



# Klasifikasi Motif Batik Solo Menggunakan Convolutional Neural Network dengan Transfer Learning VGG16

Daffa Ferdinan Aditama<sup>\*</sup>, Rr. Hajar Puji Sejati, Fadil Indra Sanjaya

Fakultas Sains & Teknologi, Program Studi Informatika, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia

Email: <sup>1,\*</sup>daffamadara128@gmail.com, <sup>2</sup>hajarsejati@gmail.com, <sup>3</sup>fadil.indra@staff.uty.ac.id

Email Penulis Korespondensi: daffamadara128@gmail.com

**Abstrak**—Batik Solo memiliki keragaman motif yang kaya dan bernilai filosofis tinggi, namun proses identifikasi motif masih banyak dilakukan secara manual sehingga bersifat subjektif dan rentan terhadap kesalahan. Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis untuk membedakan empat motif Batik Solo, yaitu Parang, Kawung, Truntum, dan Sekar Jagad, menggunakan metode Convolutional Neural Network (CNN) berbasis arsitektur VGG16 dengan pendekatan transfer learning. Dataset yang digunakan terdiri atas 280 citra batik yang terbagi secara seimbang ke dalam empat kelas (70 citra per kelas), di mana keterbatasan jumlah data diatasi melalui pemanfaatan bobot pralatih ImageNet, pembekuan seluruh lapisan konvolusi, serta penerapan augmentasi data untuk mengurangi risiko overfitting. Pemilihan VGG16 didasarkan pada pertimbangan bahwa penelitian ini berfokus pada evaluasi kemampuan ekstraksi fitur dan analisis performa klasifikasi pola visual motif Batik Solo secara mendalam, sehingga VGG16 digunakan sebagai model baseline yang stabil dan interpretatif, bukan untuk tujuan efisiensi komputasi atau implementasi mobile. Proses pelatihan dilakukan selama 50 epoch dengan pembagian data 60% data latih, 20% data validasi, dan 20% data uji, dan hasil pengujian menunjukkan akurasi sebesar 85,71% dengan nilai precision, recall, dan F1-score rata-rata masing-masing sebesar 0,88; 0,86; dan 0,86, di mana motif Sekar Jagad memperoleh performa terbaik sementara motif Truntum menjadi kelas yang paling menantang akibat karakteristik teksturnya yang halus dan repetitif.

**Kata Kunci:** Batik Solo; CNN; VGG16; Klasifikasi Citra

**Abstract**—Batik Solo has a rich variety of motifs with high philosophical value, but the process of identifying motifs is still largely done manually, making it subjective and prone to error. This study aims to develop an automatic classification system to distinguish four Batik Solo motifs, namely Parang, Kawung, Truntum, and Sekar Jagad, using the Convolutional Neural Network (CNN) method based on the VGG16 architecture with a transfer learning approach. The dataset used consists of 280 batik images divided evenly into four classes (70 images per class), where data limitations are overcome using ImageNet pre-trained weights, freezing all convolution layers, and applying data augmentation to reduce the risk of overfitting. The selection of VGG16 was based on the consideration that this study focused on evaluating feature extraction capabilities and analyzing the classification performance of Batik Solo visual patterns in depth, so VGG16 was used as a stable and interpretative baseline model, not for the purposes of computational efficiency or mobile implementation. The training process was carried out for 50 epochs with a data division of 60% training data, 20% validation data, and 20% test data, and the test results showed an accuracy of 85.71% with average precision, recall, and F1-score values of 0.88; 0.86; and 0.86, respectively, where the Sekar Jagad motif performed the best, while the Truntum motif was the most challenging class due to its smooth and repetitive texture characteristics.

**Keywords:** Batik Solo; CNN; VGG16; Image Classification

## 1. PENDAHULUAN

Batik merupakan salah satu warisan budaya yang memiliki posisi penting dalam kebudayaan Indonesia. Keunikan dan kekhasan batik telah mendapatkan pengakuan internasional, khususnya setelah UNESCO menetapkan batik sebagai Warisan Budaya Tak benda (WBTB) pada tanggal 2 Oktober 2009 (Jasmine, 2024). Secara umum, batik dapat dipahami sebagai seni menghias kain dengan pola berulang yang dibuat menggunakan alat tradisional berupa (Meranggi dkk., 2022). Produk budaya ini memiliki nilai filosofis, estetika, dan ekonomi yang tinggi, serta menjadi representasi identitas bangsa Indonesia (Benita Suciani dkk., 2024). Perkembangan batik di Indonesia telah mencapai tingkat yang sangat maju, baik dari segi variasi motif maupun teknik pembuatannya. Ragam corak dan motif yang sarat makna tersebut terus digali dari akar budaya dan adat istiadat yang berkembang di berbagai daerah (Nikmah dkk., 2024). Setiap motif batik lahir dari proses kreatif dan kognitif manusia yang terinspirasi oleh fenomena alam serta lingkungan sosialnya (Ma'ruf dkk., 2023). Berdasarkan data Badan Pusat Statistik (BPS, 2025), ekspor batik pada triwulan I tahun 2025 mengalami peningkatan signifikan sebesar 76,2 persen, yaitu dari US\$ 4,33 juta menjadi US\$ 7,63 juta. Pasar ekspor utama meliputi Amerika Serikat dan Jerman, disusul negara-negara ASEAN seperti Malaysia, Thailand, dan Vietnam (Tebo, 2025; UMKM, 2025).

Batik di Indonesia memiliki keragaman motif yang dipengaruhi oleh budaya lokal di berbagai wilayah, salah satunya adalah Batik Solo yang dikenal sebagai salah satu pusat perkembangan batik di Jawa. Batik Solo memiliki ciri khas berupa warna soğan kecokelatan serta pola yang anggun dan sarat makna filosofis (Hassa, 2024). Di antara motif yang paling dikenal dan banyak digunakan adalah Parang, Kawung, Truntum, Sekar Jagad. Motif Parang melambangkan kekuatan, keteguhan, dan keberanian, serta ditandai oleh bentuk diagonal berulang (Dharmasisya dkk., 2022). Motif Truntum dikenal sebagai simbol kasih sayang yang tulus dan abadi, dicirikan oleh pola bintang kecil atau titik-titik yang tersusun rapat (Kurniawan & Widagdo, 2024). Motif Sekar Jagad melambangkan keindahan alam dan keberagaman budaya. Motif tersebut memiliki karakter visual yang kuat, namun sering kali sulit dibedakan secara manual hanya melalui pengamatan visual, terutama ketika dipengaruhi oleh variasi bahan, teknik pewarnaan, atau kondisi pencahayaan pada citra digital (Murinto dkk., 2023). Berdasarkan permasalahan tersebut, penelitian ini



bertujuan untuk mendeteksi jenis batik Solo yaitu Parang, Kawung, Truntum dan Sekar Jagad menggunakan metode *Convolutional Neural Network* (CNN) menggunakan arsitektur VGG16

Perkembangan teknologi pengolahan citra digital berbasis *Convolutional Neural Network* (CNN) memberikan peluang besar dalam menyelesaikan permasalahan identifikasi visual secara otomatis (Yu dkk., 2023). CNN dikenal memiliki performa tinggi dalam tugas pengenalan dan klasifikasi citra karena kemampuannya mengekstraksi fitur penting dari representasi visual, baik pada ruang warna maupun citra keabuan. Dengan kemampuan tersebut, jaringan saraf tiruan mampu membedakan objek berdasarkan karakteristik visualnya secara akurat. CNN merupakan salah satu metode *deep learning* yang paling banyak digunakan karena arsitekturnya dapat menangkap fitur spasial secara bertahap dan hierarkis dari data gambar (Mienye & Swart, 2024). Salah satu arsitektur CNN yang cukup populer dan telah terbukti efektif pada berbagai tugas klasifikasi citra adalah VGG16, sebagaimana diterapkan dalam penelitian Albakia & Saputra (2023) Oleh karena itu, penelitian ini mengadopsi metode CNN dengan arsitektur VGG16 untuk mengenali dan mengklasifikasikan motif Batik Solo.

Beberapa penelitian sebelumnya telah membahas pengenalan motif batik menggunakan metode CNN dengan arsitektur VGG16. Kusanti dkk. (2023) melakukan penelitian terkait peningkatan akurasi deteksi motif batik menggunakan arsitektur CNN VGG16 dengan fokus pada pengaruh teknik pra-pemrosesan citra. Penelitian tersebut membahas permasalahan variasi ukuran citra yang sering menurunkan performa model dalam mendeteksi motif batik. Untuk mengatasinya, dua metode pra-pemrosesan dibandingkan, yaitu *resize* dan *Region of Interest* (ROI). Dataset yang digunakan terdiri dari 1.445 citra batik yang mencakup delapan kelas motif, yaitu Kawung, Parang, Satriomanah, Sawat, Sementrante, Sidomukti, Tambal, dan Truntum, dengan 1.301 citra untuk pelatihan dan 144 citra untuk pengujian. Hasil eksperimen menunjukkan bahwa teknik pra-pemrosesan memiliki dampak signifikan terhadap performa model. Metode *resize* memberikan efisiensi komputasi, namun menghasilkan akurasi yang lebih rendah, yaitu 0.89. Sebaliknya, metode ROI menghasilkan akurasi tertinggi, yaitu 0.96, sehingga terbukti lebih efektif dalam menyoroti bagian penting dari motif batik dan meningkatkan kemampuan VGG16 dalam mengenali pola. Temuan ini menegaskan bahwa seleksi pra-pemrosesan citra sangat berpengaruh terhadap akurasi deteksi motif batik berbasis *deep learning*.

Penelitian lain yang dilakukan oleh (Filia dkk., 2023) membahas permasalahan ketidakseimbangan data (*imbalanced dataset*) pada klasifikasi motif batik, yang umum terjadi akibat keterbatasan jumlah citra dan kelangkaan beberapa jenis motif. Ketidakseimbangan ini menyebabkan model cenderung lebih akurat pada kelas mayoritas dan kesulitan mengenali kelas minoritas. Untuk mengatasi hal tersebut, penelitian ini mengusulkan kombinasi teknik *oversampling* dan *advanced augmentation* yang menghasilkan variasi citra lebih realistis, meliputi perubahan warna, kontras, lipatan kain, dan distorsi tekstur. Peneliti menggunakan dua arsitektur CNN, yaitu DenseNet169 dan VGG-16, dengan tiga skenario pelatihan: tanpa augmentasi, menggunakan *oversampling* saja, serta kombinasi *oversampling* dan *advanced augmentation*. Hasil eksperimen menunjukkan bahwa DenseNet169 dengan kombinasi teknik tersebut memberikan akurasi tertinggi sebesar 84,62%, sedangkan VGG-16 mencapai 82,56%. Studi ini menegaskan bahwa penggunaan *advanced augmentation* dan *oversampling* secara bersamaan mampu meningkatkan performa model secara signifikan dibandingkan data asli maupun *oversampling* saja.

Berdasarkan penelitian-penelitian sebelumnya, dapat disimpulkan bahwa metode CNN, khususnya arsitektur VGG16, sangat efektif dalam pengenalan pola visual pada citra batik. Namun demikian, sebagian besar penelitian yang telah dilakukan berfokus pada motif dari daerah tertentu seperti Pekalongan dan Yogyakarta, sedangkan motif Batik Solo seperti Parang, Kawung, Truntum, dan Sekar Jagad belum banyak dikaji secara mendalam menggunakan arsitektur CNN tingkat lanjut seperti VGG16. Selain itu, motif batik Solo memiliki ciri visual yang lebih tegas dan repetitif, yang secara teori sangat cocok dianalisis melalui arsitektur CNN karena kemampuannya dalam mengenali pola berulang. Minimnya penelitian yang mengevaluasi performa VGG16 terhadap motif Batik Solo menunjukkan adanya celah penelitian yang perlu diisi, sekaligus memberikan peluang untuk eksplorasi lebih dalam terhadap kemampuan CNN dalam mengklasifikasikan motif batik dengan karakteristik visual yang mirip.

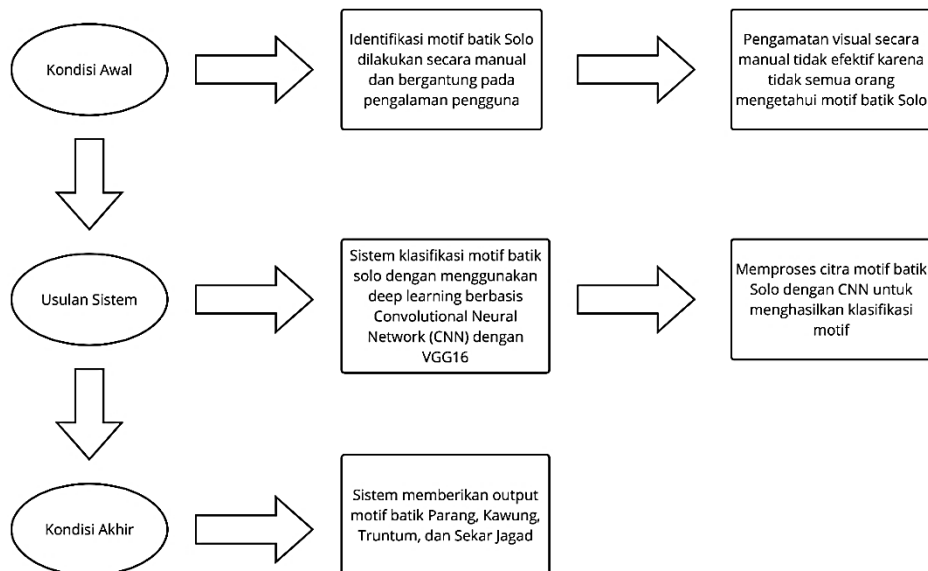
Meskipun dalam beberapa tahun terakhir telah berkembang berbagai arsitektur CNN yang lebih ringan dan efisien seperti MobileNet dan EfficientNet, penelitian ini secara khusus memilih VGG16 sebagai model yang digunakan. Pemilihan VGG16 didasarkan pada pertimbangan bahwa tujuan utama penelitian ini adalah mengevaluasi kemampuan ekstraksi fitur dan performa klasifikasi motif Batik Solo secara mendalam, bukan pada aspek efisiensi komputasi. VGG16 dikenal sebagai arsitektur CNN klasik yang stabil dan banyak digunakan sebagai *baseline model* dalam penelitian pengolahan citra, sehingga hasil yang diperoleh lebih mudah dianalisis dan dibandingkan secara ilmiah (Kumala dkk., 2025). Selain itu, struktur VGG16 yang tersusun atas lapisan konvolusi berukuran kecil (3×3) secara bertahap dinilai sesuai untuk menangkap pola berulang dan struktur tekstur pada motif batik (Rizky Rahmalia Ivani dkk., 2025). Penggunaan arsitektur CNN lain yang lebih ringan dan modern seperti MobileNet atau EfficientNet menjadi peluang pengembangan pada penelitian selanjutnya.

Dar latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis motif Batik Solo menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur VGG16. Secara khusus, penelitian ini bertujuan untuk mengidentifikasi dan membedakan motif Parang, Kawung, Truntum, dan Sekar Jagad berdasarkan karakteristik pola visualnya. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknologi pengenalan motif batik yang lebih akurat, efisien, dan mudah diterapkan, sehingga dapat mendukung upaya pelestarian batik melalui pemanfaatan citra digital dan teknologi kecerdasan buatan.

## 2. METODOLOGI PENELITIAN

### 2.1 Kerangka Dasar Penelitian

Batik Solo merupakan salah satu warisan budaya Indonesia yang memiliki beragam motif khas, seperti Parang, Kawung, Truntum, dan Sekar Jagad, dengan karakteristik visual yang berbeda. Proses identifikasi motif batik yang masih dilakukan secara manual sangat bergantung pada pengalaman pengamat, sehingga bersifat subjektif dan kurang efisien. Oleh karena itu, penelitian ini mengusulkan pengembangan sistem klasifikasi motif batik Solo berbasis pengolahan citra digital dan *deep learning* menggunakan algoritma Convolutional Neural Network (CNN) dengan arsitektur VGG16 untuk mengotomatisasi proses identifikasi motif berdasarkan karakteristik visual citra.




**Gambar 1.** Kerangka Penelitian

Dari kerangka penelitian pada Gambar 1, dijelaskan bahwa kondisi awal menunjukkan identifikasi motif batik Solo dilakukan secara manual dan bergantung pada pengalaman pengguna. Hal ini menyebabkan pengamatan visual secara manual yang tidak efektif karena tidak semua orang mengetahui motif batik Solo. Untuk mengatasi permasalahan tersebut, usulan sistem dalam penelitian ini mengembangkan sistem klasifikasi motif batik Solo dengan menggunakan *deep learning* berbasis *Convolutional Neural Network* (CNN) dengan arsitektur VGG16. Sistem ini akan memproses citra motif batik Solo dengan CNN untuk menghasilkan klasifikasi motif secara otomatis. Kondisi akhir, sistem akan memberikan output berupa klasifikasi motif batik Parang, Kawung, Truntum, dan Sekar \. Dengan sistem ini, identifikasi motif batik Solo dapat dilakukan secara otomatis dan efisien tanpa bergantung pada keahlian manual pengamat.

### 2.2 Tahapan Penelitian

Perancangan tahapan penelitian dilakukan secara sistematis untuk mengembangkan sistem klasifikasi motif Batik Solo menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur VGG16. Setiap tahapan memiliki peran penting agar model yang dibangun mampu mengenali dan membedakan motif Parang, Kawung, Truntum, dan Sekar Jagad secara akurat. Tahapan penelitian ditunjukkan pada Gambar 2 berikut. Pendekatan bertahap ini memungkinkan proses pengembangan dilakukan secara terstruktur dan terukur. Selain itu, setiap tahapan dievaluasi untuk memastikan kualitas data dan kinerja model tetap optimal.



**Gambar 2.** Tahapan Penelitian

Gambar 2 menunjukkan tahapan penelitian yang digunakan dalam pengembangan sistem klasifikasi motif Batik Solo. Proses dimulai dari identifikasi masalah, dilanjutkan dengan pengumpulan data citra motif batik, kemudian dilakukan *preprocessing* data untuk menyesuaikan format citra agar dapat diproses oleh CNN. Selanjutnya dilakukan perancangan model dengan menggunakan arsitektur VGG16, diikuti oleh tahap pelatihan model menggunakan data latih. Tahap akhir adalah evaluasi model untuk mengukur performa sistem klasifikasi berdasarkan hasil prediksi yang dihasilkan.

### 2.2.1 Identifikasi Masalah




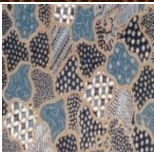
Tahap pertama dalam penelitian dilakukan identifikasi permasalahan utama, yaitu proses identifikasi jenis motif Batik Solo (Parang, Kawung, Truntum, dan Sekar Jagad) yang masih dilakukan secara manual, yang hasilnya bergantung pada pengalaman dan keahlian pengamat, sehingga cenderung subjektif, memakan waktu, dan rentang terhadap kesalahan, terutama ketika motif memiliki kemiripan visual.

### 2.2.2 Pengumpulan Data

Setelah mengetahui permasalahan utama, selanjutnya dilakukan pengumpulan data berupa citra batik Solo yang mencakup empat motif, yaitu Parang, Kawung, Truntum, dan Sekar Jagad. Data citra diperoleh melalui dua cara, yaitu memotret kain batik Solo secara langsung menggunakan kamera *smartphone* dan mengunduh dari dataset publik yang tersedia di internet. Total data yang berhasil dikumpulkan adalah 280 citra dengan distribusi yang seimbang, yaitu masing-masing 70 gambar untuk setiap motif. Seluruh citra memiliki ukuran yang seragam sebesar  $256 \times 256$  piksel untuk memudahkan proses *preprocessing* dan pelatihan model. Sampel dari data citra yang telah dikumpulkan dapat dilihat pada Tabel 1 berikut.

Meskipun jumlah data relatif terbatas jika dibandingkan dengan pendekatan *deep learning* konvensional, penelitian ini menggunakan pendekatan transfer learning dengan arsitektur VGG16 yang telah dilatih sebelumnya pada dataset ImageNet. Seluruh lapisan konvolusi pada VGG16 dibekukan (*frozen*), sehingga proses pelatihan hanya difokuskan pada lapisan *classifier*. Pendekatan ini secara signifikan mengurangi jumlah parameter yang harus dipelajari dan memungkinkan model bekerja secara efektif meskipun menggunakan dataset yang terbatas. Selain itu, untuk meningkatkan variasi data dan mengurangi risiko *overfitting*, diterapkan augmentasi data pada data latih yang mencakup rotasi, *zoom*, dan *horizontal flip*. Teknik ini bertujuan untuk mensimulasikan variasi kondisi citra batik, seperti perbedaan sudut pengambilan dan orientasi pola, sehingga jumlah sampel efektif selama pelatihan menjadi lebih beragam. Dengan kombinasi dataset yang seimbang, transfer learning, dan augmentasi data, jumlah citra yang digunakan pada penelitian ini dianggap cukup representatif untuk mengevaluasi kemampuan arsitektur VGG16 dalam mengklasifikasikan motif Batik Solo. Sampel dari data citra yang telah dikumpulkan ditampilkan pada Tabel 1.

**Tabel 1.** Sampel citra motif batik Solo

Motif Batik	Gambar
Parang	
Kawung	
Truntum	
Sekar Jagad	

Tabel 1 menunjukkan sampel citra motif Batik Solo yang digunakan sebagai dataset penelitian. Setiap kelas motif ditampilkan untuk memperlihatkan karakteristik visual khas, seperti pola diagonal pada motif Parang, pola geometris simetris pada motif Kawung, pola titik berulang pada motif Truntum, serta pola kompartemen tidak beraturan pada motif Sekar Jagad. Penyajian sampel citra pada Tabel 1 bertujuan untuk memberikan gambaran visual mengenai perbedaan pola antar motif, sekaligus menegaskan bahwa distribusi data yang seimbang pada setiap kelas diharapkan dapat mendukung proses pelatihan model CNN secara optimal dan mengurangi potensi bias terhadap kelas tertentu.

### 2.2.3 Preprocessing data

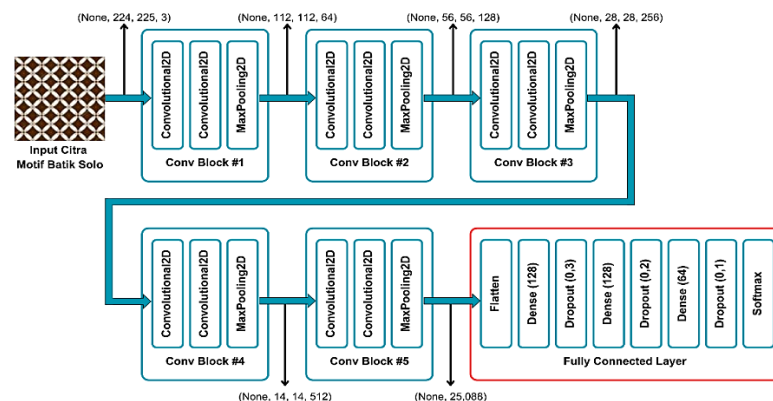
Data citra motif batik solo yang telah dikumpulkan 280 citra, tahap selanjutnya adalah *preprocessing* data untuk mempersiapkan data agar dapat diproses oleh Model CNN. Dataset dibagi menjadi tiga bagian, yaitu data latih untuk melatih model, data validasi untuk memvalidasi performa model selama proses pelatihan, dan data uji untuk mengevaluasi performa akhir model. Proses *preprocessing* dimulai dengan mengubah ukuran seluruh citra agar seragam

dan sesuai dengan ukuran input arsitektur VGG16 dengan ukuran 224x224 piksel. Setelah itu, dilakukan normalisasi nilai piksel citra untuk mengubah rentang nilai piksel dari [0,255] menjadi rentang nilai yang sesuai dengan standar *preprocessing* model VGG16, sehingga dapat mempercepat proses pelatihan dan meningkatkan konvergensi model. Langkah-langkah awal ini memastikan bahwa seluruh data berada dalam kondisi yang konsisten sebelum diproses oleh model.

Untuk meningkatkan akurasi model dan mengurangi risiko *overfitting*, dilakukan augmentasi data pada data *training*. Augmentasi data dilakukan dengan beberapa teknik transformasi, yaitu rotasi acak 20 derajat, *zoom* sebesar 20%, dan flip horizontal. Teknik augmentasi ini akan menghasilkan variasi baru dari citra *training* tanpa perlu mengumpulkan data tambahan, sehingga model dapat belajar dari berbagai kondisi, dan sudut pandang citra batik yang berbeda. Augmentasi data hanya dilakukan pada data *training* untuk memperkaya variasi data pelatihan, sedangkan data validasi dan testing tidak dilakukan augmentasi untuk menjaga konsistensi dan objektivitas dalam proses evaluasi performa model. Seluruh data yang telah melalui proses *preprocessing* ini siap digunakan untuk pelatihan model klasifikasi motif batik Solo. Tahapan *preprocessing* ini diharapkan dapat memastikan kualitas data yang optimal sebelum memasuki proses pelatihan model.

### 2.2.4 Perancangan Model

Model klasifikasi motif batik Solo dirancang dengan pendekatan *transfer learning* dengan arsitektur VGG16 yang dikombinasikan dengan *Convolutional Neural Network* (CNN). *Transfer learning* merupakan teknik yang menggunakan model *deep learning* yang telah dilatih pada dataset besar dan beragam untuk meningkatkan performa pada tugas target dengan data terbatas (Nathani, 2024). Pada arsitektur ini, VGG16 yang telah dilatih pada dataset ImageNet digunakan sebagai *feature extractor* untuk mengekstraksi fitur-fitur penting dari citra motif batik Solo, sementara CNN berfungsi sebagai *classifier* untuk mengklasifikasikan motif berdasarkan fitur yang telah diekstraksi. Dengan pendekatan ini dapat menghemat waktu pelatihan dan meningkatkan akurasi mode, dengan data yang relatif terbatas. Rancangan arsitektur dapat dilihat pada Gambar 3 berikut.



**Gambar 3.** Arsitektur Model CNN

Pada Gambar 3, model menerima input berupa citra motif Batik Solo berukuran 224x224 piksel yang kemudian diproses melalui lima *convolutional blocks* (Conv Block 1 hingga 5) dari arsitektur VGG16. Setiap *convolutional block* terdiri atas dua hingga tiga lapisan *Convolutional2D* dengan *activation function* ReLU serta satu lapisan *MaxPooling2D* untuk mengekstraksi fitur hierarkis dari citra, mulai dari tepian dan tekstur sederhana hingga pola motif yang lebih kompleks. Model VGG16 yang digunakan merupakan pre-trained model berbobot ImageNet tanpa bagian *fully connected layer* bawaan, sehingga berfungsi sebagai *feature extractor*. Seluruh lapisan konvolusinya dibekukan (*frozen weights*) untuk mempertahankan pengetahuan fitur umum dari jaringan.

Output dari Conv Block 5 selanjutnya diratakan melalui lapisan Flatten dan diproses oleh tiga lapisan Dense berturut-turut dengan 128, 128, dan 64 neuron yang menggunakan fungsi aktivasi ReLU. Setiap lapisan Dense disertai dengan lapisan Dropout sebesar 0.3, 0.2, dan 0.1 untuk mengurangi risiko *overfitting*. Pada bagian akhir, lapisan Dense dengan 4 neuron dan fungsi aktivasi Softmax digunakan untuk menghasilkan probabilitas dari empat kelas motif Batik Solo, yaitu Parang, Kawung, Truntum, dan Sekar Jagad. Model dikompilasi menggunakan *optimizer* Adam, *loss function* *categorical crossentropy*, dan metrik akurasi.

### 2.2.5 Pelatihan Model

Setelah melakukan perancangan arsitektur model, selanjutnya dilakukan pelatihan model dengan menggunakan data *training* yang telah melalui proses *preprocessing*. Proses pelatihan dilakukan selama 50 epoch dengan batch size sebesar 32. Pada setiap epoch, model belajar mengenali pola dan fitur dari citra motif batik Solo dengan cara meminimalkan fungsi *loss* menggunakan *optimizer* Adam. Dengan menggunakan *learning rate* 0,0001, untuk mengontrol besarnya pembaruan bobot model agar proses pelatihan berjalan stabil. Parameter *decay* dan *momentum* tidak diterapkan secara eksplisit, sehingga model menggunakan nilai bawaan (*default*) dari *optimizer* Adam. Selama proses pelatihan, data validasi digunakan untuk memantau performa model dan mencegah terjadinya *overfitting*. Model akan menyesuaikan

bobot pada *fully connected layer* berdasarkan *error* yang dihasilkan, sementara bobot pada layer VGG16 tetap dibekukan untuk mempertahankan ekstraksi fitur yang telah dipelajari dari dataset ImageNet.

Performa model selama pelatihan dipantau menggunakan metrik akurasi dan *loss*, baik pada data *training* maupun data validasi. Proses pembelajaran model divisualisasikan melalui grafik akurasi dan *loss* per *epoch* untuk menganalisis performa dan mendeteksi potensi *overfitting* atau *underfitting*. Pelatihan dihentikan setelah mencapai 50 *epoch*, dan model yang telah terlatih kemudian disimpan untuk digunakan pada tahap evaluasi selanjutnya.

### 2.2.6 Evaluasi Model

Setelah proses pelatihan selesai, model dievaluasi menggunakan data uji untuk mengetahui sejauh mana model mampu melakukan generalisasi dalam mengklasifikasikan motif batik Solo pada citra yang tidak pernah digunakan selama pelatihan. Evaluasi dilakukan dengan menghitung beberapa metrik kinerja, yaitu akurasi, *precision*, *recall*, dan F1-score (Dewi dkk., 2024). Penilaian ini didasarkan pada *confusion matrix* yang memuat empat parameter utama: *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Keempat parameter tersebut menjadi dasar dalam perhitungan metrik evaluasi yang digunakan untuk menilai performa model secara objektif. Pada penelitian ini, evaluasi model dilakukan melalui tiga pendekatan, yaitu *learning curve*, *confusion matrix*, dan *classification report*.

*Learning curve* digunakan untuk melihat perkembangan performa model selama proses pelatihan. Grafik ini menunjukkan hubungan antara jumlah epoch dengan nilai akurasi dan *loss* pada data pelatihan maupun validasi. Kurva akurasi menggambarkan peningkatan kemampuan model dalam mengenali pola data seiring bertambahnya iterasi, sedangkan kurva *loss* menunjukkan penurunan tingkat kesalahan prediksi. Pola kurva yang stabil dan konvergen antara akurasi serta *loss* pada data pelatihan dan validasi menandakan bahwa model telah mencapai performa yang optimal serta tidak mengalami gejala *overfitting* maupun *underfitting*.

		Predicted	
		Positive	Negative
Actual	Positive	<b>TP</b> (True Positive)	<b>FN</b> (False Negative)
	Negative	<b>FP</b> (False Positive)	<b>TN</b> (True Negative)

**Gambar 4.** Contoh *confusion matrix*

*Confusion matrix* digunakan sebagai alat untuk menilai performa model klasifikasi secara lebih komprehensif, bersamaan dengan metrik evaluasi lainnya seperti akurasi, *precision*, *recall*, dan F1-score. Tabel ini menyajikan empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), yang menjadi dasar dalam mengukur efektivitas model dalam memprediksi setiap kelas. Melalui keempat nilai tersebut, berbagai metrik evaluasi dapat dihitung untuk memberikan gambaran menyeluruh mengenai kemampuan model dalam mengklasifikasikan data secara benar. *Confusion matrix* dapat dilihat pada Gambar 4.

Sementara itu, *classification report* menyajikan performa model berdasarkan beberapa metrik utama, yaitu *precision*, *recall*, F1-score, dan akurasi. *Precision* menggambarkan tingkat ketepatan model dalam memprediksi suatu kelas secara benar, sedangkan *recall* menunjukkan sejauh mana model mampu mengenali seluruh data yang termasuk dalam kelas tersebut. F1-score merupakan rata-rata harmonik antara *precision* dan *recall* yang memberikan penilaian lebih seimbang terhadap kinerja model. Melalui metrik ini, evaluasi terhadap kualitas prediksi model dapat dilakukan secara lebih menyeluruh. Formulasi perhitungan akurasi, *precision*, *recall*, dan F1-score yang digunakan dalam *classification report* ditunjukkan pada persamaan berikut.

- Akurasi menggambarkan seberapa besar proporsi prediksi model yang tepat dibandingkan dengan keseluruhan data uji (Bang Ritan & Chandra, 2025). Rumus perhitungan akurasi sebagai berikut.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \tag{1}$$

Dalam konteks evaluasi kinerja model klasifikasi, TP atau \*True Positive\* merepresentasikan jumlah data yang diprediksi positif dan memang benar positif. TN atau \*True Negative\* menunjukkan jumlah data yang diprediksi negatif dan benar sebagai negatif. Sementara itu, FP atau \*False Positive\* adalah jumlah data yang diprediksi positif tetapi sebenarnya negatif, sedangkan FN atau \*False Negative\* menggambarkan data yang diprediksi negatif padahal sebenarnya positif. Keempat komponen ini menjadi dasar perhitungan berbagai metrik evaluasi seperti akurasi, presisi, dan *recall*.

- Persisi menunjukkan seberapa banyak prediksi positif yang benar-benar akurat dibandingkan dengan seluruh data yang diklasifikasi sebagai positif oleh model (Bang Ritan & Chandra, 2025). Rumus presisi sebagai berikut.

$$Presisi = \frac{TP}{TP+FP} \tag{2}$$



- c. Recall menggambarkan sejauh mana model mampu menangkap seluruh data yang sebenarnya termasuk kategori positif (Bang Ritan & Chandra, 2025).

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

- d. F1-score adalah nilai yang diperoleh dari rata-rata harmonis antara presisi dan recall, sehingga mencerminkan tingkat keseimbangan kinerja model antara kedua metrik tersebut (Bang Ritan & Chandra, 2025).

$$F1 - score = 2 \times \frac{Presisi \times recall}{Presisi + Recall} \quad (4)$$

### 2.3 Convolutional Neural Network (CNN)

*Convolutional Neural Network* (CNN) merupakan salah satu arsitektur jaringan saraf tiruan yang dirancang untuk mengekstraksi fitur dari data visual melalui operasi konvolusi. Tidak seperti metode konvensional yang mengharuskan perancangan fitur dilakukan secara manual, CNN dapat mempelajari dan membangun representasi fitur secara otomatis selama proses pelatihan. Arsitektur ini terinspirasi dari mekanisme kerja sistem visual manusia, di mana neuron-neuron buatan merespons pola tertentu serupa dengan neuron biologis, sementara kernel konvolusi berfungsi sebagai detektor terhadap fitur spesifik pada citra. CNN memiliki sejumlah keunggulan seperti *local connectivity*, *weight sharing*, dan proses *downsampling* sehingga mampu bekerja lebih efisien dan efektif dalam mengenali pola visual yang kompleks pada citra digital (Li dkk., 2022).

### 2.4 Arsitektur VGG16

Secara umum, *Convolutional Neural Network* (CNN) terdiri dari tiga komponen utama, yaitu *input layer*, *hidden layer*, dan *output layer*. Salah satu arsitektur CNN yang paling dikenal dalam bidang *computer vision* adalah VGG (*Visual Geometry Group*). Arsitektur ini diperkenalkan oleh Karen Simonyan dan Andrew Zisserman dari University of Oxford, dan dikembangkan oleh kelompok riset Visual Geometry Group. VGG memiliki dua varian utama berdasarkan jumlah lapisannya, yaitu VGG-16 dan VGG-19. Pada arsitektur VGG-16, terdapat 13 *convolutional layer* dan 3 *fully connected layer*, sehingga total 16 lapisan yang menjadikan model ini cukup kompleks. VGG-16 banyak digunakan dalam tugas klasifikasi objek pada citra karena kemampuannya dalam menghasilkan fitur visual yang kuat dan representatif. Dengan sekitar 138 juta parameter, arsitektur ini mampu membangun representasi fitur mendalam sehingga menghasilkan kinerja yang sangat baik dalam proses pengenalan gambar (Elzandy dkk., 2025).

## 3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan pada bagian ini disajikan berdasarkan tahapan metode yang telah dijelaskan sebelumnya, mulai dari *preprocessing* data citra, proses ekstraksi fitur menggunakan arsitektur VGG16, hingga evaluasi performa model menggunakan data uji. Setiap hasil yang ditampilkan merefleksikan kontribusi dari tahapan-tahapan tersebut terhadap kemampuan model dalam mengenali motif Batik Solo. Model dilatih dan diuji menggunakan dataset yang terdiri atas empat kelas motif, yaitu Parang, Kawung, Truntum, dan Sekar Jagad. Evaluasi performa model dilakukan secara menyeluruh dengan menggunakan beberapa metrik, meliputi akurasi, nilai *loss*, *confusion matrix*, dan *classification report*. Analisis hasil bertujuan untuk menilai kemampuan model dalam mengenali karakteristik visual setiap motif serta mengidentifikasi perbedaan performa antar kelas. Selain itu, pembahasan juga menyoroti pengaruh *preprocessing* dan augmentasi data terhadap kinerja model secara keseluruhan.

### 3.1 Preprocessing Data

Preprocessing data dilakukan dengan membagi dataset menjadi tiga bagian sebagai data training, data validasi dan data testing. Data training digunakan untuk melatih model agar dapat mempelajari pola dan fitur dari setiap motif batik, data validasi digunakan untuk memantau performa model selama proses pelatihan dan mencegah *overfitting*, sedangkan data testing digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya. Pembagian data dilakukan dengan proporsi 60% data latih, 20% data validasi, dan 20% data validasi. Proporsi pembagian dapat dilihat pada tabel 2 berikut.

**Tabel 2.** Proporsi pembagian data

Data	Proporsi	Jumlah
Data Training	60%	168 citra
Data Validasi	20%	56 citra
Data Testing	20%	56 citra
Total		280 Citra

Tabel 2 menyajikan proporsi pembagian dataset ke dalam data training, data validasi, dan data testing yang digunakan dalam penelitian ini. Dari total 280 citra, sebanyak 168 citra (60%) digunakan sebagai data training untuk melatih model agar mampu mempelajari pola visual setiap motif Batik Solo. Selanjutnya, 56 citra (20%) dialokasikan sebagai data validasi yang berfungsi untuk memantau kinerja model selama proses pelatihan serta membantu

mengendalikan terjadinya *overfitting*. Sementara itu, 56 citra (20%) lainnya digunakan sebagai data testing untuk mengevaluasi kemampuan generalisasi model terhadap data baru yang belum pernah digunakan sebelumnya.

Kemudian seluruh citra kemudian di-*resize* ke ukuran 224x225 piksel untuk menyesuaikan dengan *input* standar arsitektur VGG16, diikuti dengan proses normalisasi nilai piksel untuk mengubah rentang nilai piksel menjadi format yang sesuai. Augmentasi data juga dilakukan khusus pada data latih dengan transformasi berupa rotasi 20 derajat, *zoom* sebesar 20%, dan *horizontal flip* untuk meningkatkan variasi data dan mencegah *overfitting*. Setelah proses pra-pemrosesan ini dataset siap digunakan untuk pelatihan dan evaluasi model klasifikasi motif batik Solo. Proses *preprocessing* ini menjadi tahap awal yang penting karena kualitas hasil ekstraksi fitur oleh VGG16 sangat dipengaruhi oleh konsistensi ukuran citra, normalisasi nilai piksel, serta variasi data yang dihasilkan melalui augmentasi.

### 3.2 Pelatihan Model


Proses pelatihan model dilakukan dengan arsitektur yang menggabungkan VGG16 sebagai *feature extractor* dan *Convolutional Neural Network (CNN)* pada *fully connected layer* sebagai *classifier*. Pendekatan *transfer learning* ini memanfaatkan bobot pre-trained VGG16 yang telah dilatih pada dataset ImageNet untuk mengekstraksi fitur-fitur visual dari citra motif Batik Solo. Seluruh *layer* pada arsitektur VGG16 dibekukan (*freeze*) untuk mempertahankan kemampuan ekstraksi fitur yang telah dipelajari, sementara proses pembelajaran difokuskan pada *fully connected layer* yang berfungsi sebagai *classifier*. Arsitektur *classifier* terdiri dari lapisan Flatten, diikuti tiga lapisan Dense dengan jumlah neuron masing-masing 128,128,64 neuron. Setiap lapisan Dense menggunakan fungsi aktivasi ReLU (*Rectified Linear Unit*) untuk memperkenalkan non-linearitas dalam model, yang memungkinkan model untuk mempelajari pola yang lebih kompleks.

Untuk mencegah terjadinya *overfitting*, diterapkan teknik regularisasi menggunakan lapisan Dropout dengan nilai dropout dengan nilai berturut-turut 0.3, 0.2, dan 0.1 setelah setiap lapisan Dense. Lapisan *output* menggunakan 4 neuron dengan fungsi aktivasi softmax untuk menghasilkan probabilitas dari empat kelas motif batik solo yaitu Parang, Kawung, Truntum dan Sekar Jagad. *Hyperparameter* yang digunakan dalam pelatihan model meliputi 50 epoch untuk memberikan waktu yang cukup bagi model untuk belajar, batch size 32 untuk efisiensi komputasi dan stabilitas pembelajaran, *learning rate* 0.0001 untuk mengatur kecepatan pembaruan bobot secara bertahap dan hati-hati, serta optimizer Adam yang menggabungkan keunggulan momentum dan *adaptive learning rate*. Kombinasi *hyperparameter* ini dipilih melalui pertimbangan keseimbangan antara kecepatan konvergensi, stabilitas pelatihan, dan kemampuan generalisasi model.

Hasil pelatihan dengan *hyperparameter* tersebut menunjukkan bahwa model mencapai akurasi pelatihan sebesar 96,43% dengan *loss* 0,1324, sedangkan pada data validasi diperoleh akurasi 92,86% dengan nilai *loss* 0,7881. Perbedaan antara akurasi *training* dan validasi menunjukkan adanya sedikit *overfitting*, yang ditandai dengan selisih akurasi sekitar 3,57% dan perbedaan *loss* yang cukup signifikan antara *training* dan validasi. Namun, model tetap menunjukkan performa yang baik pada data validasi dengan akurasi di atas 90%. Pada data uji, model menghasilkan akurasi sebesar 85,71% dengan *loss* 0.7374. Meskipun akurasi testing sedikit lebih rendah dibandingkan validasi, hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik dalam mengklasifikasikan motif batik Solo pada data yang belum pernah dilihat sebelumnya. Penggunaan VGG16 sebagai *feature extractor* dengan bobot yang dibekukan (*frozen weights*) menyebabkan proses pembelajaran terfokus pada lapisan klasifikasi, sehingga performa model sangat bergantung pada kesesuaian fitur visual yang diekstraksi terhadap karakteristik motif batik.

### 3.3 Evaluasi Model

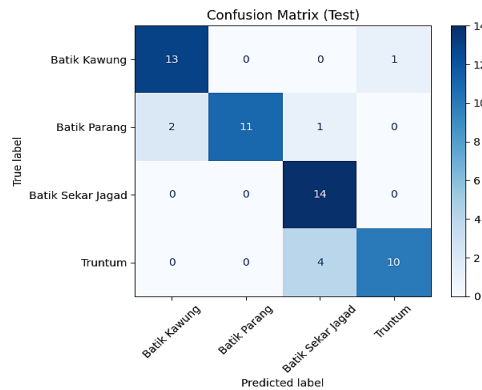
Evaluasi model dilakukan menggunakan data testing yang terdiri dari 56 citra motif Batik Solo untuk menilai kemampuan generalisasi model terhadap data yang tidak digunakan selama pelatihan. Berdasarkan hasil pengujian, model mencapai akurasi sebesar 85,71% dengan nilai *loss* 0,7374. Hasil ini menunjukkan bahwa model memiliki performa yang cukup baik dalam mengklasifikasikan empat kelas motif Batik Solo dan mampu mengenali pola visual yang relevan. Selain itu, Gambar 4 menyajikan kurva belajar (*learning curve*) yang menggambarkan perkembangan akurasi dan *loss* selama 50 epoch, sehingga memberikan gambaran mengenai stabilitas proses pelatihan serta potensi *overfitting* atau *underfitting* pada model.



**Gambar 4.** Learning curve

Pada *learning curve* Gambar 4, terlihat bahwa akurasi training meningkat secara konsisten dari sekitar 0,3 pada epoch awal hingga mencapai kurang lebih 0,96 pada epoch ke-50. Akurasi validasi juga menunjukkan tren peningkatan dari sekitar 0,5 hingga mencapai 0,93, dengan pola kurva yang relatif berdekatan dengan kurva *training*. Meskipun terdapat sedikit fluktuasi antara epoch 10–50, pola tersebut masih tergolong stabil dan menunjukkan bahwa model mampu belajar secara efektif tanpa mengalami *overfitting* yang signifikan.

Pada kurva *loss*, terlihat bahwa nilai *loss training* menurun secara tajam pada *epoch* awal dan terus berkurang secara bertahap hingga mendekati 0,2 pada epoch terakhir. *Loss validasi* juga mengalami penurunan yang stabil, meskipun nilainya berada sedikit lebih tinggi dibandingkan *loss training*. Perbedaan kecil antara kedua kurva *loss* pada akhir pelatihan mengindikasikan adanya *overfitting* ringan, namun selisih tersebut masih berada dalam batas yang dapat diterima dan tidak berdampak signifikan terhadap kemampuan generalisasi model.



**Gambar 4.** *Confusion matrix*

*Confusion matrix* digunakan untuk mengevaluasi hasil akhir dari seluruh tahapan pelatihan model, dengan menampilkan distribusi prediksi benar dan salah pada masing-masing kelas motif Batik Solo. Berdasarkan hasil *confusion matrix* pada Gambar 5, model menunjukkan performa yang cukup baik dalam mengklasifikasikan keempat kelas motif Batik Solo, yaitu Parang, Kawung, Truntum, dan Sekar Jagad. Dari total 56 citra data uji, sebanyak 48 citra berhasil diklasifikasikan dengan benar, sehingga menghasilkan tingkat akurasi sebesar 85,71%. Hasil ini menunjukkan bahwa model mampu mengenali sebagian besar pola visual yang membedakan masing-masing motif batik.

Motif Batik Sekar Jagad memiliki performa terbaik, di mana seluruh 14 citra pada kelas ini berhasil diklasifikasikan dengan benar tanpa adanya kesalahan prediksi. Hal ini mengindikasikan bahwa model memiliki kemampuan yang sangat baik dalam mengenali karakteristik visual khas motif Sekar Jagad. Motif Batik Kawung juga menunjukkan hasil yang baik dengan 13 dari 14 citra terklasifikasi secara tepat, meskipun terdapat satu citra yang salah diprediksi sebagai motif Truntum. Pada motif Batik Parang, model berhasil mengklasifikasikan 11 dari 14 citra dengan benar, sementara tiga citra lainnya mengalami kesalahan prediksi, yaitu dua citra diprediksi sebagai Kawung dan satu citra sebagai Sekar Jagad.

Motif Truntum menjadi kelas dengan tingkat kesalahan tertinggi, di mana hanya 10 dari 14 citra berhasil diklasifikasikan secara benar, sedangkan empat citra lainnya salah diprediksi sebagai Sekar Jagad. Pola kesalahan ini menunjukkan adanya kemiripan visual tertentu antar motif yang masih menjadi tantangan bagi model. Secara keseluruhan, *confusion matrix* memberikan gambaran bahwa model memiliki kemampuan klasifikasi yang cukup baik, namun masih terdapat ruang untuk peningkatan dalam membedakan motif-motif dengan karakteristik visual yang saling mendekati. Pola kesalahan klasifikasi yang muncul pada *confusion matrix* mencerminkan keterbatasan model dalam membedakan motif dengan karakteristik visual yang memiliki kemiripan pada tahap ekstraksi fitur.

**Tabel 3.** *Classification report*

	Precision	Recall	F1-Score	Support
Batik Kawung	0.87	0.93	0.90	14
Batik Parang	1.00	0.79	0.88	14
Batik Sekar Jagad	0.74	1.00	0.85	14
Truntum	0.91	0.71	0.80	14
Accuracy			0.86	56
Macro Avg	0.88	0.86	0.86	56
Weighted Avg	0.88	0.86	0.86	56

*Classification report* pada Tabel 3, memberikan gambaran rinci mengenai model dalam mengenali empat motif Batik Solo, dengan akurasi secara keseluruhan sebesar 85,71%. Nilai *precision*, *recall*, dan *F1-score* juga menunjukkan bahwa model memiliki kemampuan klasifikasi yang cukup baik, dengan nilai masing-masing sebesar 0.88, 0.86, 0.86 mengindikasikan bahwa performa model relatif seimbang pada semua kelas dan tidak bias terhadap kelas tertentu. Perbedaan nilai *precision* dan *recall* antar kelas mencerminkan variasi kemampuan model dalam mengenali karakteristik visual masing-masing motif Batik Solo.



Hasil ini berkaitan langsung dengan tahapan ekstraksi fitur menggunakan VGG16, di mana representasi fitur yang dihasilkan lebih dominan menangkap pola berskala besar dibandingkan tekstur mikro. Motif Truntum memperoleh nilai recall terendah yaitu 0,71 dengan sebagian besar citra salah diklasifikasikan sebagai motif Sekar Jagad. Secara visual, motif truntum dicirikan dengan pola bentuk menyerupai bintang yang tersusun rapat dan berulang secara homogen. Karakteristik ini termasuk tekstur halus (*fine-grained texture*), yang cenderung kurang terwakili pada feature map menengah dan tinggi VGG16 karena arsitektur ini lebih optimal dalam menangkap pola global dibandingkan detail mikro. Selain itu, augmentasi berupa rotasi dan zoom dapat berpotensi mengubah keteraturan spasial pola titik Truntum, sehingga semakin menyulitkan model dalam mempertahankan ciri khas visual motif tersebut.

Sebaliknya, motif Sekar Jagad menunjukkan performa terbaik dengan nilai recall mencapai 1,00. Keberhasilan ini disebabkan oleh karakteristik visual Sekar Jagad yang memiliki pola kompartemen yang jelas berupa bidang-bidang tidak beraturan dengan batas kontras yang kuat. Struktur ini dapat menghasilkan perbedaan tekstur dan warna yang signifikan secara spasial, sehingga mudah dikenali oleh lapisan konvolusi VGG16, khususnya pada level fitur menengah dan tinggi. Pola global yang unik ini membuat representasi fitur Sekar Jagad lebih terpisah dibandingkan motif lain. Hal ini menunjukkan bahwa tahapan ekstraksi fitur oleh VGG16 memberikan representasi yang optimal untuk motif dengan struktur global yang kuat.

Namun, nilai *precision* Sekar Jagad yang lebih rendah menunjukkan bahwa beberapa citra dari kelas lain, terutama Truntum, salah diprediksi sebagai Sekar Jagad. Hal ini mengindikasikan adanya kemiripan fitur lokal antara pola mikro pada Truntum dan elemen visual tertentu pada Sekar Jagad, sehingga sebagian citra Truntum memiliki kedekatan representasi fitur dengan kelas Sekar Jagad dalam ruang fitur model. Motif Parang dan Kawung menunjukkan performa yang relatif stabil dengan nilai *precision* dan *recall* yang berada pada tingkat menengah hingga tinggi. Motif Parang memiliki pola diagonal berulang yang konsisten dan berskala besar, sehingga mudah dikenali oleh CNN sebagai pola global, namun kemiripannya dengan struktur geometris Kawung menyebabkan beberapa kesalahan prediksi silang. Sementara itu, motif Kawung memiliki pola simetris berbentuk elips yang cukup terstruktur, tetapi variasi ukuran dan orientasi motif dalam citra menyebabkan sebagian fitur tumpang tindih dengan kelas lain.

Secara keseluruhan, hasil ini menunjukkan bahwa arsitektur VGG16 lebih efektif dalam mengenali motif dengan struktur global yang kuat dan kontras tinggi dibandingkan motif dengan pola mikro dan repetitif. Oleh karena itu, peningkatan performa pada motif seperti Truntum berpotensi dicapai melalui penyesuaian strategi augmentasi agar tidak merusak pola halus, penerapan *fine-tuning* pada layer konvolusi tertentu, atau penggunaan arsitektur CNN yang lebih sensitif terhadap detail lokal.

## 4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis guna membedakan empat motif Batik Solo, yaitu Parang, Kawung, Truntum, dan Sekar Jagad, menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur VGG16. Model yang dikembangkan mampu mencapai akurasi pengujian sebesar 85,71% berdasarkan perhitungan confusion matrix. Nilai akurasi ini muncul sebagai 0,86 (86%) pada *classification report* akibat proses pembulatan otomatis, yang menunjukkan bahwa sistem mampu mengenali pola visual pada masing-masing motif dengan cukup baik. Hasil evaluasi menunjukkan bahwa motif Truntum merupakan kelas yang paling sulit dikenali oleh model, dengan nilai recall terendah sebesar 0,71. Kesulitan ini disebabkan oleh karakteristik visual Truntum yang didominasi oleh pola mikro dan tekstur halus yang repetitif, sehingga kurang optimal ditangkap oleh arsitektur VGG16 yang lebih sensitif terhadap pola global. Sebaliknya, motif Sekar Jagad menjadi kelas yang paling mudah dikenali, dengan nilai recall mencapai 1,00. Keberhasilan ini dipengaruhi oleh struktur visual Sekar Jagad yang memiliki pola kompartemen besar, kontras tinggi, dan variasi spasial yang jelas, sehingga menghasilkan representasi fitur yang lebih terpisah dibandingkan motif lainnya. Proses pelatihan model menunjukkan bahwa arsitektur VGG16 mampu mempelajari pola visual motif batik secara efektif meskipun jumlah dataset relatif terbatas. Susunan lapisan konvolusi pada VGG16 memungkinkan model mengidentifikasi perbedaan bentuk, tekstur permukaan, dan pola berulang pada setiap motif Batik Solo. Namun demikian, penelitian ini memiliki keterbatasan, antara lain jumlah dataset yang masih terbatas dan belum sepenuhnya merepresentasikan variasi kondisi lapangan, seperti perbedaan sudut pemotretan, pencahayaan, latar belakang kain, serta variasi teknik produksi batik dari pengrajin yang berbeda. Selain itu, penelitian ini belum melakukan perbandingan performa dengan arsitektur CNN lain. Oleh karena itu, penelitian selanjutnya disarankan untuk menambah jumlah dan keragaman data citra batik, menerapkan strategi augmentasi yang lebih adaptif terhadap tekstur halus, serta melakukan *fine-tuning* atau eksplorasi arsitektur CNN lain agar model mampu mengenali motif dengan karakteristik mikro secara lebih optimal. Dengan capaian tersebut, sistem klasifikasi yang dikembangkan memiliki potensi untuk diterapkan pada sistem identifikasi motif batik berbasis digital, sehingga dapat mendukung upaya pelestarian budaya Batik Solo melalui pemanfaatan teknologi kecerdasan buatan.

## REFERENCES

- Albakia, S. A. E., & Saputra, R. A. (2023). Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16. *Jurnal Informatika Polinema*, 9(4), 451–460. <https://doi.org/10.33795/jip.v9i4.1420>



- Bang Ritan, F. M., & Chandra, A. Y. (2025). Analisis Perbandingan Kinerja Model CNN Resnet-50, VGG19 dan Mobilenet dalam Klasifikasi Penyakit pada Tamnaman Mete. *Jurnal Locus Penelitian dan Pengabdian*, 4(8), 7903–7918. <https://doi.org/10.58344/locus.v4i8.4261>
- Benita Suciani, A., Gunawansyah, G., & Maulana Adhinugraha, K. (2024). Klasifikasi Jenis Batik Menggunakan Algoritma K-Nearest Neighbors (KNN). *Infotronik: Jurnal Teknologi Informasi dan Elektronika*, 9(2), 83–89. <https://doi.org/10.32897/infotronik.2024.9.2.3846>
- Dewi, S., Ramadhani, F., & Djasmayena, S. (2024). Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network). *Hello World Jurnal Ilmu Komputer*, 3(2), 68–73. <https://doi.org/10.56211/helloworld.v3i2.518>
- Dharmasisya, ", Fakultas, J., Zulfikar, R., & Putra, S. (2022). Upaya Pemerintah Terhadap Perlindungan Ekspresi Budaya Tradisional Batik Motif Parang Sebagai Warisan Budaya Dunia. *Jurnal Program Magister Hukum FHUI*, 1, 40.
- Elzandy, I., Yulia Puspaningrum, E., & Lina Nurlaili, A. (2025). Klasifikasi Varietas Anggur Berdasarkan Citra Daun Menggunakan VGG16-XGBOOST. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(3), 5483–5491. <https://doi.org/10.36040/jati.v9i3.14309>
- Filia, B. J., Lienardy, F. F., Laksana, I. K. P. B., Jordan, J. A., Siento, J. G., Honova, S. M., Hasana, S., & Permonangan, I. H. (2023). Improving Batik Pattern Classification using CNN with Advanced Augmentation and Oversampling on Imbalanced Dataset. *Procedia Computer Science*, 227, 508–517. <https://doi.org/10.1016/j.procs.2023.10.552>
- Hassa. (2024). *Batik Sogan, Mengenal Sejarah, Asal, dan Makna Filosofinya*. <https://hassa.co.id/batik-sogan/>
- Jasmine, N. A. (2024, Oktober). *Sejarah dan Asal-usul Batik, Warisan Budaya Indonesia yang Diakui UNESCO*. <https://www.detik.com/jogja/budaya/d-7568290/sejarah-dan-asal-usul-batik-warisan-budaya-indonesia-yang-diakui-unesco>
- Kumala, R. A., Sari, C. A., & Rachmawanto, E. H. (2025). A Comparison of MobileNetV2 and VGG16 Architectures with Transfer Learning for Multi-Class Image-Based Waste Classification. *Journal of Applied Informatics and Computing*, 9(4), 1610–1624. <https://doi.org/10.30871/jaic.v9i4.9958>
- Kurniawan, M. D., & Widagdo, J. (2024). Kajian Makna Dan Sejarah Desain Motif Truntum (Sebagai Media Pembelajaran Hidup). *Jurnal Pendidikan Integrasi*, 5(3). <https://ejournals.com/ojs/index.php/jpi>
- Kusanti, J., Noersasongko, E., Soeleman, M. A., Alzami, F., Purwanto, & Hasibuan, Z. A. (2023). Pre-Processing Of Resize And Region Of Interest (ROI) To Improve The Accuracy Of Batik Detection Based On VGG-16. *2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, 242–247. <https://doi.org/10.1109/EECSI59885.2023.10295666>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Ma'ruf, M. T., Putra, E. D., Reswan, Y., & Juhardi, U. (2023). Classification Of Besurek Batik Fabrics Using Gray Level Co-Occurrence Matrix (GLCM) Features Extraction. *Jurnal Komputer, Informasi dan Teknologi*, 3(2). <https://doi.org/10.53697/jkomitek.v3i2.1211>
- Merangi, D. G. T., Yudistira, N., & Sari, Y. A. (2022). Batik Classification Using Convolutional Neural Network with Data Improvements. *JOIV: International Journal on Informatics Visualization*, 6(1), 6. <https://doi.org/10.30630/joiv.6.1.716>
- Mienye, I. D., & Swart, T. G. (2024). A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. *Information*, 15(12), 755. <https://doi.org/10.3390/info15120755>
- Murinto, M., Rosyda, M., & Melany, M. (2023). Klasifikasi Jenis Biji Kopi Menggunakan Convolutional Neural Network dan Transfer Learning pada Model VGG16 dan MobileNetV2. *JRST (Jurnal Riset Sains dan Teknologi)*, 7(2), 183. <https://doi.org/10.30595/jrst.v7i2.16788>
- Nathani, S. (2024). *A Comparative Study of Transfer Learning for Emotion Recognition using CNN and Modified VGG16 Models*. <https://doi.org/https://doi.org/10.48550/arXiv.2407.14576>
- Nikmah, F., Sukma, E. A., & Arjo, T. R. (2024). *Rekaman Informasi Arsip Batik Berbasis Web*. Polinema Press.
- Rizky Rahmalia Ivani, A., Zulfi Kurniadi, A., Belia Auly Andira, A., Wahyuni, I., Studi Teknik Informatika, P., Teknologi dan Desain, F., & Teknologi dan Bisnis Asia Malang, I. (2025). Perbandingan VGG16 dan MobileNetV2 untuk Klasifikasi Tingkat Kematangan Buah Apel. *Jurnal Sistem Komputer Asia (JISKOMSIA)*, 3(1). <https://doi.org/https://doi.org/10.32815/jiskomsia.v3i1.136>
- Tebo, B. P. S. K. (2025). *Hari Batik Nasional 2025*. <https://tebokab.bps.go.id/id/news/2025/10/02/64/hari-batik-nasional-2025.html>
- UMKM, K. (2025). *Semakin Diminati, Bisnis Batik Makin Prospektif*. <https://umkm.go.id/news/mcsossnwob44f3kw9mdp7cnz>
- Yu, F., Zhang, Q., Xiao, J., Ma, Y., Wang, M., Luan, R., Liu, X., Ping, Y., Nie, Y., Tao, Z., & Zhang, H. (2023). Progress in the Application of CNN-Based Image Classification and Recognition in Whole Crop Growth Cycles. *Remote Sensing*, 15(12), 2988. <https://doi.org/10.3390/rs15122988>