

KLASIFIKASI MOTIF BATIK INDONESIA MENGGUNAKAN DEEP LEARNING BERBASIS CONVOLUTIONAL NEURAL NETWORK (CNN)

Muhammad Rizki Pramudya Idris ¹, Ahmad ², Dzulfiqar Azhar Al Ghifari ³,

Gema Parasti Mindara ⁴, Endang Purnama Giri ⁵

^{1,2,3} Teknologi Rekayasa Perangkat Lunak, IPB University

⁴ Teknologi Rekayasa Komputer, IPB University,

⁵ Ilmu Komputer, IPB University

Jalan Kumbang No.14, Kota Bogor, Indonesia

pramudyarizki@apps.ipb.ac.id

ABSTRAK

Batik merupakan warisan budaya Indonesia yang banyak didigitalisasi dalam bentuk citra, sehingga dibutuhkan sistem pengenalan motif yang cepat dan akurat untuk mendukung dokumentasi, pencarian produk, dan edukasi. Permasalahan dalam penelitian ini adalah bagaimana merancang model klasifikasi motif batik yang mampu mengenali banyak kelas motif sekaligus tetap andal terhadap variasi citra, termasuk perbedaan sudut pengambilan dan tekstur kain. Penelitian ini bertujuan membangun dan mengevaluasi model klasifikasi motif batik berbasis *deep learning* dengan arsitektur ResNet50. Dataset yang digunakan terdiri atas 3.000 citra kain batik datar berwarna yang merepresentasikan 20 kelas motif. Metode yang diterapkan meliputi pra-pemrosesan citra dengan teknik *edge-enhanced* berbasis deteksi tepi, penerapan *transfer learning* pada ResNet50, serta pelatihan dua tahap, yaitu pelatihan *classifier head* dan *fine-tuning* sebagian lapisan. Kinerja model dievaluasi menggunakan akurasi, *precision*, *recall*, F1-score, dan *confusion matrix* pada data uji terpisah. Hasil pengujian menunjukkan bahwa model menghasilkan performa klasifikasi yang sangat baik dan relatif seimbang di sebagian besar kelas, serta tetap mampu mengklasifikasikan citra kain maupun pakaian bermotif batik, meskipun lipatan kain dan latar belakang kompleks masih dapat menurunkan tingkat keyakinan model.

Kata kunci : *convolutional neural network, ResNet50, motif batik, klasifikasi citra, deep learning*

1. PENDAHULUAN

Batik merupakan warisan budaya takbenda Indonesia yang telah diakui UNESCO sejak tahun 2009 sebagai *Representative List of the Intangible Cultural Heritage of Humanity* [1] [2]. Motif batik tidak hanya memuat nilai estetika, tetapi juga sejarah dan filosofi yang merefleksikan identitas daerah serta kearifan lokal pembatik. Di era digital, batik banyak hadir sebagai citra pada katalog daring, media sosial, dan *platform e-commerce* sehingga dibutuhkan sistem pengenalan motif yang cepat dan akurat untuk mendukung dokumentasi koleksi, pencarian produk, dan edukasi. Perkembangan *deep learning*, khususnya *convolutional neural network* (CNN), mengubah paradigma pengolahan citra dengan memungkinkan model belajar fitur langsung dari data gambar mentah [2] [3]. Sejumlah penelitian menunjukkan bahwa CNN mampu mengklasifikasikan motif batik dengan akurasi lebih tinggi dan lebih stabil dibanding metode berbasis fitur manual; pengenalan beberapa motif klasik seperti Banji, Ceplok, Kawung, Mega Mendung, Parang, dan Sekar Jagad dengan CNN dan *data augmentation* dilaporkan mencapai akurasi di atas 90% [4] [5] [6] [7].

Sebelum berkembangnya *deep learning*, pengenalan motif batik banyak mengandalkan fitur buatan tangan (*handcrafted features*) seperti warna, tekstur, dan bentuk. Berbagai studi memanfaatkan fitur tekstur Gray-Level Co-occurrence Matrix (GLCM), Local Binary Pattern (LBP), deskriptor tekstur lain, serta kombinasi fitur warna dan tekstur yang kemudian

diklasifikasikan dengan k-Nearest Neighbor (k-NN), Support Vector Machine (SVM), maupun Self-Organizing Map (SOM) [1] [8] [9]. Pendekatan ini dilaporkan mampu menghasilkan akurasi sekitar 70–90% bergantung jumlah kelas dan kualitas citra, namun kinerjanya sensitif terhadap perubahan pencahayaan, sudut pandang, skala, dan latar belakang, serta sangat bergantung pada keahlian perancang fitur [1] [9]. Dalam ranah *deep learning*, transfer learning banyak dimanfaatkan untuk meningkatkan kinerja dan efisiensi pelatihan melalui arsitektur pra-latih seperti VGG-16, ResNet-50, DenseNet, dan EfficientNet yang di-*fine-tune* menggunakan dataset batik [10] [11]. Berbagai karya melaporkan bahwa kombinasi transfer learning dan teknik *data augmentation* lanjutan mampu menghasilkan akurasi klasifikasi batik pada kisaran 84–96% [7] [11] [12] [13] [14], sementara penelitian terbaru mulai mengeksplorasi Vision Transformer (ViT) [15]. Namun, banyak studi masih berfokus pada nilai akurasi global tanpa analisis mendalam terhadap pola kesalahan pada *confusion matrix* serta belum banyak menguji model pada citra dunia nyata seperti pakaian bermotif batik dengan lipatan dan latar belakang kompleks [14] [16]. Permasalahan utama dalam penelitian ini adalah belum tersedianya model klasifikasi motif batik yang tidak hanya memiliki akurasi tinggi pada citra kain datar, tetapi juga teruji pada citra batik dunia nyata dan disertai analisis kesalahan yang komprehensif.

Sejalan dengan permasalahan tersebut, tujuan penelitian ini adalah mengembangkan dan mengevaluasi model klasifikasi motif batik Indonesia berbasis *deep learning* menggunakan CNN ResNet50 dengan skema transfer learning dan pra-pemrosesan citra berbasis deteksi tepi [11] [12]. Secara khusus, penelitian ini bertujuan: (1) menyusun dataset multi-kelas motif batik yang beragam dengan mengombinasikan sumber publik dan citra manual; (2) merancang skema pra-pemrosesan *edge-enhanced* untuk menonjolkan pola garis dan kontur motif batik; (3) menganalisis kinerja model ResNet50 pada skenario klasifikasi 20 kelas motif batik menggunakan metrik akurasi, *precision*, *recall*, F1-score, dan *confusion matrix*; serta (4) menilai kemampuan generalisasi awal model pada citra pakaian bermotif batik.

Untuk menyelesaikan permasalahan tersebut, penelitian ini menerapkan pendekatan transfer learning dengan memanfaatkan arsitektur ResNet50 pra-latih sebagai *feature extractor* yang kemudian di-*fine-tune* menggunakan dataset batik. Tahapan penelitian meliputi pengumpulan dan pembersihan data, penyusunan dataset berisi 3.000 citra kain batik datar berwarna yang merepresentasikan 20 kelas motif, pra-pemrosesan citra menggunakan teknik *edge-enhanced* berbasis deteksi tepi, pembangunan model ResNet50 dengan penambahan *classifier head*, serta pelatihan dua tahap yang mencakup pelatihan lapisan klasifikasi dan *fine-tuning* sebagian lapisan konvolusional. Kinerja model dievaluasi pada himpunan data uji terpisah dan dianalisis pola kesalahannya, kemudian diimplementasikan dalam bentuk prototipe lokal untuk menguji prediksi terhadap citra kain dan pakaian bermotif batik pada kondisi lebih mendekati penggunaan nyata.

2. TINJAUAN PUSTAKA

2.1. Pra-pemrosesan Citra Batik dan *Edge-Enhanced Input*

Sebelum citra batik diproses oleh *convolutional neural network (CNN)*, diperlukan tahap pra-pemrosesan untuk menstabilkan kualitas visual dan menonjolkan pola yang relevan. Langkah umum yang banyak digunakan antara lain pengubahan ukuran citra ke resolusi seragam, normalisasi nilai piksel, serta penyesuaian kontras agar perbedaan antara motif dan latar belakang lebih jelas [3] [4] [5] [6] [12]. Pada konteks batik, pra-pemrosesan menjadi penting karena motif sering tersusun dari garis dan kontur halus yang dapat tertutup oleh variasi pencahayaan, noise, atau artefak pemotretan.

Salah satu pendekatan yang sejalan dengan karakter visual batik adalah pemanfaatan deteksi tepi (*edge detection*). Dengan mengubah citra RGB ke keabuan, kemudian menerapkan operator deteksi tepi (misalnya Canny), struktur garis utama motif dapat diekstraksi dalam bentuk peta tepi. Peta tepi ini kemudian dioverlay kembali ke citra berwarna sehingga garis dan kontur motif menjadi lebih

menonjol sebelum dimasukkan ke jaringan CNN. Skema *edge-enhanced* seperti ini membantu model fokus pada bentuk dan alur garis batik, bukan hanya variasi warna permukaan, sehingga cocok untuk motif yang kaya pola geometris maupun ornamen organik. Dalam penelitian ini, pendekatan tersebut diintegrasikan langsung ke alur pra-pemrosesan sebagai tahap wajib sebelum citra diproses oleh ResNet50.

2.2. Klasifikasi Motif Batik Berbasis CNN

Kemunculan *convolutional neural network (CNN)* menggeser pendekatan pengenalan motif batik dari rekayasa fitur manual ke pembelajaran fitur secara otomatis langsung dari citra [2] [3] [17]. Sejumlah penelitian menunjukkan bahwa *CNN* mampu memberikan akurasi lebih tinggi dibanding metode konvensional berbasis fitur tekstur untuk pengenalan pola batik [2] [3]. Pendekatan serupa digunakan pada klasifikasi motif batik Banyuwangi, di mana *CNN* dimanfaatkan untuk menangkap pola khas daerah dan memberikan kinerja yang baik pada skenario multi-kelas [4].

Pengaruh *data augmentation* terhadap kinerja klasifikasi batik juga telah dikaji. Penelitian [5] membandingkan penggunaan *CNN* dan *k-nearest neighbor (k-NN)* dengan dan tanpa *augmentation*, dan menemukan bahwa variasi transformasi citra berperan penting dalam meningkatkan akurasi ketika variasi visual cukup tinggi. Studi lain membandingkan arsitektur LeNet dan MobileNet untuk identifikasi batik Lampung dan menunjukkan bahwa arsitektur *CNN* modern yang ringan seperti MobileNet dapat memberikan akurasi lebih baik sekaligus lebih efisien secara komputasi [10].

Selain klasifikasi motif, *CNN* juga dimanfaatkan untuk tugas terkait batik lainnya [5]. Penelitian [5] menggunakan *CNN* untuk mengidentifikasi metode pembuatan batik (tulis, cap, kombinasi) dari citra permukaan kain, dan menunjukkan bahwa perbedaan karakter visual hasil teknik produksi dapat dibedakan dengan cukup baik meskipun jumlah data terbatas. Beberapa karya terbaru mulai mengeksplorasi desain jaringan yang lebih khusus, misalnya *data augmentation* terarah untuk meningkatkan kemampuan generalisasi model [7] [13] [14] serta arsitektur Okta-Net yang dioptimalkan untuk klasifikasi batik otomatis dan dilaporkan memberikan peningkatan kinerja pada beberapa skenario uji [18].

2.3. Peningkatan Kinerja Melalui Augmentasi, Tuning, dan Pengaturan Dataset

Selain pemilihan arsitektur, keberhasilan model *convolutional neural network (CNN)* juga sangat dipengaruhi oleh strategi pengolahan dan pengaturan data [12] [13] [14]. Penelitian [13] menyoroti peran *data augmentation* dan *hyperparameter tuning* pada klasifikasi jenis batik berbasis *CNN*; kombinasi penyesuaian *learning rate*, ukuran *batch*, serta variasi *augmentation* terbukti mampu meningkatkan kinerja

model secara signifikan. Studi lain menerapkan *CNN* dengan *data augmentation* untuk klasifikasi batik Garutan dan menunjukkan bahwa penambahan variasi citra latih membantu mencegah *overfitting* pada dataset yang relatif kecil [5].

Masalah ketidakseimbangan kelas (*class imbalance*) juga mendapat perhatian khusus. Penelitian [14] mengusulkan kombinasi *advanced augmentation* dan teknik *oversampling* pada dataset batik yang tidak seimbang, dan hasilnya mampu meningkatkan nilai *F1-score* pada kelas minoritas tanpa mengorbankan performa kelas mayoritas. Di sisi arsitektur, pemanfaatan model pra-pemrosesan melalui skema *transfer learning* ditunjukkan pada [11], yang mengimplementasikan EfficientNet-B1 untuk klasifikasi motif batik dan berhasil mencapai akurasi tinggi meskipun jumlah data latih spesifik batik relatif terbatas.

Selain itu, kualitas dan pengelolaan dataset juga terbukti berpengaruh langsung terhadap kinerja model. Penelitian [12] menekankan pentingnya perbaikan kualitas data, seperti pembersihan label, eliminasi citra bermasalah, serta pengaturan ulang komposisi data antar kelas, untuk meningkatkan performa *CNN* pada tugas klasifikasi batik. Temuan-temuan tersebut menguatkan bahwa strategi pengolahan data mulai dari *augmentation*, penanganan *class imbalance*, hingga kurasi dataset merupakan faktor kunci yang perlu diperhatikan bersamaan dengan pemilihan arsitektur jaringan.

2.4. Pendekatan dan Arah Pengembangan


Di luar *CNN* konvensional, beberapa penelitian mulai mengeksplorasi arsitektur lain untuk klasifikasi motif batik. Salah satunya adalah pemanfaatan *Vision Transformer* (ViT) yang memproses citra sebagai deretan *patch* dan memanfaatkan mekanisme *self-attention*. Penerapannya pada motif batik Nusantara menunjukkan bahwa ViT mampu bersaing dengan *CNN* pada pola batik yang kompleks dan kaya detail [15].

Di sisi lain, perkembangan *deep learning* pada bidang lain juga memberi gambaran arah pengembangan, misalnya integrasi *CNN* dengan *explainable AI* (XAI) untuk menjelaskan keputusan klasifikasi melalui visualisasi area citra yang paling berkontribusi [16]. Pendekatan serupa berpotensi diadaptasi pada motif batik untuk menginterpretasikan pola atau area kain yang menjadi fokus model ketika menentukan kelas motif, meskipun hal tersebut belum menjadi fokus utama penelitian ini.

Secara keseluruhan, tinjauan ini menunjukkan bahwa penelitian klasifikasi batik saat ini didominasi oleh pendekatan *deep learning* berbasis *CNN* dengan dukungan *transfer learning* dan *data augmentation* [2] [3] [4] [5] [6] [7] [10] [11] [12] [13] [14] [17] [18]. Meskipun demikian, masih terbuka ruang pengembangan terkait peningkatan ketahanan model terhadap variasi citra dunia nyata misalnya batik yang sudah menjadi pakaian, lipatan kain, serta latar

belakang yang kompleks serta integrasi model ke dalam prototipe aplikasi yang siap digunakan oleh pengguna non-teknis [14] [15] [16] [18]. Dalam konteks tersebut, penelitian ini memanfaatkan arsitektur ResNet50, skema pra-pemrosesan *edge-enhanced*, dan evaluasi tambahan melalui prototipe lokal untuk mengamati perilaku model pada kondisi yang lebih mendekati penggunaan nyata.

3. METODE PENELITIAN



Gambar 1. Tahapan penelitian

Metode penelitian ini disusun untuk menggambarkan alur kerja pembangunan sistem klasifikasi motif batik berbasis *deep learning* secara jelas dan terstruktur [2] [17]. Secara garis besar, penelitian melalui enam tahap utama sebagaimana ditunjukkan pada Gambar 1, yaitu pengumpulan data, preparasi data, pembangunan model, pelatihan model, proses pengujian, dan evaluasi model. Pendekatan yang digunakan bersifat kuantitatif dengan paradigma *supervised learning*, di mana setiap citra batik diberi label sesuai kelas motif lalu digunakan untuk melatih model *Convolutional Neural Network* (*CNN*) berbasis arsitektur ResNet50 [19]. Model dibangun dengan skema *transfer learning* dan dipadukan dengan pra-pemrosesan citra berbasis *edge-enhancement* untuk menyelesaikan tugas klasifikasi 20 kelas motif batik [11].

Objek penelitian berupa citra digital batik Indonesia yang dikelompokkan ke dalam 20 kelas motif dengan total 3.000 citra kain batik datar berwarna (masing-masing 150 citra per kelas). Selain itu, dikumpulkan pula sejumlah citra pakaian bermotif batik dari foto pribadi dan sumber daring yang digunakan sebagai *test set* tambahan pada beberapa kelas. Ruang lingkup penelitian dibatasi pada: (1) pengolahan citra batik (pra-pemrosesan, termasuk *edge-enhancement* dan augmentasi) untuk menyiapkan data masukan model; (2) pelatihan model *CNN* ResNet50 untuk klasifikasi 20 kelas motif batik; (3) pengujian model menggunakan citra kain batik datar dan pakaian bermotif batik; serta (4) pengembangan prototipe antarmuka lokal yang memanfaatkan model terlatih sebagai demonstrasi sistem identifikasi motif batik berbasis citra [18].

3.1. Pengumpulan Data

Tahap pengumpulan data bertujuan untuk memperoleh serta memahami karakteristik citra motif batik yang akan digunakan sebagai dasar pelatihan model. Data dikumpulkan dari dua sumber, yaitu dataset publik dan penambahan citra secara manual. Dataset publik diperoleh dari salah satu kumpulan citra

batik Indonesia yang tersedia di platform Kaggle, di mana data awal telah tersusun dalam struktur folder berdasarkan kelas motif sehingga setiap citra memiliki label yang jelas. Pada tahap ini dilakukan identifikasi jumlah citra pada setiap kelas, pengecekan kualitas citra meliputi ketajaman, keberadaan noise, dan kejelasan motif, serta pemeriksaan konsistensi penamaan kelas. Citra yang buram, berukuran terlalu kecil, rusak, atau memiliki motif yang tidak jelas dieliminasi, kemudian hasil eksplorasi dan seleksi digunakan untuk menyusun dataset akhir [12]. Selain itu, untuk memperkaya variasi data pada tahap pengujian, dikumpulkan sejumlah citra tambahan secara manual [12], baik berupa foto kain batik datar maupun batik yang telah diaplikasikan pada pakaian. Citra tambahan ini diperoleh dari foto pribadi dan sumber daring yang relevan, lalu melalui proses seleksi ringan agar motif tetap terlihat jelas setelah pra-pemrosesan. Secara keseluruhan, dataset utama yang digunakan terdiri atas 3.000 citra kain batik berwarna (RGB) yang terbagi ke dalam 20 kelas motif, masing-masing sebanyak 150 citra, sedangkan citra tambahan dimanfaatkan pada tahap pengujian dan demonstrasi, terutama melalui *prototype web* [18].

3.2. Preparasi Data

Tahap preparasi data dilakukan untuk menyiapkan citra agar sesuai dengan kebutuhan arsitektur ResNet50 sekaligus menonjolkan pola khas motif batik [11]. Proses diawali dengan pembersihan data, yakni menghapus citra yang terlalu buram, berukuran sangat kecil, atau motifnya tidak tampak jelas. Seluruh citra kemudian di-*resize* menjadi 224×224 piksel (RGB) agar seragam dan efisien secara komputasi [3] [4]. Berikutnya diterapkan pra-pemrosesan *edge-enhanced*: citra RGB dikonversi ke *grayscale*, dideteksi tepinya dengan *operator Canny*, lalu hasil tepi diubah menjadi tiga kanal dan dioverlay dengan citra asli melalui operasi *weighted sum* sehingga garis dan kontur motif lebih menonjol. Citra yang sudah diproses dikonversi ke tipe *float32* dan dinormalisasi menggunakan fungsi *preprocess_input* ResNet50 agar distribusi piksel selaras dengan skema pra-latih *ImageNet*. Setelah itu, data dibagi secara *stratified* menjadi 70% data latih (dengan sebagian sebagai validasi internal) dan 30% data uji, di mana hanya data latih yang diberi *augmentasi data* (rotasi kecil, *horizontal flip*, pergeseran, *zoom* ringan, dan variasi kecerahan), sementara data validasi dan uji hanya melalui *resize*, *edge-enhanced*, dan normalisasi tanpa *augmentasi* [5] [6] [13].

3.3. Pembangunan Model

Model klasifikasi motif batik dibangun menggunakan pendekatan deep learning berbasis arsitektur ResNet50 dengan menerapkan strategi transfer learning [10] [11]. Pada tahap awal, digunakan ResNet50 pra-pemrosesan yang dilatih pada dataset *ImageNet* sebagai base model dengan pengaturan

include_top=False, sehingga lapisan klasifikasi bawaan tidak disertakan. Seluruh lapisan konvolusi pada *base model* pada awalnya di set tidak dapat dilatih (*trainable=False*) agar berfungsi sebagai *feature extractor* umum yang mengekstraksi ciri visual dasar dari citra batik. Di atas base model tersebut kemudian ditambahkan lapisan klasifikasi (*classifier head*) yang terdiri dari *GlobalAveragePooling2D* untuk mereduksi peta fitur menjadi vektor fitur global, diikuti oleh lapisan *Dropout* dengan laju 0,5 untuk mengurangi risiko *overfitting*, serta lapisan *Dense* dengan 20 neuron keluaran dan fungsi aktivasi *softmax* yang merepresentasikan 20 kelas motif batik. Setelah arsitektur model disusun, model dikompilasi menggunakan fungsi kerugian *categorical_crossentropy*, *optimizer Adam*, dan metrik evaluasi utama berupa *accuracy*. Melalui tahapan ini, diperoleh arsitektur CNN yang lengkap dan siap dilatih menggunakan dataset motif batik yang telah dipersiapkan sebelumnya.

3.4. Pelatihan Model

Pelatihan model dilakukan dalam dua tahap utama agar pemanfaatan fitur pra-latih ResNet50 dan penyesuaian terhadap karakteristik motif batik dapat berlangsung lebih stabil [11] [13]. Pada tahap pertama, yaitu pelatihan *head (feature extraction)*, seluruh *layer* pada *base model* ResNet50 tetap dibekukan (*trainable = False*) sehingga bobot pra-latih tidak berubah, dan hanya lapisan klasifikasi yang terdiri atas *GlobalAveragePooling*, *Dropout*, dan *Dense* yang dilatih. Proses pelatihan pada tahap ini menggunakan *optimizer Adam* dengan *learning rate* $1e-4$ dan *batch size* 32. Untuk mencegah *overfitting*, diterapkan mekanisme *early stopping* berbasis *validation loss* yang menghentikan pelatihan ketika kinerja pada data validasi mulai menurun, serta *model checkpoint* untuk menyimpan bobot model terbaik. Tujuan dari tahap pertama ini adalah agar lapisan klasifikasi mampu memanfaatkan fitur umum yang diekstraksi oleh ResNet50 tanpa mengubah bobot dasar model.

Pada tahap kedua dilakukan *fine-tuning* untuk menyempurnakan kinerja model [11]. Pada tahap ini, beberapa blok konvolusi terakhir pada ResNet50 diaktifkan kembali (*trainable = True*), sementara lapisan-lapisan bawah tetap dibekukan guna mempertahankan fitur dasar yang telah dipelajari dari *ImageNet*. Proses pelatihan masih menggunakan Adam, tetapi dengan *learning rate* yang lebih kecil, yaitu $1e-5$, agar penyesuaian bobot berlangsung secara halus dan stabil. Mekanisme *early stopping* dan *model checkpoint* kembali digunakan untuk memilih bobot model dengan performa terbaik pada data validasi. Model terbaik hasil *fine-tuning* kemudian disimpan dalam format berkas *.h5* dan digunakan pada seluruh proses pengujian serta implementasi pada *prototype web*.

3.5. Proses Pengujian

Tahap pengujian menjelaskan pemanfaatan model terlatih untuk memprediksi motif batik dari citra baru, baik pada skenario eksperimen maupun melalui prototipe lokal. Pada tahap ini, citra batik (kain datar atau pakaian) dipilih kemudian dipra-proses dengan alur yang sama seperti saat pelatihan, yaitu *resize* ke 224×224 piksel, *edge-enhanced*, normalisasi dengan *preprocess_input*, dan dibentuk menjadi *tensor* berukuran (1, 224, 224, 3). *Tensor* tersebut dimasukkan ke model ResNet50 untuk menghasilkan vektor probabilitas 20 kelas, lalu kelas dengan probabilitas tertinggi diambil sebagai label prediksi, dengan opsi menampilkan 5 kelas teratas untuk analisis. Pada prototipe lokal, alur ini dikemas dalam skenario unggah prediksi tampil hasil sehingga pengguna cukup mengunggah citra dan sistem langsung menampilkan nama motif beserta tingkat keyakinan model.

3.6. Evaluasi Model

Evaluasi model dilakukan untuk mengukur kualitas dan konsistensi performa, baik pada data uji terpisah maupun pada skenario penggunaan melalui prototipe lokal. Secara kuantitatif, model diuji menggunakan 30% data uji kain batik datar yang tidak pernah digunakan saat pelatihan maupun validasi. Dari hasil prediksi dan label sebenarnya dihitung beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score* per kelas, serta disusun *confusion matrix* 20×20 yang divisualisasikan dalam bentuk *heatmap* untuk melihat distribusi prediksi benar-salah dan motif yang sering tertukar. Seluruh perhitungan dilakukan dengan bantuan pustaka *scikit-learn*.


Selain itu, dilakukan evaluasi tambahan melalui prototipe lokal untuk melihat perilaku model pada kondisi yang lebih mendekati penggunaan nyata. Untuk setiap kelas motif, sekitar 10 citra uji (kain maupun pakaian bermotif batik) diunggah melalui antarmuka, lalu sistem mencatat jumlah prediksi benar dan salah serta persentase keberhasilan per kelas. Hasil ini kemudian dibandingkan dengan evaluasi formal pada data uji. Kombinasi evaluasi kuantitatif (*accuracy*, *F1-score*, dan *confusion matrix*) dan pengujian melalui prototipe memberikan gambaran yang lebih utuh tentang keandalan model dalam mengenali motif batik pada berbagai kondisi [14] [16].

4. HASIL DAN PEMBAHASAN

4.1. Presentasi Hasil


Tahap pelatihan dilakukan dalam dua fase, yaitu pelatihan *classifier head* dan *fine-tuning* sebagian *layer* atas ResNet50 dengan pra-pemrosesan *edge-enhanced*. Pergerakan nilai *accuracy* dan *loss* pada data latih maupun validasi ditunjukkan pada Gambar 2. Dari grafik tersebut terlihat bahwa *train loss* dan *val loss* menurun cukup tajam pada beberapa *epoch* awal, kemudian berangsur stabil, sementara kurva *train accuracy* dan *val accuracy* meningkat dan saling mendekat. Pola ini mengindikasikan proses

konvergensi yang baik tanpa gejala *overfitting* yang signifikan, sehingga bobot terbaik dapat dipilih berdasarkan *validation loss* terendah.



Gambar 2. Grafik pelatihan dan validasi

Evaluasi kuantitatif dilakukan pada *test set* yang berisi 568 citra ($\approx 30\%$ dari dataset utama) yang tidak pernah digunakan pada pelatihan maupun validasi. Gambar 3 menyajikan *confusion matrix* model yang digunakan untuk memetakan hubungan antara kelas sebenarnya dan kelas hasil prediksi, sehingga memudahkan identifikasi motif yang konsisten dikenali dengan benar maupun pasangan motif yang masih sering tertukar. Melalui *confusion matrix* ini, pola kesalahan klasifikasi dapat dianalisis lebih rinci sebagai dasar perbaikan model pada penelitian selanjutnya.



Gambar 3. Heatmap confusion matrix 20×20

Untuk melihat kontribusi masing-masing kelas secara lebih rinci, *precision*, *recall*, dan *F1-score* per kelas dirangkum pada Tabel 1. Terlihat bahwa sebagian besar kelas memiliki nilai metrik di atas 95%, dan beberapa motif bahkan mencapai nilai 100% pada ketiga metrik.

Tabel 1. *Precision*, *recall*, dan *F1-score* per kelas

Kelas Motif	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-score</i> (%)
batik_betawi	96	100	98
batik_bokor_kencono	100	100	100
batik_buketan	100	100	100
batik_dayak	92	100	96
batik_jlamprang	91	91	91
batik_kawung	91	87	89

Kelas Motif	Precision (%)	Recall (%)	F1-score (%)
batik_liong	100	100	100
batik_mega_mendung	100	100	100
batik_parang	100	91	95
batik_sekarjagad	100	91	95
batik_sidoluhur	97	100	98
batik_sidomukti	100	100	100
batik_sidomulyo	96	96	96
batik_singa_barong	100	100	100
batik_srikaton	100	97	98
batik_tribusono	100	100	100
batik_tujuh_rupa	100	100	100
batik_tuntrum	97	97	97
batik_wahyu_tumurun	94	100	97
batik_wirasat	100	100	100

Secara agregat, ringkasan metrik pada Tabel 2 menunjukkan bahwa model menghasilkan *accuracy* keseluruhan sebesar 0,98, dengan *precision*, *recall*, dan *F1-score macro average* maupun *weighted average* yang juga bernilai 0,98. Dari tabel ini dapat dilihat bahwa performa model stabil di seluruh kelas meskipun jumlah sampel tiap kelas tidak sepenuhnya seimbang [14].


Tabel 2. Ringkasan metrik evaluasi pada test set (30%)

Metrik	Nilai
Akurasi	0,98
Precision (macro average)	0,98
Recall (macro average)	0,98
F1-score (macro average)	0,98
F1-score (weighted avg.)	0,98

Secara keseluruhan, kombinasi arsitektur ResNet50 dengan pra-pemrosesan *edge-enhanced* memberikan kinerja yang sangat baik pada tugas klasifikasi 20 motif batik. Nilai *accuracy* dan *F1-score* yang tinggi, baik secara agregat maupun per kelas, mengindikasikan bahwa penajaman tepi membantu jaringan mengekstraksi pola garis dan kontur utama, sementara lapisan dalam ResNet50 menangkap variasi tekstur dan bentuk yang lebih kompleks. Dengan capaian tersebut, pendekatan ini layak dipertimbangkan sebagai dasar sistem identifikasi motif batik berbasis citra, khususnya jika pada penelitian selanjutnya didukung oleh dataset yang lebih luas dan beragam.


4.2. Hasil uji pada prototipe lokal

Model ResNet50 yang telah dilatih kemudian diintegrasikan ke dalam sebuah prototipe aplikasi berbasis web yang dijalankan secara lokal. Antarmuka prototipe dirancang sederhana: pengguna memilih berkas citra batik dari penyimpanan lokal, sistem menampilkan pratinjau citra, lalu hasil klasifikasi motif batik beserta tingkat keyakinan model disajikan dalam bentuk kartu informasi.



Gambar 4. Tampilan antarmuka prototipe lokal

Gambar 4 menunjukkan tampilan awal prototipe saat belum ada citra yang diunggah. Pengguna hanya melihat judul *Batik Classifier*, area unggah citra yang menampilkan ikon upload, serta informasi format berkas yang didukung (JPG, PNG, JPEG). Tampilan ini berfungsi sebagai titik awal interaksi dan memberikan petunjuk yang cukup jelas bahwa langkah pertama yang harus dilakukan adalah memilih atau menyeret berkas citra batik ke dalam area tersebut.



Gambar 5. Pratinjau citra batik yang telah dipilih pengguna

Setelah pengguna memilih citra, *prototype* menampilkan pratinjau gambar pada panel utama sebagaimana terlihat pada Gambar 5. Pada tahap ini, pengguna dapat mengganti gambar, menekan tombol klasifikasi, atau mereset tampilan. Pratinjau ini penting sebagai konfirmasi bahwa motif batik pada citra sudah terlihat cukup jelas sebelum diproses oleh model.

Contoh hasil klasifikasi ditunjukkan pada Gambar 6. Sistem mengenali motif sebagai Batik Buketan dengan tingkat keyakinan sekitar 70,90%. Kartu hasil menampilkan nama motif, nilai *accuracy* dalam persen beserta batang progres, serta informasi pendukung seperti asal daerah, jenis pola, dan deskripsi singkat. Dari tampilan ini terlihat bahwa *prototype* tidak hanya mengembalikan label kelas, tetapi juga menyediakan konteks budaya yang membantu pengguna memahami karakter motif yang diprediksi.



Gambar 6. Contoh hasil prediksi motif batik pada prototype lokal

Secara kualitatif, uji coba menunjukkan bahwa *prototype* responsif dan prediksi model umumnya selaras dengan pola visual citra uji. Nilai probabilitas yang sedikit lebih rendah (sekitar 70–85%) pada beberapa foto pakaian mengindikasikan bahwa lipatan kain dan latar belakang yang ramai masih dapat menurunkan tingkat keyakinan model, namun informasi probabilitas ini justru memberi sinyal kepada pengguna bahwa hasil klasifikasi perlu ditinjau lebih hati-hati [14].

4.3. Analisis Temuan dan Implikasi

Secara keseluruhan, kombinasi arsitektur ResNet50 dan pra-pemrosesan *edge-enhanced* terbukti efektif untuk klasifikasi 20 motif batik. Nilai *accuracy* dan *F1-score* yang mencapai 0,98 menunjukkan bahwa model mampu mengenali motif yang sangat khas sekaligus mempertahankan kinerja yang seimbang di hampir semua kelas. Motif dengan pola kuat seperti Buketan, Mega Mendung, Singa Barong, atau Wirasat sangat mudah dipelajari jaringan, sedangkan sedikit penurunan performa terlihat pada motif geometris rapat seperti Kawung, Jlamprang, Parang, dan Sekarjagad yang secara visual memang berdekatan sehingga wajar jika sebagian sampel saling tertukar [14].

Kontribusi pra-pemrosesan *edge-enhanced* terlihat dari kemampuan model untuk menangkap garis dan kontur utama batik dengan lebih jelas, terutama pada motif yang bertumpu pada struktur garis. Namun, pada motif dengan *isen* halus dan latar padat, penajaman tepi belum sepenuhnya menghilangkan ambiguitas, yang tercermin pada beberapa kesalahan silang di *confusion matrix*. Temuan ini mengisyaratkan bahwa pendekatan *edge-enhanced* memberi keuntungan penting, tetapi masih dapat diperkaya, misalnya dengan segmentasi motif atau variasi augmentasi yang lebih agresif pada pola rapat.

Dari sisi pemanfaatan, hasil pengujian menunjukkan bahwa model yang dibangun sudah cukup matang sebagai dasar sistem pengenalan motif batik berbasis citra. Alur unggah, klasifikasi, tampil

hasil yang sederhana membuat *prototype* berpotensi digunakan untuk membantu pengelolaan koleksi batik, pencarian produk di katalog digital, maupun edukasi bagi pengguna awam [18]. Informasi tambahan tentang asal daerah dan jenis pola pada halaman hasil juga membuka peluang pemanfaatan sebagai media pembelajaran interaktif mengenai warisan visual batik [17].

4.4. Keterbatasan Penelitian

Meskipun hasil yang diperoleh cukup menjanjikan, penelitian ini memiliki beberapa keterbatasan. Pertama, cakupan data masih terbatas pada 20 motif dengan 3.000 citra mayoritas berupa kain datar, sehingga belum mewakili keragaman motif batik Indonesia secara menyeluruh. Citra pakaian bermotif batik yang digunakan pada uji *prototype* juga belum seimbang antar kelas, sehingga potensi *bias* masih ada [14]. Kedua, kualitas citra bervariasi dari sisi resolusi, pencahayaan, sudut pengambilan, dan latar belakang, terutama pada foto dunia nyata; kondisi ekstrem semacam ini masih dapat menurunkan probabilitas prediksi meskipun kelas yang dipilih benar. Ketiga, eksperimen difokuskan pada satu arsitektur utama (ResNet50) dengan skema *hyperparameter* tertentu, sehingga belum mengeksplorasi model lain yang lebih ringan maupun variasi konfigurasi yang lebih luas [13] [15]. Keempat, teknik *data augmentation* yang digunakan masih tergolong dasar dan evaluasi pada *prototype* belum disertai perhitungan metrik formal tersendiri, sehingga dibutuhkan studi lanjutan yang lebih terkontrol untuk mengukur kinerja pada citra dunia nyata secara lebih rinci.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil merancang dan mengevaluasi sistem klasifikasi motif batik Indonesia berbasis citra menggunakan arsitektur ResNet50 dengan *transfer learning* dan pra-pemrosesan *edge-enhanced*. Model yang dibangun mampu mengklasifikasikan 20 motif batik dengan kinerja sangat baik pada *test set* terpisah, dengan *accuracy* dan *F1-score* sekitar 0,98 serta mayoritas kelas memiliki nilai *precision* dan *recall* di atas 95%. Uji kualitatif melalui *prototype* web lokal menunjukkan bahwa model dapat digunakan dalam alur penggunaan sederhana, meskipun citra pakaian dengan lipatan dan latar belakang kompleks masih menurunkan tingkat keyakinan pada beberapa kasus. Ke depan, perlu dilakukan perluasan dataset dengan lebih banyak citra dunia nyata, penerapan teknik *data augmentation* dan pra-pemrosesan yang lebih beragam, serta eksplorasi arsitektur yang lebih ringan agar sistem dapat diintegrasikan ke platform web maupun perangkat bergerak. Dengan pengembangan tersebut, sistem klasifikasi motif batik berbasis *deep learning* ini diharapkan dapat memberikan kontribusi nyata bagi dokumentasi, edukasi, dan pelestarian batik Indonesia.

DAFTAR PUSTAKA

- [1] A. E. Minarno, Y. Azhar, F. D. Setiawan Sumadi, and Y. Munarko, "A Robust Batik Image Classification using Multi Texton Co-Occurrence Descriptor and Support Vector Machine," in *2020 3rd International Conference on Intelligent Autonomous Systems (ICoIAS)*, Singapore: IEEE, Feb. 2020, pp. 51–55. doi: 10.1109/ICoIAS49312.2020.9081833.
- [2] A. E. Minarno, "Klasifikasi Jenis Batik Menggunakan Algoritma Convolutional Neural Network," *J. Repos.*, vol. 3, no. 2, Mar. 2021, doi: 10.22219/repositor.v3i2.1201.
- [3] M. A. Rasyidi and T. Bariyah, "Batik pattern recognition using convolutional neural network," *Bull. Electr. Eng. Inform.*, vol. 9, no. 4, pp. 1430–1437, Aug. 2020, doi: 10.11591/eei.v9i4.2385.
- [4] L. Hakim, H. R. Rahmanto, S. P. Kristanto, and D. Yusuf, "Klasifikasi Citra Motif Batik Banyuwangi Menggunakan Convolutional Neural Network," *J. Teknoinfo*, vol. 17, no. 1, p. 203, Jan. 2023, doi: 10.33365/jti.v17i1.2342.
- [5] D. Trimakno and Kusriani, "Impact of Augmentation on Batik Classification using Convolution Neural Network and K-Nearest Neighbor," in *2021 4th International Conference on Information and Communications Technology (ICOIAC)*, Yogyakarta, Indonesia: IEEE, Aug. 2021, pp. 285–289. doi: 10.1109/ICOIAC53268.2021.9564000.
- [6] C. Uswatun Khasanah, E. Utami, and S. Raharjo, "Implementation of Data Augmentation Using Convolutional Neural Network for Batik Classification," in *2020 8th International Conference on Cyber and IT Service Management (CITSM)*, Pangkal Pinang, Indonesia: IEEE, Oct. 2020, pp. 1–5. doi: 10.1109/CITSM50537.2020.9268890.
- [7] 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.
- [8] D. S. Sany, "Implementasi dan Pengujian Algoritma Fitur Warna pada Image Retrieval," *Media J. Inform.*, vol. 12, no. 1, p. 1, Jan. 2021, doi: 10.35194/mji.v12i1.1187.
- [9] N. K. Hamzidah, A. Jariyah, A. R. Ramadhani, N. Nurhasni, M. M. Parenreng, and S. Suyuti, "Evaluation of image feature extraction using gray level co-occurrence matrix (GLCM) parameters and multilayer perceptron (MLP) algorithms in classifying typical batik motifs of South Sulawesi," presented at the THE 1ST INTERNATIONAL MULTIDISCIPLINARY CONFERENCE OF APPLIED SCIENCES: Applied Sciences for Sustainable Earth, Environment and Management, Makassar, Indonesia, 2024, p. 030004. doi: 10.1063/5.0221156.
- [10] R. Andrian, H. C. Herwanto, R. Taufik, and D. Kurniawan, "Performance Comparison Between LeNet And MobileNet In Convolutional Neural Network for Lampung Batik Image Identification," *Sci. J. Inform.*, vol. 11, no. 1, pp. 147–154, Feb. 2024, doi: 10.15294/sji.v11i1.49451.
- [11] A. Hardirega, I. Jaelani, and M. Minarto, "Implementasi Convolutional Neural Network (CNN) Klasifikasi Motif Batik Menggunakan EfficientNet-B1," *JATI J. Mhs. Tek. Inform.*, vol. 8, no. 5, pp. 10023–10028, Sept. 2024, doi: 10.36040/jati.v8i5.10901.
- [12] D. G. T. Meranggi, N. Yudistira, and Y. A. Sari, "Batik Classification Using Convolutional Neural Network with Data Improvements," *JOIV Int. J. Inform. Vis.*, vol. 6, no. 1, p. 6, Mar. 2022, doi: 10.30630/joiv.6.1.716.
- [13] S. Auliaddina and T. Arifin, "Use of Augmentation Data and Hyperparameter Tuning in Batik Type Classification using the CNN Model," *SISTEMASI*, vol. 13, no. 1, p. 114, Jan. 2024, doi: 10.32520/stmsi.v13i1.3395.
- [14] B. J. Filia et al., "Improving Batik Pattern Classification using CNN with Advanced Augmentation and Oversampling on Imbalanced Dataset," *Procedia Comput. Sci.*, vol. 227, pp. 508–517, 2023, doi: 10.1016/j.procs.2023.10.552.
- [15] I. Fathurrahman, M. Djamaluddin, Z. Amri, and M. N. Wathani, "Klasifikasi Motif Batik Nusantara Menggunakan Vision Transformer (ViT) Berbasis Deep Learning," *Infotek J. Inform. Dan Teknol.*, vol. 8, no. 2, pp. 511–522, July 2025, doi: 10.29408/jit.v8i2.31108.
- [16] H. K. Kondaveeti and C. G. Simhadri, "Evaluation of deep learning models using explainable AI with qualitative and quantitative analysis for rice leaf disease detection," *Sci. Rep.*, vol. 15, no. 1, p. 31850, Aug. 2025, doi: 10.1038/s41598-025-14306-3.
- [17] N. D. Girsang, "Literature Study of Convolutional Neural Network Algorithm for Batik Classification," *Brill. Res. Artif. Intell.*, vol. 1, no. 1, pp. 1–7, Sept. 2021, doi: 10.47709/brilliance.v1i1.1069.
- [18] L. Elvitaria, E. F. Ahmad, N. A. Samsudin, S. K. Ahmad Khalid, - Salamun, and Z. Indra, "An Improved Okta-Net Convolutional Neural Network Framework for Automatic Batik Image Classification," *JOIV Int. J. Inform. Vis.*, vol. 9, no. 1, p. 115, Jan. 2025, doi: 10.62527/joiv.9.1.2591.
- [19] M. A. Rasyidi, R. Handayani, and F. Aziz, "Identification of batik making method from images using convolutional neural network with limited amount of data," *Bull. Electr. Eng. Inform.*, vol. 10, no. 3, pp. 1300–1307, June 2021, doi: 10.11591/eei.v10i3.3035.