

# Klasifikasi Motif Batik Yogyakarta dan Pekalongan Menggunakan Metode GLCM dan CNN Berbasis Arsitektur EfficientNet

Mikhail Shams Afzal Karim<sup>1</sup>, Albi Akhsanul Hakim<sup>2\*</sup>, Chesa Saskia Rafika<sup>3</sup>, Eva Yulia Puspaningrum, S.Kom., M.Kom<sup>4</sup>

<sup>1,2,3,4</sup>Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

<sup>1</sup>[22081010169@student.upnjatim.ac.id](mailto:22081010169@student.upnjatim.ac.id)

<sup>3</sup>[22081010211@student.upnjatim.ac.id](mailto:22081010211@student.upnjatim.ac.id)

<sup>4</sup>[evapuspaningrum.if@upnjatim.ac.id](mailto:evapuspaningrum.if@upnjatim.ac.id)

\*Corresponding author email: [22081010194@student.upnjatim.ac.id](mailto:22081010194@student.upnjatim.ac.id)

**Abstrak**— Batik merupakan warisan budaya Indonesia yang memiliki nilai seni tinggi dan kekayaan visual khas, terutama pada motif-motif tradisional dari Yogyakarta dan Pekalongan. Keunikan pola dan tekstur batik menjadikannya menarik untuk dikaji melalui pengolahan citra digital berbasis kecerdasan buatan. Penelitian ini bertujuan mengembangkan sistem klasifikasi motif batik berdasarkan asal daerah menggunakan kombinasi metode Gray Level Co-occurrence Matrix (GLCM) dan Convolutional Neural Network (CNN) berbasis arsitektur EfficientNetB0. Dataset yang digunakan terdiri dari 256 citra batik (125 Yogyakarta dan 131 Pekalongan), yang diperluas melalui augmentasi menjadi 759 citra. Skema eksperimen melibatkan pelatihan tiga model: GLCM + SVM, CNN murni, dan gabungan GLCM + CNN. Hasil evaluasi menunjukkan bahwa model gabungan GLCM + CNN memberikan akurasi tertinggi sebesar 97% dan nilai loss terendah, dibandingkan CNN murni (96,05%) dan GLCM + SVM (76%). Temuan ini menunjukkan bahwa integrasi fitur tekstur (GLCM) dan fitur visual (CNN) secara sinergis meningkatkan akurasi dan stabilitas prediksi. Pendekatan ini efektif untuk klasifikasi citra objek budaya dengan tekstur kompleks seperti batik dan memiliki potensi diterapkan dalam pengembangan sistem pengenalan motif digital berbasis kecerdasan buatan.

**Kata Kunci**— Batik, CNN, GLCM, Klasifikasi Citra, Pengolahan Citra Digital.

## I. PENDAHULUAN

Batik merupakan warisan budaya Indonesia yang telah diakui oleh UNESCO pada 2 Oktober 2009 sebagai bagian dari *Representative List of the Intangible Cultural Heritage of Humanity* [1]. Sebagai objek visual, batik memiliki kompleksitas pola dan tekstur yang tinggi, terutama pada motif-motif khas daerah seperti Yogyakarta dan Pekalongan. Perbedaan karakteristik visual antar daerah ini menjadikan batik sebagai subjek yang menarik untuk dikaji melalui pendekatan pengolahan citra dan kecerdasan buatan, khususnya dalam pengembangan sistem klasifikasi citra digital.

Untuk mengatasi tantangan klasifikasi motif yang kompleks, diperlukan metode ekstraksi fitur yang mampu menangkap informasi visual secara efektif. Salah satu metode yang banyak digunakan adalah *Gray Level Co-occurrence Matrix (GLCM)*, yaitu teknik statistik yang menganalisis hubungan spasial antar piksel dalam citra untuk mengekstrak fitur tekstur. Melalui GLCM, dapat diperoleh parameter tekstur seperti *contrast*,

*correlation*, *energy*, dan *homogeneity* yang mewakili karakteristik pola dalam citra. Keunggulan GLCM terletak pada kemampuannya menangkap informasi tekstur halus yang tidak terlihat secara langsung, sehingga cocok untuk membedakan motif batik yang memiliki keragaman pola tinggi. Penelitian sebelumnya menunjukkan bahwa GLCM mampu membedakan motif batik secara efektif, meskipun berasal dari jenis batik yang sama [2]. Namun, penelitian tersebut tidak menyajikan hasil kuantitatif evaluasi klasifikasi seperti akurasi, presisi, atau recall, dan hanya fokus pada tahap ekstraksi fitur. Seiring berkembangnya teknologi *deep learning*, khususnya *Convolutional Neural Network (CNN)*, metode klasifikasi citra menjadi semakin akurat dan efisien. Salah satu arsitektur CNN yang menonjol adalah *EfficientNet*, yang diperkenalkan oleh Google pada tahun 2019. Arsitektur ini mengadopsi pendekatan *compound scaling* untuk menyeimbangkan kedalaman, lebar, dan resolusi model, sehingga dapat meningkatkan akurasi tanpa menambah beban komputasi secara berlebihan. Penelitian sebelumnya menunjukkan bahwa *EfficientNet* mampu mengklasifikasikan motif batik dengan akurasi hingga 98% [3], menjadikannya pilihan yang tepat untuk tugas klasifikasi citra dengan kompleksitas visual tinggi seperti batik.

Penggabungan antara metode GLCM dan CNN telah diteliti dalam sebuah studi yang berhasil mencapai akurasi hingga 99% dalam mengidentifikasi motif batik [4]. Hasil ini menunjukkan bahwa kombinasi antara fitur tekstur dari GLCM dan fitur visual dari CNN dapat saling melengkapi dalam meningkatkan performa klasifikasi. Namun demikian, penelitian tersebut hanya berfokus pada pengenalan berbagai motif batik dari Yogyakarta, seperti motif ceplok, kawung, parang, dan lain-lain.

Berbeda dari studi tersebut, penelitian ini bertujuan untuk mengklasifikasikan batik berdasarkan asal daerahnya, yaitu membedakan apakah suatu motif berasal dari Yogyakarta atau Pekalongan, dua daerah yang memiliki ciri visual yang sangat berbeda. Selain memperluas cakupan klasifikasi, penelitian ini juga menggunakan arsitektur *EfficientNet*, yang meskipun lebih kompleks dibandingkan *MobileNet* yang digunakan dalam studi sebelumnya, telah menunjukkan performa akurasi yang lebih tinggi dalam berbagai tugas klasifikasi. Dengan menggabungkan metode GLCM dan CNN serta memperluas ruang lingkup klasifikasi, penelitian ini diharapkan dapat

memberikan kontribusi baru dalam pengembangan sistem klasifikasi motif batik berbasis citra digital.

## II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan memanfaatkan teknik pengolahan citra digital untuk mengklasifikasikan motif batik Yogyakarta dan Pekalongan. Metode ini dipilih karena mampu memberikan hasil yang objektif dan terukur dalam menganalisis perbedaan tekstur visual antar motif batik. Penelitian ini terdiri dari beberapa tahapan utama, yaitu akuisisi data, preprocessing, ekstraksi fitur menggunakan *Gray Level Co-occurrence Matrix (GLCM)*, klasifikasi menggunakan *Convolutional Neural Network (CNN)*, dan evaluasi model.

### A. Landasan Teori

#### 1) *Gray Level Co-occurrence Matrix (GLCM)*

*Gray Level Co-occurrence Matrix (GLCM)* merupakan metode analisis tekstur yang menghitung atribut seperti kontras, ketidaksamaan, keseragaman, energi, dan korelasi untuk menggambarkan struktur lokal dalam citra. Metode ini banyak digunakan dalam berbagai bidang, termasuk pengenalan pola, klasifikasi citra, hingga analisis medis, seperti dalam mendeteksi pola-pola anomali pada gambar medis. Oleh karena itu, GLCM menjadi alat yang sangat penting dalam memahami serta memanfaatkan hubungan spasial antar-piksel, termasuk dalam membedakan batik Yogyakarta dan Pekalongan.

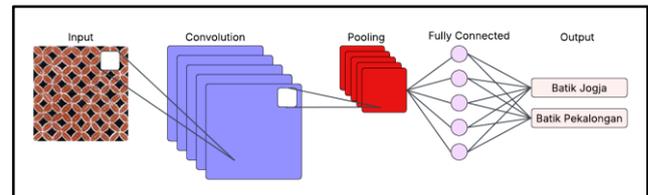
Penggunaan GLCM dalam klasifikasi motif batik sangat relevan, karena fitur tekstur yang dihasilkannya mampu menangkap perbedaan halus antar pola yang mungkin sulit diamati secara visual. Dalam motif batik yang kompleks dan detail, GLCM membantu dalam mengenali pola, arah, serta keteraturan motif. Kemampuan ini dapat meningkatkan kinerja model deep learning seperti EfficientNet, terutama dalam kondisi jumlah data pelatihan yang terbatas.

Sebagai langkah pengolahan, citra motif batik dikonversi ke dalam skala abu-abu (grayscale), di mana setiap piksel memiliki nilai intensitas antara 0 (hitam) hingga 255 (putih). Konversi ini merupakan tahap krusial karena metode GLCM hanya dapat diterapkan pada citra grayscale, dengan cara menganalisis hubungan antar piksel berdasarkan intensitasnya. Transformasi dari citra berwarna ke grayscale memungkinkan fokus analisis diarahkan pada tekstur dan pola, tanpa terpengaruh oleh variasi warna. Pendekatan ini menyederhanakan proses ekstraksi fitur, namun tetap mempertahankan informasi penting tentang keteraturan dan keragaman pola dalam motif batik, yang sangat relevan untuk keperluan klasifikasi.

#### 2) *Convolutional Neural Network (CNN)*

*Convolutional Neural Network (CNN)* merupakan jenis jaringan saraf tiruan yang dirancang khusus untuk mengolah data berbentuk grid seperti gambar. CNN sangat handal dalam mengekstraksi dan mengenali pola visual, mulai dari fitur dasar seperti tepi dan garis hingga pola yang lebih kompleks seperti bentuk dan motif. Dalam penelitian ini, CNN digunakan untuk mengklasifikasikan motif batik berdasarkan karakteristik pola dan teksturnya yang khas.

Arsitektur CNN terdiri dari beberapa lapisan utama, yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*. Lapisan *convolutional* berfungsi untuk mengekstraksi fitur dari citra input dengan menerapkan filter yang bergerak melintasi gambar, sehingga menghasilkan peta fitur yang merepresentasikan pola penting. Kemudian, *pooling layer* bertugas mengurangi dimensi spasial dari peta fitur tersebut sambil mempertahankan informasi utama, yang membantu mengurangi kompleksitas perhitungan dan mencegah *overfitting*. Setelah proses ekstraksi, fitur-fitur tersebut diteruskan ke *fully connected layer* yang mengintegrasikan seluruh informasi menjadi sebuah vektor fitur untuk menghasilkan output berupa prediksi kelas jenis batik.



Gbr. 1 Ilustrasi arsitektur CNN pada penelitian ini.

Ilustrasi pada Gbr. 1 menunjukkan tahapan proses klasifikasi motif batik yang dilakukan oleh *Convolutional Neural Network (CNN)*. Gambar motif batik sebagai citra input pertama-tama diproses melalui *convolution layer*, yang berfungsi untuk mendeteksi fitur-fitur dasar seperti garis, tepi, dan pola-pola sederhana. Setiap *convolution layer* diikuti oleh fungsi aktivasi *ReLU*, yang berperan dalam mempercepat proses pelatihan serta meningkatkan kemampuan jaringan dalam mengenali pola yang lebih kompleks. Peta fitur yang dihasilkan kemudian diproses melalui *pooling layer* untuk mereduksi dimensi data, sambil tetap mempertahankan informasi penting. Setelah melewati seluruh rangkaian layer tersebut, peta fitur diubah menjadi vektor melalui *fully connected layer* dan diteruskan ke *output layer*, yang menghasilkan prediksi klasifikasi berupa jenis motif batik.

#### 3) *Transfer Learning*

*Transfer learning* adalah teknik dalam pembelajaran mesin yang memungkinkan penggunaan kembali model yang telah dilatih pada suatu dataset besar untuk menyelesaikan tugas baru pada dataset yang berbeda, dengan sedikit penyesuaian. Pendekatan ini sangat bermanfaat dalam situasi di mana ketersediaan data berlabel terbatas, seperti pada klasifikasi motif batik. Dengan memanfaatkan pengetahuan yang telah dipelajari dari dataset besar dan umum, seperti ImageNet, model dapat mempercepat proses pelatihan dan tetap mencapai tingkat akurasi yang tinggi meskipun hanya menggunakan dataset pelatihan yang relatif kecil.

Dalam penelitian ini, digunakan arsitektur *EfficientNet* sebagai dasar model CNN. *EfficientNet* dikenal sebagai arsitektur yang efisien dan akurat, dengan pendekatan skala model yang seimbang melalui pengaturan parameter kedalaman (*depth*), lebar (*width*), dan resolusi input. Model ini telah dilatih sebelumnya pada dataset besar seperti *ImageNet*, sehingga membawa pengetahuan awal mengenai pola umum dalam citra. Proses transfer learning dimulai dengan mengadaptasi model *EfficientNet* pralatih pada dataset motif batik. Langkah

selanjutnya adalah melakukan *fine-tuning*, yaitu penyesuaian lapisan-lapisan tertentu dalam jaringan untuk mengoptimalkan performa terhadap data baru. Umumnya, lapisan awal yang bertugas mengenali fitur dasar seperti tepi, garis, dan bentuk dibiarkan tetap karena bersifat umum, sedangkan lapisan-lapisan yang lebih dalam disesuaikan agar mampu mengenali karakteristik khusus dari motif batik Yogyakarta dan Pekalongan.

Dengan pendekatan ini, model dapat memanfaatkan keunggulan arsitektur *EfficientNet* dalam efisiensi dan akurasi, serta tetap relevan terhadap konteks spesifik klasifikasi motif batik melalui proses *fine-tuning* yang terarah.

#### 4) *EfficientNet*

*EfficientNet* adalah sebuah arsitektur deep learning yang diperkenalkan oleh Google pada tahun 2019 untuk berbagai tugas visi komputer (computer vision). Keunggulan utamanya terletak pada metode compound scaling, sebuah teknik penskalaan yang secara simultan dan seimbang mengoptimalkan tiga dimensi model: kedalaman (depth), lebar (width), dan resolusi citra. Pendekatan ini terbukti mampu meningkatkan akurasi dan efisiensi secara signifikan.

Dalam penelitian ini, varian yang digunakan adalah *EfficientNetB0*. Sebagai model dasar dalam seri *EfficientNet*, arsitektur ini dirancang untuk memberikan efisiensi komputasi yang tinggi dengan jumlah parameter yang minimal. Meskipun memiliki arsitektur yang ringkas, *EfficientNetB0* tetap mampu menghasilkan akurasi yang sangat kompetitif, menjadikannya solusi ideal untuk aplikasi klasifikasi citra yang dibatasi oleh sumber daya komputasi.

Berkat kemampuannya dalam mengekstraksi fitur visual yang kompleks dan beragam, arsitektur *EfficientNetB0* menjadi pilihan yang tepat untuk tugas klasifikasi motif batik Yogyakarta dan Pekalongan. Kemampuan ini memungkinkannya mengenali perbedaan subtil antara kedua motif, bahkan pada citra dengan variasi tekstur dan detail yang rumit, sehingga dapat menghasilkan klasifikasi yang akurat.

#### B. Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan dengan menggunakan dataset yang diperoleh dari platform Kaggle, dengan sumber yang spesifik dari tiga dataset yang relevan. Ketiga dataset tersebut adalah:

- *Indonesian Batik Motifs* oleh Dionisiusdh [11]
- *Batik Nusantara - Batik Indonesia Dataset* oleh Hendryhb [12]
- *Batik Motifs* oleh Hamdanielikhsan [13]

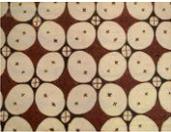
Dataset tersebut terdiri dari dua kelas, yaitu motif batik Yogyakarta (Jogja) dan Pekalongan. Jumlah citra pada masing-masing kelas adalah 125 gambar untuk kelas Jogja dan 128 gambar untuk kelas Pekalongan. Seluruh gambar yang diunduh dari Kaggle dipilih secara selektif dengan mempertimbangkan kesesuaian motif dan kualitas resolusi, guna memastikan bahwa data yang digunakan representatif dan relevan dengan tujuan klasifikasi. Dataset ini kemudian digunakan sebagai dasar dalam proses pelatihan dan pengujian model klasifikasi motif batik berdasarkan asal daerahnya.

Batik Yogyakarta, atau yang dikenal dengan Batik Jogja, merupakan salah satu jenis batik tradisional yang berasal dari

Daerah Istimewa Yogyakarta. Ciri khas batik ini terletak pada penggunaan warna-warna klasik seperti hitam, putih, dan coklat sogan, serta pola geometris yang simetris dan penuh makna filosofis. Motif-motifnya sering kali mencerminkan nilai-nilai kehidupan, kebijaksanaan, serta kearifan lokal masyarakat Jawa. Beberapa motif yang terkenal antara lain Parang, Kawung, dan Ceplok, yang pada masa lalu hanya boleh dikenakan oleh kalangan bangsawan atau keluarga keraton sebagai simbol status sosial dan budaya.

Batik Pekalongan, di sisi lain, merupakan jenis batik yang berasal dari kota Pekalongan di Jawa Tengah dan dikenal dengan kekayaan warna serta keragaman motifnya. Berbeda dengan batik Jogja yang bersifat lebih kaku dan simetris, batik Pekalongan memiliki corak yang lebih dinamis dan ekspresif, sering mengangkat unsur flora dan fauna dalam desainnya. Warna-warna cerah seperti merah, kuning, biru, dan hijau menjadi ciri khas batik ini, mencerminkan pengaruh budaya asing yang masuk melalui jalur perdagangan karena posisi geografis Pekalongan sebagai kota pelabuhan. Motif-motif seperti Jlamprang, Buketan, dan Terang Bulan menjadi cerminan kreativitas dan kekayaan budaya masyarakat pesisir.

TABEL I. GAMBAR MOTIF BATIK

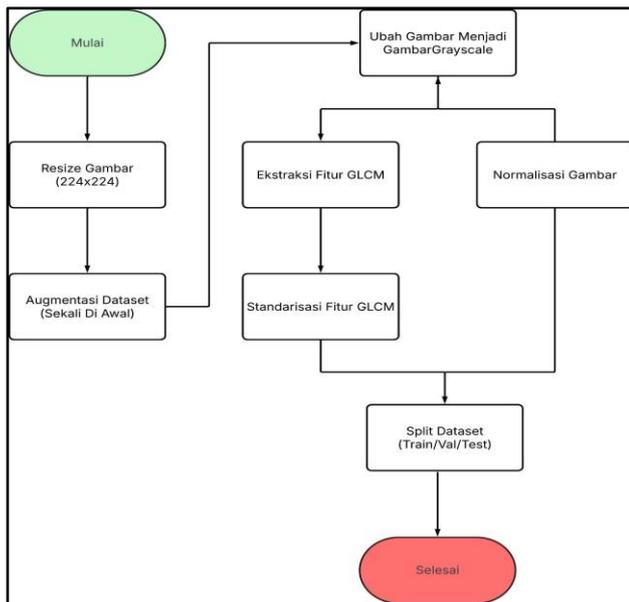
No	Nama Batik	Motif Batik
1	Batik Jogja	
2	Batik Pekalongan	

#### C. Preprocessing

Tahapan preprocessing dalam penelitian ini dirancang untuk mempersiapkan dataset citra batik agar dapat digunakan secara optimal, baik untuk proses ekstraksi fitur tekstur menggunakan Gray Level Co-occurrence Matrix (GLCM) maupun untuk pelatihan model klasifikasi menggunakan Convolutional Neural Network (CNN). Seluruh citra batik terlebih dahulu diubah ukurannya menjadi resolusi tetap 224×224 piksel, sesuai dengan kebutuhan input model CNN *EfficientNetB0* yang digunakan dalam penelitian ini. Penyamaan resolusi ini bertujuan untuk memastikan konsistensi dimensi antar citra dan kompatibilitas dengan arsitektur CNN.

Setelah proses *resize*, dilakukan tahap augmentasi data guna memperkaya variasi visual dalam dataset. Augmentasi dilakukan satu kali di awal dan hasilnya disimpan secara permanen dalam folder khusus agar seluruh proses pelatihan model menggunakan dataset augmentasi yang konsisten. Teknik augmentasi yang digunakan meliputi *horizontal flip* (80%), *random brightness and contrast* (80%), rotasi acak hingga  $\pm 15^\circ$  (70%), dan *affine transformation* (75%). Setiap citra menghasilkan satu versi asli dan dua versi hasil augmentasi, sehingga dataset awal yang terdiri dari 256 citra

berkembang menjadi 759 citra (375 batik Yogyakarta dan 384 batik Pekalongan).



Gbr. 2 Flowchart Proses Preprocessing.

Setelah augmentasi, citra diproses melalui dua jalur berbeda sesuai kebutuhan metode analisis, yaitu jalur GLCM dan jalur CNN, sebagaimana ditunjukkan pada Gbr 2.

- Pada jalur GLCM, citra yang telah diaugmentasi dikonversi ke grayscale, karena metode GLCM hanya dapat diterapkan pada citra skala abu-abu. Setelah dikonversi, dihitung lima parameter tekstur utama: contrast, dissimilarity, homogeneity, energy, dan correlation. Parameter-parameter ini dihitung pada berbagai jarak (1, 2, dan 3 piksel) dan orientasi sudut (0°, 45°, 90°, dan 135°) untuk menangkap informasi tekstur yang menyeluruh. Nilai-nilai dari seluruh kombinasi dirata-ratakan, menghasilkan vektor fitur tekstur yang mewakili setiap citra secara komprehensif.
- Pada jalur CNN, citra tetap dalam format RGB dan tidak dikonversi ke grayscale. Sebaliknya, dilakukan proses normalisasi menggunakan nilai rata-rata dan standar deviasi dari dataset ImageNet, sesuai standar input pada model EfficientNetB0 yang telah dilatih sebelumnya (pretrained). Normalisasi ini bertujuan untuk meningkatkan stabilitas pelatihan model dan mempercepat konvergensi.

Setelah kedua jalur pemrosesan selesai, fitur tekstur dari jalur GLCM dan fitur visual dari jalur CNN kemudian digabungkan (concatenated) untuk membentuk representasi fitur gabungan. Proses penggabungan ini memungkinkan model memanfaatkan kekuatan kedua pendekatan: GLCM yang fokus pada detail tekstur halus, dan CNN yang fokus pada pola visual spasial. Seluruh dataset kemudian dibagi menjadi *train set* dan *test set* dengan rasio 80:20. *Train set* dibagi lagi menjadi *train* dan *validation set* dengan rasio yang sama. Pembagian dilakukan secara acak agar model tidak terpengaruh urutan data, dan memungkinkan evaluasi performa yang adil.

Dengan pemisahan jalur grayscale (untuk GLCM) dan RGB (untuk CNN), proses preprocessing ini memastikan bahwa setiap metode menerima format input yang tepat, serta menghasilkan fitur yang dapat dikombinasikan secara optimal dalam model klasifikasi motif batik.

#### D. Pembuatan Model

Penelitian ini menggunakan pendekatan arsitektur model hibrida yang menggabungkan kekuatan dua jenis fitur, yaitu fitur tekstur dari metode Gray-Level Co-occurrence Matrix (GLCM) dan fitur visual spasial dari Convolutional Neural Network (CNN) berbasis EfficientNetB0. Kedua jalur pemrosesan data ini berjalan secara paralel dan saling melengkapi dalam membentuk representasi fitur yang lebih kaya dan informatif.

Setelah proses augmentasi dan pemrosesan awal (sebagaimana dijelaskan pada bagian sebelumnya), citra diproses melalui dua jalur utama.

- Jalur GLCM: citra hasil augmentasi dikonversi ke grayscale, kemudian dihitung parameter teksturnya menggunakan metode GLCM. Lima parameter utama—contrast, dissimilarity, homogeneity, energy, dan correlation—diekstraksi dari berbagai kombinasi jarak dan orientasi, lalu dirata-ratakan untuk membentuk vektor fitur tekstur.
- Jalur CNN: citra dalam format RGB dinormalisasi sesuai standar ImageNet, lalu dimasukkan ke dalam model CNN EfficientNetB0. Model CNN ini bertugas mengekstraksi fitur visual spasial melalui lapisan convolutional hingga menghasilkan vektor fitur akhir dari lapisan fully connected.

Setelah kedua jalur menghasilkan output masing-masing, dilakukan proses penggabungan (concatenation) antara vektor fitur GLCM dan vektor fitur CNN. Vektor gabungan ini kemudian diteruskan ke lapisan fully connected tambahan, yang berfungsi untuk mengorganisasi ulang informasi, dilengkapi dengan fungsi aktivasi ReLU untuk meningkatkan kapasitas non-linearitas dan lapisan dropout untuk mencegah overfitting.

Proses klasifikasi akhir dilakukan pada output layer, dengan jumlah neuron sesuai jumlah kelas target (dua kelas: batik Yogyakarta dan batik Pekalongan). Dengan struktur ini, model mampu memanfaatkan secara maksimal informasi tekstur mikro dari GLCM dan pola visual makro dari CNN, menjadikannya lebih tangguh dalam menghadapi variasi motif batik.

#### E. Evaluasi

Pada tahap evaluasi model dilakukan menggunakan empat metrik utama, yaitu accuracy, precision, recall, dan F1-score. Keempat metrik ini dihitung berdasarkan empat komponen penting dalam klasifikasi, yaitu:

True Positive (TP): jumlah data motif batik yang benar-benar berasal dari suatu kelas (misalnya Yogyakarta) dan diklasifikasikan dengan benar oleh model sebagai kelas tersebut.

True Negative (TN): jumlah data yang bukan berasal dari kelas tersebut dan juga diklasifikasikan dengan benar sebagai bukan kelas tersebut.

False Positive (FP): jumlah data yang seharusnya bukan dari kelas tersebut, namun salah diklasifikasikan oleh model sebagai kelas tersebut.

False Negative (FN): jumlah data yang sebenarnya berasal dari kelas tersebut, tetapi gagal dikenali oleh model (dikelompokkan ke kelas lain).

Metrik ini memberikan gambaran yang menyeluruh terhadap performa model, terutama dalam konteks klasifikasi motif batik yang memiliki karakteristik data beragam dan kemungkinan ketidakseimbangan antar kelas.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

Metrik pertama, accuracy, mengukur proporsi prediksi yang benar dari keseluruhan prediksi yang dilakukan oleh model. Meskipun memberikan gambaran umum tentang kinerja model, accuracy memiliki keterbatasan, terutama saat menghadapi dataset yang tidak seimbang. Dalam kondisi di mana satu kelas lebih dominan, model bisa saja menunjukkan nilai accuracy yang tinggi meskipun gagal mengenali kelas minoritas. Rumus perhitungannya adalah jumlah True Positive dan True Negative dibagi dengan total keseluruhan prediksi (TP + TN + FP + FN). Oleh karena itu, accuracy perlu dilengkapi dengan metrik lain untuk menilai performa model secara lebih komprehensif.

$$Precision = \frac{TP}{(TP+FP)}$$

Selanjutnya, precision digunakan untuk menilai seberapa akurat model dalam memprediksi kelas positif. Dalam konteks pengenalan motif batik, precision menunjukkan seberapa sering prediksi motif tertentu memang benar adanya, tanpa tercampur dengan motif lain. Nilainya dihitung dengan membagi True Positive dengan jumlah seluruh prediksi positif (TP + FP). Nilai precision yang tinggi mengindikasikan bahwa model jarang melakukan kesalahan dalam mengklasifikasikan motif (false positive), yang sangat penting dalam aplikasi yang menuntut ketepatan tinggi.

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

Metrik recall mengukur kemampuan model dalam menemukan seluruh kasus positif yang sebenarnya ada dalam data. Hal ini menjadi krusial terutama ketika kehilangan prediksi positif (false negative) harus dihindari. Dalam klasifikasi motif batik, recall memastikan bahwa model mampu mengenali sebagian besar motif yang seharusnya terdeteksi. Rumus perhitungannya adalah TP dibagi dengan jumlah data positif aktual (TP + FN). Nilai recall yang tinggi menunjukkan bahwa hanya sedikit motif yang terlewatkan oleh model.

$$F1-Score = 2 \times \frac{(Precision \times Recall)}{(Precision+Recall)}$$

Terakhir, F1-score merupakan metrik gabungan yang merepresentasikan keseimbangan antara precision dan recall. Perhitungannya dilakukan dengan rumus  $2 \times ((precision \times recall) / (precision + recall))$ . Metrik ini sangat berguna dalam kondisi di mana distribusi data tidak merata, karena memberikan evaluasi yang seimbang antara ketepatan dan cakupan prediksi. Dalam pengenalan motif batik, F1-score

membantu memastikan bahwa model tidak hanya akurat dalam memprediksi, tetapi juga tanggap terhadap semua kelas, termasuk kelas dengan jumlah data yang lebih sedikit.

Dengan menggunakan keempat metrik ini, evaluasi model tidak hanya fokus pada ketepatan secara umum, tetapi juga pada kualitas prediksi untuk masing-masing kelas motif. Pendekatan ini memungkinkan analisis yang lebih mendalam terhadap kekuatan dan kelemahan model dalam mengenali berbagai pola motif, sehingga hasil klasifikasi menjadi lebih andal dan representatif terhadap karakteristik data yang sebenarnya.

#### F. Eksperimen

Pada tahap eksperimen dalam penelitian ini, rancangan pengujian disusun untuk mengevaluasi performa tiga model klasifikasi motif batik, yaitu: model SVM dengan input parameter GLCM, model CNN berbasis arsitektur EfficientNetB0, dan model CNN (EfficientNetB0) yang dikombinasikan dengan input parameter GLCM. Seluruh model diuji pada dataset yang sama, dengan pembagian data menjadi train set dan test set menggunakan rasio 80:20. Selanjutnya, train set dibagi kembali menjadi train dan validation set dengan rasio yang sama, sehingga model memperoleh data pelatihan yang cukup, sekaligus menyediakan data validasi dan pengujian yang representatif untuk mengevaluasi kemampuan generalisasi.

Untuk model SVM berbasis parameter GLCM, pelatihan dilakukan dengan pendekatan *grid search* dan *5-fold cross-validation* untuk memperoleh kombinasi parameter terbaik. Pemilihan SVM didasarkan pada keunggulannya dalam menangani data berdimensi tinggi dan jumlah data yang relatif kecil. SVM bekerja dengan mencari hyperplane optimal untuk memisahkan kelas secara maksimal, menjadikannya cocok untuk fitur tekstur GLCM yang kaya informasi namun tidak memerlukan jumlah data besar. Selain itu, SVM dikenal memiliki kemampuan generalisasi yang baik dan cenderung lebih tahan terhadap overfitting dibandingkan beberapa algoritma lainnya, terutama saat bekerja dengan dataset terbatas.

Untuk dua model CNN, proses pelatihan dilakukan selama maksimal 50 epoch dengan menerapkan *early stopping* guna mencegah pelatihan berlebih (*overfitting*) dan menghindari pelatihan yang tidak memberikan peningkatan signifikan. Proses training menggunakan *optimizer Stochastic Gradient Descent (SGD)*. Pemilihan SGD didasarkan pada karakteristik dataset yang relatif kecil, sehingga penggunaan optimizer lain seperti Adam yang cepat beradaptasi dapat menyebabkan model terlalu cepat konvergen pada minimum lokal dan meningkatkan risiko overfitting. SGD menawarkan proses pembelajaran yang lebih stabil dan bertahap, serta lebih fleksibel dalam pengaturan hiperparameter seperti momentum, yang dapat membantu mempercepat konvergensi tanpa kehilangan kestabilan pelatihan. Kombinasi penggunaan SGD dan *early stopping* memberikan kontrol yang lebih baik dalam pelatihan dan meningkatkan kemampuan generalisasi model. Selain itu, pada model gabungan CNN dan GLCM, fitur tekstur hasil ekstraksi GLCM digabungkan dengan fitur visual dari CNN untuk meningkatkan akurasi klasifikasi, terutama dalam mengenali motif batik yang memiliki detail dan pola halus.

Selama proses pelatihan, dilakukan pemantauan terhadap akurasi dan loss pada data training dan validation untuk menilai apakah model belajar secara efektif tanpa mengalami overfitting. Evaluasi akhir dilakukan pada data testing menggunakan metrik evaluasi utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik-metrik ini memberikan gambaran menyeluruh tentang kemampuan model dalam mengenali jenis batik.

### III. HASIL DAN PEMBAHASAN

#### A. Hasil Training Model

Model GLCM dikombinasikan dengan algoritma klasifikasi SVM, dan proses pelatihnnya dilakukan menggunakan teknik grid search dengan *5-fold cross-validation* untuk menemukan parameter terbaik. Hasil terbaik diperoleh dengan skor rata-rata *cross-validation* sebesar 81,38%, tanpa menggunakan dataset validasi eksplisit.

Sementara itu, model CNN dan model hybrid GLCM + CNN dilatih menggunakan arsitektur jaringan saraf dalam yang dilengkapi dengan data validasi terpisah. Nilai loss dan akurasi yang dicantumkan pada tabel merupakan hasil dari proses evaluasi terhadap data validasi selama pelatihan. Tabel-tabel berikut menyajikan hasil yang diperoleh selama proses pelatihan masing-masing model terhadap dataset citra batik Yogyakarta dan Pekalongan.

TABEL 2. HASIL PELATIHAN MODEL GLCM (SVM) DENGAN GRID SEARCH

No	Model	Skema Evaluasi	Akurasi (CV)
1	GLCM (SVM)	5-Fold Cross-Validation	81,38%

TABEL 3. HASIL EVALUASI MODEL CNN DAN GLCM + CNN PADA DATA VALIDASI

No	Model	Loss	Akurasi
1	CNN	0,0278	98,6%
2	GLCM + CNN	0,0079	98,03%

Berdasarkan hasil evaluasi selama proses pelatihan menggunakan teknik grid search dengan *5-fold cross-validation*, model GLCM yang dilatih menggunakan algoritma SVM memperoleh skor akurasi rata-rata sebesar 81,38%. Karena SVM tidak menggunakan fungsi loss yang sama seperti pada model jaringan saraf tiruan, maka tidak dihasilkan nilai loss dalam proses pelatihan ini. Hasil ini mengindikasikan bahwa pendekatan berbasis fitur tekstur saja, meskipun cukup menjanjikan, masih memiliki keterbatasan dalam menangkap kompleksitas pola visual pada citra batik yang beragam.

Sebaliknya, model CNN menunjukkan performa tinggi dengan akurasi mencapai 98,6% dan nilai loss sebesar 0,0278, menunjukkan kemampuannya dalam mengekstraksi fitur visual secara efektif. Adapun model gabungan GLCM + CNN juga menunjukkan performa yang sangat baik dengan akurasi sebesar 98,03% dan nilai loss yang lebih rendah, yaitu 0,0079. Meskipun perbedaan akurasi antara model CNN dan model gabungan GLCM + CNN tidak terlalu signifikan, nilai loss

yang lebih kecil pada model hybrid mengindikasikan prediksi yang lebih stabil dan tingkat keyakinan yang lebih tinggi. Dengan demikian, model hybrid GLCM + CNN dapat disimpulkan sebagai pendekatan yang paling unggul dalam penelitian ini, karena mampu menggabungkan kekuatan fitur tekstur dan fitur visual dalam klasifikasi citra batik secara lebih optimal.

#### B. Evaluasi Model

Pada tahap ini, evaluasi dilakukan menggunakan data pengujian (testing) yang terpisah dari proses pelatihan untuk mengukur kemampuan generalisasi model terhadap citra batik yang belum pernah dilihat sebelumnya. Tabel berikut menyajikan nilai akurasi dan f1-score masing-masing kelas untuk ketiga model yang telah dibangun.

TABEL 3. HASIL EVALUASI MODEL PADA DATA TESTING

No	Model	Akurasi	F1-Score Kelas 0 (Jogja)	F1-Score Kelas 1 (Pekalongan)
1	GLCM (SVM)	76%	76%	76%
2	CNN	96,05%	96,10%	96%
3	GLCM + CNN	97%	97%	97%

Evaluasi akhir terhadap performa model dilakukan menggunakan data pengujian (testing) yang belum pernah dilihat oleh model sebelumnya. Hasil pengujian menunjukkan bahwa model GLCM murni yang menggunakan algoritma SVM menghasilkan akurasi sebesar 76%, dengan nilai f1-score yang seimbang untuk kedua kelas, yaitu 76% untuk kelas Batik Yogyakarta dan 76% untuk kelas Batik Pekalongan.

Sementara itu, model CNN murni menunjukkan performa yang jauh lebih baik dengan akurasi 96,05%, serta nilai f1-score sebesar 96,10% untuk kelas Yogyakarta dan 96% untuk kelas Pekalongan.

Menariknya, model gabungan GLCM + CNN justru memperoleh akurasi tertinggi sebesar 97% pada data testing, mengungguli model CNN murni dengan selisih 1%. Nilai f1-score untuk kedua kelas juga konsisten tinggi, yaitu 97% untuk masing-masing kelas. Temuan ini menunjukkan bahwa meskipun pada tahap validasi model CNN murni sempat menunjukkan kinerja sedikit lebih tinggi, integrasi fitur tekstur dari GLCM ke dalam arsitektur CNN pada akhirnya memberikan keuntungan tambahan dalam hal generalisasi terhadap data baru.

Secara keseluruhan, model gabungan terbukti memberikan hasil paling stabil dan akurat dalam mengklasifikasikan citra batik dari dua daerah berbeda, menjadikannya sebagai pendekatan yang paling efektif dalam studi ini.

Meskipun model gabungan GLCM + CNN menunjukkan performa akurasi tinggi (97%), masih terdapat beberapa kesalahan klasifikasi, khususnya pada motif batik dengan pola visual yang menyerupai antara Yogyakarta dan Pekalongan. Kesalahan umum terjadi pada motif batik Pekalongan yang

memiliki warna netral dan pola geometris, sehingga terkadang diklasifikasikan sebagai batik Yogyakarta. Hal ini menunjukkan bahwa model masih kesulitan dalam membedakan motif dengan ciri visual yang ambigu. Selain itu, model SVM berbasis GLCM menunjukkan akurasi paling rendah (76%) karena terbatas pada fitur tekstur saja dan tidak mempertimbangkan informasi spasial secara menyeluruh, menyebabkan overfitting pada pola tertentu dan kurang mampu melakukan generalisasi. Temuan ini menegaskan pentingnya penggabungan fitur tekstur dan visual untuk mengurangi kesalahan klasifikasi.

#### IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi motif batik Yogyakarta dan Pekalongan menggunakan pendekatan hibrida yang menggabungkan metode ekstraksi fitur tekstur Gray Level Co-occurrence Matrix (GLCM) dan arsitektur Convolutional Neural Network (CNN) berbasis EfficientNetB0. Dataset awal sebanyak 256 citra (125 batik Yogyakarta dan 131 batik Pekalongan) diperluas menjadi 759 citra melalui teknik augmentasi data yang sistematis.

Hasil pengujian menunjukkan bahwa model hibrida GLCM + CNN memberikan performa klasifikasi terbaik dengan akurasi sebesar 97% dan nilai *loss* yang lebih rendah dibandingkan model CNN murni. Secara spesifik, meskipun model CNN mencapai akurasi 96,05%, model gabungan tidak hanya unggul dalam akurasi tetapi juga memiliki *loss* lebih rendah (0,0079 dibanding 0,0278), menandakan prediksi yang lebih stabil dan tingkat kepercayaan yang lebih tinggi terhadap hasil klasifikasi. Hal ini menunjukkan bahwa integrasi GLCM memberikan kontribusi signifikan dengan menambahkan informasi tekstur mendalam yang tidak sepenuhnya ditangkap oleh CNN, terutama pada motif batik dengan pola kompleks dan detail halus.

Sementara itu, model GLCM yang dikombinasikan dengan SVM menghasilkan akurasi jauh lebih rendah, yaitu 76%, menunjukkan bahwa penggunaan fitur tekstur saja tanpa informasi spasial dari CNN tidak cukup untuk menangkap kompleksitas visual motif batik secara menyeluruh. Dengan demikian, keunggulan pendekatan gabungan GLCM + CNN terletak pada kemampuannya menyatukan kekuatan ekstraksi fitur tekstur (GLCM) dan fitur visual spasial (CNN) secara sinergis, sehingga menghasilkan model klasifikasi yang lebih akurat, stabil, dan andal.

Namun demikian, penelitian ini memiliki keterbatasan pada ukuran dataset dan cakupan jenis motif batik yang digunakan. Untuk pengembangan ke depan, disarankan memperluas dataset dengan menambahkan lebih banyak variasi motif dari berbagai daerah, serta mengeksplorasi teknik augmentasi lanjutan dan arsitektur model yang lebih kompleks guna meningkatkan kemampuan generalisasi model terhadap motif batik dengan tingkat kompleksitas yang lebih tinggi.

#### UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih yang sebesar-besarnya kepada dosen pengampu atas bimbingan dan arahnya selama proses penyusunan proyek akhir ini. Kami juga berterima kasih kepada seluruh tim penulis yang telah bekerja sama dalam pelaksanaan penelitian, mulai dari tahap perancangan,

pengolahan data, hingga analisis performa model GLCM (SVM), CNN, dan model gabungan (GLCM + CNN) untuk klasifikasi motif batik Yogyakarta dan Pekalongan. Semoga hasil penelitian ini dapat memberikan kontribusi positif bagi pengembangan teknologi pengenalan pola berbasis kecerdasan buatan dan dapat dikembangkan lebih lanjut di masa mendatang.

#### REFERENSI

- [1] W. Steelyana et al., "Batik, a beautiful cultural heritage that preserve culture and support economic development in indonesia," *Binus Business Review*, vol. 3, no. 1, p. 116, 2012.
- [2] R. A. Surya., A. Fadlil, dan A. Yudhana, "Ekstraksi Ciri Citra Batik Berdasarkan Tekstur Menggunakan Metode Gray Level Co Occurrence Matrix," dalam *Prosiding Annual Research Seminar 2016*, vol. 2, no. 1, Sulawesi Selatan, 2016, hlmn. 146-150.
- [3] A. Hardirega, I. Jaelani, dan Minarto, "Implementasi Convolutional Neural Network (CNN) Klasifikasi Motif Batik Menggunakan EfficientNet-B1," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 5, 5 Okt. 2024.
- [4] A. R. Dani., I. Handayani, "Klasifikasi Motif Batik Yogyakarta Menggunakan Metode Gcm Dan Cnn," *Jurnal Teknologi Terpadu*, vol. 10, no. 2, p. 142-156, 2024.
- [5] M. Tan dan Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *arXiv preprint arXiv:1905.11946*, 2019. [Daring].
- [6] F. R. Lestari dan F. W. Wibowo, "Klasifikasi Motif Batik Menggunakan Convolutional Neural Network (CNN) EfficientNet," *Jurnal Teknologi dan Sistem Komputer*, vol. 10, no. 4, hlm. 345-35
- [7] A. Gurunathan dan B. Krishnan, "A Hybrid CNN- GLCM Classifier for Detection and Grade Classification of Brain Tumor", *Research Square*, 2022.
- [8] D. Rohpadi et al., "Klasifikasi Citra Digital Berbasis Ekstraksi Ciri Berdasarkan Tekstur Menggunakan GLCM Dengan Algoritma K-Nearest Neighbor", *Jurnal Informatika*, hlm. 80-84, 2018.
- [9] D. Wijaya dan A. R. Widiarti, "Batik classification using KNN algorithm and GLCM features extraction", *E3S Web Conf - InCASST 2023*, vol. 2, 2024.
- [10] S. Chaitra et al, "Deep Learning Model for Image-Based Plant Diseases Detection on Edge Devices", *2021 6th International Conference for Convergence in Technology*, pp. 2-3, 2021.
- [11] D. H. Dionisius, "Indonesian Batik Motifs," *Kaggle*, [Online]. Available: <https://www.kaggle.com/datasets/dionisiusdh/indonesian-batik-motifs>.
- [12] H. B. Hendry, "Batik Nusantara - Batik Indonesia Dataset," *Kaggle*, [Online]. Available: <https://www.kaggle.com/datasets/hendryhb/batik-nusantara-batik-indonesia-dataset>.
- [13] H. Alikhsan, "Batik Motifs," *Kaggle*, [Online]. Available: <https://www.kaggle.com/datasets/hamdanielikhsan/batik-motifs>.