencakup citra satelit, segmentasi citra, CNN, dan *U-Net*.

A. Citra Satelit

Deteksi banjir melalui citra satelit mengandalkan dua sistem sensor utama, yaitu sensor optik dan radar *Synthetic Aperture Radar* (SAR), yang berfungsi saling melengkapi dalam mengatasi tantangan atmosfer seperti awan, intensitas cahaya, dan kondisi cuaca ekstrem selama peristiwa banjir. Sensor optik, seperti *Landsat* dan *Sentinel-2*, menyediakan informasi spektral yang luas dan memungkinkan pemisahan area perairan dari tutupan lahan lain melalui indeks berbasis spektral seperti *NDWI* dan *MNDWI*, serta mendukung pemantauan dinamika tutupan lahan dan vegetasi yang relevan terhadap konteks hidrologis [10], [11]. Namun, keterbatasan sensor optik terletak pada sensitivitas terhadap kondisi cuaca dan awan, sehingga diperlukan penggunaan sensor SAR yang bersifat aktif. Sensor SAR mampu menangkap citra pada kondisi siang maupun malam serta menembus awan dengan memanfaatkan kontras hamburan balik (*backscatter*) antara air dan daratan dalam berbagai polaritas (VV/VH), yang menjadikannya efektif untuk mendeteksi genangan air secara berkelanjutan [6], [12].

B. Segmentasi Citra


Segmentasi citra merupakan tahap esensial dalam proses deteksi banjir berbasis citra satelit, dengan tujuan utama membagi citra menjadi area homogen yang mewakili objek seperti air, lahan, atau vegetasi, sehingga memungkinkan analisis genangan secara spasial dan temporal [13], [14]. Pendekatan segmentasi umumnya terbagi menjadi dua kategori, yaitu berbasis piksel dan berbasis objek *Object-Based Image Analysis* (OBIA). Segmentasi berbasis piksel mengandalkan perhitungan indeks air seperti *NDWI* dan *MNDWI* untuk mengidentifikasi area genangan, sedangkan pendekatan OBIA menitikberatkan pada identifikasi batas objek di permukaan bumi untuk memperoleh hasil klasifikasi yang lebih realistis terhadap bentuk alami [13], [14].

Selain kedua pendekatan tersebut, algoritma clustering seperti k-means dan teknik segmentasi multiresolusi juga digunakan untuk menangkap dinamika perubahan tutupan lahan yang berkaitan dengan perkembangan genangan air, terutama ketika data multi-sensor digunakan dalam fusi temporal [15]. Integrasi antara segmentasi berbasis piksel dan *Object-Based Image Analysis* (OBIA) telah terbukti meningkatkan akurasi deteksi banjir dengan mengurangi *noise* dan meningkatkan konsistensi hasil pada data optik dan SAR [14]. Dalam perancangan alur kerja

segmentasi, pemilihan model dan metode harus mempertimbangkan resolusi sensor, kualitas model, serta kebutuhan detail spasial, dengan evaluasi menggunakan metrik seperti akurasi dan F1-score untuk memastikan reliabilitas hasil sebelum dilakukan validasi lapangan [14]. Dengan demikian, segmentasi citra berperan penting dalam menyediakan dasar analisis yang andal untuk pemetaan banjir, mendukung integrasi data optik-SAR, serta menjadi komponen penting dalam pengembangan sistem deteksi banjir berbasis penginderaan jauh [13], [15].

C. Model U-Net

Model U-Net merupakan model berbasis CNN yang dirancang khusus untuk tugas segmentasi citra pada *level pixel*. Arsitektur *U-Net* terdiri atas dua bagian utama, yaitu *encoder* dan *decoder*. Bagian ini berfungsi untuk mengekstraksi fitur dari citra melalui operasi konvolusi dan *pooling*, sedangkan *decoder* bertugas melakukan upsampling dan rekonstruksi citra untuk menghasilkan peta segmentasi dengan resolusi tinggi. Salah satu keunggulan utama *U-Net* adalah adanya koneksi *skip connection* antara lapisan *encoder* dan *decoder*, yang memungkinkan model mempertahankan informasi spasial penting sehingga detail objek tidak hilang selama proses kompresi data [16], [17].



Gambar 1. Arsitektur Model U-Net [18]

Pada Gambar 1 menunjukkan arsitektur *U-Net* yang dibagi menjadi 3 (tiga) bagian, yaitu jalur *contracting/downsaming*, *bottleneck* dan jalur *expanding/upsampling*.

D. Evaluasi Model Intersection over Union (IoU) dan Dice Coefficient (DICE)

Proses evaluasi melibatkan perhitungan beberapa metrik kuantitatif yang mencerminkan kinerja model secara menyeluruh, yaitu *loss*, *accuracy*, *Intersection over Union (IoU)*, dan *Dice Coefficient (DICE)* [19]. Nilai *loss* dihitung menggunakan fungsi *Binary Cross-Entropy* untuk mengukur perbedaan antara hasil prediksi dengan data aktual pada setiap piksel [20]. Metrik *accuracy* digunakan untuk menggambarkan proporsi piksel yang terklasifikasi dengan benar terhadap keseluruhan piksel dalam citra. Berikut persamaan dari *IoU* dan *Dice* yang dapat dilihat pada Persamaan (1) dan (2) :

$$IoU(X, Y) = \frac{Area\ Bersama(X \cap Y)}{Gabungan\ Area\ Ground\ Truth\ dan\ Hasil\ Segmentasi(X \cup Y)} \quad (1)$$

Standar nilai untuk IoU pada umumnya menggunakan 0,5 keatas untuk penetapan mendekti objek yang tepat.


$$DSC(X, Y) = \frac{2 \times Area\ Bersama(X \cap Y)}{Total\ Area\ Ground\ Truth(X) + Total\ Area\ Hasil\ Segmentasi(Y)} \quad (2)$$

Koefisien *Dice* memiliki nilai berkisar antara 0-1, yang mana 0 menunjukkan kedua himpunan tidak tumpang tindih dan 1 menunjukkan kedua himpunan identik[21].

III. METODE YANG DIUSULKAN

A. Arsitektur Model Secara Umum

Model yang diusulkan pada penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan model *Convolutional Neural Network* (CNN) dan arsitektur *U-Net* untuk segmentasi citra dalam identifikasi area genangan banjir. Tahapan penelitian dimulai dengan pengumpulan dataset citra banjir yang bersumber dari platform *Kaggle*, kemudian dilanjutkan dengan tahap pra-pemrosesan untuk menyiapkan data agar sesuai dengan kebutuhan pemodelan. Selanjutnya, dilakukan proses pemodelan menggunakan CNN berbasis *U-Net* guna mendeteksi serta memisahkan area genangan air dari citra satelit secara otomatis. Model kemudian dievaluasi menggunakan metrik kinerja seperti *loss*, akurasi, *Intersection over Union* (IoU), dan *Dice Coefficient* untuk menilai efektifitas segmentasi yang dihasilkan [19]. Berikut langkah-langkah dalam penelitian ini dapat dilihat lebih jelas pada bagan yang di tunjukkan Gambar 2 di bawah ini:



Gambar 2. Langkah-langkah Penelitian

B. Data dan Sumber Data

Dataset yang digunakan berasal dari *platform Kaggle* yang telah diberi anotasi area genangan air. Jumlah keseluruhan data sebanyak 3.401 citra, yang dibagi menjadi 2.380 data pelatihan (80%), 684 data validasi (15%), dan 337 data pengujian (5%). Seluruh citra berformat RGB dengan resolusi 128 x 128 piksel, sedangkan *mask* disusun dalam format biner (0 = tidak tergenang, 1 = genangan air). Dataset disimpan dalam struktur direktori terpisah untuk citra dan *mask* guna memudahkan proses pemuatan data otomatis oleh *TensorFlow* [22].

C. Implementasi Model CNN U-Net

Sebelum dataset masuk ke tahap pemodelan dengan U-Net, dataset yang diperoleh akan melalui tahap *preprocessing* dengan melakukan *resize* citra RGB *mask* menjadi ukuran 128 x 128. Kemudian menerapkan teknik augmentasi *translation*, *rotation*, *zooming*, dan *flipping* untuk meningkatkan variasi data. Normalisasi citra dilakukan dengan mengubah setiap piksel pada citra *mask* menjadi biner nilai 0 (non-genangan) dan 1 (area genangan). Selanjutnya, dataset dibagi menjadi 3 bagian, yaitu data pelatihan (*training*), validasi (*validation*) dan pengujian (*testing*) dengan pembagian 80% citra pelatihan, 15% citra validasi dan 5% citra pengujian. Model dikompilasi menggunakan *optimizer Adam* dengan fungsi kehilangan *Binary Crossentropy*, aktivasi *ReLU*, *padding "same"* dan 30 *epoch* dengan *batch size* = 8. Pada konteks penelitian ini, CNN berperan sebagai dasar arsitektur *U-Net* dalam mengekstraksi ciri-ciri visual dari citra satelit yang mengandung area genangan air. Dengan kemampuan untuk mengidentifikasi pola kompleks dari data visual, CNN memungkinkan model *U-Net* menghasilkan segmentasi citra yang lebih

akurat dan efisien, khususnya dalam kondisi lingkungan yang beragam dan kompleks seperti wilayah terdampak banjir [16], [23].

D. Evaluasi Model


Tahap ini model akan dievaluasi menggunakan beberapa metrik seperti *Accuracy*, *Precision*, *Recall*, *Loss*, *IoU*, dan *Dice Coefficient* [19]. Nilai *loss* dihitung menggunakan fungsi *Binary Cross-Entropy* untuk mengukur perbedaan antara hasil prediksi dengan data aktual pada setiap piksel [20]. Metrik *accuracy* digunakan untuk menggambarkan proporsi piksel yang terklasifikasi dengan benar terhadap keseluruhan piksel dalam citra. Sementara itu, metrik *IoU* digunakan untuk mengevaluasi tingkat tumpang tindih antara area hasil segmentasi dengan area sebenarnya (*ground truth*), yang didefinisikan sebagai rasio antara irisan dan gabungan kedua area tersebut [19]. Nilai *IoU* yang tinggi menunjukkan kesesuaian bentuk dan luas area yang dihasilkan model terhadap citra referensi. Selain itu, *Dice* dihitung untuk menilai kesamaan spasial antara hasil prediksi dan citra referensi, dengan penekanan pada keseimbangan antara *precision* dan *recall* pada tingkat piksel [24]. Kombinasi keempat metrik ini memberikan gambaran menyeluruh terhadap kemampuan model dalam mendeteksi area genangan banjir secara presisi dan konsisten. Untuk memperoleh hasil yang representatif, proses evaluasi dilakukan pada dataset uji yang tidak dilibatkan selama tahap pelatihan maupun validasi.

IV. IMPLEMENTASI MODEL DAN PEMBAHASAN


Bagian ini menyajikan hasil penelitian dalam memanfaatkan model *U-Net* berbasis *Deep Learning* untuk segmentasi citra dalam identifikasi area genangan banjir. Penelitian ini mengambil data citra satelit daerah tergenang air (banjir) melalui dataset publik yaitu *Kaggle*, dengan jumlah dataset satelit sebanyak 3.401 citra RGB kondisi banjir dan 3.401 citra *mask biner* yang menunjukkan area genangan (nilai 1) dan non-genangan (nilai 0). Setiap pasangan citra RGB dan mask merepresentasikan area genangan air dan area non-banjir. Dataset dibagi menjadi tiga bagian yaitu data latih (*train*) sebanyak 2.380 citra, 684 citra validasi dan 337 citra uji (*test*). Evaluasi dilakukan menggunakan metrik *IoU* dan *Dice Coefficient* yang bertujuan mengukur efektivitas model dalam mengenali area genangan air pada citra banjir [25].

A. Pra Pengolahan Data Citra Banjir

Pra pengolahan data citra banjir adalah salah satu langkah awal dalam mempersiapkan serta memperbaiki data citra sebelum digunakan [26]. Proses pra pengolahan data pada penelitian ini adalah *resize* citra RGB *mask* menjadi ukuran 128 x 128 untuk efisiensi komputasi. Normalisasi citra dilakukan dengan mengubah setiap piksel pada citra mask menjadi biner nilai 0 (non-banjir) dan 1 (banjir). Beberapa teknik augmentasi yang digunakan *translation* atau *shift*, *rotation*, *zooming*, dan *flipping* untuk meningkatkan variasi data. Kemudian dilakukan pembagian dataset 80% untuk citra latih, 15% citra validasi, dan 5% citra uji. Hasil pra proses memastikan bahwa setiap citra memiliki pasangan *mask* yang valid, ukuran seragam, dan format data yang sesuai untuk pelatihan jaringan konvolusional.



(a)



Gambar 3. Dataset Citra Area Genangan Banjir : (a) Citra RGB; (b) Citra *Mask*

Pada Gambar 3 di atas menampilkan dataset yang digunakan dalam penelitian untuk mendeteksi area genangan banjir. Bagian (a) menunjukkan citra RGB yang diambil dari hasil pemotretan udara, yang merepresentasikan kondisi visual wilayah terdampak banjir. Sementara, bagian (b) memperlihatkan citra mask hasil notasi yang berfungsi sebagai label *ground truth* untuk proses pelatihan model segmentasi. Area berwarna putih pada citra mask menunjukkan wilayah yang teridentifikasi sebagai genangan air, sedangkan area berwarna hitam menunjukkan wilayah non-banjir.

B. Implementasi Model *U-Net*

Pada tahap ini dilakukan implementasi arsitektur *U-Net* diterapkan untuk segmentasi area genangan banjir berbasis citra udara. Model ini diadopsi karena kemampuannya yang teruji dalam menghasilkan segmentasi presisi tinggi dari dataset yang relatif terbatas. Struktur *encoder-decoder* pada *U-Net* berfungsi mengekstraksi fitur spasial-kontekstual, sementara *skip connection* memastikan retensi detail spasial resolusi tinggi pada keluaran [27]. Untuk pelatihan dan evaluasi, dataset dibagi secara proporsional menjadi himpunan data latih untuk optimasi bobot, himpunan data validasi untuk pemantauan performa dan pencegahan *overfitting* selama pelatihan, serta himpunan data uji independen untuk evaluasi akhir performa model.

1. Arsitektur Model *U-Net*

Penelitian ini menggunakan *U-Net* sebagai model utama untuk segmentasi citra banjir. *U-Net* terdiri atas dua bagian utama, yaitu *encoder* dan *decoder*. *Encoder* berfungsi mengekstraksi fitur spasial dari citra menggunakan lapisan konvolusional bertingkat dengan jumlah filter berturut-turut 16, 32, dan 64, kernel 3x3, aktivasi *ReLU*, dan *padding* "same". Setiap blok diakhiri dengan *MaxPooling2D* untuk menurunkan resolusi spasial dan menangkap fitur global. *Decoder* bertugas merekonstruksi kembali peta fitur menjadi mask segmentasi berukuran asli melalui *Conv2DTranspose* dengan *filter* 32 dan 16 serta *stride* 2 [27]. Untuk menjaga detail tepi dan struktur spasial, digunakan mekanisme *skip connection* yang menggabungkan hasil *upsampling* dengan fitur dari lapisan *encoder* yang sepadan. Lapisan keluaran terdiri atas *Conv2D*(1, 1, *activation*='sigmoid') yang menghasilkan peta probabilitas biner dengan nilai 0–1 untuk setiap piksel.

2. Konfigurasi Pelatihan Model

Model dikompilasi menggunakan *optimizer Adam* dengan fungsi kehilangan *Binary Crossentropy*, yang cocok untuk kasus segmentasi biner. Evaluasi performa dilakukan menggunakan empat metrik utama: *Accuracy*, *Intersection over Union (IoU)*, *Dice Coefficient*, dan *Loss*. Pelatihan dilakukan selama 30 *epoch* dengan *batch size* = 8, menggunakan perangkat GPU melalui *Google Colab* untuk efisiensi komputasi. Data validasi digunakan pada setiap *epoch* untuk memantau kinerja model dan mendeteksi potensi *overfitting*.

TABEL I
PEMBAGIAN DATASET PROSES PELATIHAN, VALIDASI, DAN PENGUJIAN

Jenis Data	Jumlah Citra	Presentase (%)
Training	2.380	80
Validation	684	15
Testing	337	5
Total	3.401	100

Selama proses pelatihan, model menunjukkan peningkatan nilai akurasi dan penurunan nilai *loss* yang signifikan seiring bertambahnya jumlah *epoch*. Proses konvergensi terjadi pada sekitar *epoch* ke-25, di mana *loss* mulai stabil dan tidak menunjukkan *overfitting* yang berarti. Ringkasan hasil pelatihan dan validasi ditunjukkan pada Tabel II.

TABEL II
HASIL AKURASI DAN LOSS SELAMA PELTIHAN DAN VALIDASI

Epoch	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
5	0.886	0.878	0.279	0.302
10	0.898	0.898	0.251	0.254
15	0.910	0.903	0.222	0.245
20	0.916	0.909	0.209	0.230
25	0.924	0.912	0.188	0.221
30	0.926	0.903	0.184	0.244

Hasil pelatihan dan validasi model *U-Net* dirangkum dalam Tabel II di atas menunjukkan performa dievaluasi setiap 5 *epoch*. Proses pelatihan menunjukkan konvergensi yang stabil, ditandai dengan peningkatan *Training Accuracy* dari 0.886 ke 0.926 dan penurunan *Training Loss* dari 0.279 ke 0.184 selama 30 *epoch*.

C. Evaluasi Model

Evaluasi model dilakukan untuk mengukur performa arsitektur *U-Net* dalam mendeteksi dan melakukan segmentasi area genangan banjir berdasarkan data citra udara. Evaluasi mencakup analisis kuantitatif melalui metrik kinerja, analisis visual berdasarkan kurva *training-validation*, *confusion matrix* pada tingkat piksel, serta perbandingan citra hasil segmentasi.

1. Hasil Kinerja Segementasi

Kinerja model diukur menggunakan metrik *Accuracy*, *Precision*, *Recall*, *IoU*, dan *Dice Coefficient* sebagaimana ditunjukkan pada Tabel III. Berdasarkan hasil pengujian pada data testing, model *U-Net* menunjukkan performa yang sangat baik dengan nilai akurasi mencapai 0.908, menunjukkan bahwa sebagian besar piksel berhasil diklasifikasikan secara benar antara area genangan dan non-genangan. Nilai *Precision* sebesar 0.895 dan *Recall* sebesar 0.883 mengindikasikan keseimbangan yang baik antara kemampuan model mendeteksi area banjir dan meminimalkan kesalahan klasifikasi.

Selain itu, nilai *Intersection over Union* (IoU) sebesar 0.800 dan *Dice Coefficient* sebesar 0.889 memperlihatkan tingkat tumpang tindih yang tinggi antara hasil prediksi model dengan *ground truth*, yang berarti *U-Net* mampu menghasilkan segmentasi yang presisi dan konsisten.


TABEL III

HASIL KINERJA SEGMENTASI MENGGUNAKAN ARSITEKTUR U-NET

Metrik Evaluasi	Nilai
Accuracy	0.908
Precision	0.895
Recall	0.883
IoU	0.800
Dice Coefficient	0.889

2. Hasil Kinerja Segementasi

Evaluasi proses pelatihan dilakukan dengan menganalisis kurva *Training vs Validation Loss* dan *Training vs Validation Accuracy* sebagaimana ditunjukkan pada Gambar 4.



Gambar 4. Hasil (a) *Loss* dan (b) *Accuracy* dari *Testing* menggunakan *U-Net*

Kurva loss menunjukkan tren penurunan yang stabil pada kedua fase (pelatihan dan validasi), yang menandakan bahwa model mengalami konvergensi dengan baik tanpa gejala *overfitting*. Nilai *validation loss* mendekati *training loss* pada akhir pelatihan, menandakan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru. Sementara itu, kurva *accuracy* memperlihatkan peningkatan performa yang signifikan hingga mencapai stabilitas pada sekitar *epoch* ke-25 dengan nilai akurasi validasi di atas 0.90. Kesenjangan yang kecil antara akurasi pelatihan dan validasi menunjukkan bahwa proses pelatihan berhasil mengoptimalkan parameter model secara efektif tanpa kehilangan kemampuan prediksi terhadap data validasi.

Evaluasi lebih lanjut dilakukan menggunakan *Confusion Matrix* pada tingkat piksel untuk memeriksa distribusi prediksi antara kelas genangan (*flooded area*) dan non-genangan (*non-flooded area*). Matriks hasil prediksi ditunjukkan sebagai berikut:

TABEL IV
CONFUSION MATRIX (PIXEL LEVEL)

Actual	Prediction	
	0	1
0	2974135	239022
1	268799	2039452

Dari matriks tersebut dapat diinterpretasikan bahwa sebanyak 2.974.135 piksel berhasil diklasifikasikan dengan benar sebagai non-genangan (*True Negative*), dan 2.039.452 piksel terklasifikasi benar sebagai area genangan (*True Positive*). Kesalahan klasifikasi relatif kecil,

ditunjukkan dengan jumlah *False Positive* (239.022 piksel) dan *False Negative* (268.799 piksel). Distribusi ini menunjukkan bahwa model *U-Net* memiliki sensitivitas dan spesifisitas yang seimbang dalam mendeteksi area banjir, sehingga hasil prediksi mampu mencerminkan pola genangan secara spasial dengan akurasi tinggi.

3. Analisis Visual Hasil Segmentasi

Untuk memastikan kemampuan model dalam mengenali pola visual area banjir, dilakukan evaluasi visual terhadap hasil prediksi dibandingkan dengan *ground truth mask*. Perbandingan ini dapat dilihat pada Tabel 5, yang menampilkan pasangan citra RGB input, citra *mask* referensi, dan hasil prediksi *U-Net*.

TABEL V
PERBANDINGAN CITRA HASIL PREDIKSI U-NET DENGAN GROUND TRUTH

Citra Asli RGB	Citra Mask (Ground Truth)	Hasil Prediksi U-Net
		
		
		

Dari hasil visualisasi tersebut terlihat bahwa model *U-Net* mampu menyesuaikan bentuk area genangan dengan baik, mengikuti kontur air pada permukaan tanah atau jalan secara akurat. Hasil segmentasi menunjukkan *edge detection* yang tajam dan proporsi area yang sesuai dengan citra referensi, membuktikan kemampuan *U-Net* dalam menangkap fitur kontekstual dari genangan air secara efektif.

V. KESIMPULAN

Penelitian ini telah berhasil mengimplementasikan arsitektur *U-Net* berbasis *Deep Learning* untuk melakukan segmentasi citra pada area genangan banjir menggunakan dataset citra udara. Berdasarkan hasil evaluasi kuantitatif dan kualitatif, model menunjukkan performa yang baik dengan nilai akurasi mencapai 0.908, *precision* sebesar 0.895, *recall* sebesar 0.883, *IoU* sebesar 0.800, dan *Dice coefficient* sebesar 0.889. Hasil ini menunjukkan bahwa *U-Net* mampu mengidentifikasi area banjir secara efektif melalui pembelajaran spasial yang mendalam dari citra RGB dan menghasilkan segmentasi yang mendekati *ground truth*. Selain itu, model memiliki kemampuan generalisasi yang baik terhadap data baru. Secara visual, hasil segmentasi memperlihatkan ketepatan bentuk dan kontur area genangan, membuktikan bahwa *U-Net* mampu menangkap karakteristik air dan area terendam dengan akurasi tinggi.

Sebagai tindak lanjut, penelitian mendatang dapat diarahkan pada beberapa pengembangan penting seperti menggunakan citra satelit resolusi tinggi seperti *Sentinel* untuk meningkatkan

kemampuan deteksi genangan pada area luas. Penerapan model *U-Net* varian modern seperti *Attention U-Net*, *U-Net++*, atau *SegNet* guna memperbaiki sensitivitas model terhadap perbedaan kontras dan tekstur. Selain itu, pengembangan sistem berbasis *real-time flood monitoring* dengan dukungan *edge computing* atau *IoT drone imagery* juga menjadi arah penelitian yang menjanjikan, terutama untuk mendukung mitigasi bencana dan sistem peringatan dini berbasis teknologi kecerdasan buatan.

REFERENSI

- [1] R. M. Hakim, F. Bioresita, and N. Hayati, "Flood Inundation Identification in Katingan Regency, Indonesia using SAR Data and Adaptive Dynamic Thresholding," in *2023 8th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR)*, IEEE, Oct. 2023, pp. 1–6. doi: 10.1109/APSAR58496.2023.10389043.
- [2] D. Sekarjati *et al.*, "Rapid Monitoring for Flood Inundation Detection-Based Sentinel-1 SAR Image Data and Exposure Assessment in Urban Building Area: Makassar City, Indonesia," 2024, pp. 623–632. doi: 10.1007/978-981-97-0740-9_56.
- [3] S. Awasthi, K. Jain, G. S. Parthiyal, S. Bhattacharjee, and A. Budillon, "DB-SEN1FloodNet: A Deep Learning Based Approach for Flood Inundated Regions Detection using Sentinel-1 Synthetic Aperture Radar Satellite Datasets," in *IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, Jul. 2024, pp. 7062–7065. doi: 10.1109/IGARSS53475.2024.10641181.
- [4] S. Awasthi, K. Jain, G. S. Parthiyal, S. Bhattacharjee, and A. Budillon, "DB-SEN1FloodNet: A Deep Learning Based Approach for Flood Inundated Regions Detection using Sentinel-1 Synthetic Aperture Radar Satellite Datasets," in *IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, Jul. 2024, pp. 7062–7065. doi: 10.1109/IGARSS53475.2024.10641181.
- [5] S. P. Dulam, V. Samadi, and C. Toxtli-Hernández, "Application of Advanced Deep Learning Models for Flood Image Processing and Semantic Segmentation," Jan. 2025. doi: 10.5194/egusphere-egu24-22491.
- [6] M. A. Afzal *et al.*, "Flood Inundation Modeling by Integrating HEC-RAS and Satellite Imagery: A Case Study of the Indus River Basin," *Water (Basel)*, vol. 14, no. 19, p. 2984, Sep. 2022, doi: 10.3390/w14192984.
- [7] K. He, W. Peng, Y. Zhang, and P. Pei, "Research on the development of image segmentation based on deep learning," in *2024 2nd International Conference on Mechatronics, IoT and Industrial Informatics (ICMIII)*, IEEE, Jun. 2024, pp. 310–316. doi: 10.1109/ICMIII62623.2024.00063.
- [8] Y. Du and L. Lu, "Rapid and Accurate Detection of Flood Inundation Areas From Sentinel-1 SAR Data Using a Modified DeeplabV3+ Model," in *IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, Jul. 2024, pp. 8250–8254. doi: 10.1109/IGARSS53475.2024.10641874.
- [9] T. R. Wulan *et al.*, "Pemetaan Cepat Kawasan Terdampak Bencana Longsor Dan Banjir Di Kabupaten Bangli, Provinsi Bali," 2017. doi: 10.22146/mgi.26230.
- [10] A. Hardy, G. Oakes, and G. Ettrich, "Tropical Wetland (TropWet) Mapping Tool: The Automatic Detection of Open and Vegetated Waterbodies in Google Earth Engine for Tropical Wetlands," *Remote Sens (Basel)*, vol. 12, no. 7, p. 1182, Apr. 2020, doi: 10.3390/rs12071182.
- [11] C. Theodoridis, A. Argyriou, A. Tsouni, M. Kaskara, and C. Kontoes, "Comparative analysis of Sentinel-1 and PlanetScope imagery for flood mapping of Evros River, Greece," in *Ninth International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2023)*, K. Themistocleous, S. Michaelides, D. G. Hadjimitsis, and G. Papadavid, Eds., SPIE, Sep. 2023, p. 70. doi: 10.1117/12.2682775.
- [12] A. Betterle and P. Salamon, "Water depth estimate and flood extent enhancement for satellite-based inundation maps," Feb. 2024. doi: 10.5194/nhess-2024-22.
- [13] K. A. Lubis, M. Rusdi, and S. Sugianto, "Proses Segmentasi Citra Satelit Untuk Pemetaan Tutupan Lahan," *Jurnal Ilmiah Mahasiswa Pertanian*, vol. 6, no. 4, pp. 691–698, Nov. 2021, doi: 10.17969/jimfp.v6i4.18414.
- [14] E. Miranda and M. Aryuni, "Klasifikasi Tutupan Lahan Menggunakan Convolutional Neural Network pada Citra Satelit Sentinel-2," *SISTEMASI*, vol. 10, no. 2, p. 323, May 2021, doi: 10.32520/stmsi.v10i2.1226.
- [15] A. Premana, R. M. H. Bhakti, and D. Prayogi, "Segmentasi K-Means Clustering Pada Citra Menggunakan Ekstraksi Fitur Warna dan Tekstur," *Jurnal Ilmiah Intech : Information Technology Journal of UMUS*, vol. 2, no. 01, May 2020, doi: 10.46772/intech.v2i01.190.
- [16] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," 2015, pp. 234–241. doi: 10.1007/978-3-319-24574-4_28.
- [17] N. Ibtihaz and M. S. Rahman, "MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation," *Neural Networks*, vol. 121, pp. 74–87, Jan. 2020, doi: 10.1016/j.neunet.2019.08.025.
- [18] I. B. L. M. Suta, M. Sudarma, and I. N. Satya Kumara, "Segmentasi Tumor Otak Berdasarkan Citra Magnetic Resonance Imaging Dengan Menggunakan Metode U-NET," *Majalah Ilmiah Teknologi Elektro*, vol. 19, no. 2, p. 151, Dec. 2020, doi: 10.24843/MITE.2020.v19i02.P05.
- [19] Y. Rahman Md Atiqur; Wang, "Optimizing intersection-over-union in deep neural networks for image segmentation," 2016, pp. 234–244. doi: 10.1007/978-3-319-50835-4_21.

-
- [20] Y. C. A. Goodfellow Ian; Bengio, *Deep Learning*. MIT Press, 2016. [Online]. Available: <https://www.deeplearningbook.org/>
- [21] S. Sonia and Y. Yohannes, "Penerapan Model U-Net untuk Segmentasi Gigi pada Citra Radiografi Panoramik Orang Dewasa," *Jurnal Algoritme*, vol. 5, no. 2, pp. 188–198, Apr. 2025, doi: 10.35957/algoritme.v5i2.10965.
- [22] P. C. J. C. Z. D. A. D. J. . . . ; Z. X. Abadi Martin; Barham, "TensorFlow: A system for large-scale machine learning," 2016, pp. 265–283. [Online]. Available: <https://www.usenix.org/conference/osdi16/technical-sessions/presentation/abadi>
- [23] W. Li, H. Fu, L. Yu, and A. Cracknell, "Deep Learning Based Oil Palm Tree Detection and Counting for High-Resolution Remote Sensing Images," *Remote Sens (Basel)*, vol. 9, no. 1, p. 22, Dec. 2016, doi: 10.3390/rs9010022.
- [24] C. H. Sudre, W. Li, T. Vercauteren, S. Ourselin, and M. Jorge Cardoso, "Generalised Dice Overlap as a Deep Learning Loss Function for Highly Unbalanced Segmentations," 2017, pp. 240–248. doi: 10.1007/978-3-319-67558-9_28.
- [25] A. Sasongko, M. S. Maulana, A. Mustopa, and W. Nugraha, "Automatic Wound Image Segmentation with U-Net Model for Smartphone Application," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 10, no. 2, p. 267, Aug. 2024, doi: 10.26418/jp.v10i2.78548.
- [26] N. Pramesti and R. Rianto, "Convolutional Neural Network for Identifying Tree Species Using Stem Images," 2023. doi: 10.31315/telematika.v20i2.8774.
- [27] E. Ermatita and W. Ningsih, "Arsitektur U-Net Pada Segmentasi Citra Paru Untuk Mendeteksi Nodul Paru," 2025. doi: 10.52436/1.jpti.600.
-