

KLASIFIKASI DAN SEGMENTASI MOTIF BATIK YOGYAKARTA MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Yusril Zaidan Malih, Mutaqin Akbar

Informatika, Universitas Mercu Buana Yogyakarta

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

221110018@student.mercubuana-yogya.ac.id

ABSTRAK

Motif batik memiliki karakteristik visual yang kompleks sehingga membutuhkan metode yang efektif untuk memisahkan area motif dari latar belakang sekaligus mengenali jenis motif secara otomatis. Permasalahan utama dalam pengolahan citra batik adalah kesulitan segmentasi yang akurat akibat pola, warna, dan tekstur yang beragam, yang berdampak pada rendahnya performa klasifikasi. Penelitian ini bertujuan untuk mengembangkan sistem segmentasi dan klasifikasi motif batik menggunakan arsitektur multitask U-Net berbasis convolutional neural network (CNN). Metode yang diusulkan menghasilkan dua keluaran, yaitu peta segmentasi motif batik dan hasil klasifikasi jenis motif. Tahapan penelitian meliputi pra-pemrosesan citra, segmentasi menggunakan U-Net, masking citra berdasarkan hasil segmentasi, serta klasifikasi motif menggunakan fitur dari encoder U-Net. Model dilatih menggunakan ukuran citra 256×256 piksel, optimizer Adam, fungsi loss gabungan, dan teknik dropout. Evaluasi kinerja segmentasi menggunakan Dice Coefficient, Intersection over Union (IoU), Pixel Precision, dan Pixel Recall, sedangkan kinerja klasifikasi dievaluasi menggunakan akurasi, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa model mampu menghasilkan performa segmentasi yang sangat baik dengan nilai Dice Coefficient sebesar 87,32% dan IoU sebesar 78,66%, namun performa klasifikasi masih rendah dengan akurasi sebesar 28,71%, sehingga model multitask lebih optimal untuk segmentasi motif batik.

Kata kunci : Batik, Deep Learning, Klasifikasi Citra, Segmentasi Citra, U-Net

1. PENDAHULUAN

Batik merupakan salah satu warisan budaya Indonesia yang memiliki nilai seni, filosofi, dan simbolisme yang tinggi. Batik Yogyakarta, khususnya, dikenal melalui motif-motif khas seperti Parang, Kawung, dan Truntum yang tidak hanya berfungsi sebagai elemen estetika, tetapi juga merepresentasikan nilai moral dan pandangan hidup masyarakat Jawa. Seiring dengan perkembangan teknologi digital, upaya pelestarian batik tidak lagi terbatas pada pewarisan budaya secara konvensional, tetapi juga dapat dilakukan melalui pendekatan teknologi informasi, seperti pengenalan pola dan klasifikasi citra digital [1].

Proses identifikasi dan klasifikasi motif batik secara manual masih menghadapi berbagai kendala, antara lain membutuhkan waktu yang relatif lama, ketergantungan pada keahlian manusia, serta adanya potensi subjektivitas dalam mengenali pola motif. Kondisi ini mendorong berkembangnya penelitian di bidang *computer vision* dan *machine learning* untuk membangun sistem otomatis yang mampu mengenali motif batik berdasarkan citra digital. Salah satu metode yang banyak digunakan adalah Convolutional Neural Network (CNN), yang dirancang untuk mengekstraksi fitur visual secara hierarkis dan efektif [2], [3]. CNN telah diterapkan pada berbagai penelitian klasifikasi citra, termasuk klasifikasi motif batik dan pengenalan rambu lalu lintas yang memiliki kompleksitas visual tinggi [4], [5].

Sejumlah penelitian menunjukkan bahwa CNN mampu memberikan performa yang baik dalam klasifikasi motif batik. Penelitian oleh [6]. melaporkan akurasi tinggi dalam membedakan motif batik

berdasarkan pola dan warna, sedangkan penelitian lain oleh [7] menunjukkan akurasi lebih dari 90% dalam pengenalan motif Batik Parang. Selain itu, penggunaan teknik *transfer learning* pada arsitektur modern seperti ResNet dan MobileNet juga terbukti mampu meningkatkan performa klasifikasi secara signifikan [8], [9]. Keberhasilan CNN dalam pengenalan rambu lalu lintas dengan akurasi mencapai 97–99% pada dataset multi-kelas [4], [5]. menunjukkan bahwa metode ini memiliki kemampuan yang kuat dalam memahami representasi visual kompleks, termasuk motif batik.

Namun demikian, dalam pengolahan citra batik, proses klasifikasi saja belum cukup optimal tanpa didukung segmentasi citra yang baik. Segmentasi bertujuan untuk memisahkan area motif dari latar belakang kain agar model dapat lebih fokus pada pola utama. Salah satu arsitektur *deep learning* yang populer untuk tugas segmentasi adalah U-Net [10]., yang memiliki struktur encoder-decoder dengan *skip connection* sehingga mampu mempertahankan informasi spasial dan detail citra. U-Net telah terbukti efektif dalam melakukan segmentasi objek pada berbagai domain, termasuk citra tekstil dan pola kain [7] [13]., Meskipun demikian, penelitian yang mengintegrasikan segmentasi dan klasifikasi motif batik secara bersamaan, khususnya untuk batik Yogyakarta, masih relatif terbatas.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem segmentasi dan klasifikasi motif batik Yogyakarta menggunakan Convolutional Neural Network dengan arsitektur U-Net. Rencana penyelesaian masalah

dilakukan dengan menerapkan U-Net untuk memisahkan area motif dari latar belakang citra, kemudian memanfaatkan fitur hasil ekstraksi CNN untuk mengklasifikasikan jenis motif batik. Pendekatan ini diharapkan mampu menghasilkan sistem pengenalan motif batik yang lebih akurat dan komprehensif serta mendukung pelestarian batik tradisional melalui digitalisasi dan teknologi *deep learning*.

2. TINJAUAN PUSTAKA

Penelitian mengenai klasifikasi motif batik berbasis *deep learning* telah berkembang pesat dalam beberapa tahun terakhir seiring dengan kemajuan teknologi computer vision dan artificial intelligence. Salah satu metode yang paling sering digunakan adalah Convolutional Neural Network (CNN), karena kemampuannya dalam mengekstraksi fitur spasial dan visual dari citra dengan tingkat presisi tinggi. CNN bekerja melalui serangkaian proses konvolusi, pooling, dan aktivasi nonlinier untuk mempelajari pola-pola yang terdapat pada gambar, sehingga sangat cocok untuk mengenali tekstur, warna, dan bentuk khas pada motif batik[2].

Menurut [1], penerapan CNN pada batik Garutan mampu menghasilkan akurasi tinggi setelah dilakukan proses data augmentation untuk memperluas variasi data pelatihan. Penelitian ini menekankan pentingnya teknik augmentasi dalam mencegah overfitting, mengingat dataset batik biasanya memiliki keterbatasan jumlah dan variasi citra. Hal yang sama juga ditegaskan oleh [16] yang menyebutkan bahwa augmentasi citra seperti rotasi, flipping, dan cropping sangat efektif dalam meningkatkan generalisasi model *deep learning*.

Penelitian lain yang dilakukan oleh [6] menunjukkan bahwa CNN mampu membedakan motif batik dari berbagai daerah dengan tingkat akurasi yang stabil meskipun menggunakan dataset dengan latar belakang yang kompleks. Sedangkan [3] mengimplementasikan CNN pada aplikasi berbasis Android untuk klasifikasi motif batik, sehingga sistem dapat mengenali motif secara real-time melalui kamera perangkat. Hasil penelitian tersebut menunjukkan bahwa CNN tidak hanya efektif di lingkungan laboratorium, tetapi juga dapat diimplementasikan pada aplikasi praktis berbasis mobile computing.

Sejumlah penelitian juga menyoroti pentingnya penerapan transfer learning untuk meningkatkan kinerja model CNN. [17] memanfaatkan arsitektur transfer learning seperti VGG16 untuk mengidentifikasi batik di Jawa Tengah, dan memperoleh hasil yang lebih baik dibandingkan CNN yang dilatih dari awal. [8] serta [14] memperkuat temuan tersebut dengan menunjukkan bahwa arsitektur modern seperti ResNet-50 memiliki kemampuan lebih baik dalam mengekstraksi fitur-fitur halus pada pola batik yang rumit. Sementara itu, [9] menerapkan MobileNetV2 dengan teknik augmentasi

data untuk klasifikasi batik Semarang dan berhasil meningkatkan akurasi klasifikasi hingga 96%.


Beberapa studi lain menitik beratkan pada klasifikasi motif tertentu. [7] meneliti motif Parang menggunakan CNN dengan hasil akurasi mencapai 91,7%, sedangkan [11] menunjukkan efektivitas CNN dalam mengenali pola batik berbasis *deep learning* dengan peningkatan performa signifikan ketika model dilatih dengan dataset yang seimbang. Selain itu, penelitian oleh [18] memperlihatkan bahwa kombinasi CNN dan optimasi hiperparameter dapat mempercepat konvergensi pelatihan serta menurunkan tingkat kesalahan klasifikasi.

Pendekatan lain yang dikaji adalah penggunaan metode edge detection sebelum tahap klasifikasi.[19] menerapkan Canny Operator untuk menonjolkan garis-garis motif batik sebelum diproses dengan CNN, yang terbukti meningkatkan akurasi klasifikasi secara signifikan karena fitur tepi dapat memperjelas kontur pola batik. Hal ini memperlihatkan bahwa pengolahan citra pra-pemrosesan (*preprocessing*) seperti edge enhancement memiliki pengaruh besar terhadap hasil akhir model CNN.

Dalam ranah pengenalan pola yang lebih kompleks, segmentasi citra menjadi tahapan penting untuk memisahkan area motif dari latar belakang kain. Segmentasi memungkinkan sistem fokus pada area relevan tanpa gangguan dari noise visual. Model U-Net, yang diperkenalkan oleh Ronneberger merupakan salah satu arsitektur *deep learning* paling populer untuk tugas segmentasi karena kemampuannya dalam mempertahankan informasi spasial melalui struktur encoder-decoder. Struktur ini memungkinkan sistem untuk mengekstraksi fitur penting di tahap encoding dan merekonstruksi citra dengan detail tinggi di tahap decoding.

Dalam konteks batik, U-Net berpotensi besar digunakan untuk menyoroti area motif utama agar proses klasifikasi menjadi lebih akurat. Penelitian oleh [13] menggunakan pendekatan transfer learning berbasis MobileNet untuk pengenalan dan klasifikasi batik, menunjukkan bahwa integrasi model segmentasi dan klasifikasi dapat meningkatkan efisiensi sistem. Penelitian oleh [20] juga menegaskan bahwa pendekatan berbasis CNN memberikan hasil optimal dalam klasifikasi data pola batik yang bersifat data-driven, terutama jika dilengkapi dengan teknik segmentasi citra untuk mengurangi gangguan latar.

Selain aspek teknis, berbagai penelitian juga menyoroti kontribusi teknologi ini dalam konteks pelestarian budaya.[15] mengembangkan sistem pengenalan motif batik berbasis machine learning untuk keperluan edukasi dan media pembelajaran. Sementara [21] menerapkan model CNN sebagai sarana edukasi pengenalan motif batik untuk siswa sekolah dasar, yang memperlihatkan potensi teknologi ini dalam memperkenalkan nilai budaya kepada generasi muda.



Gambar 1. Blok Diagram Penelitian

Tabel 1. Contoh Citra Batik Setiap Kelas[22]

Jenis Batik	Contoh Citra
Geblek renteng	
Kawung	
Parang	
Sidoluhur	
Sinom parijotho salak	
Truntum	
Tumpal	

3. METODE PENELITIAN

Gambar 1 menunjukkan blok diagram alur penelitian yang digunakan dalam proses klasifikasi motif batik berbasis Convolutional Neural Network (CNN) dengan dukungan segmentasi menggunakan U-Net. Penelitian dimulai dari tahap pengumpulan data, pra-pemrosesan citra, perancangan model, pelatihan, hingga evaluasi kinerja sistem.

3.1. Dataset


Dataset yang digunakan dalam penelitian ini merupakan kumpulan citra batik sesuai Tabel 1 yang dibagi menjadi tujuh kelas, yaitu Geblek Renteng, Kawung, Parang, Sidoluhur, Sinom Parijotho Salak, Truntum, dan Tumpal. Total citra batik yang digunakan sebanyak 1.971 citra, dengan setiap kelas memiliki jumlah data yang relatif seimbang. Dataset tersebut dibagi menjadi 80% data training dan 20% data testing untuk proses pelatihan serta pengujian model CNN. Seluruh citra pada dataset diubah ke format JPEG/PNG dan diseragamkan dengan ukuran 224×224 piksel agar kompatibel dengan arsitektur CNN yang digunakan.

3.2. Praproses Data

Tahap berikutnya adalah praproses yang meliputi resize dan crop untuk menyeragamkan ukuran, memperjelas pola, serta mengurangi kompleksitas warna pada citra. selain dilakukan penyeragaman ukuran dan normalisasi nilai piksel, juga dilakukan pembuatan citra masking yang berfungsi sebagai *ground truth* pada proses segmentasi. Citra masking ini merepresentasikan area motif batik yang menjadi fokus utama sistem, sedangkan area di luar motif dianggap sebagai latar belakang.

Proses pembuatan citra masking dilakukan dengan menandai Region of Interest (ROI) pada citra batik, yaitu area yang mengandung pola motif utama. Masking dibuat dalam bentuk citra biner, di mana nilai piksel 1 (atau putih) menunjukkan area motif batik, sedangkan nilai 0 (atau hitam) menunjukkan area latar belakang. Masking ini disesuaikan dengan ukuran citra hasil preprocessing agar memiliki dimensi yang sama dengan citra input.

Citra hasil preprocessing dan citra masking selanjutnya digunakan secara berpasangan sebagai data latih pada tahap segmentasi menggunakan arsitektur U-Net. guna memisahkan pola utama motif dari latar belakang, sehingga fokus klasifikasi dapat lebih akurat terhadap fitur penting pada motif batik.



Gambar 2. Arsitektur U-Net Multitask untuk Klasifikasi dan Segmentasi Motif Batik

Citra hasil segmentasi kemudian diproses pada tahap klasifikasi menggunakan CNN, dimana jaringan konvolusional mengekstraksi fitur spasial dari citra dan melakukan pelatihan untuk mengenali pola unik

dari setiap jenis motif batik. Model CNN yang telah dilatih kemudian diuji untuk mengukur performanya berdasarkan akurasi, IoU, dan Coef Dice sehingga dapat diketahui sejauh mana sistem mampu mengklasifikasikan motif batik dengan benar.

3.3. Arsitektur U-Net Multitask untuk Klasifikasi dan Segmentasi Motif Batik

Pada penelitian ini digunakan arsitektur *deep learning* terpadu berbasis *U-Net multitask* yang dirancang untuk melakukan klasifikasi dan segmentasi motif batik secara bersamaan dalam satu model. Arsitektur ini menggunakan satu *shared encoder* sebagai pengekstraksi fitur visual citra batik, yang selanjutnya dimanfaatkan oleh dua keluaran, yaitu *classification head* untuk menentukan kelas motif batik dan *segmentation decoder* untuk memisahkan area motif dari latar belakang. Pendekatan *multitask* ini bertujuan meningkatkan efisiensi pembelajaran fitur dan menjaga konsistensi antara hasil klasifikasi dan segmentasi.

Citra batik berformat *RGB* berukuran 256×256 piksel digunakan sebagai masukan pada *input layer*. Citra kemudian diproses oleh bagian *encoder* yang terdiri dari empat blok konvolusi. Setiap blok *encoder* menggunakan dua lapisan konvolusi 3×3 dengan aktivasi *ReLU* dan *batch normalization*, diikuti operasi *max pooling* 2×2 . Jumlah *filter* meningkat secara bertahap, yaitu 64, 128, 256, dan 512 *filter*, untuk mengekstraksi fitur motif batik dari tingkat sederhana hingga kompleks. Operasi konvolusi dinyatakan sebagai:

$$S(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n) \quad (1)$$

dengan:

- I adalah matriks citra masukan,
- K adalah kernel atau filter konvolusi,
- $S(i, j)$ adalah nilai hasil konvolusi pada posisi piksel ke- (i, j) .

Fitur hasil *encoder* selanjutnya diproses pada bagian *bottleneck* yang terdiri dari dua lapisan konvolusi 3×3 dengan 1024 *filter*. Bagian ini berfungsi sebagai representasi fitur terdalam yang menyimpan informasi global citra batik.

Fitur dari *bottleneck* kemudian diarahkan ke *classification head* dengan menggunakan *Global Average Pooling (GAP)* untuk mereduksi dimensi spasial, yang dirumuskan sebagai:

$$g_k = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W f_k(i, j) \quad (2)$$

dengan $f_k(i, j)$ merupakan nilai fitur ke- k pada posisi (i, j) , serta H dan W adalah tinggi dan lebar *feature map*. Hasil *GAP* diproses oleh lapisan *fully connected* dengan aktivasi *ReLU* dan *dropout*. Lapisan keluaran klasifikasi menggunakan fungsi aktivasi *Softmax*

untuk menghasilkan probabilitas kelas motif batik, yang dirumuskan sebagai:

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}} \quad (3)$$

dengan z_i merupakan nilai logit kelas ke- i dan C adalah jumlah kelas motif batik.

Secara paralel, fitur dari *bottleneck* juga diproses oleh *decoder U-Net* untuk segmentasi. *Decoder* terdiri dari empat tahap *upsampling* menggunakan *Conv2DTranspose* berukuran 2×2 , disertai *skip connection* dari *encoder* yang bersesuaian untuk mempertahankan detail spasial motif. Lapisan keluaran segmentasi menggunakan konvolusi 1×1 dengan aktivasi *Sigmoid* untuk menghasilkan peta segmentasi biner, yang dirumuskan sebagai:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

Untuk mengukur kesalahan prediksi pada tugas klasifikasi digunakan fungsi *categorical cross-entropy*, yang dirumuskan sebagai:

$$\mathcal{L}_{cls} = - \sum_{i=1}^C y_i \log(\hat{y}_i) \quad (5)$$

dengan y_i merupakan label kelas sebenarnya dan $\hat{y}_i$ adalah probabilitas hasil prediksi kelas ke- i .

Sementara itu, pada tugas segmentasi digunakan Untuk proses pelatihan, digunakan fungsi *loss* gabungan antara klasifikasi dan segmentasi. *Loss* klasifikasi dihitung menggunakan *categorical cross-entropy*, sedangkan *loss* segmentasi menggunakan *binary cross-entropy*. *Loss* total dirumuskan sebagai:

$$\mathcal{L}_{total} = \lambda_1 \mathcal{L}_{cls} + \lambda_2 \mathcal{L}_{seg} \quad (6)$$

dengan λ_1 dan λ_2 merupakan bobot kontribusi masing-masing tugas.

Gambar 2 menunjukkan arsitektur *U-Net multitask* yang terdiri dari *encoder*, *bottleneck*, *decoder*, serta satu *classification head*. Arsitektur ini menggunakan *shared encoder* sebagai pengekstraksi fitur utama citra batik untuk mendukung tugas segmentasi dan klasifikasi secara bersamaan.

Bagian *encoder* terdiri dari empat blok konvolusi berurutan, masing-masing menggunakan dua lapisan konvolusi 3×3 dengan aktivasi *ReLU* dan *batch normalization*, diikuti oleh *max pooling* 2×2 . Jumlah *filter* meningkat secara bertahap dari 64 hingga 512 untuk mengekstraksi fitur dari tingkat sederhana hingga kompleks. Pada bagian *bottleneck* digunakan dua lapisan konvolusi 3×3 dengan 1024 *filter* sebagai representasi fitur terdalam citra.

Dari *bottleneck*, arsitektur bercabang menjadi dua. Cabang pertama berupa *classification head* yang menggunakan *Global Average Pooling*, diikuti lapisan *fully connected* dengan *dropout* dan aktivasi *Softmax* untuk menghasilkan probabilitas kelas motif batik. Cabang kedua menuju *decoder* untuk segmentasi, yang terdiri dari empat tahap *upsampling* menggunakan *Conv2DTranspose* dan *skip connection*

dari *encoder*. Lapisan keluaran segmentasi menggunakan konvolusi 1×1 dengan aktivasi *Sigmoid* untuk menghasilkan peta segmentasi biner motif batik.

4. HASIL DAN PEMBAHASAN

Bab ini membahas hasil implementasi dan pengujian sistem segmentasi dan klasifikasi citra motif batik menggunakan arsitektur U-Net multitask, di mana satu model digunakan untuk dua tujuan utama, yaitu segmentasi area motif dan klasifikasi jenis motif batik. Fokus utama pada penelitian ini adalah kinerja segmentasi, sedangkan klasifikasi digunakan sebagai fitur tambahan (*secondary task*) untuk melihat potensi pengembangan model ke arah multitask learning.

Proses pengujian dilakukan menggunakan data citra batik yang telah melalui tahapan pra-pemrosesan dan pembuatan mask. Evaluasi dilakukan secara kuantitatif menggunakan metrik segmentasi serta secara kualitatif melalui visualisasi hasil segmentasi. Pada tahap awal, citra batik berwarna (RGB) dilakukan proses pra-pemrosesan berupa resizing ke ukuran seragam dan normalisasi nilai piksel. Selanjutnya dilakukan proses masking, yaitu pembuatan citra biner yang merepresentasikan area motif batik dan latar belakang.

Masking berfungsi sebagai ground truth pada proses pelatihan model segmentasi. Mask ini digunakan untuk melatih U-Net agar mampu mempelajari batas dan pola motif batik secara lebih presisi

Kelas: Sidoluhur



Gambar 3. Citra batik asli dan mask hasil anotasi

4.1. Hasil Segmentasi Motif Batik

Evaluasi kinerja segmentasi dilakukan menggunakan beberapa metrik, yaitu Dice Coefficient, Intersection over Union (IoU), Pixel Precision, dan Pixel Recall. Seluruh nilai metrik disajikan dalam bentuk persentase (%) untuk memudahkan interpretasi hasil. Hasil pengujian segmentasi ditunjukkan pada Tabel 2.


Tabel 2. Hasil Evaluasi Segmentasi U-Net

Metrik	Nilai
Dice Coefficient	87,32%
IoU	78,66%
Pixel Precision	81,77%
Pixel Recall	96,24%

Berdasarkan Tabel 2, nilai *Dice Coefficient* sebesar 87,32% menunjukkan kesesuaian yang sangat tinggi antara hasil segmentasi model dan *ground truth*,


yang menandakan bahwa sebagian besar area motif batik berhasil dipetakan secara akurat. Nilai *IoU* sebesar 78,66% memperkuat temuan tersebut dengan menunjukkan tingkat tumpang tindih yang tinggi antara *mask* prediksi dan referensi. Selain itu, nilai *Pixel Precision* sebesar 81,77% menunjukkan bahwa sebagian besar piksel yang diprediksi sebagai motif berasal dari area motif yang benar, sedangkan *Pixel Recall* sebesar 96,24% mengindikasikan kemampuan model yang sangat baik dalam mendeteksi hampir seluruh area motif batik, meskipun masih terdapat sedikit kesalahan pada area batas.

Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa model U-Net memiliki performa segmentasi yang sangat baik dan layak digunakan sebagai tahap utama dalam pemrosesan citra motif batik.



Gambar 4. Grafik Perbandingan Dice Loss


Gambar 4 menampilkan grafik perbandingan Dice Loss pada data pelatihan dan validasi. Pada beberapa epoch awal, nilai Dice Loss mengalami penurunan yang cukup signifikan, menandakan bahwa model mampu mempelajari pola segmentasi dengan cepat. Seiring bertambahnya epoch, nilai Dice Loss cenderung stabil pada nilai rendah, terutama pada data pelatihan. Meskipun terdapat fluktuasi pada data validasi, tren keseluruhan menunjukkan bahwa model tidak mengalami overfitting yang signifikan.



Gambar 5. Grafik Perbandingan Dice Coefficient

Gambar 5 menunjukkan grafik Dice Coefficient pada data pelatihan dan validasi. Nilai Dice

Coefficient meningkat secara bertahap sejak awal pelatihan dan mencapai nilai di atas 87% pada epoch akhir. Walaupun terdapat fluktuasi pada data validasi, nilai Dice tetap berada pada rentang tinggi, yang menunjukkan kestabilan dan konsistensi model dalam melakukan segmentasi.



Gambar 6. Grafik Perbandingan IoU

Gambar 6 memperlihatkan grafik IoU untuk data pelatihan dan validasi. Nilai IoU mengalami peningkatan signifikan pada epoch awal, kemudian relatif stabil pada kisaran 78%–80%. Stabilitas ini menunjukkan bahwa model mampu mempertahankan akurasi spasial yang baik dalam memetakan area motif batik.

4.2. Hasil Klasifikasi Motif Batik

Selain digunakan untuk segmentasi, arsitektur U-Net multitask pada penelitian ini juga diterapkan untuk tugas klasifikasi motif batik. Pada skema ini, fitur-fitur yang dihasilkan oleh encoder U-Net dimanfaatkan sebagai representasi citra dan diteruskan ke lapisan klasifikasi untuk menghasilkan prediksi kelas motif. Input pada tahap klasifikasi berupa citra hasil masking, yaitu citra batik yang telah dipisahkan antara area motif dan latar belakang.


Model klasifikasi dilatih untuk mengenali beberapa kelas motif batik yang digunakan dalam penelitian. Proses pelatihan dilakukan setelah model segmentasi menghasilkan mask yang dianggap cukup baik, dengan tujuan agar penghilangan latar belakang dapat membantu model fokus pada pola motif utama. Hasil evaluasi klasifikasi ditampilkan pada Tabel 3.

Tabel 3. Hasil Evaluasi Klasifikasi U-Net

Metrik	Nilai (%)
Accuracy	28,71%
Precision	0%
Recall	0%
F1-Score	20,33%


Berdasarkan hasil pada Tabel 3, akurasi pengujian mencapai 28,71%, sedangkan nilai F1-score sebesar 20,33%. Nilai precision dan recall yang sangat rendah menunjukkan bahwa model belum mampu mengenali pola motif batik secara konsisten pada data uji. Rendahnya nilai precision dan recall disebabkan oleh kecenderungan model dalam memprediksi kelas

tertentu secara dominan, sehingga beberapa kelas motif tidak terdeteksi dengan baik. Kondisi ini umum terjadi pada klasifikasi multikelas yang memiliki kemiripan visual tinggi antar kelas serta distribusi data yang tidak seimbang.



Gambar 7. Grafik Perbandingan Loss Klasifikasi

Gambar 7 menunjukkan grafik perbandingan loss klasifikasi pada data pelatihan dan validasi. Pada epoch awal, loss validasi terlihat tinggi dan berfluktuasi tajam, yang menandakan bahwa model masih mengalami kesulitan dalam mempelajari pola klasifikasi. Seiring bertambahnya epoch, nilai loss cenderung menurun dan stabil, meskipun perbedaan antara data pelatihan dan validasi masih terlihat.



Gambar 8. Grafik Perbandingan Akurasi Klasifikasi

Gambar 8 menampilkan grafik perbandingan akurasi klasifikasi. Nilai akurasi pada data pelatihan dan validasi relatif rendah dan berfluktuasi pada kisaran 20%–30%. Fluktuasi yang cukup besar pada data validasi menunjukkan bahwa model belum mampu melakukan generalisasi dengan baik pada tugas klasifikasi.

4.3. Pembahasan

Berdasarkan seluruh hasil pengujian, dapat disimpulkan bahwa model *U-Net multitask* menunjukkan kinerja yang sangat baik pada tugas segmentasi motif batik. Hal ini ditunjukkan oleh nilai *Dice Coefficient* sebesar 87,32% dan *Intersection over Union (IoU)* sebesar 78,66%, yang mengindikasikan

tingkat kesesuaian dan tumpang tindih yang tinggi antara hasil segmentasi model dan *ground truth*. Nilai tersebut menunjukkan bahwa model mampu mempertahankan akurasi spasial dan konsistensi bentuk motif batik pada berbagai citra uji.

Dari sisi prediksi piksel, *Pixel Precision* sebesar 81,77% menandakan bahwa sebagian besar piksel yang diprediksi sebagai motif berasal dari area motif yang benar, sedangkan *Pixel Recall* sebesar 96,24% menunjukkan bahwa hampir seluruh area motif berhasil terdeteksi oleh model. Nilai *recall* yang sangat tinggi ini mengindikasikan minimnya kesalahan *false negative*, meskipun masih terdapat sedikit kesalahan pada area tepi motif yang memengaruhi nilai *precision*. Secara keseluruhan, hasil ini menegaskan bahwa arsitektur *U-Net multitask* sangat efektif digunakan untuk segmentasi motif batik dan layak dijadikan tahap utama dalam pengolahan citra batik.

Sebaliknya, kinerja klasifikasi motif batik masih tergolong rendah, dengan akurasi sebesar 28,71% dan *F1-score* sebesar 20,33%. Rendahnya nilai *precision* dan *recall* menunjukkan bahwa model belum mampu membedakan kelas motif secara konsisten. Hal ini diduga disebabkan oleh kemiripan visual antar motif, keterbatasan dan ketidakseimbangan data, serta karakteristik arsitektur *U-Net* yang lebih berfokus pada segmentasi piksel dibandingkan ekstraksi fitur global untuk klasifikasi.

Dengan demikian, penelitian ini menegaskan bahwa arsitektur *U-Net multitask* lebih optimal untuk tugas segmentasi dibandingkan klasifikasi motif batik. Tugas klasifikasi pada penelitian ini masih bersifat sekunder dan memerlukan pengembangan lebih lanjut, seperti penggunaan *backbone* CNN khusus klasifikasi atau penerapan *transfer learning*, agar diperoleh performa yang lebih optimal.

5. KESIMPULAN DAN SARAN

Artikel ini menyajikan klasifikasi dan segmentasi motif batik Yogyakarta menggunakan convolutional neural network. Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan arsitektur multitask *U-Net* pada citra motif batik sangat efektif untuk tugas segmentasi area motif, namun belum memberikan hasil yang optimal pada tugas klasifikasi motif. Hal ini ditunjukkan oleh capaian metrik segmentasi yang tinggi, yaitu Dice Coefficient sebesar 87,32%, IoU sebesar 78,66%, *Pixel Precision* sebesar 81,77%, dan *Pixel Recall* sebesar 96,24%, yang menandakan bahwa model mampu memisahkan area motif batik dari latar belakang secara akurat dan konsisten. Segmentasi yang baik ini membuktikan bahwa *U-Net* dengan struktur encoder-decoder dan skip connection sangat sesuai digunakan sebagai tahap utama dalam pengolahan citra motif batik. Sebaliknya, performa klasifikasi yang dihasilkan masih relatif rendah, yang menunjukkan bahwa fitur yang diekstraksi oleh model lebih optimal untuk segmentasi dibandingkan untuk klasifikasi global citra, serta dipengaruhi oleh

kemiripan visual antar motif dan keterbatasan distribusi data. Oleh karena itu, pada penelitian selanjutnya disarankan untuk menggunakan pendekatan klasifikasi yang lebih spesifik, seperti model CNN atau transfer learning yang berdiri sendiri setelah proses segmentasi, serta menambah jumlah dan variasi data, dan mengoptimalkan skema multitask agar kinerja kedua tugas dapat meningkat secara seimbang.

DAFTAR PUSTAKA

- [1] L. Fitriani, D. Tresnawati, and M. B. Sukriyansah, "Image Classification On Garutan Batik Using Convolutional Neural Network with Data Augmentation," *JUITA J. Inform.*, vol. 11, no. 1, p. 107, May 2023, doi: 10.30595/juita.v11i1.16166.
- [2] R. F. Alya, M. Wibowo, and P. Paradise, "CLASSIFICATION OF BATIK MOTIF USING TRANSFER LEARNING ON CONVOLUTIONAL NEURAL NETWORK (CNN)," *J. Tek. Inform. Jutif*, vol. 4, no. 1, pp. 161–170, Feb. 2023, doi: 10.52436/1.jutif.2023.4.1.564.
- [3] I. Maulana, H. Sastypratiwi, H. Muhandi, N. Safriadi, and H. Sujaini, "Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Motif Batik pada Aplikasi Computer Vision Berbasis Android," *J. Edukasi Dan Penelit. Inform. JEPIN*, vol. 9, no. 3, p. 384, Dec. 2023, doi: 10.26418/jp.v9i3.69496.
- [4] M. Akbar, "Traffic sign recognition using convolutional neural networks," *J. Teknol. Dan Sist. Komput.*, vol. 9, no. 2, pp. 120–125, Apr. 2021, doi: 10.14710/jtsiskom.2021.13959.
- [5] M. Akbar, A. S. Purnomo, and S. Supatman, "Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia," *J. Sisfokom Sist. Inf. Dan Komput.*, vol. 11, no. 3, pp. 310–315, Dec. 2022, doi: 10.32736/sisfokom.v11i3.1452.
- [6] D. Anastasya, S. Fahri, and S. Situmorang, "Implementasi Metode Convolutional Neural Network (CNN) Dalam Klasifikasi Motif Batik," *NUANSA Inform.*, vol. 18, no. 1, pp. 1–5, Jan. 2024, doi: 10.25134/ilkom.v18i1.21.
- [7] Angginy Akhirunnisa Siregar, Citra Citra, Dechy Deswita Indriani.S, and Gifari Dhaffa Prawira Sianturi, "Klasifikasi Batik Parang Menggunakan Convolutional Neural Network (CNN)," *Pop. J. Penelit. Mhs.*, vol. 3, no. 1, pp. 62–69, Dec. 2023, doi: 10.58192/populer.v3i1.1666.
- [8] A. M. AGISTA, "IMPLEMENTASI ARSITEKTUR RESNET50 PADA KLASIFIKASI MOTIF BATIK INDONESIA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," undergraduate, Universitas Islam Sultan Agung, 2025. Accessed: Oct. 27, 2025. [Online].

- Available:
<https://repository.unissula.ac.id/40941/>
- [9] E. Khoirunnisa *et al.*, “Enhanced Semarang Batik Classification using MobileNetV2 and Data Augmentation,” *sinkron*, vol. 9, no. 1, pp. 43–54, Jan. 2025, doi: 10.33395/sinkron.v9i1.14308.
 - [10] S. B. Boly and M. Akbar, “Segmentasi Citra Sel Darah Menggunakan Convolutional Neural Network,” *J. RESTIKOM Ris. Tek. Inform. Dan Komput.*, vol. 6, no. 2, pp. 390–398, Aug. 2024, doi: 10.52005/restikom.v6i2.336.
 - [11] E. Sugianto, F. Budiman, and A. Fahmi, “Implementation of Deep Learning Based on Convolution Neural Network for Batik Pattern Recognition,” *Kinet. Game Technol. Inf. Syst. Comput. Netw. Comput. Electron. Control*, Jan. 2025, doi: 10.22219/kinetik.v10i1.2019.
 - [12] F. Y. Tember and I. Najiyah, “Classification of West Java Batik Motifs Using Convolutional Neural Network,” *SISTEMASI*, vol. 12, no. 2, p. 282, May 2023, doi: 10.32520/stmsi.v12i2.2259.
 - [13] H. Sastypratiwi, H. Muhandi, and Y. Yulianti, “Batik Recognition and Classification Using Transfer Learning and MobileNet Approach,” *JOIV Int. J. Inform. Vis.*, vol. 8, no. 4, p. 2400, Dec. 2024, doi: 10.62527/joiv.8.4.2407.
 - [14] M. R. Wibisono, I. M. Nugroho, and M. Defriani, “Batik Motif Classification Using CNN With Resnet-50 Architecture,” vol. 6, no. 1, 2025.
 - [15] E. Y. Puspaningrum, E. P. Mandyartha, and F. A. Akbar, “Batik Motif Recognition Using Machine Learning Method as Educational Media (Case Study: CV. Titik Batik),” *Nusant. Sci. Technol. Proc.*, pp. 612–617, May 2025, doi: 10.11594/nstp.2025.4789.
 - [16] C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, p. 60, Dec. 2019, doi: 10.1186/s40537-019-0197-0.
 - [17] S. P. Adithama, B. Y. Dwiandiyanta, and S. B. Wiadji, “Identification of Batik in Central Java using Transfer Learning Method,” *J. Buana Inform.*, vol. 14, no. 02, pp. 77–86, Oct. 2023, doi: 10.24002/jbi.v14i02.6977.
 - [18] D. N. Ramadhan, R. A. Erwanto, and R. T. Enwan, “Klasifikasi Batik Menggunakan Algoritma CNN (Convolutional Neural Network),” vol. 3, 2024.
 - [19] Iwan Jaya Bakti and N. Hendrastuty, “APPLICATION OF CANNY OPERATOR IN BATIK MOTIF IMAGE CLASSIFICATION WITH CONVOLUTIONAL NEURAL NETWORK APPROACH,” *J. Tek. Inform. Jutif*, vol. 5, no. 3, pp. 789–798, May 2024, doi: 10.52436/1.jutif.2024.5.3.1894.
 - [20] I. P. Sari and L. Elvitaria, “Data-driven approach for batik pattern classification using convolutional neural network (CNN),” vol. 13, no. 3, 2025.
 - [21] Y. F. Bili and F. M. Sarimole, “Pengenalan dan Edukasi Motif Batik Untuk Sekolah Dasar Negeri Pondok Bahar 06 Menggunakan Metode Convolution NeuralNetwork(CNN),” Sept. 2025.
 - [22] K. Otomatis, “Klasifikasi Batik Yogyakarta Computer Vision Model.” Nov. 25, 2024. Accessed: Oct. 23, 2025. [Online]. Available: <https://universe.roboflow.com/klasifikasi-otomatis/klasifikasi-batik-yogyakarta>