

# Klasifikasi Motif Batik Indonesia menggunakan CNN VGG16 dengan *Transfer Learning* dan *Fine-Tuning*

## *Classification of Indonesian Batik Motifs using CNN VGG16 with Transfer Learning and Fine-Tuning*

<sup>1</sup>Faby Melia Shanni\*, <sup>2</sup>Pratomo Setiaji, <sup>3</sup>Wiwit Agus Triyanto

<sup>1,2,3</sup>Program Studi Sistem Informasi, Fakultas Teknik, Universitas Muria Kudus

<sup>1,2,3</sup>Jl. Lingkar Utara UMK, Gondangmanis, Bae, Kudus, Kodepos 59327, Jawa Tengah – Indonesia

\*e-mail: [fabymelia461@gmail.com](mailto:fabymelia461@gmail.com)

(received: 22 May 2026, revised: 4 June 2026, accepted: 5 June 2026)

### Abstrak

Batik merupakan warisan budaya Indonesia yang diwariskan secara turun-temurun dan telah diakui UNESCO, namun identifikasi motifnya masih bergantung pada penilaian ahli secara manual. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis motif batik menggunakan metode *Convolutional Neural Network* (CNN) dengan model VGG16 melalui pendekatan *transfer learning*. Dataset diperoleh dari repositori Indonesia Batik Motifs di Kaggle dan terdiri dari tiga kelas, yaitu Batik Bali, Batik Kawung, dan Batik Megamendung. Untuk mengatasi ketidakseimbangan data, dilakukan augmentasi hingga mencapai 1.500 citra dengan komposisi seimbang 500 citra per kelas, kemudian data dibagi dengan rasio 80:10:10. Tahap preprocessing mencakup konversi *grayscale* untuk mengurangi kompleksitas komputasi. Model dengan *fine-tuning* pada delapan layer terakhir VGG16 menghasilkan akurasi pengujian sebesar 98,00% dengan *F1-score* sebesar 0,98. Batik Megamendung memperoleh *F1-score* tertinggi (0,99), diikuti Batik Kawung (0,98) dan Batik Bali (0,97). Hasil perbandingan terhadap *MobileNetV2 transfer learning* 97,33% dan VGG16 *from scratch* 33,33% menunjukkan bahwa VGG16 *transfer learning* menghasilkan akurasi tertinggi di antara ketiga model yang diuji. Penelitian ini berkontribusi dalam pengembangan sistem klasifikasi motif batik yang akurat dan dapat diterapkan secara *real-time* melalui aplikasi web berbasis Streamlit.

**Kata kunci:** motif batik, *convolutional neural network*, *transfer learning*, klasifikasi citra, VGG16

### Abstract

*Indonesian batik is a cultural heritage passed down through generations and officially recognized by UNESCO. However, the identification of batik motifs still relies heavily on manual assessment by experts. This study aims to develop an automated batik motif classification system using a Convolutional Neural Network (CNN) based on the VGG16 architecture with a transfer learning approach. The dataset was obtained from the Indonesia Batik Motifs repository on Kaggle and consists of three batik motif classes: Batik Bali, Batik Kawung, and Batik Megamendung. To address class imbalance, data augmentation was applied to produce a balanced dataset of 1,500 images, with 500 images per class. The dataset was then divided into training, validation, and testing sets using an 80:10:10 ratio. The preprocessing stage included grayscale image conversion to reduce computational complexity. The proposed model, fine-tuned on the last eight layers of VGG16, achieved a test accuracy of 98.00% with an F1-score of 0.98. Among the three classes, Batik Megamendung achieved the highest F1-score (0.99), followed by Batik Kawung (0.98) and Batik Bali (0.97). Comparative experiments showed that the proposed VGG16 transfer learning model outperformed both MobileNetV2 with transfer learning (97.33% accuracy) and VGG16 trained from scratch (33.33% accuracy). This study contributes to the development of an accurate batik motif classification system that can be deployed in real time through a Streamlit-based web application.*

**Keywords:** batik motifs, convolutional neural networks, transfer learning, image classification, VGG16

## 1 Pendahuluan

Indonesia memiliki kekayaan warisan budaya visual yang diakui dunia internasional, salah satunya adalah batik yang sejak 2009 resmi tercatat dalam daftar warisan budaya tak benda oleh UNESCO. Namun pelestarian dan identifikasi motifnya masih menghadapi tantangan besar di era digital [1]. Setiap motif batik menyimpan nilai filosofis dan historis yang mendalam. Batik Megamendung dari Cirebon menggambarkan kebebasan melalui pola awan berlapis bergradasi. Batik Kawung dari Jawa Tengah merepresentasikan kesucian melalui pola geometris kolang-kaling yang simetris. Sementara, Batik Bali menampilkan dinamika budaya Hindu-Bali melalui komposisi visual yang kaya dan padat [1]. Keberagaman karakteristik visual ini menjadi kekayaan sekaligus tantangan tersendiri dalam upaya identifikasi dan klasifikasi motif batik secara sistematis.

Identifikasi motif batik secara konvensional sangat bergantung pada keahlian pakar perseorangan yang jumlahnya semakin terbatas, sehingga sering kali terjadi subjektivitas dan inkonsistensi dalam menentukan jenis motif tertentu [15]. Metode manual ini memiliki kelemahan mendasar, di antaranya tingkat subjektivitas yang tinggi, potensi *human error* akibat kelelahan pengamat saat menganalisis detail pola yang rumit, serta ketidakmampuan untuk menangani volume data citra batik yang masif dalam sistem pengarsipan digital modern. Permasalahan semakin kompleks ketika masyarakat awam sulit membedakan motif yang memiliki karakteristik visual serupa, seperti elemen geometris berulang pada Batik Kawung yang memiliki kemiripan dengan ornamen tertentu pada Batik Bali, sementara kebutuhan katalogisasi digital batik dalam jumlah besar terus meningkat seiring berkembangnya platform *e-commerce* dan museum digital [15].

Teknologi *Computer Vision* melalui pendekatan *Deep Learning* menawarkan solusi otomatisasi klasifikasi citra yang dapat memberikan hasil objektif, konsisten, dan cepat dibandingkan metode manual [2]. Dalam konteks klasifikasi motif batik, CNN menawarkan keunggulan signifikan karena arsitekturnya mampu menangkap representasi fitur secara berlapis, dari detail tekstur dan garis pada lapisan konvolusi awal hingga pola motif yang lebih abstrak dan kompleks pada lapisan yang lebih dalam [3]. Berbagai penelitian terdahulu telah membuktikan efektivitas CNN dalam klasifikasi batik; Ardyani & Sari mencapai akurasi 98,72% menggunakan VGG16 pada batik Demak [4].

Meskipun demikian, terdapat celah penelitian pada aspek efisiensi ekstraksi fitur terhadap dataset berukuran terbatas namun memiliki kompleksitas tekstur yang tinggi. Dataset publik *Indonesian Batik Motifs* di Kaggle hanya menyediakan puluhan citra per kelas, jauh di bawah kebutuhan ideal pelatihan model *Deep Learning* [5]. Kondisi ini berisiko menyebabkan *overfitting*, model menghafal detail data latih namun gagal melakukan generalisasi pada data baru. Untuk mengatasi permasalahan ini, dua strategi diterapkan secara bersamaan: augmentasi data offline menggunakan teknik rotasi, *flip*, zoom, *brightness adjustment*, dan translasi guna meningkatkan variasi visual data latih, serta pendekatan *transfer learning* untuk memanfaatkan pengetahuan yang telah dipelajari model dari dataset besar *ImageNet* [6].

VGG16 dipilih sebagai arsitektur utama karena susunan 16 lapisannya yang dalam terbukti efektif dalam menangkap representasi fitur visual dari tingkat rendah hingga tingkat tinggi secara konsisten melalui penggunaan filter konvolusi  $3 \times 3$  [4]. Strategi *fine-tuning* diterapkan untuk mengoptimalkan pemanfaatan bobot pralatih VGG16 pada proses klasifikasi motif batik. Selain itu, prapemrosesan berupa konversi *grayscale* digunakan untuk mereduksi kompleksitas komputasi sekaligus mempertahankan karakteristik struktural motif sebagai fitur pembeda utama antar kelas [2].

Berdasarkan permasalahan dan celah penelitian yang telah diuraikan, penelitian ini berfokus pada pengembangan sistem klasifikasi citra digital untuk membedakan motif Batik Bali, Batik Kawung, dan Batik Megamendung menggunakan CNN dengan pendekatan *transfer learning* berbasis arsitektur VGG16. Penelitian ini mengkaji kontribusi *transfer learning* terhadap kemampuan model dalam mengenali karakteristik visual ketiga motif batik pada dataset *Indonesian Batik Motifs* serta mengevaluasi performa model berdasarkan hasil pengujian menggunakan metrik akurasi, precision, recall, F1-score, dan *confusion matrix*.

Penelitian ini bertujuan menghasilkan model klasifikasi motif batik yang akurat dan efisien melalui pemanfaatan *transfer learning* VGG16. Kebaruan penelitian ini terletak pada integrasi prapemrosesan *grayscale* dengan strategi *fine-tuning* parsial, perbandingan eksperimental antara model *transfer learning* dan model *from scratch*, serta implementasi sistem dalam aplikasi web berbasis Streamlit yang dilengkapi mekanisme validasi berlapis menggunakan MobileNetV2 dan

ambang batas *confidence* untuk meningkatkan keandalan prediksi [7]. Melalui pendekatan tersebut, penelitian ini diharapkan dapat mendukung digitalisasi, dokumentasi, serta pelestarian warisan budaya Indonesia secara berkelanjutan.

## 2 Tinjauan Literatur

Penelitian tentang klasifikasi motif batik berbasis pembelajaran mesin telah mengalami perkembangan signifikan dalam lima tahun terakhir, seiring meningkatnya kebutuhan terhadap sistem identifikasi otomatis yang akurat dan objektif. Pendekatan berbasis CNN terbukti lebih unggul dibandingkan metode ekstraksi fitur manual seperti GLCM maupun *K-Nearest Neighbor* yang sebelumnya dominan digunakan. Alya *et al.* [8] membuktikan efektivitas pendekatan *transfer learning* dalam membedakan lima motif batik Indonesia dengan memanfaatkan bobot pralatih *ImageNet*. Penelitian serupa oleh Ardyani & Sari [4] mengembangkan sistem klasifikasi Batik Demak berbasis VGG16 yang diakses melalui antarmuka web dan berhasil mencapai akurasi 98,72%, mengonfirmasi bahwa arsitektur VGG16 dengan bobot pralatih *ImageNet* memiliki kapasitas yang sangat baik dalam mengekstraksi fitur tekstur kain batik meskipun domain sumber (*ImageNet*) dan domain target (batik) secara visual berbeda jauh.

Kemampuan VGG16 dalam klasifikasi citra budaya tidak terbatas pada satu jenis batik. Aditama *et al.* [7] mengklasifikasikan empat motif Batik Solo menggunakan VGG16 dengan pendekatan *transfer learning* dan mencapai akurasi 85,71%, sementara [6] melaporkan akurasi 97,43% pada klasifikasi Batik Jambi menggunakan CNN dengan dataset yang lebih besar. Perbedaan hasil antara kedua studi tersebut menunjukkan bahwa ukuran dataset dan strategi augmentasi memiliki pengaruh yang sangat besar terhadap performa akhir model. Hal ini diperkuat oleh temuan [5] yang secara khusus meneliti pengaruh augmentasi data pada klasifikasi Batik Semarang menggunakan MobileNetV2 dan membuktikan bahwa kombinasi teknik rotasi, *flip*, *zoom*, dan penyesuaian kecerahan mampu mengatasi ketidakseimbangan kelas sekaligus meningkatkan kemampuan generalisasi model secara substansial. Zeng [10] dalam survei komprehensif tentang teknik augmentasi citra berbasis *deep learning* menegaskan bahwa model yang dilatih pada dataset kecil tanpa augmentasi cenderung mengalami *overfitting*, dan berbagai teknik transformasi geometris terbukti efektif dalam meningkatkan performa klasifikasi pada domain *data-limited*.

Selain strategi augmentasi, pilihan tahap prapemrosesan juga memengaruhi karakteristik fitur yang dipelajari model. Sastypratiwi & Muhandi [2] meneliti pengenalan dan klasifikasi batik menggunakan MobileNet dengan pendekatan *transfer learning* dan menyimpulkan bahwa penghilangan informasi warna melalui konversi *grayscale* tidak berdampak negatif terhadap akurasi karena fitur geometris dan tekstural motif tetap utuh dalam representasi satu kanal. Temuan ini sejalan dengan penelitian [1] yang mengklasifikasikan motif batik Indonesia menggunakan CNN dan menemukan bahwa representasi tekstur motif yang distingtif, alih-alih informasi warna, merupakan fitur paling dominan dalam pembeda antar kelas. Pendekatan *grayscale* juga diadopsi dalam penelitian identifikasi sub-motif Batik Kawung yang menggunakan konversi *grayscale* dikombinasikan dengan deteksi tepi Canny untuk memperkuat fitur geometris motif sebelum masuk ke lapisan konvolusi [17].

Di sisi lain, sejumlah penelitian mengeksplorasi arsitektur alternatif sebagai pembanding terhadap VGG16. Sinaga *et al.* [12] menggunakan *multi-layer CNN* untuk klasifikasi batik dan memperoleh hasil yang kompetitif, sementara [13] membandingkan empat arsitektur AlexNet, EfficientNet, LeNet, dan MobileNet pada klasifikasi Batik Lampung dan menemukan bahwa LeNet mencapai akurasi tertinggi (99,33%) untuk dataset kecil karena kesederhanaannya yang justru menguntungkan pada kondisi data terbatas. Meranggi *et al.* [11] mengembangkan metode klasifikasi batik menggunakan CNN dengan teknik peningkatan data dan membuktikan bahwa keseimbangan distribusi kelas yang dihasilkan melalui augmentasi berkontribusi langsung terhadap stabilitas nilai *F1-score* antar kelas. Perbandingan lintas arsitektur ini secara konsisten menunjukkan bahwa tidak ada satu arsitektur yang unggul dalam semua kondisi; pemilihan arsitektur harus mempertimbangkan ukuran dataset, kedalaman fitur yang dibutuhkan, dan sumber daya komputasi yang tersedia [9].

Meskipun penelitian-penelitian tersebut telah memberikan kontribusi penting, terdapat beberapa celah yang belum dieksplorasi secara memadai. Pertama, mayoritas studi terdahulu hanya melaporkan akurasi akhir tanpa menyertakan perbandingan eksperimental terhadap model yang dilatih dari awal

(*from scratch*), sehingga kontribusi spesifik bobot pralatih *ImageNet* terhadap performa tidak dapat dikuantifikasi secara langsung. Kedua, strategi *fine-tuning* parsial yaitu membekukan lapisan-lapisan awal dan hanya melatih ulang sebagian lapisan konvolusi terakhir belum banyak dieksplorasi pada domain batik, padahal pendekatan ini berpotensi memberikan keseimbangan optimal antara retensi pengetahuan fitur umum dan adaptasi terhadap karakteristik tekstur batik yang spesifik. Ketiga, implementasi sistem klasifikasi yang dilengkapi mekanisme validasi berlapis untuk menolak citra di luar cakupan kelas yang didukung sistem (*out-of-distribution rejection*) belum pernah dilaporkan dalam literatur klasifikasi batik yang ada. Penelitian ini secara langsung menjawab ketiga celah tersebut melalui: (1) perbandingan sistematis antara model VGG16 *transfer learning* dengan *fine-tuning* parsial pada delapan lapisan terakhir dan model VGG16 *from scratch* pada dataset yang identik; (2) penerapan prapemrosesan *grayscale* yang dikombinasikan dengan strategi *fine-tuning* Block 4 dan Block 5 untuk optimasi ekstraksi fitur struktural motif; serta (3) implementasi sistem klasifikasi berbasis Streamlit yang dilengkapi validasi berlapis menggunakan MobileNetV2 dan ambang batas *confidence* 95% untuk memastikan keandalan prediksi pada kondisi nyata.

### 3 Metode Penelitian

Metode dalam penelitian ini disusun untuk memberikan kerangka kerja yang sistematis. Fokus utama dari metodologi ini adalah integrasi antara pengolahan citra digital tradisional dengan teknik *Deep Learning* modern untuk menghasilkan model yang mampu mengenali karakteristik unik dari budaya Indonesia secara objektif. Rincian tahapan metodologi penelitian dijelaskan sebagai berikut.

#### 1. Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang berorientasi pada pengukuran data numerik hasil pengujian sistem. Pendekatan ini menekankan pada analisis objektif untuk menguji hubungan antar variabel, di mana metrik seperti akurasi, *precision*, *recall*, dan F1-score dihasilkan dari pengujian model VGG16 terhadap dataset *Indonesian Batik Motifs*. Metode eksperimen diterapkan melalui pemberian perlakuan berupa prapemrosesan, augmentasi data, dan penerapan *transfer learning* untuk menangkap tekstur batik secara optimal.

#### 2. Objek, Sumber, dan Teknik Pengumpulan Data

Objek penelitian berfokus pada tiga motif batik Indonesia yaitu Batik Bali, Batik Megamendung, dan Batik Kawung yang memiliki karakteristik visual kontras. Data diperoleh dari repositori publik *Indonesian Batik Motifs* di platform Kaggle dalam format JPG/PNG. Teknik pengumpulan data menggunakan dokumentasi melalui seleksi sistematis berdasarkan label motif dan kualitas visual citra untuk memastikan kelayakan dalam proses pelatihan.

#### 3. Teknik Prapemrosesan dan Augmentasi Data

Tahap prapemrosesan dilakukan untuk menstandarisasi seluruh citra input sesuai spesifikasi arsitektur VGG16. Setiap citra diubah ukurannya menjadi 224 x 224 piksel agar sesuai dengan spesifikasi input VGG16, kemudian nilai intensitas piksel dinormalisasi ke interval [0,1] dengan cara membagi setiap nilai piksel 255. Selain itu, seluruh citra dikonversi ke format *grayscale* untuk mereduksi kompleksitas komputasi sekaligus mempertahankan fitur struktural motif berupa tekstur dan geometri pola.

Pemilihan representasi *grayscale* didasarkan pada karakteristik motif batik yang kekhasannya terletak pada pola struktural berupa tekstur, geometri, dan komposisi garis, bukan pada informasi warna. Pendekatan *preprocessing* berbasis *grayscale* pada klasifikasi batik telah diterapkan pada penelitian sebelumnya [14], [17] yang menunjukkan bahwa fitur struktural cukup untuk membedakan antar kelas motif. Selain itu, penggunaan *grayscale* mereduksi kompleksitas komputasi sebesar 66,7% pada tahap input (dari 3 kanal menjadi 1 kanal) tanpa kehilangan informasi tekstural yang relevan.


Meskipun dataset bersifat *grayscale*, model VGG16 yang memerlukan input tiga kanal tetap dapat memproses citra karena Keras secara otomatis mereplikasi kanal tunggal menjadi tiga kanal identik pada saat pemuatan data. Contoh citra asli dari masing-masing kelas motif batik yang digunakan dalam penelitian ini ditampilkan pada Gambar 1. Ketiga kelas memperlihatkan karakteristik visual yang berbeda secara signifikan: Batik Bali menampilkan elemen figuratif yang padat, Batik Kawung berpola geometris elips simetris, dan Batik Megamendung berpola awan

berlapis.



**Gambar 1** Contoh citra asli dataset per kelas


Dataset awal berjumlah 141 citra dengan distribusi tidak seimbang (Batik Bali 50, Batik Kawung 45, Batik Megamendung 46 citra). Untuk memperkaya variasi data latih, diterapkan serangkaian teknik augmentasi mencakup rotasi 90°, pembalikan horizontal, perbesaran, serta modifikasi kecerahan, kontras, dan pergeseran posisi gambar yang ditunjukkan pada Gambar 2, tanpa mengubah label kelas.



**Gambar 2** Hasil teknik augmentasi data pada setiap kelas motif batik

#### 4. Pembagian Dataset dan Alur Kerja

Dataset dibagi secara proporsional seperti ditunjukkan pada Gambar 3, dengan rasio 80% data latih (1.200 citra), 10% data validasi (150 citra), dan 10% data uji (150 citra). Pembagian dilakukan secara merata per kelas sehingga setiap kelas menyumbang 400 citra latih, 50 citra validasi, dan 50 citra uji.



**Gambar 3** Pembagian dataset

Penelitian ini menerapkan alur kerja unik yang memisahkan dua lingkungan pengembangan:

<http://sistemasi.ftik.unisi.ac.id>

VSCode digunakan untuk tahap prapemrosesan, augmentasi, dan pembagian dataset di tingkat lokal. Setelah dataset siap, data diunggah ke *cloud* untuk proses pelatihan. Setelah model .h5 dihasilkan, model dikembalikan ke VSCode untuk tahap evaluasi akhir dan *deployment*.

### 5. Perangkat dan Tools Penelitian

Eksperimen menggunakan komputer dengan prosesor dual-core 2,6 GHz dan RAM 8 GB. Mengingat keterbatasan GPU pada perangkat lokal, pelatihan model dilakukan di platform komputasi berbasis cloud dengan akselerasi GPU berkapasitas 16 GB. Perangkat lunak yang digunakan adalah Python dengan pustaka *TensorFlow/Keras* untuk pembangunan model, *OpenCV* untuk prapemrosesan citra, dan *Scikit-learn* untuk perhitungan metrik evaluasi. Model hasil pelatihan disimpan dalam format .h5 yang menyimpan arsitektur dan bobot model secara terpadu.

### 6. Teknik Analisis Data dan Konfigurasi Arsitektur

Penelitian ini menerapkan arsitektur VGG16 melalui pendekatan transfer learning menggunakan bobot pralatih dari *ImageNet* sebagai ekstraktor fitur. Lapisan klasifikasi asli diganti dengan *classifier head* baru, di mana seluruh lapisan dibekukan kecuali 8 lapisan terakhir (Block 5 dan sebagian Block 4) untuk *fine-tuning*. Lapisan klasifikasi yang ditambahkan terdiri atas Flatten (25.088 dimensi), Dense (128, relu) dengan regularisasi L2, Dropout (0,7), Dense (64, relu) dengan regularisasi L2, Dropout (0,6), dan Dense (3, softmax) sebagai keluaran. Model dikompilasi dengan optimizer SGD (learning rate 0,001, momentum 0,9) dan fungsi kerugian *categorical\_crossentropy*. Sebagai pembandingan tambahan, arsitektur MobileNetV2 dengan pendekatan *transfer learning* juga diuji menggunakan konfigurasi dataset dan preprocessing yang identik untuk mengevaluasi efisiensi model yang lebih ringan terhadap dataset batik terbatas. Rincian konfigurasi lapisan disajikan pada Tabel 1.

Tabel 1 Konfigurasi arsitektur model VGG16

Layer (type)	Output Shape	Param #
Block 1 — 2× Conv2D + MaxPooling	(None, 112, 112, 64)	36,928
Block 2 — 2× Conv2D + MaxPooling	(None, 56, 56, 128)	147,584
Block 3 — 3× Conv2D + MaxPooling	(None, 28, 28, 256)	590,080
Block 4 — 3× Conv2D + MaxPooling	(None, 14, 14, 512)	2,359,808
Block 5 — 3× Conv2D + MaxPooling	(None, 7, 7, 512)	2,359,808
flatten_9 (Flatten)	(None, 25088)	0
dense_23 (Dense)	(None, 128)	3,211,392
dropout_14 (Dropout)	(None, 128)	0
dense_24 (Dense)	(None, 64)	8,256
dropout_15 (Dropout)	(None, 64)	0
dense_25 (Dense)	(None, 3)	195
Total params: 17,934,531 (68.41 MB)		
Trainable params: 16,199,043 (61.79 MB)		
Non-trainable params: 1,735,488 (6.62 MB)		

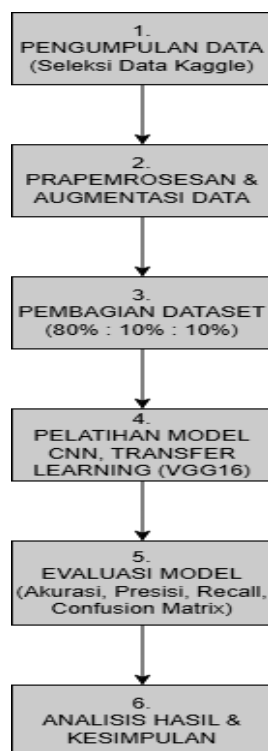
### 7. Detail Parameter Pelatihan

Pelatihan model dikonfigurasi dengan jumlah 100 *epoch* dan ukuran *batch* (*batch\_size*) sebesar 16. Model dikompilasi menggunakan optimizer SGD dengan *learning rate* 0,001 dan *momentum* 0,9 untuk menjaga stabilitas konvergensi pada proses *fine-tuning*. Optimizer SGD dengan *momentum* 0,9 dipilih karena lebih stabil pada proses *fine-tuning* dibandingkan Adam, di mana *learning rate* yang kecil dan *momentum* membantu mencegah perubahan bobot yang terlalu drastis pada lapisan konvolusi yang sudah pralatih, sehingga pengetahuan fitur dari *ImageNet* dapat dipertahankan sekaligus diadaptasi ke domain batik. Sebagai pembandingan, model *from scratch* dilatih dengan konfigurasi yang sama namun menggunakan optimizer Adam dan mekanisme

*EarlyStopping* (*patience=5*, *monitor='val\_loss'*) untuk menghentikan pelatihan secara otomatis apabila tidak terdapat perbaikan pada *validation loss* selama 5 iterasi berturut-turut.

### 8. Detail Pelaksanaan Program

Tahapan program dimulai dari pengumpulan data, prapemrosesan dan augmentasi di VSCode, pelatihan di Google Colab, hingga evaluasi akhir di VSCode kembali. Alur sistematis ini direpresentasikan dalam diagram alur pada Gambar 4.



Gambar 4 Diagram alur pelaksanaan program

### 9. Teknik Evaluasi Penelitian

Evaluasi kinerja sistem menggunakan data uji independen melalui metrik akurasi, presisi, *recall*, dan *F1-score*. Validasi silang (*cross-validation*) tidak diterapkan dalam penelitian ini mengingat dataset telah dibagi secara *stratified* dengan rasio 80:10:10 yang memastikan representasi proporsional setiap kelas pada masing-masing subset. Pendekatan *fixed split* ini konsisten dengan praktik umum pada penelitian klasifikasi citra batik berbasis *deep learning* dengan skala dataset serupa [4]. Akurasi mengukur ketepatan keseluruhan, sementara *F1-score* memberikan keseimbangan rata-rata harmonik antara presisi dan *recall*. Penggunaan *confusion matrix* juga diterapkan untuk menganalisis pola kesalahan klasifikasi antar kelas motif guna memastikan keandalan model secara detail. Metrik evaluasi yang digunakan dalam penelitian ini meliputi akurasi, presisi, *recall*, dan *F1-score* yang diformulasikan sebagai berikut:

$$\text{Akurasi} = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$\text{Presisi} = TP / (TP + FP) \quad (2)$$

$$\text{Recall} = TP / (TP + FN) \quad (3)$$

$$\text{F1-Score} = 2 \times (\text{Presisi} \times \text{Recall}) / (\text{Presisi} + \text{Recall}) \quad (4)$$

Keterangan:

TP = *True Positive* (data positif yang diprediksi benar)

TN = *True Negative* (data negatif yang diprediksi benar)

FP = *False Positive* (data negatif yang diprediksi positif)

FN = *False Negative* (data positif yang diprediksi negatif)


## 4 Hasil dan Pembahasan

Bagian ini memaparkan hasil dari serangkaian pengujian yang telah dilakukan terhadap model

klasifikasi motif batik yang dikembangkan. Fokus utama pembahasan mencakup analisis performa model selama proses pelatihan, evaluasi metrik akurasi, hingga validasi hasil melalui antarmuka aplikasi. Seluruh data yang disajikan merupakan hasil nyata dari implementasi arsitektur VGG16 dengan pendekatan *transfer learning* yang dibandingkan dengan model pelatihan dari awal (*from scratch*).


#### 4.1 Grafik Training (Accuracy dan Loss Curve)

Gambar 5 menunjukkan tren peningkatan akurasi model selama 100 *epoch*. Dapat dilihat bahwa kurva *train accuracy* dan *validation accuracy* meningkat secara signifikan pada 5 *epoch* pertama, di mana *validation accuracy* bahkan melampaui *train accuracy* pada fase awal pelatihan karena pengaruh *fine-tuning* Block 5. *Validation accuracy* tertinggi sebesar 98,67% dicapai pada *epoch* ke-11, kemudian stabil di kisaran 97,33% hingga *epoch* ke-100. Terjadi penurunan sementara (*dip*) pada sekitar *epoch* ke-35 yang kemudian pulih dan kembali stabil. Tidak adanya *gap* yang lebar antara kurva pelatihan dan validasi mengonfirmasi bahwa model terbebas dari masalah *overfitting*.



**Gambar 5** Grafik akurasi pelatihan dan validasi

Grafik *loss* pada Gambar 6 menampilkan penurunan nilai kesalahan model selama proses pembelajaran. Nilai *loss* pada data latih dan data validasi sama-sama dimulai dari nilai tinggi (sekitar 4,5) dan menurun secara konsisten hingga mendekati 0,22 pada *epoch* ke-100. Kedua kurva yang berhimpitan menunjukkan bahwa proses optimasi menggunakan *optimizer* SGD berjalan efektif. Terjadi lonjakan kecil (*spike*) pada sekitar *epoch* ke-35 yang konsisten dengan penurunan akurasi sementara, namun model berhasil pulih dan melanjutkan konvergensi hingga mencapai titik optimal. Akurasi akhir pada data uji yang dicapai sebesar 98,00% dengan *loss* 0,2480.



Gambar 6 Grafik loss pelatihan dan validasi

#### 4.2 Perbandingan Transfer Learning dan From Scratch

Uji coba perbandingan menunjukkan perbedaan kinerja yang sangat signifikan. Perbedaan kinerja antara kedua model sangat mencolok, di mana VGG16 dengan *transfer learning* mencatatkan akurasi 98,00% dan *loss* 0,2480, diikuti MobileNetV2 dengan *transfer learning* yang mencatatkan akurasi 97,33% dan *loss* 0,0272, sementara model yang dilatih dari awal hanya mampu mencapai akurasi 33,33% dengan *loss* 1,0986 setara prediksi acak pada tiga kelas. Perbandingan ini disajikan pada Tabel 2.

Tabel 2 Perbandingan kinerja model

Model	Akurasi (%)	Loss
VGG16 Transfer Learning	98,00	0,2480
MobileNetV2 Transfer Learning	97,33	0,0272
VGG16 From Scratch	33,33	1,0986

Akurasi model *from scratch* yang tidak bergerak di 33,33% hingga dihentikan *EarlyStopping* menunjukkan bahwa 1.200 citra latih tidak memadai untuk melatih arsitektur dengan lebih dari 17 juta parameter. MobileNetV2 dengan *transfer learning* mencatatkan akurasi yang kompetitif (97,33%) dengan *loss* yang jauh lebih rendah (0,0272) mengindikasikan kalibrasi probabilitas yang lebih baik meskipun akurasi akhirnya sedikit di bawah VGG16. Hal ini menunjukkan bahwa arsitektur yang lebih ringan pun mampu bekerja efektif pada dataset batik terbatas berkat bobot pralatih *ImageNet*. Sebaliknya, bobot pralatih *ImageNet* telah menyediakan representasi fitur visual yang kuat, sehingga model *transfer learning* mampu beradaptasi dengan dataset terbatas secara efektif.

Hasil yang diperoleh juga kompetitif dibandingkan penelitian sejenis pada domain batik. Ardyani & Sari [4] akurasi mencapai 98,72% menggunakan VGG16 *fine-tuning* pada 15 kelas Batik Demak dengan 938 citra. Sastypratiwi & Muhandi [2] mencapai akurasi 98,00% dengan MobileNet *transfer learning* pada 4 kelas Batik Pontianak dari 1.520 citra. Khoirunnisa et al. [5] memperoleh akurasi 100% menggunakan MobileNetV2 dengan augmentasi pada 10 kelas Batik Semarang dari 3,020 citra. Andrian et al. [13] membandingkan empat arsitektur CNN pada 10 kelas Batik Lampung dari 1.000 citra dan mencapai akurasi terbaik 99,33% menggunakan LeNet. Perbandingan dengan penelitian sejenis disajikan pada Tabel 3.

Tabel 3 Perbandingan dengan penelitian sejenis

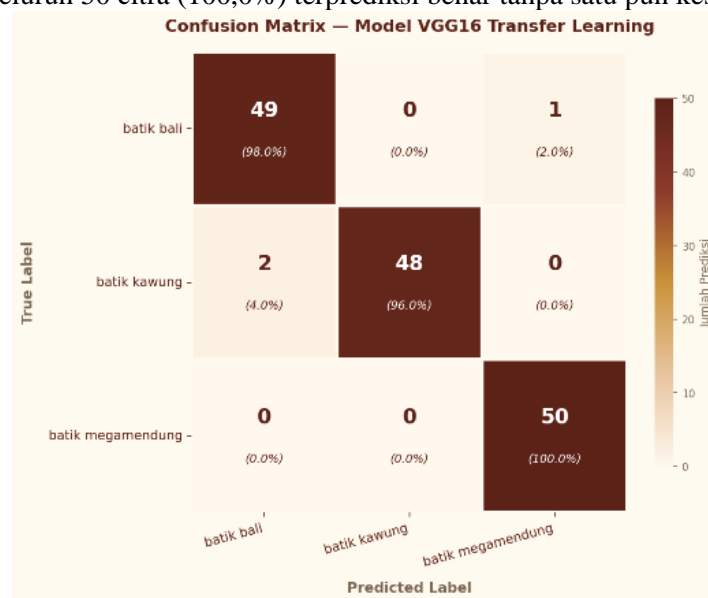
Penelitian	Arsitektur	Objek Batik	Dataset	Akurasi
Ardyani & Sari [4]	VGG16 <i>fine-tuning</i>	Batik Demak	938 citra, 15 kelas	98,72%

Sastypratiwi & Muhardi [2]	MobileNet + <i>transfer learning</i>	Batik Pontianak	1.520 citra, 4 kelas	98,00%
Khoirunnisa et al. [5]	MobileNetV2 + augmentasi	Batik Semarang	3.020 citra, 10 kelas	100,00%
Andrian et al. [13]	LeNet	Batik Lampung	1.000 citra, 10 kelas	99,33%
Penelitian ini	VGG16 <i>transfer learning</i>	Batik Bali, Kawung, Megamendung	1.500 citra, 3 kelas	98,00%

Penelitian ini mencapai akurasi 98,00% setara dengan hasil terbaik pada penelitian-penelitian sebelumnya, menunjukkan bahwa strategi kombinasi augmentasi data, *preprocessing grayscale* dan *fine-tuning* VGG16 efektif untuk klasifikasi motif batik meskipun dengan dataset yang sangat terbatas.

### 4.3 Analisis Confusion Matrix

Berdasarkan *confusion matrix* pada Gambar 7, model berhasil mengklasifikasikan 49 dari 50 citra Batik Bali secara tepat (98,0%), dengan 1 citra (2,0%) mengalami misklasifikasi ke kelas Batik Megamendung. Pada kelas Batik Kawung, sebanyak 48 citra (96,0%) terprediksi benar, sementara 2 citra (4,0%) diklasifikasikan sebagai Batik Bali. Kelas Batik Megamendung mencapai klasifikasi sempurna dengan seluruh 50 citra (100,0%) terprediksi benar tanpa satu pun kesalahan.



Gambar 7 Confusion matrix

Pola kesalahan yang terjadi dapat dianalisis dari dua sisi. Pertama, kesalahan antara Batik Kawung dan Batik Bali disebabkan oleh kemiripan karakteristik struktural kedua motif dalam representasi *grayscale*, keduanya memiliki elemen geometris berulang yang simetris sehingga sulit dibedakan ketika informasi warna dihilangkan. Kedua, kesalahan tunggal pada Batik Bali yang terprediksi sebagai Batik Megamendung kemungkinan disebabkan oleh citra augmentasi yang secara visual memiliki tekstur melengkung menyerupai pola awan Megamendung. Sebaliknya, Batik Megamendung tidak mengalami kesalahan klasifikasi sama sekali karena pola awan berlapis bergradasi yang dimilikinya merupakan fitur visual paling unik dan distingtif di antara ketiga kelas, sehingga model dapat mengenalinya dengan keyakinan penuh meski dalam format *grayscale*.

### 4.4 Analisis Per Kelas: Presisi, Recall, dan F1-Score

Hasil evaluasi per kelas ditunjukkan dalam Tabel 4. Performa tertinggi dicapai oleh Batik Megamendung dengan F1-score 0,99 dengan recall sempurna 1,00. Batik Megamendung konsisten dengan karakteristik visualnya yang paling spesifik berupa pola awan berlapis. Batik Kawung

mendapatkan skor tertinggi dalam presisi dengan nilai 1,00 dan skor *recall* sebesar 0,96 menunjukkan bahwa 2 gambar Batik Kawung diklasifikasikan secara salah sebagai Batik Bali.

Batik Bali mencapai presisi sebesar 0,96 dengan *recall* 0,98 menunjukkan bahwa model memiliki tingkat kepercayaan yang tinggi dalam mengklasifikasikan gambar yang termasuk dalam kelas ini dan performa yang baik. Rata-rata makro dari presisi, *recall*, dan *F1-score* sebesar 0,98, menunjukkan performa yang baik dan seimbang dari model dari ketiga kelas tanpa kecenderungan terhadap kelas manapun. Hal ini merupakan hasil dari keseimbangan distribusi dataset hasil dari augmentasi.

**Tabel 4 Hasil evaluasi per kelas**

Kelas Motif	Precision	Recall	F1-Score	Support
Batik Bali	0,96	0,98	0,97	50
Batik Kawung	1,00	0,96	0,98	50
Batik Megamendung	0,98	1,00	0,99	50
Accuracy			0,98	150
Macro Avg	0,98	0,98	0,98	150
Weighted Avg	0,98	0,98	0,98	150

#### 4.5 Implementasi Sistem

Model yang diperoleh yaitu *vgg16\_batik.h5* diintegrasikan ke dalam aplikasi web interaktif bernama BatikVision melalui *framework* Streamlit. BatikVision dikembangkan dengan tampilan antarmuka berkonsep batik Nusantara serta menampilkan palet warna terakota dan emas agar menimbulkan kesan visual yang selaras dengan identitas budaya objek yang diklasifikasikan.

Klasifikasi dengan BatikVision dilakukan melalui dua tahap validasi berlapis. Tahap pertama adalah validasi menggunakan model *MobileNetV2* berbasis *ImageNet* secara lokal yang bertujuan untuk memastikan bahwa citra yang diunggah merupakan jenis kain atau tekstil. Apabila citra bukan kain batik, sistem akan menolak *input* tersebut dan menampilkan pesan informatif kepada pengguna. Tahap kedua adalah proses klasifikasi motif batik menggunakan model VGG16, apabila nilai *confidence* mencapai ambang batas minimum 95%, sistem akan menampilkan hasil klasifikasi. Sebaliknya, jika nilai *confidence* berada di bawah ambang batas tersebut, sistem akan menampilkan pesan "Motif Tidak Dikenali".



**Gambar 8 Antarmuka pengguna pada aplikasi klasifikasi motif batik**

Antarmuka utama aplikasi ditampilkan pada Gambar 8, yang terdiri atas dua kolom. Kolom kiri untuk unggah citra dan kolom kanan untuk menampilkan hasil prediksi beserta tingkat kepercayaan model, deskripsi budaya, dan distribusi probabilitas ketiga kelas.

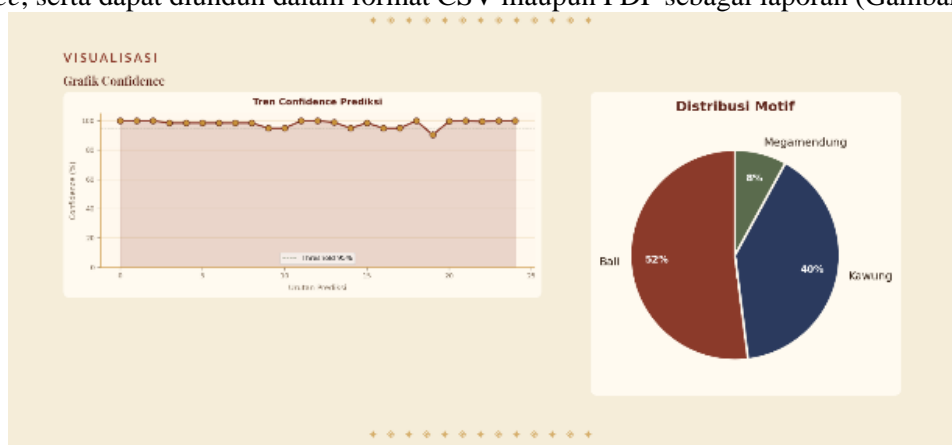
Ringkasan Prediksi			
TOTAL PREDIKSI	RATA-RATA CONFIDENCE	MOTIF TERBAHAYAK	PREDIKSI TINGGI (>95%)
25	98.1%	Bali	19

RIWAYAT ANALISIS		
History Prediksi		
Waktu	Motif Batik	Confidence
2026-05-11 01:44:12	Batik Bali	95.48%
2026-05-11 01:44:36	Batik Kawung	94.94%
2026-05-11 01:45:06	Batik Kawung	94.38%
2026-05-11 01:47:19	Batik Bali	93.99%
2026-05-11 01:48:04	Batik Bali	90.35%
2026-05-11 01:48:14	Batik Kawung	95.70%
2026-05-11 01:48:46	Batik Megamendung	100.00%
2026-05-11 01:47:19	Batik Bali	95.47%
2026-05-11 01:47:59	Batik Kawung	95.51%
2026-05-11 01:48:43	Batik Kawung	100.00%

Gambar 9 Riwayat prediksi dan analisis

Aplikasi dilengkapi dengan fitur riwayat prediksi yang tersimpan otomatis ke dalam file CSV, di mana pengguna dapat melihat tabel lengkap berisi waktu, motif yang terdeteksi, dan nilai *confidence*, serta dapat diunduh dalam format CSV maupun PDF sebagai laporan (Gambar 9).



Gambar 10 Grafik visualisasi

PENGETAHUAN BUDAYA

Ensiklopedia Motif Batik

**Batik Bali**

• Jawa Barat, Sumatera

Batik Bali merupakan motif tradisional Hindu Bali dengan pengaruh budaya lokal yang dinamis. Ciri khasnya adalah penggunaan corak paksi, meru, meru ranti, serta skema tradisional warna khas Bali seperti hitam pekat dan hitam-putih.

**Batik Kawung**

• Jawa Tengah - Lampung, Sumatera

Batik Kawung adalah salah satu motif batik tertua di Jawa, dikenal motifnya geometris. Inspirasi di atas yang berakar dari motif batik lokal lainnya. Motif ini melambungkan semangat kearifan dan penghargaan terhadap budaya warisan lokal dan keberagaman.

**Batik Megamendung**

• Cirebon, Jawa Barat

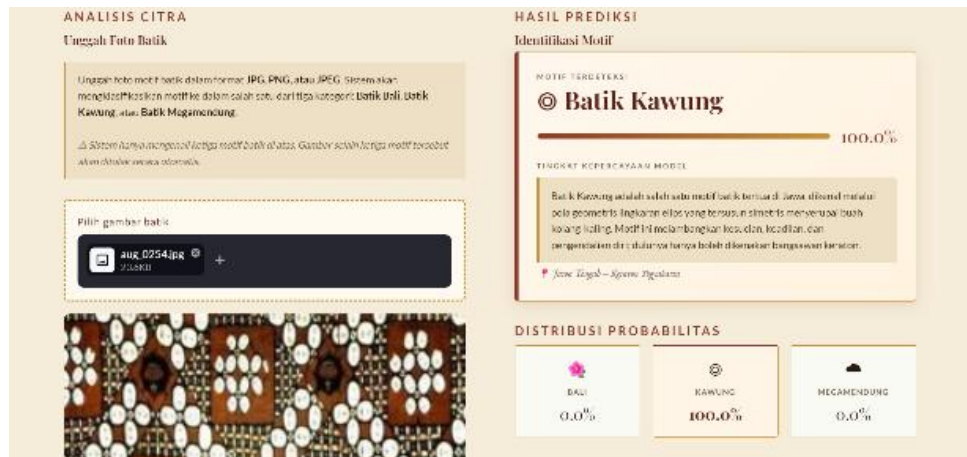
Batik Megamendung adalah jenis batik pesik Cirebon dengan motif awan bergaris warna biru keputih yang mengkilap. Terinspirasi dari Tunggul, motif ini melambungkan semangat, keberagaman, dan kebahagiaan yang seperti awan yang bergelombang.

BatikPedia - Ensiklopedia Motif Batik Indonesia - CNN PG&A Digital Learning  
July 2024, Volume 15(6) 2228-2243 | Universitas Mitra Digital 2026

Gambar 11 Ensiklopedia motif batik pada aplikasi

Visualisasi pada Gambar 10 menampilkan dua grafik yaitu grafik tren *confidence* dari seluruh prediksi yang telah dilakukan dalam satu sesi dan diagram lingkaran (*pie chart*) yang menunjukkan distribusi motif batik yang paling sering terdeteksi.

Fitur ensiklopedia pada Gambar 11 menyajikan informasi historis dan budaya mengenai ketiga motif batik yang didukung sistem, meliputi asal daerah dan deskripsi karakteristik visual masing-masing motif.

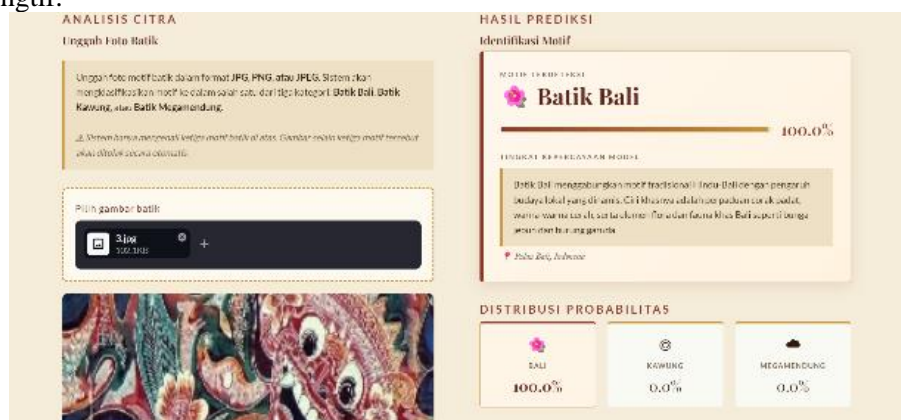


Gambar 12 Hasil klasifikasi batik kawung




Gambar 13 Hasil klasifikasi batik megamendung

Sistem pada Gambar 12 mengidentifikasi Batik Kawung dengan mengenali pola geometris lingkaran elips yang tersusun simetris sebagai fitur visual utama. Gambar 13 menunjukkan hasil klasifikasi Batik Megamendung, di mana sistem mampu mendeteksi motif awan berlapis dengan nilai *confidence* tertinggi di antara ketiga kelas, konsisten dengan karakteristik visualnya yang paling distingtif.



Gambar 14 Hasil klasifikasi batik bali



**Gambar 15** Grafik confidence per kelas

Klasifikasi Batik Bali berhasil dilakukan berdasarkan komposisi corak padat yang mengandung unsur flora dan fauna khas Bali, sebagaimana ditunjukkan pada Gambar 14. Sistem dapat mengklasifikasikan Batik Bali dengan sukses karena model dapat mendeteksi ciri khusus Batik Bali secara signifikan dibandingkan kelas motif lainnya.

Grafik confidence per kelas pada Gambar 15 menunjukkan nilai prediksi secara horizontal pada ketiga kelas motif dengan batang yang panjang merujuk pada kelas yang diprediksi dengan penanda garis putus-putus sebagai minimum *threshold* sebesar 95%. Penerapan ini bertujuan agar sistem hanya mengeluarkan hasil klasifikasi ketika model benar-benar yakin terhadap citra yang dianalisis, sehingga risiko kesalahan prediksi pada citra yang ambigu dapat diminimalkan.

## 5 Kesimpulan

Sistem klasifikasi otomatis yang dibangun dalam penelitian berbasis citra digital menggunakan CNN VGG16 dengan pendekatan *transfer learning* berhasil mencapai tingkat akurasi pengujian 98,00% dan *F1-score* 0,98 pada dataset tiga kelas motif batik Indonesia (Batik Bali, Batik Kawung, dan Batik Megamendung). Hasil ini membuktikan bahwa kombinasi augmentasi data offline, prapemrosesan *grayscale*, dan strategi *fine-tuning* pada lapisan konvolusi terakhir VGG16 merupakan pendekatan yang efektif untuk mengatasi keterbatasan dataset dalam klasifikasi citra budaya. Perbandingan eksperimental terhadap tiga model secara konsisten menunjukkan keunggulan VGG16 *transfer learning* 98,00% dibandingkan MobileNetV2 *transfer learning* 97,33% maupun VGG16 *from scratch* 33,33%, menunjukkan bahwa bobot pralatih *ImageNet* merupakan komponen esensial dalam kondisi data terbatas.

Penelitian ini memberikan kontribusi ilmiah dalam beberapa aspek. Pertama, membuktikan efektivitas strategi kombinasi augmentasi data offline, prapemrosesan *grayscale*, dan *fine-tuning* delapan lapisan terakhir VGG16 dalam mengatasi keterbatasan dataset pada domain batik. Kedua, menyediakan bukti empiris keunggulan *transfer learning* dibandingkan *from scratch* pada kondisi data yang sangat terbatas. Ketiga, mengembangkan sistem aplikasi web *BatikVision* sebagai implementasi praktis yang mendukung digitalisasi warisan budaya Indonesia, sekaligus membuka peluang aplikasi di bidang katalogisasi digital dan edukasi budaya batik.

Keterbatasan penelitian ini yang perlu diakui yaitu cakupan kelas motif batik masih terbatas pada tiga motif sehingga belum mempresentasikan keragaman motif batik Indonesia secara menyeluruh. Selain itu, penggunaan prapemrosesan *grayscale* menyebabkan hilangnya informasi warna yang berpotensi relevan untuk membedakan motif tertentu, serta dataset asli yang sangat terbatas (141 citra) sepenuhnya bergantung pada augmentasi offline yang berpotensi mengurangi keragaman representasi visual dunia nyata. Penelitian selanjutnya disarankan untuk mengeksplorasi penggunaan citra berwarna penuh guna mempertahankan informasi warna motif, penerapan *fine-tuning* yang lebih mendalam pada seluruh lapisan VGG16, perluasan cakupan kelas motif batik dari daerah lain di Indonesia, serta pengujian arsitektur CNN modern seperti EfficientNet atau ResNet untuk perbandingan performa yang lebih komprehensif.

## Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Universitas Muria Kudus yang telah memberikan dukungan fasilitas dan sumber daya dalam penyelesaian penelitian ini. Penulis juga menyampaikan terima kasih kepada pembimbing yang telah memberikan arahan, masukan, dan bimbingan teknis selama proses penelitian berlangsung, serta kepada penyedia dataset batik pada platform Kaggle yang telah menyediakan data citra secara terbuka sehingga penelitian ini dapat terlaksana.

## Referensi

- [1] E. Budimansyah, D. Ariawan, R. D. Maulana, W. R. Yudha, And M. Munsarif, “Klasifikasi Motif Batik Indonesia menggunakan *Convolutional Neural Network (CNN)*,” *Jurnal Komputer Dan Teknologi Informasi*, Vol. 3, No. 2, Aug. 2025, DOI: 10.26714/Jkti.V3i2.18627.
- [2] H. Sastypratiwi And H. Muhardi, “*International Journal on Informatics Visualization Journal Homepage : www.Joiv.Org/Index.Php/Joiv International Journal on Informatics Visualization Batik Recognition and Classification using Transfer Learning and Mobilenet Approach.*” [Online]. Available: [Www.Joiv.Org/Index.Php/Joiv](http://www.Joiv.Org/Index.Php/Joiv)
- [3] M. Vakalopoulou, S. Christodoulidis, N. Burgos, O. Colliot, And V. Lepetit, “*Deep Learning: Basics and Convolutional Neural Networks (CNN)*”, DOI: 10.1007/978-1-0716-3195-9\_3i.
- [4] S. S. F. Ardyani And C. A. Sari, “*A Web-based for Demak Batik Classification using VGG16 Convolutional Neural Network*,” *Advance Sustainable Science, Engineering And Technology*, Vol. 6, No. 4, Pp. 0240406-01-0240406–09, Aug. 2024, DOI: 10.26877/Asset.V6i4.771.
- [5] 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.
- [6] F. Pratama, M. T. A. Bangsa, And A. Yudertha, “*Klasifikasi Motif Batik Jambi menggunakan Convolutional Neural Network*,” *Riggs: Journal of Artificial Intelligence and Digital Business*, Vol. 4, No. 4, Pp. 1515–1532, Nov. 2025, DOI: 10.31004/Riggs.V4i4.3602.
- [7] D. F. Aditama, Rr. H. P. Sejati, And F. I. Sanjaya, “*Klasifikasi Motif Batik Solo menggunakan Convolutional Neural Network dengan Transfer Learning VGG16*,” *Tin: Terapan Informatika Nusantara*, Vol. 6, No. 7, Pp. 1214–1224, Dec. 2025, DOI: 10.47065/Tin.V6i7.8940.
- [8] R. Fadiyah Alya And M. Wibowo, “*Classification of Batik Motif using Transfer Learning on Convolutional Neural Network (CNN)*,” Vol. 4, No. 1, Pp. 161–170, 2023, DOI: 10.20884/1.Jutif.2023.4.1.564.
- [9] A. Akbar, M. Perdana, M. Fajar, And A. Muis Mappalotteng, “*International Journal on Informatics Visualization Journal Homepage : www.Joiv.Org/Index.Php/Joiv International Journal on Informatics Visualization Enhancing Batik Classification Leveraging CNN Models and Transfer Learning.*” [Online]. Available: [Www.Joiv.Org/Index.Php/Joiv](http://www.Joiv.Org/Index.Php/Joiv)
- [10] W. Zeng, “*Image Data Augmentation Techniques based on Deep Learning: A Survey*,” 2024, *American Institute Of Mathematical Sciences*. DOI: 10.3934/Mbe.2024272.
- [11] D. Gede, T. Meranggi, N. Yudistira, And Y. A. Sari, “*International Journal on Informatics Visualization Journal Homepage : www.Joiv.Org/Index.Php/Joiv International Journal on Informatics Visualization Batik Classification using Convolutional Neural Network with Data Improvements.*” [Online]. Available: [Www.Joiv.Org/Index.Php/Joiv](http://www.Joiv.Org/Index.Php/Joiv)
- [12] D. Sinaga, C. Jatmoko, S. Suprayogi, And N. Hedriyanto, “*Multi-Layer Convolutional Neural Networks for Batik Image Classification*,” *Scientific Journal of Informatics*, Vol. 11, No. 2, Pp. 477–484, May 2024, DOI: 10.15294/Sji.V11i2.3309.
- [13] R. Andrian *Et Al.*, “*Lampung Batik Classification using Alexnet, Efficientnet, Lenet and Mobilenet Architecture*,” 2024. [Online]. Available: [Www.Ijacs.Thesai.Org](http://www.Ijacs.Thesai.Org)
- [14] A. Kusuma Whardana, U. Alfaruq, A. Aziz, And U. T. Abeng, “*Klasifikasi Motif Batik menggunakan Convolutional Neural Network (CNN) dengan Otsu Thresholding dan Median Filter*,” 2025.
- [15] S. Arifin, “*Klasifikasi Motif Batik menggunakan Metode Convolutional Neural Network (CNN) dengan Multi Class Classification*,” *Jurnal Ilmiah It Cida : Diseminasi Teknologi Informasi*, Vol. 10, No. 1, 2024.

- [16] S. P. Adithama, B. Yudi Dwiandiyanta, And S. B. Wiadji, “*Identification of Batik in Central Java using The Transfer Learning Method 77.*”
- [17] Kusanti, Jani & Noersasongko, Edi & Soeleman, Moch & Alzami, Farrikh & Purwanto, Purwanto & Hasibuan, Zainal. (2023). *Pre-Processing of Resize and Region of Interest (ROI) to Improve the Accuracy of Batik Detection based on VGG-16.* 242-247. 10.1109/EECSI59885.2023.10295666.