



Segmentasi Citra Wayang Kulit Pandawa Berkompleksitas Visual Tinggi Menggunakan Model U-Net Berbasis Convolutional Neural Network

Krisna Refiansyah*, Mutaqin Akbar

Program Studi Informatika, Fakultas Teknologi Informasi, Universitas Mercu Buana Yogyakarta, Yogyakarta

Jl. Jembatan Merah No. 84C, Condongcatur, Depok, Sleman, Daerah Istimewa Yogyakarta, Indonesia

Email: ¹*221110093@student.mercubuana-yogya.ac.id, ²mutaqin@mercubuana-yogya.ac.id

Email Penulis Korespondensi: 221110093@student.mercubuana-yogya.ac.id

Submitted: 20/05/2026; Accepted: 04/7/2026; Published: 05/07/2026

Abstrak—Wayang kulit merupakan salah satu warisan budaya Indonesia yang memiliki nilai historis dan artistik tinggi. Kompleksitas latar belakang citra digital wayang kulit menjadi tantangan utama dalam proses segmentasi otomatis, terutama karena variasi pencahayaan, detail ornamen tatahan yang halus, serta keterbatasan metode konvensional dalam menangani variasi visual yang tinggi. Penelitian ini bertujuan mengimplementasikan arsitektur U-Net berbasis Convolutional Neural Network (CNN) untuk segmentasi citra wayang kulit Pandawa yang meliputi lima karakter utama: Puntadewa, Janaka, Werkudara, Nakula, dan Sadewa. Dataset terdiri dari 1.500 citra wayang kulit beserta topeng ground truth yang dikumpulkan secara mandiri dan dibagi menjadi 1.093 data pelatihan, 157 data validasi, dan 250 data pengujian. Model U-Net dibor menggunakan optimizer Adam dengan learning rate awal 1×10^{-4} , fungsi loss gabungan Binary Cross-Entropy dan Dice Loss, serta ukuran input 128×128 piksel. Mekanisme EarlyStopping dan ReduceLROnPlateau diterapkan untuk mengoptimalkan pelatihan dan mencegah overfitting selama proses pembelajaran berlangsung. Pengujian pada 250 data uji menghasilkan Accuracy 95,8%, AUC 98,6%, Dice Coefisien 91,9%, IoU 86,9%, Precision 91,5%, dan Recall 95,0%. Penelitian terdahulu terkait wayang kulit masih terbatas pada klasifikasi citra, sedangkan penerapan U-Net lebih banyak ditemukan pada domain medis dan satelit, sehingga penelitian ini hadir untuk mengisi celah tersebut dan berkontribusi pada pengembangan teknologi digitalisasi warisan budaya Indonesia. Kontribusi utama penelitian ini adalah menghadirkan model segmentasi citra berbasis deep learning pertama yang secara khusus memisahkan siluet wayang kulit Pandawa dari latar belakang secara otomatis, membuktikan efektivitas arsitektur U-Net pada objek warisan budaya berkompleksitas visual tinggi, serta menetapkan baseline kinerja segmentasi pada domain warisan budaya visual Indonesia yang dapat menjadi acuan bagi pengembangan sistem digitalisasi wayang kulit selanjutnya.

Kata Kunci: Segmentasi Citra; Wayang Kulit; U-Net; Convolutional Neural Network; Deep Learning

Abstract—Shadow puppetry (wayang kulit) is one of Indonesia's cultural heritages with significant historical and artistic value. The complexity of digital image backgrounds in wayang kulit poses a major challenge in automatic segmentation, particularly due to lighting variations, intricate carving (tatahan) details, and the limitations of conventional methods in handling high visual variability. This study aims to implement a U-Net architecture based on Convolutional Neural Network (CNN) for segmenting images of Pandawa shadow puppet characters encompassing five main characters: Puntadewa, Janaka, Werkudara, Nakula, and Sadewa. The dataset consists of 1,500 independently collected shadow puppet images with ground truth masks divided into 1,093 training, 157 validation, and 250 test data. The U-Net model was trained using the Adam optimizer with an initial learning rate of 1×10^{-4} , combined Binary Cross-Entropy and Dice Loss function, and 128×128 pixel input size. Early stopping and automatic learning rate adjustment via ReduceLROnPlateau were applied to optimize training and prevent overfitting throughout the learning process. The model achieved Accuracy 95.8%, AUC 98.6%, Dice Coefficient 91.9%, IoU 86.9%, Precision 91.5%, and Recall 95.0% on 250 test data. Previous studies on wayang kulit have been limited to image classification, while U-Net applications have been predominantly found in medical and satellite domains, making this study a novel contribution that addresses an existing research gap and supports the digitalization of Indonesian cultural heritage. The contribution of this study is to provide the first deep learning-based image segmentation model specifically designed to automatically separate Pandawa wayang kulit silhouettes from their backgrounds, demonstrating the effectiveness of U-Net architecture on cultural heritage objects with high visual complexity, and establishing a segmentation performance baseline for the Indonesian visual cultural heritage domain that can serve as a reference for future wayang kulit digitalization system development.

Keywords: Image Segmentation; Wayang Kulit; U-Net; Convolutional Neural Network; Deep Learning

1. PENDAHULUAN

Wayang kulit Pandawa merupakan salah satu warisan budaya Indonesia yang kaya akan nilai filosofis dan estetika visual, di mana setiap tokoh memiliki ciri khas bentuk siluet, ornamen, dan proporsi yang unik. Sejak 2003, kerajinan tradisional wayang kulit ditetapkan oleh UNESCO sebagai Warisan Kemanusiaan yang mencakup budaya lisan maupun nonbendawi. Data Badan Pusat Statistik tahun 2021 mencatat minat terhadap seni wayang mengalami penurunan sebesar 23,06% dalam kurun waktu 2018 hingga 2021 [1]. Sapphira (2023) menegaskan bahwa tradisi dan modernisasi dapat berjalan selaras melalui digitalisasi, sehingga teknologi pengolahan citra menjadi instrumen penting dalam pelestarian warisan budaya [2].

Analisis bentuk dan ciri visual tokoh wayang kulit sering terhambat oleh kompleksitas latar belakang citra digital [3]. Secara teknis, wayang kulit memiliki karakteristik visual yang sangat menantang untuk disegmentasi. Ornamen tatahan merupakan lubang-lubang kecil berukuran sub-piksel yang diukir tembus pada kulit, sehingga ketika resolusi input direduksi, detail tersebut hilang dan tepi objek menjadi ambigu antara area berlubang dan latar belakang. Selain itu, pola ukiran yang rumit pada mahkota dan kostum setiap tokoh menciptakan kontur yang

tidak beraturan dan sulit dibedakan secara otomatis, sementara variasi proporsi tubuh antar lima karakter Pandawa yang signifikan menuntut presisi tinggi dalam proses pemisahan objek. Kondisi ini diperparah dengan keragaman latar belakang citra yang dikumpulkan dari berbagai sumber digital dengan kualitas yang bervariasi. Metode konvensional seperti thresholding dan edge detection kerap mengalami penurunan performa ketika menghadapi variasi pencahayaan tinggi dan latar belakang yang rumit [4]. Sebagai alternatif yang lebih andal, Convolutional Neural Network (CNN) mampu mengekstraksi fitur secara hierarkis dan otomatis tanpa rekayasa fitur manual sehingga lebih robust terhadap variasi citra [5]. Nasrullah dan Annur (2023) membuktikan bahwa CNN mampu mengidentifikasi citra digital dengan akurasi tinggi meskipun dilatih pada dataset yang terbatas [6].

Sejumlah penelitian membuktikan efektivitas CNN dalam klasifikasi citra wayang kulit. Nurhasanah dkk. (2025) mencapai akurasi 93,90% menggunakan ResNet-18 [7]. Handani dkk. (2025) mengklasifikasikan tokoh Pandawa dan mencapai akurasi 95,70% [8]. Pratama dkk. (2022) memperoleh akurasi 92,27% dalam menentukan gagrak wayang [9], sedangkan Khoirun Nisa' dkk. (2025) melaporkan akurasi 89,50% pada klasifikasi tokoh Kurawa [10]. Setiawan dkk. (2026) mengklasifikasikan tokoh wayang Mahabharata menggunakan arsitektur ConvNeXt-Small dengan hasil yang sangat kompetitif [11]. Meskipun seluruh penelitian tersebut berhasil mencapai akurasi klasifikasi yang tinggi, pendekatan klasifikasi hanya mampu mengidentifikasi kelas tokoh secara keseluruhan tanpa memberikan informasi spasial mengenai lokasi dan batas objek wayang dalam citra. Hal ini menjadi keterbatasan mendasar ketika tujuan penelitian adalah memisahkan siluet wayang dari latar belakang secara piksel per piksel, sebagaimana dibutuhkan dalam aplikasi digitalisasi dan analisis bentuk visual. Dengan demikian, penelitian-penelitian tersebut menunjukkan bahwa CNN terbukti efektif untuk analisis citra wayang kulit, namun seluruhnya masih berfokus pada tahap klasifikasi, bukan segmentasi objek secara spesifik.

Di sisi segmentasi, U-Net menjadi arsitektur encoder-decoder yang banyak digunakan di berbagai domain. Ermatita dan Ningsih (2025) menerapkan U-Net untuk segmentasi citra paru dan mencapai akurasi 94% [12]. Setadewa dkk. (2025) melaporkan Dice 89% dan IoU 81% pada segmentasi citra satelit beresolusi tinggi menggunakan U-Net berbasis VGG16 [13]. Pada objek budaya, Fahrudin dan Akbar (2026) memperoleh Dice 87,07% dan IoU 77,23% pada segmentasi pola batik Yogyakarta menggunakan SegNet [14]. Hasil-hasil tersebut menunjukkan bahwa arsitektur berbasis encoder-decoder memiliki potensi besar dalam segmentasi objek dengan tekstur dan detail visual yang kompleks, termasuk pada objek warisan budaya yang memiliki karakteristik unik.

Berdasarkan kajian literatur yang telah dilakukan, terdapat celah penelitian yang signifikan: hingga saat ini belum ada penelitian yang secara khusus menerapkan U-Net untuk segmentasi citra wayang kulit Pandawa. Seluruh penelitian terdahulu terkait wayang kulit masih terbatas pada klasifikasi, sedangkan penelitian segmentasi berbasis U-Net lebih banyak diterapkan pada domain medis dan satelit. Celah inilah yang menjadi dasar penelitian ini. Selain itu, tantangan teknis berupa detail tatahan wayang yang sangat halus, variasi pencahayaan, serta keragaman latar belakang citra menjadikan segmentasi wayang kulit sebagai permasalahan yang lebih kompleks dibandingkan objek segmentasi pada umumnya. Karakteristik unik wayang kulit seperti kontur siluet yang tidak beraturan, ornamen tatahan berupa lubang-lubang kecil pada tubuh wayang, serta perbedaan proporsi yang signifikan antar lima karakter Pandawa menuntut metode segmentasi yang mampu menangani variasi bentuk secara akurat dan konsisten.

Oleh karena itu, penelitian ini bertujuan mengimplementasikan model U-Net berbasis CNN untuk segmentasi citra wayang kulit Pandawa guna memisahkan objek wayang dari latar belakang secara otomatis piksel per piksel. Model dievaluasi menggunakan enam metrik evaluasi yaitu Accuracy, AUC, Dice Coefisien, IoU, Precision, dan Recall untuk mengukur kinerja segmentasi secara komprehensif. Penelitian ini berkontribusi dalam membangun model segmentasi citra berbasis deep learning yang pertama kali diterapkan secara khusus pada domain wayang kulit Pandawa sehingga mengisi ruang penelitian yang belum pernah dieksplorasi sebelumnya, membuktikan efektivitas arsitektur U-Net pada objek warisan budaya berkompleksitas visual tinggi, serta menetapkan baseline kinerja segmentasi pada domain warisan budaya visual Indonesia yang dapat menjadi acuan bagi analisis pengembangan sistem digitalisasi, bentuk siluet, maupun penyimpanan wayang kulit melalui teknologi pengolahan citra digital.


2. METODOLOGI PENELITIAN

2.1 Alur Penelitian

Penelitian ini menggunakan pendekatan experimental research dengan metode supervised learning. Metodologi dirancang secara sistematis mulai dari studi literatur, pengumpulan dan anotasi data, preprocessing, augmentasi, pelatihan model U-Net, pengujian, hingga evaluasi kinerja. Alur penelitian secara keseluruhan disajikan pada Gambar 1.

Gambar 1 menunjukkan blok diagram alur penelitian yang terdiri dari delapan tahapan berurutan. Penelitian diawali dengan studi literatur untuk memahami konsep segmentasi citra dan arsitektur U-Net, dilanjutkan dengan pengumpulan citra wayang kulit dari berbagai sumber digital. Citra yang terkumpul kemudian melalui proses anotasi menggunakan LabelMe untuk menghasilkan mask biner sebagai ground truth. Tahap selanjutnya adalah preprocessing yang mencakup resize dan normalisasi citra, diikuti augmentasi data untuk memperbesar keragaman

dataset pelatihan. Model U-Net kemudian dilatih menggunakan dataset yang telah dipersiapkan, lalu diuji dan dievaluasi kinerjanya menggunakan enam metrik evaluasi.



Gambar 1. Blok Diagram Alur Penelitian

2.2 Dataset

Dataset yang digunakan merupakan kumpulan citra wayang kulit tokoh Pandawa Lima terdiri dari lima kelas: Janaka (Arjuna), Nakula, Puntadewa (Yudistira), Sadewa, dan Werkudara (Bima). Pengumpulan citra dilakukan secara mandiri dari berbagai sumber digital meliputi Instagram, Pinterest, TikTok, situs web budaya, kanal YouTube, dan pameran wayang kulit daring. Untuk memitigasi risiko artefak kompresi dari platform media sosial seperti TikTok dan Instagram, setiap citra melalui proses seleksi manual sebelum anotasi. Citra yang menunjukkan kualitas rendah, blur berlebihan, artefak kompresi JPEG yang terlihat seperti blok piksel pada tepi objek, atau noise digital yang signifikan dikeluarkan dari dataset. Hanya citra yang memiliki tepi siluet wayang yang relatif jelas dan detail tatahan yang masih dapat diidentifikasi secara visual yang dipertahankan untuk proses anotasi lebih lanjut.

Tabel 1. Distribusi Dataset per Kelas Wayang Kulit Pandawa

No	Kelas Wayang	Training	Validation	Testing	Total
1	Janaka (Arjuna)	218	32	50	300
2	Nakula	219	31	50	300
3	Puntadewa (Yudistira)	219	31	50	300
4	Sadewa	218	32	50	300
5	Werkudara (Bima)	219	31	50	300
	Total	1.093	157	250	1.500

Tabel 1 menunjukkan distribusi dataset yang terdiri dari 1.500 citra wayang kulit yang terbagi merata ke dalam lima kelas tokoh Pandawa. Setiap kelas memiliki 300 citra dengan pembagian 218–219 data training, 31–32 data validasi, dan 50 data testing. Pembagian yang merata antar kelas ini memastikan model tidak bias terhadap kelas tertentu selama proses pelatihan dan pengujian. Total keseluruhan terdiri dari 1.093 data training, 157 data validasi, dan 250 data testing.

2.3 Preprocessing Data

Tahap preprocessing bertujuan menyeragamkan ukuran dan nilai piksel seluruh citra sebelum masuk ke model. Seluruh citra dan mask diubah ukurannya menjadi 128×128 piksel menggunakan cv2.resize. Ukuran 128×128 piksel dipilih sebagai keseimbangan antara efisiensi komputasi dan kualitas segmentasi, mengingat keterbatasan sumber daya GPU yang tersedia. Pilihan resolusi ini memang berdampak pada hilangnya sebagian detail ornamen tatahan yang sangat halus, namun merupakan kompromi terbaik yang dapat dilakukan dalam penelitian ini, dan penggunaan resolusi yang lebih besar direkomendasikan untuk penelitian lanjutan guna meningkatkan presisi segmentasi pada area detail. Kemudian nilai piksel dinormalisasi dari rentang 0–255 menjadi 0–1. Proses normalisasi dinyatakan pada persamaan (1). Algoritma pengolahan citra yang tepat terbukti meningkatkan kualitas data secara substansial sehingga mendukung akurasi model yang lebih baik [15]. Untuk mask, nilai piksel dikonversi menjadi biner di mana piksel > 0 bernilai 1 (objek wayang) dan piksel = 0 bernilai 0 (background). Pipeline dataset dibuat menggunakan tf.data.Dataset dengan konfigurasi AUTOTUNE untuk pembacaan data on-demand per batch.

$$I_{\text{norm}}(x, y) = \frac{I(x, y)}{255} \quad (1)$$

2.4 Augmentasi Data

Augmentasi data diterapkan guna memperbesar keragaman data pelatihan agar model lebih robust dan meminimalkan overfitting. Augmentasi hanya diterapkan pada data pelatihan dan setiap transformasi diterapkan

secara bersamaan pada pasangan citra dan mask untuk menjaga keselarasan ground truth. Pendekatan akselerasi komputasi berbasis GPU seperti yang dikaji Akbar dkk. (2019) menunjukkan bahwa parallelisasi sangat mendukung efisiensi pipeline pengolahan citra berskala besar [16]. Konfigurasi augmentasi disajikan pada Tabel 2.


Tabel 2. Konfigurasi Augmentasi Data

No	Jenis Augmentasi	Parameter	Nilai
1	Horizontal Flip	—	0,5
2	Vertical Flip	—	0,3
3	Rotasi	limit = 15°	0,5
4	Random Brightness Contrast	brightness_limit = ±0,2; contrast_limit = ±0,2	0,5
5	Gaussian Noise	var_limit = 5–25	0,3

Tabel 2 menunjukkan lima jenis augmentasi yang diterapkan pada data pelatihan. Horizontal flip dan rotasi dengan limit 15° diterapkan dengan probabilitas 0,5 untuk mensimulasikan variasi orientasi wayang kulit. Vertical flip dan gaussian noise dengan var_limit 5–25 diterapkan dengan probabilitas 0,3 untuk menangani variasi posisi dan gangguan noise. Random brightness contrast dengan batas ±0,2 diterapkan dengan probabilitas 0,5 untuk mensimulasikan variasi pencahayaan yang umum terjadi pada citra wayang kulit dari berbagai sumber digital.

2.5 Arsitektur Model U-Net

Model yang diimplementasikan adalah arsitektur U-Net berbasis CNN dengan ukuran input 128×128×3 piksel (RGB). Arsitektur ini merupakan adaptasi dari U-Net Ronneberger et al. (2015) dengan dua penyesuaian utama: (1) ukuran input direduksi menjadi 128×128 piksel dari ukuran asli 572×572, dan (2) penambahan Batch Normalization pada setiap blok konvolusi untuk meningkatkan stabilitas pelatihan dan mempercepat konvergensi. U-Net dipilih karena kemampuannya dalam melakukan pixel-wise classification dan mempertahankan informasi spasial melalui mekanisme skip connection [17], [18]. Arsitektur model disajikan pada Gambar 2.



Gambar 2. Arsitektur Model U-Net yang Diimplementasikan

Gambar 2 mengilustrasikan keseluruhan struktur U-Net yang diimplementasikan, menunjukkan alur data dari input 128×128×3 piksel melalui encoder, bottleneck, hingga decoder dengan mekanisme skip connection pada setiap levelnya. Encoder terdiri dari empat blok konvolusi dengan dua convolutional layer 3×3 (He Normal, Batch Normalization, ReLU) dan MaxPooling 2×2. Batch Normalization ditambahkan untuk meningkatkan stabilitas pelatihan dan mempercepat konvergensi. Filter meningkat: 32→64→128→256. Operasi konvolusi dinyatakan pada persamaan (2). Bottleneck terdiri dari dua convolutional layer 3×3 dengan 512 filter. Decoder menggunakan Conv2DTranspose 2×2, concatenation dengan skip connection, dan dua convolutional layer 3×3; filter berkurang: 256→128→64→32. Output layer menggunakan konvolusi 1×1 dengan aktivasi sigmoid pada persamaan (3) yang menghasilkan segmentasi biner dengan threshold 0,5. CNN secara umum telah terbukti memberikan kinerja sangat baik pada berbagai tugas analisis citra, termasuk segmentasi objek medis maupun budaya [19].

$$S(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n) \quad (2)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

2.6 Proses Pelatihan Model

Model dikompilasi menggunakan fungsi loss gabungan Binary Cross-Entropy (BCE) dan Dice Loss persamaan (4). BCE efektif mengukur kesalahan pada tingkat piksel, sedangkan Dice Loss lebih sensitif terhadap kualitas segmentasi pada area objek kecil [20]. BCE dinyatakan pada persamaan (5) dan Dice Loss pada persamaan (6).

$$L_{\text{total}} = L_{\text{BCE}} + L_{\text{Dice}} \quad (4)$$

$$L_{\text{BCE}} = -\frac{1}{N} \sum [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (5)$$

$$L_{\text{Dice}} = 1 - \frac{2 \sum y_i \hat{y}_i + \varepsilon}{\sum y_i + \sum \hat{y}_i + \varepsilon} \quad (6)$$

Dimana y_i adalah label ground truth, $\hat{y}_i$ adalah nilai prediksi, N adalah total piksel, dan $\varepsilon = 1 \times 10^{-7}$ adalah konstanta smoothing. Optimizer Adam digunakan dengan learning rate awal 1×10^{-4} . Tiga callback diterapkan: (1) EarlyStopping (patience=10); (2) ReduceLROnPlateau (faktor 50%, patience=5); (3) ModelCheckpoint berdasarkan val_dice_coefficient tertinggi. Konfigurasi hyperparameter disajikan pada Tabel 3.

Tabel 3. Konfigurasi Hyperparameter Pelatihan Model

Parameter	Nilai
Ukuran Input Citra	128 × 128 piksel
Batch Size	4
Epochs Maksimal	50
Learning Rate Awal	0,0001 (1×10^{-4})
Optimizer	Adam
Fungsi Loss	BCE + Dice Loss
Threshold Segmentasi	0,5
Validation Split	12,5%

Tabel 3 menunjukkan konfigurasi hyperparameter yang digunakan dalam pelatihan model. Ukuran input ditetapkan 128×128 piksel dengan batch size 4 untuk menyeimbangkan efisiensi memori dan stabilitas gradien. Epochs maksimal ditetapkan 50 dengan mekanisme EarlyStopping untuk menghentikan pelatihan apabila tidak ada peningkatan signifikan. Learning rate awal 1×10^{-4} menggunakan optimizer Adam dipilih karena kemampuannya melakukan adaptasi learning rate secara otomatis. Fungsi loss gabungan BCE + Dice Loss digunakan untuk mengoptimalkan segmentasi pada tingkat piksel sekaligus menjaga kualitas area objek kecil. Threshold segmentasi 0,5 diterapkan untuk mengkonversi output sigmoid menjadi mask biner.

2.7 Evaluasi Model

Evaluasi kinerja model menggunakan tiga metrik utama yang umum digunakan dalam tugas segmentasi citra. Akurasi mengukur proporsi piksel yang diklasifikasikan benar persamaan (7). IoU (indeks Jaccard) mengukur perbandingan irisan dan gabungan antara prediksi dan ground truth persamaan (8); Ayu dan Pradipta (2024) menggunakan IoU sebagai metrik utama evaluasi U-Net pada segmentasi citra medis [21]. Dice Coefficient mengukur kesamaan antara prediksi dan ground truth dengan bobot lebih pada true positives persamaan (9); Ramdhani dkk. (2025) dan Sulistyorini dkk. (2023) menjadikan Dice coefficient sebagai acuan utama pemilihan model terbaik pada segmentasi citra [20], [22].

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

$$\text{IoU} = \frac{TP + \varepsilon}{TP + FP + FN + \varepsilon} \quad (8)$$

$$\text{Dice} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (9)$$

Dimana TP = piksel objek yang diprediksi benar; TN = piksel background yang diprediksi benar; FP = piksel background yang salah diprediksi sebagai objek; FN = piksel objek yang salah diprediksi sebagai background; $\varepsilon = 1 \times 10^{-7}$ untuk menghindari pembagian dengan nol.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Praproses Data

Sebelum pelatihan, seluruh citra melalui tahap praproses. Setiap citra diubah ukurannya menjadi 128×128 piksel, dinormalisasi ke rentang [0,1], dan nilai piksel mask dikonversi menjadi representasi biner. Gambar 3 menyajikan visualisasi praproses berupa citra original, mask ground truth, dan overlay contoh salah satu dari kelima karakter Pandawa.



Gambar 3. Hasil Praproses Data: Citra Original, Mask, dan Overlay

3.2 Proses Pelatihan Model

Pelatihan model U-Net dilakukan selama 50 epoch menggunakan optimizer Adam ($lr=1 \times 10^{-4}$), batch size 4, dan fungsi loss gabungan BCE + Dice Loss. Pada epoch ke-1, model mencatat Dice validation 0,7090 yang meningkat konsisten hingga nilai tertinggi 0,9624 pada epoch ke-45 sebagai model terbaik. ReduceLROnPlateau menurunkan learning rate dari 1×10^{-4} menjadi 5×10^{-5} pada epoch ke-26, dan menjadi $2,5 \times 10^{-5}$ pada epoch ke-32. Metrik training dan validasi per epoch disajikan pada Tabel 4 dan Tabel 5.

Tabel 4. Metrik Training Model U-Net per Epoch


Epoch	Loss	Acc	AUC	Dice	IoU	Precision	Recall
1	0,6619	0,8647	0,9423	0,6759	0,6721	0,7155	0,8672
10	0,1486	0,9736	0,9937	0,9308	0,9126	0,9492	0,9582
20	0,1044	0,9809	0,9955	0,9555	0,9361	0,9629	0,9700
32	0,0824	0,9848	0,9967	0,9650	0,9486	0,9702	0,9765
45	0,0725	0,9865	0,9977	0,9677	0,9529	0,9735	0,9792
50	0,0729	0,9865	0,9974	0,9690	0,9547	0,9733	0,9792

Tabel 4 menunjukkan bahwa training loss mengalami penurunan yang konsisten dari 0,6619 pada epoch ke-1 menjadi 0,0725 pada epoch ke-45, sementara Dice coefficient meningkat signifikan dari 0,6759 menjadi 0,9677. Accuracy training juga meningkat dari 0,8647 menjadi 0,9865, dan AUC dari 0,9423 menjadi 0,9977. Peningkatan seluruh metrik training yang stabil dan konsisten menunjukkan bahwa model berhasil mempelajari pola segmentasi wayang kulit dengan baik sepanjang proses pelatihan. Mekanisme ReduceLROnPlateau menurunkan learning rate dari 1×10^{-4} menjadi 5×10^{-5} pada epoch ke-26, dan menjadi $2,5 \times 10^{-5}$ pada epoch ke-32, sehingga konvergensi model tetap terjaga tanpa indikasi overfitting.

Tabel 5. Metrik Validasi Model U-Net per Epoch


Epoch	Loss	Acc	AUC	Dice	IoU	Precision	Recall
1	0,5282	0,9193	0,9549	0,7090	0,7276	0,9137	0,7750
10	0,1476	0,9745	0,9945	0,9296	0,9113	0,9473	0,9589
20	0,1057	0,9809	0,9957	0,9523	0,9303	0,9718	0,9570
32	0,0938	0,9833	0,9960	0,9588	0,9399	0,9676	0,9706
45	0,0895	0,9843	0,9959	0,9624	0,9434	0,9687	0,9733
50	0,0907	0,9841	0,9956	0,9617	0,9428	0,9708	0,9704

Tabel 5 menunjukkan bahwa val_Dice meningkat konsisten dari 0,7090 pada epoch ke-1 menjadi 0,9624 pada epoch ke-45, sedangkan val_Accuracy meningkat dari 0,9193 menjadi 0,9843 dan val_AUC dari 0,9549 menjadi 0,9959. Selisih yang sangat kecil antara metrik training (Tabel 4) dan metrik validasi (Tabel 5) mengkonfirmasi tidak terjadi overfitting dan model mampu melakukan generalisasi dengan baik. Mekanisme EarlyStopping dan ReduceLROnPlateau berhasil menjaga proses konvergensi tetap stabil, sejalan dengan praktik pelatihan deep learning untuk segmentasi citra yang direkomendasikan Putranto dkk. (2023) [23]. Progres kinerja model sepanjang proses pelatihan dapat dilihat pada Gambar 4 sampai Gambar 9.




Gambar 4. Grafik Training vs Validation Loss (kiri) dan Training vs Validation Accuracy (kanan)

Gambar 4 menunjukkan train loss dan val loss menurun tajam pada epoch awal dan terus turun secara gradual hingga epoch ke-45 tanpa gap yang signifikan, mengkonfirmasi tidak terjadi overfitting. Pada grafik yang sama, accuracy training dan validasi meningkat pesat di awal lalu stabil di atas 0,98 mulai epoch ke-20, membuktikan model telah mencapai konvergensi yang baik pada kedua set data.



Gambar 5. Grafik Training vs Validation AUC (kiri) dan Training vs Validation Dice Coefficient (kanan)

Gambar 5 menunjukkan AUC training dan validasi stabil di kisaran 0,995–0,998 setelah epoch ke-10, mengindikasikan kemampuan model membedakan piksel objek dan background sangat tinggi dan konsisten. Pada grafik yang sama, val_Dice meningkat konsisten dari 0,7090 (epoch 1) menjadi 0,9624 (epoch 45), membuktikan kualitas segmentasi terus membaik seiring bertambahnya epoch pelatihan.



Gambar 6. Grafik Training vs Validation IoU (kiri) dan Training vs Validation Precision dan Recall (kanan)

Gambar 6 menunjukkan val_IoU meningkat dari 0,7276 menjadi 0,9434 pada epoch ke-45, menunjukkan area tumpang tindih antara mask prediksi dan ground truth semakin besar. Pada grafik yang sama, val_Recall (0,9733) konsisten lebih tinggi dari val_Precision (0,9687), yang berarti model lebih sensitif mendeteksi piksel wayang sehingga meminimalkan False Negative dan jarang melewati area objek wayang yang seharusnya tersegmentasi. Ringkasan metrik pelatihan epoch ke-45 disajikan pada Tabel 6.

Tabel 6. Ringkasan Metrik Pelatihan Model U-Net pada Epoch Terbaik

Metrik Pelatihan	Nilai (%)
Loss	7,25%
Accuracy	98,65%
AUC	99,77%
Dice Coefficient	96,77%
IoU	95,29%
Precision	97,35%
Recall	97,92%


Tabel 6 menunjukkan training loss menurun konsisten dari 0,6619 menjadi 0,0725, sementara Dice coefficient meningkat signifikan dari 0,6759 menjadi 0,9677 pada epoch ke-45. Accuracy dan AUC juga meningkat stabil masing-masing menjadi 0,9865 dan 0,9977, menunjukkan model berhasil mempelajari pola segmentasi dengan baik. Mekanisme ReduceLROnPlateau menurunkan learning rate secara bertahap hingga $2,5 \times 10^{-5}$ pada epoch ke-32 sehingga konvergensi tetap terjaga tanpa indikasi overfitting. Konvergensi yang stabil tersebut tidak terlepas dari desain arsitektur U-Net yang digunakan. Mekanisme skip connection memungkinkan gradien mengalir langsung dari decoder ke encoder, sehingga informasi spasial resolusi tinggi tidak hilang selama

proses downsampling. Hal ini sangat krusial pada objek wayang kulit yang memiliki kontur siluet kompleks dengan variasi bentuk antar karakter yang signifikan. Penambahan Batch Normalization pada setiap blok konvolusi turut berkontribusi pada stabilitas pelatihan dengan menormalkan distribusi aktivasi antar layer, sehingga model tidak sensitif terhadap inisialisasi bobot awal dan dapat konvergen lebih cepat. Kombinasi fungsi loss BCE dan Dice Loss juga terbukti efektif: BCE mengoptimalkan klasifikasi piksel secara individual, sedangkan Dice Loss menjaga kualitas segmentasi pada area objek yang relatif lebih kecil dibandingkan background, kondisi yang umum terjadi pada citra wayang kulit dengan latar belakang yang mendominasi piksel citra. Selisih kecil antara metrik training dan validasi di seluruh epoch mengindikasikan bahwa augmentasi data yang diterapkan, mencakup horizontal flip, rotasi, brightness contrast, dan gaussian noise, berhasil memperluas distribusi data pelatihan sehingga model tidak bergantung pada pola spesifik dataset dan mampu menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

Konvergensi model yang relatif cepat, ditandai dengan stabilnya metrik validasi mulai epoch ke-20, dapat dijelaskan oleh beberapa faktor teknis. Pertama, karakteristik segmentasi biner yang hanya membedakan dua kelas (objek wayang dan background) secara inheren lebih mudah dipelajari dibandingkan segmentasi multikelas. Kedua, dominasi piksel background sekitar 60–70% per citra menyebabkan model dapat mencapai akurasi tinggi lebih awal karena kelas mayoritas lebih mudah diklasifikasikan. Namun demikian, potensi overfitting pada background yang dominan telah dimitigasi melalui penggunaan Dice Loss yang memberikan bobot lebih besar pada kelas minoritas (objek wayang), sehingga model tidak sekadar mengoptimalkan akurasi kelas background tetapi juga menjaga kualitas segmentasi objek wayang secara konsisten.

3.3 Hasil Pengujian Segmentasi

Pengujian model dilakukan terhadap 250 data citra uji yang tidak digunakan selama pelatihan. Evaluasi menggunakan enam metrik: Accuracy, AUC, Dice coefficient, IoU, Precision, dan Recall. Gambar 7 menyajikan bar chart hasil evaluasi pada test set dan hasil pixel-wise classification report.



Gambar 7. Metrik Evaluasi Test Set Model U-Net (kiri) dan Pixel-wise Classification Report U-Net (kanan)

Gambar 7 menunjukkan hasil evaluasi model pada test set secara keseluruhan, di mana model mencapai Accuracy 95,8%, AUC 98,6%, Dice Coefficient 91,9%, IoU 86,9%, Precision 91,5%, dan Recall 95,0%. Nilai Recall yang lebih tinggi dari Precision (95,0% vs 91,5%) menunjukkan model lebih sensitif dalam mendeteksi area objek wayang sehingga meminimalkan piksel wayang yang terlewat. Pixel-wise classification report pada gambar yang sama merinci performa per kelas: kelas Background memperoleh Precision sekitar 0,979, Recall sekitar 0,960, dan F1-Score sekitar 0,969, sedangkan kelas Wayang memperoleh Precision sekitar 0,921, Recall sekitar 0,957, dan F1-Score sekitar 0,939. Performa kelas Background yang lebih tinggi dari kelas Wayang wajar terjadi mengingat area background mendominasi piksel citra.

Perbedaan performa antara kedua kelas tersebut merupakan konsekuensi langsung dari ketidakseimbangan distribusi piksel dalam citra: area background mendominasi sekitar 60–70% total piksel pada sebagian besar sampel, sehingga model cenderung lebih mudah mengklasifikasikan piksel background secara benar. Kondisi ini lazim terjadi pada tugas segmentasi biner dan bukan merupakan indikasi kegagalan model, melainkan refleksi dari karakteristik intrinsik data. Penggunaan Dice Loss dalam fungsi loss gabungan secara khusus dirancang untuk mengatasi ketidakseimbangan kelas ini dengan memberikan bobot lebih besar pada area objek, yang berkontribusi pada nilai Dice test set 91,9% yang tetap tinggi meskipun distribusi piksel tidak seimbang.

Nilai Recall 95,0% yang konsisten lebih tinggi dari Precision 91,5% memiliki implikasi praktis yang penting dalam konteks aplikasi. Dalam skenario digitalisasi warisan budaya, False Negative (piksel wayang yang terlewat) lebih merugikan dibandingkan False Positive (piksel background yang salah terdeteksi sebagai wayang), karena piksel yang terlewat akan menyebabkan siluet wayang tidak terbentuk sempurna. Model yang cenderung high recall seperti ini lebih sesuai untuk aplikasi pelestarian budaya di mana kelengkapan segmentasi objek lebih diprioritaskan daripada ketepatan batas tepi secara piksel per piksel. Hasil evaluasi kuantitatif disajikan pada Tabel 7.

Tabel 7. Hasil Evaluasi Segmentasi Model U-Net pada Test Set (250 Data)

Metrik	Nilai (%)
Loss	22,6%
Accuracy	95,8%
AUC	98,6%
Dice Coefficient	91,9%
IoU	86,9%
Precision	91,5%
Recall	95,0%


Berdasarkan Tabel 7, model U-Net berhasil mencapai performa segmentasi yang sangat baik pada seluruh metrik. Nilai Accuracy 95,8% mencerminkan kemampuan klasifikasi piksel secara keseluruhan yang sangat baik, di mana hampir seluruh piksel dalam citra berhasil diklasifikasikan dengan benar baik sebagai objek wayang maupun latar belakang. AUC sebesar 98,6% mengindikasikan kemampuan diskriminasi yang sangat tinggi dalam membedakan piksel objek dan background di seluruh threshold, bukan hanya pada threshold 0,5 yang digunakan, sehingga model terbukti konsisten di seluruh rentang sensitivitas. Dice coefficient 91,9% dan IoU 86,9% secara bersama-sama mengkonfirmasi bahwa area yang diprediksi sebagai objek wayang memiliki tumpang tindih yang sangat tinggi dengan ground truth, yang berarti model tidak hanya mendeteksi keberadaan objek tetapi juga mampu mereproduksi bentuk dan batas siluet wayang secara akurat. Perbedaan antara Dice (91,9%) dan IoU (86,9%) yang tidak terlalu besar juga mengindikasikan bahwa model tidak menghasilkan prediksi yang terlalu melebar (over-segmentation) maupun terlalu sempit (under-segmentation). Nilai Recall 95,0% yang lebih tinggi dari Precision 91,5% menunjukkan model sangat efektif meminimalkan piksel wayang yang terlewat. Kinerja validasi pada epoch ke-45 disajikan pada Tabel 8.

Tabel 8. Metrik Validasi Model U-Net pada Epoch Terbaik

Metrik Validasi	Nilai (%)
Val Loss	8,95%
Val Accuracy	98,43%
Val AUC	99,59%
Val Dice Coefficient	96,24%
Val IoU	94,34%
Val Precision	96,76%
Val Recall	97,50%

Berdasarkan Tabel 8, kinerja validasi sangat tinggi dengan val_accuracy 98,43%, val_AUC 99,59%, val_dice 96,24%, dan val_IoU 94,34%. Selisih yang sangat kecil antara metrik training (Tabel 6) dan validasi (Tabel 8) mengkonfirmasi bahwa tidak terjadi overfitting dan model mampu melakukan generalisasi dengan baik. Perbandingan antara metrik training (Tabel 6) dan metrik validasi (Tabel 8) menunjukkan selisih yang sangat kecil pada seluruh indikator: Accuracy training 98,65% vs validasi 98,43%, Dice training 96,77% vs validasi 96,24%, dan IoU training 95,29% vs validasi 94,34%. Selisih yang konsisten kecil ini merupakan indikasi kuat bahwa model tidak mengalami overfitting dan mampu menggeneralisasi pola segmentasi dengan baik pada data yang belum pernah dilihat sebelumnya. Sementara itu, terdapat penurunan yang lebih signifikan antara metrik validasi (Tabel 8) dan metrik test set (Tabel 7), misalnya Dice validasi 96,24% turun menjadi 91,9% pada test set, dan IoU validasi 94,34% turun menjadi 86,9% pada test set. Penurunan ini wajar terjadi karena data validasi digunakan selama proses pelatihan untuk pemilihan model terbaik melalui ModelCheckpoint, sehingga model memiliki eksposur tidak langsung terhadap distribusi data validasi. Data test set yang sepenuhnya independen mencerminkan performa model yang lebih realistis pada kondisi dunia nyata, dan nilai Dice 91,9% serta IoU 86,9% pada test set tetap menunjukkan kinerja segmentasi yang sangat baik untuk domain objek budaya.

3.4 Hasil Segmentasi Citra Wayang Kulit


Gambar 8. Citra Original, Probabilitas, Prediksi Biner (mask), dan Overlay

Gambar 8 merupakan contoh hasil segmentasi dari 250 data pengujian. Peta probabilitas (Gambar 8b) menunjukkan kepercayaan model yang tinggi dengan warna merah pekat pada objek dan biru gelap pada background. Mask biner (Gambar 8c) merepresentasikan siluet karakter dengan tepi bersih, sementara overlay (Gambar 8d) mengkonfirmasi kesesuaian segmentasi dengan kontur fisik wayang. Hasil ini membuktikan mekanisme skip connection U-Net efektif mempertahankan informasi spasial [17], [18], konsisten dengan temuan pada segmentasi sel darah [24] dan motif batik [25]. Secara kualitatif, model berhasil memisahkan siluet Puntadewa dari latar belakang dengan akurasi tinggi, termasuk pada area tubuh utama dan sebagian besar kontur siluet. Namun demikian, model mengalami kesulitan pada beberapa kondisi tertentu, yaitu ornamen mahkota dengan detail tatahan yang sangat halus dan bagian jari tangan yang tipis yang hilang akibat proses reduksi dimensi ke resolusi 128×128 piksel. Kegagalan pada area tatahan mahkota disebabkan oleh karakteristik visual lubang tatahan yang tembus cahaya sehingga secara piksel menyerupai background, membuat model cenderung mengklasifikasikannya sebagai bukan objek wayang, sementara bagian jari tangan yang memiliki lebar hanya sekitar 2 hingga 4 piksel pada resolusi 128×128 menyebabkan batas antara jari dan background menjadi terlalu ambigu untuk dideteksi secara konsisten. Kondisi ini secara langsung berkontribusi pada nilai Precision test set (91,5%) yang lebih rendah dibandingkan Recall (95,0%), karena model cenderung sedikit over-segmentasi pada tubuh utama untuk mengkompensasi detail yang hilang di area ornamen halus. Meskipun demikian, untuk tujuan utama penelitian yaitu memisahkan objek wayang dari background guna mendukung analisis bentuk dan digitalisasi warisan budaya, tingkat akurasi yang dicapai sudah memenuhi standar yang memadai.

3.5 Pembahasan

Untuk memposisikan hasil penelitian ini secara ilmiah, perlu dilakukan perbandingan dengan penelitian-penelitian segmentasi citra berbasis deep learning yang relevan. Karena belum ada penelitian terdahulu yang secara khusus menerapkan segmentasi pada citra wayang kulit, perbandingan dilakukan terhadap penelitian segmentasi pada domain objek lain yang menggunakan arsitektur sejenis, yaitu U-Net dan SegNet. Ringkasan perbandingan disajikan pada Tabel 9.

Tabel 9. Perbandingan Kinerja Model dengan Penelitian Terdahulu

Peneliti	Tahun	Arsitektur	Objek	Dice	IoU	Accuracy
Ermatita & Ningsih	2025	U-Net	Citra paru	–	–	94,0
Setadewa dkk.	2025	U-Net (VGG16)	Citra satelit	89,0	81,0	–
Boly & Akbar	2024	U-Net	Citra sel darah	–	–	94,2
Malih & Akbar	2026	U-Net	Citra batik	87,32	78,66	–
Fahrudin & Akbar	2026	SegNet	Citra Batik	87,07	77,23	91,72

Berdasarkan Tabel 9, hasil penelitian ini dapat dibandingkan dengan beberapa penelitian segmentasi citra berbasis deep learning yang menggunakan arsitektur sejenis. Pertama, Ermatita dan Ningsih (2025) menerapkan U-Net pada segmentasi citra paru dan melaporkan akurasi sebesar 94,0% [12], sementara penelitian ini mencapai akurasi 95,8% pada objek wayang kulit yang memiliki karakteristik visual berbeda karena adanya ornamen tatahan dan variasi siluet antar karakter. Selanjutnya, Setadewa dkk. (2025) menggunakan U-Net berbasis VGG16 untuk segmentasi citra satelit dan memperoleh Dice 89,0% serta IoU 81,0% [13], sedangkan penelitian ini menghasilkan Dice 91,9% dan IoU 86,9% pada objek wayang kulit dengan latar belakang yang lebih bervariasi karena dikumpulkan dari berbagai sumber digital. Selain itu, Boly dan Akbar (2024) melaporkan akurasi 94,2% pada segmentasi citra sel darah menggunakan pendekatan berbasis CNN [24], sedangkan penelitian ini memperoleh akurasi 95,8% pada segmentasi wayang kulit Pandawa yang memiliki kompleksitas visual lebih tinggi, sehingga menunjukkan kemampuan model dalam menangani variasi bentuk dan detail objek yang beragam. Penelitian lain yang relevan adalah Malih dan Akbar (2026) yang mengkombinasikan CNN untuk klasifikasi dan segmentasi motif batik memperoleh Dice 87,32% dan IoU 78,66% [25], sedangkan penelitian ini yang berfokus khusus pada segmentasi biner menghasilkan nilai yang lebih tinggi pada kedua metrik tersebut. Hasil serupa juga terlihat pada penelitian Fahrudin dan Akbar (2026) menerapkan SegNet yang dimodifikasi pada segmentasi pola batik Yogyakarta dan mencapai Dice 87,07% serta IoU 77,23% [14], sementara penelitian ini menggunakan arsitektur U-Net standar yang dimodifikasi dengan penambahan Batch Normalization dan memperoleh nilai Dice serta IoU yang lebih tinggi pada objek wayang kulit yang secara visual lebih kompleks karena memiliki kontur siluet tidak beraturan dan detail ornamen yang lebih halus. Perlu dicatat bahwa perbandingan ini bersifat kontekstual karena masing-masing penelitian menggunakan dataset dan domain yang berbeda, sehingga perbedaan angka tidak semata-mata mencerminkan keunggulan satu arsitektur atas yang lain, melainkan juga dipengaruhi oleh karakteristik objek, kualitas dataset, dan konfigurasi pelatihan yang digunakan. Meskipun demikian, hasil yang diperoleh dalam penelitian ini menunjukkan bahwa arsitektur U-Net berbasis CNN yang diimplementasikan mampu bekerja dengan baik pada objek warisan budaya berkompleksitas visual tinggi, sejalan dengan temuan

penelitian-penelitian terdahulu yang membuktikan kehandalan arsitektur encoder-decoder pada berbagai domain segmentasi citra.

4. KESIMPULAN

Penelitian ini membuktikan bahwa arsitektur U-Net berbasis CNN mampu menjadi solusi efektif untuk segmentasi citra wayang kulit Pandawa yang selama ini belum pernah dieksplorasi secara spesifik, mengisi celah penelitian yang ada dengan pendekatan deep learning yang menghasilkan performa tinggi meskipun objek yang disegmentasi memiliki kompleksitas visual yang sangat tinggi. Secara teknis, kombinasi fungsi loss BCE dan Dice Loss terbukti menjadi kunci keberhasilan model dalam menangani pengukuran distribusi piksel antara objek wayang dan latar belakang, sementara mekanisme skip connection memastikan informasi spasial detail tidak hilang selama proses coding-decoding. Augmentasi data yang mencakup variasi orientasi, pencahayaan, dan noise berhasil membuat model tangguh terhadap keragaman citra dari berbagai sumber digital. Hasilnya, model mencapai Dice Coefisien 91,9%, IoU 86,9%, Accuracy 95,8%, AUC 98,6%, Precision 91,5%, dan Recall 95,0% pada 250 data uji, dengan selisih sangat kecil antara metrik pelatihan dan validasi yang mengkonfirmasi tidak terjadi overfitting. Model yang dihasilkan membuka peluang nyata untuk pengembangan sistem digitalisasi wayang kulit yang lebih lengkap, misalnya sebagai tahap awal dalam pipeline klasifikasi karakter, analisis bentuk siluet, atau rekonstruksi aset budaya digital. Keterbatasan utama yang teridentifikasi adalah resolusi input 128×128 piksel yang menyebabkan hilangnya detail ornamen tatahan halus pada area mahkota dan jari tangan, sehingga penelitian lanjutan disarankan untuk mengeksplorasi resolusi input yang lebih besar serta arsitektur seperti Attention U-Net atau U-Net++ guna meningkatkan presisi segmentasi pada detail area tatahan wayang kulit. Penelitian ini berkontribusi dalam menghadirkan model segmentasi citra berbasis deep learning pertama yang secara khusus diterapkan pada domain wayang kulit Pandawa, membuktikan efektivitas arsitektur U-Net pada objek warisan budaya berkompleksitas visual tinggi, serta menetapkan baseline kinerja segmentasi yang dapat menjadi acuan bagi pengembangan teknologi digitalisasi warisan budaya visual Indonesia selanjutnya.

REFERENCES

- [1] N. E. Imandayanti, H. E. Wahanani, and A. M. Rizki, "Klasifikasi Jenis Wayang menggunakan Convolutional Neural Network (CNN) dan Optimasi Adaptive Moment Estimation (ADAM)," *KERNEL*, vol. 5, no. 2, pp. 64–71, Apr. 2025, doi: 10.31284/j.kernel.2024.v5i2.6862.
- [2] R. N. Sapphira, "Titik Temu Tradisi dan Modernisasi: Adaptasi Kultural Pelestarian Wayang Kulit di Era Digital," *Anthropos: Jurnal Antropologi Sosial dan Budaya (Journal of Social and Cultural Anthropology)*, vol. 8, no. 2, pp. 75–92, Jan. 2023, doi: <https://doi.org/10.24114/antro.v8i2.41500>.
- [3] M. U. Nasution, L. S. Harahap, and F. Syakbani, "Tinjauan Metode Pengolahan Citra Digital untuk Deteksi Objek Otomatis," *JITET*, vol. 13, no. 3, Jul. 2025, doi: 10.23960/jitet.v13i3.7135.
- [4] D. Prayogi, S. R. Lubis, M. A. Rizko, and A. G. Suteja, "Optimalisasi Segmentasi Citra Digital Metode Canny Edge Detection dan Thresholding," *RIGGS*, vol. 4, no. 2, pp. 6334–6339, Jul. 2025, doi: 10.31004/riggs.v4i2.1613.
- [5] P. Purwono, A. Ma'arif, W. Rahmiani, H. I. K. Fathurrahman, A. Z. K. Frisky, and Q. M. U. Haq, "Understanding of Convolutional Neural Network (CNN): A Review," *IJRCS*, vol. 2, no. 4, pp. 739–748, Jan. 2023, doi: 10.31763/ijrcs.v2i4.888.
- [6] A. H. Nasrullah and H. Annur, "Implementasi Metode Convolutional Neural Network Untuk Identifikasi Citra Digital Daun," *Mib*, vol. 7, no. 2, p. 726, Apr. 2023, doi: 10.30865/mib.v7i2.5962.
- [7] W. Nurhasanah, W. Witanti, and H. Ashaury, "Klasifikasi Citra Pada Wayang Kulit Menggunakan Convolutional Neural Network," *Cerita*, vol. 11, no. 1, pp. 112–119, Feb. 2025, doi: 10.33050/cerita.v11i1.3700.
- [8] F. A. J. Handani, E. Wijayanti, and R. Fiati, "Implementation of Convolutional Neural Network Method in Classifying Pandawa Shadow Puppets," *J. Tek. Inform. (JUTIF)*, vol. 6, no. 1, pp. 211–219, Feb. 2025, doi: 10.52436/1.jutif.2025.6.1.1851.
- [9] A. S. S. Pratama, A. P. Wibawa, and A. N. Handayani, "Convolutional Neural Network (CNN) untuk Menentukan Gagrak Wayang Kulit," *Mnemonic*, vol. 5, no. 2, pp. 98–102, Aug. 2022, doi: 10.36040/mnemonic.v5i2.4671.
- [10] N. K. Nisa', E. Evanita, and A. A. Riadi, "Klasifikasi Wayang Kulit Kurawa Menggunakan Algoritma CNN," *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 5, no. 6, pp. 1799–1808, Jul. 2025, doi: 10.52436/1.jpti.856.
- [11] F. G. Setiawan, E. M. Dharma, and N. W. Utami, "Klasifikasi Tokoh Wayang Kulit dalam Cerita Mahabharata Versi Pewayangan Jawa Menggunakan Convolutional Neural Network (CNN) Berbasis ConvNeXt-Small," *JATI*, vol. 10, no. 2, pp. 2378–2384, Mar. 2026, doi: 10.36040/jati.v10i2.17413.
- [12] E. Ermatita and W. Ningsih, "Arsitektur U-Net Pada Segmentasi Citra Paru Untuk Mendeteksi Nodul Paru," *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 5, no. 1, pp. 123–130, Jan. 2025, doi: 10.52436/1.jpti.600.
- [13] P. H. Setadewa, K. Y. E. Aryanto, and L. J. E. Dewi, "Segmentasi Bangunan Perkotaan pada Citra Satelit Beresolusi Tinggi: CNN, U-Net (VGG16), dan DeepLabV3+ (ResNet-50)," *STORAGE: Jurnal Ilmiah Teknik dan Ilmu Komputer*, vol. 4, no. 4, pp. 337–347, Nov. 2025, doi: 10.55123/storage.v4i4.6552.
- [14] I. N. Fahrudin and M. Akbar, "Image Segmentation of Yogyakarta Batik Pattern Using SegNet," *J. Ris. Inform.*, vol. 8, no. 2, pp. 309–320, Mar. 2026, doi: 10.34288/jri.v8i2.491.
- [15] S. Ashillah, S. A. Gulo, Y. Rahmi, and D. Y. Niska, "Implementasi Algoritma Pengolahan Citra Digital untuk Perbaikan Kualitas Gambar," *Siskom-KB*, vol. 8, no. 3, pp. 274–280, May 2025, doi: 10.47970/siskom-kb.v8i3.823.
- [16] M. Akbar, A. Witanti, and I. Susilawati, "GPU Accelerated Fuzzy C-Means (FCM) Color Image Segmentation," *Compiler*, vol. 8, no. 2, Oct. 2019, doi: 10.28989/compiler.v8i2.455.



- [17] F. N. Fajri, M. Dzirkillah, and A. Khairi, “Digital Fish Image Segmentation Using U-Net for Shape Feature Extraction,” *JTOS*, vol. 7, no. 2, pp. 195–201, Dec. 2024, doi: 10.36378/jtos.v7i2.3968.
- [18] M. A. Djohar et al., “Liver Segmentation Using Convolutional Neural Network Method with U-Net Architecture,” *JITE*, vol. 6, no. 1, pp. 221–234, Jul. 2022, doi: 10.31289/jite.v6i1.6751.
- [19] D. Gunawan and H. Setiawan, “Convolutional Neural Network dalam Analisis Citra Medis,” *Konstelasi*, vol. 2, no. 2, pp. 380–386, Dec. 2022, doi: 10.24002/konstelasi.v2i2.5367.
- [20] A. F. Ramdhani, Y. Widhiyasana, and S. Rachmat, “Perbandingan Model U-Net dan ELU-Net untuk Segmentasi Semantik Citra Medis Kanker Pankreas,” *JNTETI*, vol. 14, no. 1, pp. 48–50, Feb. 2025, doi: 10.22146/jnteti.v14i1.15262.
- [21] D. W. Ayu and G. A. Pradipta, “Analisis Performansi Parameter pada Arsitektur U-Net untuk Segmentasi Nukleus pada Citra Kanker Serviks,” *JSI*, vol. 18, no. 2, pp. 131–138, May 2024, doi: 10.30864/jsi.v18i2.607.
- [22] T. Sulistyorini, E. Sova, N. Sofie, and R. I. Napitupulu, “Penerapan Hyperparameter Convolutional Neural Network (CNN) dalam Membangun Model Segmentasi Gambar Menggunakan Arsitektur U-Net dengan TensorFlow,” *Infokom*, vol. 28, no. 2, pp. 112–121, 2023, doi: 10.35760/ik.2023.v28i2.6959.
- [23] D. W. Putranto, A. Sunyoto, and A. Nasiri, “Pemanfaatan Deep Learning untuk Segmentasi Paru-Paru dari Citra X-Ray Dada,” *Teknimedia*, vol. 4, no. 2, pp. 144–150, Dec. 2023, doi: 10.46764/teknimedia.v4i2.114.
- [24] S. B. Boly and M. Akbar, “Segmentasi Citra Sel Darah Menggunakan Convolutional Neural Network,” *Restikom*, vol. 6, no. 2, pp. 390–398, Aug. 2024, doi: 10.52005/restikom.v6i2.336.
- [25] Y. Z. Malih and M. Akbar, “Klasifikasi dan Segmentasi Motif Batik Yogyakarta Menggunakan Convolutional Neural Network,” *JATI*, vol. 10, no. 1, pp. 1511–1518, Jan. 2026, doi: 10.36040/jati.v10i1.17061.